

计算机视觉结合深度学习技术快速鉴别八角粉掺伪

The application of computer vision combining with deep learning techniques for rapid discrimination of adulterated star anise powder

陈劲星

CHEN Jinxing

(福建中检华日食品安全检测有限公司,福建 福州 350008)

(Fujian CCIC-Fairreach Food Safety Testing Co., Ltd., Fuzhou, Fujian 350008, China)

摘要:目的:设计一种基于计算机视觉技术结合深度学习模型的新方法检测八角粉的掺假情况。**方法:**采集不同掺假比例八角粉的原始图像,利用预处理和数据增强技术获得图像集合。随后构建 SqueezeNet 深度学习模型,并与支持向量机(support vector machine, SVM)、K-邻近学习(K-nearest neighbor learning, KNN)、随机森林(random forest, RF)、梯度提升树(gradient boosting tree, GBT)和多层感知器(multilayer perceptron, MLP)5 种机器学习模型进行比较。**结果:**5 种机器学习模型的最高准确度仅为 66.37%,而 SqueezeNet 模型的准确度为 99.42%。**结论:**深度学习分类模型性能相较于传统机器学习分类模型更为优越,识别效果良好且样品无需预处理。

关键词:八角;掺伪鉴别;深度学习;视觉技术;SqueezeNet 模型

Abstract: Objective: This study aims to design a novel approach, utilizing computer vision combining with deep learning, for rapid determination the adulteration in star anise powder. **Methods:** Collected the original images of star anise powder with varying adulteration ratios. Employing preprocessing and data enhancement techniques, an image dataset was curated. Subsequently, a SqueezeNet model was constructed and compared with five machine learning models, including Support Vector Machine (SVM), K-Nearest Neighbor Learning (KNN), Random Forest (RF), Gradient Boosting Tree (GBT), and Multilayer Perceptron (MLP). **Results:** The highest accuracy achieved by the five machine learning models was only 66.37%,

while the accuracy of the SqueezeNet model was 99.42%. The results showed that SqueezeNet model was better than these machine learning models in identifying the adulteration in star anise powder. **Conclusion:** The proposed detection method based on computer vision combining with SqueezeNet model can effectively identify the adulteration in star anise powder. This method is easy to operate, and provides a novel technique for the rapid detection of food adulteration.

Keywords: star anise powder; adulteration identification; deep learning; visual technology; SqueezeNet model

八角属于五味子科,其果实呈八角星状,盛产于越南东部和中国西南部,被用于多种烹饪过程以改善食材风味。八角所含的莽草酸具有良好的抗病毒作用,是生产抗甲型和乙型流感药物奥司他韦的重要前体物质^[1-2]。此外,八角还拥有多种具备生物活性的化合物,具有抗菌、抗氧化、杀虫、消炎和祛痰等功效^[3-4]。

目前,针对八角果实掺假的问题已有报道,如 Vermaak 等^[5]采用短波红外高光谱成像技术结合化学计量学方法,识别中国八角中含有神经毒性化合物的日本八角,获取了 920~2 514 nm 范围光谱建立偏最小二乘判别分析(partial least squares discriminant analysis, PLS-DA)模型,该模型对日本八角和中国八角的识别率分别达到 98.42% 和 97.85%,表明短波红外高光谱成像可有效识别八角果实质量;Zhang 等^[6]开发了一种基于 DNA 条形码方式检测八角等多种香辛料掺假,通过对比纯样品与检测物的 ITS2 和 psbA-trnH 序列的差异性可有效鉴别八角及多种香辛料掺假;Shen 等^[7]通过电离与轨道阱高分辨率质谱检测八角果实和凉茶饮品掺假,该方法无需预处理任何样品即可于短时间内检测八角果实和凉茶饮品中存在的茴香苷,并可检测掺假率低于 1% 的凉茶

作者简介:陈劲星(1977—),男,福建中检华日食品安全检测有限公司高级工程师,硕士。

E-mail: chenjx@fairreach.com

收稿日期:2023-09-16 **改回日期:**2023-11-14

饮品;Joshi 等^[8]采用荧光显微镜和气相色谱法联用检测八角果实掺假;Lu 等^[9]基于 400~1 000 nm 波长范围近红外高光谱数据,结合连续投影算法(successive project algorithm,SPA)构建 PLS-DA 模型和支持向量机评估模型识别中国八角和日本八角,结果表明 SPA-PLS-DA 模型在样本交叉验证集的最高识别效果为 98.44%。但上述研究皆需昂贵仪器设备和专业人员进行操作,且样品分析时间较久,无法实现快速检测,难以推广至实际应用领域。当前常用检测方法仍以采用人工方式通过颜色、味道和气味等感官特征进行质量评估^[10],不同人对相关特性的评估标准不同,评估过程具有较强主观性和不稳定性,致使评估结果之间具有显著差异,所得评估结果可靠性低。

