DOI: 10.13733/j.jcam.issn.2095-5553.2024.11.022

相志勇, 苗玉彬. 基于 CNN 和近红外光谱的蜜柑 SSC 预测模型研究 [J]. 中国农机化学报, 2024, 45(11): 139-144

Xiang Zhiyong, Miao Yubin. Study on prediction model of citrus SSC based on CNN and near infrared spectroscopy [J]. Journal of Chinese Agricultural Mechanization, 2024, 45(11): 139-144

基于 CNN 和近红外光谱的蜜柑 SSC 预测模型研究*

相志勇, 苗玉彬

(上海交通大学机械与动力工程学院,上海市,200240)

摘要:针对抽样化验等传统果实品质检测方法具有破坏性以及现有回归预测模型存在光谱信息损失和特征提取不够完备 等问题,提出基于近红外光谱分析技术和一维卷积神经网络(1D-CNN)实现蜜柑果实可溶性固形物含量预测的模型和 方法。采集蜜柑的近红外光谱和测定可溶性固形物含量建立数据集。并通过试验对比确定使模型性能最优的网络结构 深度、卷积核尺寸和数量、有无批量归一化(BN)层、池化方式、全连接层深度和Dropout值等网络结构参数,形成包含2层 卷积层、2层BN层,2层最大池化层和2层全连接层的一维卷积神经网络,并设置Dropout值为0.2。与偏最小二乘回归、 主成分回归和支持向量机回归预测模型的性能对比试验表明:提出的1D-CNN模型预测精度和模型稳定性均优于传统 回归预测算法,其验证集上的均方根误差为0.3339,决定系数为0.8655,能够实现对蜜柑近红外光谱数据特征的有效提 取和对蜜柑可溶性固形物含量的无损检测。

关键词:蜜柑;近红外光谱;卷积神经网络;可溶性固形物;无损检测

中图分类号:TS207.3 **文献标识码:**A **文章编号:**2095-5553(2024)11-0139-06

Study on prediction model of citrus SSC based on CNN and near infrared spectroscopy

Xiang Zhiyong, Miao Yubin

(College of Mechanical and Power Engineering, Shanghai Jiaotong University, Shanghai, 200240, China)

Abstract: Aiming at the problems of destructive traditional fruit quality detection methods such as sampling assay, spectral information loss and incomplete feature extraction in the existing regression prediction models, a novel model and method based on near-infrared spectroscopy analysis technology and a one-dimensional Convolutional neural network (1D-CNN) topredict the soluble solids content of citrus fruit were proposed in this paper. A dataset has been established by gathering near-infrared spectroscopy of citrus fruits and determining their soluble solid content. The network structure parameters have been optimized to enhance the performance of the model, including the depth of the network structure, the size and quantity of convolutional kernels, the presence or absence of batch normalization (BN) layers, pooling methods, the depth of fully connected layers, and Dropout values. The final 1D-CNN model comprises two convolutional layers, two BN layers, two maximum pooling layers, and two fully connected layers, with a Dropout value of 0.2. Traditional Partial least squares regression, principal component regression, and support vector machine regression prediction models have been established to compare their performance with the 1D-CNN model. The outcomes reveal that the 1D-CNN model exhibits significantly superior prediction accuracy and model stability compared to conventional algorithms. The Root-mean-square deviation on the verification set is 0.333 9, and the Coefficient of determination is 0.865 5. This demonstrates that the 1D-CNN model can carry out feature extraction of citrus near-infrared spectral data, thereby permitting non-destructive detection of soluble solid content in citrus. Consequently, this approach provides a better solution for non-destructive detection of citrus based on near-infrared spectral analysis technology.

