

代国威,陈稼瑜,樊景超. 融合 ResNet 与支持向量机的葡萄园冠层图像叶片覆盖度分类[J].江苏农业学报,2023,39(8): 1713-1721.  
doi:10.3969/j.issn.1000-4440.2023.08.011

# 融合 ResNet 与支持向量机的葡萄园冠层图像叶片覆盖度分类

代国威<sup>1,2</sup>, 陈稼瑜<sup>3</sup>, 樊景超<sup>1,2</sup>

(1.中国农业科学院农业信息研究所,北京 100081; 2.国家农业科学数据中心,北京 100081; 3.浙江农林大学暨阳学院,浙江诸暨 311800)

**摘要:** 在视觉感知的基础上,实现作物智能喷洒作业管理是智慧农业重要的组成部分。针对葡萄园智能喷洒作业的需要,本研究构建了一种融合残差网络(ResNet)和支持向量机模型的葡萄园冠层图像叶片覆盖度分类方法。在对葡萄园冠层图像数据集进行数据增强的基础上,利用不同卷积层数的 ResNet 模型(ResNet-18、ResNet-34 和 ResNet-50)提取图像特征向量,结合近邻成分分析(NCA)算法及不同分类模型(Cubic SVM、RBF SVM、Linear SVM、DT、BT、Bayes、KNN、RF),筛选出最优葡萄园冠层图像叶片覆盖度分类方法。结果表明:残差网络模型卷积层数的增加,有利于提高模型的分类精度;葡萄园冠层图像叶片覆盖度适宜的分类方法是利用 ResNet-18、ResNet-34 和 ResNet-50 各提取1 000个特征向量,进一步利用 NCA 算法筛选出1 000个权重值较大的特征向量,并利用 Cubic SVM 模型进行分类。该方法较好实现了模型训练时间和分类精度的平衡,既能大幅减少冗余的特征向量,缩短训练时间,还可以保证模型的分类精度。该方法下模型的分类准确率、精确率、召回率分别达 98.32%、97.41%、98.73%。本研究建立的葡萄园冠层图像叶片覆盖度分类方法为智慧化的果园管理提供了有效的技术支持。

**关键词:** 残差网络; 支持向量机; 近邻成分分析; 葡萄园冠层; 叶片覆盖度; 分类

**中图分类号:** TP391.4;S24 **文献标识码:** A **文章编号:** 1000-4440(2023)08-1713-09

## Leaf coverage classification of vineyard canopy images based on ResNet and support vector machines

DAI Guo-wei<sup>1,2</sup>, CHEN Jia-yu<sup>3</sup>, FAN Jing-chao<sup>1,2</sup>

(1.Agricultural Information Institute, Chinese Academy of Agricultural Sciences, Beijing 100081, China; 2.National Agriculture Science Data Center, Beijing 100081, China; 3.Jiyang College, Zhejiang A&F University, Zhuji 311800, China)

**Abstract:** On the basis of visual perception, the realization of crop intelligent spraying operation management is an important part of intelligent agriculture. Aiming at the needs of intelligent spraying operations in vineyards, this study constructed a vineyard canopy image leaf coverage classification method that combines residual network (ResNet) and support vector machine model. Based on the data enhancement of the existing vineyard canopy image data set, the ResNet models

with different convolution layers (ResNet-18, ResNet-34 and ResNet-50) were used to extract image feature vectors. Combined with the nearest neighbor component analysis (NCA) algorithm and different classification models (Cubic SVM, RBF SVM, Linear SVM, DT, BT, Bayes, KNN, RF), the optimal vineyard canopy image leaf coverage classification method was screened. The results showed that the increase of the number of convolution layers of the residual network model could improve the classification ac-

收稿日期:2022-10-12

基金项目:国家重点研发计划项目(2021YFF0704200);中国农业科学院院级基本科研业务费项目(Y2022LM20);中国农业科学院科技创新工程项目(CAAS-ASTIP-2016-AII)

