

[文章编号] 1003-4684(2023)05-0029-05

# 基于 ResNet18 网络的油茶果壳籽分选研究

董 庚<sup>1</sup>, 王焱清<sup>1,2</sup>, 孙记委<sup>1,2</sup>, 段宇飞<sup>1,2</sup>

(1 湖北工业大学农机工程研究设计院, 湖北 武汉 430068; 2 湖北省农机装备智能化工程技术研究中心, 湖北 武汉 430068)

**[摘 要]** 油茶果脱壳后果壳与茶籽混合在一起, 油茶果的果壳与茶籽如何分选以及如何提升分选的准确率, 是油茶果产业化所面临的一个难题。基于改进 ResNet18 模型的油茶果果壳与茶籽的分选模型, 通过油茶果分选机进行图片的采集和处理获取实验样本图像, 比较不同批量尺寸、学习率、激活函数以及优化器的影响, 进一步优化模型。实验表明, 经过改进后的 ResNet18 模型, 与未改进前相比, 在损失函数上有了明显的降低, 并且验证集准确率得到提升, 验证集平均准确率由之前的 97.03%, 而最终测试集准确率由 97.25% 提高至 97.75%。较高的准确率可以满足油茶果分选的需要。

**[关键词]** 深度学习; 油茶果; 分选; ResNet18 模型

**[中图分类号]** TP391.4 **[文献标识码]** A

油茶属于山茶科植物, 与油棕、油橄榄、椰子并称为世界四大木本食用油料作物, 其中富含多种不饱和脂肪酸, 有着“东方橄榄油”的称号<sup>[1-2]</sup>。近年来在我国脱贫政策的扶持下, 油茶的产量会进一步提高, 随着产量的提高, 油茶的产业化发展也迫在眉睫。油茶的产业化过程中, 油茶果的采摘、破壳、分选和榨油环节是重中之重, 会直接影响茶油的品质<sup>[3-5]</sup>。较高的分选准确率可以减少分选时间, 提高分选效率进而增加农户的经济效益, 对于推动油茶果产业化有着重要意义。

近年来, 卷积神经网络在农业当中有着广泛应用<sup>[6-8]</sup>, 谢为俊等<sup>[9]</sup>将卷积神经网络应用于油茶籽完整性识别当中, 通过对卷积神经网络的改进从而进一步提高了分辨的准确率, 最终优化后的准确率达到 98.05%, 训练时间为 0.58 h, 能够很好地满足油茶籽在线实时分选的要求。赵洋等<sup>[10]</sup>以 ResNet18 模型为基础, 将里面的残差卷积改为空洞卷积用于对花卉的识别, 改进后的模型识别精度达到了 97.78%, 对花卉分类有一定的可行性。张怡等<sup>[11]</sup>将 ResNet 卷积神经网络应用于绿茶种类的识别当中, 很好地区别了 8 种常见的绿茶, 最终的识别准确率达到 90.99%, 为茶叶种类识别提供了一种快捷高效的新方法。

经典的卷积神经网络模型有很多, 比如 AlexNet<sup>[12]</sup>, VGGNet<sup>[13]</sup> 以及 ResNet<sup>[14-16]</sup> 等。本文研究

方向是基于 ResNet18 模型探索与油茶果的分选是否能够很好地结合, 在原有的模型基础上优化模型, 提高分选的准确率与效率, 提升油茶果分选的经济效益。

## 1 材料与方法

### 1.1 油茶果分选机结构

油茶果分选机主要是由传动系统、样本采集系统、控制系统和喷吹系统组成。油茶果分选机先经滤网筛选出合适的样本, 其样本由上料口均匀掉落在下方的托盘当中, 电动机带动链条负责传动, 使托盘均速地传动到工业相机的下方, 相机将托盘内的信息拍照上传并进行壳籽信息的判断, 确定所在位置, 当油茶果果壳的托盘经过喷吹装置时传感器会将位置信息传送给 PLC 控制器。当 PLC 控制器确定果壳达到预定位置并获得果壳的判定信号后, 会打开对应电磁阀控制气体将果壳吹出, 而茶籽则自由掉落在下方的收集装置里为后续工序做准备。具体流程与油茶果分选机结构如图 1 图 2 所示。




图 1 油茶果分选机流程

[收稿日期] 2022-12-09

[基金项目] 湖北省重点研发计划项目(2020BBA042)

