

基于注意力改进 CBAM 的农作物病虫害细粒度识别研究

王美华¹ 吴振鑫² 周祖光¹

(1. 华南农业大学数学与信息学院, 广州 510642; 2. 暨南大学信息科学技术学院, 广州 510632)

摘要: 预防和控制农作物病虫害是保证作物产量的重要措施。为了提高病虫害识别模型的准确率,对注意力 CBAM 模块进行改进,提出一种新的混合注意力模块 I_CBAM。通过通道注意力与空间注意力的并行连接,解决了串行连接两种注意力产生干扰的问题。添加了 I_CBAM 模块的 InRes-v2、MobileNet-v2、LeNet、AlexNet、改进 AlexNet 模型的 Top-1 (61 类) 准确率分别达到了 86.98%、86.50%、80.97%、84.47% 和 84.96%,比原模型分别提高了 0.51、0.62、1.74、0.53、0.55 个百分点。研究表明,提出的并行混合注意力模块 I_CBAM 在病虫害细粒度分类上具有更优的识别效果,且在不同卷积神经网络模型之间拥有良好的泛化性。将 I_CBAM 中通道注意力压缩比调整为 32,使添加了 I_CBAM 的 MobileNet-v2 迁移学习模型的内存缩小至 28.3 MB,预测一幅图像平均用时仅为 7.19 ms,大大提高了预测响应速度。将该模型部署到移动端小程序上,结果表明,添加了 I_CBAM 模块的模型具有良好的可视化应用效果。

关键词: 农作物病虫害; 细粒度识别; 混合注意力; 并行连接; 迁移学习

中图分类号: TP391.41

文献标识码: A

文章编号: 1000-1298(2021)04-0239-09

OSID:



Fine-grained Identification Research of Crop Pests and Diseases
Based on Improved CBAM via Attention

WANG Meihua¹ WU Zhenxin² ZHOU Zuguang¹

(1. College of Mathematics and Informatics, South China Agricultural University, Guangzhou 510642, China

2. College of Information Science and Technology, Jì'nán University, Guangzhou 510632, China)

Abstract: Agricultural production is a significant part of Chinese economic development. The prevention and control of crop pests and diseases are critical measures to ensure crop yield. In order to improve the accuracy of the crop pests and diseases identification model, a new attention module I_CBAM improved from CBAM was proposed. By adopting a parallel connection structure of channel attention and spatial attention, the problem of interference caused by cascade of channel attention and spatial attention module was solved. By adding I_CBAM, the prediction accuracy of the model can be steadily improved. By adding I_CBAM to the five convolutional neural network models of InRes-v2, MobileNet-v2, LeNet, AlexNet, and improved AlexNet, the accuracy of Top-1 (61 types) reached 86.98%, 86.50%, 80.97%, 84.47% and 84.96%, respectively. Compared with the original model, it was improved by 0.51, 0.62, 1.74, 0.53 and 0.55 percentage points, respectively. The final results showed that the parallel mixed attention module I_CBAM proposed had better recognition effect on fine-grained classification of crop pests and diseases. And it also had good generalization in different other convolutional neural network models. Furthermore, by adjusting the channel attention ratio in I_CBAM to 32, the memory size of the MobileNet-v2 transfer learning model with I_CBAM was further reduced to 28.3 MB. Meanwhile, the average time the model used to predict a picture was only 7.19 ms, which made a good balance between the prediction cost and the prediction accuracy. Finally, the model was deployed on the mobile terminal mini application, which had a good visual application effect.

Key words: crop pests and diseases; fine-grained identification; mixed attention; parallel connection; transfer learning

收稿日期: 2020-06-17 修回日期: 2020-08-02

基金项目: 国家自然科学基金项目(61370102、61976052)和广东省基础与应用基础研究基金项目(2019B1515210009)

作者简介: 王美华(1970—),女,副教授,博士,主要从事机器学习在农业工程领域应用研究,E-mail: wangmeihua@scau.edu.cn

0 引言

农作物病虫害是一种严重的自然灾害,需要对其进行及时预测和监控,以保证农作物的产量^[1]。病虫害的发生与种植制度、作物布局和气候趋势等因素息息相关,而普通农户的小规模种植使病虫害预测难度较大^[2-3]。

