

doi:10.6041/j.issn.1000-1298.2023.05.025

# 基于 WGAN 和 MCA – MobileNet 的番茄叶片病害识别

王志强<sup>1,2</sup> 于雪莹<sup>1,2</sup> 杨晓婧<sup>1,2</sup> 兰玉彬<sup>2,3</sup> 金鑫宁<sup>1,2</sup> 马景余<sup>1,2</sup>(1. 山东理工大学计算机科学与技术学院, 淄博 255049; 2. 山东理工大学生态无人农场研究院, 淄博 255049;  
3. 山东理工大学农业工程与食品科学学院, 淄博 255049)

**摘要:** 针对番茄病害识别模型参数量大、计算成本高、准确率低等问题,本文提出一种基于多尺度特征融合和坐标注意力机制的轻量级网络(Multi-scale feature fusion and coordinate attention MobileNet, MCA – MobileNet)模型。采集10类番茄叶片图像,采用基于Wasserstein距离的生成对抗网络(Wasserstein generative adversarial networks, WGAN)进行数据增强,解决了样本数据不足和不均衡的问题,提高模型的泛化能力。在原始模型MobileNet – V2的基础上,引入改进后的多尺度特征融合模块对不同尺度的特征图进行特征提取,提高模型对不同尺度的适应性;将轻量型的坐标注意力机制模块(Coordinate attention, CA)嵌入倒置残差结构中,使模型更加关注叶片中的病害特征,提高对病害种类的识别准确率。试验结果表明,MCA – MobileNet对番茄叶片病害的识别准确率达到94.11%,较原始模型提高2.84个百分点,且参数量仅为原始模型的1/6。该方法较好地平衡了模型的识别准确率和计算成本,为番茄叶片病害的现场部署和实时检测提供了思路和技术支撑。

**关键词:** 番茄叶片病害; 深度学习; 生成对抗网络; 多尺度特征融合; 注意力机制中图分类号: S432.9<sup>+7</sup> 文献标识码: A 文章编号: 1000-1298(2023)05-0244-09

OSID:



## Tomato Leaf Diseases Recognition Based on WGAN and MCA – MobileNet

WANG Zhiqiang<sup>1,2</sup> YU Xueying<sup>1,2</sup> YANG Xiaojing<sup>1,2</sup> LAN Yubin<sup>2,3</sup> JIN Xinning<sup>1,2</sup> MA Jingyu<sup>1,2</sup>

(1. School of Computer Science and Technology, Shandong University of Technology, Zibo 255049, China

2. Ecological Unmanned Farm Research Institute, Shandong University of Technology, Zibo 255049, China

3. School of Agricultural Engineering and Food Science, Shandong University of Technology, Zibo 255049, China

**Abstract:** With the continuous development of smart agricultural technology, plant disease identification models are increasingly pursuing the goals of accuracy, efficiency, and light weight. Aiming at the problems of large number of parameters, high calculation cost and low accuracy in the current tomato disease recognition model, a lightweight network was proposed based on multi-scale feature fusion and coordinate attention mechanism (Multi-scale feature fusion and coordinate attention MobileNet, MCA – MobileNet) model. Totally ten types of tomato leaf images were collected, and Wasserstein generative adversarial networks (WGAN) based on Wasserstein distance for data enhancement was used, which solved the problem of insufficient and unbalanced sample data and improved the generalization ability of the model. On the basis of the original model MobileNet – V2, an improved multi-scale feature fusion module was introduced to extract features from feature maps of different scales to improve the adaptability of the model to different scales; the lightweight coordinate attention mechanism module (Coordinate attention, CA) embedded in the inverted residual structure, so that the model paid more attention to the disease characteristics in the leaves and improved the recognition accuracy of the disease types. The test results showed that the accuracy rate of MCA – MobileNet for identifying tomato leaf diseases reached 94.11%, which was 2.84 percentage points higher than that of the original model, and the number of parameters was only 1/6 of the original model. This method better balanced the recognition accuracy and calculation cost of the model, and provided ideas and technical support for field deployment and real-time detection of tomato leaf diseases.

**Key words:** tomato leaf disease; deep learning; WGAN; multi-scale feature fusion; coordinate attention

收稿日期: 2022-10-10 修回日期: 2023-02-16

基金项目: 山东省引进顶尖人才“一事一议”专项经费项目(鲁政办字[2018]27号)

作者简介: 王志强(1977—),男,教授,博士生导师,主要从事农业人工智能与大数据分析研究,E-mail: wzq@sdut.edu.cn

通信作者: 兰玉彬(1961—),男,教授,博士生导师,主要从事精准农业航空及农业人工智能研究,E-mail: ylan@sdut.edu.cn

## 0 引言

番茄在生长过程中易受多种病害的侵袭, 导致其产量和质量下降, 严重影响经济效益<sup>[1]</sup>。目前我国农作物病害总体仍处于严重发生状态, 因此病害的准确、快速防治对农业生产具有十分重要的作用<sup>[2–4]</sup>。

近年来, 深度学习技术在植物保护领域应用取得显著进展, 为农作物病虫害预防与治理工作提供了有力的技术支持。卷积神经网络 (Convolutional neural network, CNN) 不同于传统机器学习的人工特征提取, 采用端到端的结构进行自动提取, 提高了网络的识别速度和精度<sup>[5–7]</sup>。但目前大多数 CNN 通过增加网络层数的方法来提高模型性能, 牺牲大量的计算资源而获得高准确率, 容易导致训练速度慢、网络参数过多等问题, 超出了许多移动和嵌入式应用程序的能力。为使模型更好地应用于实际场景, 近年来相关研究都向轻量级网络的方向发展<sup>[8]</sup>。MobileNet–V1 是一种适合于移动端和嵌入式设备的轻量级网络<sup>[9]</sup>, 但该模型在对通道数较少的卷积层输出进行操作时, 易产生信息丢失。MobileNet–V2 提出一种倒置残差结构, 在一定程度上减少了信息丢失, 在减少模型参数量的同时不影响识别精度<sup>[10]</sup>。LIU 等<sup>[11]</sup>对 MobileNet–V2 进行优化训练, 实现了对垃圾数据集的准确分类, 模型参数量仅为  $1.4 \times 10^7$ 。

