

## 机器视觉在食品无损检测中的应用研究进展

唐彦嵩, 徐锐豪, 王凤加

(清华大学深圳国际研究生院 广东深圳 518055)

**摘要** 随着全球食品消费需求的增加,食品无损检测技术在食品质量控制和安全保障中变得日益重要。本文系统综述机器视觉在食品无损检测中的应用与发展趋势。通过分析当前文献,探讨包括 RGB 成像、多光谱成像、高光谱成像等多种成像技术,以及图像处理、机器学习和深度学习等检测算法在食品无损检测中的应用。分析机器视觉在食品无损检测中应用的技术挑战,如数据集的匮乏和模型在通用场景下泛化能力不足。基于当前研究现状,展望未来的研究方向,提出多模态数据融合、嵌入式检测系统以及与深度学习技术的紧密结合等可能的发展路径,旨在为食品无损检测技术的创新提供参考和方向。

**关键词** 食品无损检测; 食品安全; 机器视觉; 机器学习; 深度学习

文章编号 1009-7848(2024)12-0013-15 DOI: 10.16429/j.1009-7848.2024.12.002

随着全球食品消费量的增加,消费者对高品质食品的需求也在不断上升<sup>[1]</sup>。为了确保食品的高品质,食品检测是一种重要的手段。食品检测的内容主要包括内部品质和外部品质<sup>[2]</sup>。内部品质包括糖度、酸度、水分含量、内部缺陷(如腐烂、虫蛀)等,这些参数对食品的口感、营养价值和保存期有直接影响。外部品质包括颜色、形状、尺寸、表面缺陷(如斑点、裂纹)等,它是消费者选择食品的重要因素。传统的食品检测方法通常需要破坏食品样品,导致食品的浪费和检测成本的增加。食品无损检测是一种在不破坏食品样品的前提下,通过物理、化学或生物方法对食品的内部和外部品质进行评估和分析的技术。该技术利用现代光学、电子、声学 and 计算机技术,通过对食品样品的图像、光谱、声波等信号进行采集和处理,从而获得食品的品质信息。与传统的破坏性检测方法相比,无损检测技术不仅提高了检测效率,减少了食品浪费,还能够实现实时监控和在线检测,为食品质量控制和安全保障提供可靠的手段。

通过采用无损检测技术,食品生产企业能够大幅提高检测速度和效率,在降低人工成本的同时,减少人为操作的误差,实现更高效、环保的生产流程。无损检测技术不仅在生产环节中发挥着

重要作用,还能为食品质量提供标准化的评估手段,确保食品在运输、储存和销售过程中始终保持高品质,从而提高食品供应链的效率和可靠性。在食品消费环节,无损检测技术可以及时发现潜在的食品安全隐患,保障消费者的健康,增强消费者对产品的信任,进而提升品牌的市场竞争力。在国际贸易中,通过应用先进的无损检测技术,我国食品企业可以提供更高质量的产品,满足国际市场对食品安全和质量的严格要求,提升我国食品产业在国际市场上的竞争力。

在多种无损检测方法中,基于机器视觉的无损检测方法的广泛应用正成为一种趋势。机器视觉技术一方面具有高度的自动化能力和低成本优势,能够实时捕捉和分析食品的外观,实现快速、高效的检测流程。另一方面,机器视觉技术通过高分辨率成像和精确的图像分析算法,能够检测到细微的外观缺陷(如裂纹、斑点和腐烂等),在提高生产效率的同时,减少人工干预的误差,在检测精度和可靠性方面具有显著优势。机器视觉技术可适用于各种类型的食品检测,在水果、蔬菜、谷物、肉类和乳制品等不同领域得到广泛应用。得益于人工智能技术的发展,机器视觉系统的智能化水平也在不断提升,可以更加准确地识别和分类不同类型的食品缺陷。基于机器视觉的无损检测技术,还具有灵活的可扩展性,能与已有的生产线和质量控制系统无缝集成,帮助食品生产企业快速迭代生产流程和质量控制策略。基于机器视觉的

收稿日期: 2024-10-29

基金项目: 国家重点研发计划课题(2023YFF1105101)

第一作者: 唐彦嵩,男,博士,特聘研究员

E-mail: tang.yansong@sz.tsinghua.edu.cn

无损检测方法因高效、灵活和智能化的特点,而成为食品无损检测领域的重要发展趋势。

本文首先运用文献计量学方法,分析基于机器视觉的食品无损检测领域的文献发表情况,挖掘研究热点及发展趋势。其次,对相关文献按照技术原理进行分类,介绍机器视觉在食品无损检测中应用的研究进展,展示其在不同食品中的实际应用案例。最后讨论机器视觉在食品无损检测中的技术挑战,提出未来的研究方向和创新点。

## 1 机器视觉在食品无损检测中应用的文献计量学分析

文献计量学分析是一种通过统计和分析文献特征和文献间关系的方法,用于揭示特定研究领域的发展动态和趋势。本文采用 CiteSpace<sup>[3]</sup>作为文献计量学分析工具,对机器视觉在食品无损检测中应用的相关文献进行历年发文量、关键词共现分析和关键词突现性分析。历年发文量分析通过统计不同年份的文献数量,揭示该领域研究的增长趋势和发展速度。关键词共现分析是通过分析文献中出现的关键词及其相互关系,揭示该领域的研究热点和核心主题。而关键词突现性分析是识别在某一特定时间段内频率突然增加的关键词,以了解该领域的新兴趋势和发展方向。这些分析的目的是为了系统了解机器视觉在食品无损检

测中的研究现状,找出研究热点和前沿问题,从而为未来的研究提供指导。

### 1.1 历年发文量分析

中文文献以中国知网(CNKI)为数据来源,以“机器视觉+食品”或“计算机+食品”作为主题词进行全字段检索,发表时间限定为2004年1月1日至2024年7月9日,文献类型为学术期刊和学位论文。随后对检索结果进行人工筛选,去除与食品无损检测不相关的文献,最终得到符合要求的中文文献380篇。英文文献以Web of Science(WoS)核心合集数据库为数据来源,选择“machine vision food detection”或“computer vision food detection”作为主题词进行全字段检索,时间范围限定为2004年1月1日至2024年7月9日,并将文献类型限定为“Article”。通过人工筛查去除检索结果中与食品无损检测不相关的文献,最终得到498篇英文文献。

2004至2024年食品无损检测领域每年发文量如图1所示,2024年发文量统计结果截止到2024年7月。相关中文文献发文量在2019年之前呈整体上升趋势,在2019年达到顶峰后开始略微下降。另外,相关英文文献历年发文量呈整体上升趋势,近5年来呈加速上升趋势。2023年相关英文文献发表量达到73篇,约是2004年发文量的17倍。




图1 2004—2024年相关领域文献发表情况

Fig.1 Publication trends in related fields from 2004 to 2024

### 1.2 关键词共现分析

利用 CiteSpace 分别对中文和英文的文献检索结果进行关键词共现分析,结果如图2所示。通过分析关键词共现图谱,可以得出以下结论:在食品无损检测领域,已有的研究采用多样化的技术方法,包括神经网络、特征提取、模式识别、高光谱

成像、多光谱成像、图像分析和图像处理等先进的人工智能、机器学习和光谱成像技术。这些技术方法不仅丰富了检测手段,也提高了检测的精确度和效率。机器视觉技术在食品安全和农产品质量控制方面的应用尤为广泛。关键词如“食品生产”“包装”“果穗”“食品安全”和“牛肉”等表明,这些

是研究的重点领域,涵盖了从原材料检测到最终产品质量控制的多个环节。关键词如“缺陷检测”“质量检测”“预测”“分类”“分级”和“颜色”等表明,该领域研究的任务类型主要包括食品缺陷检测、食品品质的分类分级,以及食品质量和颜色分

析。此外,有研究还采用多样化的系统和方法。关键词如“信息融合”“电子鼻”和“衰减全反射”等表明研究人员在开发和应用各种检测手段和技术路径方面的创新,为食品无损检测提供了新颖的解决方案。

