

# 基于深度学习的葡萄砧木叶片识别研究

潘博文<sup>1,2</sup>, 魏冰心<sup>1</sup>, 苏宝峰<sup>3</sup>, 鞠延仑<sup>1</sup>, 刘崇怀<sup>2</sup>, 樊秀彩<sup>2</sup>, 张颖<sup>2</sup>, 孙磊<sup>2</sup>, 姜建福<sup>2,4</sup>, 房玉林<sup>1</sup>

(<sup>1</sup>西北农林科技大学葡萄酒学院, 陕西杨凌 712100; <sup>2</sup>中国农业科学院郑州果树研究所, 郑州 450009;

<sup>3</sup>西北农林科技大学机械电子与电子工程学院, 陕西杨凌 712100; <sup>4</sup>中国农业科学院中原研究中心, 河南新乡 453424)

**摘要:**嫁接有利于增强树体对生物及非生物胁迫的适应能力, 提高葡萄产量和品质。葡萄砧木品种多样复杂, 识别难度较大, 深度学习能够快速提取图像的深层特征, 被广泛应用于植物图像分类识别领域。本研究以30份葡萄砧木成熟叶图像作为研究对象, 通过采集叶片图像, 构建了一个包含13547张的葡萄砧木叶片图像的数据集。采用GoogleNet、ResNet-50、ResNet-101以及VGG-16等4个卷积神经网络对其进行自动识别。结果表明: 精度最高的分类网络为ResNet-101, 在最优模型参数(学习率: 0.005, 最小批次: 32, 迭代次数: 50)下精度达到97.5%。ResNet-101模型检测的30个品种中, 平均预测精确率为92.59%, 有7个品种的预测精确率达到100%; 平均召回率为91.08%, 有8个品种的召回率达到100%, 叶片的叶面纹理、叶脉以及叶缘部分对品种识别的影响最大。以上结果证实, 深度学习网络模型可以实现对葡萄砧木的自动实时识别, 为葡萄砧木品种的保护、利用、分类研究以及其他农作物的品种识别提供参考。

**关键词:** 砧木; 深度学习; 品种识别; 葡萄; 叶片

## Research on Grape Rootstock Leaf Recognition Based on Deep Learning

PAN Bowen<sup>1,2</sup>, WEI Bingxin<sup>1</sup>, SU Baofeng<sup>3</sup>, JU Yanlun<sup>1</sup>, LIU Chonghuai<sup>2</sup>, FAN Xiucui<sup>2</sup>,  
ZHANG Ying<sup>2</sup>, SUN Lei<sup>2</sup>, JIANG Jianfu<sup>2,4</sup>, FANG Yulin<sup>1</sup>

(<sup>1</sup>College of Enology, Northwest A&F University, Yangling 712100, Shaanxi; <sup>2</sup>Zhengzhou Fruit Research Institute, Chinese Academy of Agricultural Sciences, Zhengzhou 450009; <sup>3</sup>College of Mechanical and Electronic Engineering, Northwest A&F University, Yangling 712100, Shaanxi; <sup>4</sup>Zhongyuan Research Center, Chinese Academy of Agricultural Sciences, Xinxiang 453424, Henan)

**Abstract:** Grafting is beneficial in enhancing the adaptability to biotic and abiotic stresses, and improving the yield and quality of grapes. There are varieties of grape rootstocks, while their precise clarification become complex and difficult. Deep learning, capable of rapidly capturing deep features from images, has been extensively applied in the field of plant image classification and recognition. In this study, the mature leaf images of 30 grape rootstocks were deployed to construct a dataset, comprising 13547 grape rootstock leaf images. Four convolutional neural networks, GoogleNet, ResNet-50, ResNet-101 and VGG-16, were used for image recognition. The results show that the classification network with the highest accuracy is ResNet-101, and the accuracy reaches 97.5% under the optimal model parameters (learning rate: 0.005, mini-batch size: 32, Max epochs: 50). Among the 30 varieties, the average prediction precision rate was 92.59%, and the prediction precision reaching 100% was observed in seven varieties. The recall rate of eight varieties reached 100%, and the average recall rate was 91.08%. The leaf surface texture, leaf vein and leaf margin were major

收稿日期: 2023-10-24 修回日期: 2023-11-15 网络出版日期: 2023-12-02

URL: <https://doi.org/10.13430/j.cnki.jpgr.20231024001>

第一作者研究方向为葡萄品种识别, E-mail: panbw0824@163.com

通信作者: 房玉林, 研究方向为葡萄栽培、酿酒葡萄种质资源、品质调控, E-mail: fangyulin@nwsuaf.edu.cn

姜建福, 研究方向为葡萄种质资源与遗传育种, E-mail: jiangjianfu@caas.cn

**基金项目:** 国家现代农业产业技术体系(CARS-29-yc-1); 国家园艺种质资源库运行服务(NHGRC2021-NH00-2); 中国农业科学院科技创新工程专项(CAAS-ASTIP-2017-ZFRI)

**Foundation projects:** National Modern Agricultural Industrial Technology System (CARS-29-yc-1); National Horticultural Germplasm Resource Library Operation Service (NHGRC2021-NH00-2); Special Funds for Scientific and Technological Innovation Project of Chinese Academy of Agricultural Sciences (CAAS-ASTIP-2017-ZFRI)

factors that influence variety classification. This study confirmed the application capacity of deep learning network models in real-time automatic identification of grape rootstocks, thus providing reference for the protection, utilization, classification research of grape rootstock varieties and the variety recognition of other crops.

**Key words:** rootstock; deep learning; identification of varieties; grape; leaves

在葡萄栽培中,砧木可以提高对葡萄根瘤蚜<sup>[1]</sup>、根结线虫<sup>[2]</sup>等生物害虫的抗性,还可以提高对寒冷<sup>[3]</sup>、干旱<sup>[4-5]</sup>、盐碱土地<sup>[6-7]</sup>等非生物胁迫的抵抗力。葡萄嫁接栽培是提高浆果品质、增强对生物和非生物胁迫抵抗能力、扩大栽培适应范围的有效途径<sup>[8]</sup>。国内外大部分的商业葡萄采用嫁接栽培,以优化果实品质,提高其适应性<sup>[9]</sup>。然而,由于葡萄砧木品种数量多,遗传背景狭窄,识别合适的砧木品种变得愈发困难。

