

doi:10.6041/j.issn.1000-1298.2024.03.021

基于 Swin Transformer 与 GRU 的低温贮藏番茄成熟度识别与时序预测研究

杨信廷^{1,2} 刘彤¹ 韩佳伟^{2,3} 郭向阳¹ 杨霖⁴

(1. 上海海洋大学信息学院, 上海 201306; 2. 北京市农林科学院信息技术研究中心, 北京 100097;
 3. 农产品质量安全追溯技术及应用国家工程研究中心, 北京 100097;
 4. 仲恺农业工程学院信息科学与技术学院, 广州 510225)

摘要: 面向绿熟番茄采后持续转熟特征, 适时调温是满足不同成熟度番茄适宜贮运温度需求的关键, 而果实成熟度自动识别与动态预测则是实现温度适时调控的基础条件。本文基于 Swin Transformer 与改进 GRU 提出了一种番茄成熟度识别与时序动态预测模型, 首先通过融合番茄两侧图像获取番茄表观全局红色总占比, 构建不同成熟番茄图像数据集, 并基于迁移学习优化 Swin Transformer 模型初始权重配置, 实现番茄成熟度分类识别; 其次, 周期性采集不同储藏温度(4、9、14℃)下番茄图像数据, 结合番茄初始颜色特征与贮藏环境信息, 构建基于 Swin Transformer 与 GRU 的番茄成熟度时序预测模型, 并融合时间注意力模块优化模型预测精度; 最后, 对比分析不同模型预测结果, 验证本研究所提模型的准确性与优越性。结果表明, 番茄成熟度正确识别率为 95.783%, 相比 VGG16、AlexNet、ResNet50 模型, 模型正确识别率分别提升 2.83%、3.35%、12.34%。番茄成熟度时序预测均方误差(MSE)为 0.225, 相比原始 GRU、LSTM、BiGRU 模型 MSE 最高降低 29.46%。本研究为兼顾番茄成熟度实现贮藏温度柔性适时调控提供了关键理论基础。

关键词: 番茄; 低温贮藏; 成熟度识别; 时序预测模型; Swin Transformer; GRU

中图分类号: S641.2 文献标识码: A 文章编号: 1000-1298(2024)03-0213-08

OSID: 

Low Temperature Storage Tomato Maturity Recognition and Time Series Prediction Based on Swin Transformer – GRU

YANG Xinting^{1,2} LIU Tong¹ HAN Jiawei^{2,3} GUO Xiangyang¹ YANG Lin⁴

(1. Department of Information, Shanghai Ocean University, Shanghai 201306, China)

2. Research Center of Information Technology, Beijing Academy of Agriculture and Forestry Sciences, Beijing 100097, China

3. National Engineering Laboratory for Agri-product Quality Traceability, Beijing 100097, China

4. Department of Information Science and Technology, Zhongkai University of Agriculture and Engineering, Guangzhou 510225, China

Abstract: Targeting the continuous ripening process of green mature tomatoes after harvest, timely temperature adjustment plays a pivotal role in meeting the appropriate storage and transportation temperature requirements for tomatoes at different stages of ripeness. Meanwhile, automatic recognition and dynamic prediction of fruit ripeness serve as fundamental prerequisites for achieving temperature control at the right time. A tomato ripeness recognition and temporal dynamic prediction model was proposed based on Swin Transformer and improved GRU. Firstly, by fusing the images of both sides of tomatoes, the overall redness proportion as a visual feature was obtained and a dataset of tomato images at different ripeness stages was constructed. Through transfer learning, the initial weight configuration of the Swin Transformer model was optimized to achieve tomato ripeness classification. Secondly, tomato image data at different storage temperatures (4℃, 9℃ and 14℃) was periodically collected, and the initial color features of tomatoes were combined with storage environment information to build a tomato ripeness temporal prediction model based on Swin Transformer and GRU. Furthermore, a time attention module

收稿日期: 2023-10-08 修回日期: 2023-12-19

基金项目: 国家重点研发计划项目(2023YFD2001302、2022YFD2001804)和北京市农林科学院科研创新平台建设项目(PT2023-24)

作者简介: 杨信廷(1974—), 男, 研究员, 博士生导师, 主要从事冷链物流信息化关键技术研究, E-mail: yangxt@nercita.org.cn

通信作者: 韩佳伟(1989—), 男, 高级农艺师, 博士, 主要从事智慧冷链物流关键技术研究, E-mail: hanjw@nercita.org.cn

was incorporated to enhance the prediction accuracy of the model. Lastly, the prediction results of different models were compared and analyzed to validate the accuracy and superiority of the proposed model. The results demonstrated a correct recognition rate of 95.783% for tomato ripeness classification, with respective improvements of 2.83%, 3.35%, and 12.34% compared with that of the VGG16, AlexNet, and ResNet50 models. The mean square error (MSE) for tomato ripeness temporal prediction was 0.225, representing a maximum reduction of 29.46% compared with that of the original GRU, LSTM, and BiGRU models. The research result can provide a key theoretical basis for the flexible and timely regulation of storage temperature considering tomato maturity.

