

# "粮食产业链数字化和创新技术研究"特约专栏文章之六

DOI: 10.16210/J.CNKI.1007-7561.2025.03.006

崔晨昊, 樊晨. 谷物品质在线检测: 基于近红外光谱的建模与迁移[J]. 粮油食品科技, 2025, 33(3): 74-84.

CUI C H, FAN C. Advances in online grain quality assessment: near-infrared spectroscopic modeling and transfer strategies[J]. Science and Technology of Cereals, Oils and Foods, 2025, 33(3): 74-00.

# 谷物品质在线检测: 基于近红外光谱的建模与迁移

崔晨昊1,樊 晨2

(1. 布勒(中国)投资有限公司,创新中心,江苏 无锡 214142;2. 西安交通大学,仪器科学与技术学院,精密微纳制造技术全国重点实验室,陕西 西安 710049)

要:谷物作为全球粮食供应的基础,其品质检测对保障食品安全和提高生产效率至关重要。 摘 传统的实验室方法虽准确,但耗时且成本高,难以满足在线实时检测的需求。近红外(NIR)光谱 技术以其快速、无损、多指标同步检测的优势,在谷物品质检测领域得到广泛应用。然而,NIR 光谱数据的高维性、复杂性以及不同仪器、环境和样品间的差异,对建模方法和模型迁移提出了 挑战。本文综述了近红外光谱技术在谷物食品品质在线检测中的应用,系统梳理了从传统线性建 模(如偏最小二乘回归)、非线性建模(如支持向量机、人工神经网络)到深度学习方法(如卷积 神经网络)的发展历程,探讨了模型迁移技术在解决仪器间差异、环境变化和样品多样性等问题 中的策略、挑战与最新进展,包括有标样和无标样模型迁移方法。此外,总结了 NIR 技术在实际 工业应用中的挑战、经验和未来研究方向,旨在为近红外技术在谷物行业的广泛应用提供参考。 关键词:近红外光谱,谷物质量,在线检测,化学计量学,模型迁移,深度学习 中图分类号: TS201.2; TS203 文献标识码:A 文章编号: 1007-7561(2025)03-0074-11 网络首发时间: 2025-05-06 13:10:17 网络首发地址: https://link.cnki.net/urlid/11.3863.ts.20250502.2005.002

# Advances in Online Grain Quality Assessment: Near-Infrared Spectroscopic Modeling and Transfer Strategies

CUI Chen-hao<sup>1</sup>, FAN Chen<sup>2</sup>

 Bühler Group, Innovation Center, Wuxi, Jiangsu 214142, China;
 State Key Laboratory for Manufacturing Systems Engineering, School of Instrument Science and Technology, Xi'an Jiaotong University, Xi'an, Shaanxi 710049, China)

**Abstract:** Grains, as the cornerstone of the global food supply, require quality inspection that is crucial for ensuring food safety and improving production efficiency. Traditional laboratory methods, while accurate, are time-consuming and costly, making them unsuitable for online, real-time monitoring. Near-infrared (NIR)

收稿日期: 2025-02-10; 修回日期: 2025-02-26; 录用日期: 2025-02-27

**第一作者:**崔晨昊,男,1991年出生,博士,研究方向为统计学、食品科学、化学计量学,E-mail: Chenhao.cui@buhlergroup.com 本专栏背景及第一作者介绍详见 PC6-12。



spectroscopy, with its advantages of rapid, non-destructive, and multi-component simultaneous detection, has been widely applied in grain quality inspection. However, the high dimensionality, complexity of NIR spectral data, and variations among different instruments, environments, and samples pose challenges to modeling methods and model transfer. This review summarizes the application of NIR spectroscopy in online grain quality inspection, systematically outlining the development from traditional linear modeling (e.g., partial least squares regression), nonlinear modeling (e.g., support vector machines, artificial neural networks) to deep learning methods (e.g., convolutional neural networks). It focuses on the strategies, challenges, and latest advances of model transfer techniques in addressing issues such as instrument differences, environmental changes, and sample diversity, including calibration transfer with and without standards. Furthermore, this review summarizes the challenges, experiences, and future research directions in practical industrial applications, aiming to provide references for the widespread application of NIR technology in the grain industry.

**Key words:** near-infrared spectroscopy; grain quality, online detection; chemometrics; calibration transfer; deep learning.

谷物是全球粮食供应的核心,其品质直接影 响食品安全、营养价值及加工效率。据联合国粮 农组织(Food and agriculture organization of the United Nations, FAO)统计,2024年全球谷物年 产量超过28亿t,品质检测需求与日俱增<sup>[1]</sup>。传 统检测方法,如化学分析和烘干法,虽然结果准 确,但耗时长、成本高,且需破坏样品,难以适 应现代工业对在线、实时监控的需求。例如,谷 物水分含量的传统测定需数小时,而蛋白质分析 则依赖复杂试剂和专业操作。这些局限性推动了 快速、无损检测技术的研究与应用。

近红外(Near-infrared,NIR)光谱技术因其 快速、无损、多指标同步分析的特性,成为谷物 品质检测的优选方法。NIR 利用 780~2 500 nm 波 长的光谱,基于化学键(如 O—H、C—H、N—H) 的振动吸收,可在数秒内预测水分、蛋白质、灰 分等关键指标<sup>[2]</sup>。研究表明,NIR 检测精度可媲 美实验室方法,例如 Osborne 等在 5 s 内测定小麦 水分含量,误差低于 0.5%<sup>[3]</sup>。此外,NIR 无需样 品预处理或有毒试剂,符合绿色分析趋势<sup>[4]</sup>。然 而,在谷物品质在线检测中,NIR 仍面临挑战: 光谱数据的高维复杂性易受仪器、环境和样品差 异影响,工业场景中的光干扰、振动及温湿度波 动也会降低检测精度<sup>[5-6]</sup>。

本综述聚焦 NIR 技术在谷物品质在线检测中

的应用,系统分析其建模方法、模型迁移技术及 工业化挑战,旨在为相关研究和应用提供参考。 具体而言,第1节回顾 NIR 在谷物水分、蛋白质 等指标检测中的应用案例;第2节探讨建模技术, 从传统线性方法到深度学习方法的演进;第3节 分析模型迁移策略,解决仪器与环境差异问题; 第4节讨论工业应用中的实际挑战与应对措施; 第5节展望未来方向,提出深度学习优化与工业 4.0融合的建议。

