

文章编号: 2095-2163(2024)03-0203-04

中图分类号: TP391

文献标志码: A

基于改进 EfficientNet 的花椒虫害识别模型

黄诗锐¹, 王天一¹, 李论¹, 蒋宁²

(1 贵州大学 大数据与信息工程学院, 贵阳 550025; 2 贵州玄德花椒产业发展有限公司, 贵阳 550018)

摘要: 花椒虫害会导致花椒生长异常、产量下降和品质恶化。为及时准确地发现花椒虫害,本文提出了一种基于 EfficientNet 的花椒虫害识别模型。通过实验对比 GoogleNet、MobileNetV2、MobileNetV3、ShuffleNetV2、EfficientNet 等深度学习网络,选取识别效果最好的 EfficientNet 网络构建花椒虫害识别模型,并通过改进 MBConv 模块提高模型的准确率。实验结果表明,改进后的模型准确率为 94%,相比原始的 EfficientNet 网络提高了 2%。本文提出的基于 EfficientNet 的花椒虫害识别模型具有较好的检测效果,能够应用于实际花椒地场景,对花椒虫害的监测和防治提供了有效的工具。

关键词: 花椒; 虫害识别; EfficientNet; 空间注意力机制; 网络

Zanthoxylum bungeanum maxim plant diseases and insect pests identification model based on improved EfficientNet

HUANG Shirui¹, WANG Tianyi¹, LI Lun¹, JIANG Ning²

(1 College of Big Data and Information Engineering, Guizhou University, Guiyang 550025, China);

2 Guizhou Xuande Zanthoxylum Bungeanum Maxim Industry Development Co., Ltd., Guiyang 550018, China)

Abstract: Plant diseases and insect pests' infestation of zanthoxylum bungeanum maxim can lead to abnormal growth, decreased yield, and deterioration of quality. To timely and accurately detect zanthoxylum bungeanum maxim plant diseases and insect pests, this paper proposes a zanthoxylum bungeanum maxim plant diseases and insect pests' identification model based on EfficientNet. By comparing deep learning networks such as GoogleNet, MobileNetV2, MobileNetV3, ShuffleNetV2, and EfficientNet through experiments, the most effective EfficientNet network is selected to construct a zanthoxylum bungeanum maxim plant diseases and insect pests recognition model, and the accuracy of the model is improved by improving the MBConv module. The experimental results show that the improved model has an accuracy of 94%, which is 2% higher than the original EfficientNet network. The identification model of zanthoxylum bungeanum maxim plant diseases and insect pests based on EfficientNet proposed in this article has good detection performance and can be applied to actual zanthoxylum bungeanum maxim field scenes, providing an effective tool for monitoring and controlling zanthoxylum bungeanum maxim plant diseases and insect pests.

Key words: zanthoxylum bungeanum maxim plant; diseases and insect pests identification; EfficientNet; spatial attention mechanism; network

0 引言

花椒是中国传统经济树种,种植面积为 2 300 多万亩,是世界花椒第一生产大国,在维护生态系统平衡、发展乡村特色产业、巩固脱贫攻坚成果、丰富公众饮食感受等方面发挥着重要作用。近年来,贵州省委、省政府将花椒、竹、油茶、皂角等列作为特色林业产业,作为贵州省 12 个农业特色优势产业之

一,为省内经济增长带来新的亮点^[1]。然而,随着栽培面积的扩大,花椒树易受虫害影响也在扩大,防治难度逐年增加^[2],造成花椒产量和品质下降,直接限制了花椒产品及其加工品的出口创汇。因此,构建一种高效、准确、智能化的花椒虫害识别方法,通过智能化技术对花椒虫害进行识别,对椒农及时准确的防治花椒虫害有着十分重要的促进作用。

随着图像处理技术的发展,许多学者采用深度

基金项目: 贵州省科技计划项目(黔科合支撑[2021]一般 176)。

作者简介: 黄诗锐(1999-),男,硕士研究生,主要研究方向:图像处理、深度学习;李论(1984-),男,博士,讲师,主要研究方向:生物视觉、视觉神经网络、计算机视觉、人工智能和大数据科学与技术等。

