doi:10.6041/j.issn.1000-1298.2022.11.042

## 基于深度学习的青梅品质智能分选技术与装备研究

张晓<sup>1,2</sup> 庄子龙'刘英'王旭'

(1. 南京林业大学机械电子工程学院,南京 210037; 2. 农业农村部南京农业机械化研究所,南京 210014)

摘要:青梅内外品质对其精深加工过程有重要影响,常规人工分选不仅分级效率较低,且受个人主观因素影响难以 实现标准化作业,不能满足市场需求。以深度学习技术为基础,在青梅外表缺陷分类方面,将 Vision Transformer 网 络模型应用到机器视觉系统中,引入多头注意力机制,提升全局特征表示能力,并通过 softmax 函数减少梯度,实现 青梅表面的多类(腐烂、裂纹、疤痕、雨斑、完好 5 类)检测分选,结果表明其平均判别准确率达到 99.16%,其中腐 烂、疤痕、裂纹以及完好青梅图像的判别准确率达到 100%、雨斑达到 97.38%,每组平均测试时间为 100.59 ms;该 网络的各类判别准确率、平均判别准确率均明显优于 VGG 网络、ResNet - 18 网络。青梅内部品质(SSC)预测方面, 基于高光谱成像技术,结合低秩张量恢复(LRTR)的去噪优势和堆叠卷积自动编码器(SCAE)的降维优势,构建了 LRTR -SCAE - PLSR 青梅糖度预测模型。结果表明网络规模为 119 - 90 - 55 - 36 时,模型预测集相关系数为 0.965 4,均方根误差为 0.582 7%,表现最佳;通过 SCAE、LRTR - SCAE 两种降维模型对比,LRTR - SCAE 模型不仅 维度更低,预测集相关系数也明显提高,验证了 LRTR - SCAE 模型的降维去噪优势。设计并搭建了可用于青梅内 外品质无损分选的智能装备,整机尺寸小,结构简单,分选结果满足青梅精深加工需求。

关键词:青梅;智能分选装备;可溶性固形物; Vision Transformer 模型;低秩张量恢复 中图分类号: S126 文献标识码: A 文章编号: 1000-1298(2022)11-0402-10



## Technology and Equipment Research of Green Plum Quality Intelligent Sorting Based on Deep Learning

ZHANG Xiao<sup>1,2</sup> ZHUANG Zilong<sup>1</sup> LIU Ying<sup>1</sup> WANG Xu<sup>1</sup>

(1. College of Mechanical and Electronic Engineering, Nanjing Forestry University, Nanjing 210037, China 2. Nanjing Institute of Agricultural Mechanization, Ministry of Agriculture and Rural Affairs, Nanjing 210014, China)

**Abstract:** The internal and external quality of green plum has an important impact on its processing process. Conventional manual sorting not only has low classification efficiency, but also is difficult to realize standardized operation due to personal subjective factors, which can not meet the market requirements. In the aspect of defect classification, based on deep learning technology the vision transformer network was used in machine vision system, which introduced multihead self-attention to improve the global feature representation ability, and reduce the gradient through the softmax function to realize the detection and sorting of multiple categories (rot, crack, scar, spot and normal) on the surface of green plum. The results showed that the discrimination accuracy of rot, scar, crack and normal plum images reached 100%, spot reached 97.38%, the average discrimination accuracy was 99.16%, and the average test time of each group was 100.59 ms. The discrimination accuracy and average discrimination accuracy of this network were significantly better than VGG and ResNet – 18 network. In terms of internal quality (SSC) prediction of green plum, based on hyperspectral imaging technology, the LRTR – SCAE – PLSR prediction model of green plum was constructed by combining the denoising advantages of LRTR and the dimensionality reduction advantages of SCAE. The results showed that when the network scale was 119 – 90 – 55 – 36,  $R_p$  was 0.965 4 and RMSEP was 0.582 7%. By comparing the

收稿日期: 2022-05-30 修回日期: 2022-08-29

基金项目: 江苏省农业科技自主创新资金项目(CX(18)3071)

作者简介:张晓(1987—),女,博士生,农业农村部南京农业机械化研究所助理研究员,主要从事机器视觉和木材与林果检测研究,E-mail: zhangxiao\_xhx@126.com

通信作者:刘英(1965—),女,教授,博士生导师,主要从事无损检测和图像处理研究,E-mail: lying\_new@163.com

two dimensionality reduction models of SCAE and LRTR – SCAE, LRTR – SCAE model not only had lower dimensions, but also significantly improved the correlation coefficient of prediction set, which verified the dimensionality reduction and denoising advantages of LRTR – SCAE model. An intelligent equipment for nondestructive sorting of internal and external quality of green plum was designed and built. The whole machine had small size and simple structure. The sorting results met the requirements of green plum deep processing.