自 AlexNet 网络结构出现后,卷积神经网络作为典型的深度学习方法被广泛用于语义分割、图片分类和目标检测等领域,并有效促进农业、遥感、水文和医药等行业的发展^[11~14]。高性能卷积神经网络模型由于网络分析处理效率低下大大限制其发展^[15],而轻量级卷积神经网络结构的设想推陈出新。轻量级卷积神经网络结构的构建关键是削减网络参数数量和维持网络原有性能,以减少模型所需的内存要求并显著提升模型的预测效率,降低移动端部署难度,这种网络结构可有效缓解模型对储存设备条件依赖程度高和预测速度慢的问题^[16~18]。SqueezeNet^[11]、MobileNe^[19]、ShuffleNe^[20] 和 Xception^[21] 等模型为现已提出的轻量级卷积神经网络结构。SqueezeNet 模型发表于 2016 年,其性能虽与传统 AlexNet 模型相似,但 SqueezeNet 模型比 AlexNet 模型具备更多优点:首先,因 SqueezeNet 模型可训练参数量更少,为 AlexNet 模型参数量的 1/50,神经网络结构内部通信量大幅降低,可有效提升网络模型分布式训练效率。其次,因 SqueezeNet 模型体量小,易于以其为基础制作相关程序用于手机等移动端上更新迭代,且此模型受相关设备条件限制较小,可部署于 FPGA 等特定条件设备^[11,22]。

研究拟利用计算机视觉系统结合深度学习算法高效快速鉴别八角粉掺假,以此减少人工鉴别误差,为今后相关食品检测提供依据。

1 材料与方法

1.1 材料

八角果:重庆万氏商贸有限公司;

谷壳:实验室自行制备。

使用研磨机充分研磨八角果实和谷壳,之后于电热恒温鼓风干燥箱中 70 ℃烘干,除去多余水分,然后把烘干样品粉末过 60 目筛,放置备用。选取纯八角粉作为掺假率为 0% 的原始样品,以谷壳粉对纯八角粉进行掺假,

比例为 10%, 20%, 30%, 40%, 50%, 并用震荡混匀器混匀。

1.2 图像采集

试验图像拍摄系统由佳能 600D 相机、计算机、摄影支架、拍摄台、LED 照明灯和简易摄影棚等设备构成,将佳能 600D 相机放置于载物台上方 22 cm 处与摄影支架相连,并选取白色背景作为图像背景。图像拍摄系统如图 1(a)所示,将两个稳定光源亮度的 LED 照明灯放置于摄影棚内、载物台左右两侧顶部,以稳定摄影棚中载物台周围拍摄环境的光源强度,减少因外部光源条件产生变化而影响样品图像质量。拍摄参数设置:焦距为 24 mm、光圈为 F 22、快门速度为 1/30 s, 感光度为 ISO 400, 图像像素尺寸设置为 3 450 × 3 450, 每一份样品拍摄 120 张图像。

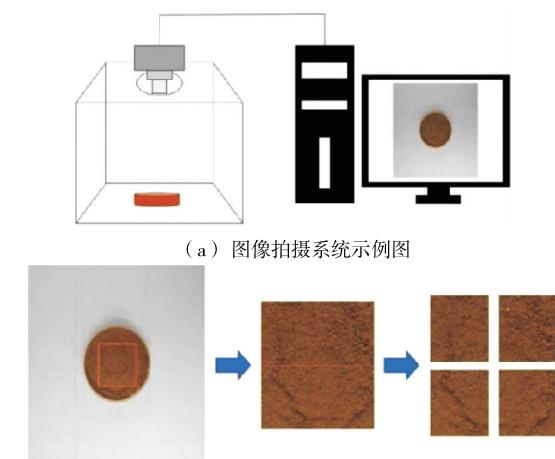


Figure 1 Sample collection and image preprocessing

1.3 图像预处理

首先对图像中部 600 像素 × 600 像素的正方形区域进行裁剪,之后将裁剪图像平均分割成 4 张互不重叠且相互独立的 300 像素 × 300 像素图像,每类样本图像数量达到 480 张($120 \times 4 = 480$),最后为匹配后续试验所用卷积神经网络模型预设输入通道尺寸,所有样本图像像素尺寸修改为 227 × 227。背景去除操作流程如图 1(b)所示,此方法可有效提升参与建模的图像数量,减少卷积神经网络中可训练参数量,加快网络分析和图像处理速度,并降低卷积神经网络训练过程的过拟合情况,缩短非必要训练迭代时间。

1.4 数据增强

深度学习模型需一定规模数据量才可使其网络参数按常规方式运行,且数据样本越充足模型训练效果越良好^[23],采用旋转、镜像、位移、缩放、随机裁剪、添加噪声、颜色变换、擦除和填充等可成倍数式扩充图像数量的数