Key words: tomato; low temperature storage; maturity recognition; time series prediction model; Swin Transformer; GRU

0 引言

番茄成熟进程分为绿熟、破色、转色、粉红、浅红、红熟等阶段,为延长番茄采后销售半径与周期,有效降低因搬运、震动、冲击等引发的机械损伤风险,番茄常采摘于具有高硬度特性的绿熟期,并在储运过程完成后熟转色。然而,伴随番茄成熟转色进程,贮运温度须适时逐步降低,以满足不同成熟度番茄所需适宜温度不同的需求^[1],否则将引发番茄成熟衰老加速、水分流失严重甚至出现冷害与腐烂变质等问题^[2]。据相关研究表明^[3-5],我国每年因储运温度与果蔬成熟度不匹配而直接造成15%~20%的采后损耗。鉴于此,番茄采后储运中精准识别与时序预测番茄成熟转色进程至关重要,可为精准预判番茄成熟等级转变节点,适时调控储运温度以及为有效解决番茄成熟度与贮运温度不匹配问题等提供可靠决策支持,在降低番茄流通损失、延长其货架期以及强化供应链控熟保质能力等方面具有现实意义和显著经济价值。

传统番茄成熟度识别方法主要依赖于人工观察和经验判断,易受主观意识、视觉疲劳及环境条件影响,存在误差高、效率低及费时费工等问题^[6]。此外,构建不同番茄成熟度时序预测模型需融合大量番茄成熟度时序变化数据,单纯采用人工裸眼标定,易将数据集自身误差叠加至预测模型,导致时序预测模型准确性与实用性不强。近年来,随着计算机软硬件技术的快速发展,基于卷积神经网络的图像处理技术已被广泛应用于番茄成熟度识别研究,其强大的非线性处理能力可以有效克服传统人工检测方法的不足^[7],且可显著提升检测效率与精度^[8]。张俊宇等^[9]提出一种基于注意力机制与改进YOLO v5s的温室番茄目标快速检测方法,对温室环境下红色番茄和绿色番茄的检测精度可达99.88%、99.18%。刘芳等^[10]提出了一种改进型多尺度YOLO算法(IMS-YOLO),构建了一种复杂环境下番茄果实快速识别网络模型,番茄果实检测精度为

97.13%。上述研究结果表明基于卷积神经网络(CNN)的番茄成熟识别技术可有效替代人工裸眼判定方法。然而,CNN在处理图形数据时主要聚焦于局部特征,较少考虑全局特征^[11],亦为模型精度提升的关键限制。鉴于此,DOSOVITSKIY等^[12]提出基于自注意力机制的Swin Transformer模型,可全局兼顾输入序列不同位置之间的关联性,并结合CNN的位移不变性和分辨率阶段性降低的特性,可有效提升识别模型的准确性与鲁棒性^[13]。此外,上述研究仅涉及番茄成熟度实时识别检测,未引入时间维度开展番茄成熟度时序预测研究,使之无法满足番茄成熟度动态预测与储运温度适时调控需求。近年来,GRU模型凭借参数设置少、结构简单与模型收敛性强等优点^[14],已在作物产量、病虫害预测、土壤质量评估等农业时序预测研究方面得以广泛应用,为农业生产提供了关键技术支撑^[15-17]。然而,GRU存在梯度层间衰减问题,无法捕捉更长时序信息,使得长时动态预测精度不高。

综上,本文以低温贮藏番茄为研究对象,重点研究定量预测贮藏过程中番茄成熟度阶段转换趋势,提出一种基于Swin Transformer和改进GRU的番茄成熟度识别与时序预测模型。首先,通过周期性取样,获取在贮藏温度4、9、14℃下番茄成熟过程图像数据。其次,利用Swin Transformer模型实现番茄成熟度分类。最后,将番茄成熟度特征与外部环境因素按照时间序列传递至GRU模块,整合番茄整个成熟期的时间信息特征,实现对番茄成熟度时序性预测,同时引入时间注意力模块对时间信息进行动态加权,以提高番茄成熟度时序性预测精度。

1 材料与方法

1.1 番茄试验材料

本文所用番茄采摘于北京市密云区某温室,采后立即运至实验室(约1 h车程)。鲜采番茄未经清洗与消毒等预处理操作,挑选果径为8 cm左右的番茄共600个,并等分为3组,贮藏温度分别为4、9、

14℃(相对湿度85%),并以1d为间隔,对番茄进行周期性图像取样。

1.2 数据采集

将单个番茄置于柔光摄影箱中,采用Nikon D90型相机分别拍摄番茄两侧图像(JPG格式),图像分辨率为4288像素×2848像素,色彩空间为sRGB。为获得番茄在不同温度条件下完整成熟过程的时序性数据,番茄样品置于ZH-RTH-225C型恒温恒湿箱内来控制环境温度和湿度,恒温控制精度为±0.5℃,湿度控制精度为±5%。选取适合绿熟期或破色期番茄的贮藏温度14℃,适合转色期或粉色期番茄的贮藏温度9℃,适合浅红期或红熟期番茄的贮藏温度4℃(表1)分别进行贮藏实验,设置相对湿度为80%。每个温度选取200个绿熟期番茄样品,每天拍摄番茄记录成熟程度,直至番茄转为红

熟期结束。4、9、14℃下数据采集分别持续40 d,各温度下番茄成熟度变化如图1所示,图中D后数字表示贮藏时间(d)。

表1 番茄成熟度分类

Tab. 1 Tomato ripeness classification

成熟度	描述	适宜温度/℃	图像
绿熟期	红色面积占比为0,果皮泛白	12~14	
破色期	红色面积占比不足10%		
转色期	红色面积占比为10%~30%	9~11	
粉红期	红色面积占比为30%~60%		
浅红期	红色面积占比为60%~90%	2~4	
红熟期	红色面积占比为90%~100%		