Key words: green plum; intelligent sorting equipment; soluble solids content; Vision Transformer model; low-rank tensor recovery

## 0 引言

青梅对心血管、泌尿、消化系统疾病有明显的预防作用和疗效<sup>[1-2]</sup>。青梅需经加工后方可食用,不同青梅精深加工产品对原料果的成分特点要求不同,其中糖度低的青梅果主要用于加工糖制青梅、青梅干、话梅等,糖度高的青梅果主要用于加工梅汁类饮品<sup>[3]</sup>。青梅深加工时主要依据青梅缺陷、糖度等进行原果分类,常规人工分选不仅分级效率较低,且受个人主观因素影响难以实现标准化作业,不能满足市场需求。检测水果糖度时,通常用测定原果中可溶性固形物含量(Soluble solids content,SSC)来表示其糖度,但传统理化检测方法具有破坏性,且效率低下,无法满足实际检测要求<sup>[4-5]</sup>。

利用光谱成像技术进行原果分选的研究和应用 越来越多,外观分类方面,传统的神经网络已无法适 应越来越庞大且复杂的数据量<sup>[6-7]</sup>。近年来深度学 习在食品检测领域取得了较多成果<sup>[8]</sup>,文献[9]将 改进的 Faster R - CNN(区域卷积神经网络)应用于 苹果、芒果、橙子的识别,平均识别率达到91.21%。 文献[10]将 ResNet 网络应用于番茄外表缺陷的识 别,识别率达到94.65%。文献[11]对 AlexNet 网络 进行优化,油茶籽完整性识别准确率达到98.05%。

内部品质检测方面,文献[12]利用高光谱成像 技术对柑橘葡萄糖、果糖和蔗糖含量进行检测,建立 了偏最小二乘回归模型,模型预测相关系数*R<sub>p</sub>*分别 为0.8802、0.9028和0.8335。文献[13]利用 PLSR(偏最小二乘)模型实现小麦蛋白质含量的预 测,预测模型相关系数*R<sub>p</sub>*为0.7981,均方根误差为 0.0094。文献[14-15]分别采用结合竞争性自适 应权重算法和多元线性回归模型、偏最小二乘回归 模型建立了肥城桃、库勒尔香梨的SSC预测模型, 模型预测集相关系数分别为0.8439、0.915。但高 光谱图像数据量庞大、冗余度高,采用传统的线性方 法数据分析时,耗时较长且效果不理想,还需对高光 谱图像进行去噪处理<sup>[16-17]</sup>,而深度学习能够有效地 提取复杂任务的高阶非线性特征来弥补其不 足[18-19]。

因此本文以青梅为研究对象,以深度学习技术为基础,将 Vision Transformer 网络模型应用到机器视觉系统中,实现青梅表面的多类(腐烂、裂纹、疤痕、雨斑、完好5类)检测分选;结合低秩张量恢复(Low-rank tensor recovery, LRTR)的去噪优势和堆叠卷积自动编码器(Stack convolution auto encoder, SCAE)的降维优势,构建LRTR – SCAE – PLSR 青梅糖度预测模型;设计并搭建青梅内外品质智能分选装备,以期为青梅加工自动化提供技术支持。

### 1 整体结构与工作原理

青梅品质智能分选装备主要由外表缺陷检测模 块、内部品质检测模块、传送台、装备底座、分选机构、 驱动电机、控制系统等组成。其结构如图 1 所示,整 机参数如下:外形尺寸为 3 600 mm × 650 mm × 1 390 mm,电机总功率为 600 W,传动形式为链传动, 青梅外表缺陷分选效率不小于 1 800 颗/h,青梅内部 品质分选效率不小于 600 颗/h。



图1 青梅品质智能分选装备

Fig. 1Green plum quality intelligent sorting equipment1. 外表缺陷检测模块2. 传送台3. 内部品质检测模块4. 分选机构5. 驱动电机6. 装备底座

工作流程如图2所示。首先,青梅进入传送台 后由光电传感器触发外表缺陷检测模块,采集青梅 外表图像信息;随后,青梅向前运动至内部品质检测 模块,采集青梅内部光谱信息;然后,分选系统完成 图谱信息处理与分析,对青梅等级作出判断;最终, 上位机与西门子 PLC s7 - 200 通信,将等级信息传 递给分选模块,并启动气嘴将青梅吹入相应等级的 分选箱。





#### 2 关键部件设计

#### 2.1 外表缺陷检测模块

缺陷检测模块由彩色相机、环形光源、暗箱、传送台等组成。其中工业相机镜头选用日本 Computar 公司的 M1620 - MP2 型(焦距 16 mm、最小物距 20 cm),工业相机选用北京大恒图像技术公司的 MER -531 - 20GC -型工业相机,相机采用安森美 PYTHON5000 型 CMOS 传感器芯片,光源采用 LED 环形光源。具体结构如图 3 所示。检测时,单颗青 梅样品随传送台进入缺陷检测模块后,光电传感器 触发彩色相机采集青梅外表图像信息,并传送至上 位机图像处理系统,完成图像预处理、背景分割、特 征提取、缺陷分选等工作。



#### 2.2 内部品质检测模块

内部品质检测模块主要由光谱相机、光谱检测 光源、暗箱、支架、传送台等组成。具体结构如图 4 所示。其中光谱相机为四川双利合普公司 GaiaField-V10E型可见近红外高光谱相机,光谱成 像范围为400~1000 nm,光谱分辨率为2.8 nm;检测光源为PHILIPS Essential 光管灯,功率50 W。为了提高分选效率,将顺序进入内部品质检测模块的4 颗青梅样品作为一组(青梅体积较小),由光电传感器触发相机进行高光谱图像数据采集,上位机图像处理系统对光谱数据进行预处理、建模、分析等。



Fig. 4 Diagram of internal quality inspection module
1. 暗箱门 2. 暗箱 3. 被检测物 4. 相机支架 5. 光源支架
6. 光谱相机 7. 光谱检测光源

