

基于改进 Alexnet 的轻量化香蕉成熟度检测

Lightweight banana ripeness detection based on improved Alexnet

蒋 瑜¹ 王灵敏²

JIANG Yu¹ WANG Lingmin²

(1. 广西农业职业技术大学, 广西 南宁 530007; 2. 桂林理工大学南宁分校, 广西 南宁 530001)

(1. *Guangxi Agricultural Vocational and Technical University, Nanning, Guangxi 530007, China*;

2. *Guilin University of Technology at Nanning, Nanning, Guangxi 530001, China*)

摘要:目的: 获得轻量化 Mini-Alexnet 香蕉成熟度分级模型并应用于安卓移动端。方法: 结合不同成熟度香蕉外部特征, 对 Alexnet 网络模型进行结构调整, 删除部分卷积层, 并利用全局平均池化代替全连接层缩减模型参数和所需内存, 且更换更大卷积核提取香蕉表皮全局特征, 得到改进后轻量化 Mini-Alexnet 网络模型, 再将 Mini-Alexnet 网络模型部署至安卓移动端 APP, 并验证其可行性和实用性。结果: Mini-Alexnet 模型仅为 11.6 MB, 香蕉五等级成熟度判别准确率为 97.76%, 移动端 APP 香蕉成熟度自动判别系统本地图片识别模式、拍照识别模式、实时识别模式准确率分别为 86.66%, 79.33%, 74.00%, 平均准确率可达 80%。结论: 改进后 Mini-Alexnet 模型占内存空间更小。

关键词: 香蕉; 轻量化模型; 成熟度; 移动设备; APP

Abstract: **Objective:** To obtain a lightweight Mini-Alexnet banana ripeness grading model and apply it to Android mobile devices. **Methods:** Based on the external characteristics of bananas with different ripeness, the Alexnet network model was restructured, part of the convolutional layer was deleted, and the global average pooling was used instead of the full connection layer to reduce the model parameters and required memory. A larger convolutional kernel was replaced to extract the global characteristics of the banana skin to achieve an improved lightweight Mini-Alexnet network model. Then the Mini-Alexnet network model was deployed as Android mobile APP, and its feasibility and practicability were verified. **Results:** The Mini-Alexnet model was only 11.6 MB, and the identification accuracy rate of banana ripeness level 5 was 97.76%. The accuracy rate of

local picture recognition mode, photo recognition mode and real-time recognition mode of the mobile APP banana ripeness automatic identification system was 86.66%, 79.33% and 74.00%, respectively, with an average accuracy rate of 80%. **Conclusion:** The improved Mini-Alexnet model occupies less memory space.

Keywords: bananas; lightweight model; ripeness; mobile device; APP

在香蕉采摘、贮藏、分拣、运输及销售等环节中, 成熟度通常是香蕉鲜果分级标准之一^[1-2], 成熟度不同, 香蕉品质存在较大差异。在香蕉果实后熟过程中, 其个体形态、内部结构等会发生不同程度的变化, 因此可以借助某些特征变化来确定其成熟度^[3]。Sanaeifar 等^[4]利用电子鼻预测香蕉果实成熟度, 但该类传感器一致性较差, 且采样时易受环境影响; Rajkumar 等^[5]利用高光谱成像研究香蕉果实不同温度下品质和成熟度之间的关系; 黎源鸿等^[6]利用高光谱技术检测香蕉果肉可溶性固形物含量、坚实度, 建立了香蕉成熟度理化指标的光谱和图像特征分类模型; Soltani 等^[7]使用电学特性检测法得到了香蕉成熟过程中电化学特性模型, 但该模型易受环境温湿度影响; Chen 等^[8]采用色差仪等光检测方法进行香蕉成熟度判别。上述方法均是根据香蕉物理和化学性质变化进行香蕉成熟度判别, 且多为接触式检测, 需借助专业检测分析设备, 成本高、实施流程复杂, 不适合实时获取结果, 不利于普及。

实际商业贸易中, 香蕉成熟度确定一般是按照 Von Loesecke 给定的香蕉果皮 7 级颜色分级法来划分, 直接由人工对照对比图后进行分类^[9], 该方法主观性较强且耗时耗力, 容易受个体感知差异、视觉疲劳等影响。参考该分级方法, 将试验香蕉按成熟度分为 5 个等级(见表 1)。

香蕉成熟度分级本质上是图像分类问题, 深度卷积神经网络在图像识别领域的应用越来越广泛。王文超

基金项目: 广西高校中青年教师科研基础能力提升项目(编号: 2024KY1247, 2020KY36006)

作者简介: 蒋瑜, 男, 广西农业职业技术大学工程师, 硕士。

通信作者: 王灵敏(1989—), 女, 桂林理工大学南宁分校工程师, 硕士。E-mail: 742709113@qq.com

收稿日期: 2023-10-07 **改回日期:** 2024-04-17

表 1 五等级香蕉成熟度分类时香蕉特征
Table 1 Banana characteristics in 5-level banana ripeness classification

等级	成熟度	香蕉特征
Level 1	Green	果皮有变黄迹象,但不明显,整体呈绿色
Level 2	Green-Yellow	果皮黄色增加,绿色中透出黄色,整体呈绿黄色
Level 3	Yellow-Green	果皮大部分呈黄色,仍有少量绿色,整体呈黄绿色
Level 4	Ripen	果皮几乎全黄,仅果柄处残留极少量绿色或果皮全黄
Level 5	OverRipen	果面全黄并出现黑色梅花点