[第一作者] 董 庚(1994-), 男, 河南南阳人, 湖北工业大学硕士研究生, 研究方向为农产品智能化无损检测技术。

[通信作者] 王焱清(1963-), 男, 湖北鄂州人, 工学博士, 湖北工业大学教授, 研究方向为农业机械化及自动化。




图 2 油茶果分选机结构

1.2 实验样本的采取与处理

本文采用的油茶果样本为油茶果分选机与配套的工业相机对样本图像进行采集，采集后的整幅样本图像(1280 像素×1024 像素)如图 3 所示。




图 3 采集的样本图像

油茶果分选机的托盘将整幅样本图片分为均匀的 64 份，果壳与茶籽的混合体由上料口自然掉落，随机分布在托盘中，以确保样本的随机性。将采集的图像由 matlab 软件将其均匀裁剪，每张图片获得 64 张独立的样本图像(128 像素×128 像素)，独立的样本图像由油茶果、果壳与空格三部分组成，其中果壳的情况较为复杂，将其分为内壳和外壳做具体的区分，以达到更好的分选效果。具体图像如图 4 所示。




图 4 剪切后的四类样本图像

从图 4 可以看出，经摊晒破壳后的油茶果外壳

与茶籽在颜色和大小方面具有部分类似的特征，较难区分，影响分选的准确率。油茶果分选机共采集整幅样本图像 26 张，裁剪为 1664 张独立样本图像，其中内壳外壳样本数量与其他样本相比数量较少，取全部的 230 张外壳和 234 张内壳，与部分的 250 张空格和 250 张茶籽作为后续建模数据。考虑到数据较少会影响后续模型的训练，将其旋转 90°，180°与 270°，并增加图片亮度与降低图片噪声，扩充至 5784 张数据图像，其中的 70% 用作训练集，20% 用作验证集，另外的 10% 用来做测试集使用。

1.3 ResNet 算法研究

卷积神经网络在图片分类中具有出色的表现，但是仍然具有一定的局限性。一般情况下网络的准确度是随着网络深度同步增加的，但是现实情况是当深度增加到一个临界值后网络的准确度会降低，这就是卷积神经网络中的梯度消失现象<sup>[17]</sup>。其原因是网络深度增加过多以后造成从后向前传播的梯度变得过小，从而使权重不再更新。除此之外，随着网络深度的增加，参数量也会变得更大，导致模型的优化变得更加困难，出现训练误差更大的问题。为了解决上述问题，He 等<sup>[14]</sup>提出了残差神经网络为基础的 ResNet 模型，其主要思想是在输入通道和输出通道之前使用跳过连接增加通道之间的联系，进而避免信息缺失的出现。在训练过程中学习上一环节的输残差，而不是将所有内容一并学习，从而减少工作量，节约时间和运行内存，降低模型的学习难度。残差单元如图 5 所示。

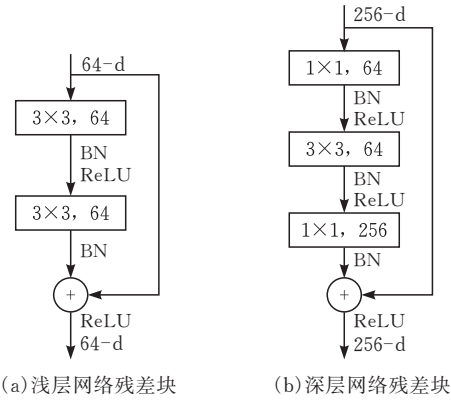


图 5 残差块结构

图 5 为 ResNet 中经常使用的两种残差块，其中(a)多用于浅层神经网络，(b)多用于深层神经网络，图 5a 输入数据经两条曲线在相交点通过卷积操作进行相加，然后由激活函数进行激活输出，相比图 5a 而言，图 5b 则在主线当中多了一个升维和降维的过程，其主要目的是节省参数，深层网络使用得越多就可以节省越多的参数，加快 ResNet 的运算速度，提升效率。

ResNet 模型有着不同的网络层数,常用的有 ResNet18、ResNet34 和 ResNet50,如果目标较为复杂的情况下还可以提升模型层数如 ResNet101 和 ResNet152。本文选用 ResNet18 模型为研究的主要模型,并针对不同的超参数进行优化,ResNet18 模型参数设置详见表 1。

表 1 ResNet18 参数设置

层数	输出尺寸	网络结构
Conv1	128×128	$\begin{bmatrix} 7\times7,4 \\ \text{最大池化层} \end{bmatrix}$
Conv2_x	64×64	$\begin{bmatrix} 3\times3,64 \\ 3\times3,64 \end{bmatrix}\times2$
Conv3_x	32×32	$\begin{bmatrix} 3\times3,128 \\ 3\times3,128 \end{bmatrix}\times2$
Conv4_x	16×16	$\begin{bmatrix} 3\times3,256 \\ 3\times3,256 \end{bmatrix}\times2$
Conv5_x	8×8	$\begin{bmatrix} 3\times3,512 \\ 3\times3,512 \end{bmatrix}\times2$
输出层	1×1	平均池化层 全连接层 SoftMax(4 维)


