

基于改进鲸鱼优化 CNN 的红富士苹果 外观分级方法

A red Fuji apple appearance grading method based on improved
whale optimization algorithm and CNN

刘素娇¹ 卢明星¹ 王春芳² 赵梓枫³ 刘 怡³

LIU Sujiao¹ LU Mingxing¹ WANG Chunfang² ZHAO Zifeng³ LIU Yi³

(1. 河南护理职业学院, 河南 安阳 455000; 2. 河南科技大学, 河南 洛阳 471000;

3. 河南农业大学, 河南 郑州 450002)

(1. Henan Vocational College of Nursing, Anyang, Henan 455000, China;

2. Henan University of Science and Technology, Luoyang, Henan 471000, China;

3. Henan Agricultural University, Zhengzhou, Henan 450002, China)

摘要:目的:有效提升机器视觉技术对红富士苹果外观品质分级的准确率。方法:建立不同外观品质等级的红富士苹果图像数据库,通过对数据库图像进行图像增强预处理,以提高模型训练效果和泛化能力。构造改进鲸鱼优化 CNN 模型,采用加权灰色关联度法压缩 CNN 卷积规模,以降低特征间的冗余度干扰和提高模型的运算速度;利用改进的鲸鱼优化算法对模型超参数进行优化配置,以降低超参数配置不当对模型分级结果的影响。结果:试验所提分级方法准确率更高,分级精确度、灵敏度分别提高了 2.05%, 2.46%。结论:试验方法能够有效实现对红富士苹果的外观分级。

关键词: 苹果; 分级; 深度学习; 机器视觉; 准确率

Abstract: Objective: In order to improve the accuracy of machine vision technology in grading the appearance quality of red Fuji apples, a red Fuji apple appearance grading method based on improved whale optimization algorithm (WOA) and CNN is proposed. **Methods:** A red Fuji apple image database with different appearance quality levels was established, and the database images were preprocessed so as to improve the training effect and generalization ability of the model. The improved CNN-LSTM was designed as the weighted grey correlation method was used to compress the CNN convolution scale, in order to reduce redundant interference between features and improve the

computational speed of the model. The improved whale optimization algorithm was used to optimize the hyperparameters configuration of CNN-LSTM, effectively reducing the impact of improper hyperparameter configuration on model classification results. **Results:** The simulation results showed that the proposed classification method had a higher accuracy, with classification accuracy and sensitivity improved by about 2.05% and 2.46%. **Conclusion:** The proposed method can effectively achieve the appearance grading of red Fuji apples.

Keywords: apple; grading; deep learning; machine vision; accuracy

开展苹果精细化分级分选有利于延伸苹果价值链,有效解决苹果质优价不高的难题^[1]。近年来,机器视觉技术在水果分级、品质检测等方面取得了长足进展^[2-4],克服了传统人工苹果分级效率低、主观性大、成本高等缺点,已成为苹果分级分类的主要方法之一^[5]。

提升图像检测准确率和检测速度是机器视觉技术成功应用于水果分级的关键^[6]。深度卷积神经网络能够高效率提取图像高维特征,这使得苹果快速、高准确率分级分选成为可能^[7]。何进荣等^[1]建立了一种多卷积神经网络融合 DXNet 苹果品质分级模型,该模型具有较高的分级准确率,但其卷积核规模较大。张立杰等^[5]提出了一种基于改进 SSD 卷积神经网络的水果分级方法,单幅图像检测时间为 5.71 ms,但该方法主要利用苹果顶部图像信息,苹果分级准确率需进一步研究。薛勇等^[8]利用 GoogLeNet 网络模型对苹果缺陷进行在线检测,测试样本识别准确率为 91.91%,但分级结果的好坏取决于网络

基金项目: 河南省教育厅高等学校青年骨干教师培养计划资助项目(编号:2016GGJS-285)