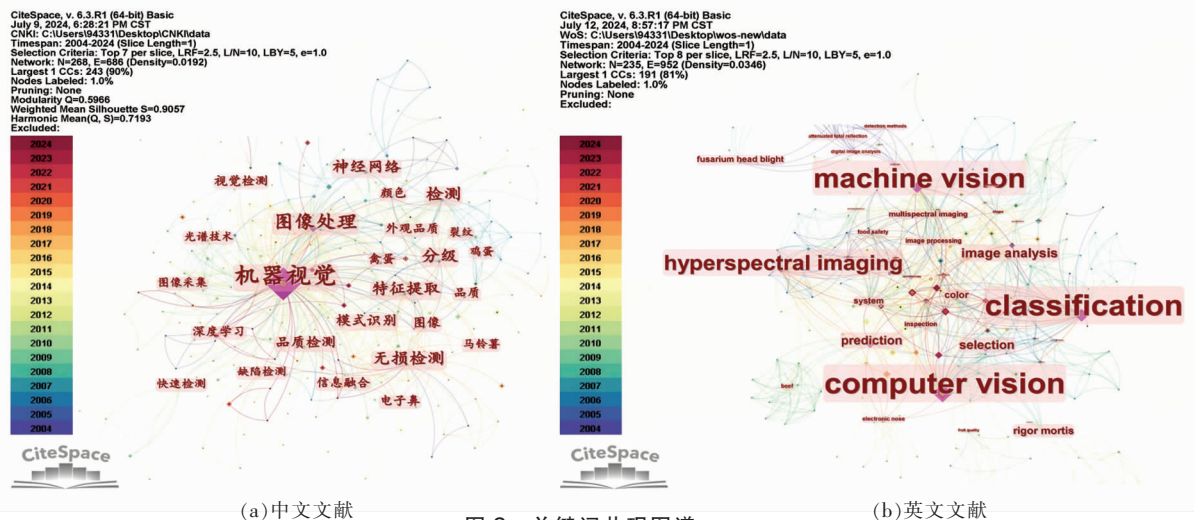


图 2 关键词共现图谱

Fig.2 Co-occurrence map of keywords

### 1.3 关键词突现分析

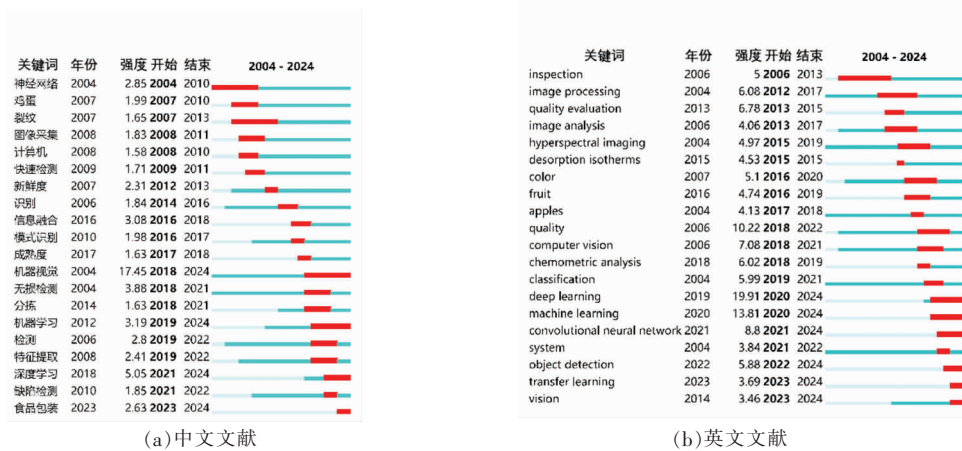
利用 CiteSpace 分别对中文文献和英文文献的关键词共现图谱进行突现性分析,结果如图 3 所示。中文文献中,2004 年至 2013 年间的研究主要集中在神经网络、图像采集、识别等基础技术上,而在 2014 年以后,研究方向逐渐转向信息融合、模式识别、机器视觉等更高级的应用领域,特别是 2018 年以后,机器学习和深度学习逐渐成为突出的研究热点。英文文献中,2004 至 2024 年期间的关键词突现性的时间分布与中文文献有一定相似性。例如,早期(2006 至 2017 年)关键词如“image processing”“image analysis”等突现性较强,而在 2018 年以后,“quality”“computer vision”“deep learning”等关键词的突现性显著增强,表明这些领域的研究受到更多的关注。英文文献的研究热点在 2018 年后向计算机视觉和深度学习等新兴技术领域转移,与中文文献的趋势一致。这表明无损检测领域的研究在全球范围内逐渐趋向于利用新兴的机器学习和深度学习技术来提升检测的精度和效率。综合来看,中文和英文文献的研究趋势大致相同,表明无损检测技术的研究在国际

上具有较高的一致性。无论是中文还是英文文献,研究热点都从早期的图像处理、图像分析等基础技术逐渐转向机器视觉、深度学习等高级应用领域。尤其是 2018 年以后,深度学习技术在食品无损检测中的应用研究显著增多,已成为研究的主流方向。未来几年,基于机器学习和深度学习技术的无损检测方法或将继续成为研究的焦点,这些技术的应用有望进一步提升食品无损检测的效率和精度。

## 2 机器视觉在食品无损检测中应用的研究进展

机器视觉技术在食品无损检测中扮演着关键角色,其应用流程主要分为两个主要环节:成像与检测。在成像环节,通过运用 RGB 成像、多光谱成像、高光谱成像等先进技术捕获食品对象的图像,或者收集如色谱分析等检测过程中产生的图像数据,为后续的检测环节提供必要的视觉输入。检测环节则利用包括传统图像处理技术、传统机器学习算法以及现代深度学习算法在内的多种方法,对输入的图像进行分析,以评估食品的数量或质





注:按突现时间排序,突现性最强的前20个关键词。

图3 关键词突现性分析

Fig.3 Keyword emergence

量属性。本文从成像技术和检测算法两个维度,综述当前该领域的研究动态和进展。

### 2.1 基于不同成像方法的食物无损检测技术

光谱是指当光通过棱镜或光栅等分光装置时,按照波长或频率的顺序分解成的一系列颜色或电磁波的排列。光谱揭示了光的不同波长或频率成分,可以用于分析光的性质和来源。光谱学是研究光谱的学科,通过分析光谱可以获得物质的成分、结构和其它物理特性。光谱成像是一种结合成像和光谱分析的技术,用于获取物体在不同波长范围的光谱信息,同时记录其空间分布。它通过捕捉每个像素点在多个波长上的光谱数据,生成既有光谱信息又有图像信息的多维数据集。根据光谱波段的数量和波段宽度的不同,光谱成像又可分为RGB成像、多光谱成像、高光谱成像和超光谱成像。

RGB成像是基础的成像方法,通过获取红色、绿色和蓝色3个波段的图像,构成食品对象的彩色图像。这种成像技术直观、简单、成本低廉,被广泛应用于食品外观质量的检测。然而,由于RGB成像仅限于3个波段,光谱信息较少,因此在识别食品内部结构和成分方面存在局限性,无法满足更高精度的检测需求。多光谱成像通过在多个特定波长下采集图像,通常选取少量特定的波段(例如红、绿、蓝、近红外等)进行成像。每个波段的图像能够反映食品在该波段下的特定光谱特性<sup>[4]</sup>。其优点在于成像速度快,数据处理相对简单,适用

于实时检测和大规模应用。常见的RGB(Red, Green, Blue)图像就是多光谱图像的一个子集。然而,由于多光谱成像的光谱分辨率较低,可能无法捕捉到食品中某些细微的光谱特征。高光谱成像则进一步扩充了光谱采集的波段,其获取的光谱数据是连续的,覆盖了更广泛的波长范围,每个像素都包含一个完整的光谱信息,使得高光谱成像能够更精确地识别和分类食品的成分和品质。高光谱成像的数据量大,处理复杂度高,其高光谱分辨率提供了更丰富的信息,因此适用于需要高精度的检测任务。超光谱成像则是高光谱成像的进一步扩展,其覆盖了更多的光谱波段,因此具有更高的光谱分辨率和更丰富的光谱信息。然而,超光谱成像系统的成本较高,数据处理更为复杂,目前尚未发现在食品无损检测领域应用该技术的报道。除了RGB、多光谱和高光谱成像技术外,还有其它几种成像技术在食品无损检测中具有广泛的应用前景,如X射线成像、荧光成像、光学相干断层扫描和电子鼻等。这些技术通过不同的物理原理和方法来获取食品的内部或表面的信息,从而提供多维度的数据来支持食品质量的评估。