#### 2.3 控制系统

控制系统主要由上位机、PLC 控制器、光电传感器、电机、串口模块等组成。硬件构成如图 5 所示, 主要实现青梅智能分选系统的启动和关闭、图像采 集与处理、传送机构运行、检测触发、自动分选等,整 机的通讯接口采用 RS485 标准方式传输。上位机 图像处理系统对青梅图像信息进行处理与分析后, 通过 RS485 串口通讯将青梅分级信号传输给 PLC 移位寄存器中,PLC 控制器保证青梅分选信息与其 位置一致,确保青梅品质智能分选系统能够实时检 测、准确分选。





#### 2.4 传送及分选机构

传送及分选机构主要由传送台、步进电机、气动 喷嘴、分选箱、气泵等组成,如图6所示。青梅经传 送台进入分选机构后,PLC 控制器依据分选信息启 动相应的气动喷嘴将青梅吹入对应的分选箱内,完 成青梅的分选工作。



Fig. 6 Green plum conveying and sorting mechanism 1. 分选箱 2. 传送台 3. 气动喷嘴 4. 步进电机 5. 气泵

## 3 智能分选算法

# **3.1** 基于 Vision Transformer 的青梅外表缺陷分 类模型

在图像分类领域,常见的卷积神经网络(CNN) 利用不断地堆积卷积层运算提取局部特征,在提取 全局特征方面存在一定的局限性。而 Vision Transformer(ViT)模型作为一种基于 Self - Attention 机制的编码器-解码器架构,不采用 RNN(循环神经 网络)顺序结构,并行化训练,能够反映复杂的空间 变换和长距离特征依赖性,通过 Softmax 函数减少 梯度<sup>[20-21]</sup>;Multihead self-attention 基于多头注意力 机制联合不同学习得到的信息,增加多组独立权重、 参数量,以提升表达能力,其全局特征表示能力更 强、迁移效果更好<sup>[22]</sup>。

## 3.1.1 图像预处理与数据集制作

2021年5月由云南省网购1200个青梅样本, 由于单颗青梅表面缺陷具有多样性,采集并筛选了 具有典型外观缺陷 RGB 图像1250幅,结合青梅分 选需求,按严重程度将青梅分为5类:腐烂(严重程 度最高)、裂纹、疤痕、雨斑、完好,如图7所示。以 比例8:2随机抽取划分训练集和验证集,并将训练 集和测试集的数据分别通过镜像、以每45°旋转角 度来扩展数据集,获得10倍增量,获得训练集样本 10000个,验证集样本2500个。



原始青梅 RGB 图像预处理既可以减少背景对 缺陷识别的影响,又可以提升网络分析、处理的速 度。具体过程如下:利用11×11卷积核进行高斯滤 波转化成灰度图,采用自适应阈值二值化、Laplacian 滤波、Canny 算子边缘提取,最终获得224 像素×224 像素的青梅图像。

研究软硬件为:系统 Windows 10、处理器 Inter 19-9900K 3.60 GHz、显卡 Nvidia GeForce RTX 2080 Ti(11GB)、环境配置 PyCharm + Pytorch 1.7.1 + Python 3.7.7 Cuda 10.0 + cudnn 7.6.5 + tensorboardX 2.1。

## 3.1.2 青梅分类算法

ViT模型由 3 个模块组成: Linear projection of flattened patches (Embedding 层)、Transformer encoder、MLP head。首先通过 Embedding 层进行数据变换,输入图像(224 像素×224 像素)按照 16×16尺寸划分成 196 个 Patches,使用卷积核大小为 16×16、步距为 16、个数为 768 的卷积来实现,采用将 Position embedding 和 Patch embedding 相加的方式能够更好地反映全图信息;其次数据进入Transformer encoder 层,重复堆叠 Encoder block *L*次, Transformer encoder 后输出的 Shape 与输入的Shape 一致;最后通过 MLP head 中 Linear 得到青梅分类结果。青梅算法框架图如图 8 所示。

其中 Encoder 第1 层输入

$$Z_{0} = \begin{bmatrix} x_{class} & x_{p}^{1}E & x_{p}^{2}E & \cdots & x_{p}^{N}E \end{bmatrix} + E_{pos}$$
$$(E \in \mathbf{R}^{(P^{2}C) \times D}; E_{pos} \in \mathbf{R}^{(N+1) \times D})$$
(1)

式中  $x_p^1, x_p^2, \dots, x_p^N$ ——Patch embedding 输入值

**E**——Patch embedding 矩阵

**E**<sub>pos</sub>——Position embedding 矩阵

P-----Patch 尺寸

C----通道数

N-----D 维向量的个数

Encoder 第l 层,输入记为 $Z_{l-1}$ ,输出记为 $Z_l$ ,公 式为

$$Z_{l} = M_{LP}(L_{N}(Z_{l}^{(\iota)})) + Z_{l}^{\iota} \quad (l = 1, 2, \cdots, L) \quad (2)$$

其中 
$$Z_l^{(\iota)} = M_{SA}(L_N(Z_{l-1})) + Z_{l-1}$$
 (3)

