

机器学习在生鲜农产品质量与安全快速无损智能检测中的应用与展望

成军虎^{1*}, 曾弘¹, 郭鸿樟¹, 林远东¹, 曾新安², 于重重³

(1. 华南理工大学食品科学与工程学院, 广东广州 510640)(2. 佛山大学食品科学与工程学院, 广东佛山 528225)

(3. 北京工商大学计算机与人工智能学院, 北京 102488)

摘要: 随着现代食品工业的发展和全球化进程的推进, 食品质量与安全日益成为公众关注的焦点。果蔬、肉品、水产等生鲜农产品采后易腐败、难保存、损失大, 实现对生鲜农产品质量与安全的实时、准确且快速的检测对食品工业的发展和消费者权益的保障具有重要的科学意义。传统的检测方法大多存在着检测要求条件较高、检测周期长、检测会对样本造成破坏等问题, 无法在食品工业中实现大规模运用。随着人工智能和计算机技术的快速发展, 具有强大预测能力和高准确性的机器学习模型已逐渐应用于生鲜农产品质量与安全的检测中, 有效克服了新兴无损检测技术检测过程中数据冗余且无法大量处理的缺点。该文介绍了机器学习及深度学习算法基本理论方法, 分析了无损检测技术融合机器学习在生鲜农产品质量与安全检测中的应用与挑战, 为未来食品品质与安全的精准实时监控提供了重要理论支撑与方法指导。

关键词: 生鲜农产品; 无损检测; 机器学习; 深度学习

文章编号: 1673-9078(2025)12-334-345

DOI: 10.13982/j.mfst.1673-9078.2025.12.1576

Non-destructive Intelligent Testing of the Quality and Safety of Fresh Agricultural Products Based on Machine Learning: Principles, Challenges, and Applications

CHENG Junhu^{1*}, ZENG Hong¹, GUO Hongzhang¹, LIN Yuandong¹, ZENG Xin'an², YU Chongchong³

(1.School of Food Science and Engineering, South China University of Technology, Guangzhou 510640, China)

(2.College of Food Science and Engineering, Foshan University, Foshan 528225, China)

(3.College of Computer and Artificial Intelligence, Beijing Technology and Business University, Beijing 102488, China)

Abstract: With the development of the modern food industry and the advancement of globalization, food quality and safety have emerged as major concerns for the public. In the context of expanding global trade and supply chains, fresh agricultural products, including fruits and vegetables, meat, and aquatic products, encounter considerable challenges related to perishability and the preservation. It is imperative to develop accurate and rapid quality and safety testing to improve monitoring and provide consumer protection. Traditional detection methods, such as gas chromatography, high-performance liquid chromatography, and

引文格式:

成军虎,曾弘,郭鸿樟,等.机器学习在生鲜农产品质量与安全快速无损智能检测中的应用与展望[J].现代食品科技,2025, 41(12):334-345.

CHENG Junhu, ZENG Hong, GUO Hongzhang, et al. Non-destructive intelligent testing of the quality and safety of fresh agricultural products based on machine learning: principles, challenges, and applications [J]. Modern Food Science and Technology, 2025, 41(12): 334-345.

收稿日期: 2024-10-23; 修回日期: 2024-12-06; 接受日期: 2024-12-09

基金项目: 国家重点研发计划项目(2023YFD2101002)

作者简介: 成军虎(1983-), 男, 博士, 副教授, 研究方向: 食品绿色加工与食品智能制造技术, E-mail: fechengjh@scut.edu.cn

polymerase chain reaction, are often limited by stringent detection requirements, long detection cycles, and potential sample damage, hindering their large-scale application in the food industry. With the rapid development of artificial intelligence and computer technology, machine learning models with strong predictive abilities and high accuracy have been widely used in quality and safety inspections of fresh agricultural products, effectively addressing the limitations related to data redundancy and the processing of large datasets. This article provides a systematic overview of machine learning technology and deep learning algorithms and analyzes their applications in quality and safety inspections of fresh agricultural products. It also introduces the principles of several emerging non-destructive testing technologies, and discusses current research progress and potential application prospects for machine learning and non-destructive testing technologies in the food industry.

Key words: fresh agricultural product; non-destructive testing; machine learning; deep learning

随着我国经济的持续发展、生鲜农产品消费量的增加对生鲜农产品的品质提出了更高要求,然而许多生鲜农产品经加工后,其细胞和组织结构受到破坏,并产生一系列的生化反应,导致营养成分的损失。此外,由于生鲜农产品易受微生物污染,即使在冷链运输过程中采取低温保鲜,其保质期也依然较短,传统的生鲜农产品检测方法大多存在着检测条件苛刻、检测周期长、检测有损等问题,无法大规模运用。因此,需要开发一种准确、高效、无损的生鲜农产品品质检测及分析技术。

随着传感技术的不断发展,无损检测技术有了进一步的发展,如电磁技术^[1]、光谱成像技术^[2]、电子鼻、电子舌以及机器视觉等^[3],它们具有高效、准确、适用范围广和自动化程度高等优点,在食品安全与质量监测中逐渐得到应用与发展。

然而,食品本身具有复杂的化学成分和结构,从生鲜食品到加工食品,涵盖了各种不同的成分和特性,因此,使用无损检测技术会导致数据的冗余以及难以解释的数据集的出现。因此,需要找到合适的方法去解决这个问题,使得以上无损检测技术能够得到更广泛的应用。

随着人工智能的不断发展,采用更加灵活高效的数据处理方法来应对不同类型和规模的数据成为了研究热点,而机器学习被认为是有效且经济的方案,其可以通过建立模型以描述数据与食品特征之间的关系,并能够自主去除冗余数据,从而节省数据处理与计算的人力物力成本^[3]。因此,基于机器学习的无损检测技术是未来食品质量与安全智能检测技术的发展趋势。

深度学习是机器学习的一种特殊形式,它通过引入更深层次的神经网络结构,提供了处理更复杂问题的能力。深度学习技术能自动学习和具有提取复杂特征的多层神经网络结构,在分析食品品质方面展现出强大的优势。Zhu 等^[4]聚焦机器学习与机器视觉技术

在食品加工中的应用,涉及食品加工中的自动化和智能化发展以及食品质量与安全的检测与监控。Deng 等^[5]讨论了深度学习技术相较于传统机器学习及其它一些传统检测方法在食品真实性鉴别中的优势和巨大潜力。Zhang 等^[6]概述了机器学习技术在食品分类中的应用,构建了用于食品类别识别的机器学习系统的核心组件。