2.1.1 RGB成像 Bhargava等<sup>[5]</sup>提出一种利用机器学习自动检测和分级多种水果的方法,通过提取图像的红、绿、蓝3种颜色通道的数值,并使用分裂合并算法<sup>[6]</sup>去除背景,然后提取包括颜色、统计、纹理和几何在内的30种特征,其中几何特征用于区分水果种类,其它特征用于质量评估,并采

用 k 近邻(k-NN)<sup>[7]</sup>、支持向量机(SVM)<sup>[8]</sup>、稀疏代表分类器(SRC)<sup>[9]</sup>和人工神经网络(ANN)<sup>[10]</sup>4 种分类器对水果质量进行分类,结果显示:SVM 在水果检测和质量评估中最为有效,分类准确率分别达 98.48%和 95.72%。Yee 等<sup>[11]</sup>提出一种新颖的光学分割方法,通过在低角度蓝色漫射光和红色漫射背光两种照明条件下拍摄的图像融合,对燕窝中的杂质进行分割和检测,算法在杂质检测中实现了 93.39%的真实阳性率,71.17%的精确度和 4.8%的假阴性检测率。Song 等<sup>[12]</sup>研究了一种基于智能手机视频检测牛肉末掺假的方法,通过手机屏幕生成不同颜色的光照射样品表面,并用前置摄像头录制短视频,然后将其转换为光谱数据,再通过偏最小二乘回归模型预测掺假程度。该回归模型的决定系数为 0.73 至 0.98,预测均方根误差为 0.04~0.16,表明该方法在检测牛肉末掺假方面具有应用潜力。Mandal 等<sup>[13]</sup>提出一种计算机视觉框架,采用频域环形均值滤波器<sup>[14]</sup>进行特征提取,利用深度神经网络<sup>[15]</sup>检测姜黄粉中的甲苯胺黄(MET)掺假,并通过随机森林回归<sup>[16]</sup>预测掺假量。试验结果表明该方法在识别和预测任务中的准确率均超过 98%,为未来开发低成本食品无损掺假检测移动设备提供了有力支持。Gao 等<sup>[17]</sup>开发了一种基于 Swin Transformer<sup>[18]</sup>和智能手机的计算机视觉方法,用于实时定量检测牛肉制品中食品水解胶体的掺假情况。研究采用预训练和微调技术,成功将牛肉按卡拉胶掺假程度(0%~20%)分为 9 个等级,其中 Swin-Tiny (Swin-T) 模型表现最佳,Top-1 准确率为 0.997,检测速度为 3.2 ms。相比之下,电化学阻抗谱法的准确率为 0.792,且需要恒温环境和约 30 min 的数据稳定时间。此外,Swin-T 模型还能以 0.975 的 Top-1 准确率区分不同类型的水解胶。Yildiz 等<sup>[19]</sup>利用人工智能技术,通过分析鱼眼特征评估鱼肉的新鲜度,并开发了结合深度学习和机器学习模型的应用程序,可即时检测鱼样本的新鲜度。试验中采用 SqueezeNet<sup>[20]</sup>和 VGG19<sup>[21]</sup>两种深度学习算法进行图像特征提取,并应用 5 种机器学习模型(k 近邻算法、随机森林、支持向量机、逻辑回归、人工神经网络)进行新鲜度分类,其中 VGG19 模型与人工神经网络结合的分类成功率最高,达到 77.3%。

2.1.2 多光谱成像 Song 等<sup>[22]</sup>基于近红外光谱<sup>[23]</sup>和机器视觉的数据融合,开发了一种快速识别掺假霉变大米的方法,以满足快速检测正常大米中掺杂霉变大米的需求。通过将连续投影算法(SPA)与主成分分析(PCA)和支持向量分类(SVC)<sup>[8]</sup>相结合,创建了基于变量选择、特征提取和非线性建模方法的 SPA-PCA-SVC 方法。采用 K 折交叉验证和预测残差平方和确定主成分的最佳数量,并使用遗传算法调整模型参数。基于近红外光谱、机器视觉及其融合数据建立了掺假大米识别模型,训练集的识别准确率分别为 92.81%,86.27%和 99.35%,测试集的识别准确率分别为 69.23%,82.69%和 96.15%。与单独使用近红外光谱或机器视觉相比,融合数据构建的模型识别性能显著提高。Yan 等<sup>[24]</sup>提出一种结合化学机器视觉的新方法,用于水供应系统中的多污染物监测,通过新型长路径光谱成像仪和机器学习模型,实现了砷、镉和硒等 3 种重金属元素的直接分析和快速检测。试验使用 380~780 nm 的可见光源,采用 ResNet-50<sup>[25]</sup>、SqueezeNet V1.1 和 GoogLeNet Inception V1 等 3 种深度学习模型进行预测,结果表明模型在不同背景饮用水系统中的预测性能稳定,能够准确、有效、实时地预测饮用水的多维指标,显著提高水质监测效率。Yin 等<sup>[26]</sup>研究了利用近红外光谱和计算机视觉技术对吐司面包中异物进行无损检测的方法,通过近红外光谱结合不同光谱预处理的距离匹配和判别分析方法,以及基于改进 U-net 的深度学习方法,分别实现了对金属铁、聚丙烯塑料和头发等异物的识别,结果表明近红外光谱判别分析结合 Savitzky-Golay 平滑处理<sup>[27]</sup>对 3 种异物识别的准确率分别为 98%,94%,91%,而计算机视觉方法的准确率分别为 95%,93%,92%,证明利用近红外光谱和计算机视觉技术在面包异物检测中的可行性。Zhang 等<sup>[28]</sup>研究了利用可见-近红外(Vis-NIR)高光谱反射成像技术识别常见柑橘表皮缺陷和分类早期腐烂柑橘的可行性。研究通过 Vis-NIR-PCA、Vis-PCA 和 NIR-PCA 进行数据降维,选取 540,623,675,805 nm 和 975 nm 5 个特征波长图像,并采用均值归一化方法校正柑橘球形表面不均匀光照分布,同时结合改进的分水岭分割算法和简单全局阈值法<sup>[14]</sup>,

检测 397 个独立测试样本中正常和缺陷柑橘的总体分类准确率为 97.73%, 腐烂和非腐烂柑橘的识别率为 100%, 结果验证了该方法在柑橘缺陷检测和早期腐烂分类中的潜力。Benouis 等<sup>[29]</sup>介绍一种基于高光谱图像和深度学习的食品托盘封口缺陷检测方法, 通过像素级数据融合方法将 3D 高光谱图像数据立方体转换为 2D 图像, 并利用深度学习算法进行检测。该方法仅选取感兴趣区域内的相关光谱波段, 从而提高计算效率并保持较高分类率。在工业数据集上进行验证的结果显示, 深度置信网络<sup>[30]</sup>、极限学习机<sup>[31]</sup>、堆栈自动编码器<sup>[32]</sup>和卷积神经网络<sup>[33]</sup>的准确率分别为 88.7%、88.3%、89.3% 和 90.1%, 验证了该方法的有效性。

**2.1.3 高光谱成像** Xie 等<sup>[34]</sup>利用高光谱成像技术分析调味后熟牛肉的光谱特性, 发现香料的光谱反射率显著低于熟牛肉中的蛋白质, 并且蛋白质在 800~956 nm 范围的光谱反射率随加热规律性增加。该研究利用主成分分析和支持向量机算法预测牛肉的含水量和嫩度, 清晰显示加热过程中牛肉嫩度的动态变化, 同时该研究还基于 750 nm/900 nm 比率图像和机器视觉方法精确计算香料分布的均匀性, 验证高光谱成像技术在熟肉品质和调料分布评估中的应用潜力。Yang 等<sup>[35]</sup>提出一种柑橘病害识别框架, 通过 AMSR 算法<sup>[36]</sup>增强图像, 突出病害特征信息, 并提出 MF-RANet 网络识别柑橘病害图像。AMSR 算法显著减轻了云层和低光对图像病斑的干扰, 使病害特征更清晰; MF-RANet 由主特征框架和细节特征框架组成, 主特征框架利用 ResNet50 和 RAM<sup>[37]</sup>提取主要特征, 细节特征框架使用 AugFPN<sup>[38]</sup>从多尺度提取并融合特征, 提高了不同病害特征的区分度。试验结果显示该网络对黄龙病、炭疽病、脂斑病、柑橘疮痂病、柑橘溃疡病和健康柑橘的检测准确率分别为 96.77%、96.22%、95.96%、95.93%、94.04% 和 97.55%, 有效提高了柑橘病害的识别率。Stasenko 等<sup>[39]</sup>提出一种基于生成对抗网络<sup>[40]</sup>和卷积神经网络的方法, 利用合成和分割的可见近红外(VNIR)光谱成像数据预测苹果早期采后腐烂和真菌感染区, 以此评估存储苹果的质量。通过 Pix2PixHD<sup>[41]</sup>模型实现了 RGB 到 VNIR 图像的高效转换, 并选择 Mask R-CNN<sup>[42]</sup>模型对 VNIR 图像进行分割,  $F1$