通讯作者: 王天一(1989-),男,博士,副教授,主要研究方向:量子通信、深度学习、大数据与人工智能等。Email: tywang@gzu.edu.cn

收稿日期: 2023-12-22

学习算法对农业虫害进行识别检测。邹修国^[3]、Liu等学者^[4]采用卷积神经网络对水稻虫害进行识别。孙鹏等学者^[5]对传统的卷积神经网络加以改进,其模型能够有效识别大豆蚜虫。杨国国等学者^[6]采用 AlexNet 架构的卷积神经网络,完成了茶园虫害识别。江顺等学者^[7]改进了 AlexNet 网络模型,对6类水稻害虫进行了有效识别。赵康迪等学者^[8]提出基于实例分割的卷积神经网络虫害检测方法,对玉米地虫害进行检测。上述研究通过使用深度学习算法对各类虫害进行识别检测,已经取得了不错的成果,但针对花椒类虫害的识别方法还缺少相关研究。

因此,本文使用 EfficientNet-B0^[9]网络作为主干网络搭建花椒虫害识别模型,通过改进 MBConv 模块并与其它深度学习算法进行对比实验研究,对被虫害侵扰的花椒与健康的花椒实现精准分类,并应用于实际花椒种植生产场景中。

1 材料与方法

1.1 试验数据

由于缺少关于花椒虫害的公开数据集,本文实验所用数据通过网络爬取获得,针对危害花椒的蚜虫和红蜘蛛等主要虫害,在百度图片上对其图像进行爬取。经过去重等预处理操作后,选取250张花椒图片作为数据集,将数据集分为健康与虫害两类图像进行实验。数据集部分图像如图1所示。



(a) 虫害



(b) 健康

图1 花椒虫害数据集

Fig. 1 Data set of the prickly pepper pest

1.2 EfficientNet 网络结构

EfficientNet-B0 网络结构见表1, EfficientNet-B0 的网络结构由9个层级组成。其中, F_i 表示对应层级的运算操作, L_i 表示在该层级中堆叠 F_i 的次数, H_i 和 W_i 表示输入特征矩阵的高度和宽度, C_i 表示通过该层级后输出特征矩阵的通道数。

表1 EfficientNet-B0 网络结构

Table 1 EfficientNet-B0 network structure

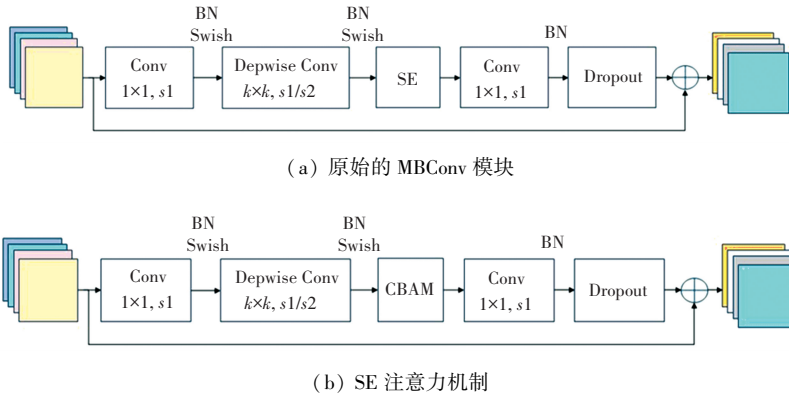
层级 i	运算操作 F_i	分辨率 $H_i \times W_i$	通道数 C_i	堆叠次数 L_i
1	Conv3×3	224×224	32	1
2	MBConv1, $k3 \times 3$	112×112	16	1
3	MBConv6, $k3 \times 3$	112×112	24	2
4	MBConv6, $k5 \times 5$	56×56	40	2
5	MBConv6, $k3 \times 3$	28×28	80	3
6	MBConv6, $k5 \times 5$	14×14	112	3
7	MBConv6, $k5 \times 5$	14×14	192	4
8	MBConv6, $k3 \times 3$	7×7	320	1
9	Conv1×1 & Pooling&FC	7×7	1 280	1

第一层级是一个卷积核大小为 3×3 的卷积层; 2~8 层级都在重复堆叠 MBConv 模块; 最后一层由一个 1×1 的卷积层、一个平均池化层和一个全连接层组成。在表1中, MBConv 模块后面的1或6为倍率因子 n ^[10], 表示 MBConv 模块中第一个 1×1 的卷积层会将输入矩阵的通道数扩充为 n 倍。 $k3 \times 3$ 或 $k5 \times 5$ 表示 MBConv 模块中深度卷积 (Depthwise Conv)^[11] 所采用的卷积核大小。

1.3 MBConv 模块

MBConv 模块如图2所示, 原始的 MBConv 模块先使用一个卷积核大小为 1×1 的普通卷积进行升维操作, 然后经过 BN 标准化^[12] 和 Swish 激活函数^[13] 后, 使用一个 $k \times k$ 的深度卷积 (k 的取值见表1) 进一步提取特征。其次, 使用 SE (Squeeze-and-Excitation)^[14] 注意力机制调整特征图中通道的权重, 提高模型的表达能力; 此后, 再使用一个卷积核大小为 1×1 的普通卷积进行降维操作; 最后, 使用 dropout 操作^[15], 降低模型的复杂度和计算量, 防止过拟合, 提高模型的效率和泛化能力。