一方面, 由于不同种类的病害叶片图像中的病斑区域存在差异, 因此在卷积过程中选择适合的卷积核非常重要。病害全局性分布的图像适合较大的卷积核, 而病害局部分布的图像更适合较小的卷积核<sup>[12]</sup>。若将不同尺寸的卷积层进行简单堆叠, 不仅会加深网络深度, 还会耗费大量计算资源。为此, 部分学者提出采用多尺度特征融合模块对网络结构进行改进, 取得了一定效果<sup>[13–15]</sup>。另一方面, 病害识别模型在训练过程中常会受到叶脉、叶片轮廓等无关信息的干扰。增加注意力机制能够使模型判断出图像中的病害区域并投入更多注意, 从而较好地获取病害的特征信息, 提高对病害种类的分类能力<sup>[16]</sup>。传统的通道注意力机制<sup>[17]</sup>能够很好地关注每个通道之间的关系, 却忽略了同一通道不同位置的特征信息。混合注意力机制沿着通道和空间两个维度依次推断注意力, 同时兼顾了位置、空间两方面因素, 使模型能够更全面地进行特征提取, 但同时也大大增加了参数量和计算成本<sup>[18]</sup>。坐标注意力机制 (Coordinate attention, CA) 能够将位置信息嵌入到通道注意力中, 使其可以通过沿一个方向捕捉较

远距离的关系, 同时也能保证在另一方向上精确的位置信息。该机制结构简单, 即插即用, 几乎不会引入额外的计算量, 对改进轻量级网络有显著效果<sup>[19]</sup>。

深度学习网络模型的训练需要数量多且种类均衡的样本数据<sup>[20]</sup>, 但由于目前可采集的番茄病害图像有限, 因此一般采用数据增强方法对原始数据集进行扩充<sup>[21]</sup>。传统的数据增强方法包括随机翻转、提高对比度、添加噪声等, 但其生成的样本数据单一, 且与原始数据集区分度低。生成对抗网络 (Generative adversarial network, GAN) 是一种无监督学习方法<sup>[22]</sup>, 是目前实现生成图像任务应用最多的手段<sup>[23]</sup>。GAN 通过生成器和判别器之间的相互对抗, 生成与现实图像十分相似的样本图像, 从而达到丰富数据集的效果<sup>[24–26]</sup>。但传统 GAN 的损失函数定义不明确, 训练过程中损失值曲线不稳定, 易出现模式崩塌等问题。Wasserstein GAN (WGAN) 能在不改变 GAN 结构的基础上, 采用 Wasserstein 距离来度量真实样本分布和生成样本分布之间的差异, 相较于其他 GAN 模型具有更稳定、更丰富的图像生成能力<sup>[27]</sup>。

本文提出一种基于 WGAN 和 MCA–MobileNet 的番茄叶片病害识别模型。该模型以 MobileNet–V2 作为骨干网络, 引入改进的多尺度特征融合模块和坐标注意力机制模块, 在保证识别精度的同时, 减少模型训练的参数量, 降低计算成本。同时采用 WGAN 进行数据增强扩充样本数据, 使原始数据集的各类病害图像更均衡, 增强模型的鲁棒性, 使其满足移动端或嵌入式设备的需要。

## 1 材料与方法

### 1.1 试验数据集

将从 PlantVillage 收集的 10 类共 4 132 幅番茄叶片图像作为试验数据集, 典型样本示例如图 1 所示。其中, 花叶病毒图像 344 幅, 白粉病图像 428 幅, 褐斑病图像 496 幅, 红蜘蛛病毒图像 482 幅, 叶霉病图像 378 幅, 早疫病图像 348 幅, 斑枯病图像 408 幅, 黄化曲叶病毒图像 430 幅, 晚疫病 416 幅, 健康叶片图像 402 幅。

### 1.2 基于 WGAN 的数据增强

由于原始数据集存在样本图像数量少、种类不均衡等问题, 为防止深度模型在训练过程出现的过拟合现象, 本研究采用生成对抗网络进行数据增强。生成对抗网络 GAN 是一种由生成器和判别器两个网络组成的无监督模型。在训练过程中, 生成器的目标是生成尽可能真的图像去欺骗判别器, 判别器

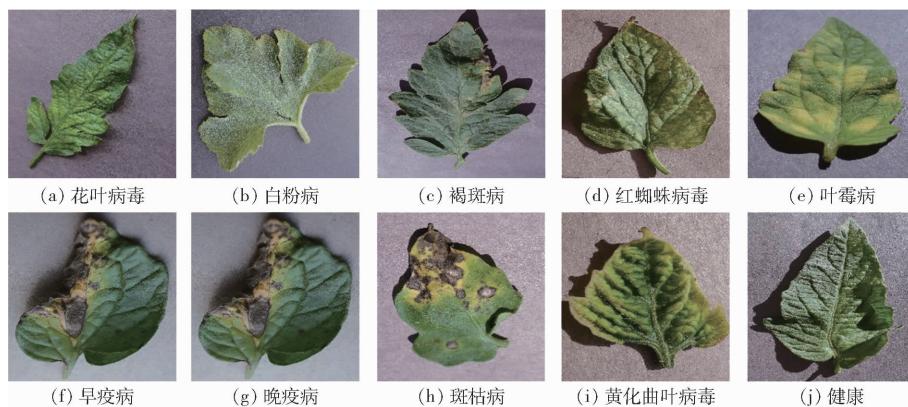


图 1 番茄叶片图像

Fig. 1 Tomato leaf images

的目标是把生成样本和真实样本区分开。生成器和判别器通过相互对抗,最终使模型达到纳什平衡。GAN 的训练目标为最小化真实数据分布与合成数据分布之间的 JS 散度。但根据 JS 散度的性质可知,如果两个样本分布几乎没有重叠时,会出现梯度为 0 的现象,导致训练时出现梯度消失。

WGAN 通过采用 Wasserstein 距离来度量真实样本分布和生成样本分布之间的差异,这样能够保证即便两个分布没有重叠,Wasserstein 距离仍然能够反映它们的远近。WGAN 模型具体结构及参数设置如图 2 所示。其中,对生成器输入随机噪声  $z$ ,然后分别经过 5 个反卷积层 (Conv2DTranspose) 和 4 个批归一化层 (Batch normalization, BN),激活函数采用 Leaky ReLU,然后将得到的图像数据输入到判别器中,分别经过 5 个卷积层 (Conv2D) 和 4 个批归一化层,激活函数同样采用 Leaky ReLU,并由 Flatten 层将数据进行一维化,最后由 Dense 层输出判别结果。