等^[10]利用人工智能的方法实现对水果损伤和糖度等品质的检测,并应用于水果品质分选机,实现了对水果损伤和糖度等品质的检测与分选,对水果损伤检测准确率为 99%。陈锋军等^[11]通过改进 EfficientDet 特征提取网络,引入卷积注意力模块(CBAM),通过细化不同成熟度之间特征映射来实现油橄榄果实成熟度检测。朱旭等^[12]利用改进 Faster R-CNN 算法,实现蓝莓图像背景消除及果实识别,对成熟果、半成熟果和未成熟果识别准确率分别为 97.00%,95.00%,92.00%,平均识别准确率为 94.67%。王辉等^[13]在 DarkNet-53 卷积神经网络基础上,用组归一化方法替换原有批量归一化方法,同时引入 YOLOv3 算法对图像全局信息进行目标预测,准确率达到 95.6%。Vijayakumar 等^[14]利用 RESNET152 深度学习卷积神经网络对火龙果成熟度和采收时间进行识别应用,在 10~500 个 epoch 范围内,与 VGG16/19 相比,其准确率更高。穆龙涛等^[15]以改进的 AlexNet 为特征提取层,将全连接层 L6、L7 的节点数修改为 768 和 256,在遮挡且复杂光照条件下图像识别精度为 96.00%。张瑞青等^[16]对比分析了 ResNet18、AlexNet 和 GoogLeNet 等模型性能,通过迁移 AlexNet 卷积层对花生荚果等级识别模型进行改进,用批归一化替换局部响应归一化,且将激活函数置于批归一化层前后不同位置,设计了 4 种不同模型,构建的花生荚果等级识别模型(PA 模型)的识别准确率达 95.43%。课题组^[17]采用迁移学习进行香蕉成熟度等级分级达到了较好的识别效果,但原始的 VGG16、AlexNet 等模型结构复杂,参数多,且应用时对硬件要求较高。

近年来出现的 AlexNet^[18]、VGG、ResNet、Inception 等算法不断提升了图片分类的准确率,但模型规模大、参数多、计算量大,一方面外部特征提取程序需要更多时间来产生输出,另一方面需要高性能设备来支持,如高性能计算机或光谱相机等专业输入设备。随着智能移动设备处理器、摄像头性能不断升级,并搭载智能操作系统,不

少学者尝试改进设计轻量化模型应用于小巧型移动设备和嵌入式设备,典型代表有 MobileNet、SqueezeNet、ShuffleNetV2 等,或是通过改进网络结构缩小模型。孙道宗等^[19]使用 iPhone11 手机自带相机拍摄复杂背景下茶树叶片图像,选择经典轻量级卷积神经网络 SqueezeNet 对铁观音、黄枝香、英红九号、老仙翁、鸡笼刊和鸭屎香 6 种不同茶树叶片进行分类,通过将 Fire 模块中 3×3 标准卷积核替换为深度可分离卷积,进一步缩小网络模型,降低网络对硬件资源的要求,同时引入注意力机制,最终测试集准确率为 90.5%,参数量为 3.69×10^5 ,分类速度为 0.109 s/幅,更有利于将卷积神经网络模型部署在移动终端等资源受限设备上。李阳德等^[20]提出了轻量级 MobileNet V3-YOLOv4 网络,参数量为 53.7 MB,训练好的 MobileNet V3-YOLOv4 的验证集精度均值为 90.92%,对于黄熟期菠萝和青熟期菠萝两种类别的检测精确率分别为 100.00% 和 98.85%,平均精度值分别为 87.62%,94.21%,推理速度为 80.85 s^{-1} ,在提高训练速度、减小参数量的同时,提高了菠萝成熟度识别精度和推理速度。吕金锐等^[21]将轻量级网络 MobileNetv3 替换 CSPDarkNet53 网络,提出了一种改进的 YOLOv4 模型用于番茄成熟度自动检测,模型参数量少复杂度低,mAP 值为 92.50%,检测速度为 37.1 FPS,模型参数量为 48 M,具有较高的番茄成熟度检测效率。李志臣等^[22]基于 ShuffleNet 构建改进轻量级卷积神经网络实现了高精度板栗自动分级,在自然光条件下用小米 Note9 手机拍摄获取包含优等品、一等品、合格品、虫蛀品和霉烂品板栗 5 481 幅图像应用于卷积网络模型的训练、验证和测试,分类性能与各种深度学习模型如 AlexNet、Mnet-1、ResNet18 进行了比较分析,改进后模型准确率达 98.90%,坏板栗被分为好板栗的比例 $< 0.5\%$,计算量小,板栗图像分类时间为 26 ms,其权重仅占 488 KB 物理存储容量。

上述提及的轻量级算法虽然从网络模型层面进行了小型化改进,但实际仍运行在具有高性能、高价格的计算机设备上,而不是直接实践于更便宜的移动设备或嵌入式设备上。在实际农业生产中,往往要考虑生产成本及易用性,如 Zhou 等^[23]开发了一款基于 CNN-SSD 的轻型现场猕猴桃检测智能手机应用程序,在 HUAWEI P20 智能手机上实现单张图像 103 ms 的最快检测速度;Genaev 等^[24]提出了一种基于 yolov4-tiny 的算法来识别果蝇并确定其性别,该算法使用 3 种不同的增强策略进行训练,并开发了一款名为 FlyCounter 的 Android 应用程序,用于在手机上本地进行实时识别,处理图像时间接近 4 s。Zeng 等^[25]提出了一种基于 YOLOv5 的轻量级改进算法来实现番茄果实实时定位和成熟度检测,在中央处理器平台上检测速度为 42.5 ms,进一步利用 Nihui 卷积神经