传统的机器学习方法一般经过病斑提取、边缘特征提取后进行分类^[4]。魏超等^[5]将农作物病斑分割分为背景移除和病斑分割两个阶段,并由此进一步提出了一种病斑袋模型,以提取出更高层抽象的特征。然而,这种传统机器学习方法对图像的预处理步骤较为复杂,并且只能应用于个别植物的少量病虫害检测,可迁移性差。随着深度学习技术的发展,病虫害图像数据日益充足,成功解决了传统机器学习需要显式提取病虫害特征和可迁移性差的问题。利用深度学习技术泛化性强的特点,能够同时对种类繁多的病虫害进行识别检测,大大提高了防治效果。国内外已有许多研究利用卷积神经网络对农作物病虫害进行识别^[6-8]。通常来说,数据质量的优劣往往决定了模型质量的优劣,一个大而全的数据集(例如 ImageNet)往往能够训练出效果较好的模型。然而,在病虫害识别领域常常面临数据量不足的问题,迁移学习技术^[9]能够利用已经标注好的数据提升模型精度,从而解决数据量不足的问题。许多研究表明,采用迁移学习并对卷积神经网络模型的所有层进行精调,能够最大程度提升原模型的基础识别率^[10-12]。

在利用深度学习和迁移学习进行图像识别时,一般会在神经网络中通过添加注意力模块来提高识别准确率。然而,传统的混合注意力模块在细粒度

多分类识别任务中表现不稳定,因此较难应用于此类任务中。

本文针对苹果、番茄、辣椒等 10 种植物的细粒度识别进行研究。首先,在卷积神经网络中采用全网络层微调的迁移学习方法,以保证病虫害识别模型准确率;针对传统注意力模块在细粒度多分类的识别任务中表现不稳定的问题,在迁移学习的基础上提出一种对卷积注意力模块(Convolutional block attention module,CBAM)^[13]进行改进的混合注意力模块(Improved CBAM,I_CBAM),以期在不同的卷积神经网络中具有良好的可移植性和泛化性。

1 实验数据

1.1 数据集来源

本文所用数据集为上海新客科技和创新工场联合制作的农作物病虫害图像。数据集包含草莓、樱桃和苹果等 10 种作物的 10 种健康状态和 27 种病虫害,其中 24 种病虫害又分为“一般”和“严重”状态(例如:“苹果黑星病一般”和“苹果黑星病严重”),共计 61 类。本文所用数据集农作物病虫害图像共 36 258 幅,数据集部分图像如图 1 所示,其具体标签如表 1 所示。将数据集图像划分为训练集与测试集。其中,训练集包含 31 718 幅图像,测试集包含 4 540 幅图像。

1.2 数据集预处理

本文数据集大部分图像尺寸 300 像素×400 像素。为了满足卷积神经网络输入图像尺寸要求,将图像尺寸统一缩放为 224 像素×224 像素,然后在此基础上进行数据增强操作。

在通常条件下,用于训练的数据越多,模型的精度就越高,其鲁棒性和泛化性也越强。数据增强是




图 1 农作物病虫害数据集部分图像示例

Fig.1 Samples of crop pests and diseases dataset

表 1 农作物病虫害数据集的分类标签

Tab.1 Labels for crop pests and diseases dataset

标签	分类	标签	分类
0	苹果健康	24	柑桔健康
1	苹果黑星病一般	25	柑桔黄龙病一般
2	苹果黑星病严重	26	柑桔黄龙病严重
17	葡萄健康	30	辣椒健康
18	葡萄黑腐病一般	31	辣椒疮痂病一般
19	葡萄黑腐病严重	32	辣椒疮痂病严重

深度学习中常用的数据扩充方法。本文在模型训练时使用双线性插值法、最近邻插值法、双三次插值法和面积插值法对图像进行缩放操作,又将图像随机进行水平和垂直翻转,从而将训练数据集扩充至 507 488 幅,最后将图像进行归一化以提高模型学习速度。模型测试时,为了保证测试结果的稳定,测试图像仅进行双线性插值法缩放和归一化操作。

2 病虫害识别模型与改进 CBAM

2.1 病虫害识别模型

卷积神经网络 (Convolutional neural network, CNN)是深度学习在图像领域应用范围最广的一种神经网络结构。本文以 CNN 为基础,搭建病虫害识别模型。首先,从病虫害数据集中批量选取训练图像,随后经过 CNN 提取图像特征。再经过全连接层 (类似于多层感知机^[14])与 Softmax 层,产生预测分类。最后计算损失值,利用反向传播调整网络参数。本文利用卷积神经网络进行病虫害分类模型的训练流程如图 2 所示。




