DOI: 10.13652/j.spjx.1003.5788.2023.60081

基于深度学习的发霉花生识别技术

Research on moulded peanut recognition technology based on deep learning

王伟娜1 许世维2 邓勤波3 李 博

WANG Weina¹ XU Shiwei² DENG Qinbo³ LI Bo⁴

- (1. 河南交通职业技术学院,河南 郑州 451460; 2. 西安建筑科技大学,陕西 西安 710054;
- 3. 陕西科技大学,陕西 西安 710021;4. 陕西风润智能制造研究院有限公司,陕西 西安 712000)
- (1. Henan College of Transportation, Zhengzhou, Henan 451460, China; 2. Xi'an University of Architecture and Technology, Xi'an, Shaanxi 710054, China; 3. Shaanxi University of Science & Technology, Xi'an, Shaanxi 710021, China; 4. Shaanxi Fengrun Intelligent Manufacturing

Research Institute Co., Ltd., Xi'an, Shaanxi 712000, China)

摘要:目的:快速、无损地识别发霉花生,提高发霉花生的识别效率。方法:采用光谱仪采集高光谱花生数据,利用深度学习技术识别霉变花生,建立 Hypernet PRMF 模型,并以 Deeplab v3+、Segnet、Unet 和 Hypernet 作为对照模型进行比较。将所提出的花生识别指数融合到高光谱图像中,作为数据特征预提取。同时将构建的多特征融合块集成到控制模型中以提高发霉花生识别效率。结果:所有模型的平均像素精度均超过了 87%。Hypernet-PRMF 模型的检测精度最高,达到 90.35%,同时对于整个花生数据集,Hypernet-PRMF 的错误识别率较低,可以有效识别图中所有的发霉花生。结论:基于深度学习所建立的 Hypernet-PRMF 模型具有较高的像素精度与检测精度,可有效识别发霉花生。

关键词:深度学习;花生;霉变;识别;多特征块

Abstract: Objective: To identify mouldy peanuts in a fast and non-destructive way and improve the identification efficiency. **Methods:** Collected hyperspectral peanut data using a spectrometer, identify moldy peanuts using deep learning technology, and established a Hypernet PRMF model, which was compared with Deeplab v3+, Segnet, Unet, and Hypernet as control models. Integrated the proposed peanut recognition index into hyperspectral images as data feature pre extraction. Simultaneously integrating the constructed multi feature fusion

blocks into the control model to improve the recognition efficiency of moldy peanuts. **Results:** The average pixel accuracy of all models exceeded 87%. the Hypernet-PRMF model had the highest detection accuracy of 90.35%, while for the whole peanut dataset, Hypernet-PRMF had a low false recognition rate and could effectively identify all mouldy peanuts in the figure. **Conclusion:** The Hypernet-PRMF model built based on deep learning has high pixel accuracy and detection precision, which can effectively identify mouldy peanuts and provide a reference basis for the identification and detection of other mouldy food and other hyperspectral objects.

Keywords: deep learning; peanuts; mildew; identification; multiple feature blocks

花生是一种重要的食用油原料,在中国多个地区广泛种植。花生霉变后会产生黄曲霉毒素,具有很强的毒性和致畸性。在油料生产或育种中,有必要选择高品质的花生^[1]。在食品工业中,虽然可以通过磁选和气选来分离正常花生和霉变花生,但霉变花生的分离仍以人工挑选为主,存在检测效率低等问题^[2]。

作为一种快速和无损的监测工具,高光谱技术可以获得更多的光谱信息,已被应用于花生检测中。例如,王 粒^[3]应用高光谱技术对市场上的霉变花生进行检测,使 用 10 种预处理算法对其进行降噪。进一步提高霉变花 生检测效率,但操作流程复杂,耗时长。Qi 等^[4]结合高光 谱技术和联合稀疏表征来识别两种类型的花生,并与支 持向量机(SVM)进行了比较,研究结果表明该方法可以 识别发霉花生,但仍存在检测精度低。李明泽^[5]使用 SVM 在 676~952 nm 光谱范围识别梅于菜样品中的发