然而,系统介绍机器学习尤其是深度学习算法融合食品无损检测技术解决食品质量与安全问题的综述鲜有报道。因此,本文系统介绍了机器学习及深度学习算法基本理论方法,分析了无损检测技术融合机器学习在生鲜农产品质量与安全检测中的应用与未来挑战,为食品品质与安全的精准实时监控提供了重要理论支撑与方法指导。

1 机器学习概述

机器学习是人工智能领域的一个重要分支,其概念最初由 Arthur Samuel 于 20 世纪 50 年代提出^[7]。其本质就是让计算机通过在数据中学习得到规律,并能够对未知数据进行分类和预测。从 2012 年开始,随着计算力提升和海量训练样本的支持,深度学习成为机器学习的研究热点,并推动了各行各业的发展。本文将分为传统机器学习和深度学习两部分进行阐述。

1.1 传统机器学习

传统机器学习是指一类在给定数据集上通过算法学习模型,从而能够对新的数据进行预测或者分类的方法。它主要通过从数据中学习特征之间的关系来实现任务,不需要显式地编程规则,其计算复杂度低、决策过程可解释性和可理解性高并且适用范围广泛。传统机器学习经过不断发展,衍生出了很多种分类方法,按学习方式的不同可分为有监督学习、半监督学习和无监督学习。

1.1.1 有监督学习

有监督学习是指人为地给机器学习算法一个带标签的数据集，这个数据集为算法提供了每个输入对应的正确输出，使得计算机能够不断调整其内部参数来最小化预测误差，经测试后得到能够使其对未知数据做出准确预测的模型。由于过程中的标签由人为提供，所以有监督学习会增加数据准备的成本和时间，如果模型在训练数据上过度拟合，可能新的数据上表现不佳，泛化能力受到限制，常见的有监督学习算法优缺点对比^[8]如表 1 所示。有监督学习被广泛应用在许多领域，如肿瘤表达模式分析^[9]、材料分析^[10]、光谱分析^[11]、肉类质量与安全的智能检测^[7]以及食品的检验、过程追溯和安全预警^[12]等。此外，有监督学习与光谱分析、材料分析等技术能够很好地综合应用，这表明有监督学习在生鲜农产品的质量与安全进行智能快速无损检测具有巨大的应用前景。

表 1 有监督学习各算法的优缺点
Table 1 Advantages and disadvantages of supervised learning algorithms

算法	优点	缺点
线性回归	建模迅速、对于小数据量和简单关系很有效	难以很好地表达出高度复杂数据之间的关系
逻辑回归	训练速度快、模型可解释性好、内存资源占用小	对多重共线性数据较为敏感、很难处理数据不平衡的问题
支持向量机	求得的解为全局最优、决策边界只取决于支持向量、无需依赖整个数据集、泛化能力强	不适用于超大数据集、对核函数的高维映射解释力不强，尤其是径向基函数
决策树	数据易于可视化与理解、运算速度快、分类精确度较高	不易处理缺失数据、易出现过拟合、数据类别多会导致错误增多、泛化性能差
K 最近邻	容易理解、训练阶段快、通常不需要过多调节、对数据的分布无要求	不易发现特征之间的关系、数据不均衡时预测偏差比较大
朴素贝叶斯	对大量的训练和查询时有较高的速度、能进行增量式运算、适合增量式训练	对输入数据表达形式敏感、样本属性有关联时预测效果不佳

1.1.2 无监督学习

无监督学习与有监督学习主要区别就是其输入的数据没有被标记，也没有确定的结果，其目的就是让计算机在没有指导的情况下去分析输入数据之间的相似性与差异性，从而自我发现数据中的规律，不断调整优化参数，建立起最合适的模型。无监督学习的性能很大程度上依赖于输入数据的质量和特征。如果数据存在噪声、缺失值或异常值，这些因素可能会对模

型的性能产生负面影响。

无监督学习的任务主要是聚类和降维，聚类就是把相似的数据分类在一起，常见算法为 K-Means 聚类；降维是为了简化数据的表示，算法主要是主成分分析（PCA），两种算法优缺点对比如表 2 所示。

表 2 无监督学习两种算法优缺点比较
Table 2 Comparison of advantages and disadvantages of two unsupervised learning algorithms

算法	优点	缺点
K-Means	算法简单易懂、计算效率高、适用于大规模数据集、产生的簇划分结果具有直观的可视化效果、易于解释和理解	实际应用中 K 值可能不好确定、比较依赖初始聚类中心的选择、不同的初始选择可能导致不同的局部最优解
主成分分析	可以将高维数据降低到较低的维度、能够提取数据中的主要特征、有助于理解数据的结构和关系、提高后续分析的准确性	对于非线性关系可能无法正确捕捉数据的结构、对数据的缩放和单位选择敏感、需要对数据进行适当的预处理

由于 K-Means 聚类计算效率高，其在无监督分类中被广泛应用，并能够与高光谱成像、计算机视觉、电子鼻、电子舌等技术结合对生鲜农产品的质量与安全进行快速无损检测^[3]。此外，Xu 等^[13]利用 PCA 和聚类分析（CA）对我国 10 个紫甘薯品种的色泽和营养成分进行了评价和综合比较，表明 PCA 能够对食品进行很好地评估，在生鲜农产品质量与安全的智能监测上有很大的应用空间。

1.1.3 半监督学习

半监督学习是有监督学习和无监督学习相结合的一种学习方法^[14]，其使用少量被标记和大量未标记的数据来训练模型，这意味着半监督学习能够节省准备标记的成本和时间，并且能够从未标记数据中发现潜在的有价值的信息，从而提高准确性并实现数据的大化利用。

半监督学习通常基于以下三种假设：

- （1）平滑性假设：相似的数据点在输出上应该是相似的，意味着未标注数据可以帮助模型了解数据的分布。
- （2）聚类假设：相同类别的样本往往在特征空间中聚集，分类决策边界应该穿过稀疏数据区域，稠密数据区域的样例不会分到决策边界两侧。
- （3）流形假设：将高维数据嵌入到低维流形中，使得高维数据可通过较少的维度来描述。
- 常见的半监督学习的算法及其优缺点对比如表 3 所示。