图 2 病虫害分类模型训练流程图

Fig.2 Training flow chart of crop pests and diseases classification model

2.2 改进混合注意力

由文献[5]可知,“病害程度”分类的错误主要集中在“病害程度”的判断上。因此,对卷积神经网络模型添加注意力,以提升对“病虫害程度”此类细粒度任务的识别效果,从而提高模型的整体识别准确率。

2.2.1 卷积神经网络中的注意力机制

卷积神经网络中的注意力机制分为软注意力和强注意力两种。其中强注意力不可微,常常用于增强学习,不属于本文讨论的范畴。软注意力可微分,即可以通过训练中的反向传播进行自主更新^[15]。本文所关注和使用的是软注意力,软注意力又可以分为空间域、通道域和混合域。其中,空间域和通道域是软注意力所关注的方面。

空间注意力 (Spatial attention)^[16]可使神经网络更加关注图像中对分类起决定作用的像素区域,而忽略无关区域。通道注意力 (Channel attention)^[17]是一种考虑特征图通道之间关系的注意力机制。混合域则是将上述两种不同注意力组合起来。CBAM 就是将卷积模块中的空间注意力和通道注意力进行混合,实现从通道到空间的顺序注意力结构,能够嵌入到卷积操作之后,容易移植。

2.2.2 改进 CBAM

CBAM^[13]模块是先输入特征图 F ,经过通道注意力加权结果为 F_1 。再经过空间注意力加权得到输出特征图 F_2 ,这是一种“串行 (cascade) 连接”的结构,其过程公式为

$$\begin{cases} F_1 = M_c(F) \otimes F \\ F_2 = M_s(F_1) \otimes F_1 \end{cases} \quad (1)$$

式中 $M_c(F)$ —— F 经过通道注意力的输出权值
 $M_s(F_1)$ —— F_1 经过空间注意力的输出权值
 $\otimes$ ——特征图加权乘法运算符号

实际上,无论是先启用通道注意力后启用空间注意力 (channel→spatial,即 CBAM),还是先启用空间注意力后启用通道注意力 (spatial→channel,即 reverse CBAM,简称 R_CBAM),排在后面的权值都是由排在前面的特征图产生。而在这个过程中,认为排在前面的注意力把原始输入特征图“修饰”了。即排在后面的注意力机制所学习到的是被“修饰”过的特征图,在一定程度上影响排在后面的注意力模块所学习到的特征。尤其在细粒度分类任务中,这种由于“串行连接”而产生的干扰,会使注意力模块的效果变得不稳定,对于准确率的提升也难以保证。

因此,为了解决这个问题,本文对 CBAM 的串行注意力模块进行改进,将原来的“串行 (cascade) 连接”改为“并行 (parallel) 连接”,使两种注意力模块都直接学习原始的输入特征图,从而无需关注空间注意力和通道注意力顺序,由此得到改进 CBAM (I_CBAM)。I_CBAM 先由输入特征图 F 分别经过通道注意力和空间注意力得到相应权值,最后将权值直接与原始输入特征图 F 加权得到输出特征图

F_2 ,其过程公式为

$$F_2 = M_c(F) \otimes M_s(F) \otimes F \tag{2}$$

式中 $M_s(F)$ —— F 经过空间注意力的输出权值
I_CBAM 的整体结构如图 3 所示。




图 3 I_CBAM 整体结构图
Fig. 3 I_CBAM structure diagram

3 实验与分析

3.1 实验环境

实验使用软件为 Python 3.5 和深度学习框架 Keras 2.3.1,以 Tensorflow-gpu 2.0.0 为后端,操作系统为 Ubuntu 18.04.3 LTS。CPU 为 Intel Xeon E5 – 2678 v3@ 2.50 GHz,GPU 为 NVIDIA RTX 2080Ti,显存 11 GB。

3.2 实验设计

首先使用混合注意力模块 CBAM 中的 channel attention (压缩比为 2)、spatial attention、CBAM、R_CBAM 和本文提出的 I_CBAM,在农作物病虫害数据集上利用不同的卷积神经网络模型进行预测准确率对比,以证明 I_CABM 的有效性和泛化性。在模型训练环节,随机选取一个批次的图像进行训练,批尺寸为 32。

本文采用 Top – 1 准确率、Top – 5 准确率、作物品种(10 类)准确率(预测的品种是否正确)、病害种类(27 类)准确率(预测的品种和病虫害种类是否正确)、病害程度(健康/一般/严重)(3 类)准确率(预测的品种、病虫害种类和相对应的严重程度是否正确)、平均一幅图像前向传播时间、模型规模和参数数量作为模型的评判标准。