### 1.3 MobileNet – V2

MobileNet 是一种轻量级 CNN,被广泛应用于移

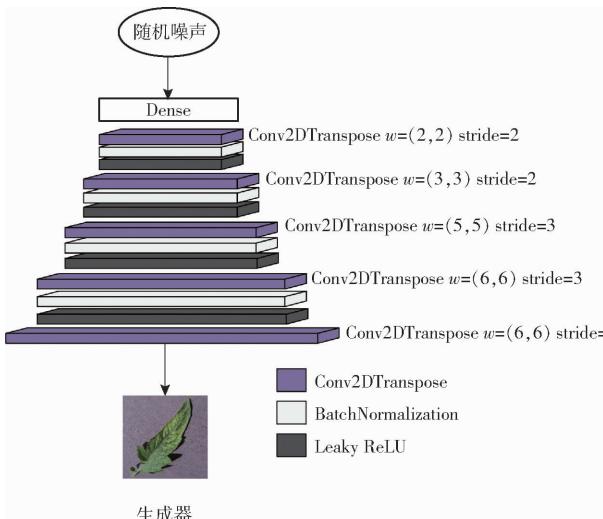


图 2 WGAN 模型及参数设置

Fig. 2 WGAN model and parameter settings

动端或者嵌入式设备。MobileNet – V1 采用的深度可分离卷积结构能够在准确率基本保持不变的前提下,有效减少模型的参数量,但只是深度可分离卷积的堆叠。同时,其采用的非线性激活函数 ReLU 在对通道数较少的卷积层输出进行操作时,易产生信息丢失的问题。MobileNet – V2 借鉴残差网络的思想,在模型中添加一种具有线性瓶颈的倒置残差结构 (The inverted residual with linear bottleneck),可以很大程度上缓解网络退化问题,相比于 MobileNet – V1 准确率更高,模型更小,进一步提高了网络性能。

本文模型采用的倒置残差结构如图 3 所示,首先采用  $1 \times 1$  的卷积核进行逐点卷积 (Pointwise convolution, PW) 升维,然后采用  $3 \times 3$  的深度卷积 (Depthwise convolution, DW),最后采用  $1 \times 1$  的 PW 卷积降维。因为此时的深度卷积只针对一个通道进行,所以计算量不会过高。当步长等于 2 时,输入和输出的特征矩阵通道数不相等,因此不需要 shortcut 连接。

### 1.4 MCA – MobileNet 模型设计

#### 1.4.1 改进的多尺度特征融合模块

传统卷积操作每一层使用的卷积核大小都是一

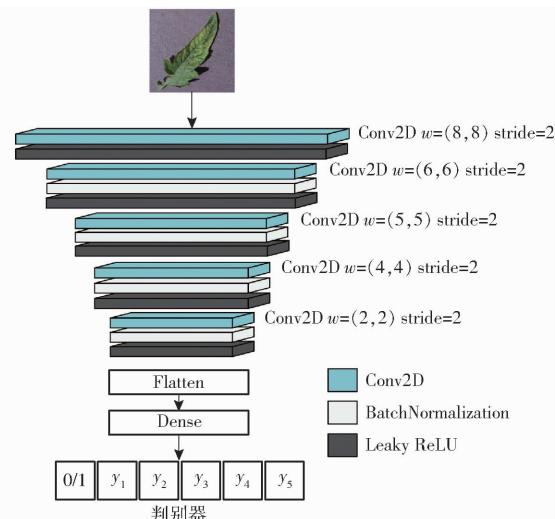


图 2 WGAN 模型及参数设置

Fig. 2 WGAN model and parameter settings

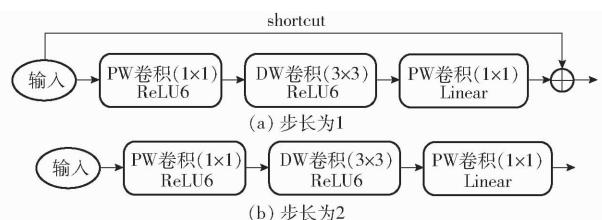


图3 两种步长情况下的瓶颈结构图

Fig. 3 Diagram of bottleneck structure in two step

致的,因此输出的每一个神经元在前一层接受的视野也是一致的。Inception结构通过采用不同尺寸的卷积核对特征图进行卷积操作,得到不同尺寸的新特征图,同时采用最大池化操作降低过拟合,最后对不同的特征图进行拼接融合,结构如图4a所示。本文对上述Inception结构进行改进,提出改进后的Bottleneck-D模块,通过采用步长为2的瓶颈结构对标准卷积进行替换,并采用 $1 \times 1$ 卷积进行降维,最后采用特征图相加的方式代替拼接,结构如图4b所示。该结构能有效减少模型的参数量,进一步增强了模型的表达能力。

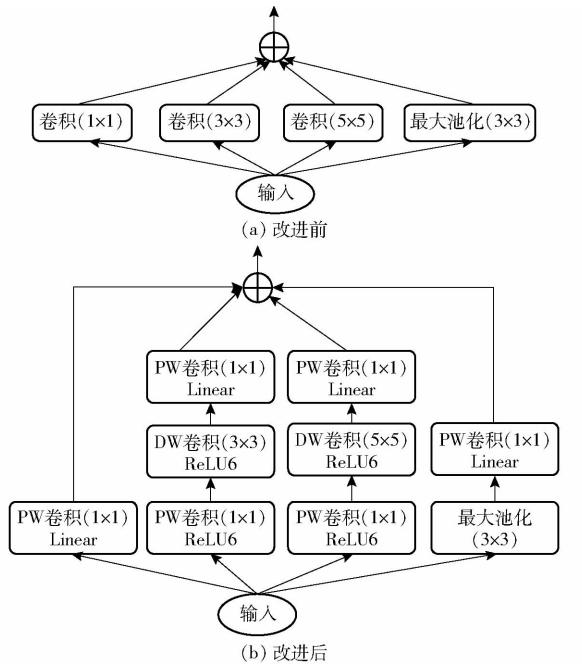


图4 改进前后多尺度特征融合模块对比

Fig. 4 Comparison diagrams of multi-scale feature fusion module before and after improvement

#### 1.4.2 坐标注意力机制

传统的通道注意力机制忽略了同一通道不同位置的特征信息,本研究通过采用坐标注意力机制(CA),将通道注意力分解为两个并行的编码操作,然后进行信息融合,实现了将位置信息嵌入到通道注意力中,能够准确突出特征图中的感兴趣区域,同时有效减少了模型的计算成本,结构如图5所示。