收稿日期:2023-03-04 改回日期:2023-07-19

基金项目:陕西省自然科学基础研究计划项目(编号:2020JQ-669);陕西省秦创原"科学家十工程师"队伍建设项目(编号:S2022-ZC-QCYK-0050)

作者简介:王伟娜(1980—),女,河南交通职业技术学院讲师,硕士。E-mail:wangweina004215@163.com

霉食品,基于 SVM 可以有效识别发霉梅干菜。但这些研究在识别决策过程中主要考虑高光谱图像中的光谱特征,未充分利用其深层空间特征。

近年来,深度学习技术已被广泛应用于食品识别领域,而食品识别通常被认为是一个图像分割或分类问题。在图像分割方面,除了全卷积网络(FCN)之外,出现了许多识别效率较高的模型,如:Deconvnet、Unet、Segnet、Deeplab^[6-8]。目前研究人员通常更关注网络结构的优化,对数据的优化相对较少。在深度学习神经网络中,特征提取结构在图像特征提取中起着重要作用。其中残差块、密集块、双路径网络以及挤压和排除块,在图像处理中也表现良好^[9]。然而,上述研究方法主要用于优化网络中的特征提取过程,缺乏对输入数据的特征优化^[10]。因此,需要构建一个多特征块用于特征提取和增强输入数据。且深度学习算法具有运算时间快,运算精度高等优势,可以极大提高霉变花生识别效率。

研究拟以花生为研究对象,探索高光谱目标识别的深度学习方法。以构建的 Unet、Segnet、Deeplab v3+和 Hypernet 作为控制模型,探索高光谱特征预提取方法在 Unet、Segnet、Deeplab v3+和 Hypernet 中的表现,并研究上述4个模型中应用多特征块的效果,比较所建模型与其他3个模型对发霉花生识别的效果,以期为实际生产提供理论和技术支持。

1 材料和方法

1.1 食品制备

从当地市场上购买普通花生和自然发霉的花生。将其分为三类(6个亚类):健康花生、霉变花生和受损花生。其中,受损的花生包括两个亚类:受损的种皮(受损 a)和部分果仁(受损 b)。霉变花生包括完全霉变的花生(霉变 a)、受损的霉变花生(霉变 b)和霉变的部分果仁(霉变 c)。健康花生和受损花生选自普通花生,霉变花生选自自然霉变花生。

采用黄曲霉毒素 B_1 快速检测试纸(胶体金免疫法)对上述 3 种花生(健康花生、霉变花生和受损花生)进行检测。霉变花生中黄曲霉毒素含量在 $20~\mu g/kg$ 以上,而其他类型的花生中则没有。因此,发霉的花生受到真菌的污染。为了防止水分对光谱特性的潜在影响,将花生在 $60~\mathbb{C}$ 的干燥机中干燥 2~h。然后将花生置于室温下并密封。

1.2 图像采集和预处理

采用 SOC710E 型便携式高光谱成像仪(上海复享光学有限公司)获取高光谱图像。FS2X 型高光谱相机(杭州彩谱科技有限公司)波长范围为 400~1 000 nm,光谱分辨率为 2.34 nm。于室内连续采集数据 30 min。在图像采集过程中。高光谱相机垂直于地面上的黑色橡胶

带。采用黑色橡胶带模拟表面结霜、反射率低的工业输送带。花生随机放置在橡胶带上,并尽可能避免相邻的花生[11]。共获得了16个花生图像,每个图像具有大约150个果仁。图像大小为1040像素×1392像素×128个波段。每个图像的左上区域包含一个灰色板区域,用于将原始数字值转换为反射率。然后,使用低通滤波器对图像进行平滑处理,以去除频谱中的噪声。

1.3 标签制作

标签包括健康、发霉、损坏。在训练数据中,带有种皮的受损 a 花生被掩盖为背景。同样,带有不完全霉变的霉变 b 和霉变 c 花生也被掩盖为背景。采用阈值分割和人工标注相结合的方法来制作标签。先选择 659,538,472 nm 3 个波长形成 RGB 颜色图像。再将彩色图像转换为灰度图像,选择适当的阈值进行阈值分割,生成原始标签图像。对分割不准确的花生进行人工标注。最终的标签图像在去除小的噪声区域后生成。