由文献[5]可知,分类错误主要集中在对于“病害程度”的判断上,因此提升对“病害程度”的识别效果是提升模型识别准确率的关键。本文主要以 Top – 1 准确率和病害程度准确率作为判断模型效果的标准。

3.3 注意力模块对比实验

首先在表现稳定的 InRes – v2^[18] 迁移学习模型(在包含 1 000 个类别的 120 万幅图像的 ImageNet 数据集中预训练)中加入各注意力模块进行对比实验。由于 InRes – v2 包含 Inception^[19] 结构和 Resnet

残差连接结构^[20],因此参考 HU 等^[17] 的嵌入方式,将注意力模块放在 Inception 结构的拼接操作之后,最后与残差相加。其在 Inception – Resnet 结构的具体嵌入方式如图 4 所示。实验选用 Adam 优化器,初始学习率为 0.000 1,训练 50 次。最终 Top – 1 准确率如图 5 所示,详细指标如表 2 所示。




图 4 Inception – Resnet 模块嵌入注意力模块示意图
Fig. 4 Embed in Inception – Resnet block attention module diagram




图 5 InRes – v2 嵌入注意力模块后的 Top – 1 准确率对比
Fig. 5 Accuracy of Top – 1 for embedding each attention module in InRes – v2

从表 2 可以看出,无论是以作物品种还是病虫害种类为划分,各模型的 Top – 5 准确率均超过了 99%,并且数值相当接近。而 Top – 1 分类的错误主

表 2 InRes-v2 嵌入各注意力模块实验结果

Tab.2 Results of attention module experiments in InRes-v2

模型	Top-1	Top-5	作物品种	病害种类	病害程度	前向传播 时间/ms	模型规模/ MB	参数数量
	准确率/%	准确率/%	(10 类)准确 率/%	(27 类)准确 率/%	(3 类)准确 率/%			
InRes-v2	86.47	99.56	98.78	97.57	88.62	9.1	625.0	$5.443\ 0\times10^7$
InRes-v2+channel attention	86.87	99.73	98.96	97.73	88.89	12.0	1 433.5	$1.224\ 6\times10^8$
InRes-v2+spatial attention	86.74	99.69	98.94	97.82	88.67	11.8	625.4	$5.444\ 0\times10^7$
InRes-v2+CBAM	86.41	99.69	99.03	97.82	88.34	13.4	1 433.9	$1.224\ 7\times10^8$
InRes-v2+R_CBAM	86.74	99.69	98.96	97.67	88.81	13.4	1 433.9	$1.224\ 7\times10^8$
InRes-v2+I_CBAM	86.98	99.69	98.88	97.58	89.15	13.4	1 433.9	$1.224\ 7\times10^8$

要受到“病害程度”判断的影响,因此添加注意力模块的首要目的,就是提升对“病害程度”的识别准确率。另外,从模型规模和参数数量的角度进行分析,由于 CBAM 中的 channel attention 存在两个全连接层,因此参数数量增长明显,模型规模翻倍。而 spatial attention 由于只需要保存一个 7×7 的卷积核,因此模型规模和参数数量都较小。

CBAM 注意力的 Top-1 准确率并不理想,排序靠后的空间注意力学习到的是排序在前的通道注意力“修饰”过的特征图,因此效果并不好。R_CBAM 的 Top-1 准确率略高一些,考虑到排序在前的空间注意力没有全连接层,因此对于原始输入特征图的“修饰”程度并不大,因此准确率有少许提升。但均未超过直接使用 channel attention 或 spatial attention 的模型,验证了串行连接注意力会导致学习效果不好的结论。而本文提出的并行混合注意力模块 I_CBAM 表现较优,其 Top-1 准确率和病害程度准确率达到了 86.98% 和 89.15%,比 CBAM 提升了 0.57/0.81 个百分点。

虽然在大型自动化场景下使用基于 InRes-v2 嵌入 I_CBAM 模型效果出色,但是在日常使用的移动端应用中,却难以部署 InRes-v2 这样大体量的模型。因此在轻量级移动端神经网络 MobileNet-v2^[21]中嵌入 I_CBAM 模块,进行对比实验,以验证 I_CBAM 在小型网络上的效果。

MobileNet-v2 是一个轻量级的模型,然而在实

验中使用 ImageNet 预训练模型时,若在 MobileNet-v2 的每个 inverted_res_block 中都加入 attention block,则会导致预训练模型中的初始参数在训练时被严重破坏,且模型的规模也变为原来的数倍,失去了 MobileNet_v2 在移动端的意义。因此,在 MobileNet_v2 的最后一个卷积后嵌入注意力模块同时删去此卷积后的批归一化层(BN)层进行对比实验,以减少参数的扰动,保证训练时的鲁棒性。对比实验选用 Adam 优化器,初始学习率为 0.000 01,训练 40 次。实验最终的 Top-1 准确率如图 6 所示,其它部分指标如表 3 所示。