将全局池化拆分成两个平均池化操作,即沿水平方向X轴和垂直方向Y轴分别对每个通道进行编码,得到高度为h和宽度为w的第c个通道的输出计算公式为

$$z_c^{(h)}(h) = \frac{1}{W} \sum_{0 \leq i \leq W} x_c(h, i) \quad (1)$$

$$z_c^{(w)}(w) = \frac{1}{H} \sum_{0 \leq j \leq H} x_c(j, w) \quad (2)$$

式中  $H, W$ —特征图的高度、宽度

将上述获得的具有全局感受野和精确位置编码信息的特征图进行拼接,然后采用 $1 \times 1$ 卷积变换函数 $F_1$ 降维,再通过归一化和非线性激活函数来编码水平和垂直方向的空间信息,得到中间特征映射公式为

$$f = \delta(F_1([z^{(h)}, z^{(w)}])) \quad (3)$$

$$f \in R^{\frac{C}{r}(H+W)} \quad (4)$$

式中  $\delta$ —非线性激活函数

$r$ —比例系数  $R$ —注意力空间

再将 $f$ 沿空间维度拆分为 $f^{(h)} \in R^{\frac{CH}{r}}$ 和 $f^{(w)} \in R^{\frac{CW}{r}}$ ,并分别通过 $1 \times 1$ 卷积变换 $F_h$ 和 $F_w$ ,得到与输入一致的通道数为

$$g^{(h)} = \sigma(F_h(f^{(h)})) \quad (5)$$

$$g^{(w)} = \sigma(F_w(f^{(w)})) \quad (6)$$

式中  $\sigma$ —sigmoid 函数

将 $g^{(h)}$ 和 $g^{(w)}$ 进行维度扩展后得到两个注意力权重,再通过与原特征的信息融合,最终计算得到坐标注意力模块的输出 $y$ 公式为

$$y_c(i, j) = x_c(i, j) g_c^{(h)}(i) g_c^{(w)}(j) \quad (7)$$

将CA嵌入到倒置残差结构中,得到改进后的

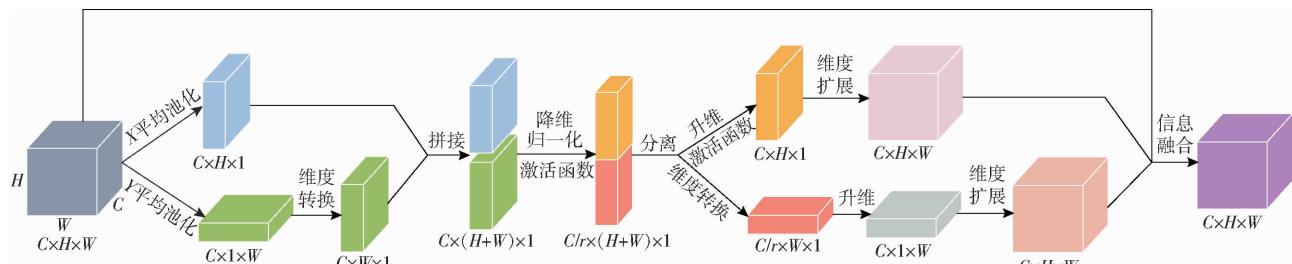


图5 坐标注意力机制结构图

Fig. 5 CA structure diagram

注意力模块 Bottleneck - A, 结构如图 6 所示。

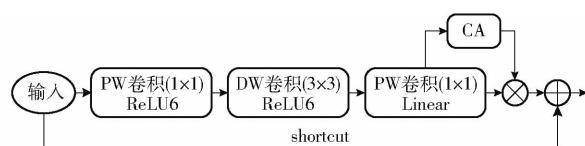


图 6 Bottleneck - A 结构图

Fig. 6 Bottleneck – A structure diagram

### 1.4.3 模型搭建

本文模型 MCA – MobileNet 是以 MobileNet – V2

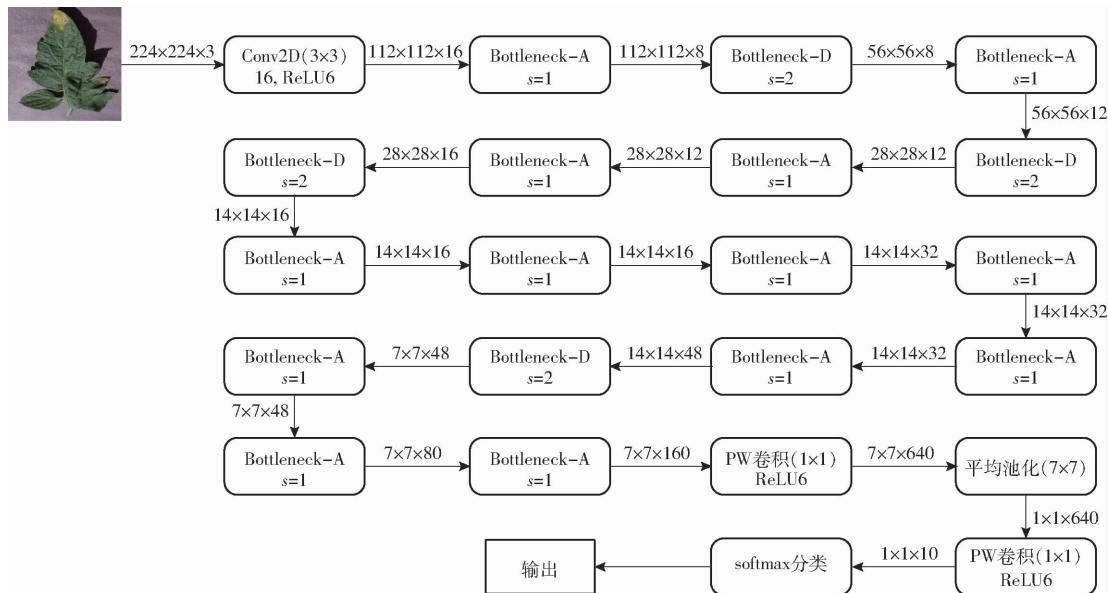


图 7 MCA – MobileNet 模型结构图

Fig. 7 MCA – MobileNet model structure diagram

## 2 试验结果与分析

## 2.1 试验环境

试验均在 64 位的 Windows 10 操作系统上进行, 使用 Python 语言调用 keras 框架实现网络的构建、训练和测试。服务器配置 16 GB 内存的 AMD Ryzen 5 - 3600 CPU(6 核处理器)和 6 GB 显存的 Nvidia GeForce GTX 1660 Ti GPU。