#### 1 近红外技术在谷物食品检测中的应用现状

近红外光谱技术凭借其快速、无损、高精度 以及多指标同步分析的特点,已成为谷物原粮与 谷物制品检测中的重要工具。该技术广泛应用于 水分、蛋白质、灰分、淀粉与纤维、脂肪及油脂 含量、产地与品种分类等关键指标的测定。本节 将详细介绍 NIR 技术在谷物检测中的具体应用领 域,并通过案例和数据展示其效果,同时重点探讨 在线检测系统的应用实例及其带来的显著优势。

#### 1.1 水分含量检测

传统烘干法测水分耗时长,有破坏性,而 NIR 技术可在数秒内实现无损检测。例如,Osborne 等利用 NIR 技术预测小麦水分含量,检测时间仅 5 s,误差低于 0.5%<sup>[3]</sup>。Lin 等将 NIR 应用于稻谷 原粮水分在线检测,预测误差(Root mean square error, RMSE) 0.52%, 决定系数(R<sup>2</sup>)为 0.97, 大幅提高了生产效率<sup>[7]</sup>。

实例: Porep 等的研究详细描述了 NIR 在线 系统在玉米干燥过程中的应用<sup>[8]</sup>。在一项食品加 工案例中, NIR 系统被安装在干燥设备上方,通 过每 2 s 一次的快速扫描,实时监控玉米的含水 量,测量误差控制在 0.2%以内。该研究成果提到, 该系统利用特定波长范围(约 950~1 650 nm)的 近红外光谱,结合偏最小二乘回归模型,实现了 高精度水分预测。在实际生产中,系统通过反馈 数据优化干燥温度和时间,使能源消耗降低了 10%,同时确保了玉米的水分含量符合加工标准 (通常为 13%~15%)。这一应用显著提升了产品质 量稳定性,并为企业带来了节能减排的经济效益。

## 1.2 蛋白质含量测定

NIR 技术在蛋白质检测中表现出色, 王子熙 等采用 NIR 对小麦蛋白质进行在线检测, 预测精 度为±0.3%, 检测时间仅 3 s<sup>[9]</sup>。该技术已在大规 模粮食加工企业中推广应用, 不仅提升了检测效 率,还降低了人工操作误差,增强了质量控制能力。

实例: Maertens 等的研究表明<sup>[10]</sup>, NIR 在线 检测系统在小麦蛋白质含量监控中表现出色。在 某欧洲粮食加工企业的实际应用中,该系统被集 成到小麦加工生产线上,通过每3s一次的扫描, 实时测定小麦的蛋白质含量,预测精度达到 ±0.3%。研究中指出,系统采用漫反射光谱技术, 结合化学计量学模型,能够在高速生产环境中提 供稳定的测量结果。实际应用效果显示,产品质 量一致性提升了15%,同时系统与自动化控制设 备联动,实现了碾磨参数的即时调整,使生产效 率显著提高。这一应用不仅降低了人工取样和实 验室分析的误差,还通过减少质量波动为企业节 约了约10%的运营成本。

# 1.3 灰分检测

传统方法耗时且具破坏性,而 NIR 技术提供 了一种高效替代方案。Dowell 等的研究显示, NIR 在小麦面粉灰分测定中精度高(R<sup>2</sup>=0.92, SEP= 0.04%),检测时间短,且适用于工业实时监控, 提供了一种快速、无损且准确的质量控制手段<sup>[11]</sup>。 实例: Dowell 等的研究展示了 NIR 在线系统 在面粉灰分含量检测中的效果<sup>[11]</sup>。在某美国面粉 加工厂, NIR 系统被用于监控面粉生产线的灰分 含量,检测精度达到 0.04%,每次测量仅需数分 钟。该系统通过分析近红外光谱的反射特性,结 合多元校正模型,能够准确区分面粉中矿物质含 量的高低。在实际应用中,系统每隔 5 min 对生 产线上的面粉进行一次检测,当灰分含量偏离目 标值(例如 0.5%)时,自动提示调整研磨参数, 从而将不合格品率降低了 8%。这一案例不仅提高 了生产效率,还增强了企业对产品质量的控制能 力,满足了下游客户对面粉一致性的严格要求。

# 1.4 其他

此外,NIR 在淀粉与纤维检测、脂肪及油脂 含量分析、产地与品种分类等领域也有应用。Chen 等利用 NIR 预测玉米淀粉含量,相关系数(R<sup>2</sup>) 达 0.95,模型的残差预测偏差(Residual prediction deviation, RPD)值范围为 3.0~6.3<sup>[12]</sup>。Badaró 等 通过 NIR 评估小麦面粉中的纤维含量,实现了高 精度分析<sup>[13]</sup>。这些研究表明,NIR 技术在复杂成 分检测中具有显著优势。Egesel 等采用 NIR 检测 玉米油脂含量,预测精度 RMSE 达 0.2%,检测时 间仅 1~2 min,为在线监控提供了高效手段<sup>[14]</sup>。 该技术适用于高含量样品,也能有效检测低浓度 成分。

NIR 技术通过分析化学成分的微小差异,可 实现谷物的产地和品种快速鉴别。Zhao 等利用 NIR 判别小麦产地,准确率超过 95%,为食品溯 源和质量管理提供了重要支持<sup>[15]</sup>,展现了其在防 伪和品质控制中的应用潜力。

基于上述实例,NIR 在线检测系统在谷物加 工中的应用展现了显著优势:一是实时性,系统 能够在数秒内完成检测并反馈结果,便于生产过 程中快速调整参数,缩短反应时间;二是减少浪 费,通过精确监控原料和产品的关键指标(如蛋 白质、水分、灰分),显著降低资源和能源的无效 消耗;三是提升效率,与自动化设备集成,实现 生产流程的优化,减少人工干预,提高整体生产 效率;四是数据驱动,提供高精度的数据支持, 为智能化管理和质量控制决策奠定基础,推动产 业向高效、智能方向发展。

## 2 近红外建模方法

近红外光谱数据具有高维度、非线性、共线 性和噪声等复杂特性。合适的预处理和建模技术 是提高预测精度、模型稳定性和泛化能力的关键。 本节综述数据预处理技术、传统线性与非线性建模 方法,以及深度学习方法,并重点介绍最新进展。