作者简介:代国威(1997-),男,四川德阳人,硕士研究生,主要从事人工智能及农业信息化研究。(Tel) 15623225909; (E-mail) dgwstyle@foxmail.com

通讯作者:樊景超, (E-mail) fanjingchao@caas.cn

curacy of the model. The suitable classification method of leaf coverage in vineyard canopy image was to extract 1 000 feature vectors by using ResNet-18, ResNet-34 and ResNet-50 respectively, and further use NCA algorithm to screen out 1 000 feature vectors with larger weight values, and use Cubic SVM model for classification. This method could realize a good balance between model training time and classification accuracy. It could not only greatly reduce redundant feature vectors, shorten training time, but also ensure the classification accuracy of the model. The classification accuracy, precision and recall rate of the model under this method were 98.32%, 97.41% and 98.73% respectively. The leaf coverage classification method of vineyard canopy image established in this study provides effective technical support for intelligent orchard management.

**Key words:** residual network; support vector machine; neighborhood component analysis; canopy of vineyard; leaf coverage; classification

葡萄是世界四大果树之一,种植面积广,经济效益高。根据国际葡萄和葡萄酒组织(OIV)的最新统计数据,近年来世界葡萄种植面积稳定在约 $7.4 \times 10^6$  hm<sup>2</sup><sup>[1]</sup>。喷洒肥料和农药是葡萄种植的主要工作,约占葡萄园每年总用工量的20%~30%<sup>[2]</sup>。由于人工喷洒作业效率低、工作量大,因此,智能化的葡萄园喷洒管理不但能实现葡萄产业提质增效,同时还能保护种植者免受农药的为害。

智能喷洒系统一般包括作物生长状态的图像采集、图像数据分析及喷洒设备的控制等部分组成。其中图像数据分析是系统中的关键。目前图像数据分析大多利用机器学习模型得以实现。卷积神经网络作为一种通用的机器学习模型,已成功应用于多种环境下的图像识别<sup>[3-7]</sup>。翟先一等<sup>[8]</sup>基于改进的YOLO卷积神经网络实现水下海参检测;Dai等<sup>[9]</sup>通过图像与文本跨模态特征融合技术识别枸杞害虫。增加卷积层数会提高模型的表达能力和准确率,但在数据不足或卷积层数过多时,也容易出现训练时误差增加、梯度消失和梯度爆炸等问题<sup>[10-12]</sup>。2015年He等<sup>[13]</sup>提出了一种深度卷积神经网络模型ResNet,较好地解决了模型深度增加时的过拟合问题,推动了深层网络模型的发展。李颀等<sup>[14]</sup>采用残差网ResNet-50作为特征提取主干层改进Faster R-CNN,提高了对葡萄果粒与果穗的检测准确率。Saeed等<sup>[15]</sup>采用结合Inception和ResNet的Inception ResNet V2模型对番茄病害进行预测,识别准确率达99.22%。近年来,模型融合技术在图像识别中得到了初步应用。一般认为模型融合能较好解决模型精度和训练时间的平衡,是智慧农业模型开发的新热点<sup>[16]</sup>。Wang等<sup>[17]</sup>提出一种基于ResNeXt网络和支持向量机(SVM)的草莓外观品质识别方法,利用ResNeXt提取草莓图像的深层特征,然后将

这些特征输入到SVM中,进而实现草莓外观品质的识别,识别准确率比单纯的ResNeXt模型提高了1.42%。Bal等<sup>[18]</sup>利用具有5个卷积层和1个全连接层的卷积神经网络(CNN)模型和SVM融合进行苹果产量预测,准确率达99.70%,比单纯利用CNN模型提高了9.71个百分点。

