

DOI: 10.13652/j.issn.1003-5788.2020.02.026

基于网中网卷积神经网络的红枣缺陷检测

Detection of jujube defects based on the neural network with network convolution

杨志锐 郑宏 郭中原 许晓航

YANG Zhi-ru ZHENG Hong GUO Zhong-yuan XU Xiao-hang

(武汉大学电子信息学院, 湖北 武汉 430072)

(School of Electronic Information, Wuhan University, Wuhan, Hubei 430072, China)

摘要:提出了一种基于网中网卷积神经网络对红枣进行缺陷检测的方法,在原有 AlexNet 卷积神经网络的基础上增加了 1×1 隐含感知层,增强了网络的非线性以提取更抽象的特征;并采用全局平均池化层的方式替换全连接层,减少大量参数的同时提升了识别准确率。对新疆骏枣进行了实测,可将红枣分为好枣、黑斑枣、皱枣、叠枣、脱皮枣、黄皮枣和裂枣 7 类,表明该方法与基于常规 SVM 的视觉检测方法和基于 AlexNet 网络的分类方法相比,分类效果得到了有效提升。

关键词:红枣;缺陷检测;网中网卷积神经网络

Abstract: We proposed a method of defect detection for jujube based on a neural network with network-in-network convolutional (NIN-CNN). This method adds 1×1 hidden perception layer to the original AlexNet convolution neural network; enhances the non-linearity of the network to extract more abstract features; and replaces the fully connected layer with the global average pooling layer, which improves the recognition accuracy while reducing a large number of parameters. In this study, Jun jujube in Xinjiang is tested. The jujube is divided into seven categories, including healthy jujube, black-spotted, wrinkled, overlapping, peeling, yellow-skinned and crack. The experimental results show that the classification effect of the proposed method is improved effectively, compared with the conventional visual detection method with SVM and the classification method with AlexNet network.

Keywords: jujubes; defect detection; neural network with network-in-network convolution

红枣味道鲜美^[1],具有极高的营养价值、食用价值和药用价值。而脱皮、裂口、虫害等缺陷会影响红枣的品质

和价值^[2]。目前红枣缺陷检测方法主要有:人工分级和基于机器视觉的分级方法。人工分级成本高、效率低、劳动强度大、精度差、易误检漏检等^[3]。詹映^[4]曾运用 RGB 和 HIS 模型提取红枣的红体均值、绿体均值、蓝体均值及均值方差,通过设置相应的阈值作为缺陷检测的方法。张萌等^[5]针对红枣表面曲率变化导致其分布不均匀的特性,提出了使用单色 CCD、滤光片和红外光源提取红枣近似图像,通过均值滤波器对去背景后的图像进行滤波获取亮度图像,并使用该亮度图像对去背景后的红枣图像进行亮度校正,提高了缺陷检测的实时性。这些方法利用图像处理 and 机器视觉技术来实现红枣的无损缺陷检测,需要根据枣的不同种类人工设计相应的特征提取器,步骤较为繁琐,且智能化程度不高。因此需要寻找高效、快速、准确、智能的红枣缺陷识别方案。

相较于传统的特征提取方法,卷积神经网络包含的卷积层具有更强大的特征学习和表征能力,并且具有自动学习特征^[6]。Mohanty 等^[7]采用 AlexNet 成功实现了植物病害的检测;Wang 等^[8]通过训练卷积神经网络实现了对植物病害严重程度的自动和准确估计;Johannes 等^[9]使用改进的基于深度残差神经网络的算法进行了多种植物疾病的检测;Ferentinos^[10]开发了卷积神经网络模型对健康和病害叶片的检测和诊断;Rangarajan 等^[11]使用 Alexnet 的预训练模型对番茄作物病害进行了有效分类。试验拟提出一种基于网中网(NIN-CNN)卷积神经网络的方法对红枣进行缺陷检测,利用含有隐藏层的 MLP 卷积层结构替换 Alexnet 中原有的单卷积层结构进行更加抽象复杂特征的提取,采用全局平均池化层替代原有的全连接层,以期在大大减少网络参数数量的同时实现更高准确率的红枣缺陷识别。