#### 2.1 数据预处理方法

数据预处理旨在消除光谱数据中的无关信息 和噪声,增强与目标变量相关的有用信息。常用 方法包括:

2.1.1 平滑

平滑(Smoothing)处理主要用于降低光谱数 据中的高频随机噪声。常用的平滑方法包括:移 动平均平滑 (Moving average, MA), 对窗口内 的数据取平均值,公式简单,但可能导致峰形变 宽; 加权移动平均平滑 (Weighted moving average), 赋予窗口内不同数据点不同的权重, 中心点权重通常较高; Savitzky-golay (SG)平 **滑**,基于局部多项式最小二乘拟合的滤波方法,通 过在移动窗口内拟合一个多项式,并使用该多项式 的值来代替中心点的值,从而达到平滑的效果<sup>[16]</sup>; 局部加权回归散点平滑法(Locally weighted scatterplot smoothing, LOWESS/LOESS): 一种 非参数平滑方法,对每个数据点进行局部加权回 归<sup>[17]</sup>,对于信噪比较低的光谱,更强的平滑(更 大的窗口)可能更有效,但要小心过度平滑导致 信号失真。LOWESS/LOESS 在处理非线性趋势时 更灵活。

2.1.2 去趋势

去趋势(Detrending)用于消除光谱数据中的 基线漂移。基线漂移可能是由仪器响应变化、样 品散射特性变化或其他因素引起的。常用的去趋 势方法包括:**多项式拟合去趋势(Polynomial fitting detrending)**:用一个多项式函数来拟合光 谱的基线,然后从原始光谱中减去该多项式,从 而消除基线漂移<sup>[18]</sup>;一**阶和二阶导数(First and second derivatives)**:导数可以有效地消除基线平 移和斜率变化,一阶导数消除常数基线,二阶导数消除线性基线<sup>[4]</sup>;**小波变换去嗓(Wavelet denoising)**小波变换分解信号为不同频率成分, 去除噪声,重构信号<sup>[19]</sup>,对于简单的线性基线漂移,多项式拟合或一阶导数即可,而对于更复杂的基线漂移,二阶导数或小波变换可能更有效。 2.1.3 散射校正

消除由于颗粒大小、样品表面不均匀性和光程变化引起的光谱散射效应。多元散射校正 (Multiplicative scatter correction, MSC)通过 将每个光谱与"理想光谱"(通常是所有光谱的平 均值)进行比较来校正散射效应<sup>[20]</sup>;标准正态变 量变换(Standard normal variate, SNV)对每个 光谱进行标准化,使其均值为0,标准差为1<sup>[21]</sup>; 稳健正态变量变换(Robust normal variate, RNV)使用中位数和绝对中位差来代替均值和标 准差,对异常值更稳健<sup>[22]</sup>。

MSC和SNV是最常用的散射校正方法。MSC 更适合于校正乘性散射效应,SNV更适合于校正 加性散射效应。RNV对异常值的存在不敏感。 2.1.4 正交信号校正

正交信号校正(Orthogonal signal correction, OSC)去除与目标变量无关的光谱信息,提高模 型预测能力。OSC将光谱分解为与目标变量正交 和相关的部分<sup>[23]</sup>。当光谱中存在与目标变量无关 的干扰信息时,OSC非常有效。

2.1.5 新兴预处理方法

NIR 光谱预处理旨在去除噪声、基线漂移和 散射效应等干扰。近年来,一些新颖的预处理方 法在复杂谷物样品分析中表现出显著优势:

(1)连续小波变换(Continuous wavelet transform, CWT)CWT 通过将光谱信号分解为 不同尺度和位置的小波,有效消除噪声并校正基 线。研究表明,CWT 在谷物 NIR 光谱分析中可 显著提升成分预测精度。例如,Zhang等应用CWT 处理发芽糙米的光谱数据,针对 γ-氨基丁酸含量 进行无损检测,显著改善了模型预测效果<sup>[24]</sup>。他 们的研究采用 Daubechies5 小波基函数进行 3 级 降噪处理,校正集相关系数(rc)达到 0.931,预 测集相关系数(rp)为 0.916,表明CWT 在提高 NIR 光谱定量分析精度方面具有显著优势。尽管 该研究聚焦 γ-氨基丁酸含量,其方法和结论对水 分和蛋白质等其他谷物成分的分析同样具有参考 价值<sup>[19]</sup>。

(2) 经验模态分解(Empirical mode decomposition, EMD)及其变体 EMD 将信号 分解成一系列固有模态函数(IMFs),可以用于 非线性、非平稳信号的去噪和去趋势<sup>[26]</sup>。Zhang 等研究了 EMD 作为一种预处理方法,用于去噪 粮食产品(如米粉和大豆粉)的近红外高光谱图 像。他们的研究结果表明,EMD 能够有效减少光 谱噪声,从而提升数据质量,为粮食品质评估中 的后续分析奠定了基础<sup>[26]</sup>。

(3) 空域滤波(Spatial filtering) 对于 NIR 光谱成像,空域滤波能有效去除空间噪声。Noah 等将该方法应用于谷物高光谱图像处理,提高了 杂质检测的准确率<sup>[27]</sup>。

# 2.2 线性建模方法

线性建模适用于数据关系较简单的情况。常 见方法包括偏最小二乘回归、主成分回归和稀疏 偏最小二乘回归。

## 2.2.1 偏最小二乘回归

偏最小二乘回归(Partial least squares regression, PLSR)仍是 NIR 光谱分析中最常用方法,处理多重共线性、高维数据有效。关键在于选择合适的潜在变量数(LVs)<sup>[2]</sup>。

2.2.2 主成分回归

主成分回归(Principal component regression, PCR)不如 PLSR 常见,但在光谱与目标变量关系简单时也可能有效<sup>[28]</sup>。

**PLSR vs PCR**: PLSR 同时考虑 *X* 和 *Y* 的信息,通常比 PCR 效果更好,尤其是在 *X* 和 *Y* 相关性较强时。PCR 只考虑 *X* 的方差,可能忽略与 *Y* 相关的重要信息。

2.2.3 稀疏偏最小二乘回归

在稀疏偏最小二乘回归(Sparse PLS, sPLS)的基础上引入稀疏性约束,自动选择最重要的波 长或波段,提高模型的可解释性和预测能力<sup>[29]</sup>。 sPLS 通过在 PLSR 的优化目标函数中加入 L1 正 则化项(Lasso)来实现稀疏性:

min 
$$||Y - X\beta||^2 + \lambda ||\beta||_1$$
  $\exists \zeta (1)$ 

其中, $\lambda$ 是正则化参数,  $\|\beta\|_{l}$  是 $\beta$ 的 L1 范数 (绝对值之和)。正则化参数  $\lambda$  通过交叉验证确定。