网络框架对改进模型进行轻量化,开发了基于 android 的番茄实时监测应用 APP,在移动端平均检测帧率为 26.5 帧/s,且算法功耗较低,比原始 YOLOv5s 提高了 268%,模型尺寸缩小了 51.1%,真实检测率达 93%。Elwirehardja 等^[26]采用智能手机自带数码相机拍摄油棕 FFB 的 6 个类别:未熟、半熟、熟、过熟、异常和空果束,分别训练了 MobileNetV1、MobileNetV2、NASNet Mobile、EfficientNetB0 等轻量级网络,最佳模型为结合迁移学习、9 角裁剪和 float16 量化训练的 EfficientNetB0,该模型在 TensorFlow Lite 上以 96 ms/幅图像的分类时间实现了 0.893 的整体测试精度,远远超过了其他 3 个模型。将模型应用至 Android 上,通过实时摄像头输入获得的油棕 FFB 图像成熟度进行分类,也能获得类似结果。

试验拟重点研究如何结合智能移动设备的优势及香蕉自身不同成熟度的特征,得到简单易用、低成本的香蕉成熟度实时、快速判别的安卓 APP 应用,以期为日常生活和工业生产应用提供依据。

1 数据来源

1.1 样本数据

香蕉样品来源于广西南宁市某农贸市场,质量为 32.6 kg。为确保香蕉样品处于果面全绿的 Green 成熟度等级、大小均匀、表皮完好无黑斑等缺陷,需对香蕉样品进行筛选,筛选后的香蕉样品数为 217 个,并对其进行常温 $[(20\pm 5)^{\circ}\text{C}]$ 左右]催熟。图像采集装置由 400 mm $\times$ 400 mm $\times$ 450 mm 的木箱改造而成,内壁覆盖白纸,底板覆盖米白色绒布放置待测样品。为模拟正常室内光照强度环境,选用功率 10 W、色温 6 500 K 可调白色环形 LED 灯管。采用华为 NOVA 2S 手机作为图片拍摄工具,通过采集装置顶部预留窗口对香蕉进行图片采集。在香蕉逐步成熟过程中,每天定时拍摄每只香蕉图像 2 幅,直至失去食用价值,智能移动设备后置摄像头图片采集参数见表 2。

1.2 数据增强

因在拍摄过程中需反复翻动香蕉,导致部分蕉体损伤腐烂而无法用于拍照,最终将所获取的可用香蕉样本数据集分为 5 个等级,每个成熟等级 120 张图片。因样本

数量较少,为保证试验的有效性和可重复性进行数据增强。香蕉颜色是区分不同成熟度等级的主要表征,且极易受到外界光线的影响,因此在对香蕉图像进行增强时不能随意改变原有图像颜色。为更好解决香蕉成熟度判别难点,借助 OpenCV 软件,采用翻转、旋转、调节亮度、添加噪声等手段完成样本图像数据增强。增强后的样本数据集中 5 个不同成熟度等级图片各 1 800 张,数据增强结果如图 1 所示。




图 1 增强后的香蕉图片

Figure 1 Banana image after augmentation

1.3 试验环境

搭载 Intel® Core™ i5-10500H CPU@2.50 GHz 处理器,内存为 16.0 GB,显卡型号 NVIDIA GeForce RTX 3060 Laptop 计算机;采用 Windows11 64bit 操作系统,深度学习框架 Pythorch1.12 + cuda11.6, Python3.7.13, Android Studio 2022.0.1。

2 基于 Alexnet 的香蕉成熟度判别模型

选择参数量相对较少,模型复杂度低,运行时占用内存较小,不易导致过拟合和梯度消失且在迁移学习中香蕉成熟度判别准确率表现最好的 AlexNet 作为基础模型进行改进,常用深度神经网络模型参数见表 3。

2.1 AlexNet 网络结构

Alexnet^[18]有 5 个卷积层、3 个池化层和 3 个全连接层,其模型结构如图 2 所示。

2.2 改进的 Alexnet 模型

ImageNet 数据集包含了香蕉类别,但只区分某个物体是否是香蕉,无法判别香蕉成熟度,AlexNet 包含 6 000 余万个参数,近 65 万个神经元,6 亿 3 000 万个连接,训练完成后.pth 模型大小为 247 MB,对移动平台硬件要求较高。试验提出一种基于 Alexnet 卷积神经网络的

表 2 智能移动设备后置摄像头图片采集参数

Table 2 Intelligent mobile device rear camera image acquisition parameter settings

项目	单位	参数	项目	单位	参数
焦距	mm	27	操作模式		AUTO
放大倍数		1.5	曝光时间	s	0.01
闪光灯状态		Off	分辨率		3 456 $\times$ 3 456
感光度	ISO	80	光圈		F1.8

表 3 常用深度神经网络参数

Table 3 Common deep neural network parameters

神经网络	模型内存/ MB	参数 ($\times 10^6$)	FLOPs/ G	准确率 ^[17] / %
AlexNet	237.95	62.38	0.71	95.56
VGG16	527.79	138.36	15.50	95.00
VGG19	548.05	143.67	19.67	88.89
ResNet50	97.49	25.56	4.12	91.11
ResNet101	169.94	44.55	7.84	92.78
Densenet121	30.44	79.79	2.88	91.67
Densenet201	76.35	20.01	4.37	94.44
GoogLeNet	25.27	6.62	1.51	91.67




