# 基于 CNN 和 XgBoost 的香蕉成熟度判别 Banana ripeness determination based on CNN and XgBoost

韩雪1 张磊2 赵雅菲3 王聪4

HAN Xue<sup>1</sup> ZHANG Lei<sup>2</sup> ZHAO Yafei<sup>3</sup> WANG Cong<sup>4</sup>

(1. 徐州开放大学,江苏 徐州 221000;2. 河南师范大学,河南 新乡 453007;

3. 开封大学,河南开封 475004;4. 江苏理工学院,江苏常州 213001)

(1. Xuzhou Open University, Xuzhou, Jiangsu 221000, China; 2. Henan Normal University,

Xinxiang, Henan 453007, China; 3. Kaifeng University, Kaifeng, Henan 475004, China;

4. Jiangsu University of Technology, Changzhou, Jiangsu 213001, China)

摘要:目的:提高香蕉成熟度的判别准确率。方法:基于 卷积神经网络和极限梯度提升算法建立香蕉成熟度的判 别方法。先通过卷积神经网络提取香蕉图像特征,并采 用全连接层网络和线性判别分析方法精简香蕉图像特 征;通过贝叶斯优化算法优化极限梯度提升算法超参数; 将简化后的香蕉图像特征输入极限梯度提升算法,通过 极限梯度提升算法对香蕉成熟度进行判别。结果:所提 方法对香蕉成熟度的判别准确度为 91.25%;与已有方法 相比,所提方法对小数据量香蕉的成熟度判别准确率明 显提高。结论:该方法可实现被测香蕉成熟度的准确判 别,有助于仓库经理、出口商实时监测香蕉的成熟度 状况。

关键词:香蕉;成熟度判别;卷积神经网络;极限梯度提升 算法;小数据量

**Abstract: Objective:** Improve the identification accuracy of banana ripeness. **Methods:** A novel method was established to identify banana ripeness based on CNN and XgBoost. Firstly, convolutional neural network was used to extract banana image features, and full-connected layer network and linear discriminant analysis were used to simplify banana image features. Then, the hyperparameters of the limit gradient lifting algorithm were optimized by Bayesian optimization algorithm. Finally, the simplified banana image features were input into the limit gradient lifting algorithm, and the banana ripeness was judged by the limit gradient lifting algorithm. **Results:** The identification accuracy of the method for banana ripeness was 91. 25%.

**作者简介:**韩雪(1976一),女,徐州开放大学副教授,硕士。 E-mail:hxuehfrt2@126.com

收稿日期:2024-01-11 改回日期:2024-04-15

Compared with the existing methods, the proposed method was more accurate to distinguish the ripeness of bananas with small data volume. **Conclusion**: The proposed method can realize the accurate identification of banana ripeness, which is helpful for warehouse managers and exporters to monitor banana ripeness in real time.

**Keywords**: banana; maturity discrimination; convolutional neural network; limit gradient lifting algorithm; small data volume

香蕉具有相当高的营养价值和药用价值,不同成熟 阶段的香蕉对人体健康有不同的益处<sup>[1]</sup>。青香蕉果实具 有较高含量的抗性淀粉,可用于控制血糖水平,而成熟的 黄色果实则适合作为新鲜水果食用,因为它含有大量的 糖类物质并能立即提供能量<sup>[2-3]</sup>。过熟的香蕉果实富含 抗氧化剂,有利于改善免疫系统并降低患乳腺癌等某些 癌症的风险<sup>[4]</sup>。食品加工业则需对香蕉成熟度进行鉴 定,用不同成熟阶段的香蕉制作特定香蕉产品<sup>[5]</sup>。

当前,研究人员对香蕉果实的成熟阶段判别开展了 广泛研究。已有方法大致可分为两类,一类是基于物理 化学特性的传统判别法<sup>[6]</sup>;另一类是基于先进计算机算 法的机器视觉判别法<sup>[7]</sup>。第一类方法根据香蕉中的淀 粉、糖、可溶性固形物、酸度等生化指标对香蕉成熟度进 行判别,获得成熟过程与果实生化特性之间的直接关系 是第一类判别方法的主要关注点<sup>[8]</sup>;但该类方法是侵入 式的。第二类方法则采用工程理论和算法对香蕉成熟度 进行判别,图像处理技术是第二类方法的核心<sup>[9]</sup>;该类方 法能够提供完全自动和非侵入式的香蕉成熟度判别 思路。

为避免破坏待检测香蕉,研究人员将更多的注意力 放在了计算机视觉辅助香蕉果实选择、分选以及基于图 像处理的香蕉果实成熟度判别的各种最新技术研究上。

**基金项目**:江苏省教育研究课题(编号:XHYBLX2023285);江苏 开放大学"十四五"科研规划课题(编号:2022KF007)

实现基于计算机算法的香蕉成熟度判别最重要的工作之一是选择合适的计算机算法。虽然机器学习算法中的支持向量机、主成分分析、人工神经网络等被广泛用于水果分类<sup>[10-11]</sup>,但卷积神经网络(convolution neural network, CNN)具有将特征提取和分类相结合的独特优点<sup>[12]</sup>。