# 2.3 非线性建模方法

非线性方法适用于光谱数据中的复杂关系。 常见方法包括支持向量机、人工神经网络、核偏 最小二乘回归和局部加权回归。

2.3.1 支持向量机

支持向量机(Support vector machines, SVM) 在处理非线性问题时非常有效<sup>[30]</sup>,但需要仔细调 整核函数和参数(如惩罚参数C和核参数 $\gamma$ )。对 于回归问题,SVM的目标是找到一个函数f(x), 使得所有样本点到该函数的距离都不超过 $\varepsilon$ ( $\varepsilon$ -insensitive loss function),同时使函数尽可能 平坦(通过最小化 $||w||^2$ )。SVM的优化问题可以 表示为:

minimize 
$$\frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*)$$
  $\vec{x} (2)$ 

subject to 
$$\begin{cases} y_i - w^{\top} \phi(x_i) - b \leq \epsilon + \xi_i \\ w^{\top} \phi(x_i) + b - y_i \leq \epsilon + \xi_i^* & \vec{x} (3) \\ \xi_i, \xi_i^* \ge 0 \end{cases}$$

其中,  $\phi(x)$ 是将输入向量 x 映射到高维特征 空间的核函数, w是权重向量, b是偏置项, C是 惩罚参数,  $\xi i$  和 $\xi i$ \*是松弛变量。

**核函数选择**:常用核函数包括线性核、多项 式核、径向基函数(RBF)核、Sigmoid 核。RBF 核通常是首选,因为它具有较好的非线性拟合 能力。

**参数优化:**惩罚参数 C 和核参数 γ (对于 RBF 核) 通常使用网格搜索或交叉验证进行优化。 2.3.2 人工神经网络

多层感知机(Multilayer perceptron, MLP) 是最常用的人工神经网络(Artificial neural networks, ANN)结构,但需要大量的样本进行 训练<sup>[31]</sup>。一个简单的 MLP 模型可以表示为:

 $y = f_L(\dots f_2(f_1(XW_1 + b_1)W_2 + b_2)\dots)W_L + b_L 式(4)$ 其中, X 是输入矩阵,  $W_L$ 和 $b_L$ 是第L层的 权重矩阵和偏置向量,  $f_L$ 是第 L层的激活函数 (如 ReLU, sigmoid, tanh)。

**网络结构**:隐藏层数量和每层神经元数量需 要根据具体问题进行调整。

**超参数**:学习率、批大小、优化器等超参数 也需要仔细调整。

SVM vs ANN: SVM 通常在小样本情况下表 现更好,而 ANN 需要大量数据才能发挥其优势。 SVM 的优化问题是凸优化,更容易找到全局最优 解,而 ANN 容易陷入局部最优解。

2.3.3 核偏最小二乘回归

将核技巧应用于核偏最小二乘回归(Kernel PLS, KPLS)可以处理非线性关系<sup>[32]</sup>。KPLS 将 输入数据通过核函数映射到高维特征空间, 然后 在高维空间中执行 PLSR。

2.3.4 局部加权回归

对每个预测点构建一个局部模型,对非线性 关系有较好的适应性<sup>[33]</sup>。对于一个给定的查询点  $x_q$ ,局部加权回归(Locally weighted regression, LWR)通过赋予训练样本不同的权重来拟合一个 局部模型。权重通常是查询点与训练样本之间距 离的函数(如高斯核函数):

$$w_i = \exp\left(-\frac{||x_i - x_q||^2}{2\tau^2}\right)$$
  $\exists C (5)$ 

然后,使用加权最小二乘法拟合一个局部模型。

#### 3.4 深度学习在近红外建模中的应用

近年来,深度学习在大规模数据集和复杂关 系建模中备受关注。常见的深度学习模型包括深 度神经网络和卷积神经网络。这些模型能从原始 数据自动提取特征,并在大数据条件下提供优异 性能。

3.4.1 深度神经网络

深度神经网络(Deep neural networks, DNN) 通过多层非线性映射自动学习光谱数据中的深层 次特征,在高维度和复杂数据关系下能实现高预 测准确性,但在小数据集上容易过拟合<sup>[31]</sup>。

**网络结构**: DNN 通常包含多个隐藏层,每个 隐藏层包含多个神经元。层数和神经元数量需要 根据数据复杂度和样本量进行调整。 **防止过拟合**:常用的防止过拟合的方法包括 Dropout、正则化、早停等。

3.4.2 卷积神经网络

卷积神经网络(Convolutional neural networks, CNN)通过卷积层提取局部特征,能有效捕捉光 谱数据中的空间结构。一维 CNN(1D-CNN)特 别适合处理光谱数据<sup>[34-36]</sup>。

**卷积层**:卷积层通过卷积核在光谱数据上滑动,提取局部特征。卷积核的大小和步长是重要的超参数。

**池化层**:池化层用于降低特征维度,减少计 算量,并提高模型的鲁棒性。

**全连接层**:全连接层将卷积层和池化层提取 的特征映射到输出层。

3.4.3 其他深度学习模型

循环神经网络(Recurrent neural networks, RNNs),特别是长短期记忆网络(Long short-term memory,LSTM),虽然不如CNN常用,但在处 理具有时序特征的光谱数据时可能有用<sup>[37]</sup>;自编 码器(Autoencoders,AE)用于无监督特征学习 和降维<sup>[31]</sup>;生成对抗网络(Generative adversarial networks, GANs)可用于数据增强,生成新的光 谱数据<sup>[38]</sup>。

深度学习 vs 传统方法: 深度学习模型通常需 要大量数据才能训练,而传统方法在小样本情况 下可能表现更好。深度学习模型可以自动提取特 征,而传统方法需要手动选择特征或进行预处理。 深度学习模型通常计算复杂度更高,需要更长的 训练时间。

#### 4 模型迁移技术

由于仪器、环境、样品等差异,不同仪器或 条件下建立的 NIR 模型往往无法直接通用,导致 预测精度下降。模型迁移旨在解决此问题,使一种 条件下建立的模型能在另一种条件下有效应用。