智能喷洒系统需要根据喷洒范围内植物长势进行喷洒量的调整,以实现高效和节约化管理。针对葡萄园智能喷洒系统中喷洒范围内的冠层密度大小自动化分类研究较少的现状,提出一种融合残差网络与支持向量机的葡萄园冠层图像精确分类方法,该方法利用3个不同卷积层数的ResNet模型(ResNet-18、ResNet-34、ResNet-50)提取葡萄园冠层图像不同区域的特征向量,同时利用近邻成分分析(NCA)算法降低特征向量维度,筛选获取权重系数高的特征向量,并比较9种分类模型的分类精度,筛选出葡萄园冠层图像叶片覆盖度适宜的分类方法,以期为进一步的葡萄园智能管理提供依据。

## 1 材料与方法

### 1.1 数据集的获取与预处理

本试验采用葡萄园冠层图像公开数据集(<https://www.agridata.cn/data.html#/datadetail?id=290328>)为数据源。该数据集包含475张图像样本,大小为640×480像素,JPG格式,由安装在静态机器人上的立体摄像机从葡萄园中采集。

数据集的每张图像都经过农艺师利用Labelme软件进行手动注释,建立图像不同区块的属性信息。由于Labelme标注的信息含有较多的冗余数据,不利于机器学习,研究中为了方便仅保留不同区块的类型信息。研究中设定葡萄园喷洒系统中具有3个喷头,分别对应冠层上部、中部和下部,因而葡萄园

冠层图像被分为上、中、下 3 个区域。为方便电控系统调节喷洒量,这些区域的大小应该保持一致(图 1)。通过对葡萄冠层图像数据观察分析,葡萄冠层叶片覆盖度可划分为 4 个等级,分别为 0、33%、66% 与 100%。当区域没有葡萄叶片时,冠层等级定义

为 0;当有一些叶子,但叶片覆盖面积低于区域总面积的一半时,定义为 33%;如果区域 50% 及以上面积被葡萄叶覆盖,但尚未完全覆盖时,定义为 66%,当整个区域被葡萄叶完全覆盖时,定义为 100%。

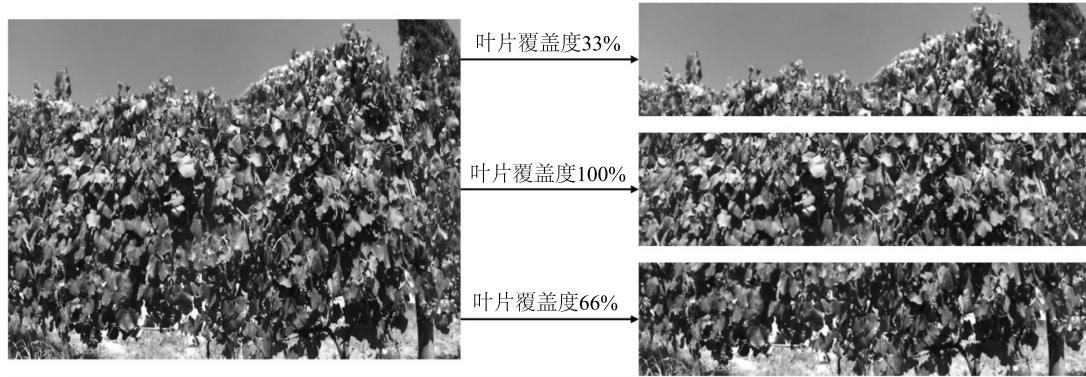


图 1 葡萄冠层叶片覆盖度分级数据图像

Fig.1 Image of grapevine canopy leaf coverage grading data

## 1.2 数据增强方法

神经网络要达到较好的分类效果,合适的样本容量尤为重要。考虑到环境与成本等因素,深度学习中常用数据增强的方法来丰富数据集,一方面可以提高模型的鲁棒性,另一方面还能缓解模型的过拟合问题<sup>[19-22]</sup>。当然针对不同的研究对象及环境,使用的数据增强方法也存在一定的差异<sup>[23-27]</sup>。通用的图像数据增强方法有平移、缩放、剪切、翻转与旋转等,但考虑葡萄园生长环境中可能出现的雾气、太阳光照、阴影等现象<sup>[28]</sup>,本研究采用通用数据增强与自然环境变化特征的数据增强相结合的组合数据增强方法实现原始数据集的扩充。具体的数据增强方法有水平镜像翻转、运动模糊变换、亮度对比度变换、数字噪声变换、降低图像质量处理、泥飞溅变换、雾气变换、太阳光照变换、阴影变换。采用 Python 软件和图像增强数据库 Albumentations 进行图像增强的实现<sup>[29]</sup>。