据增强方法,以弥补原始数据不足的缺陷^[24]。试验选取在线增强功能中的旋转和镜像方法扩充原始图像数据集,并编写程序使图像于 0~180°随机旋转及基于 x 轴和 y 轴进行随机镜像变化来增强数据。

1.5 SqueezeNet 模型

模型数据集按照 75%,15%,10% 比例将数据集划分为 2 520 张训练集图像,497 张验证集图像和 343 张测试集图像。试验选用 Matlab2020a 软件 Deep Network Designer 工具箱中 SqueezeNet 预训练网络构建分类模型。因试验采用预训练模型,需根据实际情况相应修改原始模型结构以适应新数据集。从原始 SqueezeNet 网络结构中移除参与模型分类的卷积层及分类输出层,再从画布中添加原始卷积层和分类输出层以替代已移除的结构层,并对新卷积层的各项参数重新赋值^[25]。滤波器尺寸参数变更为 1×1,stride 参数变更为 1,padding 参数变更为 same,滤波器数量变更为 6 或 7,以匹配实际参与谷壳粉掺假识别建模的类别数量。WeightLearnRateFactor 和 BiasLearnRateFactor 参数变更为 10,以减少模型训练的收敛时间并改善识别性能。最后,修改训练参数:Adam 优化算法作为优化器,categorical_crossentropy 函数作为损失函数,Mini-batchsize 调整为 32,LearnRate 参数设置为 0.000 1。

1.6 机器学习分类模型构建

为更好评估深度学习分类模型的识别性能,用 Python 编程语言提取图像特征并建模分类,与深度学习分类模型结果比较。以局部二值模式 (local binary patterns,LBP) 和方向梯度直方图 (histogram of oriented gradient,HOG) 算法提取原始图像数据集的图像特征。LBP 是将检测窗口中心像素设定为阈值,并与周围多个像素的灰度值进行对比,若检测窗口周围像素的灰度值小于中心像素所设阈值,则此像素点位置被赋值为 0,反之为 1。以局部二值模式算法提取图像特征可得到八位二进制数,再将所得八位二进制数变更为十进制数,最后可获得 256 种局部二值模式特征值作为中心像素点特征^[26]。HOG 是通过计算图像局部范围的梯度方向,并将所得图像梯度直方图作为图像特征描述子的特征提取算法。提取图像特征的步骤为:在图像预处理后分别从 x 轴和 y 轴方向计算梯度,再计算梯度的幅值和方向得到

新图像的梯度图,对相关特征信息进行 Block 归一化操作。最后,计算整张图像的特征向量^[27]。选取 Python 编程语言中 sikit-learn 库的支持向量机 (support vector machine,SVM)、K-邻近学习 (K-nearest neighbor learning,KNN)、随机森林 (random forest,RF)、梯度提升树 (gradient boosting tree,GBT) 和多层感知器 (multilayer perceptron,MLP) 等多种机器学习分类算法对所提特征信息建模分类。

2 结果与分析

2.1 样品采集图像

采用谷壳粉作为模型掺假物质。采集 7 类样品的图像,每一类样品各 120 张图像,同时每个图像经过预处理分割成 4 份,每类样品数据集包含 480 张图像,7 类共计 3 360 张图像构成八角粉掺假数据集。从图 2 可以看出,纯八角粉和谷壳粉颜色差异明显,八角粉呈棕褐色,谷物粉呈淡黄色,但 10%,20%,30%,40%,50% 掺假比例八角粉的颜色、纹理和质地之间差异性较小,不易区分。

2.2 机器学习模型结果

试验随机选取原始数据集中 80% 图像作为训练集 (2 688 张图像),20% 图像作为测试集 (672 张图像),用以训练和评估传统机器学习分类模型性能。主成分分析 (principal components analysis,PCA) 是一种常见的数据降维技术,其可将高维数据通过降维算法转化为低维数据,可视化数据空间分布,改善数据处理效率,降低分析所需时间和成本。运用 LBP 和 HOG 方式提取八角粉掺假图像特征的 PCA 降维可视化投影图。如图 3 所示,两种不同特征提取方式所提不同类别图像特征未有显著差异,且空间分布无明显区别。

表 1 为基于 LBP 和 HOG 方式提取图像特征构建的 SVM、KNN、RF、GBT 和 MLP 分类算法的预测结果。从表 1 可以看出,基于 LBP 方式提取图像特征构建的 SVM、KNN、RF、GBT 和 MLP 分类算法的预测准确度分别为 55.36%,55.95%,66.37%,60.71%,54.91%,基于 HOG 方式提取图像特征构建的 SVM、KNN、RF、GBT 和 MLP 分类算法的预测准确度分别为 35.27%,15.03%,13.99%,18.30%,21.58%,基于 LBP 方法提取图像特征所建立的分类算法结果显著优于 HOG 方法,基于 LBP 结合 RF 分类器模型所得预测准确率达到最高,为