收稿日期:2023年6月9日 修回日期:2023年11月1日

^{*} 基金项目:国家自然科学基金面上项目(51975361)

第一作者:相志勇,男,1997年生,山东潍坊人,硕士研究生;研究方向为农业生产自动化。E-mail: xiangzhiyong@sjtu.edu.cn

通讯作者: 苗玉彬, 男, 1973年生, 青岛人, 博士, 副教授; 研究方向为智能农业装备。 E-mail: ybmiao@sjtu. edu. cn

化工等行业。国内外众多学者利用近红外光谱分析技 术实现了苹果[24]、梨[5,6]、桃^[7,8]、柑橘^[9,10]、李子^[11,12] 等果实可溶性固形物含量检测研究。刘燕德[13]等利 用近红外漫透射光谱技术结合最小二乘支持向量机算 法实现了蜜柑 SCC 的在线无损检测。李俊杰等[14]运 用偏最小二乘回归(PLSR)建立了 SCC、可滴定酸以 及维C的检测模型,取得了较好的结果。近红外光谱 预测模型的建立多采用PLSR等传统建模方法,一般 首先对光谱数据进行预处理,然后提取光谱中重要波 峰信息或运用主成分分析等方法对光谱信号降维,保 留重要特征,降低计算复杂性。这些方法存在训练过 程较为复杂,表征参数较少,回归精度差强人意等不 足。卷积神经网络(CNN)是深度学习算法的代表算 法之一,其采用端到端训练模式,能自动提取数据体 征[15],训练过程更简单,参数相对较多,具有更大的优 化空间。且因为具备基于卷积权值共享和局部区域连 接等机制,CNN具有很强的泛化能力。Mishra等^[16]建 立了基于CNN的水果不同性状的多输出预测模型,同 时预测了梨果实的水分含量和SSC,模型性能优于 PLSR模型。Huang等^[17](2021)提出了基于多尺度短 切卷积神经网络的无损检测方法,用于测量马尾松幼 苗叶片中的水分和氮含量,其对应的建模均方根误差 为 0. 242 和 0. 061。Benmouna 等^[18]开发了基于 CNN 利用近红外光谱信息对富士苹果的成熟阶段进行分类 的新方法,正确率为96.5%,高于人工神经网络、支持 向量机等方法。

温州蜜柑是受人们喜爱的常见水果。随着生活水

平的不断改善,消费者对蜜柑的品质要求不断提高,除

关注蜜柑的外部成色之外,也更加注重蜜柑的内部品质。可溶性固形物含量(SSC)是衡量蜜柑品质的重要

指标[1]。但随机抽样化学检测的传统检测方法需要破

坏果体,不利于对果实进行快速筛选分级,需要研究更

型的无损快速分析技术,广泛应用于农业、食品、医疗、

近红外光谱分析技术是近年来发展起来的一种新

针对传统果实品质检测方法以及现有回归预测模型存在的不足,根据光谱数据特点,提出一种基于一维卷积神经网络(1D-CNN)和近红外光谱信息的蜜柑SSC预测模型。根据采集到的蜜柑近红外光谱数据,建立1D-CNN预测模型,并通过试验优选网络结构深度、卷积核尺寸和数量、有无批量归一化(BN)层、池

化方式、全连接层深度和Dropout值等网络结构参数, 使模型性能最优。通过与PLSR等传统预测模型对 比,讨论本文预测模型的精度和稳定性优势。

1 材料与方法

1.1 试验样品

选取10月份成熟期的新鲜采摘、颜色正常、大小 均匀、且表面无明显病变伤疤的蜜柑共340个,作为试 验样品。对所选蜜柑表皮用湿纸巾做简单的清洁处 理,擦掉表面杂质,确保不会引入外来物质导致光谱异 常。将蜜柑样品依次编号,并在22℃实验室环境下放 置24 h,分别采集蜜柑的近红外光谱和可溶性固形物 含量数据。

1.2 试验方法

1.2.1 近红外光谱采集装置

根据试验需求设计并搭建近红外光谱采集装置如 图1所示,主要包括计算机、微型光谱仪、遮光箱、卤素光 源、参比球、准直透镜和光纤等。光谱采集设置为漫透 射采集方式,4个卤素光源分别安装在遮光箱四面,相对 中轴线呈45°夹角,从4个方向照射果实。光谱仪采用 FX4000微型光谱仪,光谱分辨率为0.06 nm,采样波长 范围为200~1 100 nm,光源采用4盏100 W卤素灯,总 功率400 W,积分时间100 ms。采用Morpho软件进行 光谱采集,对每个蜜柑使其果梗朝向不同方向,采集4次 取平均值作为对应果实的近红外光谱数据。