1.4 构建方法和模型

1.4.1 高光谱数据特征预提取 在高光谱数据中,部分 波段含有较多的噪声^[12]。因此可以构建一个指数来提高 不同种类发霉花生的区分度。在训练数据中用构建的指 数带代替噪声带^[13]。主要因为指数带比噪声带包含更多 有用的信息,会得到更好的识别结果,有利于迁移学习^[14]。

从图 1 可以看出,受损花生在 451 nm 附近含有光谱 反射峰,而健康花生中没有。健康花生和受损花生的光谱反射率在 781 nm 处与霉变花生的差异趋于最大。霉变花生的光谱曲线与健康花生相似,但前者的数值更低。根据以上特点,构建了花生识别指数(PRI)来区分这 3 种花生。其计算公式:

$$D_{PRI} = \frac{2.5 \times D_{p781} \times D_{p451}}{D_{p781} + D_{p451}},$$
 (1)

式中:

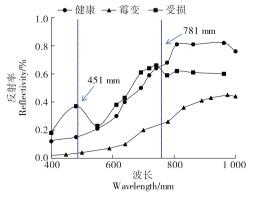


图 1 三类花生光谱曲线

Figure 1 Examples of spectral curves for three types of peanuts

D_{PRI}——花生识别指数:

 D_{781} ——781 nm 的像素值;

D_{p451}----451 nm 的像素值。

1.4.2 多特征融合块 对于霉变花生的识别,不仅可以对花生仁进行正确的分类,而且可以对霉变花生与健康花生进行准确的识别。识别结果应尽可能精确到像素。现有的图像分割模型通常通过下采样和增加卷积核的数量来实现从低级特征到高级特征的过程。这大大增加了模型的大小,导致硬件需求过大。而由单一类型的卷积核提取的图像特征往往是不够的,因此提出了多种类型的卷积核用于特征提取。为了从高光谱数据中充分提取波段信息,将多特征融合块的浅层特征提取分为4个部分。

第1部分是二维卷积,用于提取常见的食用花生纹理特征。第2部分是可分离卷积,包括深度卷积和点卷积。这种卷积的效果与常见的二维卷积接近,参数较少。这两种卷积主要用于增加卷积特征的多样性。第3部分,利用深度卷积来提取每个波段的特征^[15]。第4部分是三维卷积,用于提取光谱变化信息。这4种类型的卷积分别在批量归一化(BN)和Relu激活函数后进行串联。通过不同类型卷积的组合,可以使霉变花生的空间和光谱特征被充分提取,进一步提高识别效果。

1.4.3 Hypernet-PRMF 网络模型 Hypernet-PRMF 网络模型由 4 个部分组成:特征预提取、向下采样、向上采样、预测。特征预提取部分用于加强对不同食品花生特征的区分。下采样部分用于实现从低级特征到高级特征的过程。上采样部分用于实现从高级特征到语义信息的过程。在预测部分,分水岭分割算法被用来将像素级的结果转换成内核级的结果。

该模型采用3个下采样和3个上采样的编码器—解码器结构,并通过跳过连接将低级特征和高级特征连接起来。同时采用特征预提取和多特征融合模块。最大集合层被分离卷积所取代,以减少下采样时的信息损失,并保证参数数量不会太大。普通二维卷积、可分离卷积被用作下采样操作。普通二维卷积、可分离卷积和双线性插值被用作上采样操作。此外,还增加了两个残差块,即ASPP和Dropout,以提高网络的性能。

经过 softmax 函数,可以得到每个像素在 3 个类别 (健康、霉变、受损花生)中的预测概率[16]。预测概率最大的类别被作为最终的识别结果。像素的预测类别如式(2)所示。

$$C_{\text{pixel}} = \max(P_H, P_M, P_D), \qquad (2)$$

式中:

 C_{pixel} ——像素的预测类别;

 P_H , P_M , P_D ——健康、霉变、受损花生的像素概率。

1.5 网络分析与选择

UNET、Deeplab v3+和 Segnet 均采用编码器一解码器结构。UNET 将图像到高层语义特征的过程视为编码器,高层语义特征到像素级分类的过程视为解码器。具有对称的下采样和上采样网络,并通过 4个跳转连接来连接低层特征和高层特征。