1 NIN-CNN 网络模型

NIN-CNN 卷积神经网络是一种基于 AlexNet 改进的卷积神经网络,在原有 AlexNet 卷积神经网络的基础

作者简介:杨志锐(1995—),男,武汉大学在读硕士研究生。

E-mail:568938548@qq.com

收稿日期:2019-10-31

上增加了 1×1 隐含感知层来增强网络的非线性,从而提取更抽象的特征;采用全局平均池化层替换全连接层,不仅可减少参数数量,还有利于提高检测准确率。

1.1 AlexNet 卷积神经网络架构

如图 1 所示, AlexNet 网络结构共有 8 层,其中包含 5 层卷积层和 3 层全连接层,在第 1、2、5 卷积层后添加了最大池化层来减少下一层输入的参数和计算量;全连接层对最后一层卷积层提取的特征进行加权,通过线性变换将特征空间映射到样本标记空间;在最后一个全连接层后接 Softmax 层进行分类。

1.2 基于 AlexNet 改进的 NIN-CNN 神经网络

Alexnet 所采用的卷积滤波器属于广义线性模型,抽象程度较低,不利于高度抽象特征的提取;其全连接层参数量大,容易造成过拟合。针对以上缺陷,进行如下改进。

(1) 针对传统卷积层,通过堆加 1×1 大小的卷积层组成多层感知器 (MLP) 微型网络单元 (又称网络中的网络,即 NIN-CNN),使其提取特征的能力更强大。

(2) 用全局均值池化层替换全连接层,防止全连接产生的过拟合,并提高网络模型的泛化能力。

如图 2 所示, NIN-CNN 模型由 12 个卷积层组成。网络的具体参数如表 1 所示。该网络在 AlexNet 网络的 $11 \times 11, 5 \times 5, 3 \times 3$ 卷积层后分别串联了两个 1×1 大小的卷积核,组成 4 个 MLP 结构,每个 MLP 结构之间采用类型为最大池化层,卷积核大小为 3×3 ,步长为 2 的池化层进行连接采样,网络中的最后一个 MLP 结构之间采用类型为全局平均池化、卷积核大小为 6×6 、步长为 1 的全局均值池化层进行连接。

1.2.1 MLP 卷积层 传统卷积层使用线性滤波器进行扫描输入,后接一个非线性激活函数,得到输出作为特征图。特征提取器由卷积层和空间池化层交替堆叠产生。按式(1)计算 AlexNet 特征图。

$$f_{a,b,m} = \max(w_m^T x_{a,b}, 0), \tag{1}$$

式中:

$f_{a,b,m}$ —— AlexNet 特征图;

$x_{a,b}$ —— 以 (a, b) 为中心的输入块;




图 1 AlexNet 网络结构示意图
Figure 1 Diagram of AlexNet network




图 2 NIN-CNN 网络结构图
Figure 2 Diagram of NIN-CNN network

表 1 NIN-CNN 网络参数

Table 1 The parameters of NIN-CNN network

层名称	卷积核大小	步长	层名称	卷积核大小	步长
卷积层 1	11×11	1	卷积层 1	3×3	1
级联跨信道参数池化层 1	1×1	1	级联跨信道参数池化层 5	1×1	1
级联跨信道参数池化层 2	1×1	1	级联跨信道参数池化层 6	1×1	1
最大池化层 1	3×3	2	最大池化层 3	3×3	2
卷积层 2	5×5	1	卷积层 4	3×3	1
级联跨信道参数池化层 3	1×1	1	级联跨信道参数池化层 7	1×1	1
级联跨信道参数池化层 4	1×1	1	级联跨信道参数池化层 8	1×1	1
最大池化层 2	3×3	2	全局最大池化层	6×6	1