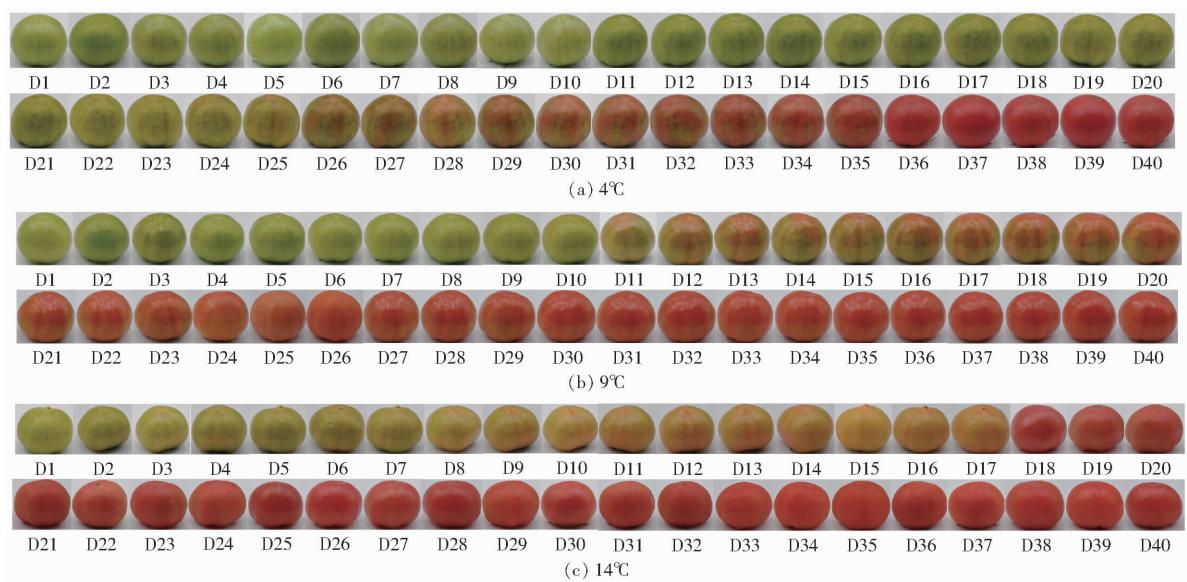


图1 各温度下番茄成熟度变化

Fig. 1 Variation of tomato ripeness at different temperatures

1.3 数据预处理

融合番茄两侧图像获取番茄全局颜色特征,为保证每幅图像在训练前类别正确,采用自适应分割方法去除图像背景及阴影获得番茄完整图像,计算番茄的像素面积,求得红色像素面积占比,依照红色像素面积占比对番茄果实进行成熟度分类,并进行数据清洗去除异常值和不合格图像。由于合并图像的分辨率与模型所需分辨率不同,故将尺寸归一化至224像素×224像素。共筛选出识别数据集7763幅样本图像,包括绿熟期1280幅,破色期1293幅,转色期1301幅,粉红期1289幅,浅红期1302幅,红熟期1298幅。随机抽取每类80%作为训练集,20%作为测试集。

对采集的时序数据,利用训练好的Swin Transformer模型提取样本图像的特征信息,获得番

茄的成熟状态信息。并将外部环境温度信息与提取的视觉特征、成熟状态信息等数据进行聚合,获得番茄每天的特征向量,按照采集时间进行时序性排序,构建反映番茄整个成熟过程的时序性特征序列。

1.4 模型构建

1.4.1 识别模型

Swin Transformer的网络结构主要由Patch Partition、Linear Embedding、Swin Transformer Blocks、Patch Merging组成。Patch Partition将输入的番茄图像分成若干个固定大小的块(patches),提高图像中局部信息处理能力,增强模型感受野。Linear Embedding将每个块映射到一个低维向量表示,将图像中的像素转化为向量形式。Swin Transformer Blocks是Swin Transformer的核心部分,由基于移动

窗口的多头自注意力模块 (W-MSA/SW-MSA)、MLP 层、LN 层和残差连接组成^[18-19], 主要实现番茄成熟度特征提取, Swin Transformer Blocks 结构如图 2 所示。

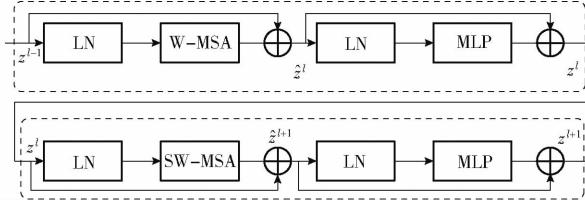


图 2 Swin Transformer Blocks 网络结构图

Fig. 2 Swin Transformer Blocks network structure diagram

W-MSA/SW-MSA 使用基于移动窗口的方式对序列进行划分, 从而减少计算量和内存占用。MLP 层采用 GELU 激活函数, 用于对输入序列进行非线性变换, 提高模型表达能力。并在两个线性变换之间加入残差连接, 增加模型深度, 增强信息流动和特征重用, 能够进一步提取番茄成熟度特征。LN 层用于对序列进行归一化操作, 使输入数据的分布更加稳定, 有助于模型捕捉番茄成熟度特征之间的关系。Patch Merging 在 Swin Transformer Blocks 之间进行下采样, 以缩小特征图的分辨率并增加通道数, 从而实现层次化的特征提取。Swin Transformer 网络结构如图 3 所示。