表 3 常见半监督学习算法优缺点对比

Table3 Comparison of advantages and disadvantages of common semi-supervised learning algorithms

算法	优点	缺点
自编码器	可通过无监督学习的方式学习数据的特征表示, 无需标记数据、学习到的特征表示可以用于后续的监督学习任务	对于复杂的数据分布和高维数据, 自编码器的训练可能会面临困难、对于一些任务可能会学习到无用的特征表示
生成式模型	可以生成新的样本, 增加数据的多样性、可通过无监督学习的方式学习到数据的分布	需要大量的计算资源、生成的样本质量可能不稳定、容易受到训练数据的影响
半监督支持向量机	可以利用无标记数据来提高模型性能、在处理高维数据和复杂数据分布时表现较好	在大规模数据集上训练时间较长、对于数据中的噪声和异常值比较敏感
图半监督学习	能够利用数据之间的关系来进行学习, 适用于关系型数据、以处理标记数据稀疏的情况	对图结构的依赖性较强、在图结构不清晰或者图噪声较多的情况下效果可能不佳
半监督决策树	解释性强、易于理解和解释; 处理高维数据具有一定优势	对于非平衡数据集, 可能会导致模型过拟合、训练时间较长

半监督学习结合了有监督学习和无监督学习的优点, 是机器学习技术的重要组成部分, 因而其应用十分广泛, 可应用于文本分类^[15,16]、图像识别^[17]、自然语言处理^[18]、计算机视觉^[19-21]、高光谱成像^[20]等。基于此, 半监督学习在许多领域都发挥着重要作用, 如医学图像分割^[21]、网络安全^[22]、3D 物体检测^[23]、地震预测^[24]等。此外, 半监督学习能够很好地在光谱成像、气味传感(电子鼻、电子舌等)以及计算机视觉中对数据进行快速有效地处理^[3], 因而其能够对生鲜农产品在冷链运输过程中产生的有害腐败物和微生物进行精确检测, 并且能够对生鲜农产品的新鲜度进行预测, 在生鲜农产品质量与安全的快速无损检测上能够被广泛应用。

1.2 深度学习

深度学习是机器学习领域的另一分支, 它的发展始于 20 世纪 50 年代的感知模型, 在最近几十年里, 深度学习随着计算机硬件计算能力的大幅度提升和数据规模的爆炸性增长得以快速发展。相较于传统机器学习, 深度学习方法在通用性和面对具有复杂结构的高维度数据时有更好的表现^[1], 通过模拟神经元的结构和工作原理, 实现对多维、复杂、大规模的数据的高效特征提取和模式识别, 已被多邻域广泛运用^[6,25-27], 尤其在图像信息的特征提取和分类中有较为优异的表现^[28], 基于以上的特点, 对于涉及影响因素复杂的生

鲜农产品质量与安全检测, 深度学习能够通过多层次的神经网络结构对其表征信息自动提取和特征表示, 因此被认为有较大的应用潜力^[11]。

1.2.1 卷积神经网络

由深度学习科学家 Lecun 等^[29]在 1998 年提出的 LeNet-5 网络被广泛认为是最早出现的 CNN 模型, 其结构见图 1a^[30], 这一结构模式也是后续发展出的其它 CNN 模型的基础, 尽管如此, LeNet-5 出现时期, 计算机计算能力仍较低, 难以支持更深、更复杂的神经网络结构, 同时大规模数据仍较难获取。因此, 无论是在数据集规模和多样性上, LeNet-5 都受到限制。同样的原因也阻碍了 CNN 的更深入发展。

直至 2012 年, 在计算机算力大幅提升和大规模数据集出现的前提下, AlexNet 网络采用更深、更宽的网络结构, 包含多个卷积层和全连接层, 使用 ReLU 激活函数, 实现更快收敛并减轻了梯度消失(Gradient Vanishing)问题, ReLU 函数也在后续其它很多 CNN 模型的非线性激活层中沿用。

AlexNet 之后, CNN 呈现出井喷式的发展, 出现了使用更深层网络结构和统一的卷积层设计的 VGGNet^[31]、采用并行处理方式的 GoogLeNet^[32]和拟合了输入与输出间的残差的 ResNet 等网络模型。其中 ResNet 模型引入残差网络结构, 通过堆叠残差模块实现构建任意深度的神经网络的同时, 使用批归一化(Batch Normalization)的方法来对抗网络加深时出现的梯度消失现象(Gradient Vanishing Problem), 避免了网络退化问题。ResNet 的提出也是深度神经网络识别效果第一次超过人类^[33]。自此更高性能卷积神经网络还引入了全连接层、激活函数、损失函数、优化器、超参数调整等。除了应用于二维的图像处理外也可应用于一维和其它多维场景^[33]。

CNN 在图像和复杂数据分析方面的强大能力, 在生鲜农产品的质量和安全检测中具有显著潜力。CNNs 与一些无损传感技术如荧光传感技术相结合, 能够准确快速地对生鲜农产品的品质做出评估, Wang 等^[34]利用 VGG16、ViT、ResNet50 和 Xception 四种 DCNN 模型对反映蔬菜新鲜度的荧光传感阵列进行特征提取和分类, 测试集总体准确率分别达到 95.10%、94.00%、96.21% 和 89.57%, 其中 ResNet50 网络表现最佳, 633 张传感阵列图像组成的测试集中只有五张未被正确归类。同时 CNN 也能使用三维卷积核对食品检测中常用的高光谱图像特征进行捕获分析^[35], 这种能力在食品包装表面检测^[36]、肉类物种分类^[37]、黄曲霉毒素检测^[38]、掺假检测^[39]等任务中得到应用。

1.2.2 循环神经网络

循环神经网络 (Recurrent Neural Network, RNN)^[36] 由输入层 (Input Layer)、输出层 (Output Layer) 和具有非线性的高维隐藏层组成。隐藏层作为网络的记忆结构, 其在某一时刻的状态与其之前的状态相关联^[36]。这种结构使 RNN 能够将输入映射到输出, 并预测未来输出^[40]。与传统的前馈神经网络不同, RNN 在其至少一个层中使用循环连接^[36], 这使得它能够在时间步之间保留信息, 从而实现状态的持久化。如图 1b^[30]所示, RNN 的架构包括一个或多个循环层, 这些循环层通过自行循环的权重矩阵实现信息的传播。每个循环层的输出既是下一个层的输入, 又通过循环连接反馈给自身。然而, 梯度消失或爆炸的问题严重影响了其性能和实际应用的可能性^[41]。