图 2 AlexNet 模型结构

Figure 2 AlexNet model structure

Mini-Alexnet 香蕉成熟度判别模型,在保证香蕉成熟度判别模型准确率的同时,尽可能缩减模型大小、提升运行效率,降低对智能移动设备的性能要求。

经大量试验对比和经验总结,在保证香蕉成熟度判别模型准确率的基础上,对 AlexNet 网络进行改进:

(1) 首个卷积层 conv1 的卷积核从 11×11 增大到 15×15 ,pad 由 2 增加到 3,第 3 个卷积层 conv3 卷积核从 3×3 增大到 6×6 ,卷积核越大,全局特征越好,可降低因香蕉相近成熟度等级局部特征相似导致的判别错误。

(2) 删除所有 LRN 层。LRN 层是一种神经元竞争机制,响应明显的神经元放大其特征,而反馈不明显的神经元被抑制,而香蕉成熟度等级判别需要依赖全局特征,局部特性的过度区分反而降低判别准确率,故删除所有 LRN 层,使用批规范化(BN)进行归一化操作,加速训练收敛过程,提升模型泛化能力。

(3) 全连接层(FC)位于模型最后 3 层,起到最终分类作用。模型大部分参数来源于全连接层,节点越多,特征权重越多,模型更容易过拟合,增加模型训练难度。简化全连接层将大大缩减模型结构,提升效率^[11-14]。Mini-AlexNet 利用全局平均池化代替全连接层 FC1、FC2,降低模型参数量及所需内存。

(4) 为了进一步减小模型大小,更利于部署至移动终端,轻量化改进的 Mini-AlexNet 模型还删除了原 Alexnet

模型中的第 3、4 个卷积层,在不影响判别效果的前提下,进一步减少模型参数量和运行需消耗的内存。

(5) 删除分组操作。为提升训练速度,AlexNet 利用两块显卡进行并行训练,目前计算机硬件单卡已满足训练能力,故不采用分组训练。

改进后的模型结构如图 3 所示。




图 3 Mini-AlexNet 模型结构

Figure 3 Mini-AlexNet model structure

2.3 模型评价指标

2.3.1 模型评估指标 运用准确率、精确率、召回率和 F_1 分数 4 个参数来判断模型判别性能,结果见表 4。

$$A = \frac{T_P + T_N}{T_P + T_N + F_P + F_N}, \quad (1)$$

$$P = \frac{T_P}{T_P + F_P}, \quad (2)$$

$$R = \frac{T_P}{T_P + F_N}, \quad (3)$$

$$F_1 = 2 \frac{PR}{P+R}, \quad (4)$$

式中:

A——准确率, %;

P——精确率, %;

R——召回率, %;

F_1 ——基于精确率与召回率的调和平均定义的量, %;

T_P ——将正类预测为正类数;

T_N ——将负类预测为负类数;

表 4 香蕉不同成熟度等级的准确率、精确率、召回率及 F_1 分数

Table 4 Accuracy, precision, recall, F_1 -score for different ripeness levels of bananas %

成熟度等级	准确率	精确率	召回率	F_1 -分数
Level 1	100.00	96.98	100.00	98.47
Level 2	94.12	97.25	94.44	95.82
Level 3	96.44	96.88	96.44	96.66
Level 4	99.33	98.68	99.33	99.00
Level 5	99.55	100.00	99.56	99.78

F_P ——将负类预测为正类数;

F_N ——将正类预测为负类数。

2.3.2 共计参数量和可训练参数量 共计参数量是模型所有带参数层的权重参数总量,总参数量与卷积核尺寸、通道数、层数相关,模型参数越多,训练模型所需数据量越大。可训练参数是指除了可以冻结的、不参与训练的结构参数,剩下的均为可训练参数,可训练参数在训练过程中值会被更新,占用更多内存。

2.3.3 图片预处理后的大小 大部分神经网络模型要求输入的图片大小是固定的,但是由于数据来源不同,大多数情况下会遇到数据集图片大小不统一,需通过一些手段进行图片预处理,如果图片尺寸长宽不相等,可以通过 crop 和 pad 两种方式使长宽相等,如果图片长宽相等,可以通过 resize 进行图片尺寸转换,直到满足模型图片输入尺寸需求。

2.3.4 前向/反向传播一次的内存大小 前向传播(forward propagation 或 forward pass)指的是按顺序(从输入层到输出层)计算和存储神经网络中每层的结果,图 4 是以单隐藏层简单网络为例。




图 4 前向传播的计算图

Figure 4 Calculation diagram of forward propagation

反向传播(backward propagation 或 back propagation)是计算神经网络参数梯度的方法。根据微积分中链式规则,按相反的顺序从输出层到输入层遍历网络,该算法存储了计算某些参数梯度时所需的任何中间变量(偏导数)。

在进行深度学习模型训练时,正向传播和反向传播之间相互依赖,较深的神经网络大批量训练时需要更大内存,对硬件要求更高。而前向/反向传播所需的内存大小为模型所有层输出大小和的 2 倍。

2.3.5 模型大小 模型越小,运行时所耗费的设备内存越小,可适应的移动平台越广泛。试验中发现,一旦出现内存消耗过大,会导致安卓 APP 应用运行慢、卡顿、闪退甚至设备死机,非常影响用户体验感。因此在保证模型判别准确率的情况下,模型越小,越利于部署于智能移动设备。