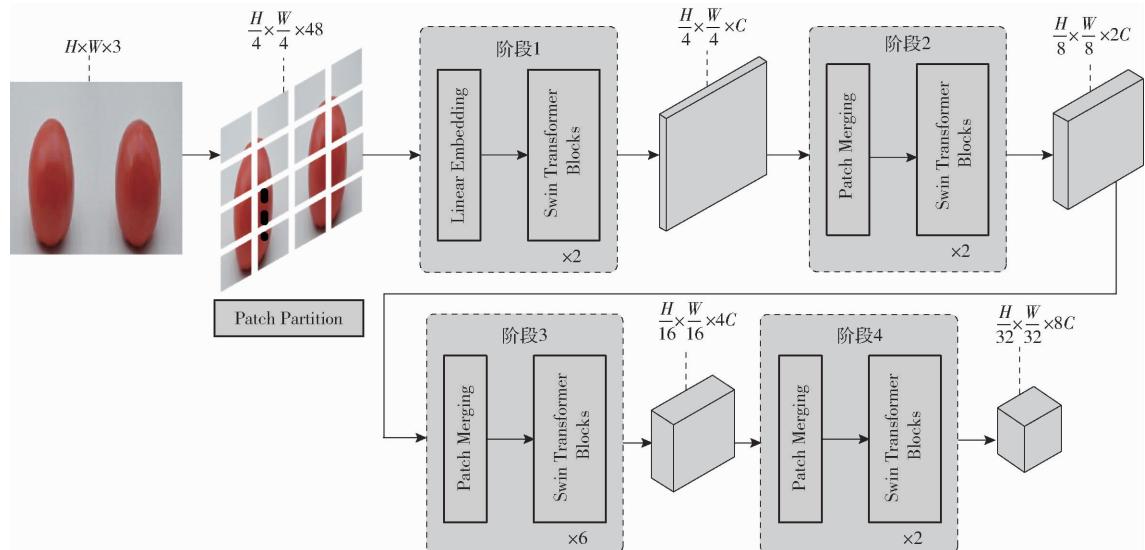


图 3 Swin Transformer 网络结构图

Fig. 3 Swin Transformer network structure diagram

1.4.2 预测模型

(1) GRU 模型

GRU 模型包含两种状态: 隐含状态 h 和候选状态 \tilde{h} , 以及两个控制门: 重置门 r 和更新门 z ^[20]。重置门决定当前时刻的输入信息如何与前一时刻的状态信息进行结合, 从而决定前一时刻状态信息的保留程度。更新门决定之前状态信息在当前时间步的保留量。在每个时间步, GRU 模型通过当前节点的输入 x_i 和前一时刻的隐含状态 h_{t-1} 获取两个控制

门的状态, 并通过重置门和更新门来控制信息的流动^[21]。GRU 网络结构如图 4 所示。

(2) 时间注意力模块

对于番茄成熟度时序预测任务, 直接使用 GRU 模型可能难以充分捕捉不同时间步之间的关联信息, 为此本文引入时间注意力模块 (Time self attention)^[22-23]。该机制基于输入序列本身, 通过注意力机制实现时间步之间的交互关系建模, 学习不同时间步之间的依赖关系。首先, 利用 3 个线性映

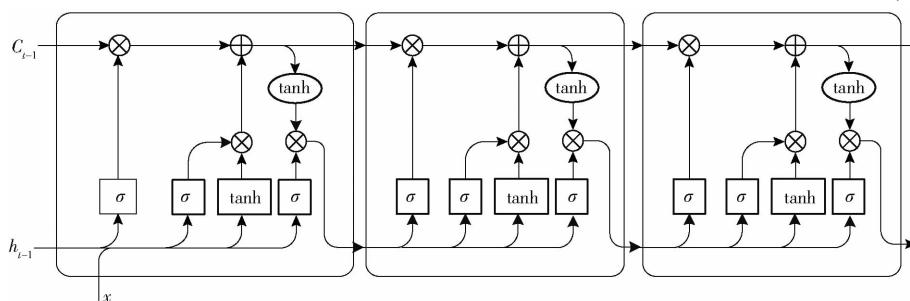


图 4 GRU 网络结构图

Fig. 4 GRU network structure diagram

射分别对输入序列提取查询向量 V 、键向量 K 和值向量 Q 。然后,通过缩放点积计算得到每个时间步的注意力分数,进而通过 Softmax 函数得到各时间步的注意权重分布。最后,通过注意权重与值向量的乘积,得到考虑时间步关联的最终输出。Time self attention 结构如图 5 所示。

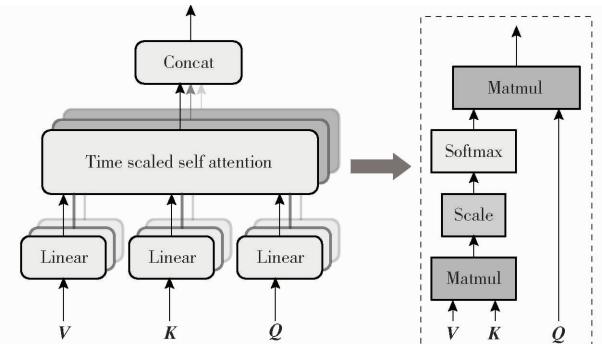


图 5 Time self attention 结构图

Fig. 5 Time self attention structure diagram

1.4.3 模型集成

为准确预测不同温度在不同时间对番茄成熟的影响,提高预测精度,本文结合 Swin Transformer 和门控循环单元 (GRU),提出一种基于 Swin Transformer – GRU 的番茄成熟度识别与时序预测模型,通过增加时间特征注意力模块有效捕捉不同特征之间的关联性和时间序列特征,对番茄成熟度进行精准识别和时序性预测,Swin Transformer – GRU 模型结构如图 6 所示。

