doi:10.6041/j.issn.1000-1298.2020.08.022

基于多层 EESP 深度学习模型的农作物病虫害识别方法

宋余庆1谢 熹1刘 哲1 邹小波2

(1. 江苏大学计算机科学与通信工程学院, 镇江 212013; 2. 江苏大学食品与生物工程学院, 镇江 212013)

摘要:为了提取图像高层语义特征、解决各种植物病虫害图像尺寸不相同的问题,提出了多层次增强高效空间金字塔(Extremely efficient spatial pyramid, EESP)卷积深度学习模型。首先,对图像进行预处理;其次,构建多层融合EESP网络模型,该模型通过对每层设置不同的空洞率进行空洞卷积,选择性地提取不同层次的特征信息,通过融合各层信息获得各种农作物病虫害图像的不同特征;最后,通过Softmax分类方法实现农作物病虫害识别。数据集包括10种农作物的61种病虫害类别,迭代训练300次,得到本文方法Top1分类准确率最高达到了88.4%,且采用三阶 EESP 模型达到了最佳效果。

关键词:农作物病虫害;深度学习;卷积神经网络;空间金字塔结构 中图分类号:TP391.41 文献标识码:A 文章编号:1000-1298(2020)08-0196-07 **O**



Crop Pests and Diseases Recognition Method Based on Multi-level EESP Model

SONG Yuqing¹ XIE Xi¹ LIU Zhe¹ ZOU Xiaobo²

(1. School of Computer Science and Telecommunication Engineering, Jiangsu University, Zhenjiang 212013, China
 2. School of Food and Biological Engineering, Jiangsu University, Zhenjiang 212013, China)

Abstract: With the rapid development of Internet of Things and artificial intelligence, the detection and treatment of crop diseases are gradually developing towards intelligence. Using computer vision methods to identify crop diseases accurately and efficiently was of great significance to ensure the normal growth of crops. In order to extract the high-level semantic features of images and solve the problem of different image sizes of various plant diseases and insect pests, a multi-level extremely efficient spatial pyramid (EESP) model based on deep learning was proposed. Firstly, the image was preprocessed, and then the proposed model was constructed. In order to extract characteristic information of different scales, the cavity ratio was different in each layer. By integrating the information of each layer, different characteristics of various crop pest images were obtained. Finally, crop pests and diseases were identified through image classification method. The data set included 61 pests and disease categories of 10 crops. After 300 epochs training, the experiments showed that the Top1 accuracy of the proposed model reached 88. 4%, which was effectively improved by about 3 percentage points compared with that of traditional methods, and it was found that using the three-layer EESP model can obtain the best effect. It had certain practical value and can be applied in actual scenarios.

Key words: crop pests and diseases; deep learning; convolution neural network; spatial pyramid structure

0 引言

我国是农业大国,农业是国民经济的基础。我 国农作物种类较多、种植范围较广,仅依靠人工方式 对病虫害进行管理消耗大量人力^[1]。只有对各种 农作物病虫害进行及时诊断和预防,才能确保农业 生产的丰收^[2]。

近年来,随着科学技术的迅速发展,计算机视觉

收稿日期: 2019-11-14 修回日期: 2020-02-10

基金项目:中国博士后科学基金项目(2017M611737)和国家自然科学基金面上项目(61772242、61572239)

作者简介: 宋余庆(1959—),男,教授,博士生导师,主要从事图像处理与分析和数据挖掘与模式识别研究,E-mail: yqsong@ ujs. edu. cn 通信作者: 刘哲(1982—),女,副教授,博士生导师,主要从事图像处理与数据挖掘研究,E-mail: lzhe@ ujs. edu. cn