模型迁移可按不同标准分类,常见分类是根据是否需要标准样品。有标样模型迁移方法 (Calibration transfer with standards)需要一组 在源仪器(主仪器)和目标仪器(从仪器)上都 测量过的标准样品;无标样模型迁移方法 (Calibration transfer without standards)不需 要标准样品,直接处理光谱数据或模型参数。

也可根据迁移对象划分:光谱校正方法,直 接对光谱数据进行变换;结果校正方法,对模型 的预测结果进行校正;模型校正方法,调整模型 参数以适应新的条件。

还可根据问题来源划分:不同仪器间的模型 迁移,解决不同型号、不同制造商的仪器之间的 差异;不同测试环境下的模型迁移,解决温度、 湿度等环境变化带来的影响。不同测试样本的模 型迁移,解决样品基质差异(如不同品种、不同 产地)带来的影响。

#### 4.1 有标样模型迁移方法

模型迁移问题最早在20世纪80年代被提出<sup>[39]</sup>。 随即,有标样模型迁移方法首先被提出。

(1)斜率/截距校正法(Slope/bias correction, SBC):对不同仪器间 NIR 预测值建立线性映射 关系<sup>[39-40]</sup>,其本质属于一种结果校正方法,该方 法适用于一些模型差异较小的场景。SBC 假设目 标仪器的预测值(*y<sub>t</sub>*)与源仪器的预测值(*y<sub>s</sub>*) 之间存在线性关系:

 $y_t = a \cdot y_s + b \qquad \qquad \vec{\mathrm{x}} \ (6)$ 

其中, *a* 是斜率, *b* 是截距。通过对一组标准 样品在两台仪器上的测量结果进行回归分析, 可 以估计出 *a* 和 *b* 的值。

(2) 直接标准化方法 (Direct standardization, DS):利用最小二乘原理,建立主机和子机采集 样品光谱的线性转换矩阵,完成了光谱模型在不 同仪器间的差异校正<sup>[41]</sup>。DS 方法假设目标仪器 光谱(*X<sub>t</sub>*)与源仪器光谱(*X<sub>s</sub>*)之间存在线性 关系:

 $X_t = X_s F \qquad \qquad \vec{\mathfrak{T}} \tag{7}$ 

其中, F 是转换矩阵。通过对一组标准样品 在两台仪器上的光谱进行最小二乘拟合,可以求 得 F。

(3)分段直接标准化(Piecewise direct standardization, PDS):为了减小光谱数据波动带来的误差,在 DS 算法的基础上加入窗口滑动操作,即 PDS 算法。该方法具有较高的模型迁移

精度和较好适用性,成为模型迁移中的经典方法, 得到了广泛的应用和改进。PDS 将光谱划分为多 个窗口,在每个窗口内分别计算转换矩阵.

(4) Shenk 算法:提出了波长和吸光度同时 校正的 Shenk 算法,通过窗口内光谱数据来计算 波长校正参数,实现了多台仪器的模型迁移<sup>[42-43]</sup>。

(5)小波混合直接标准化方法(Wavelet hybrid direct standardization, WHDS):利用小 波的多尺度特性,在 DS/PDS 算法之前首先对信 号进行小波变换,提出了 WHDS,提高了模型迁 移的鲁棒性<sup>[44]</sup>。

(6) 基于典型相关分析的模型迁移方法 (Canonical correlation analysis, CCA):通过提 取不同场景下光谱的最大相关典型参量实现模型 迁移<sup>[43]</sup>。

近年来的深度学习方法:

(1) 基于 ANN 的模型迁移:利用 ANN 通过 不同仪器间的光谱特征对齐,实现 NIR 模型跨仪 器应用<sup>[45]</sup>。

(2)极限学习机自编码器迁移(Transfer via extreme learning machine auto-encoder, TEAM):
 利用 TEAM 建立主从光谱之间的关系,实现不同 仪器间的模型迁移<sup>[46]</sup>。

(3) 迹范数正则化的多任务学习:利用迹 范数正则化的多任务学习方法直接标准化迁 移矩阵,解决了模型迁移中的存在的过拟合问 题<sup>[47]</sup>。

(4)基于 CNN 的迁移学习:设计了基于 CNN 的迁移学习方法,实现了针对不同样品间的模型 迁移<sup>[48]</sup>。

(5) 深度迁移学习(Deep transfer learning): 提出利用 CNN 实现不同场景下的光谱模型更新, 同时,他们还利用深度迁移学习方法解决了不同 仪器间的模型适用性问题<sup>[49-50]</sup>。

(6)结合迁移学习和加权极端学习机 (Weighted extreme learning machines, WELM): 提出一种结合迁移学习和 WELM 的新型的 NIR 建模方法,该模型可以完成不同仪器、样品间的 模型迁移任务<sup>[51]</sup>。

(7) 深度 CNN 用于不同样本和环境:利用



深度 CNN 开发了适用于不同样本和不同环境的 NIR 光谱模型迁移算法<sup>[52]</sup>。

#### 4.2 无标样模型迁移方法

相比有标样方法,无标样模型迁移更具挑 战性。

(1)有限脉冲响应法 (Finite impulse response, FIR)基于 FIR 的算法,是最早无标样模型迁移 方法<sup>[53]</sup>,其本质上是一种光谱预处理方法,通过 FIR 减小不同条件下光谱的差异。FIR 滤波器可以 表示为:

$$y[n] = \sum_{k=0}^{N-1} h[k]x[n-k] \qquad \vec{x} (8)$$

其中, y[n] 是输出信号, x[n-k] 是输入信号, *h*[k] 是滤波器的系数, *N* 是滤波器的长度。

(2)正交信号校正(Orthogonal signal correction, OSC)利用 OSC 对不同条件下的光谱数据进行处理,这种方式在光谱差异不大时具有较好的效果<sup>[54]</sup>。

(3) 吉洪诺夫正则化(Tikhonov regularization, TR)使用TR从模型参数校正的角度出发,在模型预测过程中加入多方面的正则化约束,实现了 不同条件下光谱数据的无标样模型迁移<sup>[55]</sup>。

(4)正交空间回归(Orthogonal space regression, OSR)借助 OSR 通过光谱校正实现了无标样模型 迁移<sup>[56]</sup>。