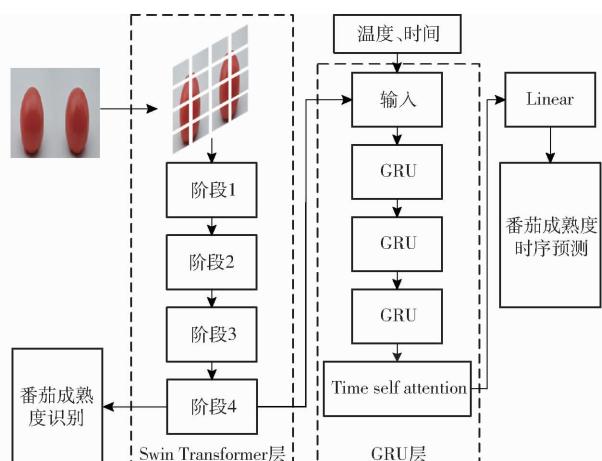


图 6 Swin Transformer – GRU 模型结构图

Fig. 6 Swin Transformer – GRU model structure diagram

1.5 实验平台

实验所使用的计算机硬件配置如下:处理器为 Intel(R) Xeon(R) Gold 6240 CPU @ 2.60 GHz 2.59 GHz,内存 512 GB,操作系统为 64 位 Windows Server 2012 R2 Datacenter 系统, GPU 显卡为 NVIDIA GeForce RTX 2080 Ti 11 GB。使用 PyTorch 1.10.2、Cuda 10.2 和 Python 3.7.1 搭建深度学习框

架训练模型,集成开发环境 (IDE) 为 PyCharm。模型实验相关参数如表 2 所示。

表 2 模型相关参数

Tab. 2 Model related parameters

模型	层数	初始学习率	迭代次数	优化器	批量尺寸
Swin Transformer		0.001	150	AdamW	32
GRU	3	0.001	300	AdamW	256

1.6 模型验证

为了验证模型的科学性和有效性,分别从成熟度识别和预测两方面进行评估。评估番茄成熟度识别模型时,选取准确率 (Accuracy)、精确率 (Precision)、召回率(Recall)、F1 值进行评价。对于番茄成熟度预测模型评估,选取平均绝对误差 (Mean absolute error, MAE)、均方误差 (Mean square error, MSE)、均方根误差 (Root mean square error, RMSE) 进行评价。

2 结果与分析

2.1 番茄成熟度识别结果分析

为检测 Swin Transformer 模块对番茄成熟度识别的效果,分别将 ResNet50、VGG16、AlexNet、Swin Transformer 与 GRU 模型组合进行对比研究,数据集预处理方式和数据集分布相同,控制模型输入端相同。图 7 为 Swin Transformer – GRU 模型损失值和准确率的变化曲线及精确率、F1 值、召回率变化曲线。从图 7 中可看出,模型检测准确率稳步上升,并逐渐达到平稳,损失值缓步下降,这大概率是因为模型在训练过程中逐渐学习到了更多的特征和模式,提高了对番茄成熟度变化的理解能力和预测准确性。图 8 为 ResNet50 – GRU、VGG16 – GRU、AlexNet – GRU、Swin Transformer – GRU 的准确率和损失值曲线,总体来看,Swin Transformer – GRU 的表现优于其他 3 个基准模型。由表 3 不同模型对于番茄成熟度识别结果可知,Swin Transformer – GRU 在准确率上达到最高 (95.783%),相较于 VGG16 – GRU、ResNet50 – GRU、AlexNet – GRU 提升 2.83% ~ 12.34%,召回率、精确率、F1 值分别提升 3.21% ~ 11.95%、2.92% ~ 12.51%、2.39% ~ 15.37%。此外,本研究以随机选取的不同成熟度单个果品为例,进一步对比验证不同模型对番茄成熟度识别的准确性(见表 4)。从表 4 可以看出,所有模型均可正确识别绿熟期、浅红期及红熟期番茄,这可能归因于绿熟番茄表面红色占比为 0、浅红与红熟期番茄表面红色面积较大等独特表观特征,更易于模型对番茄

