doi:10.6041/j.issn.1000-1298.2020.07.002

基于卷积神经网络的油茶籽完整性识别方法

谢为俊[1]　丁冶春[2,3]　王凤贺[1]　魏　硕[1]　杨德勇[1]

(1.中国农业大学工学院, 北京 100083; 2.赣南医学院药学院, 赣州 341000;
3.赣南医学院赣南油茶产业开发协同创新中心, 赣州 341000)

摘要: 针对现有油茶籽色选机无法识别碎籽的问题,提出一种基于卷积神经网络的油茶籽完整性识别算法。以油茶籽完整性识别为目标,构建油茶籽图像库;基于油茶籽完整性识别任务要求,通过对 AlexNet 网络进行优化得到适合油茶籽完整性识别的卷积神经网络模型,该网络具有 4 层卷积层、2 层归一化层、3 层池化层和 1 层全连接层。为了提高网络分类准确率和实时性,从网络结构简化和超参数优化两方面对卷积神经网络进行优化,最终网络结构(CO-Net)的分类准确率、训练收敛速度和泛化性能均得到了提高。实验结果表明,优化后的网络对油茶籽完整性识别准确率达 98.05%,训练时间为 0.58 h,模型规模为 1.65 MB,单幅油茶籽图像检测平均耗时 13.91 ms,可以满足油茶籽在线实时分选的要求。

关键词: 油茶籽; 完整性; 识别; 卷积神经网络

中图分类号: TS222$^+$.1　　**文献标识码**: A　　**文章编号**: 1000-1298(2020)07-0013-09　　**OSID**:

Integrity Recognition of *Camellia oleifera* Seeds Based on Convolutional Neural Network

XIE Weijun[1]　DING Yechun[2,3]　WANG Fenghe[1]　WEI Shuo[1]　YANG Deyong[1]

(1. *College of Engineering*, *China Agricultural University*, *Beijing* 100083, *China*
2. *School of Pharmacy*, *Gannan Medical University*, *Ganzhou* 341000, *China*
3. *Collaborative Innovation Center for Gannan Oil Tea Camellia Industrial Development*, *Gannan Medical University*, *Ganzhou* 341000, *China*)

Abstract: In order to solve the problem that the color sorter can not recognize the intact and the broken *Camellia oleifera* seeds, an integrity recognition algorithm of *Camellia oleifera* seed based on convolution neural network was proposed and the image database of *Camellia oleifera* seed was constructed. The network structure simplification and hyper-parameter optimization was conducted to improve the classification accuracy and real-time performance of the model. Firstly, the batch normalization (BN) layer of the model was selected by the comparison experiment, which speeded up the training of the model and improved the generalization performance of the model. Moreover, the Swish function was chosen as the model activation function, which improved the recognition accuracy and speeded up the convergence of the model. Furthermore, the depth and width of the network were changed to compress the size of the model and shorten the training time. In depth, the model included four convolution layers and one fully connected layer. And in the width, the number of local receptive fields (LRFs) in the convolution layers and the number of nodes in the fully connected layer were compressed. And the second and third convolution layers were replaced by the depthwise convolutions. After the structural improvement, the model was transferred to CO-Net, which was more suitable for the integrity identification of *Camellia oleifera* seeds. Besides, the hyper-parameters (batch size and learning rate) that affected the performance of the model were optimized. The final model (CO-Net) not only improved the classification accuracy but also speeded up the training convergence speed and enhanced the generalization performance of the model. The results showed that the accuracy of the optimized network

收稿日期: 2020-04-16　修回日期: 2020-05-10

基金项目: 国家重点研发计划项目(2018YFDO700102-02)和赣南油茶产业开发协同创新中心开放基金项目(YP201611)

作者简介: 谢为俊(1994—),男,博士生,主要从事农产品智能加工技术研究,E-mail: BS20193070629@cau.edu.cn

通信作者: 杨德勇(1970—),男,副教授,博士,主要从事农产物料物理特性研究,E-mail: ydy@cau.edu.cn

was 98.05%, the training time was only 0.58 h, and the model size was only 1.65 MB. The average time of detecting an image of *Camellia oleifera* seed was only 13.91 ms, which can meet the requirements of real-time sorting of *Camellia oleifera* seed.

Key words: *Camellia oleifera* seed; integrity; recognition; convolution neural network

0 引言

油茶(*Camellia oleifera* Abel.)是山茶科、山茶属植物,与油棕、油橄榄、椰子并称为世界四大木本食用油料作物,广泛种植于我国南方丘陵地区和一些东南亚国家[1]。茶油是油茶籽的主要产物,富含多种不饱和脂肪酸,被誉为"东方橄榄油"[2]。中国是油茶种植大国,据统计,2017 年油茶籽产量达到 243 万 t,在我国脱贫政策扶持下,油茶产量将进一步增加[3]。

油茶蒲不含油脂,对制取茶油不利,因此需要对其进行脱蒲处理[4]。机械脱蒲后的产物为完整油茶籽、破碎油茶籽和果蒲等组成的混合物,需要将茶籽从中分选出来,以进行后续的茶油制取,同时还需要将完整茶籽与破碎茶籽分离,以保证茶籽的储藏质量。目前油茶籽分选方式主要分为筛孔分选、气流分选、胶带摩擦分选和油茶籽色选机分选等。筛孔分选主要根据油茶籽和油茶蒲的尺寸差异进行分级筛分。如熊平原等[5]设计了一种三级筛分网振动分选装置,以获得大、中、小蒲和碎末分层筛选的效果。气流分选是根据物质之间的质量差异进行分离。如郭传真[6]研究了气流对油茶果蒲籽混合物清选的影响规律,并确定了油茶果清选气流的最佳参数。胶带分选主要利用油茶籽、果蒲与胶带的摩擦因数不同实现分选。如 WANG 等[7]利用倾斜的胶带外加气流方式进行油茶籽、果蒲分选试验,结果表明,油茶籽分选精度达到 98%,果蒲分选精度为 93%。油茶籽色选机主要利用油茶籽与果蒲的颜色差异进行籽与蒲的识别,实现油茶籽分选。如周敬东等[8]设计的油茶籽色选系统,可对 CCD 相机获取的油茶籽和果蒲图像进行识别,进而利用气流对油茶籽、果蒲进行分离。目前,油茶籽分选机械可以实现将果蒲从混合物中分离,但不能分离碎籽。