Fig. 1 Spectral acquisition device 1.准直透镜 2.蜜柑 3.卤素灯 4.遮光箱 5.灯杯 6.光纤 7.光谱仪FX4000 8.电脑

1.2.2 可溶性固形物含量测定

4.

使用AIOK高精度数显糖度计测定蜜柑的可溶性 固形物含量。将光谱采集后的蜜柑进行榨汁,并用滤 网进行过滤,用试管收集滤液备用;利用蒸馏水对糖度 仪进行校准后,使用滴管吸取果汁滤液滴入糖度仪的 样液池中读数,多次测量直至连续两次读数相同,记录 糖度仪读数。

1.3 光谱数据预处理

因背景噪声、杂散光和人工操作等因素影响,所采

Keywords: citrus; near-infrared spectroscopy; convolutional neural network; soluble solids; non-destructive testing

0

引言

便捷的无损检测技术。

集的光谱数据不可避免地包含噪声信号,需在建模之前对所采集的原始光谱数据进行预处理。选取标准正态变换(SNV)^[19]光谱预处理方法。

1.4 一维卷积神经网络

卷积神经网络(CNN)是一种多层非全连接的非 线性深度学习方法,其基本结构由卷积层、池化层和全 连接层组成,在正向传播过程中利用卷积层层和池化 层相互交替实现原始数据特征提取;在反向传播过程 中利用梯度下降法最小化误差函数实现参数提张以此 完成权值更新^[20]。一维卷积神经网络(1D-CNN)是 卷积神经网络的分支之一,其输入样本数据以及网络 结构中的卷积核、池化核等均为一维。1D-CNN的 卷积和池化过程如图2、图3所示。



图 3 池化计算过程

Fig. 3 Pooled computing process

1.5 模型评价方法

为确定最佳网络结构参数和系统参数,选择均方 根误差(Root Mean Square Error, RMSE)和决定系数 (Correlation of determination, R^2)作为模型性能评价 指标。其计算如式(1)、式(2)所示。

$$RMSE = \sqrt{\frac{\sum_{i=1}^{m} (\widehat{y}_i - y_i)^2}{m}}$$
(1)

$$R^{2} = \frac{\sum_{i=1}^{m} (\widehat{y}_{i} - \overline{y}_{i})^{2}}{\sum_{i=1}^{m} (y_{i} - \overline{y}_{i})^{2}}$$
(2)

式中: yi---模型预测值;

$$y_i$$
——预测值的均值;

2 试验结果与分析

2.1 近红外光谱和SSC分析

对 340 个 温州 蜜 柑 果 实 样 本 进 行 光 谱 采 集, 剔 除 异 常 样 本 后 得 到 332 组 原 始 光 谱 数 据, 如 图 4(a) 所 示, 使 用 KS 样 本 划 分 法 (Kennard - Stone, KS) 划

分训练集和验证集。训练集与验证集的样品数据统 计表如表1所示,样本数据分布合理,偏差较小,可 以建立回归模型。经过SNV预处理后的光谱数据 如图4(b)所示,相较于原始光谱,预处理后的光谱 特征峰更明显。



表 1 蜜柑样本理化参数

Tab. 1 Physicochemical parameters of citrus samples

品质		训练集			验证集	Aut.
类型	范围	均值	标准偏差	范围	均值	标准偏差
SSC	8.20~ 12.70	10.12	0.8326	8.40~ 12.20	10.09	0.764 3

2.2 网络结构深度设置

1D-CNN模型的第一部分是特征提取模块,由 卷积层、池化层、批量归一化(Batch normalization, BN)和ReLU激活函数组成一个相对独立的小型网络 层集合(后文称该集合为特征提取层)。为确定最佳网 络深度,对比不同深度网络结构的1D-CNN预测模 型性能指标,结果如表2所示。