3 结果与分析

3.1 Alexnet 模型

试验共训练 50 个 epoch。由图 5 可知,模型于 20 个




图 5 Alexnet 模型训练结果

Figure 5 Alexnet model training results

epoch 后开始趋向收敛,模型收敛时训练用时为 1 755 s,此时模型最佳判别准确率达 96.8%,但模型在训练过程中稳定性差,波动性较大。

3.2 改进的 Alexnet

3.2.1 采用全局池化层代替 Alexnet 全连接层的 Alexnet-1 模型 由图 6、图 7 可知,采用全局平均池化训练过程比较稳定,模型参数量缩减为 3 050 629,模型收敛后准确率为 96.58%,而采用全局最大池化会出现个别突




图 6 全局平均池化层代替 Alexnet 全连接层的 Alexnet-1 模型的训练结果

Figure 6 Training results of Alexnet-1 model with global average pooling layer instead of Alexnet full connection layer




图 7 全局最大池化层代替 Alexnet 全连接层的 Alexnet-1 模型的训练结果

Figure 7 Training results of Alexnet-1 model with global max pooling layer instead of Alexnet full connection layer

变结果,训练不稳定,且随着训练进行,出现轻微过拟合,同时模型准确率也只有 96.31%。

3.2.2 在 Alexnet-1 模型基础上删除卷积层的 Alexnet-2 模型 由图 8 可知,删除第 3、4 个卷积层后,模型复杂度降低,看似会影响准确率,但在香蕉成熟度判别时,收敛后最大准确率未降低,反而提升至 97.07%,模型在 18 个 epoch 后开始趋于收敛。

3.2.3 在 Alexnet-2 模型基础上采用大尺寸卷积核的 Mini-Alexnet 模型 由图 9 可知,采用大卷积核替换 Alexnet-2 模型中的小卷积核后,模型收敛后最大准确率提升至 97.96%,且模型在 15 个 epoch 后开始趋于收敛,缩减了收敛时间。




图 8 Alexnet-2 模型训练结果
Figure 8 Training results of Alexnet-2 model

3.2.4 改进后的 Mini-Alexnet 与其他模型的性能对比

由表 5 可知,Mini-Alexnet 模型所需训练时间最短, batchsize 为 128 张图片,准确率最高为 97.96%,模型大小约为原 Alexnet 模型的 1/20,大大降低了模型部署至移动端的难度。SqueezeNet、ShuffleNetV2 模型尺寸虽小,但网络结构较复杂,在实际训练时 batchsize 只能取 2,一定程度上影响了模型泛化能力,且训练时长会稍长,模型大小与 Mini-Alexnet 相差较小的情况下,准确率更低,其中 MobileNetV3-small 准确率最差为 87.52%。Mini-Alexnet 模型大小虽不是最小的,但前向/反向传播一次的内存大小所需最小,其在移动终端可以顺畅运行,且准确率最高,泛化能力最强,更适合实际应用。




图 9 Mini-Alexnet 模型训练结果
Figure 9 Training results of Mini-Alexnet model

表 5 Mini-Alexnet 与其他模型性能对比

Table 5 Performance comparison between Mini-Alexnet and other models

模型	共计参 数量	可训练参 数量	图片预处理后 的大小/MB	前向/反向传播一次 的内存大小/MB	总参数量的 大小/MB	总大小/ MB	准确率/ %	模型大 小/MB	训练时 间/min
Alexnet	62 378 344	62 378 344	0.57	11.05	237.95	249.58	96.80	246.77	29
Mini-Alexnet	3 050 629	3 050 629	0.57	3.66	11.64	15.88	97.96	11.60	26
MobileNetV3-small	1 672 715	1 672 715	0.57	46.84	6.38	53.79	87.52	6.64	34
ShuffleNetV2	1 258 729	1 258 729	0.57	47.93	4.80	53.31	90.51	4.96	31
SqueezeNet	737 989	737 989	0.57	89.23	2.82	92.62	91.19	2.83	41

4 模型部署至移动端

4.1 香蕉成熟度自动判别 APP 设计流程

基于 Android Studio 平台将改进后的 Mini-Alexnet 模型部署成 APP 应用于移动设备,其灵活性更大,使用更便利。APP 香蕉成熟度自动判别系统有两种登录模式,一种是账号密码登录,可以选择加载本地图片、移动端摄像头拍摄图片、启动移动端摄像头实时识别 3 种不同途径获取 3 通道彩色图片作为输入;另一种不需要账号密码的游客登录模式,只能加载本地图片作为输入。如果选用第一种登录模式,当账号密码错误时,会自动退回登录页面要求用户重新登录或者选用游客模式。系统进入成功之后,无论哪种方式输入图片,图片输入之后,

先将尺寸变换为 224×224 ,然后模型开始判别香蕉成熟度等级,最后返回识别结果,如果判别过程中出现异常,系统退回登录界面,重新开始上述过程。系统的设计流程如图 10 所示。

4.2 香蕉成熟度自动判别系统 APP

4.2.1 香蕉成熟度自动判别系统 APP 香蕉成熟度自动判别系统完成后,为了验证其实用性,重新收集 150 张图片,每个成熟度等级图片各 30 张,进行成熟度判别验证,考虑到实际应用时图片来源的多样化,测试图片来源于 3 个不同途径,其中 1/3 图片为市场上随机采购的不同成熟度等级的香蕉,在试验装置中拍摄获得,另 1/3 图片为市场采购的香蕉进行随机背景拍摄获得,剩下 1/3 为网络图片。