数据增强处理的参数设置如下:水平镜像翻转中旋转角度为 180°;运动模糊变换中模糊阈值设为 5;亮度对比度处理中,对比度按照均值调整,其他参数均设置为 0.1。数字噪声处理中以图像中随机某个像素乘 1.5,改变图像原有属性增加噪点;降低图像质量处理通过缩小和放大图像实现。泥飞溅处理以模拟泥土飞溅导致的镜头遮挡,泥土正态分布的

参数均值和方差分别设置为 0.65 和 0.35。雾气处理时使用随机雾气变换,使得背景模糊,雾气圈透明度设为 0.15,雾气强度在 0.1~0.5 随机取值。太阳光照处理的参数设置为 (0,0,1.0,0.5),其中,(0,0)为起始坐标,(1.0,0.5)为结束坐标。阴影处理中多边形的参数边设置为 4,阴影数量在 1~5 浮动,数据增强效果如图 2 所示。

随机组合以上具体的数据增强方法,各方法执行机会概率设定为 0.5。应用组合数据增强方法在 475 张葡萄园冠层图像中,每张图像执行 5 次增强,加上原始图像,最终获得 2 850 张图像样本构成增强数据集。增强数据集按 8:2 分为训练集和验证集,即训练集与验证集分别为 2 280 与 570 张图像。

## 1.3 葡萄园冠层图像叶片覆盖度分类相关算法

鉴于残差网络模型在图像识别中的优势,本研究基于不同深度残差网络 (ResNet-18、ResNet-34、ResNet-50) 的图像特征自动化提取、近邻成分分析 (Neighborhood Component Analysis, NCA) 算法的特征向量选择及多项式核支持向量机 (Cubic SVM) 对葡萄园冠层图像叶片覆盖度特征进行分类。

1.3.1 残差网络 (ResNet) 卷积神经网络 (CNN) 是深度学习模型中最受欢迎的架构之一。传统的 CNN 在处理图像数据时面临两个主要问题:一是随着图像像素数量的增加,神经元数量同步增加;二是



全连接层网络结构未考虑图像数据中的空间信息,因此传统 CNN 不适合处理图像数据。为了解决这些问题,一些学者提出了深度 CNN,它由多组卷积层计算、批量归一化、激活操作和下采样组成的多层结构堆叠而成,是深度学习中最重要图像处理算法之一。深度 CNN 具有学习能力强、参数较少和训

练方便的优势。深度 CNN 以数据驱动的方式自动学习及图像特征提取,并且提取的图像特征具有平移不变性,这是其适合处理图像数据的主要原因。深度 CNN 目前已被广泛应用于图像分类、图像处理、图像检测等方面<sup>[30-34]</sup>。




图 2 数据增强方法的应用效果

Fig.2 Application effect of data augmentation methods

然而,深度 CNN 的卷积层加深会导致训练精度下降,网络结构变得难以优化。为克服这个问题,He 等<sup>[13]</sup>提出了深层残差网络。深层残差网络具有卷积层、池化层、激活层和全连接层等结构,其核心思想是将每一层的信息直接输出,不会随着网络层数的增加而导致性能退化。通过增加网络层数,深层残差网络在一定程度上提高了准确率,同时保持了特征提取的完整性。在本研究中,采用逐渐增加深度的 ResNet-18、ResNet-34 和 ResNet-50 作为预训练的深度残差网络,这些网络能够保持较高的特征抽象能力。