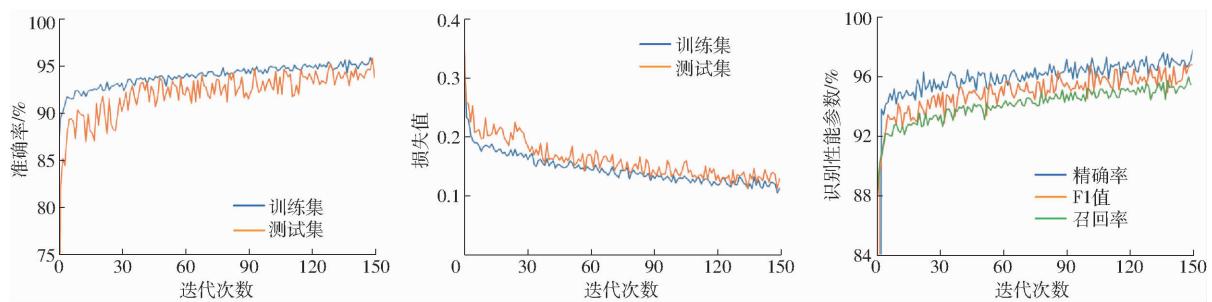


图 7 训练过程中识别性能指标变化曲线

Fig. 7 Identification performance index change curves during training

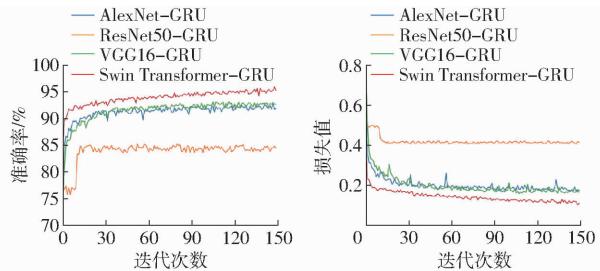


图 8 不同模型训练阶段准确率和损失值曲线

Fig. 8 Accuracy and loss curves at different stages of model training

表 3 不同模型对于番茄成熟度识别结果

Tab. 3 Recognition results of different models

for tomato maturity %

模型	准确率	召回率	精确率	F1 值
ResNet50 - GRU	85.257	84.114	83.290	83.701
VGG16 - GRU	93.142	91.241	90.545	90.891
AlexNet - GRU	92.675	90.453	91.056	90.754
Swin Transformer - GRU	95.783	94.172	93.717	93.944

表 4 不同模型对示例番茄成熟度识别结果

Tab. 4 Identification results of different models for sample tomato ripeness

示例标签	示例图像	ResNet50-GRU	VGG16-GRU	AlexNet-GRU	Swin Transformer-GRU
绿熟期 (红色占比0)		绿熟期	绿熟期	绿熟期	绿熟期
破色期 (红色占比8%)		绿熟期*	破色期	破色期	破色期
转色期 (红色占比19%)		破色期*	转色期	破色期*	转色期
粉红期 (红色占比52%)		转色期*	转色期*	粉红期	粉红期
浅红期 (红色占比87%)		浅红期	浅红期	浅红期	浅红期
红熟期 (红色占比99%)		红熟期	红熟期	红熟期	红熟期

注：* 表示识别错误。

表面颜色特征的提取,进而增大了番茄成熟度判别准确性。然而,在破色期、转色期和粉红期番茄成熟度识别方面,VGG16-GRU、ResNet50-GRU、AlexNet-GRU 却存在错误判别现象,这可能归因于破色期、转色期和粉红期番茄表面红色总占比较低且呈非均

匀分布特征,使之模型不易精准识别上述三阶段番茄表面颜色特征的微小变化。总之,本研究所提出的 Swin Transformer - GRU 模型均可正确识别不同成熟度番茄,准确性显著。

2.2 番茄成熟度预测结果分析

采用 Swin Transformer - GRU 神经网络构建番茄成熟度时序预测模型,分别取时间步为 1、3、5、9、14 进行时序预测。图 9 为模型 MAE 和 MSE 的变化曲线,由图 9 可知,模型在步长为 1 时,性能最优 (MAE 与 MSE 最低),随步长增长,模型各个指标逐渐上升,预测误差整体上升。步长为 14 时,与步长为 1 时相比 MAE、MSE、RMSE 分别提升 329.41%、112.44%、293.25%。各指标量化上升幅度显著,这可能主要由于大步长导致时间信息丢失,模拟能力下降。为检测 Swin Transformer - GRU 对番茄成熟度时序预测的效果,本实验选择 Swin Transformer - LSTM 模型、Swin Transformer - BiGRU 模型、Swin Transformer - GRU 模型作为对比(如图 10 所示),由图 10 可知,多数情况下 Swin Transformer - GRU 在 3 个评判指标上表现均优于 Swin Transformer - LSTM、Swin Transformer - BiGRU 模型,尤其是在时间步长为 1 时效果最佳,相较于其他模型,MAE、MSE、RMSE 分别降低 28.31%~30.79%、24.74%~29.46%、12.79%~30.30%。

2.3 消融实验

为进一步验证 Swin Transformer 模块、时间注意力模块对番茄成熟度时序预测的影响,本文进行消融实验,在 GRU 原模型基础上增加 Swin Transformer 模块和时间注意力机制模块,具体实验结果如表 5 所示,其中“√”表示增加此项,“×”表示未增加此项。从表 5 可以看出,单独引入 Swin Transformer 模块,MSE 降低 5.01%,MAE 降低 6.48%,RMSE 降低 8.02%,但是单独引入时间注意力机制模块时,MSE、MAE、RMSE 下降较小,分析认为 Swin Transformer 模块提高了骨干网络的特征提取能力,使得效果明显,而时间注意力机制模块可以捕捉不