表 2 不同层数1D-CNN模型的性能指标

Tab. 2 Performance indicators of 1D-CNN models with different layers

日粉	训练	F集	验证集		
运剱	$RMSE_{c}$	${R_{ m c}}^2$	$RMSE_{p}$	$R_{ m p}{}^2$	
1	0.4107	0.784 4	0.4757	0.667 0	
2	0.276 3	0.888 0	0.4054	0.768 8	
3	0.345 2	0.862 6	0.4518	0.6900	
4	0.358 1	0.805 9	0.6636	0.379 5	

由表2可知,两层网络结构的1D-CNN模型性能 最优,训练集均方根误差为0.2763,决定系数为 0.8880,验证集均方根误差为0.4054,决定系数为 0.7688。故此本文选用两层特征提取层组成的特征 提取模块。

2.3 卷积核尺寸和数目的确定

卷积层利用卷积核对前一层的特征图局部区域进 行卷积运算实现特征映射,所以卷积核的大小和数量 能够影响卷积神经网络的建模性能。在前文试验基础 和相同网络结构和参数条件下,通过试验比较不同卷 积核尺寸对模型性能的影响。因为池化层会缩短数据 长度,所以本文设定第二层的卷积核比第一层小2。 不同卷积核尺寸的1D-CNN模型效果如图5所示。



图 5 不同卷积核尺寸的 1D-CNN 模型性能指标

Fig. 5 Performance indicators of 1D-CNN models with different convolutional kernel sizes

由图5可知,卷积核尺寸为19、17时对应1D-CNN模型的性能最优,所建模型在训练集上的决定系 数为0.8880,验证集的决定系数为0.7688。

不同卷积核数目对1D-CNN预测模型性能的影响试验结果如图6所示。由图6可见,卷积核数目为8、32时模型的性能表现较好,验证集决定系数为0.7688。





2.4 BN层的设置

卷积层的输出通过 BN 机制进一步处理, BN 机制 能有效的解决梯度爆炸或梯度消失问题, 并可提高收 敛速度^[21]。表 3 为网络结构和参数相同的前提下, 是 否引入 BN 机制两种情形对 1D-CNN 预测模型的性 能影响对比。从表 3 可知, BN 层能有效提高 1D-CNN模型的性能。

	表 3	BN 层对 1D-CNN 模型性能的影响
Гab. З	Effect	of BN layer on 1D-CNN model performance

古王 DN 目	训练	训练集		集
有九 DIN 层	$RMSE_{c}$	$R_{ m c}{}^2$	$RMSE_{p}$	$R_{ m p}^{-2}$
无	0.6127	0.4834	0.8787	0.377 0
有	0.276 3	0.888 0	0.4054	0.768 8

2.5 池化方式的设置

池化层可以在保证数据特征的同时大大降低 CNN的参数量。表4为网络结构和参数相同的前提 下,最大池化和平均池化两种池化方式对1D-CNN 预测模型的性能影响对比。由表4可知,采用最大池 化的1D-CNN模型性能在验证集上的表现优于平 均池化。

表 4 池化层对 1D-CNN 模型性能的影响

Tab. 4 Effect of pooling layer on 1D-CNN model performance

汕 化 古 主	训练	、集	验证集	
他化力式	$RMSE_{c}$	${R_{ m c}}^2$	$RMSE_{p}$	$R_{ m p}{}^2$
平均池化	0.3257	0.716 9	0.436 0	0.7339
最大池化	0.276 3	0.888 0	0.4054	0.768 8

2.6 全连接层的设计

1D-CNN模型的第二部分是全连接层,全连接层 层输入层的神经元个数取决于输入数据的维度和卷积 核的数目,中间层数能影响模型的建模性能,表5为相 同特征提取层条件下,不同全连接层数对1D-CNN 预测模型的性能影响对比。