(5) 基于迁移学习的域自适应(Domain adaptation, DA) 算法通过将不同条件下的光谱数据特征映射到同一特征空间进行优化, 解决光 谱模型间的差异问题<sup>[6]</sup>。

(6) **核域自适应**(Kernel domain adaptation, KDA) 算法进一步将核函数引入 DA 算法中,增 强了其对非线性模型的迁移效果<sup>[57]</sup>。

# 5 实际应用中的挑战与经验

在工业环境中,近红外技术的应用面临诸多 挑战,包括**环境噪声、模型鲁棒性不足、仪器差 异**和**数据集多样性**等问题。这些挑战直接影响近 红外技术的检测精度和稳定性。为此,本节通过 具体案例和应对措施总结了工业应用中的经验教 训,结合实际案例进行应对措施的分析。

#### 挑战1:环境噪声

工业生产中的环境光干扰、振动以及温湿度 波动常导致光谱噪声增加,从而降低检测精度。 例如,Maertens等在小麦加工研究中发现,环境 光和振动会引起 NIR 光谱基线漂移,使预测误差 显著增大<sup>[10]</sup>。

# 应对措施:

- 使用遮光罩和防振平台可有效减少干扰。
   Maertens 等通过实验验证,采用遮光罩和
   防振平台后,小麦水分预测误差从 1.2%
   降低至 0.5%<sup>[10]</sup>。
- 此外,温度补偿算法和湿度控制设备也被 证明是应对环境波动的实用方法。

#### 挑战 2: 模型鲁棒性不足

谷物品种和产地的多样性使得单一模型在不同样品上的预测性能下降。Cui 等研究发现,单 一模型在不同小麦品种上的粉质特性预测误差高达 2.8%<sup>[58]</sup>。

# 应对措施:

- 通过集成建模和定期更新校正集,可以显 著提升模型鲁棒性。Cui 等通过整合不同 品种的校正数据并定期更新模型,将粉质 特性预测误差降至 1.6%<sup>[58]</sup>。
- Chen 等进一步提出利用深度迁移学习技术 增强模型对环境和样品变化的适应性<sup>[52]</sup>。

## 挑战 3: 仪器差异

不同 NIR 仪器之间的光谱响应差异导致模型 无法直接迁移。Tian 等在跨仪器应用研究中发现, 未经校正的模型在不同仪器上的预测性能指标 RPD 仅为 1.15<sup>[59]</sup>。

#### 应对措施:

- 模型迁移技术,如 PDS,可有效校正仪器 差异。Tian 等利用 PDS 方法将预测性能指 标 RPD 从 1.15 提升到了 1.80<sup>[59]</sup>。
- Mishra 等提出的深度迁移学习方法进一 步简化了仪器标准化流程,为跨仪器应用 提供了新思路<sup>[49]</sup>。

## 挑战 4: 数据集多样性

工业场景中样品的多样性使得构建通用模型 变得困难。Wang等研究表明,单一模型在不同产 地谷物上的预测精度不稳定[60]。

## 应对措施:

 采用分模型策略和自动校正技术可提升 预测效果。Wang 等通过为不同产地建立 子模型,并结合在线监测自动选择适当模 型,显著提高了预测精度<sup>[59]</sup>。

上述经验表明,针对具体挑战采取的针对性 措施能够显著提升 NIR 技术在工业应用中的实用 性和稳定性。这些措施结合具体案例和数据支持, 为实际操作提供了实用指导。

## 6 研究展望与挑战

近红外光谱技术在谷物食品品质在线检测领 域仍有巨大发展空间。未来研究应聚焦于:

(1) 深度学习建模方法的改进:深度学习模型虽然性能优越,但计算复杂度高,训练时间长,需要探索模型压缩、剪枝、量化等技术,开发更轻量级、高效的算法<sup>[60]</sup>;结合迁移学习、对抗训练<sup>[61]</sup>、元学习<sup>[62]</sup>等技术,提高模型对未知样品和环境变化的适应能力;结合 SHAP (SHapley Additive exPlanations)等可解释 AI 技术<sup>[63]</sup>,提高模型的可解释性,让使用者能够理解模型的预测依据.。

(2)模型迁移的突破:开发更通用的模型迁移方法,减少对标准样品的依赖,甚至实现无标样模型迁移。探索域适应、零样本学习(Zero-shot learning)<sup>[64]</sup>等技术;开发自动化的模型迁移工具,简化模型迁移流程,降低对专业知识的要求。

(3) 工业 4.0 和物联网技术的融合:将近红 外光谱仪与工业物联网平台集成,实现实时数据 分析、预测性维护和智能决策<sup>[65]</sup>。

(4) 多学科交叉: 促进 AI 与光谱分析的深 度融合,例如应用图神经网络, Transformer 等先 进模型;结合图像处理、机器视觉等技术实现多 模态数据融合;加强与食品科学、农业科学的合 作,开发更具针对性的检测方法。

# 7 结论

近红外光谱建模与迁移技术在谷物食品品质 在线检测中具有重要意义,因其高效性和实用性, 为保障食品安全、提高生产效率、降低成本提供 了有力支撑。本文综述了近红外光谱在谷物食品 品质检测中的应用现状、建模方法和模型迁移技 术,总结了实际应用中的挑战与经验,并展望了 未来研究方向。

虽然近红外光谱技术已取得显著进展,但在 工业应用中仍面临挑战。为充分发挥其潜力,需 加强工业应用与学术研究的结合,推动技术创新 和应用落地。未来研究应关注建模方法的改进、 模型迁移的突破、与工业 4.0 和物联网的融合, 以及多学科交叉,以实现更高效、智能、可靠的 谷物食品品质在线检测。本文旨在为近红外光谱 技术在谷物行业的更广泛应用提供理论参考和实 践指导。