图 6 MobileNet-v2 嵌入各注意力模块后的 Top-1 准确率对比

Fig.6 Accuracy comparison of Top-1 for embedding each attention module in MobileNet-v2

从表 3 可以看到,MobileNet-v2 模型的参数数量仅为 2.34×10^6 ,比 InRes-v2 模型的 5.443×10^7 缩减了 5.209×10^7 ,并且准确率仅比 InRes-v2

表 3 MobileNet-v2 嵌入各注意力模块实验结果

Tab.3 Results of attention module experiments in MobileNet-v2

模型	Top-1	病害程度	前向传播	模型规模/	参数数量
	准确率/%	(3 类)准确率/%	时间/ms	MB	
MobileNet-v2	85.88	87.89	7.18	27.1	2.34×10^6
MobileNet-v2+channel attention	86.06	88.21	7.33	45.8	3.97×10^6
MobileNet-v2+spatial attention	86.36	88.29	7.15	27.1	2.33×10^6
MobileNet-v2+CBAM	86.21	88.39	7.33	45.9	3.97×10^6
MobileNet-v2+R_CBAM	86.38	88.35	7.33	45.9	3.97×10^6
MobileNet-v2+I_CBAM	86.50	88.65	7.33	45.9	3.97×10^6

低 0.59 个百分点,是移动端病虫害识别的理想模型。在 MobileNet-v2 中添加各类注意力模块后准确率有提升。其中,无论是 Top-1 准确率还是病害严重程度的识别准确率,添加了 I_CBAM 的模型均为最高,对于准确率的提升十分稳定,分别比 MobileNet-v2 模型提高了 0.62、0.76 个百分点,再次证明了 I_CBAM 的有效性和鲁棒性。

激活热力图^[22] (Grad-CAM) 能够对模型的分

类结果提供很好的可视化依据。因此,为进一步分析识别准确率差异的原因,本文提取了部分测试图像在 MobileNet-v2 各注意力模块对比实验中的激活热力图,如图 7 所示。其中, P 表示经过 Softmax 函数分类后模型对于类别 y_i 的判断概率。可以观察到,添加 I_CBAM 的模型比起其它模型能够更准确地定位和选中叶片的病虫害区域,对于正确分类的判断效果也更好。




图 7 MobileNet-v2 嵌入各注意力模块后的激活热力图对比

Fig. 7 Grad-CAM comparison for embedding each attention modules in MobileNet-v2

从 InRes-v2 和 MobileNet-v2 的对比实验中可以观察到,注意力模块 I_CBAM 的参数主要来源于其中的 Channel attention 部分。例如 InRes-v2 模型参数数量为 5.443×10^7 ,而添加 Channel attention (压缩比为 2) 后则达到了 $1.224 6 \times 10^8$,说明 Channel attention 是参数数量增长的主要来源。在添加了 Channel attention 的注意力模块 (Channel attention/CBAM/R_CBAM/I_CBAM) 中,本文在实验中设置 Channel attention 全连接层的压缩比为 2,以突出学习效果。为了进一步缩减添加注意力模块后的参数数量和模型规模,使模型更加轻量,在 MobileNet-v2 上对 I_CBAM 的 Channel attention 的压缩比(2、4、8、16、32、64)进行了调参实验,在尽可能地缩减模型规模的情况下保证识别准确率,其实验结果如表 4 所示。

从表 4 中可以看到,当压缩比为 32 时,模型的

表 4 MobileNet-v2 嵌入 I_CBAM 使用不同压缩比的实验结果

Tab. 4 Results of using different reduction ratios for MobileNet-v2 embedded I_CBAM

压缩比	Top-1 准确率/%	病害程度 (3 类) 准确率/%	前向传播 时间/ms	模型规模/ MB	参数数量
2	86.50	88.65	7.33	45.9	3.97×10^6
4	86.17	88.25	7.31	36.5	3.15×10^6
8	86.15	88.13	7.25	31.8	2.74×10^6
16	86.17	88.28	7.21	29.4	2.54×10^6
32	86.39	88.43	7.19	28.3	2.43×10^6
64	86.34	88.31	7.18	27.7	2.38×10^6

