

基于深度学习的山核桃破壳物料分类识别

Classification and recognition of broken hickory shell materials based on deep learning

李文宝

曹成茂

张金炎

彭美乐

LI Wen-bao CAO Cheng-mao ZHANG Jin-yan PENG Mei-le

(安徽农业大学工学院, 安徽 合肥 230036)

(College of Engineering, Anhui Agricultural University, Hefei, Anhui 230036, China)

摘要:目的:对山核桃一次破壳后物料进行分类,提高山核桃深加工水平。方法:通过图像采集系统得到5类山核桃样本,分别为较完整壳仁未分、露仁、未破壳完整山核桃、不完整壳仁未分、壳。利用数据增广的方式,得到包含15 000个图像样本建立的数据集。在VGG16网络基础上构建模型,并按9:1的比例在包含5类山核桃物料图像的数据集上进行训练和验证。结果:该模型训练准确率和验证准确率分别达到了97.3%,99.7%;对1 713张山核桃加工物料图像进行分类识别,准确度达到了99.5%。结论:该模型能够达到对山核桃一次破壳后的物料分类识别的精度要求。

关键词:山核桃;卷积神经网络;VGG16;分类识别

Abstract: **Objective:** In order to classify the pecan materials after the shell is broken, and to improve the deep processing level of pecans. **Methods:** 5 types of pecan samples were obtained through the image acquisition system, including relatively intact shell kernels, undivided kernels, unbroken intact pecans, incomplete shell kernels undivided, and shells. Using the data augmentation way, a sample containing 15 000 images created data sets were obtained. Build a model based on the VGG16 network, which was trained and verified on a data set containing 5 types of pecan material images according to the ratio of 9 : 1. **Results:** The results showed that the accuracy of model training and validation accuracy reached 97.3% and 99.7%, respectively. Through classification and recognition of 1 713 hickory processed material images, the accuracy reached 99.5%. **Conclusion:** The model can be achieved after a break of pecan shell material classification accuracy requirements.

Keywords: hickory; convolutional neural network; VGG16; classification and recognition

山核桃系胡桃科山核桃属树种,果仁富含不饱和脂肪酸以及多种人体必需的氨基酸和矿物质,具有极高的营养价值,是皖南山区重要的经济作物之一^[1]。其果壳坚硬而厚,隔膜发达,果仁位于隔膜内,壳仁结合十分紧密,使得低损伤破壳取仁十分困难。传统的山核桃破壳加工方法主要是一次破壳和二次破壳相结合的方式,通过对破壳后的混合物料进行筛选,将山核桃仁分选出来,实现壳仁分离^[2],然而加工过程中存在着仁损伤率高,分选效率低等问题。在山核桃加工过程中对一次破壳后的物料进行细分,将不同类型的物料分二次加工,降低山核桃仁的损伤,可进一步提升山核桃的深加工水平^[3]。

计算机视觉及卷积神经网络在农业领域已有广泛的应用^[4],如 Mohammad 等^[5]通过改进的卷积神经网络来检测樱桃的外观,达到了99.4%的准确率,能够替代传统的分级方法;Kozłowski 等^[6]通过对9种卷积神经网络进行对比,实现了对大麦的视觉分类检测,准确度达93%;Nasiri 等^[7]利用迁移学习的方法对枣果进行分类,模型总体的分类准确度达96.98%。中国在农业领域也开始应用机器视觉及深度学习技术,如在玉米病害检测、水稻杂株识别,柑橘^[8]、苹果^[9]、荔枝^[10]、辣椒^[11]、番茄^[12]、茶叶^[13]等农产品分级等均有研究。汪天宇^[14]采用模糊聚类算法对山核桃进行壳仁分选,将露仁从3种破壳后的混合物料中分选出来,能够达到83%的识别准确率。对山核桃一次破壳后的物料进行进一步细分,破壳后的物料经风选、振动筛选,去除杂质、灰尘及细碎壳渣后,剩下的物料可以细分为5类:较完整壳仁未分、露仁、未破壳完整、不完整壳仁未分和壳。为了实现5种物料更精细、准确的分类,研究拟引入卷积神经网络,基于VGG16来构建分类模型,修改全连接层以实现

基金项目:国家自然科学基金面上项目(编号:52075003)