图 2 八角粉掺假不同比例谷壳粉样品原始图像

Figure 2 Original images of different proportions of corn powder adulteration in star anise powder

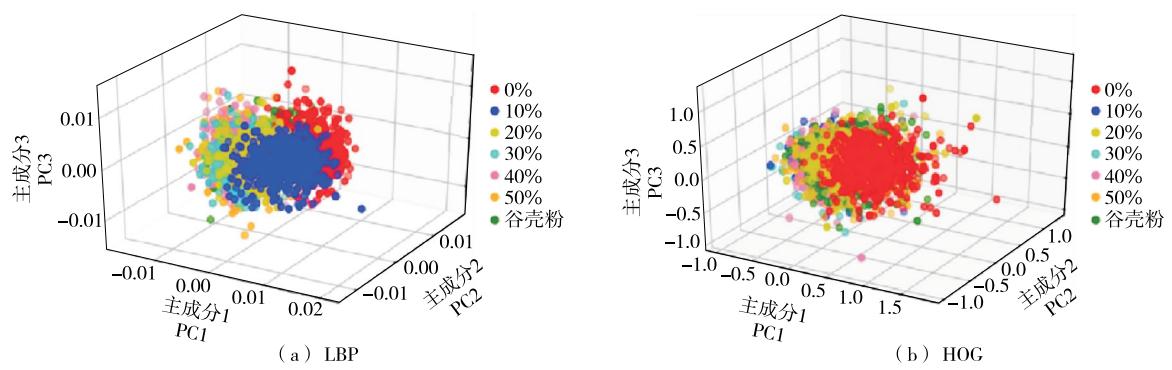


图 3 不同特征提取方式下 PCA 投影图

Figure 3 PCA projection by different feature extraction methods

66.37%。为进一步比较基于 LBP 方法建立的分类模型对不同比例掺假样品的鉴别结果,以模型预测结果为横坐标,图像真实类别为纵坐标,绘制混淆矩阵图。图 4 是基于 LBP 方式提取图像特征构建的 5 种分类器的混淆矩阵图。由图 4 可知,5 种模型均可正确识别其类别多数图像,其中 5 种模型对八角粉和纯谷壳粉样品都能够准确鉴别,但随着掺假比例从 0% 不断增加,正确鉴别的样品数先下降然后逐渐上升,其可能原因是低浓度掺假比例样品区分度不高,随着掺假比例上升,样品区分度逐渐加强。但 5 种模型对 20%,30%,40% 掺假比例样品存在较多样品的误判,上述误判结果的出现,考虑包含两个方面因素:一是因拍摄过程中,图像少数部分亮度环境发生

表 1 不同机器学习模型对掺假八角粉的鉴别结果

Table 1 Discrimination results of adulterated star aniseed powder by different machine learning models

模型	准确度/%	
	HOG	LBP
SVM	35.27	55.36
KNN	15.03	55.95
RF	13.99	66.37
GBT	18.30	60.71
MLP	21.58	54.91