作者简介: 刘素娇(1982—),女,河南护理职业学院实验师,硕士。
E-mail: sujiao0577@163.com

收稿日期: 2023-11-19 **改回日期:** 2024-04-15


模型超参数配置情况以及提取特征之间的冗余度。

研究拟提出一种基于改进鲸鱼优化 CNN 的红富士苹果外观分级方法,设计改进的鲸鱼优化算法 (whale optimization algorithm, WOA)^[9]对 CNN 网络模型超参数进行优化配置,采用加权灰色关联度法压缩 CNN 卷积规模,以降低超参数配置不当和特征间冗余度对模型分级结果的影响,并通过仿真实验验证所提方法的有效性,旨在为红富士苹果外观分级提供一种高效可行的解决方案。

1 材料与模型

1.1 图像采集系统

建立如图 1 所示的苹果图像采集系统。系统硬件包括传送带、图像采集暗箱、光电传感器、计算机等。在图像采集暗箱内放置 3 个工业线阵彩色 CCD 相机,每个 CCD 相机配置 1 个补光灯。当苹果到达光电传感器所处位置时,触发相机拍照,分别获取苹果顶部、侧面图像信息,同时记录拍摄时间。试验训练阶段,PC 计算机接收 3 个 CCD 相机传输的图片信息,建立图像训练数据库。在 MATLAB 软件平台上,利用图像训练数据库对 CNN 模型进行训练,得到苹果外观分级模型。苹果实时分级阶段,PC 计算机接收到苹果实时图像后,利用 CNN 模型确定苹果外观品质等级。



1. 传送带 2. 苹果托 3. 光电传感器 4. 图像采集暗箱 5. 计算机 6. 工业摄像机

图 1 苹果图像采集示意图

Figure 1 Schematic diagram of apple image acquisition

1.2 图像预处理与图像数据库

增加训练样本数量能够提升模型训练效果和泛化能力^[10]。因此,对 CCD 相机拍摄图像进行图像增强预处理,即采用旋转、平移、镜像等传统图像处理方法^[11]对图像进行扩增(每种方法扩增 2 倍原始图像数量),从而极大地扩展了图像抽样的覆盖度,有利于提高模型准确率。对于传送带上的某个苹果,CCD 相机共拍摄 3 张图像,经图像预处理后共得到 21 张图像。为进一步分析图像尺寸大小对苹果分级精度、效率的影响,将预处理后的图像规范化后得到 32 像素×32 像素、64 像素×64 像素、224 像素×224 像素的图像。

以红富士苹果为例,参照文献[1]提出的苹果外观五等级分级标准,在大型苹果批发市场采购 5 000 个红富士苹果,每个等级各 1 000 个,可以得到 15 000 张原始 CCD 相机图像。按照 7:2:1 的比例将原始图像划分为训练

样本、验证样本和测试样本,不同样本中各个等级苹果原始图像数量相同。对 10 500 张训练样本进行图像增强和规范化处理,分别得到 32 像素×32 像素、64 像素×64 像素、224 像素×224 像素的图像各 73 500 张。

2 红富士苹果外观分级试验

2.1 CNN 模型

卷积神经网络(CNN)主要由多个卷积块和全连接层组成^[12-13],卷积块主要包括卷积层、激活函数、批量归一化和池化层。其中,卷积层分块提取输入数据的特征,该计算过程可以描述为:

$$a^l = f(a^{l-1} \otimes W^l + b^l), \quad (1)$$

式中:

l ——当前网络层数;

$f(\cdot)$ ——激活函数;

$\otimes$ ——卷积运算;

a^l, a^{l-1} ——本层网络输出、输入;

W^l ——本层网络权重;

b^l ——偏置。

池化层在保持卷积层输出特征数量不变的基础上,对特征进行降维处理,以提升网络鲁棒性。平均值池化 y_{ave} 、最大值池化 y_{max} 是常用的池化方式。全连接层由多个隐含层和输出层构成,隐含层将提取特征抽象组合后映射到样本空间。输出层(分类层)一般采用 Softmax 函数来判定所属分类概率,当损失函数 $L(\cdot)$ 取最小值时,得到最终分类结果。隐含层、输出层和损失函数计算式为:

$$a^l = f(W^l \times a^{l-1} + b^l), \quad (2)$$

$$y = F(W^l \times a^{l-1} + b^l), \quad (3)$$

$$L[F(x_i), y_i] = -\frac{1}{n} \sum_{i=1}^n [y_i \ln F(x_i) + (1 - y_i) \ln(1 - y_i)], \quad (4)$$