为应对梯度消失和梯度爆炸问题, 后续出现了许多以 RNN 为基础的变体网络结构, 如长短期记忆 (Long Short Term Memory, LSTM) 和门控逻辑单元 (Gated Recurrent Unit, GRU)^[42]。LSTM 通在处理长序列信息时相比普通的 RNN 结构有更好的表现, 有效解决了长序列训练过程中的梯度消失和梯度爆炸问题^[42]。GRU 与 LSTM 引入门控机制, 但 GRU 有更简单的结构, 适用于计算资源较少和所要处理序列信息复杂度较低的情况^[43]。LSTM 和 GRU 通过引入输入门、输出门和遗忘门等组件来管理状态的更新和遗忘, 从而有效解决了传统 RNN 在处理长序列时的不足^[43]。

RNN 及其变体通常用于处理时间序列信息, 因此能够在生鲜农产品的供应链追踪中起到关键作用, 通过学习和记忆时间序列数据, RNN 可以帮助预测供应链中的潜在问题^[44], 如运输延误、储存温度变化等。

此外, RNN 与无损检测技术的结合在准确高效判别生鲜农产品品质上也有众多应用。如使用 RNN 作为分类器对水果品质进行预测^[45]、使用 RNN 对鱼片高光谱图像进行分析来检测新鲜程度^[46]、预测红茶存储时间^[47]、小茴香和茴香的鉴别^[48]、苹果分类^[49]、食物中孢梭菌孢子含量预测^[50]、柑橘的分类^[51]、玉米籽粒水分含量的检测^[52]等。

1.2.3 对抗神经网络

对抗神经网络 (Generative Adversarial Networks, GANs)^[44]自提出后便迅速崛起并在计算机视觉和自然语言处理等多个领域取得成功^[53], 可用于自动生成与真实数据类似的合成数据。与其它类型神经网络不同, GANs 包含生成器网络和判别器网络两个网络, 生成器负责生成类真实数据的, 而判别器的任务是区分输入的真实数据与生成的数据。这种对抗式训练模式中, 生成器会逐步优化, 使生成的数据更加接近真实数据, 而判别器则不断提升其辨别能力, 最终达到高质量的生成效果。GANs 基本架构见图 1c^[30]。

目前, GANs 应用研究主要集中在计算机视觉中的图像修复和图像生成等任务, 在艺术创作、广告设计等领域得到了应用。而 GANs 与无损检测技术相结合, 也展现出在生成和分析非线性复杂数据方面的巨大潜力。例如, 将 GAN 应用在高光谱图像的分类中, 通用对抗式训练对模型进行调整优化, 使执行高光谱图像分类任务的判别器持续得到优化^[54]。也有在医学影像融合领域利用生成器对医学检测影像进行优化^[55]。目前 GANs 在无损检测领域的应用仍较少, 未来, GANs 的应用可能在无损检测领域拓展, 推进相关技术发展。




图 1 深度学习的神经网络结构

Fig.1 The neural network structure of deep learning

注: a 为卷积神经网络图; b 为循环神经网络图; c 为对抗神经网络图; d 为图神经网络图。

1.2.4 图神经网络

图神经网络（Graph Neural Network, GNN）在2000年代初首次提出，近年来逐渐成为一种强大的深度学习模型。GNN在处理图结构数据方面展现出卓越能力，可以有效地处理和学习图结构中的关系和交互^[54]。如图1d^[30]所示，与传统的神经网络处理固定大小的平面输入数据不同，GNN使用基于图的操作分析图中节点的邻近关系，进而捕获图结构中的复杂特征。

最简化的GNN依靠全连接输出层对图数据进行分析，但显然无法满足实际使用需求，因此在这之前一般会通过节点嵌入层和图卷积层等操作对图数据进行处理。Wu等^[56]将GNN分为递归图神经网络、卷积图神经网络、图形自动编码器、时空图神经网络等^[1,57,58]任务。图形自动编码器使用自动编码器架构，包含编码器和解码器部分，通过压缩和解压缩图数据来学习特征，适用于学习图的潜在表示和进行链接预测，通过压缩图信息来提取特征^[30]。时空图神经网络结合时间维度和空间维度处理图数据，适用于时空序列数据中的图任务，被广泛用于交通流量预测、传染病传播预测^[59]等。

GNN具有强大的图结构数据处理能力，而无损检测往往涉及复杂的传感器数据、结构分析和系统监控，而这些数据通常呈现出网络或图结构，因此，GNN在生鲜农产品无损检测中有较大的应用潜力。目前，GNNs在食品质量无损检测方面的应用研究仍较少，但已在计算机视觉领域的图像分类任务中积累了大量研究经验^[1]，这些研究为GNN在食品质量无损检测中的应用提供了启示。未来，GNN在生鲜农产品无损检测中的应用范围可能会进一步扩大。例如，GNN可以用于更深入的供应链分析，帮助追踪产品流动，预测质量与安全风险。此外，GNN还可以在质量控制和异常检测方面发挥更大作用。因此，GNN在无损检测中的应用有望进一步发展，帮助提高生鲜农产品的质量与安全。

2 基于机器学习融合计算机视觉技术在食品质量与安全分析中的应用

2.1 计算机视觉技术

计算机视觉的核心在于赋予计算机人类的视觉能力，并从视觉数据中获取信息^[60]。硬件层面主要涉及图像采集，高质量的图像采集需要考虑分辨率、光照、角度、焦距等因素。通常，图像采集系统包括摄像头、传感器、照明设备和数据传输系统。通过优化这些组件，

计算机视觉能够在不同环境中采集高质量的图像和视频。计算机视觉的核心任务是软件层面的图像处理与分析，目的是从采集到的视觉数据中提取有价值的信息并以此作为反馈信号执行相应的任务。目前，计算机视觉技术与机器学习技术相结合。其中，以卷积神经网络为代表的深度学习技术凭借其在提取图像特征任务中的优异表现在图像处理与分析任务中广泛应用，推动了计算机视觉在多种应用领域的发展^[61]。