准确率与压缩比为 2 时并没有明显的变化,且模型规模已缩减至 28.3 MB,使得模型规模和准确率之间达到了较好的平衡。因此,使用 32 作为 I_CBAM 中 Channel attention 全连接层的压缩比是一个极佳

的选择。此外,对比添加了 I_CBAM 的 InRes - v2 模型,调整压缩比为 32,不仅模型规模大大缩减,且前向传播(预测)时间从 13.4 ms 减少至 7.19 ms,大大提高了预测的响应速度。

除此之外,为了进一步验证 I_CBAM 的泛化性和鲁棒性,本文还在 LeNet^[23]、AlexNet^[24] 和改进 AlexNet^[25] 3 类卷积神经网络上,采用模型随机初始化参数的训练模式,在每个卷积层后嵌入注意力模块,再次进行了各注意力模块的对比实验。其中,LeNet 对比实验选用 SGD 优化器(初始学习率为 0.01,衰减率为 0.94);AlexNet 对比实验选用 Adam 优化器(初始学习率为 0.000 1);改进 AlexNet 对比实验选用 Adam 优化器(初始学习率为 0.000 5);训练次数均为 40,最终 Top - 1 准确率和病害程度准确率如表 5、6 所示。

表 5 3 种模型的 Top - 1 准确率对比

Tab.5 Top - 1 accuracy comparison of three models			
%			
模型	LeNet	AlexNet	改进 AlexNet
原网络	79.23	83.94	84.41
原网络 + Channel attention	80.06	83.61	83.92
原网络 + Spatial attention	80.00	83.83	84.41
原网络 + CBAM	78.83	83.77	84.93
原网络 + R_CBAM	80.31	83.77	84.89
原网络 + I_CBAM	80.97	84.47	84.96

表 6 3 种模型的病害程度准确率对比

Tab.6 Disease severity accuracy comparison of three models			
%			
模型	LeNet	AlexNet	改进 AlexNet
原网络	86.16	87.47	88.52
原网络 + Channel attention	86.81	87.43	87.97
原网络 + Spatial attention	86.54	87.35	88.09
原网络 + CBAM	86.60	87.87	88.44
原网络 + R_CBAM	86.40	87.63	88.29
原网络 + I_CBAM	86.94	87.98	88.93

从表 5 可以看出,CBAM 和 R_CBAM 在不同模型中的表现并不一致。例如在改进 AlexNet 上添加 CBAM 与 R_CBAM 的模型准确率高 于不添加注意力模块的改进 AlexNet,但在 AlexNet 添加注意力模块后却均低于不添加注意力模块的 AlexNet,而在 LeNet 上则呈现一高一低的情况。I_CBAM 的模型表现则较稳定,在 3 种浅层卷积神经网络上均取得了最高的准确率,在 LeNet、AlexNet、改进 AlexNet 上添加 I_CBAM 后分别比不添加时的 Top - 1 准确率分别提高了 1.74、0.53、0.55 个百分点,病害程度准确率分别提高了 0.78、0.51、0.41 个百分点。通过对 3 种浅层卷积神经网络的再次对比,证明了 I_CBAM 具有泛化性和鲁棒性。

3.4 模型部署及可视化识别应用

为了便于用户更好地使用,采用小程序搭建了用户图形界面。如图 8a 所示,图中选用的模型为添加了 I_CBAM(压缩比为 32)的 MobileNet - v2 模型。通过拍摄或相册上传一幅图像,然后选择模型提交到小程序进行识别。小程序将相关信息发送给 Python 的 Django 框架搭建的系统后台,系统后台根据相关信息调用模型进行识别,并将识别的结果返回给小程序。小程序收到系统后台的识别结果后,展示系统后台的识别信息。

识别结果如图 8b 所示,对于健康玉米图像识别,准确率达到了 99.99%。小程序将预测前 5 项概率的结果返回给用户。如图 8c、8d 所示,对于番茄斑枯病严重和马铃薯早疫病严重的识别准确率分别达到了 99.65% 和 99.86%,而对于番茄斑枯病一般和马铃薯早疫病一般的预测概率则仅有 0.32% 和 0.07%,在病害程度的判断上非常精确。结果表明添加了 I_CBAM 的模型在细粒度分类任务上具有较好的应用效果。




图 8 病虫害识别小程序应用效果图

Fig. 8 Effect diagrams of mini program for crop pests and diseases identification

4 结 论

(1)针对细粒度多分类病虫害识别准确率低的问题,对串行连接混合注意力模块 CBAM 进行改进,提出了一种并行连接的 I_CBAM 注意力模块,解决了串行连接两种注意力产生干扰的问题。