机器视觉技术在农产品加工领域已有广泛应用。李霁阳[9]设计了一套适用于谷物外观品质分析的算法,该算法利用谷物的长度、宽度和像素面积等谷物特征参数实现谷物完整性识别。李伟等[10]基于图像处理技术提出基于形态学的棉籽破损识别方法,根据棉籽轮廓的对称性特征判断棉籽完整性。上述两种算法都是基于图像处理技术,算法复杂度较高,识别速度和识别率偏低。近年来随着深度学习技术的发展,机器视觉技术在图像分类检测和目标识别上的准确率不断提高。深度学习技术已被应用于不同领域[11],越来越多的学者将其运用在谷物[12-13]、水果[14-15]、蔬菜[16-17]等农产品目标识别和品质检测上。目前,卷积神经网络(CNN)模型,如 AlexNet[18]、VGGNet[19]和 GoogLeNet[20]等,主要针对种类繁多的目标识别,且对识别速度要求不高,因此,研究人员通常根据实际问题,设计出独特、适用的卷积神经网络结构[21-23]。上述研究结果表明,将 CNN 运用于农产品目标识别和品质检测是可行的。

本文根据油茶籽完整性识别任务要求,构建卷积神经网络模型,实现油茶籽的完整性识别。通过对比实验确定模型的总体结构;为提高网络的收敛速度、泛化性能与准确率,通过对比不同归一化方法的模型性能确定最佳归一化方法,同时比较不同激活函数对模型性能的影响,并对网络的超参数(批量尺寸和学习率)进行优化;为减小模型规模,使其更适用于茶籽分选设备,对模型卷积层感受野和全连接层节点进行压缩,以提高网络的准确率和实时性。

1 材料与方法

1.1 数据集构建

油茶果购自江西省赣州市,品种为"赣州油"。油茶果经过机械脱蒲后,选取 1 761 个完整籽和 1 039 个破碎籽,随机选取每个种类的 70% 作为训练集,30% 为验证集。其部分数据集如图 1 所示。

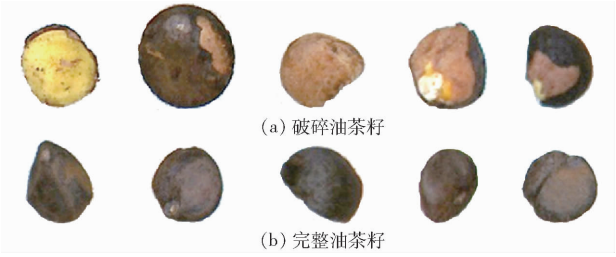

(a) 破碎油茶籽

(b) 完整油茶籽

图 1 油茶籽部分数据集

Fig. 1 Part of *Camellia oleifera* seed datasets

油茶籽图像是由彩色 CCD 相机(DFK-33UX265 型)和 8 mm 镜头(The Imaging Source,德国)采集,图像尺寸为 1 920 像素 × 1 080 像素。图像处理算法和卷积神经网络搭建是基于 Python 3.7、图像处理库 OpenCV 4.0 和深度学习库

Tensorflow 2.0.0。程序运行环境为 Intel i5－7200U 2.70 GHz CPU、4 GB 运行内存、Windows 10 操作系统。

1.2　图像预处理

单粒油茶籽图像由整幅图像(1 920 像素×1 080 像素)裁剪得到，主要步骤为：①利用 OpenCV 中的 cv2.inRang 函数对原图像进行二值化处理，得到含有大量噪声点的二值图像(图 2b)。②对二值图进行中值滤波、形态学操作和面积去噪后，得到不含噪声的二值图像(图 2c)。③将二值图作为掩膜，与原图像进行“与”操作得到去除背景的 RGB 三通道图像(图 2d)。④检测出油茶籽轮廓，并得到油茶籽最小外接矩形(图 2e)。⑤为了保持油茶籽形状轮廓不受裁剪影响，将油茶籽外接矩形每条边向外扩展 5 个像素作为裁剪矩形，得到单粒油茶籽图像(图 2f)。⑥为了满足卷积神经网络对输入图像的要求，油茶籽图像在输入前统一调整为 224 像素×224 像素的正方形图像。

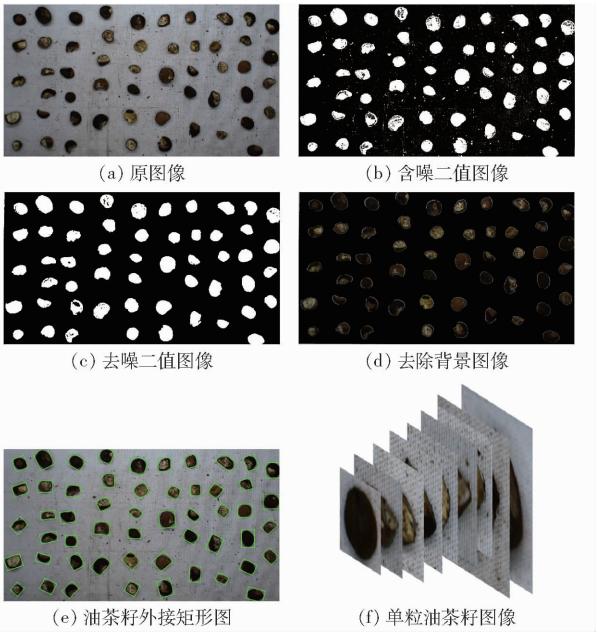

图 2　油茶籽图像预处理

Fig. 2　Image preprocessing of *Camellia oleifera* seeds

1.3　网络构建步骤

1.3.1　归一化层

在 AlexNet[18] 经典网络中，为了提高模型泛化性能，提出了局部响应归一化(LRN)，其能对局部神经元的活动创建竞争机制，使得其中响应比较大的值变得相对更大，并抑制其他反馈较小的神经元。批量归一化(BN)是一种防止网络过拟合的方法，在每一层的激活函数之前采用批量归一化处理，使非激活的输出服从均值为 0 方差为 1 的正态分布，然后通过缩放和平移，将批量归一化计算结果还原为原始输入特性。该过程可以保证网络容量、加快网络训练速度、提高网络泛化能力[24]，其数学表达式为