图 10 香蕉成熟度自动判别安卓系统 APP 设计流程图
Figure 10 Design flowchart of an android system APP for automatic determination of banana ripeness

4.2.2 香蕉成熟度自动判别系统测试 经测试,该系统判别准确率比计算机训练时验证集验证准确率稍低。测试中, Green、Green-Yellow、Yellow-Green、Ripen、OverRipen 5 个等级分别在不同模式下进行 30 次测试。由于图片来源不统一,在测试过程中使用试验装置拍摄的 1/3 图片判别准确率明显高于另外两种情况,可能是不同背景对判别结果产生了干扰,后续需进一步研究如何规避实际应用时各种不同背景对判别结果的影响,以及加入语音提醒功能、增加多种水果成熟度判别能力,除

了辅助工业生产,也更利于日常生活使用,特别是为盲人提供便利。本地图片分类判别所需时间最短;实时识别模式所需时间最长,外界光线对香蕉判别时长、判别准确率影响最大。与其他类别相比,Green 的特征区别最大,其在 3 种不同测试模式下的准确率均最高;Green-Yellow 由于是果皮黄色和绿色过渡阶段,表皮泛黄但绿色占主要,会被误判为 Green 和 Yellow-Green,准确率最低;Yellow-Green 果皮大部分呈黄色,仍有少量绿色,整体呈黄绿色,会被误判为 Green-Yellow,果皮绿色占比较少的还会被误判为 Ripen;Ripen 果皮几乎全黄,仅果柄处残留极少量绿色或果皮全黄,但未出现黑色“梅花点”,判别时会被误判为 Yellow-Green;OverRipen 果面全黄并出现黑色“梅花点”,特征比较容易区分,故在判别时只有个别“梅花点”分布少且稀疏的香蕉会被判别为 Ripen,但是“梅花点”分布量大且密集的香蕉均会被判别为 OverRipen。

由表 6 可知,本地图片模式、拍照模式和实时模式下,香蕉五等级成熟度判别平均准确率分别为 86.66%, 79.33%, 74.00%, 因实时模式下受到环境光线因素影响最大,是后期优化的重点之一。3 种不同判别模式下 Green 的准确率最高为 87.78%, 最低为 Green-Yellow, 由于外表特征处于过渡的特殊阶段,其可能会被判别为 Green 和 Yellow-Green,也是后期优化重点之一。香蕉成熟度五等级判别系统 3 种不同模式下平均准确率达到 80.00%, 可以初步满足生活和工业辅助应用。

表 6 香蕉成熟度自动判别系统 APP 实际应用测试

Table 6 Practical application test of banana ripeness automatic discrimination APP

成熟度 等级	本地图片模式			拍照模式			实时模式			平均准 准确率%
	测试次数	正确次数	准确率/%	测试次数	正确次数	准确率/%	测试次数	正确次数	准确率/%	
Green	30	28	93.33	30	26	86.67	30	25	83.33	87.78
Green-Yellow	30	23	76.67	30	21	70.00	30	19	63.33	70.00
Yellow-Green	30	25	83.33	30	23	76.66	30	20	66.67	75.55
Ripen	30	26	86.67	30	24	80.00	30	23	76.67	81.11
OverRipen	30	28	93.33	30	25	83.33	30	24	80.00	85.55
平均值	30	26.00	86.66	30	23.80	79.33	30	22.20	74.00	80.00

5 结论

研究基于 AlexNet 和不同成熟度香蕉表皮外部特征,设计了一款小型化改进型 Mini-Alexnet 模型用于香蕉成熟度检测。改进后的 Mini-Alexnet 模型仅为 11.6 MB,香蕉五等级成熟度判别准确率为 97.76%, 相比原 Alexnet 更利于部署至移动设备。模型 APP 判别系统可以在 3 种不同模式下进行香蕉五等级成熟度判别,其

中本地图片识别模式下的平均准确率可达 86.66%, 判别速度约 50 ms/幅;拍照识别模式下由于会受到拍照者拍照效果的影响,平均准确率略低为 79.33%, 判别时间约 55 ms;实时识别模式下受外界光线影响,平均准确率为 74.00%, 判别效果相对较差,判别速度相对较慢,后期需进一步优化。该 APP 可根据实际应用需求选择不同判别模式,且简单易用、普适性广、造价低。

但香蕉成熟度自动判别系统对 Green-Yellow、

Yellow-Green 两个香蕉成熟度等级平均判别准确率均未达到 80%,降低了系统整体判别准确率。因此,设计表皮特征提取性能更优的网络模型是提升香蕉成熟度自动判别系统判别准确率的一大难题;且在测试中发现光线和背景物体对所有香蕉成熟度等级判别均会产生影响,在实时识别模式下表现尤为明显,如何降低外界因素对系统判别准确率的影响是提升系统性能的另一大难题。该系统虽然可以辅助色盲、色弱人士进行香蕉成熟度判别,但对于完全视觉障碍的盲人用户却不是很友好。后续可通过采集不同背景及不同光照条件的图片进一步扩充数据集样本数量,设计复杂环境下颜色特征提取能力更强的网络模型,以提升香蕉成熟度自动判别系统判别准确率,并开发 APP 语音功能,为盲人用户提供便利,进一步提升系统的实用性和适用性。