作者简介:李文宝,男,安徽农业大学在读硕士研究生。

通信作者:曹成茂(1964—),男,安徽农业大学教授,博士生导师,博士。E-mail:caochengmao@sina.com

收稿日期:2021-02-12

5 种物料的分类,旨在验证卷积神经网络对山核桃一次破壳后物料分类识别的可行性,为提高山核桃的深加工水平提供参考。

1 材料及数据集建立

1.1 山核桃初次加工物料样本

山核桃样本为安徽省宁国市当地所产的山核桃。脱脯后的山核桃经沸水蒸煮 25 min,投入到 6HP-120A 型山核桃破壳机中进行一次破壳,振动、风选,剔除小碎壳及灰尘,剩下的物料分为 5 类(如图 1 所示):较完整壳仁未分、露仁、未破壳山核桃、壳、不完整壳仁未分。

1.2 图像采集平台

使用电脑通过 USB 连接数码相机采集图片,设计一个立体暗箱,在暗箱内部布置 LED 灯带作为光源,对所要拍摄的物料进行补光减少阴影。每张图片均为白色背景,可以减少背景对检测的物料干扰,固定相机位置、光照位置、相机与样品之间的距离。物料图像采集系统如图 2 所示,研究共采集 1 713 张图片包括 332 张较完整壳仁未分、380 张露仁、312 张未破壳完整山核桃、385 张壳和 304 张不完整壳仁未分物料。

1.3 图像预处理

试验中,相机采集的图像白色背景占整张图片的面积过大,需对采集的图片进行预处理。利用 OpenCV 计算机视觉软件库编写程序对得到的图片进行分割,去除山核桃物料的大部分白色背景,突出感兴趣区域(ROI),抑制背景,并且提取物料图片。利用阈值分割的方法分




图 1 初次破壳后的山核桃物料

Figure 1 Pecan material after the first shelling

割图像,根据目标与背景在灰度上的差异,通过设置阈值实现目标与背景的分离。采用数学表达式来表示,则可设原始图像为 $f(x,y)$,选取一个阈值用于计算背景去除的 T 值。分割后的图像 $g(x,y)$ 定义为:

$$g(x,y) = \begin{cases} 1, & \text{if } f(x,y) > T \\ 0, & \text{if } f(x,y) \leq T \end{cases} \quad (1)$$

式中:

$f(x,y)$ —— 原始图像;

$g(x,y)$ —— 阈值分割后的图像;

x,y —— 当前像素坐标;

T —— 最佳的阈值。

如图 3 所示,通过阈值分割法对原始图片进行分割后,通过形态学操作消除阈值处理不完善的地方,即图片的黑色点状区域,进而得到完整的连通区域,寻找到连通域的最小外接矩形,确定外接矩形的 4 个点坐标,对原图按照得到的点坐标进行裁剪,即可得到删除大部分白色背景的样本图片。

1.4 图像数据增广

深度神经网络中嵌入了大量的参数。因此,训练阶段需要大量的数据进行训练来学习所有的参数,否则无法对神经网络进行充分的训练,或者是出现过拟合的风险,所以需要增加训练的数据量,提升模型的泛化能力。通常使用数据增广的方法在不增加成本和时间的情况下增加训练图片的数量。

在数据增广的方法中,训练数据集使用具有相同的标签或者类来进行增加,以防止过拟合的问题。对训练数据集使用旋转、亮度变化、高度偏移、宽度偏移、缩放、水平翻转和剪切等处理,对数据进行增强。如图 4 所示,通过数据增强,将训练样本的 1 713 张图片扩充为 15 000 张图片。




图 2 样本图像采集平台

Figure 2 Sample image acquisition platform




图 3 图片预处理过程

Figure 3 Picture preprocessing process




图4 图像数据增广

Figure 4 Image data augmentation

经数据增强后,样本数量大大增加(见表1),相对于原始数据集能够更加充分地训练网络参数。训练时采取交叉熵损失函数,能够有效解决样本的不平衡性,从而提升准确率,使模型更具鲁棒性^[15]。

表1 数据增广后样本数据

Table 1 Sample data after data enhancement

样本名称	图片数量	增广后的数量	标签
较完整壳仁未分	332	2 491	A
露仁	380	3 297	B
未破壳完整	312	2 688	C
壳	385	3 416	D
不完整壳仁未分	304	2 658	E