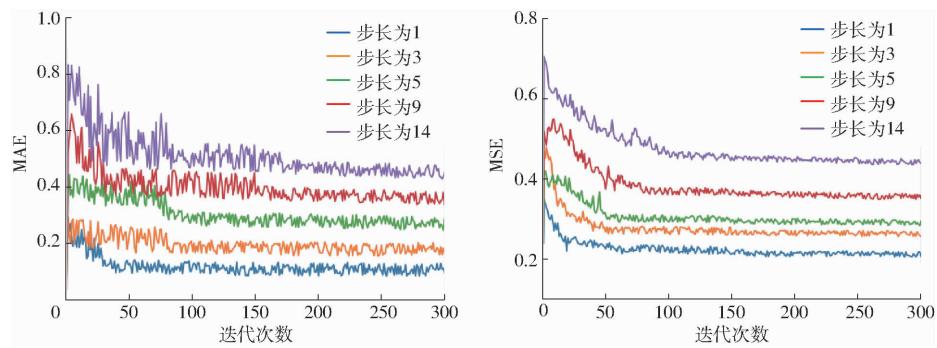


图 9 训练阶段 MAE 和 MSE 曲线

Fig. 9 MAE and MSE curves during training stages

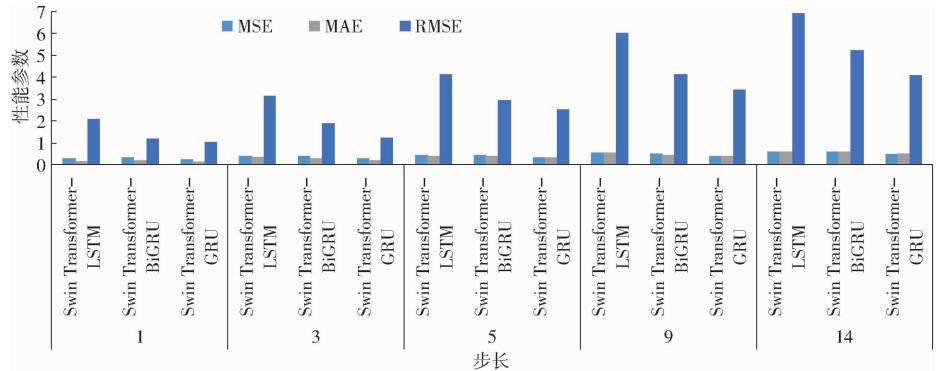


图 10 不同模型对于番茄成熟度时序预测效果

Fig. 10 Effectiveness of different models in tomato ripeness temporal forecasting

表 5 消融实验结果

Tab. 5 Results of ablation experimental model

Swin Transformer	Time self attention	MSE	MAE	RMSE
×	×	0.299	0.262	1.583
√	×	0.284	0.245	1.456
×	√	0.291	0.259	1.555
√	√	0.225	0.119	1.043

同时间步之间的关联信息,减轻特征信息传递过程中的衰减问题,因此效果提升幅度低。

3 结论

(1)以低温贮藏番茄为研究对象,在恒温恒湿箱中对其进行不同温度贮藏实验,提出一种以 Swin Transformer 为骨干网络的 GRU 番茄果实成熟度识别与时序预测模型,利用番茄表观整体红色比例构建不同成熟度番茄数据集,同时结合不同贮藏温度下番茄成熟度变化规律,并引入时间注意力机制,实现对番茄成熟度分类识别及不同温度下番茄果实成

熟度的动态预测。

(2)通过本文所构建模型与 ResNet50 - GRU 模型、VGG16 - GRU 模型、AlexNet - GRU 模型对比实验得出:本文所构建模型番茄果实成熟度识别总体准确率达 95.783%,相较于其他模型提升 2.83% ~ 12.34%。且在不同模型对示例番茄成熟度识别实验中,VGG16 - GRU、ResNet50 - GRU、AlexNet - GRU 均存在对破色期、转色期和粉红期番茄成熟度误判现象,说明 Swin Transformer 能更好地捕捉细微特征变化,保障模型对番茄成熟度识别准确性。

(3)通过本文所构建模型与 Swin Transformer - LSTM 模型、Swin Transformer - BiGRU 模型的对比实验及消融实验可知:本文所构建模型成熟度时序预测 MSE 可达 0.225,相较于其他模型降低 24.74% ~ 29.46%。引入时间注意力机制后模型 MSE 降低 20.77%,证明时间注意力机制可有效捕捉时间步关联信息,增强模型对输入序列中关键特征的学习能力,提高模型准确性。

参 考 文 献

- [1] EL-BENDARY N, EL-HARIRI E, HASSANIEN A E, et al. Using machine learning techniques for evaluating tomato ripeness [J]. Expert Systems with Applications, 2015, 42(4): 1892 ~ 1905.
- [2] CIPTANINGTYAS D, BENYAKART N, UMEHARA H, et al. Modeling the metachronous ripening pattern of mature green tomato as affected by cultivar and storage temperature[J]. Scientific Reports, 2022, 12(1): 8241.
- [3] HAN J W, ZUO M, ZHU W Y, et al. A comprehensive review of cold chain logistics for fresh agricultural products: current