参考文献

- [1] 刘海军, 赵文锋, 刘韵锋, 等. 基于 ANN 和贝叶斯优化算法的香蕉成熟度检测模型研究[J]. 现代农业装备, 2021, 42(5): 42-46.
- [2] LIU H J, ZHAO W F, LIU Y F, et al. Model for detecting banana maturity based on artificial neural network and bayesian optimization algorithm[J]. Modern Agricultural Equipment, 2021, 42(5): 42-46.
- [3] 刘阳泰, 董庆利, 秦智轩, 等. 基于 Android 智能手机图像分析判定香蕉成熟阶段[J]. 食品与发酵工业, 2016, 42(1): 212-218.
- [4] LIU Y T, DONG Q L, QIN Z X, et al. Determination of banana ripening stage based on Android smartphone image analysis[J]. Food and Fermentation Industry, 2016, 42(1): 212-218.
- [5] 王顺. 水果成熟度检测的机器视觉和嗅觉可视化技术研究[D]. 杭州: 江苏大学, 2018: 2-5.
- [6] WANG S. Research on machine vision and olfactory visualization technology for fruit maturity detection [D]. Hangzhou: Jiangsu University, 2018: 2-5.
- [7] SANAEIFAR A, MOHTASEBI S S, GHASEMI-VARNAMKHAISTI M, et al. Application of MOS based electronicnose for the prediction of banana quality properties[J]. Measurement, 2016, 82: 105-114.
- [8] RAJKUMAR P, WANG N, EIMASRY G, et al. Studies on banana fruit quality and maturity stages using hyperspectral imaging[J]. Journal of Food Engineering, 2012, 108(1): 194-200.
- [9] 黎源鸿, 王红军, 邓建猛, 等. 基于 PCA-ELM 和光谱技术预测香蕉成熟度[J]. 现代食品科技, 2017, 33(10): 268-274.
- [10] LI Y H, WANG H J, DENG J M, et al. Prediction of banana maturity based on PCA-ELM and spectral technology[J]. Modern Food Technology, 2017, 33(10): 268-274.
- [11] SOLTANI M, ALIMARDANI R, OMID M. Prediction of banana quality during ripening stage using capacitance sensing system[J]. Australian Journal of Crop Science, 2010, 4(6): 443-447.
- [12] CHEN C R, RAMASWAMY H S. Color and texture change kinetics in ripening bananas[J]. LWT-Food Science and Technology, 2002, 35(5): 415-419.
- [13] 樊刚伦. 香蕉无损采收及采后商品处理技术[J]. 农业与技术, 2012, 32(11): 104.
- [14] FAN G L. Techniques for harmless harvesting and postharvest commodity treatment of bananas[J]. Agriculture and Technology, 2012, 32(11): 104.
- [15] 王文超, 葛凤丽, 徐文凯, 等. 水果品质分选机的研发[J]. 食品与机械, 2022, 38(9): 98-102.
- [16] WANG W C, GE F L, XU W K, et al. Research and development of fruit quality sorting machine[J]. Food & Machinery, 2022, 38(9): 98-102.
- [17] 陈锋军, 张新伟, 朱学岩, 等. 基于改进 EfficientDet 的油橄榄果实成熟度检测[J]. 农业工程学报, 2022, 38(13): 158-166.
- [18] CHEN F J, ZHANG X W, ZHU X Y, et al. Maturity detection of olive fruit based on improved EfficientDet[J]. Transactions of the Chinese Society of Agricultural Engineering, 2022, 38(13): 158-166.
- [19] 朱旭, 马湫, 姬江涛, 等. 基于 Faster R-CNN 的蓝莓冠层果实检测识别分析[J]. 南方农业学报, 2020, 51(6): 1 493-1 501.
- [20] ZHU X, MA H, JI J T, et al. Detection and identification analysis of blueberry canopy fruits based on Faster R-CNN[J]. Journal of Southern Agriculture, 2020, 51(6): 1 493-1 501.
- [21] 王辉, 张帆, 刘晓凤, 等. 基于 DarkNet-53 和 YOLOv3 的水果图像识别[J]. 东北师大学报(自然科学版), 2020, 52(4): 60-65.
- [22] WANG H, ZHANG F, LIU X F, et al. Fruit image recognition based on DarkNet-53 and YOLOv3 [J]. Journal of Northeast Normal University (Natural Science Edition), 2020, 52(4): 60-65.
- [23] VIJAYAKUMAR T, VINOTHKANNA R. Mellowness detection of dragon fruit using deep learning strategy[J]. Journal of Innovative Image Processing, 2020(1): 35-43.
- [24] 穆龙涛, 高宗斌, 崔永杰, 等. 基于改进 AlexNet 的广域复杂环境下遮挡猕猴桃目标识别[J]. 农业机械学报, 2019, 50(10): 24-34.
- [25] MU L T, GAO Z B, CUI Y J, et al. Recognition of occluded kiwifruit targets in wide-area complex environments based on improved AlexNet[J]. Journal of Agricultural Machinery, 2019, 50(10): 24-34.
- [26] 张瑞青, 李张威, 郝建军, 等. 基于迁移学习的卷积神经网络花生荚果等级图像识别[J]. 农业工程学报, 2020, 36(23): 171-180.
- [27] ZHANG R Q, LI Z W, HAO J J, et al. Convolutional neural network based on transfer learning for peanut pod level image recognition[J]. Transactions of the Chinese Society of Agricultural Engineering, 2020, 36(23): 171-180.
- [28] 王灵敏, 蒋瑜. 基于深度学习的香蕉成熟度自动分级[J]. 食品