$$b_{x,y}^{i}=a_{x,y}^{i}\Big/\left[k+\alpha\sum_{j=\max\left(0,i-\frac{n}{2}\right)}^{\min\left(N-1,i+\frac{n}{2}\right)}\left(a_{x,y}^{j}\right)^{2}\right]^{\beta} \tag{1}$$

$$\boldsymbol{X}=(x^{(1)},x^{(2)},\cdots,x^{(d)}) \tag{2}$$

$$\hat{x}^{(k)}=\frac{x^{(k)}-E(x^{(k)})}{\sqrt{V_{ar}(x^{(k)})}} \tag{3}$$

$$y^{(k)}=\gamma^{(k)}x^{(k)}+\beta_1^{(k)} \tag{4}$$

$$\beta_1^{(k)}=E(x^{(k)}) \tag{5}$$

$$\gamma^{(k)}=\sqrt{V_{ar}(x^{(k)})} \tag{6}$$

式中　$b_{x,y}^{i}$——归一化输出结果

$a_{x,y}^{i}$、$a_{x,y}^{j}$——原始输入值

i——通道序号

N——通道总数

$x^{(d)}$——第 d 维输入值

x、y——特征图的宽、高

k——超参数，防止除 0 的情况发生

α、β——常数　　n——邻域长度

$\boldsymbol{X}$——BN 层输入值，共有 d 维

$\hat{x}^{(k)}$——第 k 维归一化值

$x^{(k)}$——第 k 维输入值

$y^{(k)}$——第 k 维输出值

E——均值　　V_{ar}——方差

$\gamma^{(k)}$、$\beta_1^{(k)}$——可学习的重构参数

1.3.2　激活函数

激活函数将非线性因素引入神经元，使得深度神经网络可以逼近任何非线性函数，增强了深度神经网络的学习能力。因此，深度神经网络中激活函数的选择对训练过程和模型性能有着重要影响。目前应用最多的激活函数是 ReLU 函数。图 3 为不同激活函数在定义域上的函数图像，当 $x\geqslant 0$ 时，ReLU 函数无边界，梯度可以持续传递，不会出现饱和现象，然而 $x<0$ 时，函数梯度消失，出现神经元死亡的问题。为了解决此问题，ReLU 函数的改进函数如

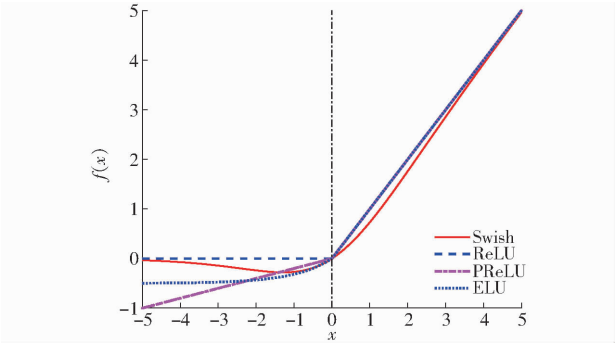

图 3　不同激活函数图像

Fig. 3　Different activation functions diagram

PReLU 和 ELU 相继提出。此外,谷歌大脑于 2017 年提出了 Swish 函数[25]来解决 ReLU 函数梯度消失的问题。

1.3.3 网络结构

本文构建的模型(CO-Net)可以视作一种局部特征自学习方法,包括一系列在卷积神经网络中发挥不同作用的连续层,包括卷积层、归一化层、池化层和全连接层。油茶籽图像特征主要由卷积层自主学习得到;归一化层可以提高模型训练收敛速度;池化层可以减小网络结构参数并保持图像特征不变,提高模型泛化能力;全连接层将前面卷积层所学到的局部特征综合为油茶籽图像的全局特征。所构建的网络可以自动学习获得油茶籽主要特征。

油茶籽在线分选具有实时性和检测准确率要求高的特点,为了提高模型的训练速度和准确率,本文对 AlexNet[18]网络进行了结构简化。首先,研究模型各层对模型性能的影响,确定网络总体结构;然后调整网络全连接层节点数量,以达到压缩模型的目的;最后调整网络卷积层各层感受野数量,达到加快模型训练速度的目的。在网络结构调整过程中,比较表征模型性能的 4 个参数(模型尺寸、训练时间、准确率和损失值),寻找出适合油茶籽完整性识别任务的最优网络结构。通过调整后,得到更适合油茶籽完整性识别的 CO-Net 网络,其拥有 4 层卷积层、2 层 BN 层、3 层池化层和 1 层全连接层(图 4),其初始参数分布如表 1 所示。