在植物品种的识别研究中,叶片比其他器官更容易采集,也更稳定<sup>[10]</sup>。任何植物的叶子都有其独特的特征,例如脉序图案、形状、中脉、顶端、叶片及边缘,而这些特征的微小变化很难被人捕捉<sup>[11]</sup>。基于植物形状、大小、图案和颜色的人类模式识别效率低、繁琐、容易出错,随着人工智能技术的快速发展,计算机视觉、机器学习等技术在品种识别方面有广阔的应用前景<sup>[12]</sup>。将计算机视觉应用到植物表型识别中,可以减轻科研人员的工作强度,加快科研进展,并自动量化表型指标<sup>[13]</sup>。机器学习算法可以检测叶片并提取其特征<sup>[14]</sup>,提高生产效率。其中深度学习作为机器学习领域的研究方向之一,能够从原始数据中自动发现叶片特征,在图像识别技术领域发展迅速<sup>[15]</sup>。GoogleNet<sup>[16]</sup>、AlexNet<sup>[17]</sup>、VGG<sup>[18]</sup>、ResNet<sup>[19]</sup>等深度学习技术已应用于植物叶片的自动识别,成为农业领域的重要研究方向之一。Chen等<sup>[20]</sup>利用多注意力融合卷积神经网络(MAFNet, multi-attention fusion convolutional neural network)对苹果叶片图像进行分类,模型的识别准确率可达98.14%。Tavakoli等<sup>[21]</sup>利用卷积神经网络(CNN, convolutional neural networks)对12种豆类进行品种识别,该模型在豆叶片背面图像数据集上具有较好的分类性能,分类准确率最高可达95.86%。Liu等<sup>[22]</sup>对酿酒葡萄自动实时识别开展了系统研究,所有卷积神经网络分类算法上对21个品种的准确率都可达到94%以上。但尚未见葡萄砧木品种自动识别的研究报道。

本研究以国内外常见的葡萄砧木为试验材料,采用4种卷积神经网络对葡萄砧木品种叶片进行自动识别,并进一步评价了各个模型的识别效率,为

葡萄砧木品种的分类、保护、利用研究以及其他农作物的品种识别提供科学参考。

## 1 材料与方法

### 1.1 葡萄砧木叶片数据集

叶片图像在中国农业科学院郑州果树研究所的国家葡萄种质资源圃(郑州)拍摄。圃地年平均气温14.2℃,年平均降水量666.0mm,年平均日照时数2436h,无霜期213d。土壤为褐色土类,质地为沙壤土,土壤pH值7.1~7.5,呈微碱性。采用单干双臂树形,架高1.8m,行株距2.5m×1.0m,南北行向,圃地管理水平中等。在本研究中,数据集包含了30个砧木品种(图1)。样本叶片在田间自然条件下采用Vivo iQOO Neo6 SE手机拍摄,采集于2022年7-8月,每天16:00-18:00,采集叶片为成熟叶,叶片完全展开,没有明显的营养缺乏、病原体感染或虫害症状,采样位置为新梢7~9节点。拍摄不同叶片不同角度的正面图像,每个品种采集叶片图像400~500张。采集图像为JPG格式,图像大小为3456×4608像素。

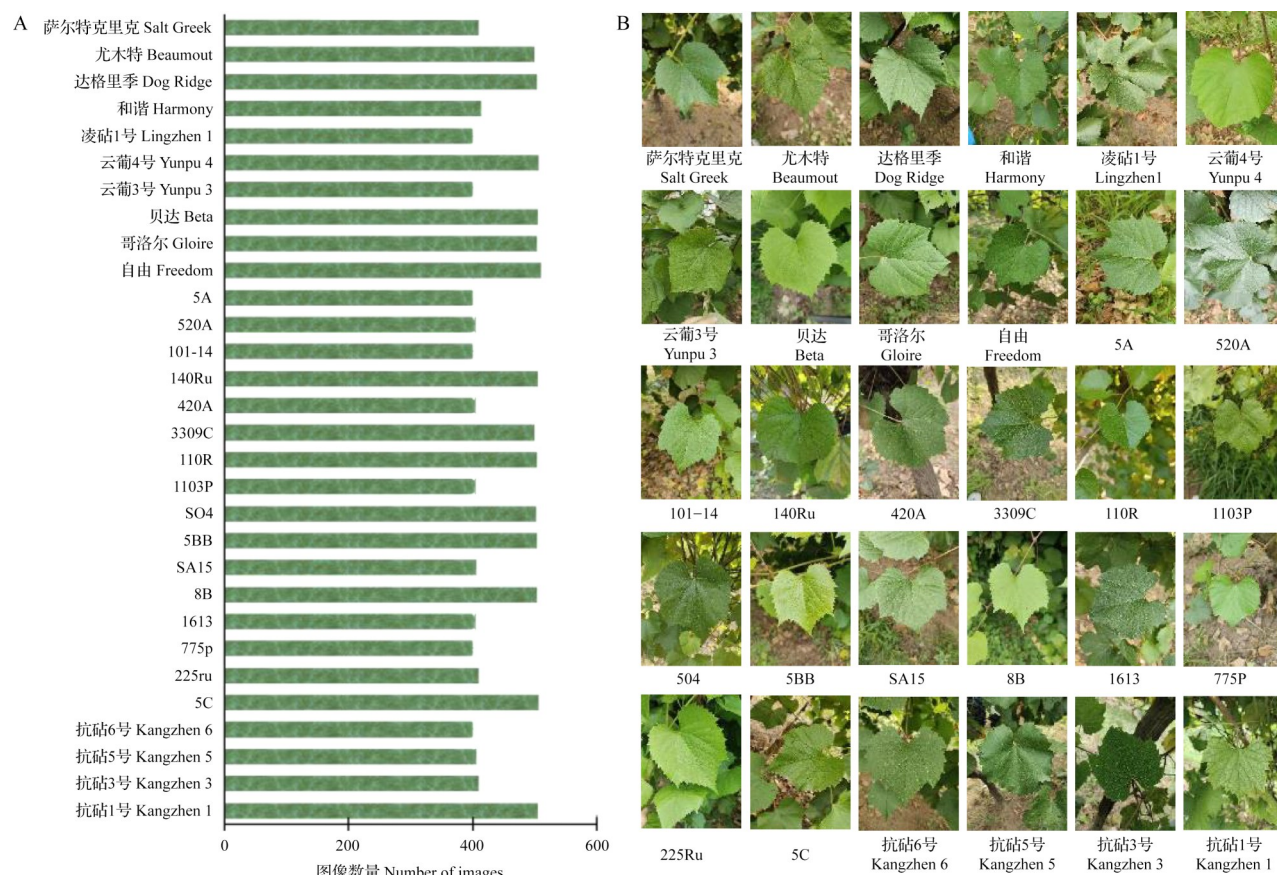
### 1.2 图像预处理

采用图像数据增强技术和几何变化技术进行图像预处理,从原始输入图像中自动获得增强的局部化图像特征,提高品种识别性能。图像数据增强技术具有通用性和高效性,可以有效地训练深度学习模型,进行亮度、饱和度、对比度等图像处理,模拟不同光照条件下叶片图像。应用缩放、旋转、固定裁剪等几何变化技术扩展图像数据集。预处理后的图像数据集按照7:2:1比例将每一品种的图像划分为训练集、测试集和验证集<sup>[23]</sup>。训练时,将图像分辨率调整到224×224像素。