式中 M<sub>sa</sub>——多头注意力机制参数

M<sub>LP</sub>——多层感知器参数

L<sub>N</sub>——图层归一化参数

- Z<sub>l</sub><sup>(i)</sup>——多头注意力机制的输出值
- 3.2 基于 LRTR SCAE PLSR 的青梅内部品质 预测模型

## 3.2.1 高光谱图像采集及预处理

利用理化检测方法(便携式糖度计等仪器设备)获取不同青梅样本的糖度(SSC)。采集1000个不同成熟度青梅样本高光谱数据,按照3:1比例划





其中

分为训练集和测试集。对得到的高光谱数据进行黑 白校准。

利用高光谱成像系统采集青梅图像,每颗青梅 采集 119 帧光谱图像,利用 ENVI 5.3 软件确定图像 的感兴趣区域 ROI(Region of interest),并提取青梅 样本在 ROI 的平均光谱作为该样本的原始光谱数 据。利用 PyCharm 2019 软件对青梅光谱数据进行 预处理、建模、分析等。图 9 为所有青梅样本的原始 光谱反射率曲线。



#### 3.2.2 低秩张量恢复

高光谱成像具有潜在的低秩张量性质和稀疏 性,利用张量模型进行降噪处理能够比较充分地利 用其在3个维度空间的互补信息<sup>[23]</sup>。LRTR 基于低 秩表示与张量分解的高光谱降噪算法研究将 LRMR (低秩矩阵恢复)模型扩展到张量模型之中,提升了 降噪性能<sup>[24]</sup>。本文基于低秩张量恢复 LRTR 对青 梅高光谱图像进行降维去噪处理,利用核范数作为 秩函数的凸代理函数,应用于张量的不同展开。

将原始含噪的高光谱数据  $Y \in \mathbb{R}^{n \times b}$ 分解成低秩

矩阵  $X_n \in \mathbf{R}^{I_1 \times I_2 \times I_3}$  和稀疏噪声矩阵  $S_n \in \mathbf{R}^{I_1 \times I_2 \times I_3}$ (*n*=1,2,3)。最小化问题可以转换为  $Y_{\min} = \min \sum_{n=1}^{3} (\| (X_n)_{(n)} \|_* + \lambda \| (S_n)_{(n)} \|_{2,1}).$ 

$$\|\boldsymbol{Y}_{(n)} - (\boldsymbol{X}_n)_n - (\boldsymbol{S}_n)_n\|_F \leq \delta$$
(4)

其中 
$$\|X\|_* = \sum_{i=1}^l \sigma_i(X)$$

式中 (*X<sub>n</sub>*)<sub>(*n*</sub>) —— 张量 *X<sub>n</sub>*的模 *n* 展开矩阵 || *X* ||<sub>2,1</sub> —— 矩阵 *X* 中每行 L2 范数之和 || ・ ||<sub>F</sub> —— Frobenius 范数,即矩阵元素绝对

- λ——正则化参数,用于平衡张量秩函数与 范数
- δ----常数,与高斯分布噪声标准差相关

使用 IALM(不精确拉格朗日乘子法) 解决最优 化问题,求解公式为

$$(\boldsymbol{X}_{n})_{(n)}^{k+1} = \operatorname{argmin} \| (\boldsymbol{X}_{n})_{(n)} \|_{*} + \frac{\beta}{2} \| \boldsymbol{Y}_{(n)} - (\boldsymbol{X}_{n})_{(n)} - (\boldsymbol{S}_{n})_{(n)}^{k} - (\boldsymbol{\Lambda}_{n})_{(n)}^{k} \|_{F}^{2} \cdot \boldsymbol{D}_{\tau} (\boldsymbol{Y}_{(n)} - (\boldsymbol{S}_{n})_{(n)}^{k} - (\boldsymbol{\Lambda}_{n})_{(n)}^{k}) \quad (n = 1, 2, 3)$$
(5)

其中  $\Lambda_n = T_n / \beta$   $T_n \in T^{l_1 \times l_2 \times l_3}$ 式中  $\beta$ ——惩罚参数  $T_n$ ——拉格朗日乘子 D (•)为奇异值阈值算子,其定义为

$$D_{\tau}(X) = US_{\tau}(\Sigma)V^{\mathrm{T}}$$

$$X = U\Sigma V^{\mathrm{T}}$$

$$S_{\tau}[x] = \mathrm{sgn}(x)\max(|x| - \tau, 0)$$

$$\tau = \lambda/\beta$$
(6)



上述优化问题通过向量软阈值函数求解,公 式为

$$g(b,\tau) = b \frac{\max\{\|b\|_{2} - \tau, 0\}}{\max\{\|b\|_{2} - \tau, 0\} + \tau}$$
(8)

3.2.3 堆叠卷积自动编码器模型

堆叠卷积自动编码器网络由多个卷积自动编码器(Convolutional auto-encoders, CAE)堆叠而成<sup>[25]</sup>,将编码层和解码层分别建模成深度卷积神经网络。利用卷积神经网络的卷积和池化操作,实现特征不变性提取的无监督提取。为尽可能减小自编码器输入与输出数据之间的差异,自编码器损失函数为

$$J(W, b_J) = \frac{1}{2n} \sum_{i=1}^{n} || \mathbf{y}_i - \mathbf{x}_i ||^2$$
(9)

式中 W——权重 b<sub>j</sub>——偏置 n——输入样本个数 **x**<sub>i</sub>,**y**<sub>i</sub>——第 i 个样本的输入和输出值 误差计算公式为

$$\{w_h, b_h, b_y\} = \operatorname*{argmin}_{w_h, b_h, b_y} \| \boldsymbol{x} - \boldsymbol{y} \|_F^2 \qquad (10)$$