Deeplab v3+使用了大量的可分离卷积,极大减少了计算量和参数的数量。该模型使用改进的 Xception 作为骨干。骨干网连接到 ASPP 作为编码器。解码器采用类似的方法,包括向上采样和特征层串联。

Segnet 采用了对称的 5 次上下采样结构。在编码器中,进行卷积和最大池化,并存储相应的最大池化指数。在解码器中,最大集合指数被用于上采样和卷积。

去除特征预提取和多特征块后的 Hypernet PRMF模型为 Hypernet。使用 Unet、Segnet、Deeplab v3 + 和 Hypernet 作为控制模型,比较了特征预提取和多特征块的效果。

1.6 模型评估

1.6.1 像素精度 像素精度计算公式如式(3)所示。

$$P_{\text{ixel}} = \frac{N_{\text{CPP}}}{N_{\text{TNP}}},\tag{3}$$

式中:

 P_{ixel} ——像素精度;

 N_{CPP} ——图像中正确预测的发霉花生像素的数量;

N_{TNP}——图像中花生像素的总数量。

1.6.2 检测精度 检测精度计算公式如式(4)所示。

$$K_{\text{ernel}} = \frac{N_{\text{CPK}}}{N_{\text{TNK}}},\tag{4}$$

式中:

K_{ernel} ── 检测精度;

N_{CPK} ——图像中正确预测的花生果仁数量;

N_{TNK}——图像中花生果仁的总数。

2 食品花生霉变检测分析与讨论

2.1 参数设置

如表 1 所示,试验数据集包括 11 张训练图像和 8 张验证图像。尺寸为 256 像素×256 像素×128 像素的图像被随机生成用于训练。同时对受损花生图像进行增强,以提高受损花生和霉变花生的区分度。所有模型训练 30 次,每次 30 个 epoch,每个 epoch 的步数设定为 500。

试验所用计算机配置:英特尔 CPU E5-2609 v3,基本 频率 1.90 GHz,英伟达 Tesla P100 GPU(12G),96 GB物理内存。食品花生霉变检测训练使用 Python 与深度学习库 Keras 实现,其可以快速建立一个深度学习训练系统

表1 试验数据集

Table 1 Experimental dataset

数据集	健康	受损 a	受损 b	受损 a	发霉 b	发霉 c
训练数据	2	1×3	1×2	2	1	1
测试数据	1	1	1	1	1	1

将重叠策略用于图像拼接^[17-18]。先对高光谱图像的边缘进行零填充运算。填充图像被裁剪成以 256 像素×256 像素×128 像素为识别单元、以 128 像素为步长的块。补丁识别后,以 128 像素×128 像素的中间大小作为补丁结果。最后,将所有的补丁拼接在一起,作为整个高光谱图像的结果。

2.2 像素精度

如表 2 所示,使用 3 幅花生图像来验证模型的像素精度。进一步研究健康花生、受损 b 和霉变 a 3 种花生的像素精度识别效果。由于受损 a 图像包含一些种皮受损的花生,霉变 b 和霉变 c 图像包含不完整的霉变花生,因此不对其进行检测识别。

在表 2 中, Unet 是使用原始 Unet 模型和原始数据的 训练结果。Unet-PR 是使用原始 Unet 模型和特征预提取数据的训练结果。Unet-PRMF 是使用带有多特征块的 Unet 模型和特征预提取数据的训练结果。通过比较 Unet 和 Unet-PR 的结果,就可以验证特征预提取(PR)的有效性。多特征块的有效性可以通过比较 Unet-PR 和 Unet-PRMF 的结果来验证。Deeplab v3+模型缩写为 Deep。

