

机器学习在食品营养与健康研究中的应用

周 鑫¹ 李大鹏^{2,3}

(1. 山东省泰安第一中学, 山东 泰安 271000; 2. 山东农业大学食品科学与工程学院, 山东 泰安 271018;
3. 食物营养与主动健康山东省工程研究中心, 山东 泰安 271018)

摘要:合理膳食是维持人体健康状态, 预防和降低慢性非传染性疾病发病风险的基础。通过高效、精准分析食品中的营养与功能成分, 进而提供个性化营养指导是食品营养与健康领域的研究热点。文章综述了机器学习等人工智能技术在食品营养成分分析、功能成分分析与筛选及个性化营养等方面的研究进展, 并提出了该领域亟待解决的问题。

关键词:机器学习; 深度学习; 食品营养; 个性化营养

Advances in the application of machine learning to food nutrition and health

ZHOU Xin¹ LI Dapeng^{2,3}

(1. Tai'an No.1 High School of Shandong Province, Tai'an, Shandong 271000, China; 2. College of Food Science and Engineering, Shandong Agricultural University, Tai'an, Shandong 271018, China; 3. Shandong Engineering Research Center of Food Nutrition and Active Health, Tai'an, Shandong 271018, China)

Abstract: A balanced diet is fundamental to maintaining human health and preventing or reducing the risk of chronic non-communicable diseases. Efficient and accurate analysis of nutritional and functional components in food, followed by the provision of personalized nutritional guidance, is a research hotspot in the field of food nutrition and health. This article reviews the research progress on artificial intelligence technologies, such as machine learning, in the analysis of food nutritional components, functional component analysis and screening, and personalized nutrition, and highlights the pressing issues that need to be addressed in this field.

Keywords: machine learning; deep learning; food nutrition; personalized nutrition

食品中的营养成分是维持人体生命活动和健康状态的基础, 合理的膳食结构可以预防和降低慢性非传染性疾病的发生风险。目前, 食品营养成分的定量表征主要采用化学分析法, 这种传统的方法过程复杂耗时, 且需要训练有素的专业人员操作, 制约了其在营养健康产业中的应用^[1]。近年来, 人工智能 (artificial intelligence, AI)、机器学习 (machine learning, ML)、深度学习 (deep learning, DL)、大数据、机器人等信息相关技术被引入食品研究和开发领域, 为解决食品营养与健康领域的热点问题提供了有力的技术支撑。

机器学习为人工智能的一个子领域, 旨在研究和发

展能够通过数据驱动的方式自动优化其性能的算法和计算模型, 其核心在于让计算机系统无需依赖显式编程指令, 而是通过统计推断、模式识别和优化方法, 从输入数据 (经验) 中自动提取规律 (学习), 并利用这些规律对新的未知数据作出预测或决策。使用数据拟合模型为机器学习的核心, 因此范围从经典的统计方法如最小二乘回归 (least squares regression, LR) 到化学计量方法如偏最小二乘回归 (partial least squares regression, PLSR), 再到更现代的数据密集型方法如支持向量机 (support vector machine, SVM)、随机森林 (random forest, RF)、k 近邻 (k-nearest neighbors, KNN) 和人工神经网络 (artificial neural

基金项目:山东省重点研发计划项目 (编号: 2021TZX007); 国家自然科学基金面上项目 (编号: 32472342)

通信作者:李大鹏 (1973—), 男, 山东农业大学教授, 博士。E-mail: dpli73@sdaa.edu.cn

收稿日期: 2025-02-19 **改回日期:** 2025-04-07

引用格式:周鑫, 李大鹏. 机器学习在食品营养与健康研究中的应用[J]. 食品与机械, 2025, 41(7): 235-242.

Citation: ZHOU Xin, LI Dapeng. Advances in the application of machine learning to food nutrition and health[J]. Food & Machinery, 2025, 41(7): 235-242.

network, ANN)等^[2]。深度学习是机器学习的一种特定形式,与传统机器学习需要手动提取特征不同,深度学习由多层 ANN 组成,具有强大的特征学习能力,可以从复杂的数据中预测特征,而无需手动提取数据的特征^[3](图 1)。目前,机器学习等人工智能技术已成为食品工业领域的研究热点,相关研究主要集中在食品图像识别、品质分级、质量安全检测和食品产业链等领域,在食品营养与健康领域的研究和应用还相对较少。文章拟总结近年来机器学习在食品营养成分分析、功能成分分析与筛选及个性化营养等方面的研究进展,旨在为 AI 助力食品营养与健康领域研究提供理论与技术支持。




图 1 人工智能、机器学习和深度学习之间的关系

Figure 1 Relationship between artificial intelligence, machine learning, and deep learning

1 机器学习在食品营养成分分析中的应用

膳食中的各种食物为人体生长发育、维持正常的生理功能和保持健康提供必需的营养素。传统营养素的分析方法主要依赖实验室化学分析(如高效液相色谱、质谱)和人工经验,存在成本高、耗时长、难以规模化等问题。Burke等^[4]提出了个人数字助理辅助该过程,但仍存在误差大和估计食物数量不准确的缺点。机器学习从原始数据中提取关键特征(如光谱吸收峰、图像纹理、颜色直方图),使用 PLS、SVM、VNN 等算法学习特征与营养成分的映射关系形成模型,通过模型对新样本的营养素含量和摄入量进行预测,并通过交叉验证评估模型准确性(图 2)。