## 2.2 超参数设置

由于超参数的设置会对模型性能和识别准确率产生影响,试验分别使用 Adam、SGD 和 Nadam 优化器,对解决计算效率低、所需内存多等问题具有明显优势,3 种优化算法试验选取模型的迭代次数为 50 次,学习率为 0.0001,批量大小为 15。

## 2.3 评价指标

采用准确率、精准率、召回率、F1 值、参数量、浮点计算数和推理速度作为分类指标对不同模型进行评估。

## 2.4 数据增强试验

为有效扩充样本数据,增强模型的鲁棒性和检

为主干网络，并通过引入改进的多尺度特征融合模块 Bottleneck - D 和坐标注意力机制模块 Bottleneck - A，得到改进后的模型结构如图 7 所示。图中，首先输入图像尺寸为  $224 \times 224 \times 3$ ，然后经过一个  $3 \times 3$  卷积，再经过多个 Bottleneck - A 和 Bottleneck - D 模块，能够在保证识别准确率的同时减小模型规模，最后经过 2 个  $1 \times 1$  卷积和平均池化层后，最后通过 Softmax 层对 10 类番茄叶片图像进行分类，得到输出结果。

表 1 数据增强前后图像数量  
Table 1 Comparison of number of images before  
and after data enhancement

类型	增强前图像数量	增强后图像数量
花叶病毒(MV)	172	1 588
白粉病(PM)	214	2 960
褐斑病(TLS)	248	2 852
红蜘蛛病毒(SM)	241	1 752
叶霉病(LM)	189	1 691
早疫病(EB)	174	2 504
斑枯病(SLS)	204	1 617
黄化曲叶病毒(YLCV)	215	1 840
晚疫病(LB)	208	1 692
健康(H)	201	1 870

以数据集前 5 种病害为例, 样本图像示例及损失值曲线如图 8 所示。由图可知, 试验生成的图像

十分接近原始数据集的病害图像,且各类病害间特征差异明显,为模型识别不同种类的病害提供了良

好的图像数据。WGAN 训练过程中有时不稳定,会生成含有少量噪声的图像,但不影响总体的图像效果。

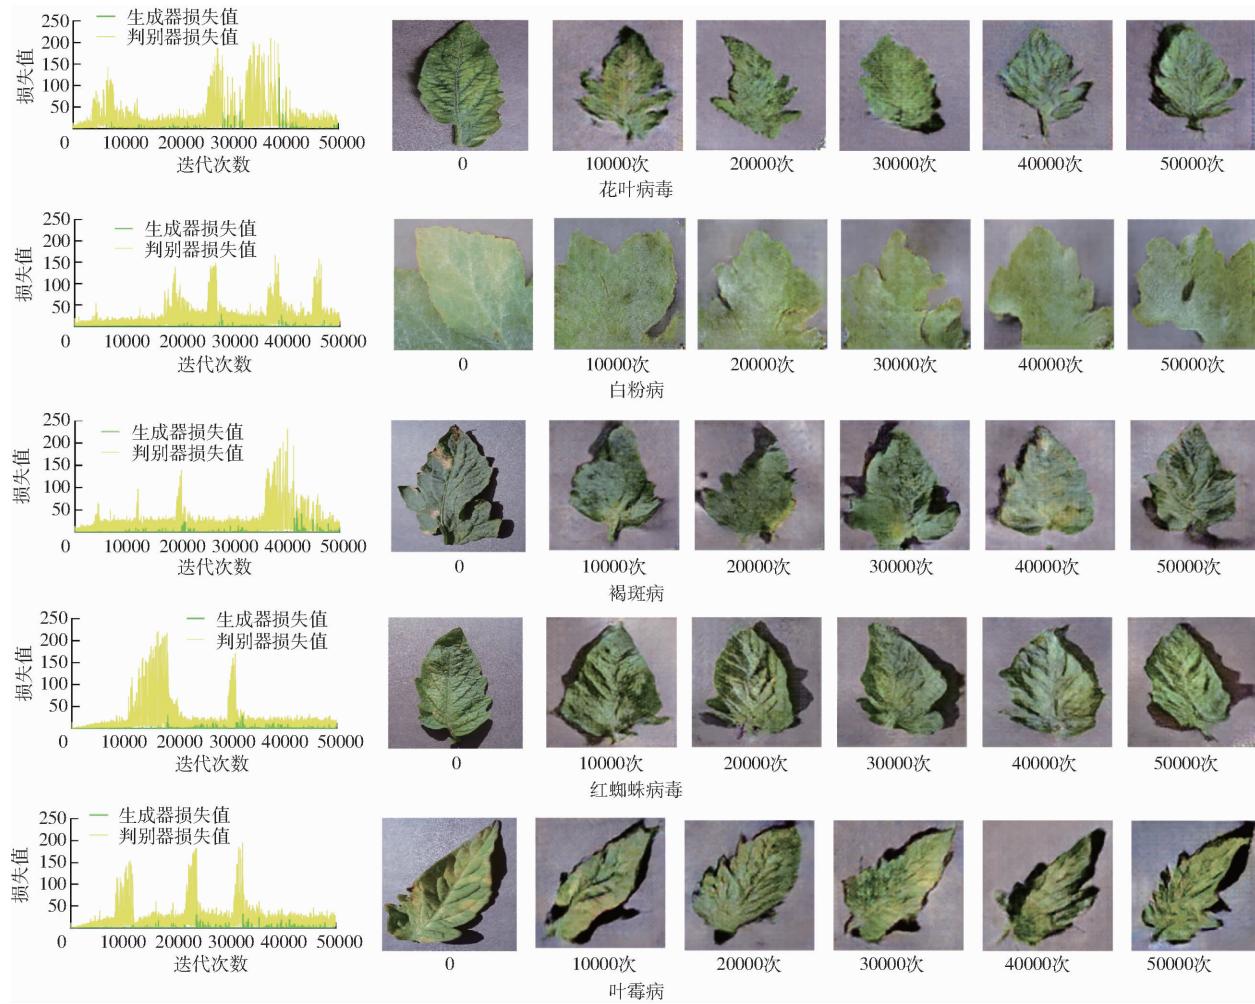


图 8 WGAN 生成的病害图像和损失值曲线

Fig. 8 Disease image and loss curve generated by WGAN

为验证数据增强对各类病害精度的影响,分别采用不同的数据集对模型进行试验,结果如图 9 所示。结果表明,9 种病害和健康叶片的识别准确率分别较原模型提升 0.53~5.47 个百分点。利用十折交叉验证计算模型平均准确率,将测试集划分成 10 份,取每份测试集准确率的平均值作为平均准确率。结果表明,数据增强后模型平均准确率由