莫松涛等<sup>[7]</sup>构建了一种基于遗传算法与 SVM 的香 蕉果实成熟度判别方法,经过 10 次预测后,该方法对香 蕉成熟度的平均判别准确率达到 86.20%。王灵敏等<sup>[13]</sup> 提出基于深度学习 AlexNet 的香蕉成熟度自动分级方 法,测试结果表明,AlexNet 模型可快速准确识别并分类 不同成熟度香蕉。刘海军等<sup>[14]</sup>建立了基于人工神经网络 和贝叶斯优化算法的高精度香蕉成熟度检测模型,测试 结果表明,该模型具有较高的准确率、较强的可靠性和泛 化能力。Kahfi等<sup>[15]</sup>搭建了基于灰度共生矩阵和 K 最近 邻方法的香蕉成熟度判别模型,测试结果表明,该模型可 实现香蕉成熟度的高精度判别。Saranya 等<sup>[16]</sup>提出基于 卷积神经网络和被囊群算法的香蕉成熟度判别方法,测试 结果表明,该方法在成熟阶段的粗略分类和完全可接受的 分类方面都优于基于计算机视觉的其他所对比方法。

为了避免 CNN 潜在的过拟合问题,可采用 CNN 和 极限梯度提升算法(extreme gradient boosting algorithm, XgBoost)的组合来对香蕉果实进行成熟度判别。 XgBoost可有效降低 CNN 的计算复杂度,并且有助于降 低对 CNN 的池化层和全连接层的需要<sup>[17]</sup>。

对于已有基于深度学习和机器学习算法的香蕉成熟 度判别方法,为确保具有良好的香蕉成熟度判别性能,需 要构建一个由大量香蕉图像组成的数据集。然而,构建 庞大的数据集时常难以实现。为解决该问题,可引入数 据增强。数据增强是一种通过各种技术来增加训练数据 集中图像数量的技术。然而,数据增强需要为深度学习 和机器学习算法的执行创建额外的预处理步骤,从而增 加了香蕉成熟度判别的复杂性。已有水果分类方法大多 需要经过多个图像预处理和过滤步骤才能得到准确的分 类结果。此外,多数已有香蕉成熟度判别方法基于单个 香蕉果实进行成熟度判别,这在香蕉果实成熟度实时判 别中不太切合实际。 为解决香蕉成熟度判别方法存在的以上问题,研究 拟提出一种基于 CNN 和 XgBoost 架构的香蕉成熟度判 别方法,以期在较小数据集下获得较好的香蕉成熟度判 别准确度和精确度。

## 1 香蕉图像数据集

从市场上购买不同品种(grand naine、poovan、ney poovan、karpuravalli、rtherali)、不同成熟度的香蕉簇。将 香蕉簇分成未熟(unripe,UR)、欠熟(underripe,UDR)、成 熟(ripe,R)和过熟(overripe,OR)4个成熟阶段。完全绿 色果实被归类为未成熟果实。果皮颜色为黄绿色,为欠 熟。全黄果皮果实为成熟果实。果皮有褐色斑点、黑色 斑块被归类为过熟果实。

数据集经过收集和准备,以获得与真实实际场景相 似的香蕉图像。在相同的光照条件下,使用 Eos 200D 型 佳能数码单反相机拍摄香蕉的照片,并将图像保存为.jpg 格式。此外,还从互联网上手动收集不同成熟度香蕉图 像。训练数据集共包含 720 张图片;每类香蕉有 180 张图 片,其中 90 张来自互联网。验证数据集由 120 张图片组 成;每类 30 张图片,其中 15 张图片来自互联网。测试数 据集由 80 幅图像组成;每类 20 幅图像,其中 10 幅来自互 联网。此外,这些图像是经过精心挑选的,它们代表了真 实的不同成熟度香蕉场景。

图片尺寸为6000像素×4000像素。水平分辨率为 72 dpi,垂直分辨率为72 dpi。不平衡的数据集可能会导 致模型无法正确学习未被充分代表的香蕉种类,并且可 能会降低对不同成熟阶段香蕉的分类精度。因此,从每 个品种中随机收集香蕉图像时,尽管没有特别规定每个 品种的图像数量;但确保了收集到的代表每个品种的图 像数量是平衡的。

来自数据集的香蕉样本图像如图1所示。

## 2 香蕉成熟度判别框架

所搭建香蕉果实成熟度判别系统的 CNN、XgBoost 二元结构分两个阶段实现,即特征提取阶段和分类器阶 段。架构框图如图 2 所示。

CNN模型经过训练,可以从固定维度的输入图像中



图 1 香蕉样本图像 Figure 1 Banana sample figures





提取图像特征。一旦训练结束,CNN 模型就可以用作特 征提取器。CNN 模型选用 VGG 16,它是一种预训练的 CNN 架构。XgBoost 用于在分类器阶段进行流行度预 测,根据 CNN 从输入图像中提取的特征,将香蕉果实分 类为 4 个成熟阶段之一。所用 CNN 模型的架构如表 1 所示。所提混合架构的训练分两个阶段进行:① VGG 16 训练,从输入图像中构建香蕉成熟度判别的特征提取器; ② XgBoost 训练,构建从 VGG 16 提取的特征的集成增 强分类器。XgBoost 训练阶段发生在 VGG 16 完成训练 之后。经过训练的 VGG 16 可以有效地生成提取香蕉图 像的高级特征。