式中 h——编码后的隐含层特征参数

y——确定参数  $w_h$ 、 $b_h$ 、 $b_y$  后的输出数据

*x*——输入数据

3.2.4 LRTR - SCAE - PLSR 青梅糖度预测模型

本文结合低秩张量恢复的去噪优势和堆叠卷积 自动编码器的降维优势,构建了LRTR – SCAE – PLSR 模型对不同青梅样本的糖度进行预测。选用 相关系数 R 和均方根误差(RMSE)作为模型性能评 价指标:训练集相关系数  $R_c$ 、均方根误差 (RMSEC);预测集相关系数  $R_p$ 、均方根误差 (RMSEP)。RMSEC 和 RMSEP 越小且 R 越大的情 况下,模型性能和预测效果越好。输入为119 维的 青梅高光谱特征曲线。具体模型预测流程如图 10 所示。

基于 LRTR - SCAE - PLSR 青梅糖度预测模型 主要步骤如下:

(1)利用低秩张量恢复方法对青梅样本 ROI 光 谱数据进行求解寻优,对正则化参数  $\lambda$ 、惩罚参数  $\beta$ 、拉格朗日乘子  $T_n$ 等参数寻优,得到低秩矩阵  $X_n$ 和稀疏噪声矩阵  $S_n$ 。





(2)低秩矩阵 X<sub>n</sub> 作为 SCAE 网络输入,激活函数为 Sigmoid 函数,学习率设置为 0.2。利用 SCAE 网络中权重参数 w、b,对隐含网络层数 m、隐含层神经元个数 j 进行调参寻优。

(3) 构建 SAE - PLSR 预测模型,将输出结果与 理化检测数据进行对比,计算误差并反向传播,训练 网络寻优,直至输出青梅样本 SSC 预测。

## 4 试验与结果分析

#### 4.1 青梅缺陷分类结果与分析

青梅缺陷分类网络代码采用 Python 编写,利用 深度学习框架 PyTorch 定义网络计算图,在迁移学 习策略基础上对其进行优化,加速训练学习速度。 将测试集青梅数据导入训练好的青梅缺陷检测网络 模型,得出测试结果,如图 11 所示。

基于 ViT 模型青梅缺陷分类网络的训练集平均 判别准确率达到 99.53%,验证集平均判别准确率达 到 99.16%。由图 12 可知,280 个疤痕缺陷青梅图 像、800 个腐烂缺陷青梅图像、460 个完好青梅图像、 160 个裂纹缺陷青梅图像均被正确识别,其准确率达 到 100%。但 800 个雨斑缺陷青梅中有 779 个被正确 识别,21 个被误识为完好青梅,占比 2.6%。根据截 图识别结果分析,如图 13 所示部分测试结果,红色框 选为识别错误的图像,该图像上雨斑的位置较偏、雨 斑点数较浅,雨斑未被识别,所以识别错误。

将 ViT 网络与 VGG 网络、ResNet - 18 网络进行 模型性能对比,以各类判别准确率、平均判别准确 率、每组平均测试时间(每 32 幅图像为一组)作为 评价指标。将 3 个网络模型充分训练,在训练集上 交叉熵损失均小于0.005时得到3种模型,将模型







在同一未知样品数据集上进行测试,得到最终准确 率,结果如表1所示。可知 ViT 网络平均判别准确率 达到 99.16%,其中腐烂、疤痕、裂纹以及完好青梅图 像的各类判别准确率达到 100%,雨斑达到 97.38%, 均明显优于其他网络,但其每组平均测试时间为



Fig. 13 Screenshot of green plum test results

#### 表1 与其他网络的青梅缺陷测试结果对比

 Tab. 1
 Comparison of green plum defect test results

with other networks

| 参数          |    | VJT 网络    | VGG   | ResNet - 18 |
|-------------|----|-----------|-------|-------------|
|             |    | VII (*12) | 网络    | 网络          |
|             | 腐烂 | 100       | 89.38 | 99.25       |
| 各类判别准确率/%   | 雨斑 | 97.38     | 89.88 | 92.15       |
|             | 疤痕 | 100       | 78.93 | 83.35       |
|             | 裂纹 | 100       | 55.63 | 78.13       |
|             | 完好 | 100       | 89.88 | 95.65       |
| 平均判别准确率/%   |    | 99.16     | 84.00 | 93.80       |
| 每组平均测试时间/ms |    | 100. 59   | 86.56 | 81.69       |

100.59 ms,稍大于其他两组网络。ViT 网络以其独有 的多头注意力机制,增加多组独立权重,全局特征表示 能力更强、迁移效果更好,验证了其在缺陷分类性能上 的优越性;但参数量增加,致使其运算时间加长。

#### 4.2 青梅糖度预测结果与分析

采用低秩张量恢复和堆叠卷积自动编码器对青 梅样本高光谱数据进行去噪和降维处理,提取低维特 征。试验可知,SCAE 网络隐含层数 m、隐含层神经元 个数 j 是影响模型预测结果的重要因素,3 种不同模 型规模的青梅糖度预测结果如图 14,不同网络层数 及隐含层神经元个数对应的预测结果如表 2 所示。