W_m ——卷积参数。

当需要提取的特征较简单,是线性可分时,这种线性卷积足以用于提取抽象特征;当特征较为复杂,抽象度更高时,采用高度非线性函数进行抽象特征的提取。

根据 CNN 高层特征是底层特征通过某种运算的组合原理,NIN-CNN 网络对传统的卷积层进行了改进:采用少量参数取得了超过 AlexNet 的性能,提出在每个局部感受野中增加更为复杂的运算,并引入基于感知机模型的卷积层。多层感知机作为一个深度模型,并按式(2)进行计算。

$$\begin{cases} f_{a,b,m}^1 = \max[(w_{m1}^1)^T x_{a,b} + b_m, 0]; \\ \vdots \\ f_{a,b,m}^n = \max[(w_{m1}^n)^T f_{a,b}^{n-1} + b_m, 0], \end{cases} \quad (2)$$

式中:

$f_{a,b,m}^1$ ——第 1 个特征图;

$f_{a,b,m}^n$ ——第 n 个特征图;

b_m ——第 m 层的偏置;

w_m^n ——第 n 层卷积;

$x_{a,b}$ ——以 (a,b) 为中心的输入块。

传统卷积层后串联两个大小为 1×1 并具有 ReLU 函数的卷积层即可组成 MLP 卷积层。改进的 NIN-CNN 网络使用的 MLP 卷积层实际上是由一个普通的卷积层和两个 1×1 卷积层构成,其中普通卷积层用来提取图像的局部特征, 1×1 卷积层增加了网络单元的非线性,有利于提取不同通道的特征图像。此外,NIN-CNN 网络模型

中的每个卷积层后都有一个 Relu 非线性层,增加了卷积层数量,使其具有更好的非线性决策函数的建模效果,提高了分类的准确率。

1.2.2 全局平均池化层 AlexNet 网络的卷积层、池化层以及激活函数层将原始数据映射到隐层特征空间,最后一个卷积层得到的特征图被量化后送入全连接层,全连接层将学到的“分布式特征表示”映射到样本标记空间,并连接归一化指数函数逻辑回归层进行分类。但全连接层因为参数数量太多,容易出现过拟合现象,阻碍网络的泛化能力。因此将 dropout 层用于正则化,在训练过程中将全连接层的一半激活值置 0,改善了其泛化能力并在很大程度上预防了过拟合。

实际上,对最后一个卷积层输出的每个特征图进行全局均值池化,使每张特征图都可以得到一个输出,在大大减少参数量、减小网络的同时可避免过拟合;此外,每张特征图的输出特征可表示输出类的特征,通过增强特征图与类比间的对应关系使网络结构保留得更好。dropout 层的引入造成了全连接层的参数量大大增加,模型复杂度高,泛化能力差,而 NIN-CNN 神经网络采用全局均值池化替代全连接层的策略使得 dropout 不复存在,并且达到了用更少的参数取得更准确分类效果的目的。

2 基于 NIN-CNN 的红枣缺陷检测

试验提出的基于 NIN-CNN^[12] 的红枣缺陷检测流程包含网络模型的学习和网络模型的检测两大阶段,具体流程图如图 3 所示。

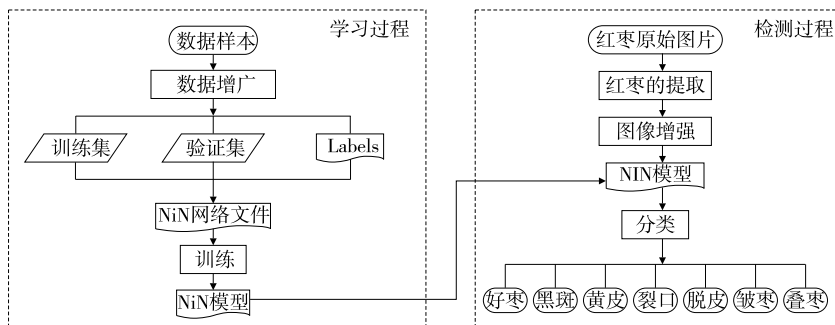


图 3 NIN-CNN 模型学习与检测流程图

Figure 3 Flow chart of NIN-CNN model of learning and detection

2.1 网络模型的学习

首先要进行样本数据的增广得到不同亮度、角度的扩充数据样本;然后进行参数设置;最后利用预设参数的 NIN-CNN 模型对样本进行学习,直至得到最终的网络模型。

2.1.1 数据的增广 卷积神经网络对于数据量的要求比较高,首先对红枣进行数据增广以提高模型的泛化能力。自然图像的数据增广包括水平或垂直翻转、旋转、缩放、裁剪、平移、添加噪声、调整对比度和亮度等。红枣存在