### 1.3 卷积神经网络的模型选择

在深度学习领域,卷积神经网络是最常用的算法。卷积神经网络主要由输入层、卷积层、池化层、全连接层和输出层组成。卷积层由一组卷积滤波器组成,将输入图像与这些滤波器进行卷积,生成输出特征图。池化层的主要任务是通过卷积运算对特征图进行二次采样。随后,将全连接层用作CNN分类器。最后从输出层进行最终分类<sup>[24]</sup>。





A: 砧木叶片图像数量; B: 砧木品种叶片样图

A: Number of rootstock leaf images; B: Leaf samples of rootstock varieties

图1 30个葡萄砧木品种叶片图像

Fig.1 Leaf images of 30 grape rootstock varieties

本研究选择 GoogleNet、ResNet-50、ResNet-101 以及 VGG-16 四个卷积神经网络模型对砧木叶片数据集进行训练验证<sup>[24]</sup>。ResNet 是 He 等<sup>[25]</sup>于 2016 年提出的一种深度残差网络,为了解决层次加深难以训练的问题,引入了跳跃连接的快速结构——残差块,残差网络结构使得反向传播算法运行平稳,基于该结构,衍生出相应的 ResNet-18<sup>[26-27]</sup>、ResNet-50<sup>[28-29]</sup>、ResNet-101<sup>[30]</sup>等更大更深的网络结构。GoogleNet 由 9 个深度序列的模块化结构组成,使用的是 Inception-v1 模块,在增加卷积神经网络深度和宽度的同时,不增加额外的训练参数<sup>[31-32]</sup>,GoogleNet 更适合处理大规模数据集。VGG 模型由小的堆叠卷积滤波器组成<sup>[33]</sup>,该网络增加神经网络的深度来提高模型的分类效果,同时还可以对网络进行正则化,降低过拟合的风险<sup>[34]</sup>。

#### 1.4 评价模型性能指标

对于深度学习分类任务常用的评价指标有:精度 ( $A$ , accuracy)、损失值 ( $L$ , LOSS) 精确率 ( $P$ , precision)、召回率 ( $R$ , recall) 以及  $F1$  值。

$$A = \frac{TP + TN}{TP + FP + FN + TN} \times 100\% \quad (1)$$

$$L = -\frac{1}{N} \sum_{i=1}^M \sum_{c=1}^M y_{ic} \log(p_{ic}) \quad (2)$$

$$P = \frac{TP}{TP + FP} \times 100\% \quad (3)$$

$$R = \frac{TP}{TP + FN} \times 100\% \quad (4)$$

$$F1 = \frac{P \times R \times 2}{P + R} \quad (5)$$

式中,  $TP$  代表预测为正确且实际正确的样本数;  $FP$  代表预测为正确但实际错误的样本数;  $FN$  代表预测为错误但实际正确的样本数;  $TN$  代表预测为错误且实际错误的样本数;  $M$  代表类别的数量;  $y_{ic}$  代表样本  $i$  的真实品种为  $c$  取 1, 否则取 0;  $p_{ic}$  代表样本  $i$  属于品种  $c$  的概率。

#### 1.5 基于 Grad-CAM 的可视化分析

卷积神经网络的特征学习是一个抽象的过程,为了解砧木叶片样本的特征学习情况,利用梯度加权类别激活映射 (Grad-CAM, gradient-weighted

class activation map)技术<sup>[35]</sup>,将每幅图像中用于品种识别预测的特征区域通过热图可视化,直观地表达算法获得分类结果的原因。类激活图可视化(CAM, class activation map)技术提取的是最后一个特征层和输出之间的全局平均池化层,其局限性是网络模型中必须有池化层,而 Grad-CAM 适用非池化层连接的网络结构,应用范围比 CAM 更广。

### 1.6 实验平台

实验平台为操作系统为 64 位 Windows 10 操作系统,将深度学习分类模型部署在云服务器上,深度学习框架为 TensorFlow2.8.0(谷歌大脑团队,美国),GPU 为 NVIDIA GeForce RTX 3090,计算机

语言为 Python3.8,操作软件为 pycharm2022.2.2 (JetBrains公司,捷克)。

## 2 结果与分析

### 2.1 分类模型选择

为了对所有的卷积神经网络进行公平比较,对实验参数进行标准化。得到了不同卷积神经网络结构的分类结果,包括 VGG-16、ResNet-101、ResNet-50 和 GoogleNet。分类模型的准确率见表 1。结果表明,4 种卷积神经网络模型均可行,且 ResNet-101 在 30 个葡萄品种的验证数据集上精度最高,证明了在实际生长环境中使用深度学习进行葡萄品种识别的可行性。

表 1 四种分类模型的准确率

Table 1 The accuracy of four classification models

分类模型 Classification models	迭代次数 Max epochs	学习率 Learning rate	最小批次 Mini-batch size	精度(%) Accuracy
VGG-16	50	0.001	32	93.13
GoogleNet	50	0.001	32	87.96
ResNet-50	50	0.001	32	92.55
ResNet-101	50	0.001	32	95.41

### 2.2 模型参数选择

选择 ResNet-101 作为分类模型,测试不同训练参数对分类性能的影响。在保持其他参数不变的情况下,设置 3 个实验 T1、T2 和 T3,学习率分别为 0.001、0.005 和 0.01。结果表明,当学习率为 0.005 时,分类性能达到最佳。

在合理的范围内增加最小批次可以提高内存的利用率,提高训练速度。对于大规模训练,在相

同的迭代次数下必须确保使用更大的批处理训练获得与较小的批处理相似的测试精度。在保持学习率为 0.005,其他参数不变的情况下,设置了 3 个实验 T2、T4 和 T5,其中最小批次分别为 16、32 和 64。表 2 显示了 ResNet-101 检测模型在不同最小批次下的分类精度。结果表明,最小批次为 32 时,ResNet-101 分类模型的分类精度最高。