SE 注意力机制虽然能够自适应地调整特征图中通道的权重, 但却忽略了空间信息。因此, 使用结合了通道和空间的注意力机制 (Convolutional Block Attention Module, CBAM)^[16] 替换原始的 SE 注意力机制 (见图2), 来改进 MBConv 模块。



(a) 原始的 MBConv 模块

(b) SE 注意力机制

图 2 MBConv 模块结构

Fig. 2 MBConv module structure

1.4 CBAM 注意力机制

CBAM 结构如图 3 所示, CBAM 是结合了通道和空间的轻量级卷积注意力模块。通道注意力模块 CAM 主要关注输入特征图的通道维度, 通过学习权重来对每个通道进行加权; 空间注意力模块 SAM 则关注特征图中的空间维度, 通过学习权重来调整不同位置的特征图响应。通过结合通道注意力和空间注意力, CBAM 模块能够自适应地调整特征图的通道和空间维度, 从而提高网络对不同特征的感知能力。这种注意力机制可以帮助网络在不同任务和场景下更好地捕捉和利用特征信息, 从而提高模型的性能和鲁棒性。相关描述公式如下:

$$F' = M_c(F)F \quad (1)$$

$$F'' = M_s(F')F' \quad (2)$$

$$M_c(F) = \sigma\{MLP(AvgPool(F)) + MLP(MaxPool(F))\} \quad (3)$$

$$M_s(F') = \sigma\{f^{7 \times 7}([AvgPool(F'); MaxPool(F')])\} \quad (4)$$

其中, 式(1)表示 CAM 过程, 即输入特征 F 经过通道注意力模块一维卷积 M_c 后, 将卷积结果与原图相乘得到 F' ; 式(2)表示 SAM 过程, 即将 CAM 输出结果 F' 作为输入, 进行空间注意力模块的二维卷积 M_s , 最后将卷积结果与原图相乘得到最终结果 F'' ; 式(3)、式(4)分别为通道注意力公式和空间注意力公式。




图 3 CBAM 结构

Fig. 3 CBAM structure

2 实验结果与分析

2.1 实验环境

本研究硬件配置环境为 Intel(R) Core (TM) i7-9700K 处理器, 12 G 显存的 NVIDIA RTX2080ti 显卡, RAM 为 32 GB 的 DDR4; 软件环境为 Window10 系统, 搭建深度学习 Pytorch 2.0.1 框架, CUDA 版本为 11.7。

2.2 评价指标

为了评价本文所提模型的性能, 采用识别准确率 (Accuracy)、浮点运算量 (Floating Point Operations, FLOPs) 以及参数量 (Parameters)^[17] 作为评价指标。其中, 参数量表示在网络模型中可训练参数的个数, 用百万 (Million, M) 为单位; 浮点运算量表示浮点运算的次数, 用来衡量网络模型的复杂度, 用十亿 (Billion, B) 为单位。

识别准确率是图像分类模型中最重要的评价指标, 是指被正确识别的样本量占测试集总量的概率值, 计算公式如下:

$$Accuracy = \frac{P_c}{P_{ALL}} \times 100\% \quad (5)$$

其中, P_c 表示被正确识别的样本数量, P_{ALL} 表示测试集的总样本数量。

2.3 结果与分析

为了充分评估本文提出的基于 EfficientNet 的花椒虫害识别模型, 选取相同类型的深度学习网络模型与其进行实验对比, 其中包括 GoogleNet^[18]、MobileNetV2^[19]、MobileNetV3^[20]、ShuffleNetV2^[21]。为保持实验的一致性, 均使用公开的源码进行试验。对比结果见表 2。

由表 2 可见, EfficientNet-B0 网络相较于其他深度学习网络取得了最好的识别准确率。在此基础

上,本文通过改进 MBCConv 模块构建的 EfficientNet 网络比原始的 EfficientNet-B0 网络提升了 2 个百分点。在模型参数量和运算量变化不大的情况下,改进的 EfficientNet 网络模型准确率最高。