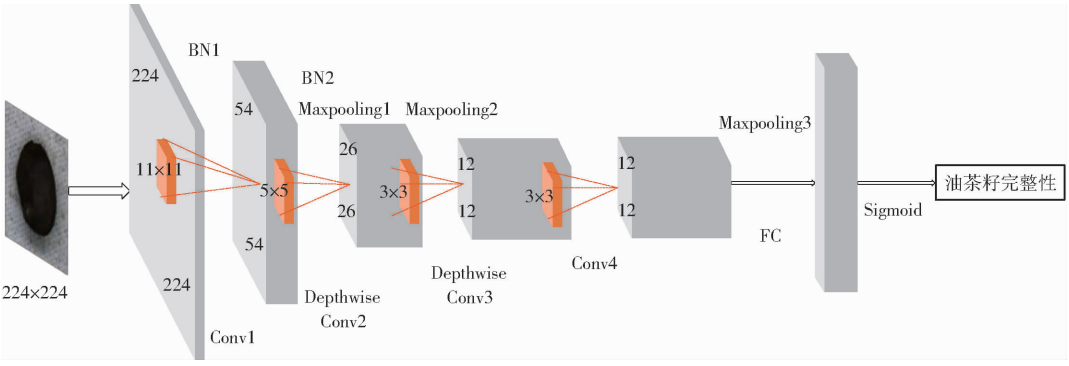

图 4 CO-Net 网络整体结构图

Fig. 4 Overall structure diagram of CO-Net

表 1 CO-Net 初始参数分布

Tab. 1 Initial parameters distribution of CO-Net

网络层	输出尺寸	感受野尺寸	卷积步长	参数量/个
Conv1	54×54×96	11×11	4	34 944
BN1	54×54×96			384
Maxpooling1	26×26×96	3×3	2	0
Depthwise Conv2	26×26×256	5×5	1	614 656
BN2	26×26×256			1 024
Maxpooling2	12×12×256	3×3	2	0
Depthwise Conv3	12×12×384	3×3	1	885 120
Conv4	12×12×384	3×3	1	1 327 488
Maxpooling3	5×5×384	3×3	2	0
FC	4 096×1			39 325 696
Output	2×1			8 194

1.3.4 卷积层结构的优化

深度可分离卷积认为卷积层通道间的相关性和空间相关性是可以退耦合的,将它们分开映射,能达到更好的效果[26]。深度可分离卷积将传统的卷积操作(图 5a)分为一个深度卷积操作和一个卷积核为 1×1 的传统卷积操作(图 5b),通过此操作后可以减少卷积操作的参数量和计算量。假设输入特征图为 $D_F \times D_F \times M$、输出特征图为 $D_F \times D_F \times N$、卷积核为 $D_K \times D_K$,则传统卷积的参数量、计算量和深度可分离卷积的参数量、计算量为

$$C_{para} = D_K \times D_K \times M \times N \tag{7}$$

$$C_{cal} = D_K \times D_K \times M \times N \times D_F \times D_F \tag{8}$$

$$D_{para} = D_K \times D_K \times M + M \times 1 \times 1 \times N \tag{9}$$

$$D_{cal} = D_K \times D_K \times M \times D_F \times D_F + M \times N \times D_F \times D_F \tag{10}$$

式中 C_{para}——传统卷积层参数量

D_{para}——深度可分离卷积层参数量

C_{cal}——传统卷积层计算量

D_{cal}——深度可分离卷积层计算量

深度可分离卷积与传统卷积参数量、计算量之比为

$$\frac{D_{para}}{C_{para}} = \frac{D_{cal}}{C_{cal}} = \frac{1}{N} + \frac{1}{D_k^2} \tag{11}$$

由式(11)可知,当卷积核尺寸大于 1 时,深度可分离卷积可有效减少模型参数量和计算量。因此,为了进一步压缩模型尺寸和提高模型训练速度,本文依次将第 2~4 层卷积层(Conv2~Conv4)替换为深度可分离卷积层(Depthwise Conv)。

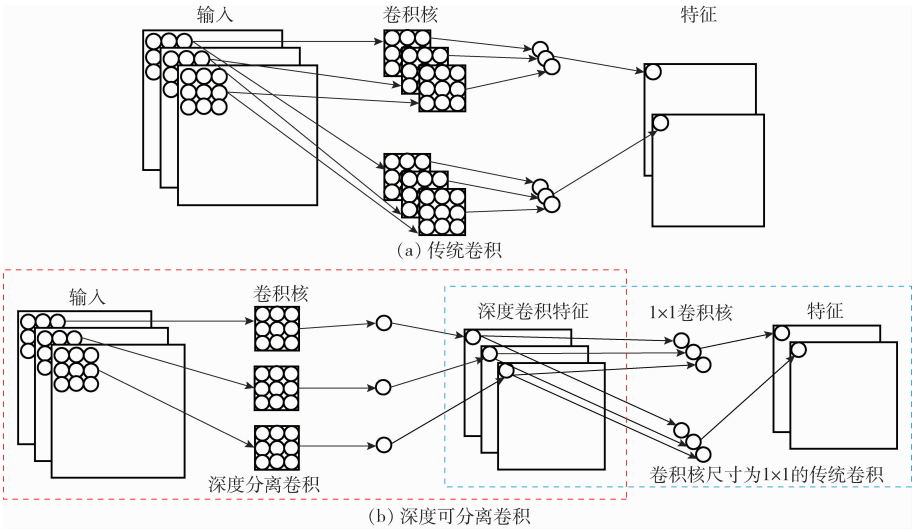

图 5　传统卷积与深度可分离卷积示意图

Fig. 5　Traditional convolution and depthwise convolution diagram

2　结果与分析

2.1　批量尺寸对模型性能的影响

批量尺寸(Batch size)表示卷积神经网络在训练过程中每批训练使用图像的数量。合适的批量尺寸可以加快模型训练速度、减少训练时间。批量尺寸与模型训练梯度下降速度关系密切。本文进行了不同批量尺寸对模型性能影响的对比实验，结果如图 6 所示。由图可知，模型训练准确率和损失值分别随训练次数的增加而升高和减小。此外，随着批量尺寸的增大，训练收敛速度不断加快，但过大的批量尺寸会导致过多内存消耗，可能会导致程序崩溃，且当批量尺寸为 64 和 128 时，模型收敛速度相近，最终 CO－Net 网络选择批量尺寸为 64 进行训练。