图 2 基于图像数据的机器学习预测营养成分含量

Figure 2 Machine learning for predicting the content of nutritional components based on image data

1.1 蛋白质

食物中蛋白质含量测定的常规方法为凯氏定氮法,具有精确度高和适用范围广等优势,但操作复杂、耗时较长。Caporaso等^[5]利用近红外光谱(NIR)和数字成像相结合的高光谱成像技术,构建了基于 PLSR 模型预测蛋白质含量的机器学习模型,实现了对单个小麦籽粒蛋白的快速分析。采用 NIR 技术结合 PLSR 模型构建的机器学习方法也能快速检测出马铃薯和红薯中的蛋白质含量,其 R^2 最高达到了 0.98^[6]。Li 等^[7]采用肯纳德—斯通算法采集榛子仁的 NIR 光谱数据,发现基于一阶导数的 PLSR 模型最适合分析榛子仁中的蛋白含量。Cui 等^[8]比较了卷积神经网络(convolutional neural network, CNN)与 PLSR 模型在小麦面粉蛋白质含量预测中的性能,发现 CNN 模型更准确,噪声更小。昆虫蛋白是一种新型蛋白资源,其氨基酸组成决定了昆虫蛋白的质量。Hou 等^[9]采用傅里叶变换红外光谱(fourier transform infrared spectroscopy, FTIR)收集 9 种商业昆虫的光谱数据,利用 PLSR、决策树(decision tree, DT)和径向基人工神经网络(RBFNN)等机器学习方法建立了一种快速、无损预测氨基酸含量的自动系统。Abdallah 等^[10]采用反射光谱和 CCD 可见光检测技术,利用反向传播人工神经网络(BP-ANN)和自适应神经模糊推理系统(ANFIS)建模算法构建的监督机器学习模型可用于牛肉蛋白含量分析,且 BP-ANN 机器学习模型比 ANFIS 机器学习模型更适合用于光学肉类质量检测。Shermila 等^[11]使用安卓手机采集了 9 种不同保健饮料粉的 990 张照片,利用一阶统计量、定向梯度直方图、线性二值模式、灰度共生矩阵、梯度幅度和梯度方向特征,采用支持向量机的线性回归模型对其蛋白质含量进行了预测。结果表明,使用全色分量图像和图像的蓝色通道,通过深度学习均可对保健饮料粉中的蛋白含量进行可靠的预测,其最小平平均预测误差分别为 ± 1.96 , ± 1.97 。

1.2 脂肪

食物中脂肪含量测定常用的方法有索氏抽提法、酸水解法和碱水解法等。由于不同食物及其脂肪形态、性状等存在较大差异,传统检测方法的适用性较差,而采用深度学习建立的无损检测技术具有更好的适用性和精准度。Muñoz 等^[12]利用深度学习技术分析了干腌火腿切片中的肌肉脂肪含量,比较了 4 种网络深度、2 类过滤器共 8 个 CNN 的预测性能。结果表明, CNN3_512 能够较为精确地分析火腿切片中的瘦肉组织和脂肪,整体像素准确度达到 0.99。Malek 等^[13]提出了一种改进的 1D-CNN 化学计量学方法分析肉中脂肪含量,与传统的 CNN 方法相比,预测精度得到了显著提升。不饱和脂肪酸含量、脂肪酸组成是影响富含油脂类食品品质的重要因素。Liu 等^[14]应用机器学习方法分析了傅里叶变换红外光谱采集

的昆虫食品数据以预测脂肪酸组成和含量。结果表明,所采用的5种机器学习模型(PLSR、RF、SVM、GRNN、RBNN)在预测不同类型脂肪酸含量中的适应性存在差别,例如对于肉豆蔻酸、棕榈酸和硬脂酸,PLSR模型表现最好,对于其他脂肪酸,回归树或神经网络方法的表现优于PLSR。

Liu等^[15]将拉曼光谱和深度学习算法结合开发了一种基于视觉几何组(visual geometry group, VGG)结构的深度神经网络,在分辨动物脂肪(猪油、黄油、羊肉脂肪和鸡脂肪)和植物油(大豆油和花生油)中的准确率达到100%。美国某大学针对国家健康和营养调查(NHANES)数据开发了一种基于机器学习的脂肪酸预测模型,基于总脂肪含量的原始数据,通过KNN和DT两种模型可准确地预测零食中的脂肪酸类别^[16]。

1.3 碳水化合物

碳水化合物是人体能量的主要来源,了解其摄入量对糖尿病患者的膳食干预具有重要的意义。Anthimopoulos等^[17]通过设置参考卡来捕获并重建食物的3D图像,采用径向基支持向量机(RBF-SVM)作为分类器,以颜色直方图和局部二值模式作为特征来识别食物的种类,使用美国农业部营养数据库作为查找表估算出了食物中碳水化合物含量。随后,该团队进一步使用双视图3D重建方法测量体积,有效提高了对食物图像中碳水化合物含量预测的准确度^[18]。淀粉是膳食中碳水化合物的主要来源。马铃薯和甘薯富含淀粉,Diaz等^[19-20]利用近红外高光谱技术,比较了PLSR和多元线性回归(MLR)两种模型在预测淀粉含量方面的差异,发现MLR模型具有更好的适应性($R^2=0.97$)。