表 5 不同全连接层数 1D-CNN 模型的性能指标

Tab. 5 Performance indicators of 1D-CNN models with different fully connected layers

层数 -	训练	〔集	验证集		
	$RMSE_{c}$	$R_{ m c}^{\ 2}$	$RMSE_{p}$	${R_{ m p}}^2$	
1	0.239 9	0.919 1	0.466 4	0.688 0	
2	0.276 3	0.888 0	0.4054	0.768 8	
3	0.256 5	0.886 5	0.5936	0.517 1	
4	0.241 3	0.923 6	0.598 9	0.476 2	

由表5可知,两层全连接层的1D-CNN模型在 验证集上的表现明显优于其他模型。这是全连接层数 增多,模型参数的增加导致模型过拟合。

2.7 Dropout的设定

由于近红外光谱数据具有比较高的数据维度,网络的参数量偏大,容易导致过拟合等问题发生。本文通过在网络结构中加入Dropout层,减缓高维近红外光谱带给网络的影响,从而提高蜜柑预测模型的稳定性。表6为相同网络结构和参数的前提下,不同丢弃率对1D-CNN预测模型的性能影响对比。由表6可知,在本试验中,选择丢失率为0.2时,预测模型的性能表现最好。

表 6	不同 Dropout 值 1D-CNN 模型的性能指标	
-----	-----------------------------	--

Tab. 6 Performance indicators of 1D-CNN models with different *Dropout* values

	训练	宗集	验证集		
Dropout -	$RMSE_{c}$	$R_{ m c}{}^2$	RMSE _p	$R_{ m p}^{-2}$	
0.1	0.2979	0.8524	0.483 8	0.777 0	
0.2	0.2602	0.896 1	0.3339	0.865 5	
0.3	0.3553	0.841 3	0.487 1	0.749 1	
0.4	0.219 9	0.9104	0.6696	0.5587	
0.5	0.341 8	0.777 8	0.626 9	0.6205	

2.8 1D-CNN 蜜柑 SSC 预测模型建立

基于前文试验结果,1D-CNN模型的网络结构 及参数如图7所示。



Fig. 7 Network structure of the 1D-CNN model

图 7 中 1D-CNN 网络结构含有 2个卷积层(C1, C3),其卷积核大小分别为 19 和 17,卷积核数量分别 为 8 和 32。2个最大池化层(S2,S4)按照设定步长和 窗口大小降低数据维度。为防止卷积计算过程中梯度 消失,引入 BN 机制,在卷积层后加入 BN 层。全连接 层有 2 层(F5,F6)的神经元个数分别为 1 024 和 32,并引入 Dropout 机制,提高模型稳定性, Dropout 值取为 0.2。

基于上述1D-CNN网络结构建立蜜柑SSC预测 模型,模型在训练集上的均方根误差为0.2602,决定 系数为0.8961,在验证集上均方根误差为0.3339,决 定系数为0.8655。蜜柑SSC测定值和预测值的散点 图如图8所示。





2.9 模型性能对比

为验证 1D-CNN 模型的有效性,选择相同训练 集和验证集样本,采用 SNV 预处理,分别与偏最小二 乘回归(PLSR)、主成分回归(PCR)和支持向量机回 归(SVR)预测模型进行对比分析,结果如表7所示。

	表 7	不同建模	方法的蜜	柑 SSC 模	型性能	
Tab.	7 Perfe	ormance o	f different	modeling	methods	for
		sweet o	citrus SSC	models		

冲出于	训练	床集	验证集		
建陕力法 -	$RMSE_{c}$	$R_{ m c}{}^2$	$RMSE_{p}$	$R_{ m p}{}^2$	
1D-CNN	0.2602	0.896 1	0.333 9	0.865 5	
PLSR	0.2702	0.900 0	0.471 2	0.761 9	
PCR	0.116 2	0.8623	0.651 1	0.124 9	
SVR	0.398 0	0.780 0	0.414 3	0.802 5	