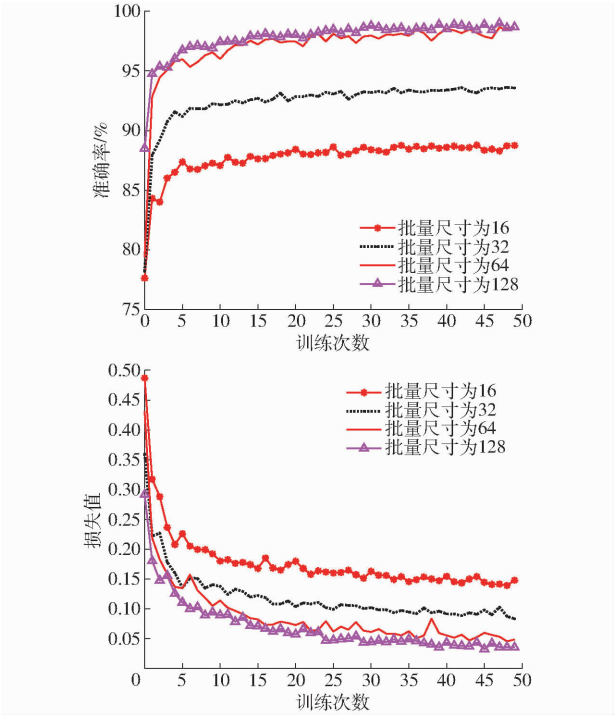

图 6　批量尺寸对模型训练效果的影响

Fig. 6　Effects of batch size on training accuracy and training loss

2.2　学习率对模型性能的影响

学习率(Learning rate)是卷积神经网络训练过程中很重要的一个超参数，学习率表示每次更新参数的幅度，合适的学习率可以加快模型训练收敛速度。本文比较了 5 个不同学习率对模型训练效果的影响，结果如图 7 所示。由图可知，模型训练收敛速度随学习率增加而加快。但学习率不能无限增大，当学习率过大时，需要优化的参数会出现波动而不

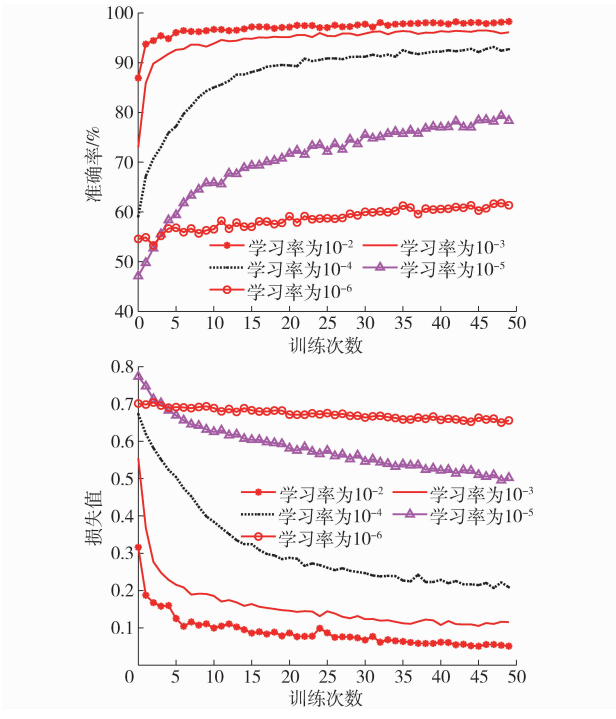

图 7　学习率对模型训练效果的影响

Fig. 7　Effects of learning rate on training accuracy and training loss

收敛;而学习率过小,会导致待优化的参数收敛缓慢。本文网络模型在学习率为 10^{-2} 时收敛速度最快,因此选择学习率为 10^{-2} 进行训练。

2.3 归一化方法对模型性能的影响

对数据进行归一化操作可以提高模型泛化性能和加快模型训练收敛速度,因此选择合适的归一化方法对模型性能有重要意义。本文比较了无归一化层、局部响应归一化(LRN)和批量归一化(BN)对网络模型性能的影响,结果如图 8 所示。可以看出,未添加归一化层与添加 LRN 层的模型准确率基本一致,但模型训练时间由 1.01 h 增加到 1.12 h,说明 LRN 层对模型识别准确率没有大幅度提升作用,还会增加网络复杂性,这与 SIMONYAN 等[19]的研究结果类似。然而,添加 BN 层网络的收敛速度比添加 LRN 层的快,模型训练时间由 1.12 h 减少为 0.71 h,且训练准确率有所提高,可能是因为 LRN 层作用于特征图通道层面,而 BN 层作用于特征图整体数据且 BN 层中含有可学习的重构参数。另一方面,BN 层解决了深层网络训练过程中由于网络参数变化而引起内部节点数据分布发生变化的现象。所以在 CO-Net 中使用 BN 层作为网络归一化层。

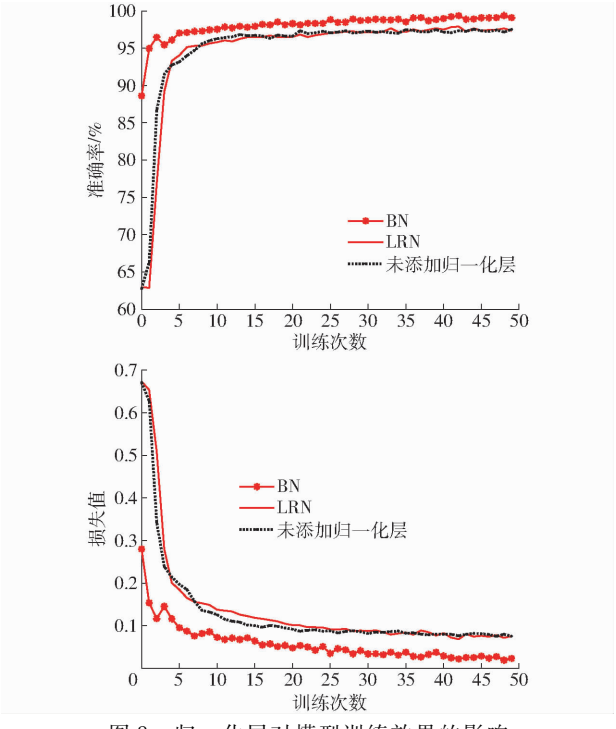

图 8 归一化层对模型训练效果的影响

Fig. 8 Effects of normalization layer on training accuracy and training loss

2.4 激活函数对模型性能的影响

激活函数对 CNN 成功的训练起着重要作用。Swish 激活函数具有非饱和、光滑、非单调等特点,其应用于图像分类、机器翻译等多个具有挑战性领域时,在深度网络上的表现优于或等同于 ReLU 激活函数[25],本文也得到了同样结果。图 9 为 PReLU、ELU、ReLU 和 Swish 激活函数对模型训练效果的影响。结果表明,Swish 函数对模型收敛速度的影响比其他 3 个函数大,这可能是由于 Swish 函数在定义域上处处可导且在 x 为负值时,模型梯度仍然可以传递,从而避免了神经元死亡的问题。因此,在 CO-Net中使用 Swish 函数作为模型激活函数。