表 2 不同训练参数下 ResNet-101 的性能

Table 2 The performance of ResNet-101 at different training parameters

实验 Test	学习率 Learning rate	最小批次 Mini-batch size	迭代次数 Max epochs	精度(%) Accuracy
T1	0.001	32	50	95.41
T2	0.005	32	50	97.50
T3	0.010	32	50	96.29
T4	0.005	16	50	96.25
T5	0.005	64	50	96.42
T6	0.005	32	30	97.45
T7	0.005	32	80	97.12

迭代次数也是影响模型学习进度的重要因素。在其他参数不变的情况下,设置3个实验T2、T6和T7,迭代次数分别为30、50、80。表2中显示了不同迭代次数下的精度。结果表明,最理想的迭代次数为50。

因此,ResNet-101分类模型的优化参数为学习率0.005,最小批次为32,迭代次数为50,其模型分类精度高达97.50%。

### 2.3 LOSS及训练精度变化曲线

损失函数(LOSS function)是反应预测结果与实际结果之间的差异的函数,差异越小,模型性能越好。T2实验参数下4个模型网络训练的LOSS变化曲线如图2所示。结果表明:ResNet-101的初始损失约为0.8,变化趋势为前5次快速下降,5~20次缓慢下降,20次后趋于稳定,稳定值约为0.08。ResNet-50的初始损失约为0.68,变化趋势为前20次稳定下降,20次后趋于稳定,稳定值约为0.10。GoogleNet的初始损失约为0.74,变化趋势为前10次快速下降,10~20次稳定下降,20次后趋于稳定,稳定值约为0.20。VGG-16的初始损失约为3.15,前10次急速下降,10~20次缓慢下降,之后趋于稳定,最终LOSS值稳定于0.29。说明相比VGG-16以及GoogleNet,ResNet-101和ResNet-50的最终损失值相对较低,且最终LOSS值较为稳定。

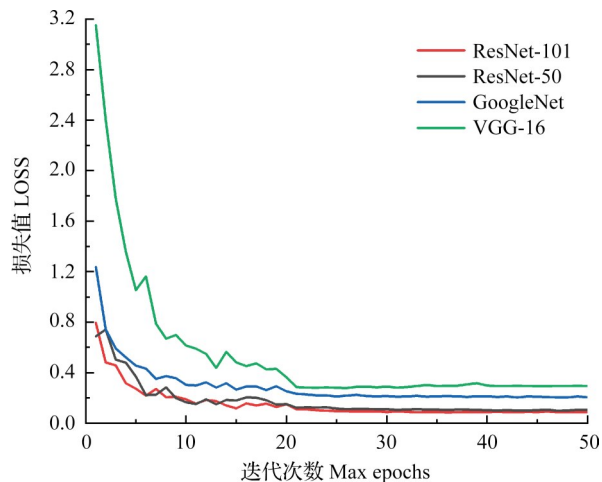


图2 训练LOSS变化曲线

Fig.2 Training LOSS change curve

由图3可知,GoogleNet从训练开始精度急速升高,迭代次数20次后,精度逐渐稳定,总体精度变化浮动大,精度增长较不稳定,最终精度在93.3%左右波动。VGG-16从训练开始精度急速升高,于迭代次数20次后趋于稳定,最终精度稳定于93.13%。ResNet-50从训练开始精度便逐渐提高,

从迭代次数15次后精度趋于稳定,总体精度变化浮动小,最终精度在96.62%左右波动。ResNet-101从训练开始精度便逐渐提高,总体精度变化浮动小,精度增长较为稳定,最终精度达到了97.50%。说明相比GoogleNet、VGG-16以及ResNet-50,ResNet-101收敛更快且更为稳定,且ResNet-101的最终精度均高于GoogleNet、VGG-16以及ResNet-50。

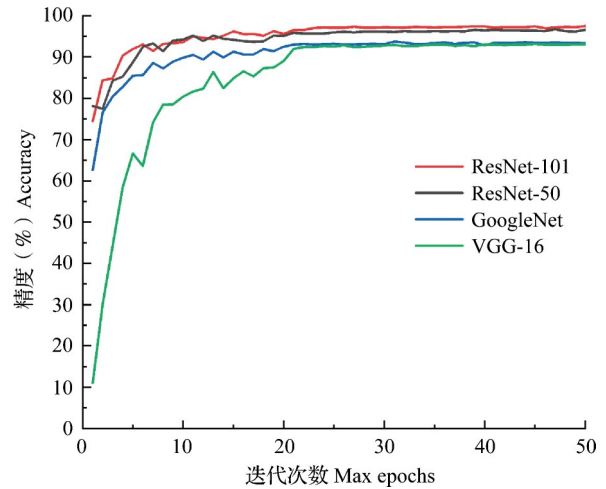


图3 分类精度变化曲线

Fig.3 Classification accuracy change curve

### 2.4 识别精确率、召回率及F1值分析

如图4A所示,在ResNet-101检测模型的30个品种中,有7个品种的识别精确率为100%,分别为5C、达格里季、1613、抗砧1号、萨尔特克里克、云葡3号、云葡4号,30个品种的平均识别精确率达到了92.59%。ResNet-50有7个品种的识别精确率为100%,分别为5BB、自由、1613、SA15、萨尔特克里克、抗砧6号、云葡3号,30个品种的平均识别精确率达到了93.46%。VGG-16有5个品种的识别精确率为100%,分别为5C、达格里季、1613、萨尔特克里克、云葡4号,30个品种的平均识别精确率为86.63%。GoogleNet仅有4个品种预测精确率达到100%,分别为5C、自由、抗砧6号、凌砧1号,30个品种的平均识别精确率为88.09%。相比之下,ResNet-101、ResNet-50的模型优于GoogleNet、VGG-16,各品种之间的识别精确率差距较小,模型更为稳定。综上,结果表明卷积神经网络模型对30个葡萄砧木的识别效率高。