大小不均;在生产线上进行检测时,其摆放角度也是随机的;此外,红枣加工所处生产环境中存在各种图像噪声。综上,分别采用尺度统一化、水平及垂直翻转、旋转、高斯加噪的方法进行数据增广。

数据增广采用的是 python 数据增广库 imgaug,具体步骤为:首先采用水平翻转、上下反转、镜像翻转改变红枣的空间位置。然后利用 imgaug 库中的函数进行高斯加噪模拟生产环境中的噪声,同时对空间进行明暗变换来模拟生产线上不同的光照。最后将红枣图像归一化到

大小为 256×256 。试验中对空间的翻转、旋转、明暗变换以及空间加噪赋予一定的概率,每张样本图片可能随机地被翻转随机的度数,亮度随机增加或减少,随机加上噪声。此外,根据每类红枣的数量进行相应倍数的增广使其整体达到数据均衡,部分增广后的图片如图 4 所示。由图 4 可知,增广后的红枣在角度、光照强度等方面都发生了变化,大大提高了样本的数量和多样性。




图 4 数据增广前后对比图片

Figure 4 Comparison between original pictures and picture after data augmentation




图 5 红枣提取步骤及图像增强前后对比图

Figure 5 Steps to extract jujubes and comparison between the original pictures and the image enhanced

$$\text{Gray} = (W \times R + V \times G + U \times B) / 3. \quad (3)$$

(3) 图像二值化:在进行加权平均时,已将红枣与背景进行了大致的分离。在进行二值化时,只需设置一个合适的阈值就可将红枣部分变为白色像素,背景变为黑色像素,根据多次试验经验,阈值设置为 30。

(4) 二值化去噪:为了去除噪声,再次对图像进行最大轮廓的获取,将轮廓以外的部分图像像素变为 0。

(5) 红枣分割:采用掩膜法,因为掩膜法在去除背景和噪声的同时,不会对关键区域进行破坏。由于红枣部分的灰度值明显高于背景部分的,因此将红枣灰度化后

2.1.2 网络的超参数设置 卷积神经网络超参数的选取与设置对训练结果有着至关重要的影响。其中学习率的选择决定学习算法的性能表现,学习率大,梯度下降比较快,可能会在某一步越过最优值;学习率小,学习速度慢,导致收敛速度慢,容易过拟合。试验采用从头训练的方式,学习率设置为 $0.010 \sim 0.001$ 。此外,迭代次数也需通过选取比较进行确定,使用训练集的全部数据对模型进行一次完整训练为一次迭代,训练时设定的迭代次数为 $20 \sim 30$ 。

2.2 基于 NIN-CNN 模型的红枣缺陷检测流程

由于生产线环境嘈杂,亮度不可控等,采集的图片存在亮度不均、噪声多、背景杂乱等不足。因此,采用 NIN-CNN 进行检测前需对红枣进行预处理,首先对红枣进行提取使其与背景分离,再进行图像增强以消除噪声,并使红枣表面亮度分布均匀,最后将图片输入 NIN-CNN 模型中进行预测,得到分类结果。

2.2.1 红枣的提取 如图 5 所示,红枣图像提取步骤分为红枣粗分割、红枣灰度化、图像二值化、二值化去噪、红枣分割。

(1) 红枣粗分割:首先对图片进行大致的分割,按比例将图片分为左半部分、中间部分和右半部分,分别提取左边红枣、中间红枣和右边红枣。

(2) 红枣灰度化:图片灰度化常见方法有最大值法、平均值法和加权平均法,试验采用加权平均法对红枣图像进行灰度化。加权平均法表示为:

设置一个合适的阈值便可获得一个较好的掩膜。将掩膜作用于原始图片,进而成功提取红枣。

2.2.2 红枣图片的匀光处理 由于生产线环境为不可控因素,采集的红枣图片存在亮度分布不均匀现象^[13]。此外,由于拍摄时间不同也可能造成红枣样本的整体亮度存在差异。为了增强深度学习的效果,图像增强第一步为亮度校正,其目的是消除红枣表面亮度分布不均匀的现象。

亮度校正算法采用的是基于照度-反射模型,图像亮度 $f(x, y)$ 可表示为入射分量 $i(x, y)$ 与反射分量

$r(x,y)$ 的乘积。即

$$f(x,y) = i(x,y) \times r(x,y) \quad (4)$$

图像中变换缓慢的部分体现为入射分量,突变的分体现为反射分量。根据该特性,将图像的低频部分从原始图像中提取出来,再经傅里叶反变换得到亮度图像,获得的亮度图像可对原始的分布不均匀的灰度图像进行亮度矫正。具体过程为在频域中进行中心变换,离散傅里叶变换,最后用低通滤波器滤波,再进行傅里叶反变换,从而实现了在频域内处理图像,使图像亮度分布均匀^[14]。图像增强后红枣表面光照分布更加均匀,高光照部分亮度略微降低。

3 结果与分析

试验针对新疆骏枣进行了实测,通过数据增广共采用 41 467 张红枣图片作为数据集,将红枣分为好枣、黑斑、黄皮、裂口、脱皮、皱枣和叠枣 7 类。按接近于 6 : 2 : 2 的比例划分训练集(25 129 张)、验证集(8 424 张)和测试集(7 914 张)。将数据集中的每类红枣图片表示成一个一维向量,表征红枣的分类类别。训练前对红枣数据进行预处理,训练的每张图片的特征均要减去训练集所有图片的特征均值,将输入数据各个维度都中心化为 0,从而减少计算量,避免数据过度变差,训练效果受到影响。表 2 为试验中不同种类红枣的训练集、验证集和测试集数量。

3.1 7 类红枣分类标准

如图 6 所示,好枣由成熟的新疆骏枣进行晾晒后加




图 6 红枣分类图

Figure 6 Classification of 7 types of jujubes

正确的数量占总量的比重,并按式(5)计算准确率。

$$R = \frac{TP + TN}{TP + FN + FP + TN} \times 100\% \quad (5)$$

式中:

R——准确率, %;

TP——正类预测为正类的数量;

FN——正类预测为负类的数量;

FP——负类预测为正类的数量;

TN——负类预测为负类的数量。

3.3 NIN-CNN 网络参数的设置

根据 2.1.2 中超参数设置的原则,将求解器类型设置

表 2 7 类红枣数量

Table 2 Numbers of 7 different types of jujubes

类别	训练集	验证集	测试集
好枣	3 516	1 170	1 166
黑斑	3 552	1 184	1 120
黄皮	3 672	1 275	1 071
裂口	3 600	1 200	1 140
脱皮	3 415	1 135	1 125
皱枣	3 654	1 260	1 095
叠枣	3 720	1 200	1 200
合计	25 129	8 424	7 917

工而成,表皮呈鲜红或紫红,无明显的脱皮、褶皱、霉烂。皱枣是由不成熟的红枣干制形成,果肉干瘪、表皮褶皱较多。脱皮枣是在红枣制造过程中由于鸟啄、虫蛀等导致红枣表皮脱落,内部果肉外漏。黄皮枣由于树龄短、种植技术不规范导致红枣表皮整体颜色泛黄。烂枣是指红枣受到微生物侵害,果肉变质或者霉变导致表皮呈现黑色霉烂区域。裂口枣是由于果枣生产过程中受到机器损伤导致表面存在较长的裂口。叠枣是因为在生产线上,由于机械的翻转、红枣的放置等导致相机抓取图像时视野中存在两个或两个以上的红枣。

3.2 准确率计算

机器学习中常用的评价指标为准确率,即评估捕获的成果中目标成果所占的比例,试验中的准确率指预测

为随机梯度下降,学习率策略设置为 Step,每 10 个迭代次数降低为原来的 1/10,记忆因子设置为 0.9,分别选择迭代次数为 20,25,30,学习率为 0.010,0.001,将训练后得到的模型采用验证集进行预测,得到不同初始速率、迭代次数下的准确率,如表 3 所示。