表 2 各网络模型结果对比

Table 2 Comparison of the results of each network model

模型种类 (Model type)	准确率 Accuracy/ %	模型参数量 Parameters/ M	浮点运算量 FLOPs/ B
GoogleNet	82	10.43	1.51
MobileNetV2	80	3.50	0.33
MobileNetV3	86	2.54	0.06
ShuffleNetV2	88	2.27	0.14
EfficientNet-B0	92	5.29	0.42
Improved EfficientNet	94	5.30	0.44

3 结束语

针对原始 EfficientNet 网络中 MBCConv 模块只关注到通道权重而忽略了空间信息的问题,本文提出了一种基于 EfficientNet 的花椒虫害识别模型。通过在 MBCConv 模块中引入 CBAM 注意力机制,将通道注意力和空间注意力结合起来提高模型捕捉不同特征信息的能力。本文所提出的模型准确率高、参数量低,可以将其部署和应用到移动端,为花椒虫害的检测和防治提供了一个可靠的检测工具。在后续研究中可以尝试将其部署到移动端,以方便实际场景中的应用。

参考文献

[1] 陈应福,王港,张亚洲. 贵州省花椒产业发展现状及建议[J]. 现代园艺,2023,46(14):25-27.

[2] 吉波,张耀华,银航,等. 花椒病虫害生物防治的研究综述[J]. 陕西农业科学,2020,66(10):72-75,104.

[3] 邹修国. 基于计算机视觉的农作物病虫害识别研究现状[J]. 计算机系统应用,2011,20(6):238-242.

[4] LIU Z, GAO J, YANG G, et al. Localization and classification of paddy field pests using a saliency map and deep convolutional neural network[J]. Scientific Reports, 2016, 6: 20410.

[5] 孙鹏,陈桂芬,曹丽英. 基于注意力卷积神经网络的大豆虫害图像识别[J]. 中国农机化学报,2020,41(2):171-176.

[6] 杨国国,鲍一丹,刘子毅. 基于图像显著性分析与卷积神经网络的茶园虫害定位与识别[J]. 农业工程学报,2017,33(6):

156-162.

[7] 江顺,黄红星,莫里楠,等. 基于改进 AlexNet 的岭南水稻虫害识别方法研究[J]. 江苏农业科学,2023,51(23):187-195.

[8] 赵康迪,单玉刚,袁杰,等. 基于实例分割的玉米虫害检测研究[J]. 河南农业科学,2022,51(12):153-161.

[9] TAN Mingxing, LE Q V. EfficientNet; Rethinking model scaling for convolutional neural networks [C]//Proceedings of the 36th International Conference on Machine Learning. Long Beach: ICML, 2019: 6105-6114.

[10] HOWARD A G, ZHU Menglong, CHEN Bo, et al. MobileNets: Efficient convolutional neural networks for mobile vision applications[J]. arXiv preprint arXiv:1704.04861, 2017.

[11] CHOLLET F. Xception; Deep learning with depthwise separable convolutions [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA:IEEE, 2017: 1251-1258.

[12] IOFFE S, SZEGEDY C. Batch normalization; Accelerating deep network training by reducing internal covariate shift [C]//Proceedings of the 32nd International Conference on Machine Learning. Lille: ICML, 2015: 448-456.

[13] RAMACHANDRAN P, ZOPH B, LE Q V. Searching for activation functions[J]. arXiv preprint arXiv:1710.05941, 2017.

[14] HU Jie, SHEN Li, SUN Gang. Squeeze-and-excitation networks [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA:IEEE,2018: 7132-7141.

[15] HINTON G E, SRIVASTAVA N, KRIZHEVSKY A, et al. Improving neural networks by preventing co-adaptation of feature detectors[J]. arXiv preprint arXiv:1207.0580, 2012.

[16] WOO S, PARK J, LEE J Y, et al. Cbam; Convolutional block attention module [C]//Proceedings of the European Conference on Computer Vision (ECCV). Munich:dblp, 2018; 3-19.

[17] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [J]. Advances in Neural Information Processing Systems, 2012, 25: 1097-1105.

[18] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Boston:IEEE, 2015: 1-9.

[19] SANDLER M, HOWARD A, ZHU Menglong, et al. Mobilenetv2: Inverted residuals and linear bottlenecks [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA:IEEE,2018:4510-4520.

[20] HOWARD A, SANDLER M, CHU G, et al. Searching for mobilenetv3 [C]// Proceedings of the IEEE/CVF International Conference on Computer Vision. Seoul: IEEE, 2019: 1314-1324.

[21] MA Ningning, ZHANG Xiangyu, ZHENG Haitao, et al. Shufflenet v2: Practical guidelines for efficient CNN architecture design [C]//Proceedings of the European Conference on Computer Vision (ECCV). Munich:dblp,2018; 116-131.