### 2.1 VGG 16

VGG 16 是一种深度卷积神经网络,由 16 个卷积层和 3 个全连接层组成,是一种经典的深度学习模型,常用于图像分类和特征提取任务。

表⊥	VGG 16 的模型架构	

lable 1	I he i	model	framework	of	VGG	1

E	输出形状		参数数目			
			权重		偏斜量	
Input	(批量大小,3,200,200)					
VGG-16 特征提取器	(批量大小,512,7,7)					
Flatten	(批量大小,25088)					
Linear	(批量大小,1000)	25	088 00	0	1000	
ReLu	(批量大小,1000)					
Drop out	(批量大小,1000)					
Linear	(批量大小,30)		30 33	33	30	
ReLU	(批量大小,30)					
Linear	(批量大小,4)		12	20	4	
总参数		25	119 15	54		

(1) 输入层: VGG 16 接受输入的图像数据, 通常是 彩色图像, 每个像素由 RGB 3 个通道表示。

(2)卷积层:VGG 16 包含 13 个卷积层,每个卷积层 都使用小尺寸的 3×3 卷积核进行特征提取。这些卷积 层逐渐增加深度和复杂度,能够学习到图像的低级特征 (如边缘和纹理)到高级特征(如形状和物体部件)。

(3)池化层:在每两个卷积层之间,VGG 16 使用最 大池化层来减少特征图的尺寸,同时保留主要的特征。 最大池化操作能够降低计算量并提高模型的鲁棒性。

(4)全连接层:VGG 16 的最后 3 个卷积层被转换成 全连接层,其中包括两个具有 4 096 个神经元的隐藏层和 一个具有 1 000 个神经元的输出层。这些全连接层将卷 积层提取的特征映射到最终的类别概率分布。

(5) Softmax 层: VGG 16 的输出层采用 Softmax 函数,将网络的原始输出转换为对应每个类别的概率分布, 使得模型可以对输入图像进行分类。

VGG 16 的主要特点是网络结构简单而深度较大,具 有良好的特征提取能力和泛化能力。然而,由于网络的 深度较大,导致参数量庞大,训练和推理速度较慢,同时 需要大量的计算资源和数据。VGG 16 具有 3 个工作阶 段:特征提取、自适应平均池化和特征分类<sup>[18]</sup>。在所使用 的 CNN 模型中,前两个阶段保持不变,但对 VGG 16 中 的分类器部分进行了舍弃,以适应所提出的香蕉成熟度 判别框架。

VGG 16 的特征提取部分具有一致的 3×3 步长为 1 的滤波器,这些滤波器形成卷积层排列。VGG 16 的特征 提取部分始终使用相同的填充层和最大池层,这些填充 层和最大池层采用 2×2 步长为 2 的滤波器。

## 2.2 XgBoost

XGBoost(extreme gradient boosting)是一种高效的、 可扩展的、梯度提升树(gradient boosting tree)的集成机 器学习算法。它是由天池大赛的冠军 Chen Tianqi 开发 的,并且在许多数据科学竞赛和实际应用中获得了广泛 的成功。

(1)梯度提升树(gradient boosting tree):XGBoost是 建立在梯度提升树的基础之上的。梯度提升树是一种集 成学习算法,通过串行地训练多个决策树来提高模型的 性能。每个新的树都会尝试纠正之前树的错误,并逐步 减少模型的残差(即目标值与模型预测之间的差异)。

(2)决策树(decision tree):在 XGBoost 中,每个基础 学习器都是一棵决策树。决策树是一种树状结构,其中 每个内部节点代表一个特征属性的判断,每个叶子节点 代表一个类别或数值。

(3)损失函数(loss function):XGBoost使用了梯度 提升算法中的损失函数来衡量模型预测值与实际值之间 的差异。通常情况下,回归问题使用的损失函数是均方 误差(mean squared error),而分类问题使用的是对数损 失函数(log loss)。

(4) 正则化(regularization):为了防止过拟合, XGBoost 引入了正则化项,包括L1 正则化(L1 regularization)和L2 正则化(L2 regularization)。正则化 项通过惩罚模型复杂度来控制模型的复杂度,使其更具 泛化能力。

(5) 学习率(learning rate): XGBoost 中的学习率是 一个重要的超参数,它决定了每棵树对模型的贡献程度。 较小的学习率会使得模型的训练过程更加稳定,但可能 需要更多的迭代次数才能收敛到最优解。

(6) 特征列采样(column subsampling): 为了提高模 型的泛化能力和降低过拟合的风险, XGBoost 引入了特 征列采样,即每次训练只使用部分特征列进行模型训练。

(7) 并行计算(parallel computing): XGBoost 利用了 并行计算的能力来加速模型训练过程,通过在每个迭代 步骤中同时处理多个样本和特征列来提高计算效率。

通过以上这些机制, XGBoost 能够高效地拟合复杂 的数据模式,并且在各种机器学习任务中表现出色。

#### 香蕉成熟度判别流程和成熟度特征 3

香蕉成熟度判别流程如图 3 所示,具体步骤:

(1) 调整香蕉图像尺寸。深度学习架构在较小维度 的图片上训练更快,因此,获取目标香蕉簇的图像后,首 先将图像调整为较小的尺寸。使用 open cv 从本地存储 中读取图像,然后将读取的图像对象转换为 Pytorch 可操 作的张量, Pytorch 是为此工作选择的深度学习框架。





(2) 执行基于均值和标准差的归一化,以确保整个数 据集分布集中且值限制在0和1之间。这种标准化可确 保梯度下降学习收敛,并且不会发生由于高值导致的梯 度爆炸。

(3) 将归一化的图像馈送到 VGG 16 预训练模型。 VGG 16 由一系列完全连接的层和末端的 softmax 层完 成的。交叉熵被用作损失函数来反向传播 VGG 16 的预 测误差,以便学习 VGG 16 内的权重。