式中:

y ——所属分类概率值;

$F(\cdot)$ ——输出层激活函数;

(x_i, y_i) ——第 i 个样本;

n ——样本规模。

如图 2 所示,试验设计的 CNN 模型包括 2 个卷积块和 1 个全连接层,其中,在卷积块中引入加权灰色关联度




图 2 试验设计 CNN 模型

Figure 2 CNN model designed

法来压缩卷积规模,以降低特征间的冗余度干扰和提高模型的运算速度,并采用改进的鲸鱼优化算法对模型超参数进行优化配置,以降低超参数配置不当对模型分级结果的影响。

2.2 卷积核压缩

通过设计加权灰色关联度法来度量卷积核特征间的加权关联度,依规则压缩加权关联度高的卷积核,从而降低卷积核规模。具体实现过程为:

Step1: 对于第 i 个训练样本 (x_i, y_i) ($i=1, \dots, n$), 经第 l 层网络卷积操作后得到特征向量 $(\tau_{1,1}^l, \dots, \tau_{i,j}^l, \dots, \tau_{n,m}^l)$ (m 为 l 层网络卷积核数, $\tau_{i,j}^l$ 为第 j 个卷积核对应提取特征值)。 n 个训练样本卷积后得到特征序列矩阵 $\mathbf{A}_{n \times m} = [\tau_{i,j}^l]_{n \times m}$:

$$\mathbf{A}_{n \times m} = \begin{bmatrix} \tau_{1,1}^l & \tau_{1,2}^l & \dots & \tau_{1,m}^l \\ \tau_{2,1}^l & \tau_{2,2}^l & \dots & \tau_{2,m}^l \\ \vdots & \vdots & \ddots & \vdots \\ \tau_{n,1}^l & \tau_{n,2}^l & \dots & \tau_{n,m}^l \end{bmatrix} \quad (5)$$

Step2: 按式(6)对 $\mathbf{A}_{n \times m}$ 进行归一化处理,得到归一化矩阵 $\mathbf{B}_{n \times m} = [b_{ij}]_{n \times m}$ 。

$$b_{ij} = \frac{\tau_{i,j}^l - \min(\tau_{1,j}^l, \tau_{2,j}^l, \dots, \tau_{n,j}^l)}{\max(\tau_{1,j}^l, \tau_{2,j}^l, \dots, \tau_{n,j}^l) - \min(\tau_{1,j}^l, \tau_{2,j}^l, \dots, \tau_{n,j}^l)}, \quad (6)$$

$$b_{ij} = \begin{cases} a_{ij} & a_{ij} > 0 \\ -a_{ij} & a_{ij} < 0 \end{cases}$$

Step3: 根据式(7),从 $\mathbf{A}_{n \times m}$ 中选取确定最大特征序列 $Z = (z_1, \dots, z_j, \dots, z_m)$ 。利用 $Z = (z_1, \dots, z_j, \dots, z_m)$, 结合式(8)计算得到关联系数矩阵 $\mathbf{C}_{n \times m} = [c_{ij}]_{n \times m}$ 。

$$z_j = \max(b_{1j}, b_{2j}, \dots, b_{nj}), \quad (7)$$

$$c_{ij} = (\min_j |\tau_{i,j}^l - z_j| + \rho \times \max_j |\tau_{i,j}^l - z_j|) / (|\tau_{i,j}^l - z_j| + \rho \times \max_j |\tau_{i,j}^l - z_j|), \quad (8)$$

式中:

ρ ——分析系数,取 $\rho=0.5$ 。

Step4: 为进一步体现不同特征权重差异,根据式(9)和式(10)计算 $\mathbf{A}_{n \times m}$ 中特征 $\tau_{i,j}^l$ 的比重值 $\tau_{i,j}^l$ 、熵值 h_j , 并根据式(11)计算得到特征权重 ω_j 。

$$\tau_{i,j}^l = \tau_{i,j}^l / \left(\sum_{i=1}^n \tau_{i,j}^l \right), \quad (9)$$

$$h_j = \left(- \sum_{i=1}^n \tau_{i,j}^l \ln \tau_{i,j}^l \right) / \ln m, \quad (10)$$

$$\omega_j = (1 - h_j) / \left(\sum_{j=1}^m (1 - h_j) \right). \quad (11)$$

Step5: 结合 $\mathbf{C}_{n \times m} = [c_{ij}]_{n \times m}$ 和特征权重 ω_j 得到加权关联系数矩阵 $\mathbf{D}_{n \times m} = [d_{ij}]_{n \times m}$ 。 d_{ij} 取值越大,表明第 i 个卷积得到的特征与第 j 个卷积得到的特征越相似。

$$d_{ij} = \begin{cases} 1, & i=j \\ c_{ij} \times \omega_j, & j > i \\ d_{ji}, & j < i \end{cases} \quad (12)$$

$$\mathbf{D}_{n \times m} = \begin{bmatrix} 1 & d_{12} & \dots & d_{1m} \\ & 1 & \dots & d_{2m} \\ & & \ddots & \vdots \\ & & & 1 \end{bmatrix}. \quad (13)$$

Step6: 设定压缩加权阈值 $\omega_{\min}$, 对于第 i 个卷积核, 统计其加权关联系数向量 $(d_{i1}, \dots, d_{im})$ 中 $> \omega_{\min}$ 的个数, 并标记为 λ_i 。设定卷积核压缩阈值 $\lambda_{\min}$ 。若 $\lambda_i \geq \lambda_{\min}$, 则删除卷积核 i , 否则保留。

2.3 模型超参数配置

2.3.1 改进鲸鱼优化算法 (IWOA) 鲸鱼优化算法 (WOA) 模拟座头鲸狩猎行为, 设计了包围猎物、泡泡网攻击、随机游动 3 种进化方式, 并通过系数向量 θ 和随机数 γ 的大小来确定鲸鱼个体具体更新方式。 t 时刻, 对于鲸鱼个体 $X(t)$, 其更新式为:

$$\theta = 4(1 - t/T_{\max})r_1 - 2(1 - t/T_{\max}), \quad (14)$$

$$X(t) \leftarrow X(t) + \theta \cdot \gamma \cdot (X_{\text{rand}}(t) - X(t))$$

$$\begin{cases} |X^*(t) - X(t)| \times e^{g \times s} \cos(2\pi \times s) + X^*(t), & \gamma \geq 0.5 \\ X^*(t) - \theta \times |2r_2 \times X^*(t) - X(t)|, & |\theta| < 1 \text{ and } \gamma < 0.5 \\ X_{\text{rand}}(t) - \theta \times |2r_2 \times X_{\text{rand}}(t) - X(t)|, & |\theta| \geq 1 \text{ and } \gamma < 0.5 \end{cases} \quad (15)$$

式中:

$X^*(t)$ ——种群最优解;

r_1, r_2 —— $[0, 1]$ 间随机向量;

g ——常数;

s —— $[-1, 1]$ 间随机数;

$X_{\text{rand}}(t)$ ——种群内随机选择的一个个体;

$T_{\max}$ ——算法最大迭代次数。

从 WOA 更新过程可知, 其属于全局搜索范畴, 当求解复杂多局部极值优化问题时, 还存在收敛精度不高、容易陷入局部最优等缺陷^[14-15]。

因此, 设计改进鲸鱼优化算法 (IWOA)。

(1) 增加局部搜索机制。利用 DPC 算法^[16] 对种群进行聚类分析。DPC 算法对大多数数据都有很好的聚类效果^[16], 对于种群个体 $X_i(t)$, DPC 定义局部密度 ρ 和最近点距离 δ :

$$\rho_i = \sum_j \chi(d_{ij} - d_c), \chi(x) = \begin{cases} 1, & x < 0 \\ 0, & x \geq 0 \end{cases}, \delta_i = \min_{i, \rho_j > \rho_i} d_{ij}, \quad (16)$$