Fig. 14 Prediction results of different network scales

|        | 表 2        | 基于 LRTR -       | -SCAE - 1 | PLSR 青梅   | 糖度预测结   | 5果          |    |
|--------|------------|-----------------|-----------|-----------|---------|-------------|----|
| Tab. 2 | Prediction | ı results of gr | een plum  | SSC based | on LRTR | - SCAE - PL | SR |

| 隐含层个数 | 神经元最优 | 模型规模                    | 训练集相关<br>至数 P | 均方根误差             | 预测集相关    | 均方根误差    |
|-------|-------|-------------------------|---------------|-------------------|----------|----------|
|       |       | 示 奴 n <sub>C</sub>      | RMSEC/%       | 示或 R <sub>P</sub> | RMSEP/%  |          |
| 2     | 55    | 119 - 90 - 55           | 0. 903 5      | 0. 727 9          | 0. 897 3 | 0.8033   |
| 3     | 36    | 119 - 90 - 55 - 36      | 0.9783        | 0. 562 8          | 0.9654   | 0. 582 7 |
| 4     | 27    | 119 - 90 - 55 - 36 - 27 | 0. 931 9      | 0. 594 7          | 0.9061   | 0. 732 3 |

由表 2 可知, 当隐含层数为 3, 网络规模为 119-90-55-36 时, LRTR-SCAE-PLSR 模型最终 预测集相关系数  $R_p$ 最大, 为 0.965 4, RMSEP 最小, 为 0.582 7%; 特征数为 36, 降维效果明显。网络规 模为 119-90-55-36-27 时,  $R_p$ 为 0.906 1, RMSEP 为 0.732 3%, 随着网络层数增加, 网络训练 成本加大, 预测集相关系数  $R_p$ 并未进一步提高, 可 能是网络层数增加导致训练误差变大的原因。

与其他回归模型预测结果的对比如表 3 所示。 由结果可知,对于 PLSR 回归模型,经过 SCAE 降维 后,原高光谱数据降至 47 维, *R*<sub>c</sub>为 0.945 1, *R*<sub>p</sub>为 0.930 8,而 LRTR - SCAE 处理后,数据维度降至 36, *R*<sub>c</sub>为 0.978 3, *R*<sub>p</sub>为 0.965 4,不仅维度更低,预测集 相关系数也明显提高,验证了 LRTR - SCAE 模型的 降维去噪优势,有效提取了原光谱的有效特征,优化 了模型规模。对于 BP、SVR、PLSR 这 3 种不同回归 模型,在模型规模、训练集相关系数 *R*<sub>c</sub>和预测集相 关系数 *R*<sub>p</sub>方面, PLSR 回归模型表现均明显优于 其他模型,故青梅糖度预测最终确定选用LRTR -

#### 表 3 各模型预测结果对比

# Tab. 3 Comparison of prediction results of different models

| 降维算法        | 回归   | 描刊加措               | 训练集相      | 预测集相      |
|-------------|------|--------------------|-----------|-----------|
|             | 模型   | 侠望规快               | 关系数 $R_c$ | 关系数 $R_P$ |
| SCAE        | BP   | 119 - 90 - 85 - 62 | 0. 832 2  | 0. 791 7  |
|             | SVR  | 119 - 90 - 78 - 59 | 0. 895 7  | 0. 852 9  |
|             | PLSR | 119 - 90 - 55 - 47 | 0.9451    | 0.9308    |
| LRTR – SCAE | BP   | 119 - 90 - 85 - 56 | 0.8617    | 0. 835 9  |
|             | SVR  | 119 - 90 - 78 - 49 | 0.9106    | 0.9038    |
|             | PLSR | 119 - 90 - 55 - 36 | 0.9783    | 0.9654    |

SCAE - PLSR 模型。

## 5 青梅分选人机交互系统

青梅品质分选系统主要完成对采集的青梅图像 信息和光谱信息进行处理、分析、判定等,并在界面 显示功能及预测结果等,具体如图 15 所示。交互系 统软件主要是基于 Windows 平台利用 PyQt5 进行设 计搭建。依据青梅深加工对品质的实际需求,综合 考虑青梅表面缺陷以及糖度(SSC)预测结果,将青 梅分为4 个品级。具体如下:根据外表缺陷,一等 品为完好,二等品为雨斑,三等品为裂纹、疤痕,四等 品为腐烂;根据内部品质(糖度),SSC 为6%以上时 是一等品,为4%~6%时是二等品,为2%~4%时



图 15 计算机软件界面 Fig. 15 Computer software interface

是三等品;为2%以下时是四等品。当缺陷、SSC属 于同一品级时,青梅将被分为该品级,当缺陷、SSC 不属于同一品级时,将根据较低品级进行判定。

#### 6 结论

(1)青梅外表缺陷分类方面,结合青梅分选需 求,以 ViT 网络模型为基础,通过 softmax 函数减少 梯度,引入多头注意力机制,其全局特征表示能力更 强、迁移效果更好。平均判别准确率达到 99.16%, 其中腐烂、疤痕、裂纹以及完好青梅图像的判别准确 率达到 100%、雨斑达到 97.38%。ViT 网络的平均 判别准确率、各类判别准确率均明显优于 VGG 网 络、ResNet - 18 网络。但其每组平均测试时间为 100.59 ms,略高于 VGG 网络、ResNet - 18 网络的 86.56、81.69 ms,主要是参数量增加,致使其运算时 间加长。