VGG 16 的目标函数为

$$f_{\rm VGG\,16} = \min \sum_{i=1}^{m} L(x_i, \hat{x}_i) , \qquad (1)$$

f<sub>VGG 16</sub>----VGG 16 的目标函数(即对所有样本预测 的总损失之和最小);

*m*——样本总数量;

L(•)——VGG 16 的损失函数;

 $x_i$ 、 $\hat{x}_i$  —— 第 *i* 个样本的真实值和预测值。

(4) 将整个训练数据集依次传递给全连接层网络和 线性判别分析算法,以获得来自 VGG 16 特征提取器输 出特征的简化特征,并将简化特征输入 XgBoost,用于对 XgBoost 进行训练。VGG 16 特征提取器输出的特征被 变换到较低的维度,使得四类成熟度香蕉图像之间具有 充足的类可分离性。

(5) 最后, XgBoost 以对数损失为目标函数指导树木 生长的阶段,得出最终预测的香蕉成熟阶段。XgBoost 的 目标函数为

$$f_{\text{XgBoost}} = \min \sum_{j=1}^{n} l(y_j, \hat{y}_j) + \sum_{k=1}^{K} \Omega(f_k) , \qquad (2)$$

式中:

*l*(•)——损失函数;

 $y_j$ 、 $y_j$ ——第j个样本的真实值和预测值;

*K* ——树的总数;

 $f_k$ 、 $\Omega(f_k)$  —— 第 k 棵树的预测函数和复杂度函数。

尽管在 CNN 和 XgBoost 训练的每个阶段都加入了 正则化技术,但由于使用低维数据进行高维特征学习,会 出现一定程度的过拟合。为解决该问题,将 CNN 学习到 的特征通过线性判别分析(linear discriminant analysis, LDA),以最大限度地提高 XgBoost 对香蕉成熟度的判别 准确性。LDA 是一种监督降维技术,它将高维特征降为 投影空间中更易分离的低维特征。从根本上说,LDA 试 图找到一组轴,使每类图像的均值分离最大化,同时使每 个簇内的方差最小化。

在应用 LDA 转换后,将使特征更易于 XgBoost 对香 蕉成熟度判别。

#### CNN 和 XgBoost 训练 4

## 4.1 VGG 16 训练阶段

卷积和下采样在 CNN 中的应用已被证明比简单的 前馈多层感知器(multilayer perceptrons, MLP)更具优 势,特别是对于图像的分类任务[19]。由于使用了卷积滤 波器,权重共享得以实现。卷积操作的输出是特征图,其 深度取决于所用滤波器的数量。每个滤波器都有固定的 宽度和高度,可作为视觉感受器在图像上滑动。在 VGG 16 训练过程中,滤波器的权重通过学习获得。

在输入图像中使用相同的固定滤波器,与 MLP 相比 减少了使用的参数数量。这种权重共享还使 VGG 16 对 图像中的仿射变换具有不变性,从而能够识别图像中任 何方向的特定物体。池化是聚集特征映射的过程。它有 助于缩小特征图的大小,但保留了重要的属性。最大集 合提取子区域中的最大值,而平均集合则对子区域中的 激活值进行平均。池化层独立作用于输入的每个片段。 它缩小了表征空间的大小,从而避免了过度拟合。为提 升 VGG 16 的泛化能力,VGG 16 进行了迁移学习。

VGG 16 包括 3 个部分:① 特征提取器;② 自适应平 均池化;③ 分类器。在所提香蕉成熟度判别框架中, VGG 16 内的整个分类器阶段被忽略,在自适应平均池化 阶段之后提取的非线性特征作为输入馈送到 XgBoost。 需要提取的特征数目被设置为 f\_SIZE。在 VGG 16 的训 练过程中,特征提取器权重是冻结的,不会被反向传播修 改。只有经过特征提取后的线性层的权值才被训练。

VGG 16 接受训练时, XgBoost 模型不参与。一旦 VGG 16 训练结束,图像特征被传递到 XgBoost,作为 XgBoost 分类器的训练数据集<sup>[20]</sup>。

4.2 XgBoost 训练阶段

XgBoost 是一种优化的梯度提升算法,可有效对数据 进行并行处理,具有高度的数据处理灵活性,研究用其代 替 VGG 16 的 Softmax 分类器,实现对香蕉成熟度的最终 判断。决策树本身是用于分类任务的一种流行的最大似 然算法,但单一的决策树不足以学习复杂结构特征之间 的相互作用。因此,单个决策树是弱分类器。对决策树 的增强是将一个弱学习器(如决策树)逐个添加到实际概 率的残差中以拟合预测概率的过程。该过程是顺序拟合 的,可以从以前的弱学习者的错误分类中学习。该顺序 过程可有效地构建一个强大的分类器。

使用 XgBoost 作为图像类别判断的分类器阶段的优 点是,可以由一个集成阶段来对提取的特征进行分类,而 不是从 CNN 分类器阶段获得一组训练好的分类器权值。

## 5 分类方法验证与结果分析

## 5.1 香蕉图像特征提取准确率分析

VGG 16 采用 ADAM 优化器进行训练,批次大小设置为 12,总迭代次数设置为 25。采用交叉熵作为损失函

数,学习率设为 0.001。当验证损失在随后的迭代中没有 减少时,停止训练 VGG 16 模型,以防止过高的拟合。所 搭建分类器架构中采用了 dropout 等正则化技术,以从反 向传播中删除随机选择的神经元。