由表 3 可知,NIN-CNN 网络在学习率为 0.010 时的准确率高于学习率为 0.001 时的,其中迭代次数为 30 时的准确率最高,因此最终确定 NIN-CNN 网络的超参数为迭代次数 30,学习率 0.010。AlexNet 网络在学习率为 0.001 时的准确率高于学习率为 0.010 时的,其中迭代次

数为 20 时的准确率最高,因此最终确定 Alexnet 网络的超参数为迭代次数 30,学习率 0.001。

3.4 试验比较与检测性能评估

3.4.1 不同网络参数总量的比较 将两个网络的参数性能进行比较可知,NIN-CNN 在添加 1×1 卷积层加深网络深度的同时减少了大卷积核的数量,从而减少了参数数量;另一方面,采用局部均值池化代替全连接层极大地减少了参数量,同时防止了过拟合。AlexNet 网络的参数数量为 56 896 903,而 NIN-CNN 网络的参数数量为 6 577 351,减少了 88.44%。

3.4.2 数据增广对检测性能的影响 由表 4 可知,增广后,AlexNet 网络的准确率提高了 1.14%,NIN-CNN 网络的准确率提高了 1.05%,验证了数据增广对网络模型准确率提升的有效性。

表 3 不同迭代次数和学习率下 NIN-CNN 和 AlexNet 网络的准确率

Table 3 Accuracy of different epochs in NIN-CNN and AlexNet %

迭代次数	NIN-CNN		AlexNet	
	0.001	0.010	0.001	0.010
20	73.57	94.74	93.82	93.54
25	76.79	94.79	93.72	93.32
30	77.07	94.72	93.81	93.40

表 4 数据增广前后准确率的比较

Table 4 Comparison between the original data and data augmentation %

网络	增广前	增广后
AlexNet	92.67	93.81
NIN-CNN	93.74	94.79

3.4.3 检测性能比较 试验引入了目前常用的基于 SVM 的机器视觉方法进行比较^[15-16],采用手工设计规则提取红枣特征,然后将 7 类不同特征组合成特征向量输入 SVM 中进行分类,最后使用验证集对模型进行测试。由表 5 可知,SVM 方法的好枣识别准确率最高,但其他 6 类缺陷红枣的准确率均低于 NIN-CNN 和 AlexNet 网络;AlexNet 网络的黑斑、黄皮、裂口红枣识别准确率高于 NIN-CNN 网络的,但好枣、脱皮、皱枣、叠枣红枣识别的准确率低于 NIN-CNN 网络的。相对于 SVM 方法,NIN-CNN 网络在红枣缺陷识别方面表现出极大的优越性^[18];NIN-CNN 网络的缺陷识别准确率比 Alexnet 模型的高 1%左右,证明试验采用 1×1 卷积核加深网络,全局均值池化方式替代全连接层来提升缺陷识别准确率是有效的。

表 5 不同方法检测准确率的比较

Table 5 Comparison of the accuracy in different detection methods %

类别	SVM 方法	AlexNet 网络	NIN-CNN 网络
好枣	97.94	94.60	97.26
黑斑	50.00	96.52	91.67
黄皮	75.11	100.00	95.56
裂口	75.68	97.63	90.53
脱皮	45.71	94.40	97.23
皱枣	33.33	92.31	99.53
叠枣	84.06	91.67	94.79
总准确率	84.06	93.81	94.79

4 结论

针对红枣的缺陷特征,提出一种基于 AlexNet 卷积神经网络对红枣进行分类的方法,并进行验证实验,利用改进的网络 NIN-CNN 对红枣进行分类。结果表明,基于 AlexNet 网络的红枣识别准确率为 93.81%,基于 NIN-CNN 网络的红枣识别准确率为 94.79%,验证了 NIN-CNN 网络相对于 AlexNet 网络的优越性。试验提出的基于 NIN-CNN 卷积神经网络的分类方法对裂枣和黑斑枣的识别准确率还不够理想,后续可考虑引入残差网络等结构对试验方法进一步改进。

参考文献

[1] 亓树艳,王荔,莫晓燕. 大枣多糖的提取工艺及抗氧化作用研究[J]. 食品与机械, 2012, 28(4): 117-120.