2 模型构建

分类识别模型的建立主要基于卷积神经网络,特征不是人为设计的,而是使用一种通用的学习方法从数据中学得,避免了繁琐的特征提取过程^[16]。卷积神经网络的网络深度对于分类精度和检测性能有重要作用,VGG16通过加深同质化网络结构来提升分类性能^[17]。VGG的分类能力略逊于GoogLeNet,但其拓扑结构没有GoogLeNet复杂,VGG网络生成的特征优于其他的CNN,如AlexNet、GoogLeNet。因此,VGG在计算机视觉任务中是热门的选择之一^[18]。

2.1 网络模型结构

选择VGG16作为山核桃物料分类网络的特征提取的网络结构,其包含13个卷积核为 3×3 的卷积层,5个最大池化层,输入图片经VGG16结构的神经网络提取特征,然后展平处理为特征向量,对特征向量进行批归一化(BN)处理,通过全连接层对样本进行分类,使用Softmax

函数对分类概率进行归一化。试验建立的模型网络结构如图5所示。

2.2 卷积层

VGG16包含13个卷积核为 3×3 的卷积层。第一层的卷积层可能只提取输入图片的低级特征,如边缘、角点、颜色等,更深的卷积层从低级的特征图中提取更复杂的特征。假设输入图像为 $(m, n, 3)$,卷积核的输入节点为 (x, y, z) ,使用 $w_{x,y,z}^i$ 表示对于输出单位节点矩阵的第 i 个节点卷积核的权重,该输出节点对应的偏置项 b^i ,输出单位矩阵该点的取值计算如式(2)所示:

$$g(i) = f\left(\sum_{x=1}^m \sum_{y=1}^n \sum_{z=1}^3 a_{x,y,z} \times w_{x,y,z}^i + b^i\right), \quad (2)$$

式中:

$a_{x,y,z}$ ——输入节点为 (x, y, z) 的取值;

f ——激活函数。

为增加网络模型的非线性,采取ReLU函数作为激活函数,其数学公式为^[19]:

$$f(x) = \begin{cases} x, & \text{if } x > 0 \\ 0, & \text{otherwise} \end{cases}. \quad (3)$$

ReLU函数是分段线性函数,经该函数处理,所有的负值和0取值均为0,所有的正值则不变。ReLU函数能够使模型变得稀疏,经该函数处理后的模型可以更好地挖掘相关特征。

2.3 池化层

卷积神经网络还具有缩小图片大小作用的池化层。利用图像局部相关性的原理,对图像进行采样,池化层对原始特征层的信息进行压缩,减少处理的数据量,从而预防过拟合。试验网络模型采用的是最大池化方式,其池化过程如图6所示。




图5 模型网络结构

Figure 5 Model network structure




图 6 池化过程示意图

Figure 6 Schematic diagram of pooling process

2.4 批规范化层(BN)

批规范化层是 2015 年由 Loffe 等^[20]提出,主要是为了加速神经网络的收敛过程以及提高训练过程中的稳定性。在 CNN 中使用批规范化处理会使网络加深,并且训练过程所需要的迭代次数会减少。试验构建的分类模型,在通过卷积层与池化层后,展平为特征向量,并通过 BN 层对数据进行归一化处理,提高训练过程的稳定性。批规范化操作的数学表达式为:

$$y = \frac{(x - \mu)y}{\sqrt{\sigma^2 + \epsilon}} + \beta, \quad (4)$$

式中:

x —— 当前训练批次;

μ, σ —— x 的平均值和标准差;

β —— 可训练参数;

ϵ —— 较小的常数(用来避免零为除数)。

2.5 全连接层(FC)

全连接层中,每一个神经元都与上一层所有神经元进行全连接,全连接层可以整合卷积层或者池化层中具有类别区分性的局部信息,包含向量权重和激活函数,将卷积层输出拉伸为一维特征向量作为输入,然后该向量与权重向量作点乘,将点乘的结果作为激活函数的输入,最终输出的结果便是全连接层的最终结果。