由于维度灾难, VGG 16 的特征维度太高, XgBoost 无法直接训练。为此, 引入了全连接层(fully connected layer, FC)+LDA 的组合策略来降低特征维度。LDA 将 模型学习到的香蕉图像特征投射到一个低维空间中, 使 得不同成熟度香蕉类内变化小、类间区别大。当从全连 接层获得特征值并将其提供给 XgBoost 后, XgBoost 对香 蕉成熟度的判别准确率可得到明显提升。在固定 f\_size 为 30 和输入特征维度为 25 088 的情况下, 对香蕉成熟度 的判别准确率的观察结果:① 仅使用全连接层的准确率 为 82.5%;② 仅使用 LDA 的准确率为 81.25%;③ 使用 全连接层+LDA 的准确率为 91.25%。3 种情况的混淆 矩阵如图 4 所示。从表 2 的性能指标值和图 4 的混淆矩 阵中可以看出, 采用 FC+LDA 组合策略的 XgBoost 可以 更准确地区分不同成熟度的香蕉。

#### 5.2 香蕉图像特征提取效果的可视化

为了实现对香蕉图像特征提取效果的可视化,利用 LDA 将从 VGG 16 中获取的 25 088 个训练和测试特征 转换为二维特征,并绘制成二维特征图,如图 5(a)和 图 6(a)所示。此外,25 088 个训练和测试特征分别通过 FC+LDA 策略进行特征缩减,并将这些特征绘制成二维 特征图,如图 5(b)和图 6(b)所示。如图 5 和图 6 所示,相 比于 LDA 策略,采用 FC+LDA 策略获得的不同成熟度 香蕉的类特征之间区分度更明显,更利于不同成熟度香 蕉的类分离,这将十分有利于 XgBoost 对不同成熟阶段 香蕉进行分类。

## 5.3 XgBoost 的超参数选择

XgBoost 的超参数通过贝叶斯优化算法(bayesian optimization algorithm, BOA)进行调优。XgBoost 中可调整的超参数包括:树的数量、学习率、最小子权重、增长策



Figure 4 Confusion matrices

#### 采用不同降维策略的分类器对香蕉成熟度的 表 2 判别效果

Table 2 Discrimination effects of classifiers using different dimensionality reduction strategies on banana ripeness

八步市	准确	精度/	召回	F1 分
万矢益	率/%	%	率/%	数/%
CNN	85.00	87.30	85.00	86.13
CNN+FC+XgBoost	86.25	87.00	86.00	86.00
CNN+LDA+XgBoost	82.15	81.50	81.25	81.40
CNN+FC+LDA+XgBoost	91.25	92.84	91.25	92.03

略、每棵树的最大深度、每棵树的列采样、每层分割、每棵 树可用的子采样数据集比例、正则化参数(如 alpha、 lambda 和 gamma)。Skopt.Bayesiansearch cv 用于从每个 参数的数值网格中找出最佳超参数,贝叶斯优化算法通 过使用高斯过程回归来确定目标函数的最小值。通过为 训练集设置5倍交叉验证方案,进行 XgBoost 超参数的 优化。训练数据被分为5个部分,所有部分的不同成熟



度香蕉的分布相同。在每次运行中,一部分设置为测试 集,其余部分设置为训练集。以香蕉成熟度的判别准确 性作为评估指标。在交叉验证方案的每次运行中,贝叶 斯优化选择可使香蕉成熟度判别准确性最大的 XgBoost 超参数。调优后的 XgBoost 超参数如表 3 所示。

为对不同成熟度的香蕉进行准确分类,为 XgBoost 设置损失函数和评估集两个参数。损失函数:"multi: softprob",这是一个多分类损失函数,可优化每个类别的 softmax 概率,输出概率最高的类。评估集:用于执行提 前停止,以便在验证损失没有显著减少的情况下防止添 加更多的树。

通过贝叶斯优化方法为 XgBoost 设置超参数时,贝 叶斯优化方法采用的评价指标设定为对数损失最小。采 用训练集和验证集中的香蕉图像训练和验证所提出的香 蕉成熟度判别方法时,可将香蕉图像特征从 25 088 个减 少到 30 个。如图 7 所示,随着树数量的增多,对数损失先 是迅速下降,然后当树数量达到200时趋于稳定。

采用贝叶斯优化算法优化的超参数之后,XgBoost分 类器对不同成熟度香蕉分类的最佳受试者操作特征曲线





Figure 5 The image features of the training set obtained from the output features of VGG 16 processed by LDA strategy and FC+LDA strategy respectively



The image features of the test set were obtained by processing the output features of VGG 16 with Figure 6 LDA strategy and FC+LDA respectively

XgBoost 的超参数	参数值	XgBoost 的超参数	参数值
Learning rate	(0.001, 0.02, "log-uniform")	reg lambda	(1, 5, "log-uniform")
min_child weight	(1, 2, 3)	reg_alpha	(1, 10, "log-uniform")
max_depth	(3, 4)	Gamma	(1, 8, "log-uniform")
subsample	(0.8, 1, "uniform")	No. of estimators	(5, 100, "uniform")
colsample bytree	(0.5, 1, "uniform")	Max delta step	(0.1, 0.2)
colsample bylevel	(0.4, 1, "uniform")		