- status, challenges, and future trends[J]. Trends in Food Science & Technology, 2021, 109: 536 – 551.
- [4] 王身相. 预冷对冷链过程中食品质量的保护作用[J]. 成都航空职业技术学院学报, 2015, 31(1): 45 – 47.
WANG Shenxiang. Protective effect of quality of food with pre-cooling during cold chain logistics[J]. Journal of Chengdu Aeronautic Polytechnic, 2015, 31(1): 45 – 47. (in Chinese)
- [5] 中国物流与采购联合会冷链物流专业委员会. 中国冷链物流发展报告(2022)[M]. 北京:中国财富出版社, 2022.
- [6] HUANG Y, DONG W, CHEN Y, et al. Online detection of soluble solids content and maturity of tomatoes using Vis/NIR full transmittance spectra[J]. Chemometrics and Intelligent Laboratory Systems, 2021, 210: 104243.
- [7] WAN P, TOUDESHKI A, TAN H, et al. A methodology for fresh tomato maturity detection using computer vision[J]. Computers and Electronics in Agriculture, 2018, 146: 43 – 50.
- [8] BELOUZ K, NOURANI A, ZEREG S, et al. Prediction of greenhouse tomato yield using artificial neural networks combined with sensitivity analysis[J]. Scientia Horticulturae, 2022, 293: 110666.
- [9] 张俊宁, 毕泽洋, 闫英, 等. 基于注意力机制与改进 YOLO 的温室番茄快速识别[J]. 农业机械学报, 2023, 54(5): 236 – 243.
ZHANG Junning, BI Zeyang, YAN Ying, et al. Fast recognition of greenhouse tomato targets based on attention mechanism and improved YOLO[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(5): 236 – 243. (in Chinese)
- [10] 刘芳, 刘玉坤, 林森, 等. 基于改进型 YOLO 的复杂环境下番茄果实快速识别方法[J]. 农业机械学报, 2020, 51(6): 229 – 237.
LIU Fang, LIU Yukun, LIN Sen, et al. Fast recognition method for tomatoes under complex environments based on improved YOLO[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(6): 229 – 237. (in Chinese)
- [11] 刘拥民, 刘翰林, 石婷婷, 等. 一种优化的 Swin Transformer 番茄叶片病害识别方法[J]. 中国农业大学学报, 2023, 28(4): 80 – 90.
LIU Yongmin, LIU Hanlin, SHI Tingting, et al. Tomato leaf disease recognition based on an optimized Swin Transformer[J]. Journal of China Agricultural University, 2023, 28(4): 80 – 90. (in Chinese)
- [12] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, et al. An image is worth 16×16 words: transformers for image recognition at scale[J]. arXiv Preprint, arXiv: 2010.11929, 2020.
- [13] 李翔, 张涛, 张哲, 等. Transformer 在计算机视觉领域的研究综述[J]. 计算机工程与应用, 2023, 59(1): 1 – 14.
LI Xiang, ZHANG Tao, ZHANG Zhe, et al. Survey of Transformer research in computer vision[J]. Computer Engineering and Applications, 2023, 59(1): 1 – 14. (in Chinese)
- [14] 石庆兰, 束金阳, 李道亮, 等. 基于 BiLSTM – GRU 融合网络的稻虾养殖溶解氧含量预测[J]. 农业机械学报, 2023, 54(10): 364 – 370.
SHI Qinglan, SHU Jinyang, LI Daoliang, et al. Dissolved oxygen prediction in rice and shrimp culture based on BiLSTM – GRU fusion neural networks[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(10): 364 – 370. (in Chinese)
- [15] WANG J, WANG P, TIAN H, et al. A deep learning framework combining CNN and GRU for improving wheat yield estimates using time series remotely sensed multi-variables[J]. Computers and Electronics in Agriculture, 2023, 206: 107705.
- [16] HE Z, JIANG T, JIANG Y, et al. Gated recurrent unit models outperform other machine learning models in prediction of minimum temperature in greenhouse based on local weather data[J]. Computers and Electronics in Agriculture, 2022, 202: 107416.
- [17] 赫晓慧, 罗浩田, 乔梦佳, 等. 基于 CNN – RNN 网络的中国冬小麦估产[J]. 农业工程学报, 2021, 37(17): 124 – 132.
HE Xiaohui, LUO Haotian, QIAN Mengjia, et al. Yield estimation of winter wheat in China based on CNN – RNN network [J]. Transactions of the CSAE, 2021, 37(17): 124 – 132. (in Chinese)
- [18] 李建, 杜建强, 朱彦陈, 等. 基于 Transformer 的目标检测算法综述[J]. 计算机工程与应用, 2023, 59(10): 48 – 64.
LI Jian, DU Jianqiang, ZHU Yanchen, et al. Survey of Transformer-based object detection algorithms [J]. Computer Engineering and Applications, 2023, 59(10): 48 – 64. (in Chinese)
- [19] 杨锋勇, 王赫, 杨庆江, 等. 融合 YOLOv5s 与 Swin Transformer 的森林火灾检测[J]. 高师理科学刊, 2023, 43(6): 37 – 41.
YANG Fengyong, WANG He, YANG Qingjiang, et al. Fusion of YOLOv5s and Swin Transformer for forest fire detection[J]. Journal of Science of Teachers' College and University, 2023, 43(6): 37 – 41. (in Chinese)
- [20] 李文忠, 刘成帅, 邬强, 等. GRU – Transformer 洪水预报模型构建与应用[J]. 中国农村水利水电, 2023(11): 35 – 44.
LI Wenzhong, LIU Chengshuai, WU Qiang, et al. Construction and application of GRU – Transformer flood forecasting model [J]. China Rural Water and Hydropower, 2023(11): 35 – 44. (in Chinese)
- [21] 祁柏林, 赵娅倩, 魏建勋, 等. 基于 ResGCN – GRU 的大气污染风险源识别[J]. 计算机系统应用, 2023, 32(6): 301 – 307.
QI Bolin, ZHAO Yaqian, WEI Jianxun, et al. Identification of air pollution risk sources based on ResGCN – GRU [J]. Computer Systems and Applications, 2023, 32(6): 301 – 307. (in Chinese)
- [22] VASWANI A, SHAZEEB N, PARMAR N, et al. Attention is all you need[J]. Advances in Neural Information Processing Systems, 2017, 30: 5998 – 6008.
- [23] LAI G, CHANG W C, YANG Y, et al. Modeling long- and short-term temporal patterns with deep neural networks[C] // The 41st International ACM SIGIR Conference on Research & Development in Information Retrieval, 2018: 95 – 104.