197

研究取得了极大的进步,国内逐渐将其应用到农业 生产上。谢春燕等[3]利用光谱和图像之间的关系 设计了图像和光谱信息融合的病虫害叶片检测系 统,基本做到了无损检测与识别。随着深度学习的 快速发展,图像分类任务的精度得到了较大提 升^[4-5]。最早提出的 LeNet - 5^[6] 用于 MNIST 数据 集分类,取得了较高的准确率,随后又提出了 AlexNet^[7], GoogleNet^[8], $VGG^{[9]}$, ResNet^[10], DenseNet^[11]、CSPNet^[12]等模型,在图像分类^[7]上准 确率得到进一步提升。深度学习方法也逐渐应用于 农作物病虫害检测研究中,ZHANG等^[13]利用 VGG-16 模型对不同时期病菌感染的苹果叶片进行分类, 准确率达到 90.4%。YANG 等^[14]提出基于深度卷 积神经网络的模型,对水稻病叶进行识别,精度达到 了 95.48%。由此看出,深度学习方法能够快速从 大规模数据集中学习到需要进行分类任务的特征. 使计算机视觉任务能够获得更高的效率和精度。本 文提出通过多层次网络模型深度学习方法来提高农 作物病虫害的识别率。

1 相关理论

1.1 空洞卷积

空洞卷积(Dilated/atrous convolution),也叫膨 胀卷积,是在标准的卷积核里面注入空洞,以此来增 加感受野^[15]。相比一般的卷积操作,空洞卷积多了 一个超参数称为空洞率,指卷积核中每个元素之间 的间隔数量,传统的空洞卷积操作如图1所示。



图 1a 为空洞率为1 的 3 × 3 卷积。图 1b 为空 洞率为2 的 3 × 3 卷积,实际的卷积核还是 3 × 3,但 是空洞数为1,也就是对于一个7 × 7 的图像,只有 其中9 个红色的点和 3 × 3 的卷积核进行卷积操作, 其余点忽略。可以看到虽然卷积核为 3 × 3,但感受 野已经增大到了7 × 7。图 1c 是空洞率为4 的卷积 操作,在空洞率为1 和空洞率为2 的卷积后面,能达 到 15 × 15 的感受野。对比传统的卷积操作,3 个步 长为1 的 3 × 3 卷积操作叠加起来只能达到 7 × 7 的 感受野,随着卷积数量的线性增长,空洞卷积的感受 野呈指数级增长。

1.2 深度可分离卷积

传统卷积是同时考虑区域和通道的,而在可分 离卷积中,可将区域和通道分开计算,先进行卷积计 算,再进行通道数转换^[16],如图2所示。比如,假设 一个 *n*×*n* 的滤波器,其输入通道数为*c*,输出通道 数为*c*'。传统卷积的参数量为*n*²*cc*',而采用可分离 卷积,参数量仅需*n*²*c*+*cc*' = (*n*²+*c*')*c*,随着输出通 道数增多,参数量增长趋势变慢。



2 基于 EESP 模型的农作物病虫害识别过程

本研究基于深度学习方法对农作物病虫害图像 进行分类识别,首先加载数据集,对数据进行预处 理,然后将图像送入构建的多层 EESP 网络进行训 练,进行多层次特征提取,最后通过 Softmax 函数对 获取到的特征进行病虫害种类识别。基本流程如图 3 所示,其中,*P_n*表示预测为第*n*种病虫害的概率。



Fig. 3 Flow chart of the proposed method

2.1 基于重采样的数据预处理

目前,大多数分类数据集包含较多的类别,且每 个类别包含的样本数量各不相同,少则几乎没有,多 则几千幅图像,如图4所示。

样本不平衡会带来过拟合等一系列问题^[17],另 外训练集和验证集不同类别样本分布几乎一致,因



Fig. 4 Sample distribution for each category of dataset

此进行重采样非常有必要。

为了解决样本不平衡问题,可剔除样本数量过 少的类别。对于剩余类别,进行样本重采样处理,具 体算法如下:

输入:D: 病虫害数据集;

c: 类别数

输出:L:列表

计算类别 i 的样本数量,取平均数下界 S_{avg} ;

for i = 1 : c do:

if $i < = S_{avg}$:

为类别 i 生成一个长度为 S_{avg} 的随机排列的列表 L_i ;

用列表 L_i 中的 id 值对对应类别的数量 S_i 取余,获得对应的索引值;

根据索引值找到对应的图像;

将第 i 类的列表添加到总列表 L 中.