2.6 Softmax 函数

将 Softmax 函数应用于全连接层后,该函数预测了属于每一种类别图片的归一化概率,实现对研究物料的最终分类概率预测。在处理多分类($C > 2$)问题上,分类器最后的输出单元需要使用 Softmax 函数进行数值处理,其定义式为:

$$S_i = \frac{\exp(v_i)}{\sum_j \exp(v_j)}, \quad (5)$$

式中:

v_j —— 分类器前级输出单元的输出;

i —— 类别索引;

c —— 总的类别数;

S_i —— 当前元素的指数与所有元素指数和的比值。

所有类别的概率和为 1,即 $\sum_{i=1}^c s_i = 1$ 。Softmax 将分类的输出数值转化为相对概率,因此更容易理解和比较。

2.7 损失函数

多分类任务通常采用交叉熵损失函数,交叉熵表示的是实际输出与期望输出的距离,交叉熵越小二者的概率分布越近。假设概率分布 p 为期望输出,概率分布 q 为实际输出, $H(p, q)$ 为交叉熵,其计算式为:

$$H(p, q) = - \sum_{j=1}^T p(x) \log q(x), \quad (6)$$

式中:

T —— 分类类别数。

试验设计的网络输出结果在输出前经过了 Softmax 函数,将网络输出变成概率分布。由于样本集不是太大,采用批量梯度下降,最后交叉熵损失为所有 batch 的均值。

2.8 Dropout 方法

为了防止训练过程中模型出现过拟合,造成准确度下降,引入 Dropout 方法。该方法一方面是为了避免过拟合,另一方面是使用更有效的方式进行模型融合。当神经元被置 0 时,其不会参与前向传播和反向回传的计算,其他神经元可以参与训练,并且更新权重。这个过程可以使神经元学习出来的模型不会太过依赖某些局部特征,提高了模型的泛化能力。Dropout 原理如图 7 所示。

3 训练与结果分析

采用 pytorch 深度学习框架,使用 python3.7 编程语言构建卷积神经网络,实现对山核桃物料的分类,其硬件配置见表 2。

3.1 训练参数及结果

为了验证模型性能,将数据集中样本的 90%(13 502 张图片)用于训练,剩下的 10%(1 498 张图片)用于测试。训练过程中,将 Dropout 率设置为 0.5, batch_size 设置为 32,训练 epoch 设置为 50。采用随机梯度下降算法(SGD)对模型参数进行优化训练。模型学习率是 SGD 算法中的重要参数,为了保证训练速度,将初始学习率设置




图 7 Dropout 原理示意图

Figure 7 Schematic diagram of Dropout principle


表 2 硬件配置表
Table 2 Hardware configuration table

类别	设备配置
CPU	E5-2678V3 2.5 GHZ
GPU	NVIDIA GeForce RTX 2080 Ti
内存	62 GB
硬盘	100 GB

为 0.001,学习率下降间隔数为 5 个 epoch,其调整倍数为 0.1。分别对数据增广前、后的数据集进行训练,结果如图 8 所示。由图 8 可知,增广后,训练过程更加平滑,能够有效地降低过拟合,提高训练精度。

3.2 特征图可视化

卷积神经网络训练是一个黑箱过程,通过可视化特



征图,能够更加直观地了解卷积神经网络的学习情况,图 9 为山核桃物料图像及其不同的特征图。

3.3 混淆矩阵

为了评估模型对 5 种山核桃加工物料的识别性能,使用混淆矩阵观察分类结果。使用训练后的模型对原始数据集 1 713 张图片进行预测,并制作混淆矩阵,将较完整山核桃、不完整山核桃、未破壳山核桃、露仁和壳 5 种类型设置标签对应 A、B、C、D、E。使用混淆矩阵的横坐标表示山核桃加工物料的真实标签,纵坐标表示预测标签,预测结果如图 10 所示。

由图 10 可知,经 50 个 epoch 训练得到的模型,其总体分类精度较高,达 99.5%。为了更准确地描述模型对各种物料的分类情况,分析各类别的精确率、召回率和特异度,结果见表 3。