如表 2 所示,所有模型的平均像素精度均超过了 87%,表明深度学习模型可以准确地识别单类的食品 花生。其中特征预提取和多特征块对 Deeplab v3+和

表 2 不同模型的像素精度

Table 2 Pixel precision of different models \%

模型类别	健康花生	受损 b	发霉 a
Deep	79.49 ± 12.41	94.42 ± 1.94	98.45 ± 0.68
Deep-PR	86.32 ± 11.14	95.31 ± 2.03	97.81 ± 1.37
Deep-PRMF	93.28 ± 6.99	97.41 ± 1.18	97.97 ± 1.73
Segnet	73.09 ± 29.11	92.42 ± 4.37	97.82 ± 1.54
Segnet-PR	76.64 ± 27.03	89.02 ± 6.04	96.38 ± 2.38
Segnet-PRMF	78.72 ± 26.40	85.62 ± 10.45	96.76 ± 1.68
Unet	98.73 ± 0.50	98.69 ± 0.67	99.20 ± 0.33
Unet-PR	99.02 ± 0.44	98.87 ± 0.69	98.72 ± 0.46
Unet-PRMF	98.08 ± 2.11	99.07 ± 0.42	98.49 ± 0.40
Hypernet	84.63 ± 22.44	96.76 ± 2.39	99.50 ± 0.78
Hypernet-PR	89.62 ± 11.67	97.40 ± 1.51	98.88 ± 0.54
Hypernet-PRMF	93.94 ± 4.39	97.11 ± 2.13	98.96 ± 1.31

Hypernet 有最明显的改进。经过特征预提取, Deeplab v3+和 Hypernet 的平均像素精度明显提高,分别提高了2.37%和1.67%。随着多特征块的加入, Deeplab v3+和 Hypernet 的平均像素精度分别提高了3.07%和1.37%。标准偏差有下降的趋势,进一步证明模型变得更加稳健。由于权重的随机初始化和食品霉变识别数据的随机生成,每次训练的结果都存在不确定性,这是影响准确性的重要因素。尽管优化后 Unet 和 Segnet 的精度没有显著变化,但特征预提取和多特征块的作用可显著提高图像识别效果。

2.3 检测精度

为进一步降低发霉花生的错误识别,有必要设置一个阈值来忽略少量的错误识别的像素。阈值越小,霉变花生的效率就越高。参考李兴鹏等[19]的研究成果,将15%作为识别霉变花生的阈值,比较了识别霉变花生的5%,10%,15%的阈值。根据霉变食品花生样品的质量,单颗普通花生中霉变像素超过10%的花生被认定为霉变花生。霉变像素超过10%的花生被鉴定为受损花生。其他情况被认定为健康花生。

如表 3 所示,有 1 066 颗花生的图像用来验证 12 个模型的检测精度。在特征预提取后,4 个对照模型的检测精度提高了 0.53%~1.20%。在此基础上,向模型添加多特征块后,检测精度提高了 0.72%~5.66%。此外,Hypernet-PRMF模型的检测精度最高,达到 90.35%。所有模型在图像信息相对简单的健康、受损 b、霉变 a 和霉变 b 图像上都表现出良好的性能。相比之下,健康花生图像和受损 a 的图像信息相对复杂,这对模型的识别能力要求更高。而且构建的 3 个 Hypernet 模型在复杂图像中的识别精度大大超过了其他模型,说明该模型具有很强的泛化能力。

2.4 霉变花生图像识别效果

使用建立的 Hypernet-PRMF 模型对发霉花生图像进行识别,进一步验证模型的准确性。如图 2(c)所示,模型能很好地区分发霉部分、种皮受损部分和正常种皮部分,同时对于整个花生数据集,Hypernet-PRMF 的错误识别率较低,可以有效识别图中所有的发霉花生。而且可以观察到发霉的花生有更多的红色像素,健康的花生有更多的绿色像素。很容易将发霉的花生与健康的花生分开。结合像素级和核级的识别结果,该模型可以达到像素级的花生纹理识别,可以胜任各种类型的花生识别任务。