end if

end for

对L做一个随机排序,得到最后的图像列表. return L

图 5 为重采样算法的一个案例。通过重采样算法的预处理,解决了不同类别之间样本不均衡的问题,同时保证了数据集不会过大,处理后的数据集分布如图 6 所示。

2.2 基于多层特征融合的网络模型

2.2.1 ESP 和 EESP 模块

高效空间金字塔 (Efficient spatial pyramid,





Fig. 6 Sample distribution of dataset after resampling

ESP) 卷积模块最早由 MEHTA 等^[18] 在 2018 年提 出,最开始用于图像的语义分割。不过由于它具备 很好的拓展性和鲁棒性,经过改进之后在计算机视 觉的其它任务中也获得很多应用,具体结构如图 7a 所示。ESP 模块基本步骤如下:①对 M 维的输入特 征使用 $d \uparrow M \times 1 \times 1$ 的卷积核,将特征降至 d 维。 ②使用 $k \uparrow 不同膨胀率的卷积核对步骤①输出的特$ $征进行卷积,得到 <math>k \uparrow 大小相同的特征图。③对上$ $一层输出的 <math>k \uparrow 特征图按一定规则进行拼接和融$ 合,得到最终的输出。

为了使计算更加高效,MEHTA 等^[19]又提出了 增强高效空间金字塔(EESP)卷积模块,如图 7b 所 示,对 ESP 模块做了如下改进:①将 ESP 的 pointwise 卷积层替换为 group point-wise 卷积层。②将 ESP 的传统空洞卷积层替换为 depth-wise 空洞卷积 层。③在 ESP 步骤③之后使用一个 group point-wise 卷积层来学习输入层之间的线性组合。

与 ESP 相比, EESP 可以减少许多参数, 从而很 大程度上提高效率。

图 7 中, Conv 表示传统的可分离卷积操作, DConv - *k* 表示空洞率为 *k* 的空洞卷积, DDConv - *k*







图 7 ESP、EESP 模块结构 Fig. 7 Structure of ESP and EESP

2.2.2 多层次 EESP 模型的结构

EESP 模块显著提升了视觉任务的效率,但是由 于各种植物的病虫害区域及尺寸各不相同,单一的 EESP 模块在农业病虫害数据集上并不能很好地进 行分类,所以考虑使用多层 EESP 模块,将它们的输 出堆叠到一起进行分类,能显著提升分类的准确率。

为了解决图像的尺度不平衡问题,本文采用多 层 EESP 模型进行分类,如图 8 所示,其中 *p_i*(*i*=1, 2,…,5)为对应层特征图的尺寸。

原图经过预处理后通过一个步长为2的卷积, 先进入第1层 EESP 组合模块(EESP-1),它由5个 EESP 模块串联构成,EESP-1中每个 EESP 模块的 空洞卷积的空洞率依次设为1、2、3、…,可以保证在 一个块内提取比较细小的病虫害特征。第5个 EESP 模块处理完成后,进行一次下采样操作,执行 步长为2的平均池化操作。为了增强图像病虫害区 域的原始特征信息,将它的输出和经过3×3平均池 化操作(步长为2)的原图进行叠加操作,再将叠加 的结果作为输入进入第2层 EESP 组合模块(EESP-2),以此类推,直到第5层 EESP 组合模块(EESP-5)处理完成。模型各层的参数设定如表1所示(输 入图像为224 像素×224 像素)。

5 层 EESP 组合模块都处理完成之后,将每层叠 加的结果进行全局平均池化,进行层级拼接操作。 层级之间的拼接原则如下:一阶 EESP:选取最后一





层处理之后特征。二阶 EESP:选取第4 层和第5 层 处理之后特征。三阶 EESP:选取第3、4、5 层处理之 后特征。四阶 EESP:选取第2、3、4、5 层处理之后特 征。五阶 EESP:选取5 个层处理之后特征。

每层特征提取出来之后,各自进行一次池化操作,池化层的卷积核根据对应层特征图的尺寸进行 选择,确保池化之后得到的特征图尺寸为1×1。然 后把各层的特征进行拼接(Concat)操作,之后再进 行分类。这样能够保证不同尺寸的病虫害区域被识 别并正确分类,从而显著提高分类精度。

2.3 算法实现

多层 EESP 模型的训练算法如下:

- 输入:I: 病虫害图像
 - n:输出层数
- 输出:θ:网络参数
 - θ : 初始化参数

表1 多层 EESP 模型各层参数

Tab. 1 Parameters for each layer of multi-level

EESP model				
	输出图像尺寸/	重复	输出	
云	(像素×像素)	次数	通道数	
3×3 Convolution	112 × 112	1	16	
EESP	112×112	4	16	
EESP + Avg. Pooling	56×56	1	32	
EESP	56×56	4	32	
EESP + Avg. Pooling	28×28	1	64	
EESP	28×28	4	64	
EESP + Avg. Pooling	14×14	1	128	
EESP	14×14	4	128	
EESP + Avg. Pooling	7×7	1	256	
EESP	7×7	4	256	
EESP + Avg. Pooling	4×4	1	512	
全连接层		1	59	

for i = 1:5 do:

分配 EESP 模块空洞卷积的空洞率: *i*, *i*+1,

```
i + 2, \dots;
```

 if *i* > 5 - n: 进行池化及特征拼接操作;
 计算每幅图像的类别得分;
 和真实类别对比,计算损失函数 L(θ);
 使用随机梯度下降算法更新梯度 θ^{t+1} = θ^t -

 $\lambda \nabla_{\theta^t} L(\theta^t);$

end for return θ

3 实验结果与分析

3.1 数据集与实验环境

采用的数据集来自 AI Challenger 2018 (https:// challenger.ai/competition/pdr2018),按照物种-病害-程 度分类,包含 10 个物种,共 61 个病虫害。带标签的 数据包含 32 768 幅训练集图像和4 992 幅验证集图 像。表 2 展示了部分植物不同程度的病虫害图像。

使用该数据集 59 个类别(去除第 44、45 类), 共计 32 766 幅图像进行训练。采用 Pytorch 框架进 行实现,在 2 块 NVIDIA GTX 2080Ti 显卡上进行实 验,并使用 CUDA9.0 和 cuDNN 作为支持。

3.2 实验

3.2.1 模型参数设置

目前训练网络模型的方式有多种,包括所有网络的权重随机初始化生成,也可以使用在其他网络 上预训练的网络权重参数。本文选择在 ImageNet^[20]上训练好的权重参数进行初始化,采用 和 ESPNetv2^[19]相同的训练方式,每次迭代的学习率 η,计算公式为

表 2 部分植物不同程度病虫害图像 Tab. 2 Images of different crop diseases in several plants

病虫害类别	健康	一般	严重
苹果雪松锈病			
櫻桃白粉病		The second second	
玉米灰斑病			alli
玉米锈病			
马铃薯早疫病			P
草莓叶枯病			

 $\eta_t = \eta_{\max} - (t \mod T) \eta_{\min}$ (1) 式中 t——迭代次数 η_{\min} ——学习率的下界

 η_{max} ——学习率的上界

T——循环周期 mod——求余操作函数 取 $\eta_{min} = 0.1, \eta_{max} = 0.5, T = 5$ 。网络的 Batch size 设 置为 256, 迭代次数设置为 300, 每 50 次迭代后学习 率减半。例如, 第 128 次迭代的学习率为 0.05。通 过优化交叉熵损失函数来训练得到最优模型。

$$L_{oss}(x, y, w) = -\sum_{n=1}^{N} \sum_{i=1}^{C} (y_{ni} lgf_{ni}(x) + \lambda R(w_n))$$
(2)

其中

$$R(w_n) = \sum_{j}^{j} \| w_j \|$$

 $f_{ni}(x) = \frac{\mathrm{e}^{x_i}}{\sum \mathrm{e}^{x_i}}$

式中 *f_{ni}*(*x*)——经过 Softmax 函数处理后的分类 向量中的第*i*项

- x_i——预测分类向量中的第 i 项元素
- x;——预测分类向量中的第 j 项元素
- y_{ni}——指示标量,指示第 i 个样本预测的类别,将该类对应的值标识为1,其余标识为0

%

N——样本数量 w_j ——第j个预测分类向量的权重向量 $R(w_n)$ ——L2 正则项 C——类别数量 λ ——自定义常量,设为 4×10^{-5}

3.2.2 评价指标

该模型在4992 幅验证集图像上进行测试(同 样去除对应的第44、45类)。采用图像分类任务里 面常用的 Top1 和 Top5 评价指标进行模型评价。 Top1 指取最后输出的概率向量中概率最大的类别 作为预测类别,如果和真实类别一致则预测正确,否 则预测错误;Top5 指取最后概率向量中最大的前5 个概率的类别,其中只要包含了真实类别即为预测 正确。