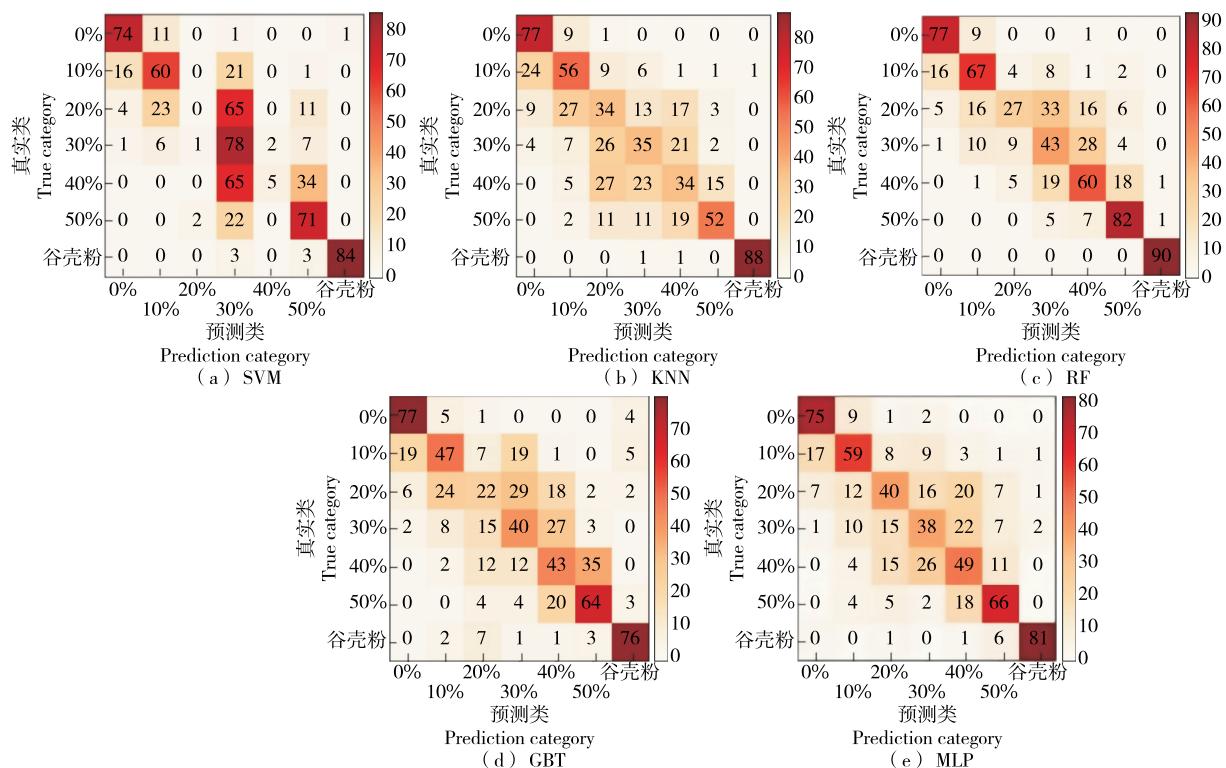


图 4 基于 LBP 构建的 5 种分类器的混淆矩阵图

Figure 4 Confusion matrix of five classifiers by LBP

变化及被误判图像与误判类别图像之间颜色和纹理等特征具有较高相似度,致使图像被错误分类。二是所用两种传统特征提取方式仅可提取浅层次的低级图像特征,较难获取深层次的高级图像特征,难以通过单一低级特征表示图像具体信息,导致分类器整体分类结果欠佳,无法正确鉴别八角粉中谷壳粉掺假图像。

2.3 SqueezeNet 模型结果

图 5 显示八角粉掺假识别模型的损失函数曲线和准确度曲线图。由图 5(a)可知,前 200 次迭代周期内,模型的训练损失值和验证损失值迅速降低,损失函数曲线快速收敛。经 300~400 次迭代,损失函数曲线收敛速度减缓,且收敛趋于稳定。经 780 次迭代后,模型的训练损失值降为 0.014 7,验证损失值降为 0.005 0。模型训练过程

中,验证集损失函数曲线与训练集损失函数曲线拟合情况良好,二值损失率相似且曲线变化趋势相近,模型无明显过拟合。曲线经 150 次迭代后逐渐收敛,损失值浮动明显,并在第 500 次迭代时训练损失值达到 0.538 4,异常训练损失值的出现考虑是因 Mini-batch 参数设置不佳,致使曲线收敛过程出现明显浮动并出现异常值。图 5(b)为准确度随迭代次数变化图,经 200 次训练迭代后,模型的验证识别效果较为稳定,而训练识别结果变幅较大且出现准确率为 84.38% 的异常值,考虑是因学习率所设参数值较大,导致模型结构过于复杂,致使训练集识别效果下降。在经 780 次迭代后,模型最终训练准确率为 100.00%,验证准确率为 100.00%,说明模型可以有效识别八角粉掺假。

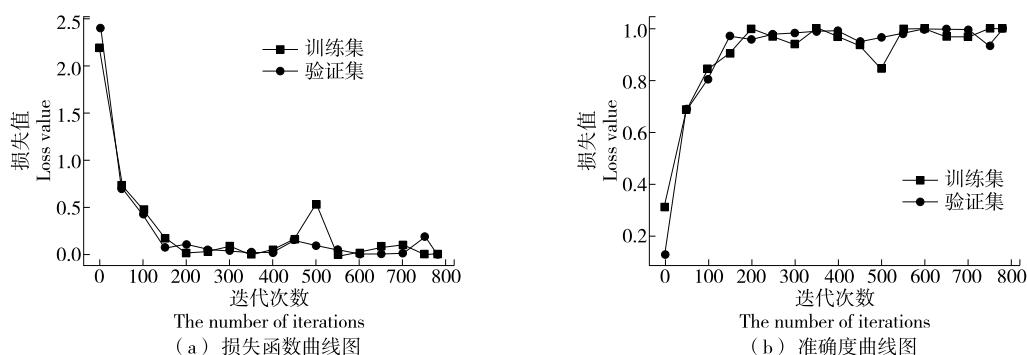


图 5 SqueezeNet 模型的建模过程
Figure 5 Modeling process by SqueezeNet model

图 6(a)是采用测试集评估模型实际识别效果所得混淆矩阵图,其中,“20%”类别有 1 个图像样本被错误预测为“10%”类别,“40%”类别有 1 个图像样本被错误预测为“50%”类别,模型测试集准确率达到 99.42%。通过结果可知,模型测试识别效果稳定,测试集中仅有 2 张图像被错误识别为其他类别图像,考虑是因在图像拍摄过程中八角粉样品表面部分亮度光线反射不均,表面亮度产生变化且图像颜色质地等特性较为相似导致图像被误判。