(2) 青梅内部品质(SSC) 预测方面, 基于高光谱 成像技术, 结合低秩张量恢复的去噪优势和堆叠卷 积自动编码器的降维优势,构建了 LRTR - SCAE - PLSR 青梅糖度预测模型。网络规模为 119 -90 - 55 - 36时,模型预测集相关系数为 0.965 4,均方根 误差为 0.582 7%,表现最佳;但随着网络层数增加,  $R_p$ 并未进一步提高,可能是网络层数增加导致训练 误差变大。通过与 BP、SVR 回归模型比对,在模型 规模、训练集相关系数  $R_c$ 和预测集相关系数  $R_p$ 方面,LRTR - SCAE - PLSR 模型表现最优。通过 SCAE、LRTR - SCAE 两种降维模型比对,LRTR - SCAE 模型不仅维度更低,预测集相关系数也明显 提高,验证了 LRTR - SCAE 模型的降维去噪优势。

(3)基于上述外表缺陷分类及内部品质预测模型,设计并搭建了可用于青梅内外品质无损分选的智能装备,主要由外表缺陷检测模块、内部品质检测 模块、传送机构、分选机构、控制系统、人机交互系统 等组成。该装备整机尺寸小,结构简单,分选结果满 足青梅深加工需求,对提高青梅产品附加值具有重 要意义。

#### 参考文献

- [1] 刘功德,苏艳兰,黄富宇,等. 青梅的功能价值及加工研究进展[J]. 农业研究与应用,2018,31(4):1-8.
   LIU Gongde, SU Yanlan, HUANG Fuyu, et al. Function value and processing research progress of *Prunus mume*[J].
   Agricultural Research and Application,2018,31(4):1-8. (in Chinese)
- [2] 赵维薇,申元英. 青梅果药理学作用研究进展[J]. 安徽农业科学,2017,45(4):128-131.
   ZHAO Weiwei,SHEN Yuanying. Research progress on pharmacological effects of *Prunus mume* fruit[J]. Journal of Anhui Agricultural Sciences,2017,45(4):128-131. (in Chinese)
- [3] 林钥铭,杨颖,杨雪,等. 成熟度对青梅果汁营养成分及风味的影响[J]. 浙江农业学报,2014,26(4):1049-1054.
   LIN Yueming, YANG Ying, YANG Xue, et al. Effects of ripe stage on nutritional composition and flavor of green mume juice
   [J]. Acta Agriculturae Zhejiangensis,2014,26(4):1049-1054. (in Chinese)
- [4] 刘燕德,马奎荣,孙旭东,等. 梨和苹果糖度在线检测通用数学模型研究[J]. 光谱学与光谱分析,2017,37(7):2177-2183.

LIU Yande, MA Kuirong, SUN Xudong, et al. The fruits soluble solids content detection online using universal mathematical model[J]. Spectroscopy and Spectral Analysis,2017,37(7):2177-2183. (in Chinese)

- [5] 李红,张凯,陈超,等. 基于高光谱成像技术的生菜冠层含水率检测[J]. 农业机械学报,2021,52(2):211-217,274. LI Hong, ZHANG Kai, CHEN Chao, et al. Detection of moisture content in lettuce canopy based on hyperspectral imaging technique[J]. Transactions of the Chinese Society for Agricultural Machinery,2021,52(2):211-217,274. (in Chinese)
- [6] 李成吉,张淑娟,孙海霞,等. 基于计算机视觉的核桃外观缺陷检测[J]. 现代食品科技,2019,35(8):247-253,246.
   LI Chengji, ZHANG Shujuan, SUN Haixia, et al. Walnut appearance defect detection based on computer vision[J]. Modern Food Science and Technology,2019,35(8):247-253,246. (in Chinese)
- [7] 雷凯栋. 基于高光谱、计算机视觉对核桃壳、仁及分心木的识别[D]. 太谷:山西农业大学,2018. LEI Kaidong. Classification of walnut kernel, shell, and distracter by high-spectrum and computer vision[D]. Taigu: Shanxi Agricultural University,2018. (in Chinese)
- [8] CHEN Y, ZHAO X, JIA X. Spectral-spatial classification of hyperspectral data based on deep belief network[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2015, 8(6):2381-2392.
- [9] WAN S, GOUDOS S. Faster R CNN for multi-class fruit detection using a robotic vision system [J]. Computer Networks, 2020, 168: 107036.
- [10] DA COSTA A Z, FIGUEROA H E H, FRACAROLLI J A. Computer vision based detection of external defects on tomatoes using deep learning[J]. Biosystems Engineering, 2020, 190:131 – 144.
- [11] 谢为俊,丁冶春,王凤贺,等. 基于卷积神经网络的油茶籽完整性识别方法[J]. 农业机械学报,2020,51(7):13-21.
   XIE Weijun, DING Yechun, WANG Fenghe, et al. Integrity recognition of *Camellia oleifera* seeds based on convolutional neural network[J]. Transactions of the Chinese Society for Agricultural Machinery,2020,51(7):13-21. (in Chinese)
- [12] MAGWAZA L S, LANDAHL S, CRONJE P J R, et al. The use of Vis/NIRS and chemometric analysis to predict fruit defects and postharvest behaviour of 'Nules Clementine' mandarin fruit[J]. Food Chemistry, 2014, 163:267 - 274.
- [13] 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.

[14] 邵园园,王永贤,玄冠涛,等.基于高光谱成像的肥城桃品质可视化分析与成熟度检测[J].农业机械学报,2020,51(8): 344-350.