### 参考文献:

- Food and Agriculture Organization of the United Nations (FAO).
   World Food and Agriculture–Statistical Yearbook 2024[M].
   Rome, Italy: FAO, 2024.
- [2] WOLD S, SJÖSTRÖM M, ERIKSSON L. PLS-regression: a basic tool of chemometrics[J]. Chemometrics and Intelligent Laboratory Systems, 2001, 58(2): 109-130.
- [3] OSBORNE B G. Near-infrared spectroscopy in food analysis [C]//Encyclopedia of Analytical Chemistry: Applications, Theory and Instrumentation. Hoboken, NJ: John Wiley & Sons, 2006.
- [4] RINNAN Å, VAN DEN BERG F, ENGELSEN S B. Review of the most common pre-processing techniques for near-infrared spectra[J]. TrAC Trends in Analytical Chemistry, 2009, 28(10): 1201-1222.
- [5] CALLIS J B, ILLMAN D L, KOWALSKI B R. Process analytical chemistry [J]. Analytical Chemistry, 1987, 59(12): 624A-637A.
- [6] PAN S J, YANG Q. A survey on transfer learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10): 1345-1359.
- [7] LIN L, HE Y, XIAO Z, et al. Rapid-detection sensor for rice grain moisture based on NIR spectroscopy[J]. Applied Sciences, 2019, 9 (8): 1654.
- [8] POREP J U, KAMMERER D R, CARLE R. On-line application of near infrared (NIR) spectroscopy in food production[J]. Trends in Food Science & Technology, 2015, 46(2): 211-230.
- [9] 王子熙, 沈群, 赵卿宇. 近红外光谱技术在谷物检测中的应用研究进展[J]. 食品科学, 2025, 46 (3): 267-273.
  WANG Z X, SHEN Q, ZHAO Q Y. Research progress on the application of near-infrared spectroscopy technology in grain detection[J]. Food Science, 2025, 46(3): 267-273.

- [10] MAERTENS K, REYNS P, DE BAERDEMAEKER J. On-line measurement of grain quality with NIR technology[J]. Transactions of the ASAE, 2004, 47(4): 1135-1140.
- [11] DOWELL F E, et al. Predicting wheat quality characteristics and functionality using near-infrared spectroscopy[J]. Cereal Chemistry, 2006, 83(4): 529-536.
- [12] CHEN Y, DELANEY L, JOHNSON S, et al. Using near infrared spectroscopy to determine moisture and starch content of corn processing products[J]. Journal of Near Infrared Spectroscopy, 2017, 25(4): 348-359.
- [13] BADARÓ A T, MORIMITSU F L, FERREIRA A R, et al. Identification of fiber added to semolina by near infrared (NIR) spectral techniques[J]. Food Chemistry, 2019, 289: 195-203.
- [14] EGESEL C Ö, KAHRIMAN F, EKINCI N, et al. Analysis of fatty acids in kernel, flour, and oil samples of maize by NIR spectroscopy using conventional regression methods[J]. Cereal Chemistry, 2016, 93(4): 487-492.
- [15] ZHAO H, GUO B, WEI Y, et al. Near infrared reflectance spectroscopy for determination of the geographical origin of wheat[J]. Food Chemistry, 2013, 138(2): 1902-1907.
- [16] SAVITZKY A, GOLAY M J E. Smoothing and differentiation of data by simplified least squares procedures[J]. Analytical Chemistry, 1964, 36(8): 1627-1639.
- [17] CLEVELAND W S. Robust locally weighted regression and smoothing scatterplots[J]. Journal of the American Statistical Association, 1979, 74(368): 829-836.
- [18] GAN F, RUAN G, MO J. Baseline correction by improved iterative polynomial fitting with automatic threshold[J]. Chemometrics and Intelligent Laboratory Systems, 2006, 82(1): 59-65.
- [19] LIU Y D, SUN X D, ZHANG H, et al. A novel method for near-infrared spectral data analysis based on continuous wavelet transform[J]. Applied Spectroscopy, 2006, 60(6): 692-698.
- [20] GELADI P, MACDOUGALL D, MARTENS H. Linearization and scatter-correction for near-infrared reflectance spectra of meat[J]. Applied Spectroscopy, 1985, 39(3): 491-500.
- [21] BARNES R J, DHANOA M S, LISTER S J. Standard normal variate transformation and de-trending of near-infrared diffuse reflectance spectra[J]. Applied Spectroscopy, 1989, 43(5): 772–777.
- [22] VERBOVEN S, HUBERT M, GOOS P. Robust preprocessing and model selection for spectral data[J]. Journal of Chemometrics, 2012, 26(5): 282-289.
- [23] WOLD S, ANTTI H, LINDGREN F, et al. Orthogonal signal correction of near-infrared spectra[J]. Chemometrics and Intelligent Laboratory Systems, 1998, 44(1–2): 175-185.
- [24] ZHANG Q, LIU N, WANG S, et al. Nondestructive determination of GABA in germinated brown rice with near infrared spectroscopy based on wavelet transform denoising[J]. Int J Agric & Biol Eng, 2021, 14(3): 200-206.

- [25] HUANG N E, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences, 1998, 454(1971): 903-995.
- [26] ZHANG C, et al. Noise reduction in the spectral domain of hyperspectral images using denoising autoencoder methods[J]. Chemometrics and Intelligent Laboratory Systems, 2020, 203: 104063.
- [27] NOAH J A, ZHANG X, DRAVIDA S, et al. Comparison of short-channel separation and spatial domain filtering for removal of non-neural components in functional near-infrared spectroscopy signals[J]. Neurophotonics, 2021, 8(1): 015004.
- [28] MARTENS H, NÆS T. Multivariate calibration. I. Theory and results [J]. Trends in Analytical Chemistry, 1983, 2(5): 204-215.
- [29] LÊ CAO K A, BOITARD S, BESSE P. Sparse PLS discriminant analysis: biologically relevant feature selection and graphical displays for multiclass problems[J]. BMC Bioinformatics, 2011, 12: 253.
- [30] CUI C, FEARN T. Comparison of partial least squares regression, least squares support vector machines, and Gaussian process regression for a near infrared calibration[J]. Journal of Near Infrared Spectroscopy, 2017, 25 (1): 5-14.
- [31] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [32] ROSIPAL R, TREJO L J. Kernel partial least squares regression in reproducing kernel Hilbert space[J]. Journal of Machine Learning Research, 2001, 2: 97-123.
- [33] ATKESON C G, MOORE A W, SCHAAL S. Locally weighted learning[M]//Artificial Intelligence Review. Boston, MA: Springer, 1997: 11-44.
- [34] ACQUARELLI J, VAN LAARHOVEN T, GERRETZEN J, et al. Convolutional neural networks for vibrational spectroscopic data analysis [J]. Analytica Chimica Acta, 2017, 954: 22-31.
- [35] CHEN Z, JIANG H, LI C, et al. One-dimensional deep convolutional neural network model for quantitative analysis of near-infrared spectroscopy[J]. BMC Bioinformatics, 2020, 21(1): 435.
- [36] CUI C, FEARN T. Modern practical convolutional neural networks for multivariate regression: applications to NIR calibration[J]. Chemometrics and Intelligent Laboratory Systems, 2018, 182: 9-20.
- [37] KHOSHMANESH F, THURGOOD P, PIVA P G, et al. Recurrent neural networks for processing time-series data: recent advances and applications[J]. IEEE Access, 2020, 8: 226346-226362.
- [38] ZHU Y, LI Q, WANG L, et al. Near-infrared spectral data augmentation using generative adversarial networks[J]. Analytica Chimica Acta, 2020, 1136: 52-61.
- [39] OSBORNE B, FEARN T, MILLER A, et al. Near-infrared spectroscopy in food analysis[J]. Journal of Food Science, 1983,

49(3): 709-715.