表 3 XgBoost 的超参数取值

Table 3 Hyperparameter values of XgBoost

(receiver operating characteristic curve, ROC)如图 8 所示。由图 8 可知,所提方法能很好地区分不同成熟度香蕉,可有效避免将其他成熟度香蕉错分为未熟香蕉。

## 5.4 与已有分类方法对比

为进一步验证所提方法有效性,将所提方法(VGG 16+ FC+LAD+BOA+XgBoost)对香蕉成熟度判别效果与基 于遗传算法+SVM的香蕉果实成熟度判别方法(GA+ SVM)<sup>[7]</sup>、基于 AlexNet 模型的香蕉果实成熟度判别方法 (AlexNet)<sup>[13]</sup>、VGG 16+FC+LAD+XgBoost 方法、基于 灰度共生矩阵和K最近邻方法的香蕉成熟度判别方法



图 8 所提方法对不同成熟度香蕉分类的 ROC



(GLCM+KNN)<sup>[15]</sup>、基于模糊卷积神经网络和被囊群算 法的香蕉成熟度判别方法(F-CNN+TSA)<sup>[16]</sup>进行对比。 VGG 16+FC+LAD+XgBoost 方法与所提方法的区别 在于是否采用 BOA 进行超参数优化。GA+SVM、 VGG 16+FC+LAD+XgBoost、所提方法、AlexNet、 GLCM+KNN、F-CNN+TSA 对香蕉成熟度进行判别的混 淆矩阵如图 9~图 14 所示,对香蕉成熟度判别的性能指标 如表 4 所示。

由图 11 可知,XgBoost 的超参数经 BOA 优化后,所 提方法对香蕉成熟度的判别准确率得到明显提升,达到 91.25%。与其他方法相比,所提方法对香蕉成熟度判别 的假阳性率大大降低。对比结果还表明,即使有手动设









图 10 VGG 16+FC+LAD+XgBoost 的混淆矩阵 Figure 10 Confusion matrix of VGG 16+FC+ LAD+XgBoost



Figure 11 Confusion matrix of the proposed method



Figure 12 Confusion matrix of AlexNet



图 13 GLCM+KNN 的混淆矩阵 Figure 13 Confusion matrix of GLCM+KNN





表 4 不同方法对香蕉成熟度判别的效果

Table 4 Performances of different methods on banana ripeness identification

分类器	准确率/	精度/	召回率/	F1 分数/	
	%	%	%	%	
GA+SVM	85.00	87.30	85.00	86.13	
所提方法	91.25	92.84	91.25	92.03	
AlexNet	78.75	80.00	79.00	78.00	
GLCM+KNN	78.25	82.00	79.00	79.00	
F-CNN+TSA	82.50	83.00	82.00	82.00	

计的预处理阶段,机器学习算法对香蕉成熟度的判别准确性也比深度学习模型差。结合图 9、图 11 和表 4 可知, GA+SVM 虽与所提方法对过熟香蕉的分类效果相当, 但其对香蕉成熟度的总体判别效果不如所提方法。这可 能源于 GA+SVM 可将过熟香蕉的深棕色和黑色与其他 成熟度香蕉的浅绿色和黄色很好地区分(20 个过熟香蕉 图像全部正确判别),但对其他成熟度香蕉的颜色难以 区分。

为验证选用 XgBoost 的合理性,将 VGG 16+FC+ LDA 得到的香蕉图像特征传递给其他 3 个分类器:高斯 朴素贝叶斯分类器(gaussian naïve bayesian classifier, GNB)、支持向量机(support vector classifier,SVC)、k 最 近邻算法(k-nearest neighbours algorithm,KNN),并将所 提方法对香蕉成熟度的判别效果与 VGG 16+FC+ LDA+GNB、VGG 16+FC+LDA+SVC、VGG 16+ FC+LDA+KNN进行了对比,如图 15 所示,仅 VGG 16+ FC+LDA+SVC 能够达到较高的分类准确率。然而, SVC 的分类准确率仍低于所提方法(91.25%)。

当可用数据较少时,SVC 可以与 XgBoost 相媲美,因 为 SVC 在小数据集情况下也具有良好的不同成熟度香 蕉分类效果。当数据集规模增大时,SVC 会耗费大量计 算时间,而且与 XgBoost 在上述网格上运行贝叶斯优化 搜索相比,选择合适的内核将是一项艰巨的任务。因此, 考虑到分类方法的可扩展性,与 GNB、SVC、KNN 相比, 选用 XgBoost 作为分类器更为合理。

综上,现有研究中的机器学习和深度学习算法在进行香蕉成熟度判别时需要额外的数据增强和图像预处理 技术,而所提方法省去了主要的预处理步骤。

许多现有研究中的机器学习和深度学习算法都需要 考虑每个像素的信息,然后进行手动特征提取,因此过程 繁琐且耗时。通过在加工生产线上实施所提方法的双核 架构,只需一个步骤就能利用预先训练好的模型自动完 成香蕉图像的特征提取和香蕉成熟度的准确判别。此 外,所提方法能够在较小的数据集上实现对香蕉成熟度 的高精度判别。



Figure 15 Confusionmatrice of different classifiers

## 6 结论

利用 VGG 16、极限梯度提升算法、线性判别分析、全 连接层和贝叶斯优化算法的组合,提出了一种完全非侵 人式的香蕉果实成熟度判别方法。结果表明,该方法优 于已有的机器学习和深度学习算法。虽然深度学习算法 的主要要求是拥有足够大的数据集,但所提方法能够利 用相对较小的数据集获得高准确度的香蕉成熟度判别, 这对于在工业出口和加工应用中使用所提方法判别复杂 和成簇香蕉的成熟度至关重要。此外,所提方法的计算 复杂度相对较小,且具有所需的香蕉成熟度判别精度。 这反过来又减轻了处理器中内存的负担,从而有助于能 源的有效利用。