3.3 实验结果分析

对一阶和三阶 EESP 结构模型进行比较,训练 损失如图 9 所示。从图中可以看出,三阶 EESP 模 型损失下降得更快,因为三阶 EESP 模型从 3 个不 同的 EESP 进行输出,融合了不同尺度下的特征,使 得不同农作物病虫害特征更加丰富,分类更加准确。 另外,在经过 200 次迭代后,由于加入了 L2 正则项, 损失变得逐渐平缓,模型趋于稳定,所以训练后期的 曲线会出现一定的波动。



各模型的测试准确率见表3。从表3中可以发现,三阶 EESP 的模型分类效果最佳,即把第3、4、5 层处理之后的特征叠加起来能获得最佳的特征。主 要原因是不同层能够提取不同分辨率的病虫害图像

汞 5

Tab. 3 Testing accuracy of models of different levels

		%
模型	Top1	Top5
一阶 EESP	85.3	99.5
二阶 EESP	87.1	99.6
三阶 EESP	88.1	99.7
四阶 EESP	88.3	99.5
五阶 EESP	88.4	99.6

特征,小的特征在前面的层得以保留,大的特征在后面的层更加明显,不同层的特征拼接之后能够进行 准确分类。不过并不是层数越多就越好,可以看到 四阶和五阶 EESP 模型得到的准确率和三阶模型非 常接近,原因是从低层 EESP 模块提取到的病虫害 区域特征不明显,将特征拼接之后对分类的帮助并 不大,准确率提升并不显著,反而增加了模型的复杂 度。

另外,比较各阶模型在不同迭代次数下的准确 率,如图 10 所示。可以看出,针对任意阶 EESP 模型,随着训练迭代次数的增加准确率不断提高,在 300 次后趋于平稳,因此选择迭代次数为 300。



表 4 为传统分类网络^[24]结果比较,发现使用多 层 EESP 结构之后 Top1 准确率明显提升,Top5 依然 稳定在较高水平,这说明使用不同分辨率的空洞卷 积对特征提取有较大的帮助。

表 4 传统分类网络测试准确率 Tab. 4 Testing accuracy of classical models

8	······	
网络模型	Top1	Top5
VGG - 16 ^[9]	85.9	99. 7
$ResNet = V1 = 101^{[10]}$	84. 7	99.6
$ResNet = V2 = 101^{[21]}$	85.7	99.8
Inception – $V4^{[22]}$	85.7	99.5
Inception – ResNet – $V2^{[22]}$	86. 1	99.6
$MobileNet-V1^{[23]}$	85.0	99. 7

4 结论

(1)基于多层特征融合,结合空洞卷积理论构 建多层 EESP 模型,提出了基于多层特征融合的农 作物病虫害识别方法,实现了对农作物病虫害图像 的精确分类,Top1 分类准确率最高达到 88.4%。

(2)通过与传统网络模型进行比较,结果表明, 本文方法对农作物病虫害图像的分类效果提升较为 明显。

参考文献

ZHANG Fang. Research on crop disease detection system based on computer vision[D]. Xi'an: Shaanxi University of Science and Technology, 2013. (in Chinese)

- [2] 杨舒广.农作物科学种植及病虫害防治技术浅析[J].农家参谋, 2019(19):139.
 YANG Shuguang. Analysis on crop science planting and pest control technology[J]. The Farmers Consultant, 2019(19): 139. (in Chinese)
- [3] 谢春燕,吴达科,王朝勇,等. 基于图像和光谱信息融合的病虫害叶片检测系统[J/OL]. 农业机械学报,2013,44(增刊 1):269-272.

XIE Chunyan, WU Dake, WANG Chaoyong, et al. Insect pest leaf detection system based on information fusion of image and spectrum [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2013,44(Supp. 1):269 - 272. http://www.j-csam.org/jcsam/ch/reader/view_abstract. aspx? file_no = 2013S148&flag = 1. DOI:10.6041/j. issn. 1000-1298. 2019. S0. 048. (in Chinese)

[4] 贾少鹏,高红菊,杭潇.基于深度学习的农作物病虫害图像识别技术研究进展[J/OL].农业机械学报,2019,50(增刊): 313-317.