果蔬中的可溶性固形物含量常采用折光仪检测,其被用来近似代替含糖量。Yu等^[21]采用堆叠式自动编码(SAE)和全连接神经网络(FNN)相结合的深度学习与可见光/近红外高光谱成像技术建立的可溶性固形物含量分析方法被用于分析库尔勒香梨中的含糖量,模型的预测能力可达到 $R^2=0.921$, RMSEP=0.22%, RPD=3.68。章恺等^[22]将高光谱检测技术、最小二乘支持向量机和改进的鲸鱼算法相结合实现了对猕猴桃糖度的无损检测。Cho等^[23]利用数码相机采集草莓的可见光图像,结合HSV颜色模型和PSL模型成功预测了草莓中的糖含量和酸度。Wen等^[24]构建了CNN和变分自动编码器(VAE)为基础的多层感知器(MLP)分析和编码单个草莓的可见光图像并预测其总可溶性固形物含量,成功评估了草莓的甜度水平。Sun等^[25]采用近红外高光谱技术,通过建立PLSR、主成分分析(PCA)、SVM和ANN模型,实现了对甜瓜的甜度和硬度值的预测。针对光谱信息数据建模存在冗余信息量大、整体收敛性差,复杂度高等问题,乔正

明等^[26]提出了一种基于小波包变换的特征波长筛选和樽海鞘算法改进极限学习机的方法,提高了苹果糖度预测的精度。

尽管近红外光谱可用于果蔬等食品中含糖量等营养成分的分析,但一台近红外设备上建立的模型无法有效地应用于其他同类型设备,存在模型转换难的问题。自编码器(AE)神经网络模型是一种典型的深度学习模型,可以在降维的同时进行特征提取,捕捉不同仪器之间的基线漂移、波长漂移等信息,较好地解决光谱校正和模型转换的问题。Guo等^[27]在苹果可溶性固形物含量的近红外光谱分析中,采用AE神经网络模型可以有效消除不同检测终端和不同批次样品间的差异,且具有良好的应用前景。

1.4 多营养成分

深度学习可用于同时分析食物中的多种营养成分。Chen等^[28]以3个不同的NIR光谱仪上测量的80个玉米样品数据集构建了水分、蛋白质、油脂和淀粉含量预测的集成卷积神经网络(ECNN)模型。Shruti等^[29]利用改进的偏最小二乘回归(mPLS)技术建立的近红外光谱预测模型可用于苋菜和荞麦籽粒中油脂、蛋白质、脂肪酸和必需氨基酸含量的预测。

膳食餐盘中的食物具有多样性、区域性等特点,如何通过餐盘食物图像快速准确预测其中的营养素是一项较大的挑战。Chen等^[30]利用Tripadvisor和Google Place收集了美国大哈特福德地区470家餐厅的15 908张美食图片,采用专有的深度学习模型Calorie Mama评估了餐厅食品中的热量、碳水化合物、蛋白质和脂肪等营养素。Ma等^[31]构建了一个开放获取的中国菜肴图像数据库ChinaFood-100,优化选取了深度学习模型Inception V3,实现了对餐盘中的蛋白质、纤维素、维生素C、钙、铁等营养素含量的准确预测。Shi等^[32]建立了一种中国托盘餐图像集ChinaLunchTray-99,采用更快的区域卷积神经网络(Faster R-CNN)的深度学习特征提取框架分析了餐盘中的蛋白质、碳水化合物、脂肪、膳食纤维、维生素A、维生素E、维生素C、钙、磷、钾、钠、镁、铁、锌、硒、铜、锰和胆固醇等成分。Park等^[33]采集了92 000张韩国食物图像作为训练集,将深度学习模型应用于移动的设备来检测和量化食物的营养摄入情况。Lu等^[34]开发了一种名为goFOOD™的系统,可以根据智能手机捕获的食品图像估计膳食中碳水化合物、蛋白质和脂肪等营养素含量。基于对118种市售加工食品样本的高光谱(NIR和Vis-NIR)图像数据,Marín-Méndez等^[35]筛选了10种不同的模型预测其能量、水分、脂肪、碳水化合物和灰分含量,其中含量预测最准确的为蛋白质。Shao等^[36]采用四传感器的英特尔实感D435(2个红外传感器,1个红外激光发射器和1个

颜色传感器)采集餐盘食物图像,建立了一种 Swin-Nutrition 深度学习方法评估膳食中碳水化合物、脂肪和蛋白质含量。以上研究大多采用 RGB 食物图像作为输入的单模态预测方法,强调食物识别和分类,由于缺少食物质量和体积方面的数据,影响了营养成分预测的准确性。多模态方法在 RGB 图像的基础上增加了深度图像(RGB-D),采用数据互补的方式提升模型的准确性(图 3)。Nutrition5k 为一个包含 5 000 个真实世界中常见菜肴及其相关视频、深度图像、成分重量和营养信息的数据集,常被用于训练和测试模型的预测效果^[37]。Shao 等^[38]利用 Nutrition5k 中的 2 960 对 RGB-D 图像,构建了融合多模态特征(MMFF)和多尺度融合的碳水化合物、蛋白、脂肪的评价网络,模型的鲁棒性得到有效提升。Nian 等^[39]构建了成分引导的多模态交互和细化网络(IMIR-Net)增强对 RGB-D 食品数据的理解,其预测平均 PMAE 值为 17.4%。Bianco 等^[40]以 Nutrition5k 为参照,比较了意大利和美国食物成分数据库(FCDB)之间的差异,为提高深度学习在全球差异化膳食营养评估中的准确性提供了技术参考。