由图 6(b)可知,与机器学习相比,深度学习模型准确率达到 99.42%,而传统机器学习方法的准确率不高,深度学习模型所得预测结果优于传统机器学习方法。其可能原因是 SqueezeNet 选用 1×1 尺寸卷积核,网络结构的原始参数量大大缩减,有效提升模型训练效率并缩短训练时长,且 SqueezeNet 模型采用延缓正常模型结构中欠采样步骤的方法,确保含有更多相关特征信息的激活图可供予至后续卷积层中,使模型也可训练参数量较少的训

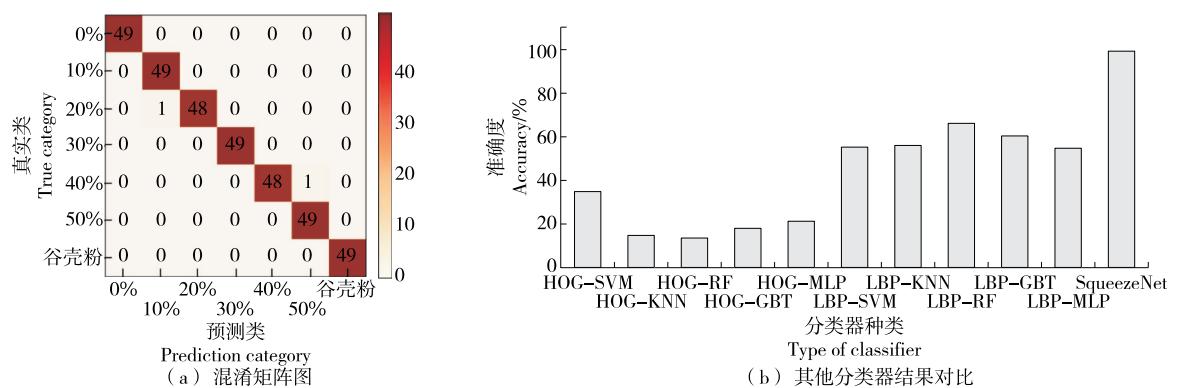


图 6 SqueezeNet 模型的鉴别结果

Figure 6 Discrimination results of the SqueezeNet model

练环境中取得良好结果^[1]。

3 结论

研究设计一种采用计算机视觉技术结合深度学习检测八角粉掺假的新方法。先采集不同掺假比例八角粉样品图像,通过图像预处理和数据增强技术获得所需图像集合,构建 SqueezeNet 模型,并与 5 种机器学习模型进行比较。结果表明,采用局部二值模式和方向梯度直方图两种特征提取方式结合支持向量机、K-邻近学习、随机森林、梯度提升树和多层感知器 5 种机器学习方法建模,模型的最高准确度仅为 66.37%,而 SqueezeNet 深度学习模型的准确度为 99.42%。深度学习分类模型性能相较于传统机器学习分类模型更为优越,识别效果良好且样品无需预处理。研究提出的计算机视觉技术结合深度学习的检测方法,在推广应用中的关键点为采集环境的影响可能使样品图像与实际样品产生部分差异,进而影响识别结果。此外,研究采用的是典型掺假物和单一品种的样品,使得样本种类不足,致使所建模型在后续推广中还需要完善。