(2)为了验证 I_CBAM 模块的有效性和鲁棒性,设计并对比了 channel attention、spatial attention、CBAM、R_CBAM 和 I_CBAM 在 5 种不同卷积神经网络中的识别效果。结果表明,添加了 I_CBAM 的 InRes - v2、MobileNet - v2、LeNet、AlexNet、改进

AlexNet 模型的 Top - 1 (61 类) 识别准确率分别为 86.98%、86.50%、80.97%、84.47% 和 84.96%,比未添加注意力模块的原模型分别高 0.51、0.62、1.74、0.53、0.55 个百分点。说明 I_CBAM 在病虫害细粒度分类上具有较优的识别效果,且在不同卷积神经网络模型之间拥有良好的泛化性。

(3)对添加了 I_CBAM 的 MobileNet - v2 模型进行不同压缩比的调参比对实验,进一步缩减模型规模至 28.3 MB,且预测一幅图像的平均用时仅为 7.19 ms。将该模型部署到移动端小程序上,具有良好的可视化应用效果。

参 考 文 献

[1] 曹乐平. 基于机器视觉的植物病虫害实时识别方法[J]. 中国农学通报, 2015, 31(20): 244 - 249.
CAO Leping. Real-time identification method of plant diseases and insect pests based on machine vision[J]. Chinese Agricultural Science Bulletin, 2015, 31(20): 244 - 249. (in Chinese)

[2] 陈舜, 逯非, 王效科. 中国主要农作物种植农药施用温室气体排放估算[J]. 生态学报, 2016, 36(9): 2560 - 2569.
CHEN Shun, LU Fei, WANG Xiaoke. Estimation of greenhouse gas emissions from pesticide application in major crops in China[J]. Acta Ecologica Sinica, 2016, 36(9): 2560 - 2569. (in Chinese)

[3] MILITANTE S V, GERARDO B D, DIONISIO N V. Plant leaf detection and disease recognition using deep learning[C]//2019 IEEE Eurasia Conference on IOT, Communication and Engineering (ECICE). IEEE, 2019.

[4] KAUR R, KANG S S. An enhancement in classifier support vector machine to improve plant disease detection[C]//IEEE International Conference on Moocs, 2016: 135 - 140.

[5] 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. Detection of crop diseases based on deep learning[J]. Journal of Jiangsu University(Natural Science Edition), 2019, 40(2): 190 - 196. (in Chinese)

[6] 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 of image recognition technology for crop diseases and insect pests 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?flag=1&file_no=2019s048&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2019.S0.048. (in Chinese)

[7] 蒲秀夫, 宁芊, 雷印杰, 等. 基于二值化卷积神经网络的农业病虫害识别[J]. 中国农机化学报, 2020, 41(2): 177 - 182.
PU Xiufu, NING Qian, LEI Yinjie, et al. Identification of agricultural pests and diseases based on binary convolutional neural network[J]. Journal of Chinese Agricultural Mechanization, 2020, 41(2): 177 - 182. (in Chinese)

[8] FERENTINOS K P. Deep learning models for plant disease detection and diagnosis[J]. Computers and Electronics in Agriculture, 2018, 145: 311 - 318.

[9] DONAHUE J, JIA Y, VINYALS O, et al. Decaf: a deep convolutional activation feature for generic visual recognition[C]//International Conference on Machine Learning, 2014: 647 - 655.

[10] 许景辉, 邵明烨, 王一琛, 等. 基于迁移学习的卷积神经网络玉米病害图像识别[J/OL]. 农业机械学报, 2020, 51(2): 230 - 236, 253.
XU Jinghui, SHAO Mingye, WANG Yichen, et al. Image recognition of corn diseases based on transfer learning convolutional neural network[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(2): 230 - 236, 253. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=2002025&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2020.02.025. (in Chinese)

[11] MOHANTY S P, HUGHES D P, MARCEL S. Using deep learning for image-based plant disease detection[J]. Frontiers in Plant Science, 2016, 7: 1419.

[12] KAMAL K C, YIN Z, LI B, et al. Transfer learning for fine-grained crop disease classification based on leaf images[C]//Workshop on Hyperspectral Imaging and Signal Processing: Evolution in Remote Sensing (WHISPERS), 2019: 1 - 5.

[13] WOO S, PARK J, LEE J, et al. CBAM: convolutional block attention module[C]//European Conference on Computer Vision, 2018.

[14] RUCK D W, ROGERS S K, KABRISKY M, et al. The multilayer perceptron as an approximation to a Bayes optimal discriminant function[J]. IEEE Transactions on Neural Networks, 1990, 1(4): 296 - 298.