### 参考文献

- [1] 覃翠钠,李志春,何雪梅,等.基于成熟度研究不同品种香蕉多 酚含量及抗氧化活性的差异[J].食品工业科技,2022,43(22): 52-60.
  - QIN C N, LI Z C, HE X M, et al. Polyphenol content and antioxidant capacity from banana with different varieties and maturity[J]. Science and Technology of Food Industry, 2022, 43 (22): 52-60.
- [2] DO NASCIMENTO TINOCO L P, DE SA OLIVEIRA L, AUGUSTA I M, et al. Green banana biomass (Musa sp.) as an ingredient in the development of pasta[J]. Research, Society and Development, 2022, 11(3): e2711326204.
- [3] 彭思琪, 王娟. 香蕉皮总黄酮的提取及其抗氧化和抑制酪氨酸酶的活性[J]. 食品研究与开发, 2022, 43(20): 132-140.
  PENG S Q, WANG J. Antioxidant activity and inhibition ontyrosinase of total flavonoids extracted from banana peels [J].
  Food Research and Development, 2022, 43(20): 132-140.
- [4] AFZAL M F, KHALID W, AKRAM S, et al. Bioactive profile and functional food applications of banana in food sectors and health: A review[J]. International Journal of Food Properties, 2022, 25(1): 2 286-2 300.

[5] 张帅, 李跃森, 费鹏, 等. 香蕉果肉对乳酸菌在冻干和贮存中活性的影响[J]. 粮食与油脂, 2022, 35(7): 87-92.

ZHANG S, LI Y S, FEI P, et al. Effects of banana pulp on the viability of lactic acid bacteria during freeze-drying and storage[J]. Cereals & Oils, 2022, 35(7): 87-92.

[6] 吴水金, 张帅, 林宝妹, 等. '香粉 1号'香蕉成熟过程中挥发性成分组成及其变化分析[J]. 食品安全质量检测学报, 2023, 14 (18): 245-252.

WU S J, ZHANG S, LIN B M, et al. Composition and change analysis of volatile components in 'Xiangfen No. 1' banana at different ripening stages[J]. Journal of Food Safety & Quality, 2023, 14(18): 245-252.

- [7] 莫松涛, 董涛, 赵汐璇, 等. 基于遗传算法与 SVM 的香蕉果实 成熟度判别模型[J]. 果树学报, 2022, 39(12): 2 418-2 427.
  MO S T, DONG T, ZHAO X X, et al. Discriminant model of banana fruit maturity based on genetic algorithm and SVM[J]. Journal of Fruit Science, 2022, 39(12): 2 418-2 427.
- [8] 李芬芳, 李奕星, 袁德保, 等. 不同乙烯利浓度及贮藏温度对
   "南天黄"香蕉果实后熟品质的影响[J]. 中国南方果树, 2022, 51
   (2): 72-77, 83.
- LI F F, LI Y X, YUAN D B, et al. Effects of different concentrations of ethrel and storage temperatures on post-ripening quality of 'Nantianhuang' banana[J]. South China Fruits, 2022, 51 (2): 72-77, 83.
- [9] 刘祎帆, 杜卉妍, 钟玉鸣, 等. 基于香蕉、粉蕉成熟过程中硬度 变化建立成熟度随机森林模型[J]. 广东农业科学, 2020, 47(6): 106-115.

LIU H F, DU H Y, ZHONG Y M, et al. Construction of maturity random forest models based on the changes of fruit firmness[J]. Guangdong Agricultural Sciences, 2020, 47(6): 106-115.

[10] 王菲菲, 刘彭, 孙凤伟, 等. 基于支持向量机和压力传感器的 水果分类系统[J]. 食品与机械, 2023, 39(9): 83-88.

WANG F F, LIU P, SUN F W, et al. Fruit classification system based on the pressure sensor coupled with support vector machine [J]. Food & Machinery, 2023, 39(9): 83-88.

(下转第178页)

- [16] 李博, 籍保平. 葡萄糖酸内酯豆腐生产过程中微生物的变化及豆腐中主要腐败菌的鉴定[J]. 食品科学, 2006(5): 77-82.
  LI B, JI B P. Isolation and identification of major purified bacteria in glucono-delta-lactone Tofu processing[J]. Food Science, 2006 (5): 77-82.
- [17] 曲敏, 陈红丽, 王宇, 等. 传统豆制品腐败菌污染及抑制研究 进展[J]. 食品科学技术学报, 2022, 40(3): 167-178.
  QU M, CHEN H L, WANG Y, et al. Research progress of spoilage bacteria pollution and inhibition of traditional soy products [J]. Journal of Food Science and Technology, 2022, 40(3): 167-178.
- [18] 李博, 李里特, 辰已英三, 等. 豆腐(豆浆)中屎肠球菌生长的 温度预测模型[J]. 中国农业大学学报, 2003, 8(2): 49-54.
  LI B, LI L T, TATSUMI E, et al. Predictive model for effect of temperature on the growth of *E. faecium* in tofo (soymilk) [J].
  Journal of China Agricultural University, 2003, 8(2): 49-54.
- [19] 何婉莹, 黄展锐, 赵良忠, 等. 生浆法制作豆腐的工艺优化[J]. 现代食品科技, 2021, 37(10): 188-196.
  HE W Y, HUANG Z R, ZHAO L Z, et al. Optimization of Tofo production from filtered raw soybean milk [J]. Modern Food Science and Technology, 2021, 37(10): 188-196.
- [20] BOBBADI S, KIRANMAYI CHINNAM B, NELAPATI S, et al. Occurrence and genetic diversity of ESBL producing Klebsiella species isolated from livestock and livestock products[J]. Journal of Food Safety, 2019, 40(1): e12738.