90.57% 提升至 94.11%, 较数据增强前提升 3.54 个百分点,说明数据增强后的模型对各类病害的识别准确率更高,识别效果更好,并提升了模型鲁棒性。

## 2.5 消融试验

为证明本研究的改进算法可提高模型性能,分别对两种改进算法进行消融试验,共组合为 5 种模型。

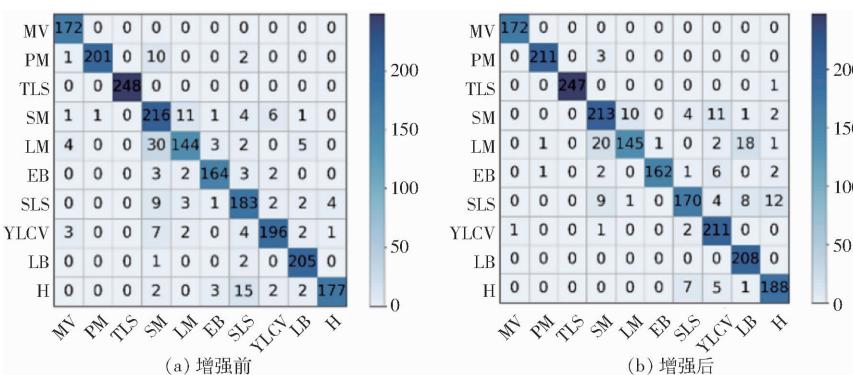


图 9 数据增强对模型影响的混淆矩阵对比

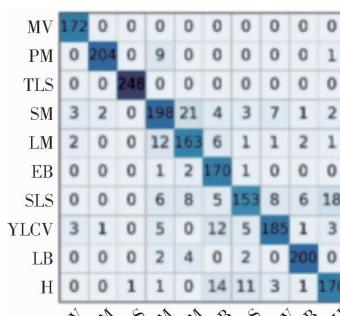
Fig. 9 Confusion matrix comparison charts of impact of data enhancement on model

其中,主干网络均选择 MobileNet - V2,且均采用经过 WGAN 数据增强后的番茄叶片图像作为数据集,结果如表 2 所示,表中“√”表示采用了改进算法。

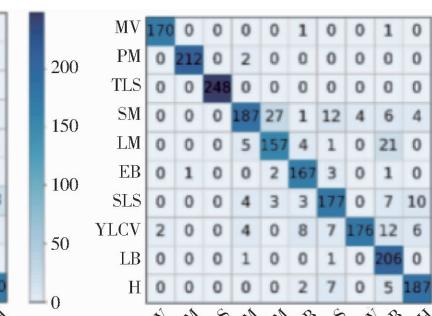
表 2 消融试验结果

Tab. 2 Comparison of results of test

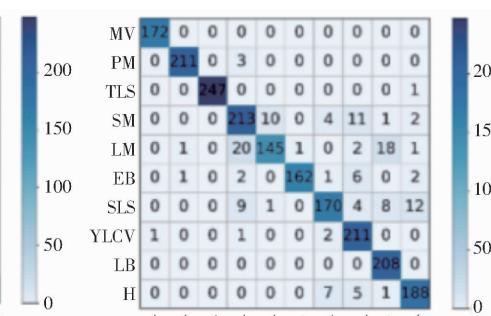
模型 编号	影响因素		准确率/%	参数量
	多尺度卷积	注意力机制		
1		√	90.21	$2.76 \times 10^6$
2	Inception	√	91.38	$2.30 \times 10^6$
3	√		91.00	$2.11 \times 10^6$
4	√	SE	92.90	$1.78 \times 10^6$
5	√	CBAM	93.12	$1.69 \times 10^6$
6	√	√	94.11	$7.50 \times 10^5$



(a) 模型1



(b) 模型2

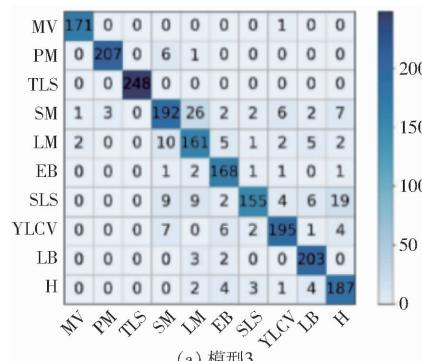


(c) 模型6

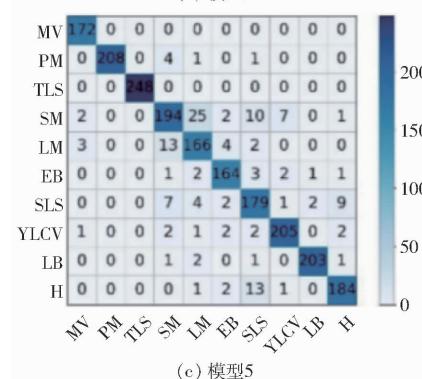
图 10 采用不同的多尺度特征融合模块得到的混淆矩阵

Fig. 10 Confusion matrix obtained by using different multiscale feature fusion modules

在原始模型 MobileNet - V2 的网络层之间通过不添加注意力机制和分别添加 SE、CBAM 和 CA 模块得到的模型 3 ~ 6 进行对比试验,得到准确率分别为