图3 基于RGB-D图像的机器学习等人工智能技术预测食品营养成分

Figure 3 Artificial intelligence technologies such as machine learning based on RGB-D images for predicting food nutritional components

2 机器学习在功能成分分析与筛选中的应用

食物中的多酚、黄酮、多糖等功能成分是调节人体健康的重要营养物质,其组成和含量影响食物的营养价值。枸杞中富含多酚、黄酮等功能成分,是中国传统药食兼用食品。Shen 等^[41-43]采用近红外光谱技术结合传统的机器学习方法可以较好地定量分析枸杞和黑枸杞中的总酚、总黄酮、总花青素等成分。Zhang 等^[44]将深度学习方法应用于干黑枸杞的花青素、类黄酮和酚类物质分析中,取得了与传统机器学习模型相当的结果。儿茶素含量是茶叶品质的重要决定因素,Zhang 等^[45]采用深度学习方法实现了同时准确预测红茶中 4 种主要儿茶素含量(表儿茶素的 $R^2=0.92$, RMSE=0.018; 表儿茶素没食子酸酯的 $R^2=$

0.96, RMSE=0.11; 表没食子儿茶素的 $R^2=0.97$, RMSE=0.14; 表没食子儿茶素没食子酸酯的 $R^2=0.97$, RMSE=0.32)。虾青素和类胡萝卜素是食物中典型的抗氧化成分,张全通等^[46]采用计算机视觉结合卷积神经网络技术实现了南极磷虾粉中虾青素含量的准确预测;汤馥睿等^[47]利用全量程光谱仪结合连续小波变换和竞争性自适应重加权算法建立了预测叶片中类胡萝卜素含量的机器学习方法。

机器学习模型还被用于天然产物中功能成分的筛选。Zhang 等^[48]综述了机器学习筛选抗菌、抗癌、抗炎、蛋白靶向等功能成分的研究案例,总结并比较了不同算法之间的优缺点。Periwal 等^[49]以 FDA 批准的 1 410 种药物与其已知靶点之间的映射为数据集,建立了一种膳食功能成分筛选的机器学习方法。骨骼肌流失是导致老年人生活质量下降、慢性病发病率和死亡率增加的重要因素, Lee 等^[50]基于多靶点的机器学习系统发现柑橘醇是干预骨骼肌分化和萎缩的有效功能成分。5-脂氧合酶(5-LO)为炎症反应的重要靶点, Mikutis 等^[51]利用小分子-生物分子相互作用数据库 ChEMBL 作为数据集,构建了一种机器学习筛选具有抑制 5-LO 活性的天然产物方法,成功鉴定出 9 种功能成分。Zhang 等^[52]开发了一个基于机器学习的预测抗炎活性成分的在线平台 InflammNat (<http://www.inflamnat.com/>),可以用于预测化合物与靶标之间的互作关系。以上研究成果为机器学习等 AI 技术筛选具有健康调节功效的活性成分提供了高效且准确的预测方法。

3 机器学习与个性化营养

个性化营养也称精准营养,是一种使用个人特征信息开发有针对性的营养建议、产品或服务的方法^[53]。近年来,随着基因组学、蛋白组学、代谢组学等多组学技术的发展,利用机器学习等 AI 工具开展的个性化膳食建议成为食品营养领域的研究热点(图 4)。