分数分别为 58.861(腐烂区)、40.968(真菌区)和 94.800(腐烂区和真菌区)。试验使用一个包含 1 305 个 RGB 和 VNIR 苹果图像的配对数据集, 以及额外获取的 1 029 个 VNIR 图像进行模型训练和测试, 并在配备图形处理单元的嵌入式系统上验证该方法的有效性。Pourdarbani 等<sup>[43]</sup>利用高光谱成像技术在 550~900 nm 光谱范围检测橙子的碰伤情况, 并比较二维(2D)和三维(3D)卷积神经网络(CNN)在高光谱图像分析中的效果。研究首先对 60 个橙子样品进行机械碰伤处理, 并在碰伤前和碰伤后 8 h 及 16 h 分别采集高光谱图像数据, 然后使用浅层 7 层网络(CNN-7)和深层 18 层网络(CNN-18)对样品进行分类。研究采用两种输入处理方法: 基于每个波段的二维信息和基于完整高光谱图像数据的三维信息, 结果显示, 三维模型的准确率最高, 其中 3D-CNN-18 的分类准确率为 94%, 3D-CNN-7 为 90%。

**2.1.4 其它成像技术** Gao 等<sup>[44]</sup>结合 X 射线成像技术、图像处理技术与机器学习算法, 解决了由于密度不均导致的核桃质量检测准确率低的问题。研究首先通过图像处理技术去除核桃 X 射线图像背景并分割出核仁区域, 提取核桃和核仁形态特征参数用于构建质量预测模型。结果显示基于核桃形态或纹理特征参数的质量预测模型决定系数( $R^2$ )较低, 残差预测偏差(RPD)小于 1.4, 不具有可靠性; 而基于核桃和核仁形态特征参数构建的偏最小二乘(PLS)和径向基函数(RBF)模型<sup>[45]</sup>的  $R^2$  均高于 0.84, RPD 分别为 1.8133 和 1.7474。当进一步采用竞争自适应重加权采样(CARS)优化参数后,  $R^2$  均高于 0.86, RPD 分别为 1.8759 和 1.8850, 表明核桃及其核仁形态特征的应用可提高模型预测准确性, 为核桃的精确分级提供了新思路。Hui 等<sup>[46]</sup>综述了基于智能手机和侧流免疫分析的快速检测技术在医学诊断、环境监测和食品安全中的应用。通过智能手机内置的高清摄像头拍照, 并利用机器视觉图像识别技术, 将试纸条显色的光学信号转换为基于可见光比色分析或荧光分析技术的数字信号, 实现试纸条显色的定性或定量检测。作者还讨论并总结了基于智能手机拍摄的定量检测模式、实施方法和面临的挑战, 为实现多目标分析和现场快速定性定量检测提供了参



考。Gorji 等<sup>[47]</sup>结合深度学习和荧光成像技术,自动识别肉类胴体上的粪便污染。首先利用 Efficient-Net-B0<sup>[48]</sup>模型对肉面图像进行污染区域检测,并使用 U-Net<sup>[49]</sup>模型精确分割污染区域, Efficient-Net-B0 模型在区分清洁和污染区域时达到 97.32% 的准确率, U-Net 模型在分割粪便残留区域时获得 89.34% 的交并比 (IoU)。Viejo 等<sup>[50]</sup>提出一种基于人工智能的新型系统,结合机器人技术、电子鼻和机器学习等技术,能够实现客观和低成本啤酒质量评估,并在发酵识别、消费者偏好与接受度、理化分析和比色分析方面表现出较高的准确性,同时还可与区块链技术相结合实现全产业链的透明化追溯。Ekramirad 等<sup>[51]</sup>研究了一种评估鸡肉片木质胸肌病 (WB) 的无损检测方法。首先利用光学相干断层扫描 (OCT), 以微米级分辨率成像鸡肉组织的亚表面微结构, 然后使用机器学习模型分析这些特征, 并按 WB 的严重程度对鸡肉片分类。结果表明该方法在区分正常与不同程度木质化鸡胸肉的分类中表现出高效性, 最高准确率分别达到 100%, 93.3%, 95% 和 85%。展示出 OCT 作为一种快速、无创的皮下成像工具在家禽行业质量控制中的潜力。

## 2.2 基于不同检测算法的食品无损检测技术

食品无损检测中使用的检测算法主要包括传统图像处理算法、传统机器学习算法和现代深度学习算法。这些算法各有其独特的优势与应用领域。传统图像处理算法侧重于利用图像的像素信息, 通过阈值分割、直方图变换和滤波等技术实现目标的检测和分类, 不需要大量数据进行训练, 然而准确率不高, 且应用场景有限。传统机器学习算法则通过特征提取和在一定规模的数据集上训练模型, 实现对食品品质的检测, 拓宽无损检测应用场景的同时提高了准确率。随着深度学习技术的进步, 现代深度学习算法逐渐成为食品无损检测的主流方法, 依托其强大的数据处理能力和高度的自动化特性, 为复杂的食品检测任务提供了创新性的解决方案。通过这些技术的应用, 食品无损检测不仅实现了精度的提升, 也推动了检测过程的自动化和实时化, 为食品质量控制和安全保障提供了有力支持。

2.2.1 传统图像处理算法 Chen 等<sup>[52]</sup>提出一种用于自动化去脏机器人系统中的禽类内脏分割方法, 其采用改进后的区域主动轮廓法, 并通过色彩空间转换和上、下帽变换等图像处理操作<sup>[14]</sup>, 精确去除图像背景噪声并提取禽类内脏轮廓, 试验结果表明: 该方法在心肝区域和脂肪区域的识别准确率分别为 98.98% 和 99.75%, 整体内脏识别准确率为 98.96%。Patel 等<sup>[53]</sup>开发了一种基于单色相机的计算机视觉系统, 用于检测芒果表面的常见缺陷。该系统采用阈值处理、滤波等预处理技术, 在对图像进行亮度提升、对比度增强和伽玛值调整后, 利用 Otsu 阈值<sup>[14]</sup>法分割水果表面的缺陷, 并通过局部阈值方法进行背景校正以消除非均匀光照影响, 然后通过查找表均衡像素强度, 并使用粒子滤波器提取缺陷区域, 最终检测到的缺陷区域的平均检测准确率为 88.75%, 效率为 97.88%。Tian 等<sup>[54]</sup>提出一种结合近红外相机成像技术和自适应阈值分割算法的早期苹果瘀伤检测方法, 从而解决苹果在采摘、包装和运输过程中易受瘀伤且难以人工筛选的问题。首先构建了近红外相机成像系统, 分别获取健康苹果、单个和多个瘀伤苹果在 30 min 内的全波段图像, 然后提出一种自适应阈值分割算法, 并采用高通滤波、特征提取、自适应阈值分割和霍夫圆检测等图像处理算法对获取的全波段图像进行处理, 以应对苹果果柄和萼片对早期瘀伤检测的干扰。结果表明, 所提出的算法对健康苹果样本的检测准确率为 95.56%, 对早期瘀伤样本的 F1 得分为 94.70%, 优于常用的图像分割算法如 Otsu 和固定阈值法, 为快速和无损检测农产品质量提供了一种新思路。