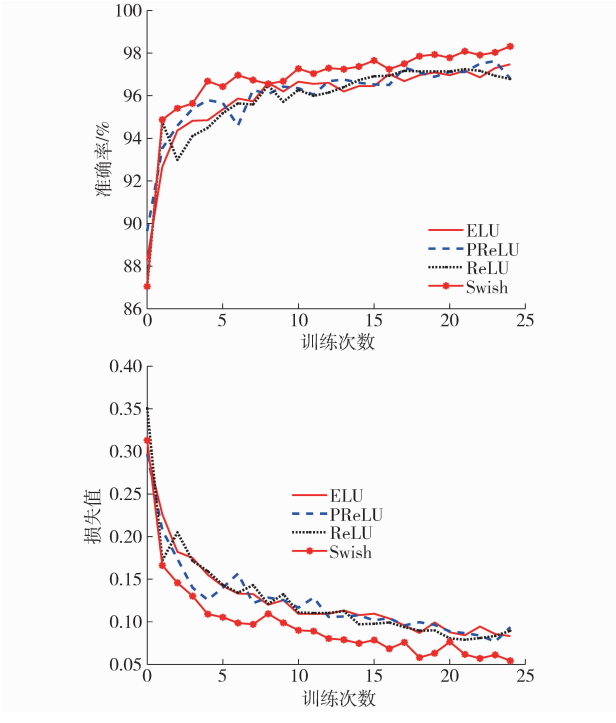

图 9 激活函数对模型训练效果的影响

Fig. 9 Effects of activation function on training accuracy and training loss

2.5 全连接层对模型性能的影响

全连接层是将卷积层学习到的局部特征整合为去除空间位置信息的全局特征,所以全连接层含有参数最多,是影响模型尺寸的重要因素。为了确定模型全连接层数量,本文将全连接层数量由零依次增加到 2 层,结果如图 10 所示。由图可知,当只有 1 层全连接层时,模型性能与拥有 2 层全连接层时没有明显变化甚至有所提高,但是当无全连接层时,模型性能明显下降,这可能是因为模型所有参数均包含在全连接层内,所以只有 1 层全连接层对模型性能影响不大,但全连接层包含的是去除空间位置信息的全局特征,全部删除将导致模型性能下降。为了进一步压缩模型,通过调整全连接层节点数量来寻找模型规模最优值。表 2 是全连接层不同节点数对模型的影响。由表 2 可知,减少模型节点数可以压缩模型规模,但是对模型训练时间影响有限,因为全连接层参数最多,而模型训练耗时主要来自卷积操作。综

合模型测试准确率、模型尺寸和训练时间，最终 CO－Net 采用 1 层全连接层，节点数为 256。

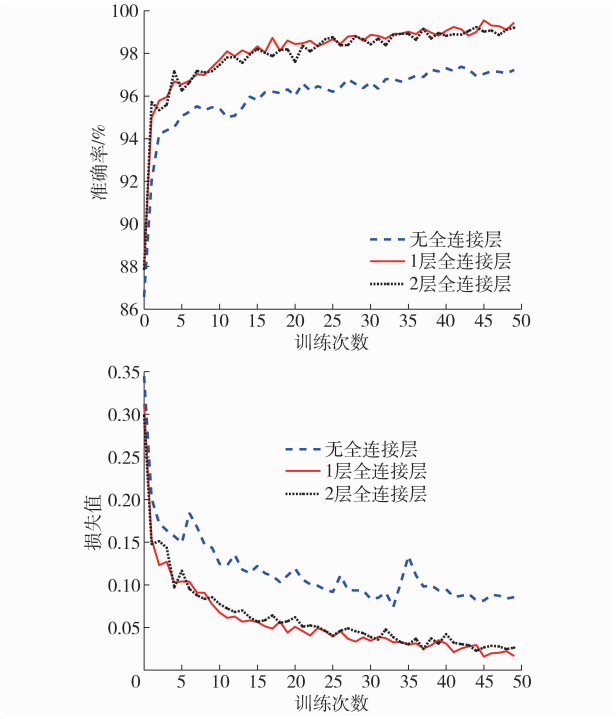

图 10　全连接层对模型训练效果的影响

Fig. 10　Effects of fully connected layers on training accuracy and training loss

表 2　全连接层节点数对模型性能的影响

Tab. 2　Effects of fully connected layers on performance of model

全连接层节点数	训练准确率/%	模型规模/MB	训练时间/h	测试准确率/%
4 096	99. 37	321	4. 88	98. 61
2 048	99. 54	171	4. 51	97. 86
1 024	99. 48	96. 9	4. 79	97. 91
512	99. 51	59. 4	4. 33	97. 97
256	99. 57	40. 6	4. 30	98. 40
128	99. 25	31. 2	4. 27	98. 29
64	99. 08	26. 5	4. 45	98. 29
32	98. 72	24. 2	4. 48	98. 24

2. 6　卷积层对模型性能的影响

卷积层通过不同尺寸感受野对图像进行卷积操作，提取图像局部特征，是卷积神经网络中最重要的组成部分，因此卷积层的设置对模型性能起着至关重要的作用。CO－Net 是从零开始独立训练，在只有 1 层卷积层时，模型训练准确率和收敛速度均最低，模型性能随着卷积层层数增加而提升，但提升速度越来越慢，当卷积层数量为 4 时，模型性能甚至优于 5 层卷积层（图 11），由此可见保证模型具有一定深度是必要的，但模型深度也不是越深越好，最终确定 CO－Net 卷积层层数为 4 层。为加快模型训练速度、降低模型训练时间，本文对卷积层感受野数量进行调整，结果如表 3 所示。结果表明减少模型感受野数量不仅可以减小模型规模，更重要的是可以大幅降低模型训练时间。子模型 1 与子模型 3 相比，模型规模由 40. 60 MB 减少为 8. 47 MB，训练时间由 4. 30 h 减少为 1. 16 h，而测试准确率基本保持不变，原因是卷积层拥有大量卷积操作，需要消耗大量时间，减少感受野数量可以减少卷积操作，降低模型训练时间。此外，本文还将传统卷积层替换为深度可分离卷积层，结果如表 4 所示，深度可分离卷积层可以有效减少模型参数量以达到压缩模型的效果和减