3 结论

试验研究了基于深度学习的高光谱霉变花生识别方

表 3 不同模型的检测精度

Table 3 Detection accuracy of different mo
--

模型类别	健康花生	受损-a	受损-b	发霉-a	发霉-b	发霉-c
Deep	63.39 ± 26.78	63.93 ± 11.12	97.62±4.66	100.00±0.00	99.65 ± 0.94	99.41 ± 1.42
Deep-PR	75.24 ± 24.02	58.70 ± 16.15	97.90 ± 3.97	100.00 ± 0.00	99.35 ± 1.50	97.71 ± 3.58
Deep-PRMF	89.97 ± 13.46	86.05 ± 9.23	99.31 ± 2.07	100.00 ± 0.00	97.82 ± 3.71	94.56 ± 6.49
Segnet	55.79 ± 41.14	66.69 ± 17.05	94.31 ± 10.34	100.00 ± 0.00	99.62 ± 0.88	98.21 ± 6.62
Segnet-PR	61.77 ± 30.75	68.36 ± 16.39	93.22 ± 12.75	100.00 ± 0.00	99.92 ± 0.30	98.80 ± 2.23
Segnet-PRMF	64.66 ± 34.43	73.14 ± 14.84	95.67 ± 8.58	100.00 ± 0.00	99.47 ± 1.34	96.32 ± 4.99
Unet	99.66 ± 0.65	57.29 ± 30.35	98.81 ± 2.35	100.00 ± 0.00	99.98 ± 0.14	99.79 ± 0.51
Unet-PR	99.47 ± 0.94	65.65 ± 26.50	99.18 ± 2.17	100.00 ± 0.00	99.98 ± 0.14	98.91 ± 1.79
Unet-PRMF	98.57 ± 3.26	83.64 ± 8.29	99.87 ± 0.36	100.00 ± 0.00	99.95 ± 0.27	99.76 ± 0.82
Hypernet	75.13 ± 29.51	80.34 ± 14.95	99.20 ± 1.62	100.00 ± 0.00	99.95 ± 0.19	99.73 ± 0.64
Hypernet-PR	75.69 ± 30.89	78.39 ± 11.74	99.55 ± 0.71	100.00 ± 0.00	99.98 ± 0.14	99.17 ± 2.42
Hypernet-PRMF	88.76 ± 12.28	79.92 ± 19.25	97.94 ± 4.77	100.00 ± 0.00	100.00 ± 0.00	99.84 ± 0.39

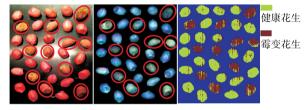


图 2 图像识别结果

Figure 2 Recognition result of mixed image

法,提出了高光谱数据的特征预提取方法和多特征融合块,分别用于 Unet、Segnet、Deeplab v3+和构建的 Hypernet模型。像素精度和检测精度的结果表明,数据特征预提取方法对提高识别霉变花生和受损花生具有极大的识别精度。构建的 Hypernet-PRMF 模型的检测精度等进行研究,未进一步深入讨论检测时间等其他检测性能对霉变花生检测的影响。因此,应进一步研究基于深度学习模型的检测时间、检测准确率,以提高霉变花生检测的综合性能。

参考文献

- [1] 王锐, 王桂英, 吴文福, 等. 基于仿生智能算法的高水分玉米收购定等系统研究[J]. 粮油食品科技, 2023, 31(2): 74-82.
 - WANG R, WANG G Y, WU W F, et al. Research on high-moisture corn acquisition and leveling system based on bionic intelligence algorithm[J]. Science and Technology of Cereals, Oils and Foods, 2023, 31(2): 74-82.
- [2] 熊春晖, 佘永新, 焦逊, 等. 高光谱成像技术在农产品无损检测中的应用[J]. 粮油食品科技, 2023, 31(1): 109-122.
 - XIONG C H, SHE Y X, JIAO X, et al. Application of hyperspectral imaging technology in nondestructive testing of agricultural products[J]. Science and Technology of Cereals, Oils and Foods,

2023, 31(1): 109-122.