2.2 食品质量与安全检测进展

一般来说，对食品质量的判断主要由人类感官测试确定，对于复杂的食品品质信息来说，这是低效且主观的^[62]。而将机器学习与计算机视觉技术应用在食品质量与安全的智能检测中，能准确捕获食品表征的详细信息，有效降低人为误判的风险^[4]，实现在食品生产过程中对品质监控的自动化与智能化。例如，Deng等^[63]基于ShuffleNet和迁移学习，开发了一种用于在线胡萝卜缺陷检测的轻量级网络，准确率达99.82%，并在由照明室和上位计算机组成计算机视觉系统的基础上开发出一个如图2^[63]所示的胡萝卜质量检验和分级的全自动系统。也可以结合荧光传感等技术对食品新鲜度与安全性进行评估进行。如Li等^[64]使用二维经验模式分解来去除多光谱图像中的噪声并进一步重建图像。并提出一种改进的形态梯度重建、标记提取和图像校正的流域分割方法，以高准确率实现苹果的新鲜度划分。分析流程见图3^[64]。Wang等^[34]用智能手机成像系统采集反映蔬菜新鲜度的荧光传感阵列图像，并使用多种模型进行特征提取和分类，准确率最高可达96.21%。




图2 胡萝卜分级系统的机械结构

Fig.2 Mechanical structure of carrot grading system

注：(a) 胡萝卜自动分级系统（1个传动系统，2个计算机视觉系统，3个气动分级系统）；(b) 光室示意图（2.1 线性摄像机，2.2 胡萝卜，2.3 镜面，2.4 镜像）。




图 3 基于 PC3 评分图像的苹果衰变检测流程图

Fig.3 Apple decay detection flow chart based on PC3 scoring image

未来，随着计算机视觉技术的不断发展，食品质量与安全智能检测将会变得更加可靠和高效。通过与物联网和区块链等其他技术的结合，可以进一步提升智能化水平，确保食品质量和安全。

3 机器学习融合高光谱技术在食品质量与安全分析中的应用

随着人工智能和高光谱技术的快速发展，机器学习和高光谱成像（Hyperspectral Imaging, HSI）已被广泛认为是比较高效智能的无损检测技术，可应用于食品的快速无损检测之中，本章对高光谱成像技术进行介绍以及基于机器学习与高光谱技术在食品质量与安全检测上的应用分析。

3.1 高光谱成像技术

高光谱成像技术（HSI）是基于非常多窄波段的影像数据技术，其在光谱维度上也设置了多个通道，将一定波长范围的光进行细致的分割，以探测目标的二维几何空间以及一维光谱信息，从而获得高光谱分辨率、窄波段的图像数据。高光谱成像可用于表征图像上每个点的外部信息，并获得每个点的光谱数据，从而能够分析得到其内部所含物质的信息，目前已被广泛应用于医学诊断^[65]、航天航空^[66]、食品质量检测^[67]等领域。

3.2 食品质量与安全智能检测进展

高光谱成像最终会获得目标物每个点的图像数据和光谱信息，导致了在实际应用中会出现大量冗余数据，而利用机器学习技术能够很好地筛除掉无用的数据，从而很好地解决高光谱成像技术在数据上的问题。因此，基于机器学习的高光谱成像技术能够对食品质量与安全进行高效智能的检测。在食品质量与安全检测中，高光谱成像仪器能够采集到食品的图像信息以及光谱数据，结合机器学习技术自动对食品中存在的有害微生物以及有害气体进行智能检测。例如，Soni等^[50]结合高光谱成像以及深度学习，建立了一套量化食品中产包梭菌孢子的深度学习模型，具有较高的精度；Li等^[68]通过图4所示过程记录样品的反射光谱，得到了如图5所示的结果，证实了基于深度学习的近红外高光谱方法预测特定食品蛋白质含量的可行性。通过比较各种常规方法和近红外光谱分析的准确性和可解释性，表明了基于深度学习的近红外高光谱成像在预测食物品质方面具有巨大潜力^[68]；Makino等^[69]使用可见近红外高光谱成像和机器学习快速、无损地检测碎牛肉中的鸡肉掺假，证实了高光谱成像与机器学习相结合可用于检测、量化和可视化添加到碎牛肉中的鸡肉掺假量，从而说明基于机器学习的高光谱成像技术在食品质量与安全的智能检测上具有非常大的应用潜力。




图 4 高光谱图像采集光谱提取过程

Fig.4 Hyperspectral image acquisition spectrum extraction process





图 5 数据集的光谱表征和实验结果可视化

Fig.5 Spectral characterization of data sets and visualization of experimental results

4 机器学习融合与电子鼻/舌技术在食品质量与安全分析中的应用

食品在运输、储存和销售过程中容易发生腐败变质，从而感官品质大大降低并且会产生有害气体。随着人工智能和传感器技术的不断发展，基于机器学习的电子鼻与电子舌技术应运而生，能够对食品中的有害物质进行快速智能无损检测。

4.1 电子鼻与电子舌技术

电子鼻是一种无损检测技术，其通过模仿动物的嗅觉系统来检测食品中产生的挥发物来评估食品质量。电子鼻主要由气敏传感器阵列、信号预处理和模式识别三部分组成，工作时将挥发物产生的化学信号转化为电信号，由多个传感器对一种气味的响应，构成了传感器阵列对该气味的响应谱，基于此，电子鼻技术可用于分析微弱的气味以及相似气味之间的细微区别，可应用于环境气体检测^[70]、医学诊断^[71]、爆炸物检测^[72]以及食品质量检测^[73]等领域。与电子鼻类似，电子舌也是一种无损检测技术，模仿人的舌头对食品中的液体进行检测从而评估食品质量。电子舌主要由味觉传感器阵列、信号采集系统和模式识别系统三部分组成，检测原理与电子鼻类似，可被应用于环境检测^[74]、爆炸物检测^[75]以及食品质量与感官评价^[76]等。

4.2 食品质量与安全智能检测进展

电子鼻与电子舌最终输出的信号是电信号强度，等待一定时间后，每个传感器的稳定信号由一个矢量组成^[3]，需要进一步进行建模分析。此外，输入到传感器的信号包括许多不相关的信息以及噪声导致结果不准确，这表明需要对输入信号进行预处理，而机器