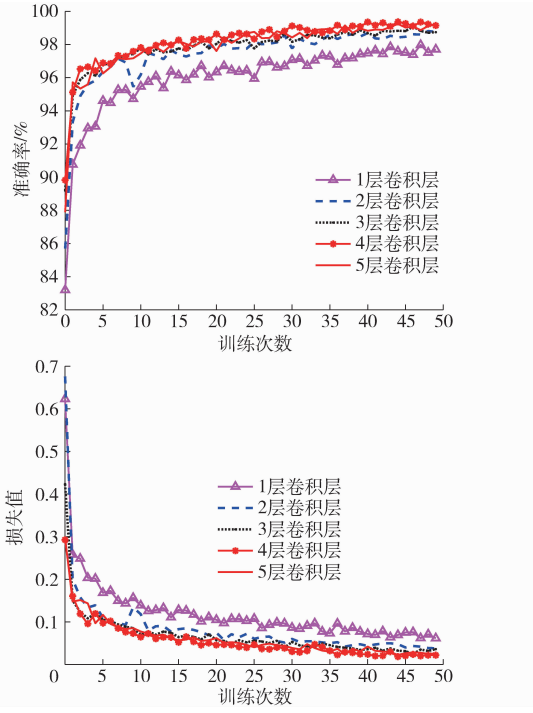

图 11　卷积层对模型训练效果的影响

Fig. 11　Effects of convolution layers on training accuracy and training loss

表 3　卷积层感受野数量对模型性能的影响

Tab. 3　Effects of number of LRFs on performance of model

子模型编号	压缩子模型参数（a、b、c、d、e）	训练准确率/%	模型规模/MB	训练时间/h	测试准确率/%
1	96、256、384、384、256	99. 57	40. 60	4. 30	98. 40
2	64、128、256、256、256	99. 28	21. 00	2. 39	98. 02
3	32、64、128、128、256	99. 38	8. 47	1. 16	98. 39
4	32、32、64、64、256	99. 15	3. 88	1. 04	97. 75
5	32、32、32、32、256	99. 10	2. 04	1. 05	97. 91

注：a、b、c、d 分别指第 1 ~ 4 层卷积层感受野数量，e 指全连接层节点数。

表 4 深度可分离卷积层对模型性能的影响

Tab. 4 Effect of depthwise convolutions on performance of model

子模型编号	压缩子模型结构	训练准确率/%	模型规模/MB	训练时间/h	测试准确率/%
3	32、64、128、128、256	99.38	8.47	1.16	98.39
6	Depthwise Conv2	98.70	2.13	1.09	97.50
7	Depthwise Conv2 ~ 3	98.75	1.65	0.58	98.05
8	Depthwise Conv2 ~ 4	98.44	0.65	0.47	97.49

少模型计算量以达到加快模型训练的效果。当模型第 2、3 层卷积层替换为深度可分离卷积层后,模型规模由原来的 8.47 MB 进一步减小为 1.65 MB,模型训练时间减少一半而模型精度仅轻微下降,使其更适合在嵌入式系统上使用,可以用于硬件配置较低的分选设备。实际使用时,应当根据软硬件条件,挑选适合实际生产的模型。

2.7 模型性能比较

本文将模型性能表征参数(训练准确率、模型规模、训练时间和测试准确率)作为目标参数,将 CO - Net 与其他经典模型(AlexNet、MobileNet V1、MobileNet V2、MobileNet V3[26] 和 SqueezeNet[27])进行比较,结果如表 5 所示。由表可知,采用不同模型结构时,模型性能不同,其中 AlexNet 模型训练时间最长,为 9.43 h,测试准确率为 98.33%,但其模型规模最大(356 MB),不适用于油茶籽在线分选设备。MobileNet V3_Large 在轻量级网络中模型规模最大,训练时间为 5.52 h,其测试准确率达到了 97.26%。本文提出的 CO - Net 测试准确率达到了 98.05%,而模型规模和训练时间分别是 MobileNet V3_Large 的 1/38 和 1/10,且单幅图像检测平均耗时仅 13.91 ms。通过比较可知,CO - Net 更适合用于油茶籽在线分选。

表 5 CO - Net 与不同经典模型性能比较

Tab. 5 Performance comparison between CO - Net and different classical models

模型	训练准确率/%	模型规模/MB	训练时间/h	测试准确率/%
AlexNet	99.15	356.00	9.43	98.33
MobileNet V1	97.83	6.39	3.67	97.02
MobileNet V2	95.82	5.93	3.53	95.53
MobileNet V3_Small	92.45	22.10	4.01	91.60
MobileNet V3_Large	98.27	62.10	5.52	97.26
SqueezeNet	88.04	5.71	1.09	87.49
CO - Net	98.75	1.65	0.58	98.05

3 结论

(1)以批量归一化(BN)作为模型归一化方法,提高了模型的训练收敛速度和模型的泛化性能。Swish 函数可有效解决 ReLU 激活函数出现神经元死亡的问题,提高了模型的准确率和训练收敛速度。

(2)CO - Net 网络具有 4 层卷积层、2 层归一化层、3 层池化层和 1 层全连接层,4 层卷积层和 1 层全连接层的节点数分别为 32、64、128、128 和 256,第 2、3 卷积层采用深度可分离卷积层,使模型规模减小为原来的 1/5,且训练时间缩短一半。模型选择训练批量尺寸为 64,学习率为 10^{-2}。

(3)CO - Net 网络对油茶籽完整性的识别准确率达 98.05%,与 MobileNet V3_Large 模型相当;但训练时间大幅缩短,为 0.58 h;模型规模大幅减小,为 1.65 MB;单幅图像检测平均耗时 13.91 ms,可满足油茶籽在线实时分选的要求。

参 考 文 献

[1] 王凤贺,丁冶春,陈鹏枭,等. 油茶籽热风干燥动力学研究[J/OL]. 农业机械学报,2018,49(增刊):426 - 432.
WANG Fenghe, DING Yechun, CHEN Pengxiao, et al. Investigation on hot-air drying of *Camellia oleifera* seeds[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(Supp.): 426 - 432. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag = 1&file_no = 2018s058&journal_id = jcsam. DOI: 10.6041/j.issn.1000-1298.2018.S0.058. (in Chinese)

[2] XIE Weijun, CHEN Pengxiao, WANG Fenghe, et al. Dielectric properties of *Camellia oleifera* seed kernels related to microwave and radio frequency drying[J]. International Food Research Journal, 2019, 26(5): 1577 - 1585.