参考文献

- [1] MUHSINAH A B, MAQBUL M S, MAHNASHI M H, et al. Antibacterial activity of *Illicium verum* essential oil against MRSA clinical isolates and determination of its phyto-chemical components[J]. *J King Saud Univ Sci*, 2022, 34: 101800.
- [2] GAVAHIAN M, CHU Y, LORENZO J, et al. Essential oils as natural preservatives for bakery products: Understanding the mechanisms of action, recent findings, and applications[J]. *Crit Rev Food Sci Nutr*, 2020, 60(2): 310-321.
- [3] PATRA J K, DAS G, BOSE S, et al. Star anise (*Illicium verum*): Chemical compounds, antiviral properties, and clinical relevance[J]. *Phytother Res*, 2020, 34(6): 1 248-1 267.
- [4] EL-SAYED S M, YOUSSEF A M. Potential application of herbs and spices and their effects in functional dairy products[J]. *Heliyon*, 2019, 5(6): 1 989.
- [5] VERMAAK I, VILJOEN A, LINDSTRÖM S W. Hyperspectral imaging in the quality control of herbal medicines: The case of neurotoxic Japanese star anise[J]. *J Pharm Biomed Anal*, 2013, 75: 207-213.
- [6] ZHANG M T, SHI Y H, SUN W, et al. An efficient DNA barcoding based method for the authentication and adulteration detection of the powdered natural spices[J]. *Food Control*, 2019, 106: 106745.
- [7] SHEN Y, VAN BEEK T A, CLAASSEN F W, et al. Rapid control of Chinese star anise fruits and teas for neurotoxic anisatin by direct analysis in real time high resolution mass spectrometry [J]. *J Chromatogr A*, 2012, 1 259: 179-186.
- [8] JOSHI V C, SRINIVAS P V, KHAN I A. Rapid and easy identification of *Illicium verum* Hook. f. and its adulterant *Illicium anisatum* Linn. by fluorescent microscopy and gas chromatography [J]. *J AOAC Int*, 2005, 88(3): 703-706.
- [9] LU Y, WANG W, NI X Z, et al. Non-destructive discrimination of *Illicium verum* from poisonous adulterant using Vis/NIR hyperspectral imaging combined with chemometrics [J]. *Infrared Phys Technol*, 2020, 111: 103509.
- [10] 高海生. 味精及香辛料掺假的鉴别检验(下)[J]. 物流工程与管理, 1995, 17(6): 29-30.
- [11] GAO H S. Identification test of adulteration of monosodium glutamate and spices (II) [J]. *Logistics Eng Manag*, 1995, 17(6): 29-30.
- [12] GOUTAM K S, SANTOS K D, POONAM S. A deep learning-based distracted driving detection solution implemented on embedded system[J]. *Multimedia Tools and Applications*, 2023, 82(8): 11 697-11 720.
- [13] WU X J, ZHAO Z L, TIAN R L, et al. Total synchronous fluorescence spectroscopy coupled with deep learning to rapidly identify the authenticity of sesame oil[J]. *Spectrochim Acta, Part A*, 2020, 244: 118841.
- [14] JAHANBAKHSI A, MOMENY M, MAHMOUDI M, et al. Classification of sour lemons based on apparent defects using stochastic pooling mechanism in deep convolutional neural networks[J]. *Sci Hortic*, 2020, 263: 109133.
- [15] ARORA M, MANGIPUDI P, DUTTA M K. Deep learning neural networks for acrylamide identification in potato chips using transfer learning approach[J]. *J Ambient Intell Hum Comput*, 2021, 12(12): 10 601-10 614.
- [16] 夏亮. 基于轻量级卷积神经网络的人脸检测研究[D]. 广州: 广州大学, 2023: 2-7.
- [17] XIA L. Research on face detection based on lightweight convolutional neural networks [D]. Guangzhou: Guangzhou University, 2023: 2-7.
- [18] DENG L M, LI J, HAN Z Z. Online defect detection and automatic grading of carrots using computer vision combined with deep learning methods [J]. *LWT-Food Sci Technol*, 2021, 149(2): 111832.
- [19] MESA A R, CHIANG J Y. Multi-input deep learning model with RGB and hyperspectral imaging for banana grading [J]. *Agriculture*, 2021, 11(8): 687.
- [20] MOINO M J. Plum ripeness analysis in real environments using deep learning with convolutional neural networks[J]. *Agronomy*, 2021, 11(11): 2 353.
- [21] ASHWINKUMAR S, RAJAGOPAL S, MANIMARAN V, et al. Automated plant leaf disease detection and classification using optimal MobileNet based convolutional neural networks[J]. *Mater Today: Proc*, 2022, 51: 480-487.
- [22] GANGOPADHYAY R, KULKARNI P T, BONONI A. Throughput performance of multiwavelength shufflenet with/without wavelength conversion[J]. *J Opt Commun*, 2003, 24(3): 42-49.

(下转第 69 页)