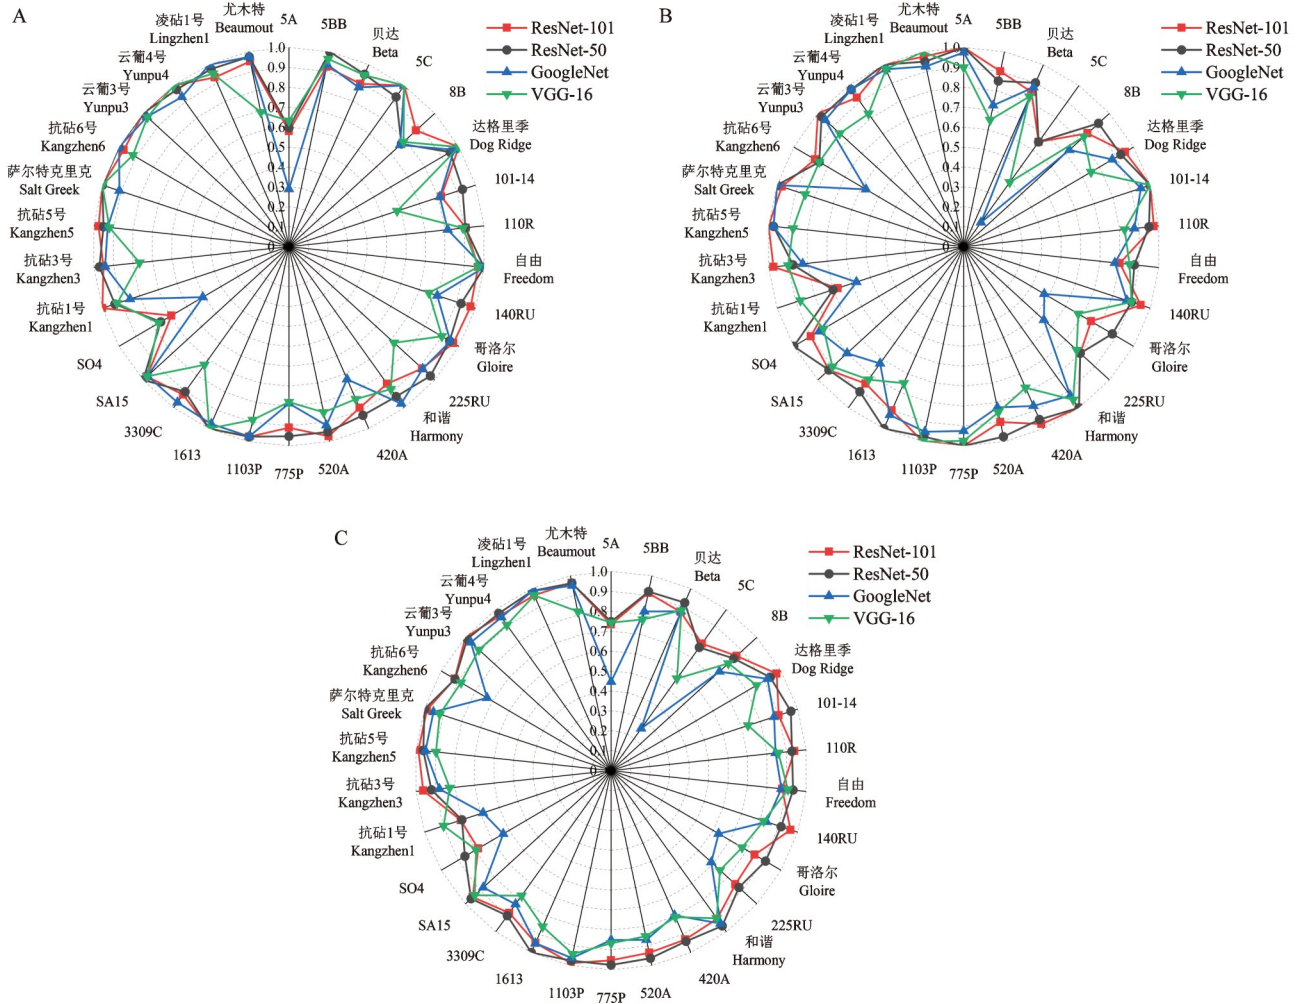
召回率越高,漏检的概率越低。在ResNet-101检测模型的30个品种中,有8个品种的召回率达到100%,分别为5A、101-14、和谐、775p、1103p、抗砧5号、云葡3号、凌砧1号,30个品种的平均召回率达到了91.08%。ResNet-50有8个品种的召回率达到



100%, 分别为 5A、101-14、和谐、775p、1613、SO4、萨尔特克里克、凌砧 1 号, 30 个品种的平均召回率达到了 92.25%。VGG-16 有 3 个品种的召回率达到 100%, 分别为 101-14、1103p、尤木特, 30 个品种的平均召回率为 84.08%。GoogleNet 仅有萨尔特克里克这 1 个品种召回率达到 100%, 30 个品种的平均召回率为 81.33% (图 4B)。相比之下, ResNet-101、ResNet-

50 的模型优于 GoogleNet、VGG-16, 各品种之间的召回率更稳定。

*F1* 值越高, 模型整体性能越好, ResNet-101 与 ResNet-50 的模型 *F1* 值较高, 各品种数据 *F1* 值差距较小, 说明模型可信度较高, 模型效果更为稳定 (图 4C)。



A: 30 个品种在不同网络模型中的精确率; B: 30 个品种在不同网络模型中的召回率; C: 30 个品种在不同网络模型中的 *F1* 值  
 A: The precision of 30 varieties in different network models ; B: The recall rate of 30 varieties in different network models ;  
 C: *F1* values of 30 varieties in different network models

图 4 ResNet-101、ResNet-50、GoogleNet、VGG-16 模型的识别精确率、召回率以及 *F1* 值

Fig.4 Recognition precision, recall rate, and *F1* value of ResNet-101, ResNet-50, GoogleNet, and VGG-16 models

### 2.5 Grad-CAM 可视化分析

使用 Grad-CAM 算法输出最终卷积层中权重的梯度热图, 并对网络模型进行可视化。如图 5 所示, 颜色越红的区域, 表明这部分特征在类别定向中起着更关键的作用。对于葡萄砧木叶片的品种

鉴定, 叶片的叶面纹理、叶脉以及叶缘部分对分类的影响最大。与 GoogleNet 以及 VGG-16 模型相比, ResNet-101 和 ResNet-50 对葡萄砧木叶片识别范围更广, 对完整叶片表面和背景中的同种叶片均能识别到位。