2 结果与分析

2.1 运行平台


本文实验搭建的训练环境为 Win11 操作系统,使用 CPU 进行模型训练,在 intel(R) Core(TM) i7-11800H 处理器中运行,Python 版本为 3.9.7,Pytorch 版本为 1.11.0。

2.2 批量尺寸对模型的影响

批量尺寸(batch\_size)指的是训练过程中每批运行使用图像的数量,是深度学习的重要参数。合适的批量尺寸能够提高模型测试集的准确率,对模型训练速度的提升也有较大的影响。为方便二进制的计算,习惯上选择为 2 的次幂。本文以批量尺寸(16、32、64、128)做为研究基础,探究不同因素对模型具体的影响。数据如图 6 所示。



(a)训练集损失函数数值




(b)验证集准确率

图 6 不同批量尺寸的损失值与验证集准确率的变化曲线


由图 6 可得,批量尺寸的大小与训练集损失函数成正比,与验证集准确率成反比,且越大的批量尺寸验证集准确率折线浮动越大,花费的时间也越多,过大的批量尺寸也会产生较大的内存消耗,不利于长时间运行,因此选用 32 作为 ResNet18 的批量尺寸。

2.3 学习率对模型性能的影响

学习率(Learning rate)是深度学习中重要的超参数,其作用是决定目标函数是否能够收敛到局部最小值以及收敛到最小值的时间。一个合适的学习率可以更快达到 loss 的最小值,可以保证收敛的 loss 值是神经网络的全局最优解。结合文献<sup>[18]</sup>以及实验经验,本文以学习率分别为 0.1、0.01、0.001、0.0001 和 0.00001,在其他不变的情况下进行实验,得到的数据如图 7 所示。



(a)训练集损失函数数值



(b)验证集准确率

图 7 不同学习率损失值与验证集准确率的变化曲线

从实验数据中可以得出结论,随着学习率的减小,模型的损失函数数值变低的同时验证集准确率

也在不断地提高,但是过小的学习率会减慢模型损失函数变化的速度,增加网络收敛的复杂度,并导致模型被困在局部最小值。在学习率达到 0.00001 的时候训练损失函数并没有进一步下降而是反向增加,故将最终的学习率定为 0.0001。

2.4 激活函数对模型的影响

激活函数是 ResNet18 中极其重要的概念,其激活函数的意义是判定神经元的输出,具有非线性特征。将非线性的因素引入神经元中,可以提升神经网络对模型的表达能力,并且具有线性模型所不具备的解决问题的能力。每个激活函数的表达式不同,起到的作用也各不相同<sup>[19]</sup>,本文选取了 Relu、LeakyReLU 和 Sigmoid 三种激活函数进行了对比,具体实验数据如图 8 所示。





图 8 不同激活函数的损失值与验证集准确率的变化曲线

图中可以看出虽然使用的不同的激活函数,但是对模型都有积极的作用,整体相差较小,LeakyReLU 激活函数在损失函数方面整体与其他两种函数相比略大且折线浮动略高,同时在验证集准确率方面也不占优势。Sigmoid 激活函数在损失函数上与 Relu 激活函数相差较小,但是准确率浮动较大。因此在 ResNet18 中使用 Relu 函数作为激活函数。

2.5 优化器对模型的影响

优化器的选择关系到 ResNet 模型能否快速收敛并取得较高的准确率和召回率,不同的优化器对网速的损失函数与测试集准确率也有着不同的影响,本文选用 Adam、SGD、和 Adamax 三种优化器进行对比,对比数据如图 9 所示。





图 9 不同优化器损失值与验证集准确率的变化曲线

图中能够得出结果,优化器 SGD 与其他两者相比在损失函数和准确率上不具有优势,而 Adamax 作为 Adam 的优化,在 Adam 的基础上增加了一个学习率上限的概念,具有一定的稳定性,折线幅度较低。所以选择 Adamax 作为 ResNet18 的优化器。

2.6 优化后的 ResNet18 模型

基于前面实验部分得到的各部分数据进行模型优化,得到改进后的 ResNet18 模型进行对比,数据如图 10 所示。





图 10 改进后的损失值与验证集准确率的变化曲线

由图 10 中得出结论,训练损失函数方面改进后的 ResNet18 模型与改进前相比有明显的降低,模



型更加稳定,验证集准确率也得到了了一定的提升,其初始准确率高于未改进的模型且整体曲线的波动相比较少,验证集平均准确率更是由之前的 97.03%,提升为当前的 97.21%整体样本的准确率有了小幅度提升。将改进前的模型与改进后的模型使用预留的 578 张测试集图片进行测试,结果如表 2 所示。