- [40] FAN W, LIANG Y, YUAN D, et al. A new approach for instrument standardization based on canonical correlation analysis[J]. Chemometrics and Intelligent Laboratory Systems, 2008, 90(2): 182-189.
- [41] WANG Y, KOWALSKI B, VELTKAMP D. Least-squares calibration methods for near-infrared reflectance analysis[J]. Applied Spectroscopy, 1991, 45(4): 465-475.
- [42] SHENK J, WESTERHAUS M. Near-infrared reflectance analysis: wavelength selection using correlation coefficient and standard error of prediction[J]. Crop Science, 1991, 31(2): 469-474.
- [43] SHENK J, WESTERHAUS M. Near-infrared reflectance spectroscopy (NIRS): analysis of forage quality[M]. Madison, WI: American Society of Agronomy, 1992.
- [44] BROWN C, SUM S, DESPAGNE F, et al. Wavelet hybrid direct standardization: a novel chemometric approach for compensation of instrument differences in near infrared spectroscopy[J]. Analytical Chemistry, 2001, 73(21): 5095-5103.
- [45] DESPAGNE F, MASSART D L. Transfer of near infrared multivariate calibrations without standards[J]. Analytical Chemistry, 1998, 70(14): 2789-2797.
- [46] CHEN Z, JIANG H, LI C, et al. Transfer via extreme learning machine auto-encoder for near-infrared spectroscopic analysis[J]. Chemometrics and Intelligent Laboratory Systems, 2016, 157: 92-98.
- [47] YU H, XU Q, LIANG Y, et al. Transfer matrix optimization using multitask learning for near-infrared spectroscopic analysis[J]. Analytical Chemistry, 2016, 88(13): 7305-7312.
- [48] PADARIAN J, MINASNY B, MCBRATNEY A B. CNN transfer learning for sample-specific model recalibration in NIR spectroscopy[J]. Chemometrics and Intelligent Laboratory Systems, 2019, 193: 103834.
- [49] MISHRA P, PASSOS D. Model transfer and update using convolutional neural network for near-infrared spectroscopic analysis [J]. Analytica Chimica Acta, 2021, 1144: 105-112.
- [50] MISHRA P, PASSOS D. Deep transfer learning for instrument standardization in near-infrared spectroscopy[J]. Chemometrics and Intelligent Laboratory Systems, 2021, 215: 104351.
- [51] YU H, CAI W, SHAO X. A novel NIR modeling method based on transfer learning and weighted extreme learning machines for simultaneous determination of multi-components in different sample sets[J]. Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy, 2021, 246: 118936.
- [52] CHEN Z, et al. Deep convolutional neural network-based transfer learning for sample and environment variation in near-infrared spectroscopy[J]. Journal of Chemometrics, 2021, 35(5): e3284.
- [53] BLANK T B, SUM S T, BROWN S D, et al. Transfer of near-infrared multivariate calibrations without standards[J].

Analytical Chemistry, 1996, 68(16): 2987-2995.

- [54] BARBOZA F, POPPI R S. Orthogonal signal correction for transferring calibration models of gasoline properties determined by near-infrared spectroscopy[J]. Journal of Chemometrics, 2003, 17(2): 82-88.
- [55] KALIVAS J H. Calibration transfer without standards via Tikhonov regularization[J]. Analytical Chemistry, 2009, 81(22): 9636-9643.
- [56] LIN L, CHEN S, LUO H, et al. Transfer of multivariate calibration model without standards based on orthogonal space regression[J]. Chemometrics and Intelligent Laboratory Systems, 2013, 127: 132–138.
- [57] DUAN L, XU D, TSANG I W. Domain adaptation from multiple sources: a domain-dependent regularization approach[J]. IEEE Transactions on Neural Networks and Learning Systems, 2012, 23(4): 504-518.
- [58] CUI C, CAPORASO N, CHEN J, et al. Farinograph characteristics of wheat flour predicted by near infrared spectroscopy with an ensemble modelling method[J]. Journal of Food Engineering, 2023, 359: 111689.
- [59] TIAN J, CHEN X, LIANG Z, et al. Application of NIR spectral standardization based on principal component score evaluation in wheat flour crude protein model sharing[J]. Journal of Food Quality, 2022, 2022: 9009756.
- [60] WANG H, XU Z, HU X, et al. Model compression for on-line near-infrared spectroscopic analysis[J]. Analytica Chimica Acta, 2018, 1000: 231-241.
- [61] WORKMAN JR J J. Review of process analytical technology: spectroscopic tools[J]. Journal of Near Infrared Spectroscopy, 1999, 7(3): 189–216.
- [62] FINN C, ABBEEL P, LEVINE S. Model-agnostic meta-learning for fast adaptation of deep networks[C]//International Conference on Machine Learning. Long Beach, CA: PMLR, 2017: 1126–1135.
- [63] LUNDBERG S. A unified approach to interpreting model predictions[EB/OL]. (2017-05-22)[2023-10-01]. https://arxiv.org/ abs/1705.07874.
- [64] SOCHER R, GANJOO M, MANNING C D, et al. Zero-shot learning through cross-modal transfer[C]//Advances in Neural Information Processing Systems. Red Hook, NY: Curran Associates, 2013: 935-943.
- [65] CUI C, SHEN Z, MISHRA P, et al. An AIoT-based approach to high-throughput grain quality control: application to the food industry[C]// 2023 IEEE 23rd International Conference on Communication Technology (ICCT). [2025-02-10].