学习算法能够很好地解决上述问题,因此,机器学习和电子鼻与电子舌相结合能够很好地实现对食品质量和安全的智能无损检测。Wijaya 等^[77]建立了一种电子鼻信号噪声过滤的牛肉质量检测框架并利用 K-最近邻(k-Nearest Neighbor, K-NN)等机器学习算法进行测试,得到了良好的效果;Putri 等^[78]开发并用监督机器学习模型评估了一种紧凑型便携式的电子鼻来分类不同的肉松产品,如图 6 所示,在食品真伪检测中展现出了良好的效果;Zeng 等^[79]首次利用定量描述分析,利用电子鼻从样品上方快速采集数据,使用无监督 PCA 来可视化不同香气类型的酸奶分布,将机器学习与电子鼻相结合,实现对原味香气酸奶类型的快速识别;Li 等^[80]利用电子鼻、电子舌和电子眼融合数据,结合人工神经网络(Artificial Neural Network, ANN)、随机森林回归(Random Forest Regressor, RFR)等机器学习算法,实现了对冷冻竹荚鱼新鲜度的系统评价和定量预测并得到了较高的准确率。




图 6 用于肉松鉴定的便携式电子鼻

Fig.6 Portable electronic nose for meat floss identification

5 挑战与展望

在无损检测技术方面,由于生鲜农产品在运输、储存以及销售过程中劣变过程动态且复杂,需要对其进行实时监测,同时,无损检测技术通常需要在实验室环境下进行,仪器体积庞大且不利于移动,而在食品生产线等实际应用场景中,需要实现实时监测和移动式检测设备,故开发小型化的高光谱成像、电子鼻以及电子舌仪器,并保证其有较好的响应速度和准确性是一大难题。因此,未来的无损技术研究可以往设备的高精度、高响应速度以及高便携度方向发展,由此提高无损技术的实际应用能力。此外,公开可用的基准无损技术数据集较少^[3],这使得无损检测技术在生鲜农产品质量与安全检测上的应用受到限制。因此需要建立完善的食品光谱库以及电子鼻、电子舌的响应图谱库以支持检测和识别工作。

在算法方面,机器学习算法需要大量的标注数据,但获取和标注生鲜农产品的数据以及进行数据特征提取可能比较困难,尤其是考虑到不同类型的农产品。同时生鲜农产品的外观特征具有较大的多样性和变化性,这给智能检测带来了挑战,需要算法具备

较强的泛化能力。其次,实时的食品检测要求算法需要具备高效性和快速性。因此,未来的研究可以通过开发对数据依赖性低的算法以降低数据集准备和特征提取的难度,还可以开发性能更加佳的集成算法,充分发挥多种算法的优势,简化学习过程并提高检测结果的准确性。此外,可以将深度学习与自动化技术、大数据等结合,实现生鲜农产品质量与安全快速无损智能检测的目标,并为农产品产业带来更多的机遇和发展空间。

6 结论

本文介绍了机器学习与深度学习的原理及算法特点,综述了新兴食品无损检测技术与机器学习技术在生鲜农产品质量与安全快速智能无损检测上的应用,机器学习因其能够处理大规模数据、适应性和泛化能力强、能快速迭代优化提高准确性等特点,能够很好地解决新兴无损检测技术数据冗余,难以处理的问题。此外,深度学习技术在图像特征提取中有着优异表现,结合计算机视觉技术,通过检测食品的外部的缺陷和异常来判断其质量,从而实现对食品品质的分级,取得了显著的效果。可见,机器学习在食品质量与安全检测中的应用具有广泛的前景和深远的影响,极大地推动高品质食品的生产和食品工业的发展。本文分析了此技术在应用上的挑战与展望,希望将更多的机器学习技术应用到生鲜农产品的质量与安全的检测之中。

参考文献

- [1] FAKHLAEI R, BABADI A A, SUN C, et al. Application, challenges and future prospects of recent nondestructive techniques based on the electromagnetic spectrum in food quality and safety [J]. Food Chemistry, 2024, 441: 138402.
- [2] PU H, YU J, SUN D W, et al. Feature construction methods for processing and analysing spectral images and their applications in food quality inspection [J]. Trends in Food Science & Technology, 2023, 138: 726-737.
- [3] LIN Y, MA J, WANG Q, et al. Applications of machine learning techniques for enhancing nondestructive food quality and safety detection [J]. Critical Reviews in Food Science and Nutrition, 2023, 63(12): 1649-1669.
- [4] ZHU L, SPACHOS P, PENSINI E, et al. Deep learning and machine vision for food processing: a survey [J]. Current Research in Food Science, 2021, 4: 233-249.
- [5] DENG Z, WANG T, ZHENG Y, et al. Deep learning in food authenticity: recent advances and future trends [J]. Trends in Food Science & Technology, 2024, 144: 104344.
- [6] ZHANG Y, DENG L, ZHU H, et al. Deep learning in food category recognition [J]. Information Fusion, 2023, 98: 101859.
- [7] 林梓杰,董庆利.机器学习在肉类微生物安全中的应用研究进展[J].肉类研究,2022,36(11):36-41.
- [8] 杨剑锋,乔佩蕊,李永梅,等.机器学习分类问题及算法研究综述[J].统计与决策,2019,6:36-40.
- [9] DYRSKJØT L, THYKJAER T, KRUGHØFFER M, et al. Identifying distinct classes of bladder carcinoma using microarrays [J]. Nature Genetics, 2003, 33(1): 90-96.
- [10] KHANZADEH M, CHOWDHURY S, MARUFUZZAMAN M, et al. Porosity prediction: supervised-learning of thermal history for direct laser deposition [J]. Journal of Manufacturing Systems, 2018, 47: 69-82.
- [11] LIU X, ZHENG L, HAN C, et al. Identifying the activity origin of a cobalt single-atom catalyst for hydrogen evolution using supervised learning [J]. Advanced Functional Materials, 2021, 31(18): 2100547.
- [12] 赵峙尧,刘明昊,白林,等.基于机器学习对食品安全的调控与分析[J].食品工业科技, 2024,45(11):11-19.
- [13] XU M, LI J, YIN J, et al. Color and nutritional analysis of ten different purple sweet potato varieties cultivated in china via principal component analysis and cluster analysis [J]. Foods, 2024, 13(6): 904.
- [14] VAN ENGELEN J E, HOOS H H. A survey on semi-supervised learning [J]. Machine Learning, 2020, 109(2): 373-440.
- [15] DUARTE J M, BERTON L. A review of semi-supervised learning for text classification [J]. Artificial Intelligence Review, 2023, 56(9): 9401-9469.
- [16] XU Z, LI J, LIU B, et al. Semi-supervised learning in large scale text categorization [J]. Journal of Shanghai Jiaotong University (Science), 2017, 22: 291-302.
- [17] JI Q, JIANG Y, WU Z, et al. An image recognition method for urine sediment based on semi-supervised learning [J]. Innovation and Research in BioMedical, 2023, 44(2): 100739.
- [18] LI C, WENG Y, ZHANG Y, et al. A systematic review of application progress on machine learning-based natural language processing in breast cancer over the past 5 years [J]. Diagnostics, 2023, 13(3): 537.
- [19] LU S, YAN Z, CHEN W, et al. Dual consistency regularization with subjective logic for semi-supervised medical image segmentation [J]. Computers in Biology and Medicine, 2024, 170: 107991.
- [20] WANG Q, ZHANG Q, ZHANG J, et al. Graph-based semisupervised learning with weighted features for hyperspectral remote sensing image classification [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2022, 15: 6356-6370.
- [21] HAN K, SHENG V S, SONG Y, et al. Deep semi-supervised learning for medical image segmentation: a review [J]. Expert Systems with Applications, 2024, 245: 123052.
- [22] MVULA P K, BRANCO P, JOURDAN G-V, et al. A survey on the applications of semi-supervised learning to cyber-security [J]. ACM Computing Surveys, 2024, 56(10): 1-41.
- [23] YANG L, ZHANG X, LI J, et al. Mix-teaching: a simple, unified and effective semi-supervised learning framework for monocular 3d object detection [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2023, 33(11): 6832-6844.
- [24] ZHU W, BIONDI E, LI J, et al. Seismic arrival-time picking on distributed acoustic sensing data using semi-supervised learning [J]. Nature Communications, 2023, 14(1): 8192.
- [25] LEN, RATHOUR V S, YAMAZAKI K, et al. Deep reinforcement