式中:

d_c ——截断距离;

d_{ij} —— $X_i(t)$ 与 $X_j(t)$ 间的距离。

DPC 选取 $\gamma = \rho \times \delta$ 取值较大的鲸鱼个体为聚类中心, 通过描绘 $\rho - \delta$ 决策图^[17] 实现对种群聚类分析, 从而将种群划分为多个子种群, 每个子种群独立迭代进化 $t_{\max}$ 次后, 所有子种群重新混合, 执行一次全局进化操作。

(2)自适应学习与 $X^*(t)$ 极限进化。基本 WOA 在进化时,个体 $X(t)$ 直接选取 $X^*(t)$ 、 $X_{\text{rand}}(t)$ 全部信息进行学习,增加算法发生“早熟”的概率,为此,引入自适应学习机制,即个体 $X(t)$ 自适应选取 $X^*(t)$ 、 $X_{\text{rand}}(t)$ 部分信息进行学习,自适应学习系数 ω 为:

$$\omega = \omega_{\max} - (\omega_{\max} - \omega_{\min}) \times [1 - 1/(1 + e^{-2t/T_{\max}})], \quad (17)$$

式中:

$\omega_{\max}$ 、 $\omega_{\min}$ ——最大、最小值。

对于种群最优解 $X^*(t)$,设计自适应极限进化操作,即随机选取 $X^*(t)$ 内 $[\omega \times N]$ 个编码位进行取反操作(N 为优化问题维度)。

$$x_j(t) = x_{j,\min}(t) + \omega \times [x_{j,\max}(t) - x_j(t)], \quad (18)$$

式中:

$x_j(t)$ —— $X^*(t)$ 中被选取的第 j 个取反操作编码位;

$x_{j,\max}$ 、 $x_{j,\min}$ ——第 j 个编码位对应的最大、最小值。

由式(16)~式(18)可知,通过引入局部搜索、自适应学习和 $X^*(t)$ 极限进化机制,使得 IWOA 能够在更深的空间内进行搜索,提高了算法复杂优化问题求解能力。

2.3.2 IWOA 优化配置模型超参数 试验设计的 CNN 卷积神经网络涉及的超参数有卷积核数目 m_1 、 m_2 ,压缩加权阈值 $\omega_{\min}$ 、卷积核压缩阈值 $\lambda_{\min}$,隐含层神经元数 m_3 、 m_4 ,隐含层权重矩阵 $W_{m'_2 \times m_3}$ 、 $W_{m_3 \times m_4}$ (m'_2 为 m_2 经过压缩后的特征数),隐含层神经元中心 $\Theta_1 = (c_1^1, \dots, c_{m_3}^1)$ 、 $\Theta_2 = (c_1^2, \dots, c_{m_4}^2)$ 。利用 IWOA 对超参数进行优化配置,个体 $X(t)$ 编码和目标函数 $U[X(t)]$ 分别定义为:

$$X(t) = [m_1, m_2, m_3, m_4, \omega_{\min}, \lambda_{\min}, W_{m'_2 \times m_3}, W_{m_3 \times m_4}, \Theta_1, \Theta_2], \quad (19)$$

$$U[X(t)] = \min \frac{1}{n} \sum_{i=1}^n \|y - y_{\text{per}}\|, \quad (20)$$

式中:

y 、 y_{per} ——实测值和网络预测值。

其中, y 采用专家评分法^[18]对个体训练样本外观品质进行赋分。图 3 为试验所提红富士苹果外观分级方法实现流程图。

3 仿真试验

3.1 验证实验

采用 32 像素 $\times$ 32 像素、64 像素 $\times$ 64 像素、224 像素 $\times$ 224 像素的 73 500 张图像(每个外观等级各 14 700 张)对所提 CNN 模型进行训练,训练批量大小设定为 12,卷积核大小设定为 3 $\times$ 3、5 $\times$ 5,卷积层激活函数选取为 sigmoid 函数,池化方式设定为最大值池化 $y_{\max}$,输出层 softmax 函数。IWOA 参数设置:种群规模 $Q = 300$ 、 $g = 1$ 、 $T_{\max} = 500$ 、 $t_{\max} = 20$ 、 $\omega_{\max} = 0.85$ 、 $\omega_{\min} = 0.15$ 。采用 IWOA 和卷积核压缩操作对 CNN 模型进行优化,图 4 为 IWOA 与 WOA、CML-WOA^[15] 函数收敛曲线,表 1 为不同像素下 CNN 模型优化结果。利用优化后的 CNN 神经网络对 1 000 个验证苹果进行外观等级验证实验(每个等级苹果各 200 个),表 2 为不同像素下不同等级苹果外观等级识别正确率结果。

由表 1、表 2 可知,相比于 WOA、CML-WOA,IWOA 具有更高的收敛精度;IWOA 能够得到合理的 CNN 网络超参数,卷积核压缩操作进一步降低了卷积核规模。对于不同像素下的苹果外观等级识别正确率,所提方法识别正确率均 $> 99.0\%$,说明采用 IWOA 以及加权灰色关联度法对 CNN 神经网络结构进行优化配置,进一步提升了模型识别能力,使其能够有效应用于红富士苹果外观等级识别应用。




图 3 红富士苹果外观分级方法实现流程图

Figure 3 Implementation flowchart of the red Fuji apple appearance grading method




图 4 IWOA、WOA、CML-WOA 函数收敛曲线

Figure 4 Convergence curves of IWOA, WOA, CML-WOA

表 1 不同像素下 CNN 模型优化结果

Table 1 Optimization results of CNN models under different pixels

组别	m_1	m_2	m_3	m_4	m'_1	m'_2	$\omega_{\min}$	$\lambda_{\min}$
32 像素×32 像素	16	44	138	64	10	36	3	7
64 像素×64 像素	22	58	146	72	17	45	7	13
224 像素×224 像素	44	68	182	88	34	51	11	19

表 2 不同像素下不同等级苹果外观识别正确率

Table 2 Accuracy of apple appearance recognition at different pixels and grades %

组别	苹果外观等级				
	1 级	2 级	3 级	4 级	5 级
32 像素×32 像素	99.3	99.2	99.0	99.4	99.2
64 像素×64 像素	99.6	99.4	99.3	99.6	99.5
224 像素×224 像素	99.7	99.8	99.8	99.7	99.9

3.2 对比试验

为进一步分析所提方法的性能,采用 YOLO-v7 网络^[6]、改进 CNN 神经网络(ICNN)^[3]、改进的残差神经网络(IResNet)^[19]对 500 个测试苹果进行测试(每个等级苹果各 100 个),选取文献[3]提出的灵敏度 e_1 、准确度 e_2 、精确度 e_3 、 F_1 分数以及检测时间 t_1 为评价指标,表 3 为不同像素下 4 种识别分级方法评价指标对比结果。

由表3可知,试验所提方法对32像素×32像素下苹

表 3 不同像素下 4 种识别分级方法评价指标对比结果

Table 3 Comparison results of evaluation indicators for 4 recognition and grading methods under different pixels

方法	32 像素×32 像素					64 像素×64 像素					224 像素×224 像素				
	$e_1/\%$	$e_2/\%$	$e_3/\%$	F_1 分数	t_1/ms	$e_1/\%$	$e_2/\%$	$e_3/\%$	F_1 分数	t_1/ms	$e_1/\%$	$e_2/\%$	$e_3/\%$	F_1 分数	t_1/ms
YOLO-v7	96.4	96.2	95.9	96.1	11.4	97.2	97.7	97.6	97.4	22.3	98.3	98.2	98.4	98.1	30.8
ICNN	97.3	97.1	96.9	97.4	20.1	98.4	98.2	98.6	98.5	31.4	99.1	98.9	99.0	99.2	37.1
IResNet	98.4	98.6	98.5	98.2	27.4	99.1	98.9	99.2	99.0	44.8	99.4	99.6	99.5	99.3	55.1
试验方法	99.2	99.4	99.3	99.4	9.6	99.6	99.6	99.7	99.4	14.5	99.7	99.8	99.9	99.6	24.6