表 2 模型测试集准确率

模型	错误样本				平均准确率/%
	内壳	外壳	茶籽	空格	
ResNet18	4	7	6	0	97.25
改进 ResNet18	3	5	5	0	97.75

测试结果证明,改进后的 ResNet18 测试集在油茶果的分选上准确率提升,有效的降低了外壳的错误率,在整体的平均准确率有了小幅度的提升,能够满足油茶果分选的实际需求。

3 结论

1)在其他相同的条件下,采用较大的批量尺寸可以很好地提升模型的损失函数。但是较大的批量尺寸会增长模型的运行速度,提高运算时间,而且过大的批量尺寸也会使模型的验证集准确率进一步波动。

2)学习率的降低可以使模型更快收敛,但是过低的学习率也会减少验证集准确率,从而使模型效果变差。最终表明,选用 0.0001 的学习率最适合油茶果的分选。

3)激活函数和优化器的作用同样重要,不同的选择有着不同的影响,最终选择 Relu 激活函数和 Adamax 优化器。

4)优化后的模型在准确率方面得到了一定的提高,实际测试平均准确率由之前的 97.25%提升为选择的 97.75%,提升幅度不大但是证明了研究方向是正确的。下一步可以进一步改进模型,得到更好的模型效果。

[ 参 考 文 献 ]

[1] 柏云爱,宋大海,张富强,等. 油茶籽油与橄榄油营养价值的比较[J]. 中国油脂,2008,33(03):39-41.

[2] 段宇飞,皇甫思思,王焱清,等. 基于机器视觉的油茶果果壳与茶籽分选方法研究[J]. 中国农机化学报,2020,41(06):171-178.

[3] 徐克生,杜鹏东,汤晶宇,等. 油茶果预处理装备及发展趋势[J]. 林业机械与木工设备,2021,49(04):8-14.

[4] 周敬东,李敏慧,周明刚,等. 油茶果的模糊聚类色选算法[J]. 中国农机化学报,2015,36(04):94-99.

[5] 周敬东,黄云朋,李敏慧,等. 一种基于 CCD 相机的通道式油茶果色选机系统[J]. 中国农机化学报,2015,36(05):128-133.

[6] 赵志衡,宋欢,朱江波,等.基于卷积神经网络的花生籽粒完整性识别算法及应用[J].农业工程学报,2018,34(21):195-201.

[7] 吕梦棋,张芮祥,贾浩,等. 基于改进 ResNet 玉米种子分类方法研究[J]. 中国农机化学报,2021,42(04):92-98.

[8] 林丽惠,魏毅,潘俊虹. 基于卷积神经网络的武夷岩茶叶片分类方法[J]. 宁德师范学院学报(自然科学版),2021,33(04):363-369.

[9] 谢为俊,丁冶春,王凤贺,等.基于卷积神经网络的油茶籽完整性识别方法[J].农业机械学报,2020,51(07):13-21.

[10] 赵洋,梁迎春,许军,等.改进 ResNet18 网络模型的花卉识别[J].计算机技术与发展,2022,32(07):167-172.

[11] 张怡,赵珠蒙,王校常,等.基于 ResNet 卷积神经网络的绿茶种类识别模型构建[J].茶叶科学,2021,41(02):261-271.

[12] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C].2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2016.

[13] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition. [J] Computer Science ,2014.

[14] KRIZHEVSKY, ALEX, SUTSKEVER, ILYA, HINTON, GEOFFREY E. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM,2017,60(06):84-90.

[15] CHAO N I. Automatic inspection machine for maize kernels based on deep convolutional neural networks [J]. Biosystems Engineering, 2019, 178 : 131-144.

[16] ANDREAS KAMILARIS,FRANCESC X,PRENAFETA-BOLD Ú. Deep learning in agriculture: A survey [J]. Computers and Electronics in Agriculture, 2018, 147 : 70-90.

[17] 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. 2015:448-456.

[18] 朱莉,宋绪秋,邢鑫,等.基于改进 ResNet34 网络的树种识别研究[J]. 国外电子测量技术,2022,41(07):119-125.

[19] 黄毅,段修生,孙世宇,等. 基于改进 sigmoid 激活函数的深度神经网络训练算法研究[J]. 计算机测量与控制,2017,25(02):126-129.