- learning in computer vision: a comprehensive survey [J]. *Artificial Intelligence Review*, 2022,55(4): 1-87.
- [26] LI H. Deep learning for natural language processing: advantages and challenges [J]. *National Science Review*, 2018, 5(1): 24-26.
- [27] GUROVICH Y, HANANI Y, BAR O, et al. Identifying facial phenotypes of genetic disorders using deep learning [J]. *Nature Medicine*, 2019, 25(1): 60-64.
- [28] MOEN E, BANNON D, KUDO T, et al. Deep learning for cellular image analysis [J]. *Nature Methods*, 2019, 16(12): 1233-1246.
- [29] 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.
- [30] SANCHEZ-LENGELING B, REIF E, PEARCE A, et al. A gentle introduction to graph neural networks [J]. *Distill*, 2021, 6(9): e33.
- [31] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [J]. *Arxiv*, 2014, 140: 91556.
- [32] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions [C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. USA: IEEE, 2015: 1-9.
- [33] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. USA:IEEE, 2016: 770-778.
- [34] WANG D, ZHANG M, ZHU Q, et al. Intelligent vegetable freshness monitoring system developed by integrating eco-friendly fluorescent sensor arrays with deep convolutional neural networks [J]. *Chemical Engineering Journal*, 2024, 488: 150739.
- [35] KONG Y, WANG X, CHENG Y. Spectral-spatial feature extraction for HSI classification based on supervised hypergraph and sample expanded CNN [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2018, 11(11): 4128-4140.
- [36] MEDUS L D, SABAN M, FRANCÉS-VÍLLORA J V, et al. Hyperspectral image classification using CNN: application to industrial food packaging [J]. *Food Control*, 2021, 125: 107962.
- [37] AL-SARAYREH M, REIS M M, YAN W Q, et al. Potential of deep learning and snapshot hyperspectral imaging for classification of species in meat [J]. *Food Control*, 2020, 117: 107332.
- [38] GAO J, ZHAO L, LI J, et al. Aflatoxin rapid detection based on hyperspectral with 1D-convolution neural network in the pixel level [J]. *Food Chemistry*, 2021, 360: 129968.
- [39] KONG D, SHI Y, SUN D, et al. Hyperspectral imaging coupled with CNN: a powerful approach for quantitative identification of feather meal and fish by-product meal adulterated in marine fishmeal [J]. *Microchemical Journal*, 2022, 180: 107517.
- [40] SALEHINEJAD H, SANKAR S, BARFETT J, et al. Recent advances in recurrent neural networks [J]. *Arxiv*, 2017, 180: 101078.
- [41] VAN HOUDT G, MOSQUERA C, NÁPOLES G. A review on the long short-term memory model [J]. *Artificial Intelligence Review*, 2020, 53(8): 5929-5955.
- [42] CHO K, VAN MERRIËNBOER B, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation [J]. *Arxiv*, 2014, 1406: 1078.
- [43] CHUNG J, GULCEHRE C, CHO K, et al. Empirical evaluation of gated recurrent neural networks on sequence modeling [J]. *Arxiv*, 2014, 141: 23555.
- [44] NGUYEN H D, TRAN K P, THOMASSEY S, et al. Forecasting and anomaly detection approaches using LSTM and LSTM autoencoder techniques with the applications in supply chain management [J]. *International Journal of Information Management*, 2021, 57: 102282.
- [45] DHIMAN B, KUMAR Y, HU Y C. A general purpose multi-fruit system for assessing the quality of fruits with the application of recurrent neural network [J]. *Soft Computing*, 2021, 25(14): 9255-9272.
- [46] TRAN T T, NGUYEN L D, HOAI P N, et al. Long short-term memory (LSTM) neural networks for short-term water level prediction in Mekong river estuaries [J]. *Songklanakarin Journal of Science & Technology*, 2022, 44(4): 1057.
- [47] HONG Z, ZHANG C, KONG D, et al. Identification of storage years of black tea using near-infrared hyperspectral imaging with deep learning methods [J]. *Infrared Physics & Technology*, 2021, 114: 103666.
- [48] CHEN C, YANG B, SI R, et al. Fast detection of cumin and fennel using NIR spectroscopy combined with deep learning algorithms [J]. *Optik*, 2021, 242: 167080.
- [49] SHI X, CHAI X, YANG C, et al. Vision-based apple quality grading with multi-view spatial network [J]. *Computers and Electronics in Agriculture*, 2022, 195: 106793.
- [50] SONI A, AL-SARAYREH M, REIS M M, et al. Hyperspectral imaging and deep learning for quantification of clostridium sporogenes spores in food products using 1D-convolutional neural networks and random forest model [J]. *Food Research International*, 2021, 147: 110577.
- [51] YU Y, AN X, LIN J, et al. A vision system based on CNN-LSTM for robotic citrus sorting [J]. *Information Processing in Agriculture*, 2024, 11(1): 14-25.
- [52] ZHANG L, ZHANG Q, WU J, et al. Moisture detection of single corn seed based on hyperspectral imaging and deep learning [J]. *Infrared Physics & Technology*, 2022, 125: 104279.
- [53] CAI Z, XIONG Z, XU H, et al. Generative adversarial networks: a survey toward private and secure applications [J]. *ACM Computing Surveys (CSUR)*, 2021, 54(6): 1-38.
- [54] ZHU L, CHEN Y, GHAMISI P, et al. Generative adversarial networks for hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(9): 5046-5063.
- [55] ZHOU T, LI Q, LU H, et al. GAN review: models and medical image fusion applications [J]. *Information Fusion*, 2023, 91: 134-148.
- [56] WU Z, PAN S, CHEN F, et al. A comprehensive survey on graph neural networks [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2020, 32(1): 4-24.
- [57] ZHANG T, ZHENG W, CUI Z, et al. Tensor graph convolutional neural network [J]. *Arxiv*, 2018, 180: 310071.
- [58] MARCHEGGIANI D, TITOV I. Encoding sentences with graph convolutional networks for semantic role labeling [J]. *Arxiv*, 2017, 170304826.
- [59] KAPOOR A, BEN X, LIU L, et al. Examining covid-19 forecasting using spatio-temporal graph neural networks [J]. *Arxiv*, 2020, 20: 0703113.