**1.3.2 近邻成分分析(NCA)算法** 特征选择是机器学习的关键步骤之一。特征选择的目的在于提高分类模型的分类速度和模型性能。近邻成分分析

(NCA)算法是机器学习中常用的特征选择器,是欧氏距离测量的一种替代算法<sup>[35]</sup>。NCA 中利用马氏距离生成权重,使用一种类似于 K 最近邻(K-nearest neighbor, KNN)的技术来寻找若干区域,区域中所有数据点共享相同标签,且具有相同标签的数据点之间的距离低于具有不同标签的数据点之间的距离。NCA 中通过距离来确定权重,较低的权重表示冗余特征,较高的权重定义为信息特征。

**1.3.3 多项式核支持向量机(Cubic SVM)** 支持向量机(SVM)是一种机器学习算法,通过对数据的学习训练,进而实现数据的分类或建模<sup>[36]</sup>。SVM 在可分离数据、不可分离数据和非线性数据等 3 类数据的分类上有较多应用。对于可分离数据,SVM 通过选择最佳超平面来完成分类;对于不可分离数据,

SVM 使用软边界实现数据的分类;对于非线性数据,SVM 利用带核函数的非线性变换进行处理,即基于核函数再生理论,在多维空间中找到一个超平面,保留简单 SVM 超平面分离的所有基本特征<sup>[37]</sup>。与线性 SVM 相比,多项式核 SVM 更适合处理困难的分类工作。本研究中利用 3 次多项式核支持向量机(Cubic SVM)处理非线性数据。

#### 1.4 葡萄园冠层图像叶片覆盖度分类方法比较

1.4.1 特征向量生成方式筛选 利用 ResNet-18、ResNet-34 和 ResNet-50 各自提取的 1 000 个特征向量、合并后得到的 3 000 个特征向量及合并后再利用 NCA 算法提取的 1 000 个优化特征向量,分别利用 Cubic SVM 分类模型进行分类(表 1),比较不同深度残差网络特征向量生成方式及 NCA 算法对分类精度及训练时间的影响,筛选出合适的特征向量生成方式。

表 1 特征向量生成方式设计方案

Table 1 Design scheme of feature vector generation method

试验编号	特征向量生成模型	特征向量数量(个)	NCA 算法应用	分类模型
T1	ResNet-18	1 000	-	Cubic SVM
T2	ResNet-34	1 000	-	Cubic SVM
T3	ResNet-50	1 000	-	Cubic SVM
T4	ResNet-18、ResNet-34、ResNet-50	3 000	-	Cubic SVM
T5	ResNet-18、ResNet-34、ResNet-50	3 000	✓	Cubic SVM

-表示不应用 NCA 算法,✓表示应用 NCA 算法。

1.4.2 不同分类模型比较 在筛选出合适的特征向量生成方式的基础上,进一步利用不同的机器学习分类模型,包括多项式核支持向量机(Cubic SVM)、高斯核支持向量机(RBF SVM)、线性支持向量机(Linear SVM)、决策树(Decision tree,DT)、高斯贝叶斯(Gaussian Naive Bayes,GNB)、袋装树(Bagged tree,BT)、K 最近邻(K-Nearest neighbor,KNN)、余弦 K 最近邻(Cosine KNN)和随机森林(Random forest,RF),进行葡萄园冠层图像叶片覆盖度分类,比较不同分类模型下的分类精度,筛选出适宜的分类模型。

1.4.3 消融验证试验 为比较不同深度 ResNet 网络生成的特征向量及 NCA 算法对葡萄冠层图像叶面积覆盖度分类的影响,开展的消融试验如表 2 所示。试验 1~3 分别直接利用 ResNet-18、ResNet-34