Zeevi 等^[54]设计了一种机器学习算法,整合了血液参数、饮食习惯、人体测量(身高、臀围等)、身体活动和肠道




图4 基于多组学数据的机器学习个性化营养

Figure 4 Machine learning-based personalized nutrition using multi-omics data

微生物群等信息,准确地预测了个性化饮食的餐后血糖反应。Berry等^[55]采集了英国1 002例包括双胞胎和健康成人的遗传、代谢、微生物组和膳食背景数据,通过机器学习的方法预测了甘油三酯和葡萄糖对标准化膳食的反应,为制定个性化饮食策略提供了信息。Pokushalov等^[56]以生物标志物为导向的个性化营养能够更精确地评估健康状况、识别缺陷和考虑个人的代谢特征。糖化血红蛋白(HbA 1c)为3个月平均血糖水平的标志物,通常用于评估糖尿病管理中的血糖控制。短期(90 d)和中期(6个月)随访研究^[57-59]表明,基于机器学习等人工智能技术的个性化营养计划成功降低了HbA 1c水平,一定程度上缓解了糖尿病症状。机器学习方法还能更准确地评估食物模式和营养模式与10年心脏代谢风险之间的关联,为个性化膳食降低心血管疾病风险提供了数据支撑^[60]。GenAIS™系统可根据每个人的生物标志物特征定制膳食补充剂的摄入建议,患者在90 d内LDL-C以及总胆固醇和甘油三酯水平的降低幅度显著高于标准的医生指导方案^[61]。Ramos-Lopez等^[62]根据表型和基因型标记以及生活方式和饮食偏好等信息,确定了蛋白质适度高或脂质低的两种个性化低热量减肥饮食对不同类型超重/肥胖人群的适用性。量身定制的个性化营养膳食计划是以菜单方式进行推荐而不是单个食物的组合。因此,Lee等^[63]利用机器学习的方式从真实膳食数据中提取隐含的营养成分模式用于优化菜单,该方法在儿童膳食计划中被证明是可行的。Feng等^[64]开发了一种AI智能手机小程序,旨在帮助在中国营养师短缺的情况下为大众提供菜肴的营养评价和餐后个性化营养评估。Sookrah等^[65]面向高血压患者,在综合分析用户的高血压水平、过敏史、年龄、体重、吸烟/饮酒、饮食摄入量和食物偏好等信息的基础上使用机器学习建立了DASH个性化膳食推荐系统。针对更年期女性的症状强度、脉搏率、体温、睡眠时间和饮食习惯等基本参数,Logapriya等^[66]通过机器学习建立了具有个性化定制的膳食指导系统。Santhuja等^[67]使用机器学习、物联网和图像处理技术评估食物图像数据并提取有用信息,通过物联网实时反馈为用户提供个性化的营养建议。机器学习模型中的大型语言模型(LLMs),例如DeepSeek、GPT等,可以理解和生成自然语言,具有卓越的准确性和流畅性,使其成为可用于教育、医疗保健、金融等领域的强大工具。Van-Erp等^[68]讨论了使用LLMs和AI来分析食谱和食品营养相关技术及应用实例。今后,LLMs在数字化营养方面具有广阔的应用场景,包括提供个性化的营养建议、回答营养相关的问题、生成个性化食谱、分析和解释营养相关的数据等^[69],有可能彻底改变人们饮食习惯,为个性化营养和健康管理提供专业且有价值的指导。

4 结语

随着光谱成像等无损检测技术的快速发展,大量的食品图像数据可以从不同维度采集和分析,机器学习等人工智能工具的介入为快速、实时获取和评估食品特别是餐盘食品营养健康特征提供了更为高效和准确的技术手段。同时,基因组、蛋白组、脂质组、代谢组、微生物组等组学技术为食品营养与健康领域的研究提供了海量的个性化人体数据,也亟需人工智能辅助分析以建立个体数据、膳食与健康之间的关系,进而为个性化营养提供精准的指导。

尽管基于卷积神经网络及其优化模型的机器学习等人工智能技术在食品营养和健康领域已展现出非常高的识别准确性和出色的泛化能力,但在大规模基准数据集构建、高精度图像采集与校准分析、多模型混合技术融合等技术层面还存在一些尚待解决的问题。①用于模型训练和构建的数据集不完整,需要来自多样化和大规模的真实世界数据提高机器学习等人工智能模型的准确度。②光谱图像采集设备,特别是便携式采集设备的精度不高。不同光谱图像采集设备(包括手机等移动终端设备)所建立的模型通用性差,需要解决设备校正和模型转换的问题。③模型的运行效率不高,需要进一步优化和创新机器学习的模型和算法以降低时间复杂度,引入其他先进模型与机器学习模型混合以提高识别的准确度和鲁棒性。④个性化营养中的生物标志物还需进一步结合多组学技术挖掘,不同健康需求与个性化生物标志物之间的关系还需要借助人工智能工具进一步阐明。

参考文献

- [1] INGLE P D, CHRISTIAN R, PUROHIT P, et al. Determination of protein content by NIR spectroscopy in protein powder mix products[J]. *Journal of AOAC International*, 2016, 99(2): 360-363.
- [2] HASSOUN A, AÏT-KADDOUR A, ABU-MAHFOUZ A M, et al. The fourth industrial revolution in the food industry: part I: industry 4.0 technologies[J]. *Critical Reviews in Food Science and Nutrition*, 2023, 63(23): 6 547-6 563.
- [3] CLASS L C, KUHNEN G, ROHN S, et al. Diving deep into the data: a review of deep learning approaches and potential applications in foodomics[J]. *Foods*, 2021, 10(8): 1 803.
- [4] BURKE L E, WARZISKI M, STARRETT T, et al. Self-monitoring dietary intake: current and future practices[J]. *Journal of Renal Nutrition*, 2005, 15(3): 281-290.
- [5] CAPORASO N, WHITWORTH M B, FISK I D. Protein content prediction in single wheat kernels using hyperspectral imaging[J]. *Food Chemistry*, 2018, 240: 32-42.
- [6] SU W H, XUE H D. Imaging spectroscopy and machine