2.2.2 传统机器学习算法 Zhang 等<sup>[29]</sup>利用可见-近红外高光谱反射成像技术, 提出识别 7 种常见橙子表皮缺陷和橙子早期腐烂的方法。首先采用分段主成分分析技术进行数据降维, 并选取 540, 623, 675, 805 nm 和 975 nm 处的 5 个特征波长图像, 通过均值归一化方法校正橙子表面的不均匀光照分布, 然后采用分水岭分割算法检测缺陷橙子和分类早期腐烂橙子, 结果表明: 在 397 个独立测试样本中, 正常与缺陷橙子的总体分类准确率为 97.73%, 腐烂橙子的分类准确率为 100%。

Thanasarn 等<sup>[55]</sup>开发了一种基于灰度图像参数的图像处理方法来检测未正确去除肠线的虾。该方法通过对 200 张虾的图像进行一系列的图像处理操作,然后提取形状和图像直方图等参数,利用线性判别分析和支持向量机对图像中的虾是否被正确去除肠线进行分类,其中支持向量机的分类准确率超过 98%,为实现全自动虾质量检测提供了参考。Mandal 等<sup>[56]</sup>提出一种计算机视觉框架,通过多重随机森林算法检测姜黄粉中是否存在苏丹红-I 掺假,解决了现有检测方法测试时间长,费用高和移动性差的问题,试验结果显示,该框架的分类准确率超过 99%,预测的相关系数( $R^2$ )高达 0.99。Shen 等<sup>[57]</sup>提出一种基于支持向量机的新型机器视觉算法,用于估算马铃薯的形状和大小。首先通过灰度和线性变换、图像滤波、实体和边界检测等操作处理原始图像,然后提取几何特征、图像小波矩和边界分形维数,并利用支持向量机对其进行分类。在 64 个马铃薯样本上的试验结果表明,基于多项式核函数的支持向量机在形状辨别上准确率为 88.89%,基于线性核函数的支持向量机在大小评估上准确率为 87.41%。Sarkar 等<sup>[58]</sup>采用人工智能技术检测红辣椒粉中的掺假情况,利用含有不同比例砖粉掺杂的红辣椒粉图像数据集进行训练,应用 RGB、HSV、Lab 和 YCbCr 等颜色空间滤波及均值和直方图特征提取技术,结果显示在分类任务中,使用 HSV 颜色空间直方图特征的 Cat Boost<sup>[59]</sup>分类器表现最佳,在回归任务中,使用 Lab 颜色空间直方图特征的 Extra Tree<sup>[60]</sup>回归器表现最佳。Bhargava 等<sup>[61]</sup>提出一种基于机器学习和计算机视觉的算法,用于检测红茶发酵程度(发酵、过度发酵和未发酵),首先通过高斯滤波对图像进行预处理,然后提取纹理、颜色、几何形状、Laws 纹理能量、梯度直方图和离散小波变换等特征,并通过 PCA 进行特征选择,最后使用 k-NN、SRC 和 SVM 进行分类,结果表明 SVM 的检测准确率最高,为 98.75%。

2.2.3 现代深度学习算法 Roy 等<sup>[62]</sup>提出一种基于深度学习的算法,通过语义分割检测腐烂或新鲜的水果,主要应用于苹果的表皮缺陷检测。该研究采用 UNet 和改进的增强版 UNet (En-UNet)对水果图片进行分割,试验结果表明,En-UNet 模型

的准确率为 97.54%,高于 UNet 的准确率为 (95.36%),且平均 IoU 得分为 0.866。Syed-Ab-Rahman 等<sup>[63]</sup>提出一种基于端到端深度学习的模型用于柑橘病害的检测和分类,该模型通过两阶段深度卷积神经网络对图像进行处理:第 1 阶段使用区域建议网络提出潜在病变区域,第 2 阶段利用分类器对最可能的病变区域进行分类,试验结果表明:该模型的检测准确率为 94.37%,平均精度为 95.8%,能够有效识别并区分柑橘黑斑病、柑橘细菌性溃疡病和黄龙病 3 种病害。Maurya 等<sup>[64]</sup>提出一种基于深度学习的计算机视觉框架,用于检测富含碳水化合物的油炸食品中的丙烯酰胺。研究比较了无迁移学习的六层卷积神经网络(CNN)与采用迁移学习的模型在分类任务中的表现,试验结果表明,无迁移学习的六层 CNN 平均  $F1$  得分为 0.9251,而采用迁移学习的方法平均  $F1$  得分达到 0.9644。Sundaram 等<sup>[65]</sup>提出一种基于模糊池化改进的 ThinNet 架构用于柠檬分类。与传统池化相比,模糊池化基于模糊逻辑提升了 CNN 的准确性,在 CIFAR-10<sup>[66]</sup>和 SVHN<sup>[67]</sup>数据集上的单层 CNN 测试中分别达到 92%和 97%的分类准确率。将模糊池化层应用于 ThinNet 架构,并使用反向传播方法进行训练,在柠檬数据集上的试验表明,该方法将柠檬分为优、中、差 3 类,最终分类准确率达 97%,优于先前的 CNN 架构。Shao 等<sup>[68]</sup>提出一种名为 Swin-Nutrition 的端到端食品营养成分无损检测方法,结合深度学习和无损检测技术(NDDT),用于评估食品营养成分。该方法利用 Swin Transformer 作为骨干网络进行食品图像特征提取,并通过特征融合模块(FFM)获取辨别性特征表示,提升预测准确性。试验结果表明,在 Nutrition5k 数据集上,Swin-Nutrition 方法对卡路里、质量、脂肪、碳水化合物和蛋白质的平均绝对误差百分比(PMAE)分别为 15.3%,12.5%,22.1%,20.8%和 15.4%,展示了该方法的有效性和高效性。Chen 等<sup>[69]</sup>提出一种基于深度学习的核桃仁智能分级方法,利用结合空间注意力机制和 SE 网络<sup>[70]</sup>结构的深度学习模型,通过机器视觉提高核桃仁分级的准确性和效率,试验结果表明,结合空间注意力和空间增强方法的 ResNet152V2-SA-SE 模型在测试集上的最高准确率为 92.2%,



显著优于 ResNet152V2、EfficientNetB7 和 VGG19 模型。Feng 等<sup>[71]</sup>提出一种基于计算机视觉的 YOLOv5n-se 模型检测大西洋鲑鱼中残留物的方法,通过在 YOLOv5n 中引入 SE 注意机制,解决了传统检测方法需要大型或特定仪器的问题,实现了快速、低成本和实时的残留物检测,试验结果表明改进的 YOLOv5n-se 模型的 *F1* 分数为 0.842,平均精度 (mAP50) 为 0.865,优于 YOLOv5n、YOLOv5s、YOLOv5m、YOLOv5l、YOLOv8n 和 Faster RCNN 等模型,且模型权重仅为 3.75 MB,可有效区分反光与鱼鳞,并避免将脂肪误检为骨骼。Sajitha 等<sup>[72]</sup>提出一种使用知识嵌入的图卷积神经网络(KEGCNN)检测香蕉质量的智能农业应用,其首先把香蕉图像转化为知识图谱,接着运用知识嵌入技术将知识图谱中的信息映射到连续向量空间,然后利用图卷积神经网络(GCNN)分析图结构以进行准确检测,KEGCNN 在捕捉不同节点之间的上、下文交互方面特别有效,能够以无监督方式从图中的数据中学习,使其能利用图结构中的固有知识,证明其在香蕉水果质量检测中的适用性。

### 3 机器视觉在食品无损检测中的技术挑战

虽然机器视觉技术在食品无损检测领域取得一定的进展,但其发展仍受到若干技术瓶颈的制约。首先,缺乏大规模公开数据集和标准化的评

测基准是该领域研究发展的主要障碍。与通用视觉任务相比,食品无损检测领域缺乏广泛认可、大规模的数据集和评测基准,如 ImageNet<sup>[73]</sup>和 COCO<sup>[74]</sup>,这限制了研究人员间的交流与合作,并影响算法性能的公正比较。目前大多数研究工作都是在规模较小的私有数据集上进行的,且由于不同研究团队采用的成像设备不同,采集到的图像数据缺乏统一标准,无法整合成通用的大规模数据集,限制了机器学习和深度学习模型在泛化能力上的提升。