图 8 分类准确度
Figure 8 Classification accuracy




图 9 山核桃物料及其特征图可视化

Figure 9 Visualization of pecan material and its feature map




图 10 混淆矩阵

Figure 10 Confusion matrix

表 3 5 种山核桃物料预测分类数据
Table 3 Forecast classification data of 5 pecan materials

样本名称	精确率/%	召回率/%	特异度/%	标签
较完整壳 仁未分	99.1	99.4	99.8	A
露仁	99.2	99.5	99.8	B
未破壳完 整山核桃	100.0	99.4	100.0	C
壳	100.0	100.0	100.0	D
不完整壳 仁未分	99.3	99.3	99.9	E

由表 3 可知,模型对露仁的识别精确率达到了 99.2%,能够有效地将露仁分选出,对于需要剔除的壳以及将要送回一次破壳机重新破壳的完整山核桃识别精确率达到了 100.0%。

3.4 模型对比

利用深度学习的方法对山核桃破壳物料进行分类,与传统的非线性分类模型进行对比,结果见表 4。

表 4 不同分类模型对比

Table 4 Comparison of different classification models

模型	整体精度/%
SVM-高斯内核	82.3
BP 神经网络	85.1
VGG16	99.5

由表 4 可知,传统的 SVM、BP 神经网络的分类精度最高只能达到 85.1%,而 VGG16 的分类精度达到了 99%以上,具有较好的优越性。

4 结论

针对含隔类坚果山核桃一次破壳后的 5 种物料(较完整壳仁未分、露仁、未破壳完整、不完整壳仁未分和壳),引入了深度学习算法,并进行了一系列的训练和探究。结果表明,较完整壳仁未分、露仁、未破壳完整、不完整壳仁未分和壳 5 种物料的识别精确率分别达 99.1%,99.2%,100.0%,100.0%,99.3%;与传统的非线性模型相比,VGG16 模型对破壳物料的分类精度更高,其总体准确度达到了 99.5%。综上,利用深度学习对山核桃物料进行分类,能够有效地识别山核桃,识别准确度高且稳定。受条件限制,研究中对物料采用单个角度的拍摄,图像可能无法完整地表达各类别物料,仍需进一步考虑取样方法。研究中将物料分为 5 类,可能还存在一些如霉变的山核桃仁等物料,需对样本划分进一步细化。

参考文献

[1] 李夕勃,赵书岗,王红霞,等.核桃坚果硬壳结构与木质素和纤维素相关性研究[J].湖北农业科学,2012,51(22):5076-5079.
LI Xi-bo, ZHAO Shu-gang, WANG Hong-xia, et al. Relationship between walnut shell structures and the content of lignin cellulose[J]. Hubei Agricultural Sciences, 2012, 51(22): 5076-5079.

[2] 刘明政,李长河,曹成茂,等.核桃分级破壳取仁及壳仁分离关键技术及装置研究进展[J].农业工程学报,2020,36(20):294-310.
LIU Ming-zheng, LI Chang-he, CAO Cheng-mao, et al. research progress of technology and device for size-grading shell-kernel separation of walnut[J]. Transactions of the Chinese Society of Agricultural Engineering, 2020, 36(20): 294-310.

[3] 曹成茂,李正,罗坤,等.山核桃二次破壳取仁机设计与试验[J].农业机械学报,2019,50(3):128-135.

CAO Cheng-mao, LI Zheng, LUO Kun, et al. Design and experiment of secondary shell breaking machine for pecan[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(3): 128-135.

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

[5] MOMENY M, JAHANBAKHSI A, JAFARNEZHAD K, et al. Accurate classification of cherry fruit using deep CNN based on hybrid pooling approach[J]. Postharvest Biology and Technology, 2020, 166: 111204.

[6] KOZŁOWSKI M, GÓRECKI P, SZCZYPINSKI P M. Varietal classification of barley by convolutional neural networks[J]. Biosystems Engineering, 2019, 184: 155-165.

[7] NASIRI A, TAHERI-GARAVAND A, ZHANG Yu-dong. Image-based deep learning automated sorting of date fruit[J]. Postharvest Biology and Technology, 2019, 153: 133-141.

[8] 龚中良,杨张鹏,梁力.基于机器视觉的柑橘表面缺陷检测[J].江苏农业科学,2019,47(7):236-239.
GONG Zhong-liang, YANG Zhang-peng, LIANG li. Detection of citrus surface defects based on machine vision[J]. Jiangsu Agricultural Sciences, 2019, 47(7): 236-239.