- [3] 王粒. 基于高光谱图像的花生品种分类、霉变检测及蛋白质含量预测[D]. 雅安: 四川农业大学, 2022: 40-41.
 - WANG L. Peanut variety classification, mildew detection and protein content prediction based on hyperspectral images[D]. Ya'an: Sichuan Agricultural University, 2022: 40-41.
- [4] QI X T, JIANG J B, CUI X M, et al. Identification of fungicontaminated peanuts using hyperspectral imaging technology and joint sparse representation model[J]. Journal of Food Science and Technology, 2019, 56(7): 3 195-3 204.
- [5] 李明泽. 基于多光谱图像技术的梅干菜杂质检测研究与系统 开发[D]. 无锡: 江南大学, 2021: 36-37.
 - LI M Z. Research and system development on the detection of impurities in dried plum vegetables based on multispectral image technology[D]. Wuxi: Jiangnan University, 2021: 36-37.
- [6] 李薇, 王晓涵, 陈燕, 等. 食品非定向筛查样品前处理方法及材料的研究进展[J]. 化学教育(中英文), 2023, 44(10): 1-5.
 - LI W, WANG X H, CHEN Y, et al. Research progress on pretreatment methods and materials of food non directional screening samples[J]. Chinese Journal of Chemical Education, 2023, 44(10): 1-5.
- [7] 白一睿, 方辉, 张泽. 基于 YOLO 神经网络模型的花生智能精选系统设计[J]. 机械, 2023, 50(2): 1-6.
 - BAI Y R, FANG H, ZHANG Z. Design of an intelligent peanut selection system based on YOLO neural network model [J]. Machinery, 2023, 50(2): 1-6.
- [8] 孙晓荣, 田密, 刘翠玲, 等. 太赫兹衰减全反射技术对板栗果仁霉变程度判别研究[J]. 食品安全质量检测学报, 2022, 13(14): 4 527-4 533.
 - SUN X R, TIAN M, LIU C L, et al. A study on the discrimination of chestnut kernel moldy degree using terahertz attenuated total reflection technology[J]. Journal of Food Safety & Quality, 2022, 13

(14): 4 527-4 533.

- [9] 许文娟, 赵晗, 王洪涛, 等. 电子鼻在食品安全检测领域的研究进展[J]. 食品工业, 2022, 43(2): 255-260.
 - XU W J, ZHAO H, WANG H T, et al. Research progress of electronic nose in the field of food safety detection[J]. The Food Industry, 2022, 43(2): 255-260.
- [10] 成亚倩, 高志贤, 周焕英, 等. 食品中黄曲霉毒素比色生物检测技术研究进展[J]. 分析试验室, 2021, 40(8): 966-976.
 CHENG Y Q, GAO Z X, ZHOU H Y, et al. Research progress of
 - Aspergillus flavus colorimetric biological detection technology in food[J]. Chinese Journal of Analysis Laboratory, 2021, 40 (8): 966-976.
- [11] 王林, 王宇栋, 朱宝, 等. 仓储片烟中优势霉菌的分离鉴定及 其霉变挥发性代谢产物研究[J]. 河南农业科学, 2023, 52(3): 101-108.
 - WANG L, WANG Y D, ZHU B, et al. Isolation and identification of dominant molds in warehouse tobacco and study on moldy volatile metabolites [J]. Journal of Henan Agricultural Sciences, 2023, 52(3): 101-108.
- [12] 戴松松, 殷勇. 基于高光谱信息特征选择的玉米霉变程度 Fisher 鉴别方法[J]. 食品与机械, 2018, 34(3): 68-72.
 - DAI S S, YIN Y. Fisher identification method of corn mildew degree based on Feature selection of hyperspectral information[J]. Food & Machinery, 2018, 34(3): 68-72.
- [13] 徐彦, 李忠海, 付湘晋, 等. 近红外光谱技术在稻米品质快速检测中的应用[J]. 食品与机械, 2011, 27(1): 158-161, 174.

 XU Y, LI Z H, FU X J, et al. Application of near-infrared spectroscopy technology in rapid detection of rice quality[J]. Food & Machinery, 2011, 27(1): 158-161, 174.
- [14] 曾瑜, 谌委菊, 全珂, 等. 基于脱氧核酶的食品安全快速检测方法研究进展[JI. 食品与机械, 2022, 38(6): 205-212.