- learning for intelligent determination of potato and sweet potato quality[J]. *Foods*, 2021, 10(9): 2 146.
- [7] LI D D, ZHANG D Y, JIANG D P, et al. Hazelnut quality detection based on deep learning and near-infrared spectroscopy [J]. *Ukrainian Journal of Physical Optics*, 2022, 23(4): 267-283.
- [8] CUI C H, FEARN T. Modern practical convolutional neural networks for multivariate regression: applications to NIR calibration[J]. *Chemometrics and Intelligent Laboratory Systems*, 2018, 182: 9-20.
- [9] HOU Y C, ZHAO P H, ZHANG F, et al. Fourier-transform infrared spectroscopy and machine learning to predict amino acid content of nine commercial insects[J]. *Food Science and Technology*, 2022, 42: e100821.
- [10] ABDALLAH S E, ELMESSERY W M, AL-SATTARY N S A. An innovative optical instrument for meat quality inspection based on artificial intelligence techniques[J]. *Ama-Agricultural Mechanization in Asia Africa and Latin America*, 2022, 53(2): 55-69.
- [11] SHERMILA P J, MILTON A. Estimation of protein from the images of health drink powders[J]. *Journal of Food Science and Technology*, 2020, 57(5): 1 887-1 895.
- [12] MUÑOZ I, GOU P, FULLADOSA E. Computer image analysis for intramuscular fat segmentation in dry-cured ham slices using convolutional neural networks[J]. *Food Control*, 2019, 106: 106693.
- [13] MALEK S, MELGANI F, BAZI Y. One-dimensional convolutional neural networks for spectroscopic signal regression[J]. *Journal of Chemometrics*, 2018, 32(5): e2977.
- [14] LIU Z D, RADY A, WIJEWARDANE N K, et al. Fourier-transform infrared spectroscopy and machine learning to predict fatty acid content of nine commercial insects[J]. *Journal of Food Measurement and Characterization*, 2021, 15 (1): 953-960.
- [15] LIU J Z, YANG S W, XIE Y H, et al. Classification of fats and oils based on Raman spectroscopy and deep learning[J]. *Journal of Computational Biophysics and Chemistry*, 2024, 23 (6): 753-764.
- [16] TACHIE C Y E, OBIRI-ANANEY D, TAWIAH N A, et al. Machine learning approaches for predicting fatty acid classes in popular US snacks using NHANES data[J]. *Nutrients*, 2023, 15(15): 3 310.
- [17] ANTHIMOPOULOS M, DEHAIS J, SHEVCHIK S, et al. Computer vision-based carbohydrate estimation for type 1 patients with diabetes using smartphones[J]. *Journal of Diabetes Science and Technology*, 2015, 9(3): 507-515.
- [18] DEHAIS J, ANTHIMOPOULOS M, SHEVCHIK S, et al. Two-view 3D reconstruction for food volume estimation[J]. *IEEE Transactions on Multimedia*, 2017, 19(5): 1 090-1 099.
- [19] DIAZ J T, VEAL M W, CHINN M S. Development of NIRS models to predict composition of enzymatically processed sweetpotato[J]. *Industrial Crops and Products*, 2014, 59: 119-124.
- [20] HAASE N U. Prediction of potato processing quality by near infrared reflectance spectroscopy of ground raw tubers[J]. *Journal of Near Infrared Spectroscopy*, 2011, 19(1): 37-45.
- [21] YU X J, LU H D, WU D. Development of deep learning method for predicting firmness and soluble solid content of postharvest Korla fragrant pear using Vis/NIR hyperspectral reflectance imaging[J]. *Postharvest Biology and Technology*, 2018, 141: 39-49.
- [22] 章恺, 朱丽芳, 李入林, 等. 基于改进 WOA-LSSVM 和高光谱的猕猴桃糖度无损检测[J]. *食品与机械*, 2024, 40(5): 107-112, 226.
- ZHANG K, ZHU L F, LI R L, et al. Non destructive detection of kiwifruit sugar content based on improved WOA-LSSVM and hyperspectral analysis[J]. *Food & Machinery*, 2024, 40(5): 107-112, 226.
- [23] CHO W, NA M, KIM S, et al. Automatic prediction of Brix and acidity in stages of ripeness of strawberries using image processing techniques[C]//2019 34th International Technical Conference on Circuits/Systems, Computers and Communications (ITC-CSCC). JeJu, Korea: IEEE, 2019: 1-4.
- [24] WEN J H, ABEEL T, DE WEERDT M. "How sweet are your strawberries?": predicting sugariness using non-destructive and affordable hardware[J]. *Frontiers in Plant Science*, 2023, 14: 1160645.
- [25] SUN M J, ZHANG D, LIU L, et al. How to predict the sugariness and hardness of melons: a near-infrared hyperspectral imaging method[J]. *Food Chemistry*, 2017, 218: 413-421.
- [26] 乔正明, 詹成. 基于近红外光谱和 SSA-ELM 的苹果糖度预测[J]. *食品与机械*, 2021, 37(9): 121-126.
- QIAO Z M, ZHAN C. Prediction of sugar content in apple based on near-infrared spectroscopy of SSA-ELM[J]. *Food & Machinery*, 2021, 37(9): 121-126.
- [27] GUO Z M, ZHANG Y Y, WANG J Y, et al. Detection model transfer of apple soluble solids content based on NIR spectroscopy and deep learning[J]. *Computers and Electronics in Agriculture*, 2023, 212: 108127.
- [28] CHEN Y Y, WANG Z B. Quantitative analysis modeling of infrared spectroscopy based on ensemble convolutional neural networks[J]. *Chemometrics and Intelligent Laboratory Systems*, 2018, 181: 1-10.
- [29] SHRUTI, SHUKLA A, RAHMAN S S, et al. Developing an NIRS prediction model for oil, protein, amino acids and fatty acids in amaranth and buckwheat[J]. *Agriculture*, 2023, 13 (2): 469.
- [30] CHEN X, JOHNSON E, KULKARNI A, et al. An exploratory approach to deriving nutrition information of restaurant food from crowdsourced food images: case of Hartford[J].