[2] 毛永民,宋仁平,申连英,等. GB/T 22345—2008 鲜枣质量等级[S]. 北京: 中国标准出版社, 2006: 1-6.

[3] 钟小华,曹玉华,张永清,等. 基于机器视觉技术的红枣全表面信息无损分拣系统研究与实现[J]. 食品与机械, 2017, 33(5): 114-118.

[4] 詹映. 基于机器视觉新疆红枣颜色分级方法研究[D]. 阿拉尔: 塔里木大学, 2015: 21-26.

[5] 张萌,许敏. 红枣表面缺陷快速检测方法研究[J]. 江苏农业科学, 2015, 43(7): 331-334.

[6] KRIZHEVSKY A, SUTSKEVER I, HINTON G. Image net classification with deep convolutional neural networks [J]. Advances in Neural Information Processing Systems, 2012, 25(50): 6 608-6 615.

[7] MOHANTY S P, HUGHES D P, SALATHE MARCEL. Using deep learning for image-based plant disease detection[J]. Frontiers in Plant Science, 2016, 7(3): 1 419.

[8] WANG Guang, SAN Yu, WANG Jian-xin. Automatic image-based plant disease severity estimation using deep learning[J]. Computational Intelligence and Neuroscience, 2017, 2 017: 1-8.

(下转第 181 页)

- and bioactivity of Citrus flavonoids: A focus on antioxidant, anti-inflammatory, anticancer and cardiovascular protection activities [J]. *Phytochemistry Reviews*, 2017, 16 (3): 479-511.
- [6] 邵金华, 何福林, 陈霞, 等. 梓树根皮总黄酮分离纯化及其抑菌活性研究[J]. *食品与机械*, 2017, 33(2): 140-144.
- [7] 张硕, 倪亚红, 黄静, 等. 酶—超声辅助提取杨树皮总黄酮及其表征[J]. *林业工程学报*, 2019, 4(2): 73-79.
- [8] 杨昱, 白靖文, 俞志刚. 超声辅助提取技术在天然产物提取中的应用[J]. *食品与机械*, 2011, 27(1): 170-174.
- [9] 苏秀芳, 甘海妹, 黄智想. 微波辅助法提取细叶黄皮果仁总黄酮及其清除羟自由基活性的测定[J]. *精细化工*, 2010, 27(12): 1 184-1 186.
- [10] 许建本, 苏秀芳, 莫耀芳. 超声波辅助法提取假苹婆树叶总黄酮及其清除羟自由基能力[J]. *食品工业科技*, 2018, 39(23): 205-208, 215.
- [11] 王全泽, 袁堂丰, 刘磊磊, 等. 响应面法优化闪式提取罗汉松总黄酮及其抗氧化活性[J]. *精细化工*, 2018, 35(1): 65-71.
- [12] 陈建福. 响应面优化超声辅助提取黄槿叶总黄酮工艺及其亚硝酸盐清除能力[J]. *食品工业科技*, 2019, 40(6): 199-203, 210.
- [13] 李欣然, 朱森, 韩世明, 等. 刺梨叶总黄酮超声辅助提取工艺优化[J]. *食品研究与开发*, 2019, 40(12): 189-193.
- [14] 周旋, 许明祥, 蔡文卓, 等. 女贞子总黄酮超声辅助提取工艺及体外抗氧化活性研究[J]. *食品与机械*, 2019, 35(3): 188-194.
- [15] GU Xue-dong, SUN Ya-jing, MA Chang-zhong, et al. The optimization of ultrasonic extraction process of total flavonoids from *Rhodiola Crenulata* by response surface method [J]. *Medicinal Plant*, 2017, 8(6): 33-39.
- [16] 王振吉, 杨申明, 张光勇. 首乌藤总黄酮提取工艺优化及抗氧化性研究[J]. *中国酿造*, 2019, 38(3): 177-180.
- [17] 郭文娟, 王娜, 王娜娜, 等. 山楂核总黄酮的超声提取及抗氧化活性[J]. *精细化工*, 2016, 33(2): 152-156.