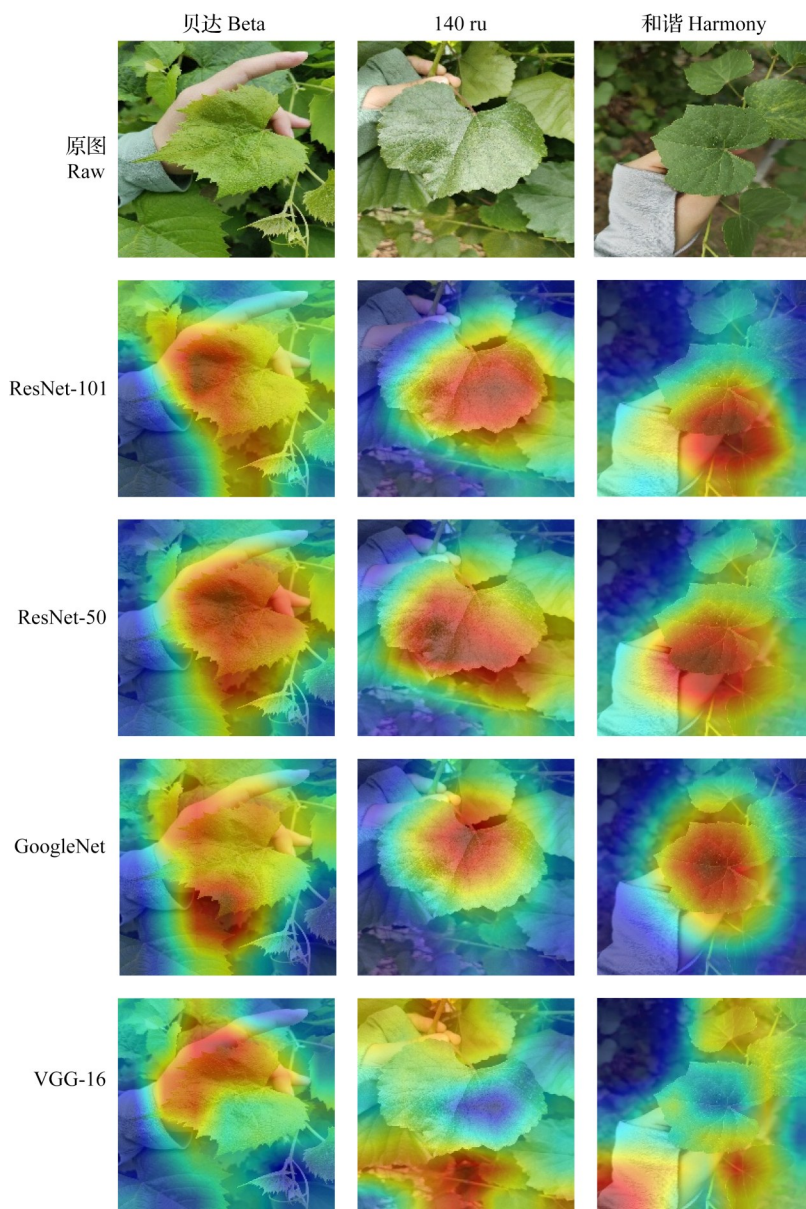


图5 不同卷积神经网络算法 Grad-CAM 分类效果图

Fig.5 Different convolutional neural network algorithm Grad-CAM classification effect diagram

### 3 讨论

葡萄砧木品种识别对遗传育种分类和作物估产具有重要意义,葡萄砧木种类繁多,肉眼难以分辨。传统的鉴定方法往往依赖于专家的知识经验,很难对已有葡萄砧木品种进行自动识别。植物叶片即使在不同的时期也表现出很小的差异,因此可以作为植物品种识别的特征,深度学习方法具有快速、准确、客观的特点。因此,本研究通过葡萄砧木叶片图像预处理技术,利用卷积神经网络具有较强的特征提取和分类能力,通过VGG-16、GoogleNet、ResNet-50、ResNet-101等深度学习框架开展葡萄砧木叶片种类识别,分析不同卷积神经网络对图像的

识别分类能力,实现对葡萄砧木的快速准确识别。分析模型分类结果对比发现,ResNet-101和ResNet-50模型比另外两个模型总体识别精度高4%左右,LOSS稳定值大概只有一半,品种平均识别精确率及召回率均较高,单一品种识别精确率、召回率达到100%的品种数量远高于GoogleNet和VGG-16,且较低迭代次数下就能获得较优模型,效果更好且耗时更短。

Cheng等<sup>[36]</sup>利用葡萄的近红外高光谱图像,采用支持向量机、随机森林和AdaBoost方法建立识别模型,结果表明支持向量机模型具有最好的分类效果,对红葡萄和白葡萄的平均验证准确率分别为90%和81%。Pereira等<sup>[37]</sup>利用AlexNet识别自然条



件下采集的葡萄品种图像,对数据集进行了各种预处理,但得到的准确率为77.3%。本研究采用的模型可以获得更高的分类结果,且自然环境中的样本采集更接近现实生活中的识别样本。为了提升卷积神经网络的识别效果,后续将尝试通过增加注意力机制、多尺度融合、调整模型结构等方法,减少模型深度,以提高模型的识别速度。未来应深入探究轻量级网络算法和应用案例,充分发挥轻量级网络的优势。

在自然环境条件下,存在叶片被遮挡、背景杂乱和光照亮度不均匀等问题,这会影响葡萄砧木品种识别的准确性<sup>[38]</sup>,使用不同的智能设备采集图像,采集到的叶片图像在距离和分辨率上存在一定的差异,可能也会对识别结果产生一定的影响。因此,未来的研究方向可能涉及开发新的技术或算法来解决这些问题。深度学习算法对数据集的信息量和质量要求严格,在某些情况下,当数据集噪声干扰过大时,会出现过拟合的情况,这对所建模型的泛化能力产生了负面影响;数据不足时,模型可能无法泛化。因此,扩大数据集,减少噪声干扰,选择模型性能最佳的网络以及参数都至关重要。此外,为了保证良好的性能,有必要对分类算法的输入向量进行降维,以优化学习算法的处理。研究表明,即使在田间环境中,典型的智能手机或数码相机采集的图像也可以用来训练卷积神经网络,以准确地识别葡萄品种。

本研究只提取了形状、纹理等少量特征用于葡萄砧木的特征提取。下一步的研究方向是提取更多特征参数,比如结合其他植物器官进行更准确的识别。此外,葡萄砧木品种繁多,资源丰富,叶片数据集可以进一步扩大,算法可以精简修改,以便进行更多的品种识别研究。