- Nutrients, 2021, 13(11): 4 132.
- [31] MA P H, LAU C P, YU N, et al. Image-based nutrient estimation for Chinese dishes using deep learning[J]. Food Research International, 2021, 147: 110437.
- [32] SHI J L, HAN Q, CAO Z X, et al. DeepTrayMeal: automatic dietary assessment for Chinese tray meals based on deep learning[J]. Food Chemistry, 2024, 434: 137525.
- [33] PARK S J, PALVANOV A, LEE C H, et al. The development of food image detection and recognition model of Korean food for mobile dietary management[J]. Nutrition Research and Practice, 2019, 13(6): 521-528.
- [34] LU Y, STATHOPOULOU T, VASILOGLOU M F, et al. goFOOD™: an artificial intelligence system for dietary assessment[J]. Sensors, 2020, 20(15): 4 283.
- [35] MARÍN-MÉNDEZ J J, LURI ESPLANDIÚ P, ALONSO-SANTAMARÍA M, et al. Hyperspectral imaging as a non-destructive technique for estimating the nutritional value of food[J]. Current Research in Food Science, 2024, 9: 100799.
- [36] SHAO W J, HOU S J, JIA W K, et al. Rapid non-destructive analysis of food nutrient content using swin-nutrition[J]. Foods, 2022, 11(21): 3 429.
- [37] THAMES Q, KARPUR A, NORRIS W, et al. Nutrition5k: Towards automatic nutritional understanding of generic food[J/OL]. Computer Vision and Pattern Recognition. (2021-07-21) [2024-12-11]. <https://ui.adsabs.harvard.edu/abs/2021arXiv210303375T>.
- [38] SHAO W J, MIN W Q, HOU S J, et al. Vision-based food nutrition estimation via RGB-D fusion network[J]. Food Chemistry, 2023, 424: 136309.
- [39] NIAN F D, HU Y J, GU Y H, et al. Ingredient-guided multi-modal interaction and refinement network for RGB-D food nutrition assessment[J]. Digital Signal Processing, 2024, 153: 104664.
- [40] BIANCO R, MARINONI M, COLUCCIA S, et al. Tailoring the nutritional composition of Italian foods to the US Nutrition5k dataset for food image recognition: challenges and a comparative analysis[J]. Nutrients, 2024, 16(19): 3 339.
- [41] SHEN T T, ZOU X B, SHI J Y, et al. Determination geographical origin and flavonoids content of goji berry using near-infrared spectroscopy and chemometrics[J]. Food Analytical Methods, 2016, 9(1): 68-79.
- [42] LI Y H, ZOU X B, SHEN T T, et al. Determination of geographical origin and anthocyanin content of black goji berry (*Lycium ruthenicum* Murr.) using near-infrared spectroscopy and chemometrics[J]. Food Analytical Methods, 2017, 10(4): 1 034-1 044.
- [43] ARSLAN M, ZOU X B, TAHIR H E, et al. Near-infrared spectroscopy coupled chemometric algorithms for prediction of antioxidant activity of black goji berries (*Lycium ruthenicum* Murr.) [J]. Journal of Food Measurement and Characterization, 2018, 12(4): 2 366-2 376.
- [44] ZHANG C, WU W Y, ZHOU L, et al. Developing deep learning based regression approaches for determination of chemical compositions in dry black goji berries (*Lycium ruthenicum* Murr.) using near-infrared hyperspectral imaging [J]. Food Chemistry, 2020, 319: 126536.
- [45] ZHANG M Z, ZHANG T, WANG Y, et al. Accurate prediction of tea catechin content with near-infrared spectroscopy by deep learning based on channel and spatial attention mechanisms[J]. Chemosensors, 2024, 12(9): 184.
- [46] 张全通, 郑尧, 杨柳, 等. 计算机视觉结合卷积神经网络快速检测南极磷虾粉中的虾青素含量[J]. 食品工业科技, 2025, 46(3): 11-18.
- ZHANG Q T, ZHENG Y, YANG L, et al. Rapid detection of astaxanthin in antarctic krill meal by computer vision combined with convolutional neural network[J]. Science and Technology of Food Industry, 2025, 46(3): 11-18.
- [47] 汤馥睿, 徐媛媛, 耿芫, 等. 模型约束与机器学习下的植物类胡萝卜素和叶绿素含量反演方法[J]. 光谱学与光谱分析, 2024, 44(8): 2 174-2 182.
- TANG F R, XU Y Y, GENG Y, et al. Retrieval of plant carotenoids and chlorophyll contents with model constraints and machine learning[J]. Spectroscopy and Spectral Analysis, 2024, 44(8): 2 174-2 182.
- [48] ZHANG R H, LI X L, ZHANG X J, et al. Machine learning approaches for elucidating the biological effects of natural products[J]. Natural Product Reports, 2021, 38(2): 346-361.
- [49] PERIWAL V, BASSLER S, ANDREJEV S, et al. Bioactivity assessment of natural compounds using machine learning models trained on target similarity between drugs[J]. PLoS Computational Biology, 2022, 18(4): e1010029.
- [50] LEE J J, AHN B M, KIM N, et al. Ensemble Machine learning model identified citrulinol as functional food candidate for improving myotube differentiation and controlling CT26-Induced myotube atrophy[J]. Journal of Functional Foods, 2023, 104: 105542.
- [51] MIKUTIS S, LAWRIOWITZ S, KRETZER C, et al. Machine learning uncovers natural product modulators of the 5-lipoxygenase pathway and facilitates the elucidation of their biological mechanisms[J]. ACS Chemical Biology, 2024, 19(1): 217-229.
- [52] ZHANG R H, REN S P, DAI Q, et al. InflamNat: web-based database and predictor of anti-inflammatory natural products [J]. Journal of Cheminformatics, 2022, 14(1): 30.
- [53] ORDOVAS J M, FERGUSON L R, SHYONG TAI E, et al. Personalised nutrition and health[J]. BMJ, 2018, 361: k2173.
- [54] ZEEVI D, KOREM T, ZMORA N, et al. Personalized nutrition by prediction of glycemic responses[J]. Cell, 2015, 163(5): 1 079-1 094.
- [55] BERRY S E, VALDES A M, DREW D A, et al. Human