(上接第 139 页)

- [9] BOSS E A, FILHO R M, TOLEDO E C V D. Freeze drying process: Real time model and optimization[J]. *Chemical Engineering and Processing*, 2004, 36(43): 1 475-1 485.
- [10] 李俊奇, 李保国. 药品真空冷冻干燥过程监控技术研究进展[J]. *化工进展*, 2015, 34(8): 3 128-3 132.
- [11] 邹晓霜, 李佳妮, 姜楠, 等. 响应面法优化豆腐真空冷冻干燥工艺[J]. *食品科学*, 2017, 38(18): 202-206.
- [12] 丁成翠, 徐志孙, 章程辉, 等. 青胡椒冷冻干燥工艺的优化[J]. *中国调味品*, 2012, 37(2): 46-50.
- [13] 罗洁莹, 汤梅, 柳建良, 等. 蓝莓真空冷冻干燥工艺优化[J]. *食品研究与开发*, 2018, 39(3): 91-95.
- [14] 陈林和, 章志成. 基于 MATLAB/SIMULINK 和组态王的监视平台在污泥热风干燥中的应用[J]. *数字通信世界*, 2017(9): 139-140.
- [15] 黄忠闯. 芒果、米葱真空冷冻干燥工艺的研究[D]. 南宁: 广西大学, 2011.
- [16] 厄特延, 黑斯利. 冷冻干燥[M]. 徐成海, 译. 北京: 化学工业出版社, 2005.
- [17] 焦凌霞, 李保国, 高愿军, 等. 水果加工中热烫处理对 V_C 保存率的影响[J]. *河南职业技术学院学报*, 2004, 32(1): 42-44.
- [18] 刘军波, 刁礼根, 赵芸. 蓝莓花青素加工环境稳定性研究[J]. *食品与生物技术学报*, 2017, 37(10): 1 073-1 079.
- [19] 徐成海. 真空干燥技术[M]. 北京: 化学工业出版社, 2012.
- [20] XIANG Jun, HEY J M, LIEDTKE V, et al. Investigation of freeze-drying sublimation rates using a freeze-drying microbalance technique[J]. *International Journal of Pharmaceutics*, 2004, 279(1/2): 95-105.

(上接第 145 页)

- [9] JOHANNES A, PICON A, ALVAREZ-GILA A, et al. Automatic plant disease diagnosis using mobile capture devices, applied on a wheat use case[J]. *Computers and Electronics in Agriculture*, 2017, 138(12): 200-209.
- [10] FERENTINOS K P. Deep learn models for plant disease detection and diagnosis[J]. *Computers and Electronics in Agriculture*, 2018, 145(20): 311-318.
- [11] RANGARAJAN A K, PURVSHOTHAMAN R, RAMESH A. Tomato crop disease classification using pre-trained deep learning algorithm[J]. *Procedia Computer Science*, 2018, 133: 1 040-1 047.
- [12] LI Fei, LI Zhi-tang. An improved interconnection network based on NIN[J]. *Wuhan University Journal of Natural Sciences*, 2004(3): 303-308.
- [13] 钟克洪, 丁明跃, 周成平, 等. 基于均匀空间的颜色分级方法[J]. *中国图象图形学报*, 2004(11): 7-13, 127.
- [14] 李江波, 饶秀勤, 应义斌. 水果表面亮度不均校正及单阈值缺陷提取研究[J]. *农业机械学报*, 2011, 42(8): 159-163.
- [15] 庞江伟, 应义斌. 机器视觉在水果缺陷检测中的研究现状[J]. *农机化研究*, 2006(9): 47-49.
- [16] 邵帅. 一种基于三支决策 SVM 分类的图像识别方法[J]. *现代计算机*, 2019(18): 64-69.
- [17] 王春普, 文怀兴, 王俊杰. 基于机器视觉的大枣表面缺陷检测[J]. *食品与机械*, 2019, 35(7): 168-171.