[3] ZHU Guangfei, LIU Hai, XIE Yucen, et al. Postharvest processing and storage methods for *Camellia oleifera* seeds[J]. Food Reviews International, 2019, 36(4): 319 - 339.

[4] 朱广飞,任嘉嘉,王振,等. 油茶果脱壳机的设计与工作参数优化[J]. 农业工程学报,2016,32(7):19 - 27.
ZHU Guangfei, REN Jiajia, WANG Zhen, et al. Design of shelling machine for *Camellia oleifera* fruit and operating parameter optimization[J]. Transactions of the CSAE, 2016, 32(7): 19 - 27. (in Chinese)

[5] 熊平原,王毅,吴卓葵,等. 油茶青果脱壳装置研究与设计[J]. 中国农机化学报,2016,37(5):126 - 129.

XIONG Pingyuan, WANG Yi, WU Zhuokui, et al. Research and design on shelling machine of green Camellia fruit[J]. Journal of Chinese Agricultural Mechanization, 2016,37(5):126 – 129. (in Chinese)

[6] 郭传真. 油茶果皮籽分离装置的设计与试验研究[D]. 武汉:华中农业大学, 2011.

[7] WANG Fenghe, DING Yechun, XIE Weijun, et al. Design and experimental study of a separating machine for seed and peel of *Camellia oleifera* fruit[J]. IFAC-PapersOnLine, 2019,52(30):87 – 91.

[8] 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(5):128 – 133.
ZHOU Jingdong, HUANG Yunpeng, LI Minhui, et al. Channel color sorter of *Camellia oleifera* fruit based on CCD camera[J]. Journal of Chinese Agricultural Mechanization, 2015,36(5):128 – 133. (in Chinese)

[9] 李霁阳. 谷物外观品质检测方法的研究[D]. 北京:北方工业大学,2017.

[10] 李伟,于振东,陈涛,等. 基于形态学的棉花种子破损检测[J]. 农业机械学报, 2009, 40(4):169 – 172.
LI Wei, YU Zhendong, CHEN Tao, et al. Identification and detection for surface damages of cottonseed based on morphology [J]. Transactions of the Chinese Society for Agricultural Machinery, 2009, 40(4):169 – 172. (in Chinese)

[11] KAMILARIS A, PRENAFETA-BOLDÚ F X. Deep learning in agriculture: a survey[J]. Computers and Electronics in Agriculture, 2018,147:70 – 90.

[12] NI Chao, WANG Dongyi, VINSON R, et al. Automatic inspection machine for maize kernels based on deep convolutional neural networks[J]. Biosystems Engineering, 2019,178:131 – 144.

[13] ALTUNTAŞ Y, CÖMERT Z, KOCAMAZ A. Identification of haploid and diploid maize seeds using convolutional neural networks and a transfer learning approach[J]. Computers and Electronics in Agriculture, 2019,163:104874.

[14] YU Yang, ZHANG Kailiang, YANG Li, et al. Fruit detection for strawberry harvesting robot in non-structural environment based on Mask-RCNN[J]. Computers and Electronics in Agriculture, 2019,163:104846.

[15] OLANIYI E O, OYEDOTUN O K, ADNAN K. Intelligent grading system for banana fruit using neural network arbitration[J]. Journal of Food Process Engineering, 2015,40(1):e12335.

[16] OPPENHEIM D, SHANI G, ERLICH O, et al. Using deep learning for image-based potato tuber disease detection[J]. Phytopathology, 2019,109(6):1083 – 1087.

[17] MA Juncheng, DU Keming, ZHENG Feixiang, et al. A recognition method for cucumber diseases using leaf symptom images based on deep convolutional neural network[J]. Computers and Electronics in Agriculture, 2018,154:18 – 24.

[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] SIMONYAN K,ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. arXiv Preprint arXiv, 2014: 1409.1556.

[20] CHRISTIAN S, VINCENT V, SERGEY I, et al. Rethinking the inception architecture for computer vision[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, 2016.

[21] RONG Dian, XIE Lijuan, YING Yibin. Computer vision detection of foreign objects in walnuts using deep learning[J]. Computers and Electronics in Agriculture, 2019,162:1001 – 1010.

[22] 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.
ZHAO Zhiheng, SONG Huan, ZHU Jiangbo, et al. Identification algorithm and application of peanut kernel integrity based on convolution neural network[J]. Transactions of the CSAE, 2018, 34(21):195 – 201. (in Chinese)

[23] 孙红,李松,李民赞,等.农业信息成像感知与深度学习应用研究进展[J/OL].农业机械学报,2020,51(5):1 – 17.
SUN Hong, LI Song, LI Minzan, et al. Research progress of image sensing and deep learning in agriculture[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(5): 1 – 17. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? file_no=20200501&flag=1:DOI: 10.6041/j.issn.1000-1298.2020.05.001. (in Chinese)

[24] WANG Di, TIAN Fengchun, YANG S X, et al. Improved deep CNN with parameter initialization for data analysis of near-infrared spectroscopy sensors[J]. Sensors (Basel, Switzerland), 2020,20(3):874.

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

[26] ANDREW G H, ZHU Menglong, CHEN Bo, et al. Mobilenets: efficient convolutional neural networks for mobile vision applications[J]. arXiv Preprint arXiv,2017: 1704.04861.

[27] LANDOLA F N, HAN S, MOSKEWICZ M W, et al. Squeezenet: AlexNet-level accuracy with 50 × fewer parameters and <0.5 MB model size[J]. arXiv Preprint arXiv,2016:1602.07360.