由表7可知,在建模条件相同的情况下,1D-CNN、PLSR和SVR模型性能较好,PCR模型产生过 拟合。其中又以1D-CNN模型性能最好,其在训练 集上的均方根误差为0.2602,决定系数为0.8961;在 验证集上的均方根误差为0.3339,决定系数为 0.8655。其次是SVR模型,在训练集上的均方根误 差为0.3980,决定系数为0.7800;在验证集上的均方 根误差为0.4143,决定系数为0.8025。PLSR模型性 能相对较差,在训练集上的均方根误差为0.2702,决 定系数为0.9000;在验证集上的均方根误差为 0.4712,决定系数为0.7619。

综上可见,1D-CNN预测模型性能相比其他模型性能更优。相较于传统回归算法,1D-CNN能够提升模型的精度和稳定性,有效改进基于近红外光谱的蜜柑品质无损检测技术。

3 结论

1) 基于近红外光谱分析技术对蜜柑进行无损检测时,传统建模方法所得模型存在光谱信息损失和特征提取不够完备等问题,为此提出基于近红外光谱分析技术和1D-CNN的蜜柑SSC预测模型。通过对比试验,研究确定1D-CNN预测模型的最佳网络结构参数,实现更为准确的蜜柑SSC预测,验证集均方根误差为0.3339,决定系数为0.8655。

2)对比试验表明,相较于PLSR模型(在验证集上的均方根误差为0.4712,决定系数为0.7619)、 SVR模型(在验证集上的均方根误差为0.4143,决定 系数为0.8025)和PCR模型(在验证集上的均方根误 差为0.6511,决定系数为-0.1249),1D-CNN模型 性能更优秀。

3)研究结果为基于近红外光谱实现快速高效的 蜜柑SSC无损检测提供技术支持。

参考文献

[1]刘燕德,施宇,蔡丽君,等.基于CARS算法的脐橙可溶性固形物近红外在线检测[J].农业机械学报,2013,44
 (9):138-144.

Liu Yande, Shi Yu, Cai Lijun, et al. On-line NIR detection model optimization of soluble solids content in navel orange based on CARS [J]. Transactions of the Chinese Society for Agricultural Machinery, 2013, 44(9): 138-144.

- [2] 庞新安.近红外光谱技术及其在农产品品质分析中的应用[J]. 广西农业生物科学,2007(1):83-87.
 Pang Xin'an. Near infrared spectrum technique and its application in quality analysis on farm produce [J]. Journal of Guangxi Agriculture and Biological Science, 2007(1): 83-87.
- [3] Zhang Y, Chen Y, Wu Y, et al. Accurate and nondestructive detection of apple brix and acidity based on visible and near-infrared spectroscopy [J]. Applied

Optics, 2021, 60(13): 4021-4028.