JIA Shaopeng, GAO Hongju, HANG Xiao. Research progress on image recognition technology of crop pests and diseases based on deep learning[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(Supp.): 313 – 317. http: //www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? file_no = 2019S048&flag = 1. DOI: 10.6041/j. issn. 1000-1298. 2019. S0.048. (in Chinese)

- [5] 汪京京,张武,刘连忠,等. 农作物病虫害图像识别技术的研究综述[J]. 计算机工程与科学,2014,36(7):1363-1370.
 WANG Jingjing, ZHANG Wu, LIU Lianzhong, et al. Summary of crop diseases and pests image recognition technology[J].
 Computer Engineering & Science, 2014,36(7):1363-1370. (in Chinese)
- [6] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition [J]. Proceedings of the IEEE, 1998, 86(11):2278-2324.
- [7] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks [J]. Advances in Neural Information Processing Systems, 2012, 25(2): 1097 - 1105.
- [8] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015: 1-9.
- [9] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [J]. arXiv Preprint arXiv: 1409.1556, 2014.
- [10] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770 - 778.
- [11] IANDOLA F, MOSKEWICZ M, KARAYEV S, et al. DenseNet: implementing efficient convNet descriptor pyramids [J]. arXiv Preprint arXiv: 1404.1869,2014.
- [12] WANG C Y, LIAO H Y M, YEH I H, et al. CSPNet: a new backbone that can enhance learning capability of CNN[J]. arXiv Preprint arXiv:1911.11929,2019.
- [13] ZHANG K, GUO Y R, WANG X S, et al. Multiple feature reweight Dense Net for image classification [J]. IEEE Access, 2019, 7:9872-9880.
- [14] YANG L, YI S J, YONG Z, et al. Identification of rice diseases using deep convolutional neural networks [J]. Neurocomputing, 2017, 267:378-384.
- [15] YU F, KOLTUN V. Multi-scale context aggregation by dilated convolutions[J]. arXiv Preprint arXiv: 1511.07122, 2015.
- [16] CHOLLET F. Xception: deep learning with depthwiseseparable convolutions [C] //2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, HI, 2017: 1800 – 1807.
- [17] 曹鹏.不均衡数据分类方法的研究[D]. 沈阳:东北大学,2014.
 CAO Peng. Research on unbalanced data classification method[D]. Shenyang: Northeastern University, 2014. (in Chinese)
- [18] MEHTA S, RASTEGARI M, CASPI A, et al. ESPNet: efficient spatialpyramid of dilated convolutions for semantic segmentation [C] // In ECCV, 2018.
- [19] MEHTA S, RASTEGARI M, SHAPIRO L, et al. ESPNetv2: alight-weight, power efficient, and general purpose convolutional neural network[J]. arXiv Preprint arXiv: 1811.11431v3, 2018.
- [20] RUSSAKOVSKY O, DENG J, SU H, et al. ImageNet: large scale visual recognition challenge [J]. arXiv Preprint arXiv: 1409.0575, 2014.
- [21] HE K M, ZHANG X Y, REN S Q, et al. Identity mappings in deep residual networks [C] // Proceedings of the 14th European Conference on Computer Vision. Heidelberg: Springer Verlag, 2016: 630-645.
- [22] SZEGEDY C, IOFFE S, VANHOUCKE V, et al. Inception V4, inception ResNet and the impact of residual connections on learning[C] // Proceedings of the 31st AAAI Conference on Artificial Intelligence, 2017: 4278 - 4284.
- [23] HOWARD A G, ZHU M, CHEN B, et al. MobileNets: efficient convolutional neural networks for mobile vision applications [C] // In CVPR, 2017.
- [24] 魏超,范自柱,张泓,等. 基于深度学习的农作物病害检测[J]. 江苏大学学报(自然科学版),2019,40(2):190-196.
 WEI Chao, FAN Zizhu, ZHANG Hong, et al. Crop disease detection based on deep learning[J]. Journal of Jiangsu University (Natural Science Edition), 2019,40(2):190-196. (in Chinese)