## 4 结论

本研究在田间环境下采集了13547张葡萄砧木叶片图片的数据集,然后采用图像预处理和数据增强相结合的方法对图像特征进行增强,以增强训练数据集。在此基础上,利用4个深度学习网络(GoogleNet, ResNet-50, ResNet-101, VGG-16)对30个葡萄砧木品种的叶片图像进行识别,并对模型参数进行了优化。所有的卷积神经网络分类算法在30个品种的验证数据上均能达到90%以上的精确率。其中,ResNet-101模型在时间和模型复杂度方面均优于其他模型,在最优模型参数(学习率:

0.005,最小批次:32,迭代次数:50)下精度达到97.5%。采用Grad-CAM算法对4种卷积神经网络的分类效果进行评价,表明4种卷积神经网络均能准确识别叶片的主要特征,而叶片的叶面纹理、叶脉以及叶缘特征对植物叶片识别起决定性作用。本研究结合深度学习技术实现葡萄砧木的自动识别,以无损的方式获取田间葡萄品种信息。未来将会成为无人农业建设的一部分。综合来看,本研究对葡萄品种的识别研究有一定指导意义,为葡萄砧木品种识别提供新思路。

## 参考文献

- [1] Andziejewski S, Oliveira D C, Bernardi D, Botton M. Resistance of grapevine genotypes (*Vitis* spp.) to *Daktulosphaera vitifoliae* (hemiptera: Phylloxeridae) in Brazil: Implications for pest management. *Environ Entomol*, 2022, 51 (6): 1166-1171
- [2] 葛启要. 葡萄砧木杂种优株田间繁育特性及抗南方根结线虫表现. 杨凌:西北农林科技大学, 2023  
Ge Q Y. Field breeding characteristics and resistance to *Meloidogyne incognita* of grape rootstock hybrid superior plants. Yangling: Northwest A & F University, 2023
- [3] 郭艳兰, 牟德生, 赵连鑫, 王鑫, 马宗桓, 张兆铭, 张利年. 六个葡萄砧木品种(系)的抗寒性评价. *中外葡萄与葡萄酒*, 2022(3): 38-43  
Guo Y L, Mou D S, Zhao L X, Wang X, Ma Z H, Zhang Z M, Zhang L N. Analysis of cold resistance of six wine grape rootstock varieties. *Sino-overseas Grapevine & Wine*, 2022 (3): 38-43
- [4] Ren C K, Li Z H, Song P H, Wang Y, Liu W D, Zhang L H, Li X G, Li W H, Han D G. Overexpression of a grape MYB transcription factor gene *VhMYB2* increases salinity and drought tolerance in *Arabidopsis thaliana*. *International Journal of Molecular Sciences*, 2023, 24(13): 1-18
- [5] 刘竞择, 曹柠, 张艳霞, 陈祖民, 史晓敏, 王振平. 葡萄砧木冬季抗抽干能力及抗旱性综合评价. *果树学报*, 2020, 37 (3): 339-349  
Liu J Z, Cao N, Zhang Y X, Chen Z M, Shi X M, Wang Z P. Comprehensive evaluation on resistance of different grape rootstocks to vine dehydration and drought stress during overwintering. *Journal of Fruit Science*, 2020, 37(3): 339-349
- [6] Zhao B L, Liu Z Y, Zhu C M, Zhang Z J, Shi W C, Lu Q J, Sun J L. Saline-alkaline stress resistance of cabernet sauvignon grapes grafted on different rootstocks and rootstock combinations. *Plants-Basel*, 2023, 12(15): 1-14
- [7] Albuquerque S M M, Bentzen S H R, Nascimento S E, Barroso N J, José H P, Lima R T, Gomes N V, Nascimento S A, Soares S E, Luiz F S S. Higher control of  $\text{Na}^+$  and  $\text{Cl}^-$  transport to the shoot along with  $\text{K}^+/\text{Na}^+$  selectivity is determinant for differential salt resistance in grapevine