- [4] Xia Y, Fan S, Li J, et al. Optimization and comparison of models for prediction of soluble solids content in apple by online Vis/NIR transmission coupled with diameter correction method [J]. Chemometrics and Intelligent Laboratory Systems, 2020, 201: 104017.
- [5] Wang J, Wang J, Chen Z, et al. Development of multi-cultivar models for predicting the soluble solid content and firmness of European pear (Pyrus communis L.) using portable vis-NIR spectroscopy [J]. Postharvest Biology and Technology, 2017, 129: 143-151.
- [6] Mishra P, Woltering E, Brouwer B, et al. Improving moisture and soluble solids content prediction in pear fruit using near-infrared spectroscopy with variable selection and model updating approach [J]. Postharvest Biology and Technology, 2021, 171: 111348.
- [7] Minas I S, Blanco-Cipollone F, Sterle D. Accurate non-destructive prediction of peach fruit internal quality and physiological maturity with a single scan using near infrared spectroscopy [J]. Food Chemistry, 2021, 335: 127626.
- [8] Yuan L M, You L, Yang X, et al. Consensual regression of soluble solids content in peach by near infrared spectrocopy [J]. Foods, 2022, 11(8): 1095.
- [9] Song J, Li G, Yang X, et al. Rapid analysis of soluble solid content in navel orange based on visible-near infrared spectroscopy combined with a swarm intelligence optimization method [J]. Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy, 2020, 228: 117815.
- [10] Santos C S P, Cruz R, Goncalves D B, et al. Non-destructive measurement of the internal quality of citrus fruits using a portable NIR device [J]. Journal of AOAC International, 2021, 104(1): 61-67.
- [11] 赵志磊,王雪妹,刘冬冬,等.基于BP-ANN和PLS的近红外光谱无损检测李果实品质的研究[J].光谱学与光谱分析,2022,42(9):2836-2842.
 Zhao Zhilei, Wang Xuemei, Liu Dongdong, et al. Quantitative analysis of soluble solids and titratable acidity content in Angeleno plum by near-infrared spectroscopy with BP-ANN and PLS [J]. Spectroscopy and Spectral Analysis, 2022, 42(9):2836-2842.
- [12] Pérez-Marín D, Paz P, Guerrero J E, et al. Miniature handheld NIR sensor for the on-site non-destructive assessment of post-harvest quality and refrigerated storage behavior in plums [J]. Journal of Food Engineering, 2010, 99(3): 294-302.
- [13] 刘燕德, 胡军, 欧阳玉平, 等. 赣南脐橙可溶性固形物近 红外光谱在线无损检测[J]. 广东农业科学, 2016, 43

(9):105-111.

Liu Yande, Hu Jun, Ouyang Yuping, et al. Online detection of soluble solids content for Gannan navel by visible-near infrared diffuse transmission spectroscopy [J]. Guangdong Agricultural Science, 2016, 43(9): 105-111.

[14] 李俊杰,张绩,汪小伟,等.近红外光谱大数据分析塔罗
 科血橙内在品质的研究[J].食品研究与开发,2020,41
 (20):193-197,209.
 Li Junjie, Zhang Ji, Wang Xiaowei, et al. Study on

internal quality of Tarocco blood orange based on large data analysis of near-infrared spectroscopy [J]. Food Research and Development, 2020, 41 (20): 193–197, 209.

- [15] 刘伟男.基于深度学习的近红外光谱猪肉新鲜度检测研究[D]. 徐州:中国矿业大学, 2022.
 Liu Weinan. Study on pork freshness detection by near-infrared spectroscopy based on deep learning [D].
 Xuzhou: China University of Mining and Technology, 2022.
- [16] Mishra P, Passos D. Multi-output 1-dimensional convolutional neural networks for simultaneous prediction of different traits of fruit based on near-infrared spectroscopy [J]. Postharvest Biology and Technology, 2022, 183: 111741.
- [17] Huang Z, Zhu T, Li Z, et al. Non-destructive testing of moisture and nitrogen content in Pinus Massoniana seedling leaves with NIRS based on MS-SC-CNN [J]. Applied Sciences, 2021, 11(6): 2754.
- [18] Benmouna B, Garcia-Mateos G, Sabzi S, et al. Convolutional neural networks for estimating the ripening state of fuji apples using visible and near-infrared spectroscopy [J]. Food and Bioprocess Technology, 2022, 15(10): 2226-2236.
- [19] 余怀鑫.基于可见一近红外光谱技术的柑橘品质无损检 测研究[D].武汉:华中农业大学,2021.
 Yu Huaixin. Research on non-destructive testing of citrus quality based on visible near-infrared spectroscopy technology [D]. Wuhan: Huazhong Agricultural University, 2021.
- [20] 温馨.基于深度学习的水果糖度可见/近红外光谱无损检 测方法研究[D].北京:北京交通大学,2018.
 Wen Xin. Research on non-destructive determination technology of fruit sugar degree by visible/near-infrared spectroscopy based on deep learning [D]. Beijing: Beijing Jiaotong University, 2018.
- [21] 邢超.基于深度神经网络的云环境服务故障识别方法[J].数据通信,2022(4):12-15.
 Xing Chao. Fault identification method for cloud environment services based on deep neural networks [J]. Data Communication, 2022(4):12-15.