(上接第135页)

- [11] MASEKO K H, REGNIER T, ANYASI T A, et al. Discrimination of Musa banana genomic and sub-genomic groups based on multielemental fingerprints and chemometrics [J]. Journal of Food Composition and Analysis, 2022, 106: 104334.
- [12] 王辉, 张帆, 刘晓凤, 等. 基于 DarkNet-53 和 YOLOv3 的水果图 像识别[J]. 东北师大学报(自然科学版), 2020, 52(4): 60-65.
  WANG H, ZHANG F, LIU X F, et al. Fruit image recognition based on DarkNet-53 and YOLOv3 [J]. Journal of Northeast Normal University (Natural Science Edition), 2020, 52(4): 60-65.
- [13] 王灵敏, 蒋瑜. 基于深度学习的香蕉成熟度自动分级[J]. 食品 与机械, 2022, 38(11): 149-154.
  WANG L M, JIANG Y. Automatic classification of banana ripeness based on deep learning[J]. Food & Machinery, 2022, 38 (11): 149-154.
- [14] 刘海军, 赵文锋, 刘韵锋, 等. 基于 ANN 和贝叶斯优化算法的香 蕉成熟度检测模型研究[J]. 现代农业装备, 2021, 42(5): 42-46. LIU H J, ZHAO W F, LIU Y F, et al. Model for detecting banana maturity based on artificial neural network and bayesian optimization algorithm[J]. Modern Agricultural Equipment, 2021, 42(5): 42-46.
- [15] KAHFI A H, HASAN M, HASANAH R L. Classification of banana ripeness based on color and texture characteristics [J]. Journal of Computer Networks, Architecture and High

 [21] 陈金玉, 刘单阳, 蓝蔚青, 等. 3 种天然产物联合抗生素对肺炎 克雷伯氏菌的协同抗菌作用[J]. 上海海洋大学学报, 2022, 31
 (2): 586-593.

CHEN J Y, LIU D Y, LAN W Q, et al. Synergistic antibacterial effect of three natural products combined with antibiotics onKlebsiella pneumoniae [J]. Journal of Shanghai Ocean University, 2022, 31(2): 586-593.

- [22] DHARA L, TRIPATHI A. Cinnamaldehyde: A compound with antimicrobial and synergistic activity against esbl-producing quinolone-resistant pathogenic Enterobacteriaceae [J]. European Journal of Clinical Microbiology & Infectious Diseases, 2019, 39 (1): 65-73.
- [23] 张宁. 基于群体感应途径探讨茶多酚对肺炎克雷伯菌毒力及 耐药性的作用[D]. 南昌: 南昌大学, 2020: 17-18.
  ZHANG N. Effects of tea polyphenols on the virulence and drug resistance of Klebsiella pneumoniae based on quorum sensing[D].
  Nanchang: Nanchang University, 2020: 17-18.
- [24] 林碧莲,陈浩,代传芝,等.壳寡糖的酶法可控制备及其在预 包装豆腐保鲜中的应用[J].食品与发酵工业,2023,49(12): 136-143.

LIN B L, CHEN H, DAI C Z, et al. Enzymatic controlled preparation of chitosan oligosaccharides and its application in preservation of pre-packaged tofu [J]. Food and Fermentation Industries, 2023, 49(12): 136-143.

Performance Computing, 2023, 5(1): 10-17.

- [16] SARANYA N, SRINIVASAN K, PRAVIN K S K. FBCNN-TSA: An optimal deep learning model for banana ripening stages classification[J]. Journal of Intelligent & Fuzzy Systems, 2023, 44 (3): 5 257-5 273.
- [17] HE W W, HE H Y, WANG F L, et al. Rapid and uninvasive characterization of bananas by hyperspectral imaging with extreme gradient boosting (XGBoost) [J]. Analytical Letters, 2022, 55(4): 620-633.
- [18] 范志文,光翠娥,干建平.基于反向传播人工神经网络的酱牛肉中金黄色葡萄球菌的生长模型[J]. 食品与生物技术学报,2020,39(7):83-90.
   FAN Z W, GUANG C E, GAN J P. Growth model of

Staphylococcusaureus in soy beef based on backpropagation artificial neural network [J]. Journal of Food Science and Biotechnology, 2020, 39(7): 83-90.

- [19] UPADHYAY A, SINGH S, KAOJIYA S. Segregation of ripe and raw bananas using convolutional neural network [J]. Procedia Computer Science, 2023, 218: 461-468.
- [20] 高立秀,陈得丽,万兴森,等.基于机器学习的切丝后含水率 预测及控制方法[J]. 食品与机械, 2021, 37(4): 189-194, 211.
  GAO L X, CHEN D L, WAN X M, et al. Prediction and control method of moisture content after cutting based on machine learning[J]. Food & Machinery, 2021, 37(4): 189-194, 211.