此外,通用视觉任务与食品无损检测任务之间存在着显著的域间差异,导致某些检测模型在通用视觉任务上表现优秀,而在食品无损检测任务上的表现不佳。为了说明这一现象,本文选取 6 种深度学习模型,并在 4 个公开的食品无损检测数据集上分别进行训练和测试。训练轮次为 120 轮,测试指标为 top-1 准确率,选取所有训练轮次中最高的 top-1 准确率作为模型在特定数据集上的性能指标。结果如表 1 所示,虽然 EVA02 和 ConvNeXt V2 在通用视觉任务基准测试中表现良好,但是在食品无损检测的特定数据集上,其整体性能却不及其它模型。在开发新的食品无损检测方法时,应当特别考虑该领域的的数据特点,有针对性地设计算法和模型。同时这也体现食品无损检测领域对于构建数据集和评测基准的迫切需求,从而促进算法的不断完善。

表 1 不同模型在食品无损检测数据集上的表现

Tabel 1 Performance of different models on food nondestructive testing datasets

模型	参数量/ 百万	Top-1 准确率/%				
		ImageNet1K	Fruit Quality <sup>[75]</sup>	Meat Quality <sup>[76]</sup>	Potato Disease <sup>[77]</sup>	Banana Disease <sup>[78]</sup>
DINO V2 <sup>[79]</sup>	304	84.50	30.38	92.89	37.37	30.72
EVA02 <sup>[80]</sup>	305.08	89.65	59.63	97.37	37.37	67.85
ConvNeXt V2 <sup>[81]</sup>	197.96	88.18	30.38	50.00	37.37	34.55
EfficientNet V2 <sup>[82]</sup>	118.52	85.43	94.12	99.47	100.00	98.93
GLIP <sup>[83]</sup>	196.74	—	99.82	99.74	99.42	98.84
RIFormer <sup>[84]</sup>	73.47	83.70	83.33	96.58	37.37	41.67

### 4 机器视觉在食品无损检测中的研究趋势和展望

与现代深度学习技术的紧密结合正成为机器视觉在食品无损检测中的一个重要发展方向。传统的图像处理 and 机器学习方法虽在某些特定的应

用场景中取得一定的成果,但其在复杂的食品无损检测任务中仍表现不佳。而以卷积神经网络、扩散模型以及自监督学习等方法为代表的现代深度学习技术,不仅能够从大规模数据中自主学习丰富的知识表征,还可以通过迁移学习和模型微调

等手段,有效缓解数据量不足和域间差异等问题,提高机器视觉在多种食品检测场景下的泛化能力。为了应对食品无损检测中可能存在的多样化挑战,可以通过数据增强和生成对抗网络(GANs)等手段补充训练数据,同时通过迁移学习和模型微调,优化深度学习模型在不同食品类型中的表现。此外,深度学习模型的轻量化也至关重要,应注重将深度学习技术应用到嵌入式设备中,确保模型在低资源环境下的高效运行,满足实时检测和成本控制的需求。

多模态数据的融合与分析是食品无损检测领域的另一个重要研究方向。食品无损检测通常涉及多种成像技术,如可见光成像、近红外光谱成像、超声波成像和X射线成像等,每种成像技术各有优劣。多模态数据融合可以通过将不同成像技术获取的信息进行整合与分析,从而弥补单一检测方法的不足,提供更加全面和准确的检测结果。近年来,深度学习方法在多模态数据融合中的应用虽取得显著进展<sup>[83,85-86]</sup>,但仍需进一步优化融合算法,以更好地处理异质数据。在这一过程中,应关注如何设计和研发能够支持多种成像技术的融合平台,整合不同类型的传感器数据,提升检测的精度和可靠性。此外,融合算法需要经过大量实际生产环境的验证,确保其能够应对不同食品种类、生产流程以及质量控制的需求,真正实现从实验室到生产线的无缝对接。

面向通用生产生活场景的检测方法或将成为未来研究的重点方向之一。随着食品安全问题的日益突出,食品无损检测的应用场景正从实验室走向生产和生活场景。这种变化不仅对检测方法的精度和可靠性提出更高的要求,还需要检测方法兼顾实时性、便携性和低成本等特点,因此低成本嵌入式检测系统将成为重要发展方向,尤其是结合物联网技术实现食品质量的实时监控和远程评估,可以显著提高生产效率并降低人工干预。在此基础上,智能化和自动化的检测系统将成为关键趋势,行业可以通过与机器人技术结合,推动从检测到分拣的全流程自动化,进一步提升生产线的工作效率和食品质量管理的精准度。此外,随着云计算和大数据技术的成熟,食品生产过程中的每一个环节都可以实现智能决策和实时监控,从

而在保证食品质量的同时降低成本,提高食品安全管理水平。

## 5 结语

本文综述了机器视觉在食品无损检测领域的应用与发展。随着机器视觉技术的迅速发展,其在食品无损检测中的广泛应用正在成为一种趋势。从最初仅能应用于简单场景,到逐渐扩展到复杂多变的检测环境,基于机器视觉的食品无损检测的精确性和效率都在不断提升。然而,当前的研究仍面临着一些技术挑战,如大规模公开数据集的匮乏,领域间的差异性对模型泛化能力的影响等。这些问题限制了机器视觉在食品无损检测中的进一步推广与应用。未来的研究在对成像技术和检测算法持续优化的同时,进一步挖掘食品质量多模态数据的潜力,开发更加高效的检测系统,以满足实际生产中的需求。总而言之,机器视觉技术在食品无损检测中的应用具有广阔前景,为保障食品安全、提高食品质量提供更有力的技术支持。

## 参 考 文 献

- [1] 费威, 马跃. 我国进口食品不合格率的影响因素[J]. 华南农业大学学报(社会科学版), 2016, 15(5): 99-109.  
FEI W, MA Y. Factors influencing the non-conformance rate of imported food in China[J]. Journal of South China Agricultural University (Social Science Edition), 2016, 15(5): 99-109.
- [2] 庆兆坤. 苹果无损检测的可见-近红外激光漫反射光谱图像技术研究[D]. 北京: 中国农业大学, 2007.  
QING Z S. Research on visible-near infrared laser diffuse reflection spectroscopy technology for non-destructive detection of apples[D]. Beijing: China Agricultural University, 2007.
- [3] CHEN C. CiteSpace II: Detecting and visualizing emerging trends and transient patterns in scientific literature[J]. Journal of the American Society for Information Science and Technology, 2006, 57(3): 359-377.
- [4] 于文博. 基于峰值密度聚类的高光谱图像分析方法研究[D]. 郑州: 郑州大学, 2017.  
YU W B. Research on hyperspectral image analysis