- ZHU H, WANG L X. Research on safety issues, regulatory difficulties and countermeasures of webcast food[J]. Food Safety Guide, 2022(21): 14-17, 21.
- [12] 邹俊芳. 我国农产品网络销售的监管问题研究[D]. 沈阳: 沈阳工业大学, 2022: 1-20.
- ZOU J F. Research on the supervision of online sales of agricultural products in China[D]. Shenyang: Shenyang University of Technology, 2022: 1-20.
- [13] 费威, 王阔. 直播电商下品牌商与主播的食品安全动态策略分析[J]. 宏观质量研究, 2023, 11(1): 87-98.
- FEI W, WANG K. Analysis of food safety dynamic strategy of brand owners and anchors under live streaming e-commerce [J]. Macro Quality Research, 2023, 11(1): 87-98.
- [14] 史彦泽, 费威, 王阔. 直播电商背景下消费者食品购买意愿影响因素分析[J]. 经济与管理, 2022, 36(6): 77-83.
- SHI Y Z, FEI W, WANG K. Analysis of influencing factors of consumers' food purchase intention under the background of live streaming e-commerce[J]. Economics and Management, 2022, 36 (6): 77-83.
- [15] 徐博. 电商直播中我国食品虚假宣传监管现状与对策建议[J]. 食品科学技术学报, 2021, 39(6): 22-27.
- XU B. Current situation and countermeasures of food false propaganda supervision in China in e-commerce live broadcast[J]. Journal of Food Science and Technology, 2021, 39(6): 22-27.
- [16] 时延安, 郑平心. 网络直播中违法营销食品的刑法问题[J]. 公安学研究, 2022, 5(3): 20-31, 123.
- SHI Y A, ZHENG P X. Criminal law issues of illegal marketing of food in online live broadcasting[J]. Public Security Research, 2022, 5(3): 20-31, 123.
- [17] 刘惠明, 王玉琪. 直播销售模式下农产品质量安全问题及法律规制探究[J]. 食品安全质量检测学报, 2021, 12(8): 3 387-3 391.
- LIU H M, WANG Y Q. Exploration on quality safety and legal regulation of agricultural products under live broadcast sales mode [J]. Journal of Food Safety and Quality Testing, 2021, 12 (8): 3 387-3 391.
- [18] 中国消费者协会. 中消协发布《中国消费者权益保护状况年度报告(2021)》指出: 党的十八大以来我国消费者保护工作取得新的突破性成就 [EB/OL]. (2020-04-22) [2023-06-11]. <https://cca.org.cn/zxsd/detail/30413.html>.
China Consumer Association. The annual report on the protection of the rights and interests of Chinese consumers (2021) released by the China consumer association pointed out that since the 18th national congress of the communist party of China, new breakthrough achievements have been made in consumer protection in China[EB/OL]. (2020-04-22) [2023-06-11]. <https://cca.org.cn/zxsd/detail/30413.html>.
- [19] 北京阳光消费大数据研究院. 北京阳光消费大数据研究院发布 2021 年直播带货消费维权舆情分析报告 [EB/OL]. (2020-03-02) [2023-06-11]. <http://www.sun-c.cn/dynamic/372.html>.
Beijing Sunshine Consumer Big Data Research Institute. Beijing Sunshine consumer big data research institute released the public opinion analysis report on 2021 live consumption with goods[EB/OL]. (2020-03-02) [2023-06-11]. <http://www.sun-c.cn/dynamic/372.html>.
- [20] 中国消费者协会. 中消协: 行业发展势头强劲, 消费问题不容忽视, 消费者为直播电商购物新业态在线打分 [EB/OL]. (2020-03-31) [2023-07-06]. <https://cca.cn/zxsd/detail/29532.html>.
China Consumer Association. China Consumer Association: The industry has a strong development momentum, and the consumption problem cannot be ignored. Consumers give online ratings for the new format of live e-commerce shopping[EB/OL]. (2020-03-31) [2023-07-06]. <https://cca.cn/zxsd/detail/29532.html>.
- [21] 中国政府网. “直播营销”怎么管? 新规来了 [EB/OL]. (2021-04-23) [2023-07-02]. http://www.gov.cn/xinwen/2021-04/23/content_5601680.htm.
Chinese Government Website. What about "live marketing"? Here comes the new rules[EB/OL]. (2021-04-23) [2023-07-02]. http://www.gov.cn/xinwen/2021-04/23/content_5601680.htm.

(上接第 47 页)

- [21] PATEL A. Unet based xception model for prostate cancer segmentation from MRI images [J]. Multimed Tools and Appl, 2021, 12: 1-17.
- [22] PRADANA-LOPEZ S, PEREZ-CALABUIG A M, CANCILLA J C, et al. Deep transfer learning to verify quality and safety of ground coffee[J]. Food Control, 2021, 122: 107801.
- [23] IZQUIERDO M, LASTRA-MEJIAS M, GONZÁLEZ-FLORES E, et al. Visible imaging to convolutionally discern and authenticate varieties of rice and their derived flours[J]. Food Control, 2020, 110: 106971.
- [24] SUHARJIT O, ELWIREHARDJA G N, PRAYOGA J S. Oil palm fresh fruit bunch ripeness classification on mobile devices using deep learning approaches [J]. Comput Electron Agric, 2021, 188: 106185.
- [25] BERNARDO L S, DAMASEVICIUS R, DE ALBUQUERQUE V H C, et al. A hybrid two-stage squeezenet and support vector machine system for parkinson's disease detection based on handwritten spiral patterns[J]. Int J Appl Math Comput Sci, 2021, 31(4): 31.
- [26] 王文伟, 张雯. 基于局部二值模式和深度学习的人脸识别[J]. 计算机应用, 2015, 35(5): 1 474-1 478.
- WANG W W, ZHANG W. Journal of computer applications[J]. J Comput Appl, 2015, 35(5): 1 474-1 478.
- [27] ZOU B X, LIN J R. Contour extraction research of image[J]. Computer Engineering and Applications, 2008, 44(25): 161-165.