果外观分级的灵敏度、准确度、精确度、 F_1 分数指标分别达到 99.2%,99.4%,99.3%,99.4%,较其他 3 种算法分别最大提高了 1.51%,1.72%,1.81%,1.21%;64 像素×64 像素下苹果外观分级的灵敏度、准确度、精确度、 F_1 分数指标分别达到 99.6%,99.6%,99.7%,99.4%,较其他 3 种算法分别最大提高了 2.46%,2.47%,2.05%,1.84%;224 像素×224 像素下苹果外观分级的灵敏度、准确度、精确度、 F_1 分数指标分别达到 99.7%,99.8%,99.9%,99.6%,较其他 3 种算法分别最大提高了 1.42%,1.63%,1.50%,1.53%。随着像素的增加,单幅图片检测时间随之增加,但试验所提方法的检测时间小于其他 3 种算法。

综上,试验所提方法在各类评价指标上具有较为突出的优势,能够快速、准确地给出苹果外观等级分类结果,且对于较低分辨率图像仍具有较高的分级准确率。

4 结论

研究提出了一种基于改进鲸鱼优化 CNN 的红富士苹果外观分级方法,通过引入加权灰色关联度法和改进鲸鱼优化算法,在降低特征间冗余度和超参数配置不当对模型分级结果影响的同时,提高了分级检测运算速度。结果表明,与其他方法相比,试验所提方法具有更高的识别精度和识别速度,分级精确度和灵敏度分别提高了