- method based on peak density clustering [D]. Zhengzhou: Zhengzhou University, 2017.
- [5] BHARGAVA A, BANSAL A. Automatic detection and grading of multiple fruits by machine learning[J]. *Food Analytical Methods*, 2020, 13(3): 751–761.
- [6] JAIN A K, DUBES R C. Algorithms for clustering data [M]. Hoboken, NJ, USA: Prentice–Hall, Inc., 1988: 10–15.
- [7] COVER T, HART P. Nearest neighbor pattern classification[J]. *IEEE Transactions on Information Theory*, 1967, 13(1): 21–27.
- [8] CORTES C, VAPNIK V. Support–vector networks[J]. *Machine Learning*, 1995, 20(3): 273–297.
- [9] WRIGHT J, YANG A Y, GANESH A, et al. Robust face recognition via sparse representation [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2009, 31(2): 210–227.
- [10] MINSKY M L, PAPERT S A. Perceptrons: an introduction to computational geometry [M]. 5th ed. Cambridge, MA, USA: MIT Press, 1990: 227–246.
- [11] YEE C K, YEO Y H, CHENG L H, et al. Impurities detection in edible bird’s nest using optical segmentation and image fusion [J]. *Machine Vision and Applications*, 2020, 31(7/8): 68.
- [12] SONG W R, YUN Y H, WANG H, et al. Smartphone detection of minced beef adulteration [J]. *Microchemical Journal*, 2021, 164: 106088.
- [13] MANDAL D, CHATTERJEE A, TUDU B P. A deep neural network and random forests driven computer vision framework for identification and prediction of metanil yellow adulteration in turmeric powder [J]. *Concurrency and Computation: Practice and Experience*, 2022, 34(1): e6500.
- [14] LUKAC R, PLATANIOTIS K N. Color image processing: methods and applications [M]. Boca Raton, FL, USA: CRC Press, 2018: 237–273.
- [15] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient–based learning applied to document recognition [J]. *Proceedings of the IEEE*, 1998, 86(11): 2278–2324.
- [16] RIGATTI S J. Random forest [J]. *Journal of Insurance Medicine*, 2017, 47(1): 31–39.
- [17] GAO Z C, CHEN S S, HUANG J X, et al. Real–time quantitative detection of hydrocolloid adulteration in meat based on swin transformer and smartphone [J]. *Journal of Food Science*, 2024, 89(7): 4359–4371.
- [18] LIU Z, LIN Y T, CAO Y, et al. Swin transformer: hierarchical vision transformer using shifted windows [C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV). Montreal, QC, Canada: IEEE, 2021: 9992–10002.
- [19] YILDIZ M B, YASIN E T, KOKLU M. Fisheye freshness detection using common deep learning algorithms and machine learning methods with a developed mobile application [J]. *European Food Research and Technology*, 2024, 250(7): 1919–1932.
- [20] KOONCE B. SqueezeNet [M]//Koonce B. Convolutional neural networks with swift for tensorflow. Berkeley, CA, USA: Apress, 2021: 73–85.
- [21] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large–scale image recognition [C]//Bengio Y, LeCun Y. 3rd International Conference on Learning Representations. San Diego, CA, USA: ICLR, 2015.
- [22] SONG C X, LIU J M, WANG C Q, et al. Rapid identification of adulterated rice based on data fusion of near–infrared spectroscopy and machine vision [J]. *Journal of Food Measurement and Characterization*, 2024, 18(5): 3881–3892.
- [23] PAVIA D L, LAMPMAN G M, KRIZ G S, et al. Introduction to spectroscopy [M]. Boston, MA, USA: Cengage Learning, 2008: 14–19.
- [24] YAN J C, LEE J C, LIU L, et al. A novel method for multi–pollutant monitoring in water supply systems using chemical machine vision [J]. *Environmental Science and Pollution Research*, 2024, 31(18): 26555–26566.
- [25] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA: IEEE, 2016: 770–778.
- [26] YIN J F, HAMEED S, XIE L J, et al. Non–destructive detection of foreign contaminants in toast bread with near infrared spectroscopy and computer vision techniques [J]. *Journal of Food Measurement and Characterization*, 2021, 15(1): 189–198.
- [27] SCHAFFER R. What is a savitzky–golay filter? [lecture notes] [J]. *IEEE Signal Processing Magazine*, 2011, 28(4): 111–117.
- [28] ZHANG H L, CHEN Y, LIU X M, et al. Identifi-



- cation of common skin defects and classification of early decayed citrus using hyperspectral imaging technique[J]. *Food Analytical Methods*, 2021, 14(6): 1176–1193.
- [29] BENOUIS M, MEDUS L D, SABAN M, et al. Food tray sealing fault detection in multi-spectral images using data fusion and deep learning techniques[J]. *Journal of Imaging*, 2021, 7(9): 186.
- [30] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. *Neural Computation*, 2006, 18(7): 1527–1554.
- [31] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: Theory and applications[J]. *Neurocomputing*, 2006, 70(1/2/3): 489–501.
- [32] VINCENT P, LAROCHELLE H, LAJOIE I, et al. Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion[J]. *Journal of Machine Learning Research*, 2010, 11(12): 3371–3408.
- [33] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. *Nature*, 2015, 521(7553): 436–444.
- [34] XIE A G, SUN J, WANG T M, et al. Visualized detection of quality change of cooked beef with condiments by hyperspectral imaging technique[J]. *Food Science and Biotechnology*, 2022, 31(10): 1257–1266.
- [35] YANG R L, LIAO T J, ZHAO P R, et al. Identification of citrus diseases based on AMSR and MF-RANet[J]. *Plant Methods*, 2022, 18(1): 113.
- [36] LEE C H, SHIH J L, LIEN C C, et al. Adaptive multiscale retinex for image contrast enhancement[C]//2013 International Conference on Signal-Image Technology & Internet-Based Systems. Kyoto, Japan: IEEE, 2013: 43–50.
- [37] MNH V, HEES N, GRAVES A, et al. Recurrent models of visual attention[C]//Proceedings of the 27th International Conference on Neural Information Processing Systems – Volume 2. Cambridge, MA, USA: MIT Press, 2014: 2204–2212.
- [38] GUO C X, FAN B, ZHANG Q, et al. AugFPN: Improving multi-scale feature learning for object detection [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA, USA: IEEE, 2020: 12592–12601.
- [39] STASENKO N, SHUKHRATOV I, SAVINOV M, et al. Deep learning in precision agriculture: Artificially generated VNIR images segmentation for early postharvest decay prediction in apples[J]. *Entropy*, 2023, 25(7): 987.
- [40] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks[J]. *Communications of the ACM*, 2020, 63(11): 139–144.
- [41] WANG T C, LIU M Y, ZHU J Y, et al. High-resolution image synthesis and semantic manipulation with conditional GANs [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA: IEEE, 2018: 8798–8807.
- [42] HE K M, GKIOXARI G, DOLLAR P, et al. Mask R-CNN [C]//2017 IEEE International Conference on Computer Vision (ICCV). Venice, Italy: IEEE, 2017: 2980–2988.
- [43] POURDARBANI R, SABZI S, ZOHRABI R, et al. Comparison of 2D and 3D convolutional neural networks in hyperspectral image analysis of fruits applied to orange bruise detection[J]. *Journal of Food Science*, 2023, 88(12): 5149–5163.
- [44] GAO T Y, ZHANG S J, SUN H X, et al. Mass detection of walnut based on X-ray imaging technology[J]. *Journal of Food Process Engineering*, 2022, 45(8): e14034.
- [45] ALPAYDIN E. *Machine learning* [M]. Cambridge, MA, USA: MIT Press, 2021: 160–187.
- [46] 李辉, 盈盈, 曹振, 等. 基于智能手机拍照判读的侧流免疫层析快速检测技术研究进展[J]. *分析化学*, 2022, 50(1): 1–11.
- LI H, YING Y, CAO Z, et al. Research progress on rapid detection technology based on smartphone and lateral flow immunoassay[J]. *Chinese Journal of Analytical Chemistry*, 2022, 50(1): 1–11.
- [47] GORJI H T, SHAHABI S M, SHARMA A, et al. Combining deep learning and fluorescence imaging to automatically identify fecal contamination on meat carcasses[J]. *Scientific Reports*, 2022, 12(1): 2392.
- [48] TAN M X, LE Q V. EfficientNet: Rethinking model scaling for convolutional neural networks[C]//Chaudhuri K, Salakhutdinov R. Proceedings of the 36th International Conference on Machine Learning: Vol. 97. Long Beach, CA, USA: PMLR, 2019: 6105–6114.
- [49] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image seg-