- [60] BALLARD D H, BROWN C M. Computer Vision [M]. Prentice Hall Professional Technical Reference, 1982.
- [61] VOULODIMOS A, DOULAMIS N, DOULAMIS A, et al. Deep learning for computer vision: a brief review [J]. Computational Intelligence and Neuroscience, 2018, 2018(1): 7068349.
- [62] PEDRESCHI F, MERY D, BUNGER A, et al. Computer vision classification of potato chips by color [J]. Journal of Food Process Engineering, 2011, 34(5): 1714-1728.
- [63] DENG L, LI J, HAN Z. Online defect detection and automatic grading of carrots using computer vision combined with deep learning methods [J]. Lwt, 2021, 149: 111832.
- [64] LI J, LUO W, WANG Z, et al. Early detection of decay on apples using hyperspectral reflectance imaging combining both principal component analysis and improved watershed segmentation method [J]. Postharvest Biology and Technology, 2019, 149: 235-246.
- [65] CALIN M A, PARASCA S V, SAVASTRU D, et al. Hyperspectral imaging in the medical field: present and future [J]. Applied Spectroscopy Reviews, 2014, 49(6): 435-447.
- [66] WIJATA A M, FOULON M F, BOBICHON Y, et al. Taking artificial intelligence into space through objective selection of hyperspectral earth observation applications: to bring the “brain” close to the “eyes” of satellite missions [J]. IEEE Geoscience and Remote Sensing Magazine, 2023, 11(2): 10-39.
- [67] FENG Y Z, SUN D W. Application of hyperspectral imaging in food safety inspection and control: a review [J]. Critical Reviews in Food Science and Nutrition, 2012, 52(11): 1039-1058.
- [68] LI T, WEI W, XING S, et al. Deep learning-based near-infrared hyperspectral imaging for food nutrition estimation [J]. Foods, 2023, 12(17): 3145.
- [69] KAMRUZZAMAN M, MAKINO Y, OSHITA S. Rapid and non-destructive detection of chicken adulteration in minced beef using visible near-infrared hyperspectral imaging and machine learning [J]. Journal of Food Engineering, 2016, 170: 8-15.
- [70] DOMÈNECH-GIL G, DUC N T, WIKNER J J, et al. Electronic nose for improved environmental methane monitoring [J]. Environmental Science & Technology, 2023, 58(1): 352-361.
- [71] SHLOMI D, ABUD M, LIRAN O, et al. Detection of lung cancer and EGFR mutation by electronic nose system [J]. Journal of Thoracic Oncology, 2017, 12(10): 1544-1551.
- [72] LIU P, GUO X, LIANG C, et al. Rapid detection of trace nitro-explosives under UV irradiation by electronic nose with neural networks [J]. ACS Applied Materials & Interfaces, 2023, 15(30): 36539-36549.
- [73] ALI M M, HASHIM N, ABD AZIZ S, et al. Principles and recent advances in electronic nose for quality inspection of agricultural and food products [J]. Trends in Food Science & Technology, 2020, 99: 1-10.
- [74] GARCIA-BREIJO E, PERIS R M, PINATTI C O, et al. Low-cost electronic tongue system and its application to explosive detection [J]. IEEE Transactions on Instrumentation and Measurement, 2012, 62(2): 424-431.
- [75] JIANG H, ZHANG M, BHANDARI B, et al. Application of electronic tongue for fresh foods quality evaluation: a review [J]. Food Reviews International, 2018, 34(8): 746-769.
- [76] CETÓ X, VOELCKER N H, PRIETO-SIMÓN B. Bioelectronic tongues: new trends and applications in water and food analysis [J]. Biosensors and Bioelectronics, 2016, 79: 608-626.
- [77] WIJAYA D R, SARNO R, ZULAIKA E. Noise filtering framework for electronic nose signals: an application for beef quality monitoring [J]. Computers and Electronics in Agriculture, 2019, 157: 305-321.
- [78] PUTRI L A, RAHMAN I, PUSPITA M, et al. Rapid analysis of meat floss origin using a supervised machine learning-based electronic nose towards food authentication [J]. Npj Science of Food, 2023, 7(1): 31.
- [79] ZENG H, HAN H, HUANG Y, et al. Rapid prediction of the aroma type of plain yogurts via electronic nose combined with machine learning approaches [J]. Food Bioscience, 2023, 56: 103269.
- [80] LI H, WANG Y, ZHANG J, et al. Prediction of the freshness of horse mackerel (*Trachurus japonicus*) using E-nose, E-tongue, and colorimeter based on biochemical indexes analyzed during frozen storage of whole fish [J]. Food Chemistry, 2023, 402: 134325.