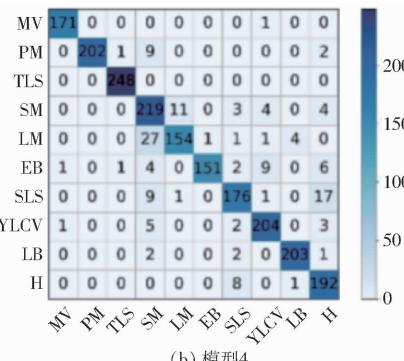
(a) 模型3



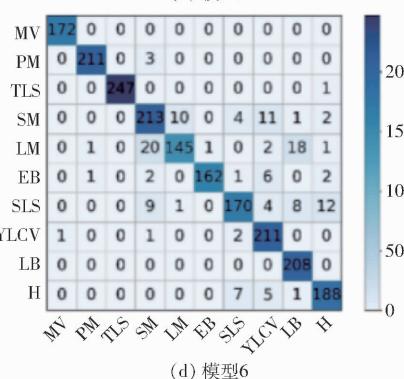
(c) 模型5

为验证在 MobileNet - V2 中引入改进的多尺度特征融合模块的有效性,试验分别采用不引入多尺度模块的模型 1,引入未改进的 Inception 多尺度模块模型 2 与本文模型 6 进行对比试验,得到准确率分别为 90.21%、91.38%、94.11%,测试集混淆矩阵如图 10 所示。由图可知,引入本文改进多尺度特征融合模块 Bottleneck - D 的模型对识别番茄叶片病害具有更优的效果,各类病害的误判率更低,因此验证了 Bottleneck - D 的有效性,能够提高模型的识别能力。

为验证在 MobileNet - V2 中引入改进后的坐标注意力机制模块在提升模型性能方面的优势,分别



(b) 模型4



(d) 模型6

图 11 采用不同的注意力机制模块得到的混淆矩阵

Fig. 11 Confusion matrix obtained by using different attention mechanism modules

中的病害特征,且对每一类病害的分类效果都较好,因此验证了 Bottleneck - A 的有效性,能够使模型更准确地识别病害的种类,从而提升模型性能。

## 2.6 与传统网络的对比试验

为验证改进模型 MCA - MobileNet 的识别能力,将其与 5 种传统模型 AlexNet、VGG - 16、Inception - V3、ResNet - 50 和 MobileNet - V2 进行对比试验,验证集准确率变化曲线如图 12 所示。由图可知,MCA - MobileNet 对番茄叶片病害的识别率更高,且在训练 30 次时基本达到收敛状态,曲线相较于其他传统模型更平稳,振荡幅度更小,训练过程更稳定,鲁棒性较好。

表 3 不同网络模型分类识别性能对比

Tab. 3 Comparison of classification recognition performance of different network models

模型	准确率/%	精准率/%	召回率/%	F1 值/%	参数量	浮点运算数/GFLOPs	推理速度/(f·s <sup>-1</sup> )
AlexNet	86.77	89	87	87	$5.04 \times 10^9$	4.79	20.4
VGG - 16	88.20	90	89	89	$1.081 \times 10^{11}$	4.27	25.2
Inception - V3	89.13	91	91	90	$3.25 \times 10^8$	2.14	23.6
ResNet - 50	89.86	90	89	89	$2.631 \times 10^8$	3.26	21.5
MobileNet - V2	91.27	91	92	92	$4.60 \times 10^6$	0.51	35.2
MCA - MobileNet	94.11	94	94	94	$7.50 \times 10^5$	0.24	42.4

3 ~ 5 个百分点,召回率分别提高 2 ~ 7 个百分点,F1 值分别提高 2 ~ 7 个百分点,参数量分别减少  $3.85 \times 1.0^6 \sim 1.0735 \times 10^8$ ,浮点运算数分别减小 0.27 ~ 4.55 GFLOPs,推理速度分别提高 7.2 ~ 22 f/s。

## 3 结论

(1) 将改进的多尺度特征融合模块和坐标注意力机制模块引入 MobileNet - V2 中,得到试验模型 MCA - MobileNet,使其能更集中于番茄叶片中的病斑信息,同时大大减少了模型的参数量。

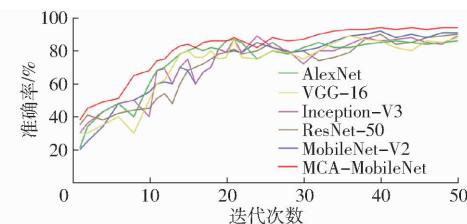


图 12 不同模型在验证集的准确率变化曲线

Fig. 12 Accuracy change curves of different models in validation set

对上述模型的准确率、召回率、参数量和处理速度等指标进行统计,结果如表 3 所示。由表可知,MCA - MobileNet 相比于其他 5 种传统模型,准确率分别提高 2.84 ~ 7.34 个百分点,精确率分别提高

(2) 采用 WGAN 进行数据增强能够对样本数据进行扩充,解决了原始样本数据不足、不均衡的问题,并且采用增强后的数据集进行试验有效提高了模型识别的准确率,增强了模型的鲁棒性。

(3) 相较于传统网络,MCA - MobileNet 在准确率、精准率、召回率、F1 值上均有提升,分别达到 94.11%、94%、94%、94%,模型训练的参数量仅为  $7.5 \times 10^5$ ,降低了参数内存,对识别番茄叶片病害具有更平稳的收敛过程和更出色的性能,可应用于移动式或嵌入式设备。

## 参 考 文 献

- [1] 李君明,项朝阳,王孝宣,等.“十三五”我国番茄产业现状及展望[J].中国蔬菜,2021(2):13~20.  
LI Junming, XIANG Chaoyang, WANG Xiaoxuan, et al. Current situation of tomato industry in China during “The Thirteenth Five-year Plan” period and future prospect[J]. China Vegetable, 2021(2):13~20. (in Chinese)
- [2] 贾兆红,张袁源,王海涛,等.基于 Res2Net 和双线性注意力的番茄病害时期识别方法[J].农业机械学报,2022,53(7):259~266.  
JIA Zhaozhong, ZHANG Yuanyuan, WANG Haitao, et al. Identification method of tomato disease period based on Res2Net and bilinear attention mechanism[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(7): 259~266. (in Chinese)
- [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.  
Zhai Zhaoyu, CAO Yifei, XU Huanliang, et al. Review of key techniques for crop disease and pest detection[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(7): 1~18. (in Chinese)
- [4] 杨英茹,吴华瑞,张燕,等.基于复杂环境的番茄叶部图像病虫害识别[J].中国农机化学报,2021,42(9):177~186.  
YANG Yingru, WU Huarui, ZHANG Yan, et al. Tomato disease recognition using leaf image based on complex environment [J]. Journal of Chinese Agricultural Mechanization, 2021, 42(9): 177~186. (in Chinese)
- [5] 王军敏,樊养余,李祖贺.基于深度卷积神经网络和迁移学习的纹理图像识别[J].计算机辅助设计与图形学学报,2022,34(5):701~710.  
WANG Junmin, FAN Yangyu, LI Zuhe. Texture image recognition based on deep convolution neural network and transfer