- ZENG Y, CHEN W J, QUAN K, et al. Research progress on rapid detection methods for food safety based on deoxyribonuclease[J]. Food & Machinery, 2022, 38(6): 205-212.
- [15] 廉飞宇, 杨静, 付麦霞, 等. 玉米中黄曲霉毒素 B₁的太赫兹时域光谱检测与识别 [J]. 中国粮油学报, 2014, 29(8): 111-116, 123.
 - LIAN F Y, YANG J, FU M X, et al. Terahertz time-domain spectroscopy analysis for aflatoxin B_1 solution[J]. Journal of the Chinese Cereals and Oils Association, 2014, 29(8): 111-116, 123.
- [16] 郭志明, 王郡艺, 宋烨, 等. 果蔬品质劣变传感检测与监测技术研究进展[J]. 智慧农业(中英文), 2021, 3(4): 14-28. GUO Z M, WANG J Y, SONG Y, et al. Research progress in sensor detection and monitoring technology for quality deterioration of
- [17] 马佳佳, 王克强. 水果品质光学无损检测技术研究进展[J]. 食品工业科技, 2021, 42(23): 427-437.

 MA J J, WANG K Q. Research progress in optical non-destructive testing technology for fruit quality[J]. Science and Technology of Food Industry, 2021, 42(23): 427-437.

fruits and vegetables[J]. Smart Agriculture, 2021, 3(4): 14-28.

- [18] 张雨鑫. 高光谱成像技术在饲料及原料霉变检测中的应用[J]. 黑龙江粮食, 2022(12): 53-55.

 ZHANG Y X. Application of hyperspectral imaging technology in the detection of moldy feed and raw materials[J]. Heilongjiang Grain, 2022(12): 53-55.
- [19] 李兴鹏,姜洪喆,蒋雪松,等. 木本粮油林果品质的近红外光谱及成像无损检测研究进展[J]. 食品与发酵工业,2022,48(2):302-308.
 - LI X P, JIANG H Z, JIANG X S, et al. Research progress in near-infrared spectroscopy and imaging non-destructive testing of woody grain, oil, forest and fruitquality[J]. Food and Fermentation Industries, 2022, 48(2): 302-308.

(上接第109页)

- [57] ZAHIR M H, MOHAMED S A, SAIDUR R, et al. Supercooling of phase-change materials and the techniques used to mitigate the phenomenon[J]. Appl Energy, 2019, 240: 793-817.
- [58] LIU K, HE Z, LIN P, et al. Highly-efficient cold energy storage enabled by brine phase change material gels towards smart cold chain logistics[J]. Journal of Energy Storage, 2022, 52: 104828.
- [59] 刘璐. 基于相变材料的果蔬冷链物流运输发展现状文献综述 [J]. 上海节能, 2021(5): 494-498.
 - LIU L. Literature review on the development of fruit and vegetable cold chain logistics and transportation based on phase change materials[J]. Shanghai Energy Saving, 2021(5): 494-498.
- [60] SHA Y, HUA W, CAO H, et al. Properties and encapsulation forms of phase change material and various types of cold storage box for cold chain logistics: A review[J]. Journal of Energy Storage, 2022, 55: 105426.
- [61] WANG T, QIU X, CHEN X, et al. Sponge-like form-stable phase

- change materials with embedded graphene oxide for enhancing the thermal storage efficiency and the temperature response in transport packaging applications [J]. Applied Energy, 2022, 325: 119832.
- [62] NAVROTSKAYA A, ALEKSANDROVA D, CHEKINI M, et al. Nanostructured temperature indicator for cold chain logistics[J]. ACS Nano, 2022, 16(6): 8 641-8 650.
- [63] BAHRAMI R, ZIBAEI R, HASHAMI Z, et al. Modification and improvement of biodegradable packaging films by cold plasma: A critical review[J]. Critical Reviews in Food Science and Nutrition, 2022, 62(7): 1 936-1 950.
- [64] 窦勇, 姚妙爱, 闾怀中, 等. 冷等离子体对单核增生李斯特菌的杀菌机理[J]. 中国农业科学, 2020, 53(24): 5 104-5 114.

 DOU Y, YAO M A, LU H Z, et al. Antibacterial mechanism of cold plasma against listeria monocytogenes[J]. Scientia Agricultura Sinica, 2020, 53(24): 5 104-5 114.