[9] 王鑫,赵莹,杨简.基于视觉技术的苹果分拣系统设计[J].中国农机化学报,2014,35(5):169-172.
WANG Xin, ZHAO Ying, YANG Jian. Design of fruits sorting system based on vision technology[J]. Journal of Chinese Agricultural Mechanization, 2014, 35(5): 169-172.

[10] 孙宝霞,汤林越,何志良,等.基于机器视觉的采后荔枝表皮微损伤实时检测[J].农业机械学报,2016,47(7):35-41.
SUN Bao-xia, TANG Lin-yue, HE Zhi-liang, et al. Real-time detection of micro-damage on peel of postharvest Litchi based on machine vision[J]. Transactions of the Chinese Society for Agricultural Machinery, 2016, 47(7): 35-41.

[11] 任锐,张淑娟,赵华民.基于机器视觉的辣椒外部品质检测[J].食品与机械,2021,37(1):165-168.
REN Rui, ZHANG Shu-juan, ZHAO Hua-min. study on external quality detection of pepper based on machine vision[J]. Food & Machinery, 2021, 37(1): 165-168.

[12] 刘鸿飞,黄敏敏,赵旭东,等.基于机器视觉的温室番茄裂果检测[J].农业工程学报,2018,34(16):170-176.
LIU Hong-fei, HUANG Min-min, ZHAO Xu-dong, et al. Detection of cracking tomato based on machine vision in greenhouse[J]. Transactions of the Chinese Society of Agricultural Engineering, 2018, 34(16): 170-176.

[13] 高震宇,王安,刘勇,等.基于卷积神经网络的鲜茶叶智能分选系统研究[J].农业机械学报,2017,48(7):53-58.
GAO Zhen-yu, WANG An, LIU Yong, et al. Intelligent fresh-tea-leaves sorting research based on convolution neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(7): 53-58.

(下转第 185 页)