- mentation[C]//Medical image computing and computer-assisted intervention –MICCAI 2015: Vol. 9351. Munich, Germany: Springer International Publishing, 2015: 234–241.
- [50] GONZALEZ VIEJO C, FUENTES S. Low-cost methods to assess beer quality using artificial intelligence involving robotics, an electronic nose, and machine learning[J]. *Fermentation*, 2020, 6(4): 104.
- [51] EKRAMIRAD N, YOON S C, BOWKER B C, et al. Nondestructive assessment of woody breast myopathy in chicken fillets using optical coherence tomography imaging with machine learning [J/OL]. *Research Square preprint*: 3229288, 2023. <https://www.researchsquare.com/article/rs-3229288/v1>.
- [52] CHEN Y, FENG K, LU J J, et al. Machine vision on the positioning accuracy evaluation of poultry viscera in the automatic evisceration robot system[J]. *International Journal of Food Properties*, 2021, 24(1): 933–943.
- [53] PATEL K K, KAR A, KHAN M A. Monochrome computer vision for detecting common external defects of mango[J]. *Journal of Food Science and Technology*, 2021, 58(12): 4550–4557.
- [54] TIAN M M, ZHANG J C, YANG Z R, et al. Detection of early bruises on apples using near - infrared camera imaging technology combined with adaptive threshold segmentation algorithm[J]. *Journal of Food Process Engineering*, 2024, 47(1): e14500.
- [55] THANASARN N, CHAIPRAPAT S, WAIYAKAN K, et al. Automated discrimination of deveined shrimps based on grayscale image parameters [J]. *Journal of Food Process Engineering*, 2019, 42(4): e13041.
- [56] MANDAL D, CHATTERJEE A, TUDU B. A color channel based on multiple Random Forest coupled with a computer vision technique for the detection and prediction of Sudan dye - I adulteration in turmeric powder[J]. *Color Research & Application*, 2022, 47(2): 388–400.
- [57] SHEN D L, ZHANG S F, MING W Y, et al. Development of a new machine vision algorithm to estimate potato's shape and size based on support vector machine[J]. *Journal of Food Process Engineering*, 2022, 45(3): e13974.
- [58] SARKAR T, CHOUDHURY T, BANSAL N, et al. Artificial intelligence aided adulteration detection and quantification for red chilli powder[J]. *Food Analytical Methods*, 2023, 16(4): 721–748.
- [59] PROKHORENKOVA L, GUSEV G, VOROBEV A, et al. CatBoost: Unbiased boosting with categorical features [C]//Proceedings of the 32nd International Conference on Neural Information Processing Systems. Red Hook, NY, USA: Curran Associates Inc., 2018: 6639–6649.
- [60] GEURTS P, ERNST D, WEHENKEL L. Extremely randomized trees[J]. *Machine Learning*, 2006, 63: 3–42.
- [61] BHARGAVA A, BANSAL A, GOYAL V, et al. Machine learning & computer vision-based optimum black tea fermentation detection[J]. *Multimedia Tools and Applications*, 2023, 82(28): 43335–43347.
- [62] ROY K, CHAUDHURI S S, PRAMANIK S. Deep learning based real-time Industrial framework for rotten and fresh fruit detection using semantic segmentation [J]. *Microsystem Technologies*, 2021, 27(9): 3365–3375.
- [63] SYED -AB -RAHMAN S F, HESAMIAN M H, PRASAD M. Citrus disease detection and classification using end-to-end anchor-based deep learning model[J]. *Applied Intelligence*, 2022, 52(1): 927–938.
- [64] MAURYA R, SINGH S, PATHAK V K, et al. Computer-aided automatic detection of acrylamide in deep-fried carbohydrate-rich food items using deep learning[J]. *Machine Vision and Applications*, 2021, 32(4): 79.
- [65] MOHANA SUNDARAM K D, SHANKAR T, SUDHAKAR REDDY N. A novel fuzzy pooling based modified ThinNet architecture for lemon fruit classification[J]. *Journal of Intelligent & Fuzzy Systems*, 2022, 43(5): 6877–6891.
- [66] KRIZHEVSKY A, HINTON G. Learning multiple layers of features from tiny images[R]. Toronto, ON, Canada: University of Toronto, 2009.
- [67] NETZER Y, WANG T, COATES A, et al. Reading digits in natural images with unsupervised feature learning [C]//NIPS workshop on deep learning and unsupervised feature learning. Granada, Spain: MIT Press, 2011, 2011(2): 4.
- [68] SHAO W J, HOU S J, JIA W K, et al. Rapid non-destructive analysis of food nutrient content us-

- ing swin-nutrition[J]. *Foods*, 2022, 11(21): 3429.
- [69] CHEN S W, DAI D, ZHENG J, et al. Intelligent grading method for walnut kernels based on deep learning and physiological indicators[J]. *Frontiers in Nutrition*, 2023, 9: 1075781.
- [70] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Salt Lake City, USA: Ieee, 2018: 7132-7141.
- [71] FENG Y, LI X X, ZHANG Y G, et al. Detection of Atlantic salmon residues based on computer vision[J]. *Journal of Food Engineering*, 2023, 358: 111658.
- [72] SAJITHA P, ANDRUSHIA A D, MOSTAFA N, et al. Smart farming application using knowledge embedded-graph convolutional neural network (KEGCNN) for banana quality detection[J]. *Journal of Agriculture and Food Research*, 2023, 14: 100767.
- [73] DENG J, DONG W, SOCHER R, et al. Imagenet: A large-scale hierarchical image database [C]//2009 IEEE conference on computer vision and pattern recognition. Miami, Florida: Ieee, 2009: 248-255.
- [74] LIN T Y, MAIRE M, BELONGIE S, et al. Microsoft coco: Common objects in context [C]//Computer Vision-ECCV 2014: Vol. 8693. Zurich, Switzerland: Springer International Publishing, 2014: 740-755.
- [75] MESHARAM V, PATIL K. FruitNet: Indian fruits image dataset with quality for machine learning applications[J]. *Data in Brief*, 2022, 40: 107686.
- [76] ULUCAN O, KARAKAYA D, TURKAN M. Meat quality assessment based on deep learning [C]//2019 Innovations in Intelligent Systems and Applications Conference (ASYU). Izmir, Turkey: Ieee, 2019: 1-5.
- [77] ARSHAGHI A, ASHOURIAN M, GHABELI L. Potato diseases detection and classification using deep learning methods[J]. *Multimedia Tools and Applications*, 2023, 82(4): 5725-5742.
- [78] THAKAR A. Banana Classification Dataset [Z/OL]. (2022-10-23) [2024-10-25] <https://www.kaggle.com/datasets/atrithakar/banana-classification>.
- [79] OQUAB M, DARCET T, MOUTAKANNI T, et al. DINOv2: Learning robust visual features without supervision [J/OL]. *Transactions on Machine Learning Research*, 2024 [2024-10-25]. <https://openreview.net/forum?id=a68SUt6zFt>.
- [80] FANG Y X, SUN Q, WANG X G, et al. Eva-02: A visual representation for neon genesis[J]. *Image and Vision Computing*, 2024, 149: 105171.
- [81] WOO S, DEBNATH S, HU R, et al. Convnext v2: Co-designing and scaling convnets with masked autoencoders [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver Canada: Ieee, 2023: 16133-16142.
- [82] TAN M X, LE Q Ü. Efficientnetv2: Smaller models and faster training [C]//Meila M R N, Zhang T. Proceedings of the 38th International Conference on Machine Learning: Vol. 139. Virtual Event: PMLR, 2021: 10096-10106.
- [83] LI L H, ZHANG P, ZHANG H, et al. Grounded language-image pre-training [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). New Orleans, Louisiana: IEEE, 2022: 10965-10975.
- [84] WANG J H, ZHANG S Y, LIU Y, et al. RIFormer: Keep your vision backbone effective but removing token mixer [C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Vancouver, Canada: IEEE, 2023: 14443-14452.
- [85] RADFORD A, KIM J W, HALLACY C, et al. Learning transferable visual models from natural language supervision [C]//International Conference on Machine Learning. Virtual only, IMLS, 2021: 8748-8763.
- [86] LI J N, LI D X, XIONG C M, et al. Blip: Bootstrapping language-image pre-training for unified vision-language understanding and generation [C]//International conference on machine learning, Baltimore, USA: IMLS, 2022: 12888-12900.



## Research Progress in the Application of Machine Vision in Food Nondestructive Detection

Tang Yansong, Xu Ruihao, Wang Sujia

*(Tsinghua Shenzhen International Graduate School, Shenzhen 518055, Guangdong)*

**Abstract** With the increasing global demand for food consumption, food nondestructive detection technology has become increasingly important in food quality control and safety assurance. This paper systematically reviews the application and development trends of machine vision technology in food nondestructive detection. By analyzing current literature, various imaging technologies including RGB imaging, multispectral imaging, hyperspectral imaging, and Raman spectroscopy imaging, as well as detection algorithms such as traditional image processing, machine learning, and deep learning, are discussed in the context of food nondestructive detection. The paper also examines the technical challenges of machine vision in food nondestructive detection, such as the lack of datasets and the insufficient generalization ability of models in universal scenarios. Based on the current state of research, the paper envisions future research directions, proposing possible development paths such as multimodal data fusion, embedded detection systems, and close integration with deep learning technologies. This paper aims to provide a comprehensive research review for the development of food nondestructive detection technology and offer guidance and direction for technological innovation in practical applications.

**Keywords** food nondestructive detection; food safety; machine vision; machine learning; deep learning