- postprandial responses to food and potential for precision nutrition[J]. *Nature Medicine*, 2020, 26(6): 964-973.
- [56] POKUSHALOV E, PONOMARENKO A, SHRAINER E, et al. Biomarker-guided dietary supplementation: a narrative review of precision in personalized nutrition[J]. *Nutrients*, 2024, 16(23): 4 033.
- [57] SHAMANNA P, SABOO B, DAMODHARAN S, et al. Reducing HbA1c in type 2 diabetes using digital twin technology-enabled precision nutrition: a retrospective analysis [J]. *Diabetes Therapy*, 2020, 11(11): 2 703-2 714.
- [58] SHAMANNA P, JOSHI S, SHAH L, et al. Type 2 diabetes reversal with digital twin technology-enabled precision nutrition and staging of reversal: a retrospective cohort study [J]. *Clinical Diabetes and Endocrinology*, 2021, 7(1): 21.
- [59] REIN M, BEN-YACOV O, GODNEVA A, et al. Effects of personalized diets by prediction of glycemic responses on glycemic control and metabolic health in newly diagnosed T2DM: a randomized dietary intervention pilot trial[J]. *BMC Medicine*, 2022, 20(1): 56.
- [60] PANARETOS D, KOLOVEROU E, DIMOPOULOS A C, et al. A comparison of statistical and machine-learning techniques in evaluating the association between dietary patterns and 10-year cardiometabolic risk (2002—2012): the ATTICA study[J]. *The British Journal of Nutrition*, 2018, 120(3): 326-334.
- [61] POKUSHALOV E, PONOMARENKO A, SMITH J, et al. Efficacy of AI-guided (GenAIS™) dietary supplement prescriptions versus traditional methods for lowering LDL cholesterol: a randomized parallel-group pilot study[J]. *Nutrients*, 2024, 16(13): 2 023.
- [62] RAMOS-LOPEZ O, CUERVO M, GONI L, et al. Modeling of an integrative prototype based on genetic, phenotypic, and environmental information for personalized prescription of energy-restricted diets in overweight/obese subjects[J]. *The American Journal of Clinical Nutrition*, 2020, 111(2): 459-470.
- [63] LEE C H, KIM S, LIM C, et al. Diet planning with machine learning: teacher-forced REINFORCE for composition compliance with nutrition enhancement[C]// *Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining*. Singapore: ACM, 2021: 3 150-3 160.
- [64] FENG J Y, LIU H W, MAI S P, et al. Protocol of a parallel, randomized controlled trial on the effects of a novel personalized nutrition approach by artificial intelligence in real world scenario[J]. *BMC Public Health*, 2023, 23(1): 1 700.
- [65] SOOKRAH R, DHOWTAL J D, DEVI NAGOWAH S. A DASH diet recommendation system for hypertensive patients using machine learning[C]// *2019 7th International Conference on Information and Communication Technology (ICoICT)*. Kuala Lumpur, Malaysia: IEEE, 2019: 1-6.
- [66] LOGAPRIYA E, SURENDRAN R, NAVANEETHAKRISHNAN S R, et al. Optimizing health through nutrition: machine learning insights for menopausal women[C]// *2024 International Conference on Innovation and Intelligence for Informatics, Computing, and Technologies (3ICT)*. Sakhir, Bahrain: IEEE, 2024: 94-101.
- [67] SANTHUJA P, GURUVA REDDY E, ROY CHOUDRI S, et al. Intelligent personalized nutrition guidance system using IoT and machine learning algorithm[C]// *2023 Second International Conference on Smart Technologies For Smart Nation (SmartTechCon)*. Singapore: IEEE, 2023: 250-254.
- [68] VAN-ERP M, REYNOLDS C, MAYNARD D, et al. Using natural language processing and artificial intelligence to explore the nutrition and sustainability of recipes and food[J]. *Frontiers in Artificial Intelligence*, 2021, 3: 621577.
- [69] ABELTINO A, RIENTE A, BIANCHETTI G, et al. Digital applications for diet monitoring, planning, and precision nutrition for citizens and professionals: a state of the art[J]. *Nutrition Reviews*, 2025, 83(2): e574-e601.