- [15] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back-propagating errors[J]. *Nature*, 1986, 323(6088): 533–536.
- [16] FU J, ZHENG H, MEI T. Look closer to see better; recurrent attention convolutional neural network for fine-grained image recognition[C]//IEEE Conference on Computer Vision & Pattern Recognition, 2017:4476–4484.
- [17] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]//IEEE Conference on Computer Vision & Pattern Recognition, 2018:7132–7141.
- [18] SZEGEDY C, IOFFE S, VANHOUCKE V, et al. Inception – v4, Inception – ResNet and the impact of residual connections on learning[C]//Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Computer Society, 2016:1–9.
- [19] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]//IEEE Conference on Computer Vision & Pattern Recognition, 2015:1–9.
- [20] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//IEEE Conference on Computer Vision & Pattern Recognition, 2016:770–778.
- [21] SANDLER M, HOWARD A, ZHU M, et al. MobileNetV2: inverted residuals and linear bottlenecks[C]//Conference on Computer Vision and Pattern Recognition. IEEE, 2018.
- [22] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-cam; visual explanations from deep networks via gradient-based localization[C]//IEEE International Conference on Computer Vision, 2017:618–626.
- [23] 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.
- [24] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. *Communications of the ACM*, 2017, 60(6): 84–90.
- [25] 孙俊, 谭文军, 毛罕平, 等. 基于改进卷积神经网络的多种植物叶片病害识别[J]. *农业工程学报*, 2017, 33(19): 209–215.
SUN Jun, TAN Wenjun, MAO Hanping, et al. Identification of multiple plant leaf diseases based on improved convolutional neural network[J]. *Transactions of the CSAE*, 2017, 33(19): 209–215. (in Chinese)
-

(上接第 125 页)

- [20] 王立军, 段良坤, 郑招辉, 等. 三移动两转动振动筛驱动机构优化与试验[J/OL]. *农业机械学报*, 2018, 49(6): 138–145.
WANG Lijun, DUAN Liangkun, ZHENG Zhaohui, et al. Optimization and experiment on driving mechanism of vibrating screen with three translations and two rotations[J/OL]. *Transactions of the Chinese Society for Agricultural Machinery*, 2018, 49(6): 138–145. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20180616&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2018.06.016. (in Chinese)
- [21] 胡志超, 彭宝良, 田立佳, 等. 5X-5 型风筛式清选机的研制[J]. *西北农业学报*, 2007, 16(4): 288–291, 294.
HU Zhichao, PENG Baoliang, TIAN Lijia, et al. Design of 5X-5 air-screen separator[J]. *Acta Agriculturae Boreali-occidentalis Sinica*, 2007, 16(4): 288–291, 294. (in Chinese)
- [22] 刘正怀, 郑一平, 王志明, 等. 微型稻麦联合收获机气流式清选装置研究[J/OL]. *农业机械学报*, 2015, 46(7): 102–108.
LIU Zhenghuai, ZHENG Yiping, WANG Zhiming, et al. Design on air-flowing cleaning unit of micro rice-wheat combine harvester[J/OL]. *Transactions of the Chinese Society for Agricultural Machinery*, 2015, 46(7): 102–108. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20150716&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2015.07.016. (in Chinese)
- [23] 廖庆喜, 陈立, 李海同, 等. 油菜联合收获机脱出物清选试验台[J/OL]. *农业机械学报*, 2013, 44(10): 80–85, 79.
LIAO Qingxi, CHEN Li, LI Haitong, et al. Cleaning unit test-bed of extraction components for rape combine harvester[J/OL]. *Transactions of the Chinese Society for Agricultural Machinery*, 2013, 44(10): 80–85, 79. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20131014&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2013.10.014. (in Chinese)
- [24] MIU P I, KUTZBACH H D. Modeling and simulation of grain threshing and separation in threshing units—Part I[J]. *Computers and Electronics in Agriculture*, 2008, 60(1): 96–104.
- [25] 高连兴, 苏展, 陈中玉, 等. 对辊半喂入式小区育种花生摘果装置设计与试验[J/OL]. *农业机械学报*, 2016, 47(9): 93–98.
GAO Lianxing, SU Zhan, CHEN Zhongyu, et al. Design and experiment of double-roller semi-feeding peanut picking device for breeding in mini type area[J/OL]. *Transactions of the Chinese Society for Agricultural Machinery*, 2016, 47(9): 93–98. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20160914&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2016.09.014. (in Chinese)