2.05%, 2.46%, 分级检测时间最大降低了约 55.4%。后续将围绕提升所提方法处理效率上开展深入研究, 使其更适用于红富士苹果外观分级实际工程应用。

参考文献

- [1] 何进荣, 石延新, 刘斌, 等. 基于 DXNet 模型的富士苹果外部品质分级方法研究[J]. 农业机械学报, 2021, 52(7): 379-385.
HE J R, SHI Y X, LIU B, et al. External quality grading method of Fuji apple based on deep learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(7): 379-385.
- [2] 刘佳浩, 高军伟, 张炳星, 等. 基于机器视觉的水果分级系统[J]. 食品与机械, 2023, 39(6): 112-118.
LIU J H, GAO J W, ZHANG B X, et al. Design of fruit grading system based on machine vision[J]. Food & Machinery, 2023, 39(6): 112-118.
- [3] 张效禹, 黄国言, 杨永涛, 等. 基于改进 CNN 的草莓成熟度分类方法[J]. 食品与机械, 2023, 39(10): 130-137.
ZHANG X Y, HUANG G Y, YANG Y T, et al. A method for strawberry ripeness classification method based on improved CNN[J]. Food & Machinery, 2023, 39(10): 130-137.
- [4] 吕金锐, 付燕, 倪美玉, 等. 基于改进 YOLO v4 模型的番茄成熟度检测方法[J]. 食品与机械, 2023, 39(9): 134-139.
LU J R, FU Y, NI M Y, et al. Research on tomato maturity detection method based on improved YOLOv4 model [J]. Food & Machinery, 2023, 39(9): 134-139.
- [5] 张立杰, 周舒骅, 李娜, 等. 基于改进 SSD 卷积神经网络的苹果定位与分级方法[J]. 农业机械学报, 2023, 54(6): 223-232.
ZHANG L J, ZHOU S H, LI N, et al. Apple location and classification based on improved SSD convolutional neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(6): 223-232.
- [6] 张灵枝, 黄艳, 于英杰, 等. 基于近红外光谱技术的六大茶类快速识别[J]. 食品与生物技术学报, 2024, 43(1): 48-59.
ZHANG L Z, HUANG Y, YU Y J, et al. Rapid identification of six major tea categories based on near-infrared spectroscopy[J]. Journal of Food Science and Biotechnology, 2024, 43(1): 48-59.
- [7] CHAO X F, SUN G Y, ZHAO H K, et al. Identification of apple tree leaf diseases based on deep learning models[J]. Symmetry, 2020, 12(7): 1 065.
- [8] 薛勇, 王立扬, 张瑜, 等. 基于 GoogLeNet 深度迁移学习的苹果缺陷检测方法[J]. 农业机械学报, 2020, 51(7): 30-35.
XUE Y, WANG L Y, ZHANG Y, et al. Defect detection method of apples based on GoogLeNet deep transfer learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(7): 30-35.
- [9] MIRJALILI S, LEWIS A. The whale optimization algorithm[J]. Advances in Engineering Software, 2016, 95: 51-67.
- [10] 何文斌, 魏爱云, 明五一, 等. 基于机器视觉的水果品质检测综述[J]. 计算机工程与应用, 2020, 56(11): 10-16.
HE W B, WEI A Y, MING W Y, et al. Survey of fruit quality detection based on machine vision[J]. Computer Engineering and Applications, 2020, 56(11): 10-16.
- [11] 张忠志, 薛欢庆, 范广玲. 基于改进卷积神经网络的红枣缺陷识别[J]. 食品与机械, 2021, 37(8): 158-162, 192.
ZHANG Z Z, XUE H Q, FAN G L. Research on jujube defect recognition method based on improved convolution neural network[J]. Food & Machinery, 2021, 37(8): 158-162, 192.
- [12] 武东辉, 许静, 陈继斌, 等. 基于融合注意力机制与 CNN-LSTM 的人体行为识别算法[J]. 科学技术与工程, 2023, 23(2): 681-689.
WU D H, XU J, CHEN J B, et al. Human activity recognition algorithm based on CNN-LSTM with attention mechanism [J]. Science Technology and Engineering, 2023, 23(2): 681-689.
- [13] 杨保军, 梁琪, 宋雪梅. 基于计算机虚拟技术研究牦牛乳硬质干酪苦味肽的抑菌活性差异[J]. 食品与生物技术学报, 2021, 40(12): 75-87.
YANG B J, LIANG Q, SONG X M. Study on difference of antibacterial activity of bitter peptide from yak milk hard cheese based on computer virtual technology[J]. Journal of Food Science and Biotechnology, 2021, 40(12): 75-87.
- [14] LI M D, XU G H, FU Y W, et al. Improved whale optimization algorithm based on variable spiral position update strategy and adaptive inertia weight[J]. Journal of Intelligent & Fuzzy Systems: Applications in Engineering and Technology, 2022, 42(3): 1 501-1 517.
- [15] 汤安迪, 韩统, 徐登武, 等. 混沌多精英鲸鱼优化算法[J]. 北京航空航天大学学报, 2021, 47(7): 1 481-1 494.
TANG A D, HAN T, XU D W, et al. Chaotic multi-leader whale optimization algorithm [J]. Journal of Beijing University Aeronautics and Astronautics, 2021, 47(7): 1 481-1 494.
- [16] RODRIGUEZ A, LAIO A. Clustering by fast search and find of density peaks[J]. Science, 2014, 344(6 191): 1 492-1 496.
- [17] 陈叶旺, 申莲莲, 钟才明, 等. 密度峰值聚类算法综述[J]. 计算机研究与发展, 2020, 57(2): 378-394.
CHEN Y W, SHEN L L, ZHONG C M, et al. Survey on density peak clustering algorithm[J]. Journal of Computer Research and Development, 2020, 57(2): 378-394.
- [18] 王晓彤. 基于 AHP 及专家打分法的大跨度隧道风险评估[J]. 现代隧道技术, 2020, 57(S1): 233-240.
WANG X X. Risk assessment of the large-span tunnel based on AHP and expert scoring method [J]. Modern Tunnelling Technology, 2020, 57(S1): 233-240.
- [19] 万薇, 卜莹雪, 王祥, 等. 基于改进 ResNet 模型的食品新鲜度识别方法[J]. 食品与机械, 2023, 39(9): 123-127.
WAN W, BU Y X, WANG X, et al. Food freshness recognition method based on improved ResNet model[J]. Food & Machinery, 2023, 39(9): 123-127.