SHAO Yuanyuan, WANG Yongxian, XUAN Guantao, et al. Visual detection of SSC and firmness and maturity prediction for Feicheng peach by using hyperspectral imaging [J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(8):344-350. (in Chinese)

[15] 陈东杰,姜沛宏,郭风军,等.不同速度对近红外光谱预测库尔勒香梨品质模型的影响[J].光谱学与光谱分析,2020, 40(6):1839-1845. CUEN Durring HANC Britagy CUO Function and a Effect of and intermediate balance hand on NUB different

CHEN Dongjie, JIANG Peihong, GUO Fengjun, et al. Effect of prediction model of kolar pear based on NIR diffuse transmission under different moving speed on online [J]. Spectroscopy and Spectral Analysis, 2020, 40(6):1839 – 1845. (in Chinese)

- [16] 薛志祥,余旭初,谭熊,等. 局部超图拉普拉斯约束的高光谱影像低秩表示去噪方法[J]. 光学学报,2017,37(5):77-85.
   XUE Zhixiang, YU Xuchu, TAN Xiong, et al. Local hypergraph laplacian regularized low-rank representation for noise reduction of hyperspectral images[J]. Acta Optica Sinica,2017,37(5):77-85. (in Chinese)
- [17] ZHU R, DONG M, XUE J H. Spectral nonlocal restoration of hyperspectral images with low-rank property [J]. IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing, 2014, 8(6): 3062 - 3067.
- [18] LIU Z, HE Y, CEN H, et al. Deep feature representation with stacked sparse auto-encoder and convolutional neural network for hyperspectral imaging-based detection of cucumber defects[J]. Transactions of the ASABE, 2018,61(2): 425-436.
- [19] YU J, HUANG D, WEI Z. Unsupervised image segmentation via stacked denoising auto-encoder and hierarchical patch indexing[J]. Signal Processing, 2017,143:346-353.
- [20] WANG N, ZHOU W, WANG J, et al. Transformer meets tracker:exploiting temporal context for robust visual tracking[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 1571 1580.
- [21] YAN B, PENG H, FU J, et al. Learning spatio-temporal transformer for visual tracking [C] // Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021: 10448 10457.
- [22] LIU Z, LIN Y, CAO Y, et al. Swin transformer: hierar-chical vision transformer using shifted windows [C] // Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021: 10012 - 10022.
- [23] 龚韬. 基于低秩表示与张量分解的高光谱降噪算法研究[D]. 北京:中国科学院大学,2020.
   GONG Tao. Research on hyperspectral denoising algorithm based on low rank representation and tensor decomposition[D].
   Beijing: University of Chinese Academy of Sciences, 2020. (in Chinese)
- [24] FAN H, CHEN Y, GUO Y, et al. Hyperspectral image restoration using low-rank tensor recovery [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2017, 10(10):4589-4604.
- [25] MARCO J, HERNANDEZ Q, MUNOZ A, et al. DeepToF:off-the-shelf real-time correction of multipath interference in timeof-flight imaging[J]. ACM Transactions on Graphics, 2018, 36(6):1-12.

#### (上接第368页)

[30] 滕峰成,王珊珊,杨雪璠,等. 基于 PSO 算法的 GMM 改进 J - A 磁滞模型的参数辨识与验证[J]. 计量学报,2021,42 (9):1193-1199.

TENG Fengcheng, WANG Shanshan, YANG Xuepan, et al. Parameter identification and verification of improved J – A hysteresis model of GMM based on PSO algorithm [J]. ACTA Metrologica Sinica, 2021,42(9):1193 – 1199. (in Chinese)

- [31] ALSALIBI B, ABUALIGAH L, KHADER A T. A novel bat algorithm with dynamic membrane structure for optimization problems[J]. Appl. Intell., 2021, 51(4):1992-2017.
- [32] ALTAN A, KARASU S, ZIO E. A new hybrid model for wind speed forecasting combining long short-term memory neural network, decomposition methods and grey wolf optimizer[J]. Applied Soft Computing, 2021, 100(11):25-39.
- [33] NADIMI-SHAHRAKI M H, TAGHIAN S, MIRJALILI S. An improved grey wolf optimizer for solving engineering problems [J]. Expert Systems with Applications, 2021,166:113917.
- [34] 李伟中,孔令成,王美玲.结合模糊逻辑的自适应灰狼优化算法[J]. 小型微型计算机系统,2021,42(10):2023-2030.
   LI Weizhong, KONG Lingcheng, WANG Meiling. Adaptive gray wolf optimization algorithm combined with fuzzy logic[J].
   Journal of Chinese Computer Systems,2021,42(10):2023-2030. (in Chinese)
- [35] WU Y H, SUN L Q, WANG B N. A hybrid XGBoost ISSA LSTM model for accurate short-term and long-term dissolved oxygen prediction in ponds[J]. Environmental Science and Pollution Research, 2021,9(5):863-876.
- [36] XUE J K, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm [J]. Systems Science & Control Engineering, 2020, 8(1):269 - 284.
- [37] ZHANG C L, DING S F. Stochastic configuration network based on chaotic sparrow search algorithm [J]. Knowledge Based Systems, 2021, 220(23):1103-1116.
- [38] THONGBAI P, MILROY S, BANGE M, et al. Agronomic responses of cotton to low soil oxygen during waterlogging [C] // 10th Australian Agronomy Conference, Hobart, Tasmania, 2001: 185 – 190.
- [39] BHATTARAI S P, MCHUFH A D, LOTZ G, et al. Cotton under subsurface drip and furrow irrigation in a heavy clay soil[J]. Aust. J. Exp. Agr., 2005, 18(3):1321 - 1329.