构特性和感官风味俱佳。后续可进一步根据超微绿茶粉的高膳食纤维和抗氧化性对绿茶面条的保健功能进行探究,以期为全值化利用绿茶及开发高端面条提供科学依据。

参考文献

- [1] GUO S, KUMAR A M, WANG Yue-fei, et al. Current understanding in conversion and application of tea waste biomass: A review[J]. Bioresource Technology, 2021, 338: 125530.
 - [2] LU Xin-shan, ZHAO Yan, SUN Yan-fei, et al. Characterisation of polysaccharides from green tea of Huangshan Maofeng with antioxidant and hepatoprotective effects[J]. Food Chemistry, 2013, 141(4): 3 415-3 423.
 - [3] SUN Yue, WANG Yu-wan, SONG Peng-peng, et al. Anti-obesity effects of instant fermented teas in vitro and in mice with high-fat-diet-induced obesity[J]. Food & Function, 2019, 10(6): 3 502-3 513.
 - [4] ZHAO Li-na, WANG Shao-yun, HUANG Yi-fan. Antioxidant function of tea dregs protein hydrolysates in liposome-meat system and its possible action mechanism[J]. International Journal of Food Science & Technology, 2014, 49(10): 2 299-2 306.
 - [5] LIANG Ying, QU Zhuo-ting, LIU Mei, et al. Further interpretation of the strengthening effect of curdlan on frozen cooked noodles quality during frozen storage: Studies on water state and properties[J]. Food Chemistry, 2021, 346: 128908.
 - [6] 管馨馨, 董伟峰, 李慧娟, 等. 绿茶色素提取及其稳定性研究[J]. 食品工业, 2017, 38(2): 100-102.
 - GUAN Qing-xin, DONG Wei-feng, LI Hui-juan, et al. Extraction and stability of pigment from green tea[J]. Food Industry, 2017, 38(2): 100-102.
 - [7] 徐国良. 绿茶生鲜面的品质调控研究[J]. 食品研究与开发, 2014, 35(8): 19-22.
 - XU Guo-liang. Studies on quality control of superfine green tea powder fresh noodles[J]. Food Research and Development, 2014, 35(8): 19-22.
 - [8] 张家辉, 李曼, 朱科学, 等. 超微绿茶粉生鲜面的研制及特性研究[J]. 食品工业科技, 2011, 32(9): 164-166.
 - ZHANG Jia-hui, LI Man, ZHU Ke-xue, et al. Study on the preparation and properties of superfine green tea powder fresh noodles[J]. Science and Technology of Food Industry, 2011, 32(9): 164-166.
 - [9] 秦琴, 王禹峰. 超细粉体制备工艺的研究现状[J]. 热加工工艺, 2018, 47(4): 47-50.
 - QIN Qin, WANG Yu-feng. Research status of preparation technology of ultrafine powder[J]. Hot Working Technology, 2018, 47(4): 47-50.
 - [10] 唐璇, 李东, 雷雨, 等. 抹茶超微粉碎技术研究进展[J]. 食品工业, 2021, 42(8): 222-226.
 - TANG Xuan, LI Dong, LEI Yu, et al. Research progress of matcha ultrafine pulverization technology[J]. Food Industry, 2021, 42(8): 222-226.
 - [11] 陈梦诗, 蔡茜茜, 赵立娜, 等. 微粉化处理对绿茶物理特性及抗氧化性的影响[J]. 中国食品学报, 2018, 18(11): 126-132.
 - CHEN Meng-shi, CAI Xi-xi, ZHAO Li-na, et al. Effect of superfine green tea powder on physical characteristics and antioxidant activity[J]. Journal of Chinese Institute of Food Science and Technology, 2018, 18(11): 126-132.
 - [12] 袁地顺. 超细微茶粉在面条上的应用研究[J]. 福建茶叶, 2003(1): 10-11.
 - YUAN Di-shun. Study on the application of superfine tea powder in noodles[J]. Fujian Chaye, 2003(1): 10-11.
 - [13] 于克学, 孙建霞, 白卫滨, 等. 超微茶粉面条的研制[J]. 食品科技, 2008(6): 121-123.
 - YU Ke-xue, SUN Jian-xia, BAI Wei-bin, et al. Study on ultramicrosome green tea powder noodle [J]. Food Science and Technology, 2008(6): 121-123.
 - [14] 韦玲冬, 易霞, 邹溪, 等. 绿茶面条的制作及其微观结构与茶多酚含量的变化[J]. 贵州农业科学, 2020, 48(10): 135-139.
 - WEI Xue-ling, YI Xia, ZHOU Xi, et al. Preparation, microstructure and tea polyphenols content variation of green tea noodles [J]. Guizhou Agricultural Sciences, 2020, 48(10): 135-139.
 - [15] HONG Ting-ting, MA Yue, YUAN Yi-rong, et al. Understanding the influence of pullulan on the quality changes, water mobility, structural properties and thermal properties of frozen cooked noodles[J]. Food Chemistry, 2021, 365: 130512.
-
- (上接第 138 页)
- [14] 汪天宇, 曹成茂, 谢承健, 等. 基于模糊聚类算法的山核桃壳仁分选系统设计[J]. 食品与机械, 2018, 34(6): 110-114, 157.
 - WANG Tian-yu, CAO Cheng-mao, XIE Cheng-jian, et al. Design of hickory nuts shell and kernel sorting system based on fuzzy clustering algorithm[J]. Food & Machinery, 2018, 34(6): 110-114, 157.
 - [15] 杨明欣, 张耀光, 刘涛. 基于卷积神经网络的玉米病害小样本识别研究[J]. 中国生态农业学报, 2020, 28(12): 1 924-1 931.
 - YANG Ming-xin, ZHANG Yao-guang, LIU Tao. Corn disease recognition based on the Convolutional Neural Network with a small sampling size[J]. Chinese Journal of Eco-Agriculture, 2020, 28(12): 1 924-1 931.
 - [16] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7 553): 436.
 - [17] GHAZI M M, YANIKOGLU B, APTOULA E. Plant identification using deep neural networks via optimization of transfer learning parameters[J]. Neurocomputing, 2017, 235: 228-235.
 - [18] INKYU S, ZONGYUAN G, FERAS D, et al. Deep fruits: A fruit detection system using deep neural networks[J]. Sensors, 2016, 16(8): 1 222.
 - [19] DYRMANN M, KARSTOFT H, MIDTIBY H S. Plant species classification using deep convolutional neural network[J]. Biosystems Engineering, 2016, 151: 72-80.
 - [20] IOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[C]// International Conference on Machine Learning. [S.l.]: PMLR, 2015: 448-456.