- learning[J]. Journal of Computer-Aided Design & Computer Graphics, 2022, 34(5): 701–710. (in Chinese)
- [6] 蓝金辉, 王迪, 申小盼. 卷积神经网络在视觉图像检测的研究进展[J]. 仪器仪表学报, 2020, 41(4): 167–182.  
LAN Jinhui, WANG Di, SHEN Xiaopan. Research progress on visual image detection based on convolutional neural network [J]. Chinese Journal of Scientific Instrument, 2020, 41(4): 167–182. (in Chinese)
- [7] 张军锋, 尚展垒. 基于深度学习卷积神经网络的花生籽粒完整性检测[J]. 食品与机械, 2022, 38(5): 24–29, 36.  
ZHANG Junfeng, SHANG Zhanlei. Peanut kernel integrity detection based on deep learning convolution neural network [J]. Food & Machinery, 2022, 38(5): 24–29, 36. (in Chinese)
- [8] WANG L, ZHAN Y, LIU S, et al. Precision detection of dense polums in orchards using the improved YOLOv4 model [J]. Frontiers in Plant Science, 2022, 13:839269.
- [9] HOWARD A G, ZHU M, CHEN B, et al. MobileNets: efficient convolutional neural networks for mobile vision applications [J]. arXiv preprint, arXiv 1704:04861, 2017.
- [10] SANDLER M, HOWARD A G, ZHU M, et al. MobileNetV2: inverted residuals and linear bottlenecks[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 4510–4520.
- [11] LIU X, ZHI Z W, ZI J W, et al. Lightweight neural network based garbage image classification using a deep mutual learning [C]// Parallel Architectures, Algorithms and Programming: 11th International Symposium. Springer Singapore, 2021: 212–223.
- [12] 黄林生, 罗耀武, 杨小冬, 等. 基于注意力机制和多尺度残差网络的农作物病害识别[J]. 农业机械学报, 2021, 52(10): 264–271.  
HUANG Linsheng, LUO Yaowu, YANG Xiaodong, et al. Crop disease recognition based on attention mechanism and multi-scale residual network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(10): 264–271. (in Chinese)
- [13] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]// 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2015: 1–9.
- [14] 刘芳, 刘玉坤, 林森, 等. 基于改进型 YOLO 的复杂环境下番茄果实快速识别方法[J]. 农业机械学报, 2020, 51(6): 229–237.  
LIU Fang, LIU Yukun, LIN Sen, et al. Fast recognition method for tomatoes under complex environments based on improved YOLO[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(6): 229–237. (in Chinese)
- [15] 毛力, 张艺楠, 孙俊. 融合注意力与时域多尺度卷积的手势识别算法[J]. 计算机应用研究, 2022, 39(7): 2196–2202.  
MAO Li, ZHANG Yinan, SUN Jun. Gesture recognition algorithm combining attention and time-domain multiscale convolution [J]. Application Research of Computer, 2022, 39(7): 2196–2202. (in Chinese)
- [16] 宋宇鹏, 边继龙, 安翔, 等. 基于注意力机制的 DenseNet 模型的树种识别应用[J]. 实验室研究与探索, 2020, 39(7): 122–127, 173.  
SONG Yupeng, BIAN Jilong, AN Xiang, et al. Application of tree species identification based on DenseNet model with attention mechanism[J]. Research and Exploration in Laboratory, 2020, 39(7): 122–127, 173. (in Chinese)
- [17] JIE H, LI S, SAMUEL A, et al. Squeeze-and-excitation networks[J]. arXiv preprint, arXiv 1709:01507, 2017.
- [18] 王立舒, 秦铭霞, 雷洁雅, 等. 基于改进 YOLOv4-Tiny 的蓝莓成熟度识别方法[J]. 农业工程学报, 2021, 37(18): 170–178.  
WANG Lishu, QIN Mingxia, LEI Jieya, et al. Blueberry maturity recognition method based on improved YOLOv4-Tiny[J]. Transactions of the CSAE, 2021, 37(18): 170–178. (in Chinese)
- [19] 孙俊, 朱伟栋, 罗元秋, 等. 基于改进 MobileNet-V2 的田间农作物叶片病害识别[J]. 农业工程学报, 2021, 37(22): 161–169.  
SUN Jun, ZHU Weidong, LUO Yuanqiu, et al. Recognizing the diseases of crop leaves in fields using improved MobileNet-V2[J]. Transactions of the CSAE, 2021, 37(22): 161–169. (in Chinese)
- [20] TANG H, GAO S, WANG L, et al. A novel intelligent fault diagnosis method for rolling bearings based on Wasserstein generative adversarial network and convolutional neural network under unbalanced dataset[J]. Sensors, 2021, 21(20): 6754.
- [21] WANG S, MINKU L L, YAO X. Resampling-based ensemble methods for online class imbalance learning [J]. IEEE Transactions on Knowledge & Data Engineering, 2015, 27(5): 1356–1368.
- [22] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks [J]. Advances in Neural Information Processing Systems, 2014, 3: 2672–2680.
- [23] 邓博, 贺春林, 徐黎明, 等. 生成对抗网络文字生成图像算法综述[J]. 计算机工程与应用, 2022, 58(23): 42–55.  
DENG Bo, HE Chunlin, XU Liming, et al. Text-to-image synthesis: survey of state-of-the-art[J]. Computer Engineering and Applications, 2022, 58(23): 42–55. (in Chinese)
- [24] XIAO D, ZENG R, LIU Y, et al. Citrus greening disease recognition algorithm based on classification network using TRL-GAN[J]. Computers and Electronics in Agriculture, 2022, 200: 107206.
- [25] 何敏, 邱圆, 易小平, 等. 基于 MD-CGAN 的脑部肿瘤图像生成方法研究[J]. 湖南大学学报(自然科学版), 2022, 49(8): 179–185.  
HE Min, QIU Yuan, YI Xiaoping, et al. Research on brain tumor image generation method based on MD-CGAN[J]. Journal of Hunan University(Natural Sciences), 2022, 49(8): 179–185. (in Chinese)
- [26] DEWI C, CHEN R C, LIU Y T, et al. YOLO V4 for advanced traffic sign recognition with synthetic training data generated by various GAN[J]. IEEE Access, 2021, 9:97228–97242.
- [27] ARJOVSKY M, CHINTALA S, BOTTOU L. Wasserstein GAN[J]. arXiv preprint, arXiv 1701:07875, 2017.