- rootstocks. *Journal of Plant Growth Regulation*, 2023, 42(9): 5713-5726
- [8] Li M M, Guo Z J, Jia N, Yuan J W, Han B, Yin Y G, Sun Y, Liu C J, Zhao S J. Evaluation of eight rootstocks on the growth and berry quality of 'marselan' grapevines. *Scientia Horticulturae*, 2019, 248: 58-61
- [9] Harris Z N, Pratt J E, Kovacs L G, Klein L L, Kwasniewski M T, Londo J P, Wu A S, Miller A J. Grapevine scion gene expression is driven by rootstock and environment interaction. *BMC Plant Biology*, 2023, 23(1): 1-15
- [10] Wang Z, Cui J, Zhu Y. Review of plant leaf recognition. *Artificial Intelligence Review*, 2022, 56(5): 4217-4253
- [11] Aslam T, Qadri S, Qadri S F, Nawaz S A, Razzaq A, Zarren S S, Ahmad M, Rehman M U, Hussain A, Hussain I, Jabeen J, Altaf A. Machine learning approach for classification of mangifera indica leaves using digital image analysis. *International Journal of Food Properties*, 2022, 25(1): 1987-1999
- [12] Patricio D I, Rieder R. Computer vision and artificial intelligence in precision agriculture for grain crops: A systematic review. *Computers and Electronics in Agriculture*, 2018, 153: 69-81
- [13] Li Z B, Guo R H, Li M, Chen Y R, Li G Y. A review of computer vision technologies for plant phenotyping. *Computers and Electronics in Agriculture*, 2020, 176: 1-21
- [14] Pushpanathan K, Hanafi M, Mashohor S, Ilahi W F F. Machine learning in medicinal plants recognition: A review. *Artificial Intelligence Review*, 2020, 54(1): 1-23
- [15] Chen Y, Huang Y Q, Zhang Z Z, Wang Z, Liu B, Liu C H, Huang C, Dong S Y, Pu X J, Wan F H, Qiao X, Qian W Q. Plant image recognition with deep learning: A review. *Computers and Electronics in Agriculture*, 2023, 212: 1-17
- [16] 陈文博, 刘昌华, 刘春苔, 孙开琼. 基于GoogLeNet的稻米品种识别与碎米检测. *中国粮油学报*, 2023, 38(2): 146-152
- Chen W B, Liu C H, Liu C T, Sun K Q. Identification rice varieties and broken rice based on GoogLeNet. *Journal of the Chinese Cereals and Oils Association*, 2023, 38(2): 146-152
- [17] 倪建功, 杨昊岩, 李娟, 韩仲志. 基于改进型AlexNet的花生荚果品种识别. *花生学报*, 2021, 50(4): 14-22
- Ni J G, Yang H Y, Li J, Han Z Z. Variety identification of peanut pod based on improved AlexNet. *Journal of Peanut Science*, 50(4): 14-22
- [18] 孙孟研, 王佳, 马睿, 代东南, 刘起, 穆春华, 马德新. 基于注意力机制的轻量化VGG玉米籽粒图像识别模型. *中国粮油学报*, 2024, DOI: 10.20048/j.cnki.issn.1003-0174.000226
- Sun M Y, Wang J, Ma R, Dai D N, Liu Q, Mu C H, Ma D X. Image recognition model of light VGG maize kernel based on attention mechanism. *Journal of the Chinese Cereals and Oils Association*, 2024, DOI: 10.20048/j.cnki.issn.1003-0174.000226
- [19] 杨静, 郝润平, 张迎迎, 汪炜杰. 基于深度学习的中草药植物视觉识别方法研究. *中国体视学与图像分析*, 2023, 28(2): 203-211
- Yang J, Xi R P, Zhang Y Y, Wang W J. Visual identification on Chinese herbal medicine plants based on deep learning. *Chinese Journal of Stereology and Image Analysis*, 2023, 28(2): 203-211
- [20] Chen J, Han J, Liu C, Wang Y, Shen H, Li L. A deep-learning method for the classification of apple varieties via leaf images from different growth periods in natural environment. *Symmetry*, 2022, 14(8): 1-14
- [21] Tavakoli H, Alirezazadeh P, Hedayatipour A, Nasib A H B, Landwehr N. Leaf image-based classification of some common bean cultivars using discriminative convolutional neural networks. *Computers and Electronics in Agriculture*, 2021, 181: 1-11
- [22] Liu Y, Su J, Shen L, Lu N, Fang Y, Liu F, Song Y, Su B. Development of a mobile application for identification of grapevine (*Vitis vinifera* L.) cultivars via deep learning. *International Journal of Agricultural and Biological Engineering*, 2021, 14(5): 172-179
- [23] Mukasa P, Wakholi C, Faqeerzada M A, Amanah H Z, Kim H, Joshi R, Suh H K, Kim G, Lee H, Kim M S, Baek I, Cho B K. Nondestructive discrimination of seedless from seeded watermelon seeds by using multivariate and deep learning image analysis. *Computers and Electronics in Agriculture*, 2022, 194: 1-10
- [24] Chen C Y, Jing L H, Li H, Tang Y W, Chen F L. Individual tree species identification based on a combination of deep learning and traditional features. *Remote Sens-Basel*, 2023, 15(9): 1-25
- [25] He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition. *CoRR*, 2015, 8: 770-778
- [26] 黄林生, 罗耀武, 杨小冬, 杨贵军, 王道勇. 基于注意力机制和多尺度残差网络的农作物病害识别. *农业机械学报*, 2021, 52(10): 264-271
- Huang L S, Luo Y W, Yang X D, Yang G J, Wang D Y. Crop disease recognition based on attention mechanism and multi-scale residual network. *Transactions of the Chinese Society for Agricultural Machinery*, 2021, 52(10): 264-271
- [27] Chen Z, Jiang Y, Zhang X, Zheng R, Qiu R, Sun Y, Zhao C, Shang H. ResNet18DNN: Prediction approach of drug-induced liver injury by deep neural network with ResNet18. *Briefings in Bioinformatics*, 2022, 23(1): 1-9
- [28] Huang H, You Z, Cai H, Xu J, Lin D. Fast detection method for prostate cancer cells based on an integrated resnet50 and yolov5 framework. *Computer Methods and Programs in Biomedicine*, 2022, 226: 1-8
- [29] Al-Gaashani M S A M, Samee N A, Alnashwan R, Khayyat M, Muthanna M S A. Using a resnet50 with a kernel attention mechanism for rice disease diagnosis. *Life*, 2023, 13(6): 1-14
- [30] Mahmood Khan R N, Hussain L, Alluhaidan A S, Majid A, Lone K J, Verdiyev R, Al-Wesabi F N, Duong T Q. Covid-19 lung infection detection using deep learning with transfer

- learning and resnet101 features extraction and selection. *Waves in Random and Complex Media*, 2022, 18: 1-24
- [31] Szegedy C, Liu W, Jia Y Q, Sermanet P, Reed S, Anguelov D, Erhan D, Vanhoucke V, Rabinovich A. Going deeper with convolutions. *CoRR*, 2014, 7: 1-9
- [32] 林景栋, 吴欣怡, 柴毅, 尹宏鹏. 卷积神经网络结构优化综述. *自动化学报*, 2020, 46(01): 24-37
- Lin J D, Wu X Y, Chai Y, Yin H P. Structure optimization of convolutional neural networks: A survey. *Acta Automatica Sinica*, 2020, 46(1): 24-37
- [33] 张驰, 郭媛, 黎明. 人工神经网络模型发展及应用综述. *计算机工程与应用*, 2021, 57(11): 57-69
- Zhang C, Guo Y, Li M. Review of development and application of artificial neural network models. *Computer Engineering and Applications*, 2021, 57(11): 57-69
- [34] 方宇伦, 陈雪纯, 杜世昌, 吕君, 王勇. 基于轻量化深度学习 VGG16 网络模型的表面缺陷检测方法. *机械设计与研究*, 2023, 39(2): 143-147
- Fang Y L, Chen X C, Du S C, Lv J, Wang Y. Surface defect detection method based on lightweight deep learning VGG16 network model. *Machine Design & Research*, 2023, 39(2): 143-147
- [35] Selvaraju R R, Cogswell M, Das A, Vedantam R, Parikh D, Batra D. Grad-cam: Visual explanations from deep networks via gradient-based localization. *International Journal of Computer Vision*, 2020, 128(2): 336-359
- [36] Cheng Y L, Yang S Q, Liu X, Zhang E Y, Song Z S. Identification of wine grape varieties based on near-infrared hyperspectral imaging. *Applied Engineering in Agriculture*, 2019, 35(6): 959-967
- [37] Pereira C S, Morais R, Reis M J C S. Deep learning techniques for grape plant species identification in natural images. *Sensors*, 2019, 19(22): 1-22
- [38] Barhate D, Pathak S, Dubey A K. Hyperparameter-tuned batch-updated stochastic gradient descent: Plant species identification by using hybrid deep learning. *Ecological Informatics*, 2023, 75: 1-10