- 与机械, 2022, 38(11): 149-154.
- WANG L M, JIANG Y. Automatic classification of banana ripeness based on deep learning[J]. Food & Machinery, 2022, 38(11): 149-154.
- [18] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6): 84-90.
- [19] 孙道宗, 丁郑, 刘锦源, 等. 基于改进 SqueezeNet 模型的多品种茶树叶片分类方法[J]. 农业机械学报, 2023, 54(2): 223-230, 248.
- SUN D Z, DING Z, LIU J Y, et al. A multi variety tea tree leaf classification method based on improved SqueezeNet model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(2): 223-230, 248.
- [20] 李阳德, 马晓慧, 王骥. 基于轻量级 MobileNet V3-YOLOv4 的生长期菠萝成熟度分析[J]. 智慧农业(中英文), 2023, 5(2): 35-44.
- LI D Y, MA X H, WANG J. Analysis of pineapple maturity during growth period based on lightweight MobileNet V3-YOLOv4[J]. Smart Agriculture, 2023, 5(2): 35-44.
- [21] 吕金锐, 付燕, 倪美玉, 等. 基于改进 YOLOv4 模型的番茄成熟度检测方法[J]. 食品与机械, 2023, 39(9): 134-139.
- LU J R, FU Y, NI M Y, et al. Research on tomato maturity detection method based on improved YOLOv4 model[J]. Food & Machinery, 2023, 39(9): 134-139.
- [22] 李志臣, 凌秀军, 李鸿秋, 等. 基于改进 ShuffleNet 的板栗分级方法[J]. 山东农业大学学报(自然科学版), 2023, 54(2): 299-307.
- LI Z C, LING X J, LI H Q, et al. Chestnut grading method based on improved ShuffleNet[J]. Journal of Shandong Agricultural University (Natural Science Edition), 2023, 54(2): 299-307.
- [23] ZHOU Z, SONG Z, FU L, et al. Real-time kiwifruit detection in orchard using deep learning on Android™ smartphones for yield estimation[J]. Comput Electron Agric, 2020, 179: 105856.
- [24] GENAEV M A, KOMYSHEV E G, SHISHKINA O D, et al. Classification of fruit flies by gender in images using smartphones and the YOLOv4-tiny neural network[J]. Mathematics, 2022, 10(3): 295.
- [25] ZENG T, LI S, SONG Q, et al. Lightweight tomato real-time detection method based on improved YOLO and mobile deployment[J]. Computers and Electronics in Agriculture, 2023, 205: 107625.
- [26] ELWIREHARDJA G N, PRAYOGA J S. Oil palm fresh fruit bunch ripeness classification on mobile devices using deep learning approaches[J]. Computers and Electronics in Agriculture, 2021, 188: 106359.

(上接第 20 页)

- [31] 于美娟, 杨慧, 黄绿红, 等. 传统鲈鱼固态发酵过程中细菌群落与挥发性风味物质的相关性[J]. 食品与机械, 2023, 39(3): 1-10.
- YU M J, YANG H, HUANG L H, et al. The potential correlation between bacterial community and the characteristic volatile flavour of traditional fermented fish during solid fermentation[J]. Food & Machinery, 2023, 39(3): 1-10.
- [32] 张春林, 杨亮, 李喆, 等. 酱香型白酒酒醅堆积微生物多样性及其与风味物质的关系[J]. 食品科技, 2022, 47(4): 111-118.
- ZHANG C L, YANG L, LI Z, et al. Microbial community and its relationship with volatile compounds in Moutai-flavor Baijiu stacking fermentation process[J]. Food Science and Technology, 2022, 47(4): 111-118.
- [33] 于倩倩, 李聪, 周辉, 等. 发酵肉制品风味分析及形成途径研究[J]. 肉类工业, 2019(11): 52-58.
- YU Q Q, LI C, ZHOU H, et al. Study on flavor analysis of fermented meat product and its forming way[J]. Meat Industry, 2019(11): 52-58.
- [34] 张盼文, 李浩, 徐钰红, 等. 一株来源于豆豉的地衣芽孢杆菌全基因组学及其风味物质形成分析[J]. 食品与发酵工业, 2022, 48(19): 36-44.
- ZHANG P W, LI H, XU Y H, et al. Whole genome and flavor formation analysis of a *Bacillus licheniformis* strain from Douchi [J]. Food and Fermentation Industries, 2022, 48(19): 36-43.

(上接第 42 页)

- [20] XU P C, QIAN Y X, WANG R, et al. Entrapping curcumin in the hydrophobic reservoir of rice proteins toward stable antioxidant nanoparticles[J]. Food Chemistry, 2022, 387: 132906.
- [21] LI Z P, LIN Q Q, MCCLEMENTS D J, et al. Curcumin-loaded core-shell biopolymer nanoparticles produced by the pH-driven method: Physicochemical and release properties [J]. Food Chemistry, 2021, 355: 129686.
- [22] LI M L, LIU Y B, LIU Y, et al. pH-driven self-assembly of alcohol-free curcumin-loaded zein-propylene glycol alginate complex nanoparticles [J]. International Journal of Biological Macromolecules, 2022, 213: 1 057-1 067.
- [23] JOG R, BURGESS D J. Pharmaceutical amorphous nanoparticles [J]. Journal of Pharmaceutical Sciences, 2017, 106(1): 39-65.
- [24] ZHANG D C, JIANG F Y, LING J H, et al. Delivery of curcumin using a zein-xanthan gum nanocomplex: Fabrication, characterization, and in vitro release properties[J]. Colloids and Surfaces B: Biointerfaces, 2021, 204: 111827.