和 ResNet-50 模型进行分类;试验 4~6 分别利用 ResNet-18、ResNet-34 和 ResNet-50 网络模型各自输出 3 000 个特征向量的基础上,基于 NCA 算法选择 1 000 个优化特征向量,再利用 Cubic SVM 进行分类;试验 7 利用 ResNet-18 与 ResNet-34 网络模型分别输出 1 500 个特征向量,基于 NCA 算法选择 1 000 个优化特征向量,再利用 Cubic SVM 进行分类;试验 8 利用 ResNet-18、ResNet-34 和 ResNet-50 网络模型各自输出 1 000 个特征向量的基础上,基于 NCA 算法选择 1 000 个优化特征向量,再利用 Cubic SVM 进行分类。

表 2 消融验证试验设计方案

Table 2 Design scheme of ablation verification test

试验编号	特征向量生成模型	特征向量数量(个)	NCA 算法应用情况	分类模型
X1	-	-	-	ResNet-18
X2	-	-	-	ResNet-34
X3	-	-	-	ResNet-50
X4	ResNet-18	3 000	✓	Cubic SVM
X5	ResNet-34	3 000	✓	Cubic SVM
X6	ResNet-50	3 000	✓	Cubic SVM
X7	ResNet-18+ ResNet-34	1 500+ 1 500	✓	Cubic SVM
X8	ResNet-18+ ResNet-34+ ResNet-50	1 000+ 1 000+ 1 000	✓	Cubic SVM

-表示不应用 NCA 算法,✓表示应用 NCA 算法。

#### 1.5 试验平台及参数设置

本试验在移动图形工作站进行,主要算法由微软 VSCode 和 Python3.9 执行,采用 Pytorch 深度学习框架,使用图形处理器(GPU)加速图像处理,图像绘制选择 Matplotlib。操作系统采用 Windows11 专业工作站版,英特尔酷睿 i7-11800H 处理器,存储器选择第四代 DDR4,32.00 GB 内存,显卡 NVIDIA GeForce RTX 3060 Laptop,6 GB 显存。

基于残差网络模型提取葡萄冠层图像特征研究中,输入图像模式被转换为 RGB,残差网络输入层大小设定为 224×256,通道数为 3。为统一残差网络模型提取特征向量的输出大小,冻结 ResNet-18、ResNet-34 与 ResNet-50 模型主干特征提取层的权重参数,并设置全连接层输出大小为 1 000;ResNet-50 使用 IMAGENET1K\_V2 权重参数,ResNet-18 与 ResNet-34 采用 IMAGENET1K\_V1 权重参数。

## 1.6 模型性能评价指标

本研究中使用准确率 (*Accuracy*)、精确率 (*Precision*)、召回率 (*Recall*) 与 Kappa 系数等 4 个常用的指标评价模型的性能。算法如下:

$$Accuracy = \frac{TP+TN}{TP+FP+TN+FN} \quad (1)$$

$$Precision = \frac{TP}{TP+FP} \quad (2)$$

$$Recall = \frac{TP}{TP+FN} \quad (3)$$

$$Kappa = \frac{p_a - p_g}{1 - p_g} \quad (4)$$

式中, *TP* 表示正确划分为正样本的个数; *FP* 表示错误划分为正样本的个数; *FN* 表示错误划分为负样本的个数; *TN* 表示正确划分为负样本的个数。  $p_a$  表示预测正确的样本量除以总样本数, 可称之为总分类精度;  $p_g$  为实际样品数量与预测的样品数量的乘积除以样本总数的平方。

## 2 结果与分析

### 2.1 不同分类模型的分类性能

基于增强后的葡萄冠层图像数据, 依据表 1 不同特征向量生成模型, 模型训练时间和测试精度如表 3 所示。从表 3 中可以看出, 基于 ResNet-50 模型提取 1 000 个特征向量的分类效果高于 ResNet-18 模型和 ResNet-34 模型。基于 ResNet-18、ResNet-34、ResNet-50 模型各提取 1 000 个特征向量再进行分类, 准确率达到 97.42%, 然而训练时间却持续了 170.91 s。虽然准确率比基于 ResNet-50 模型提取 1 000 个特征向量的分类准确率提高了 0.63%, 但训练时间却多了 107.90 s。而基于 ResNet-18、ResNet-34、ResNet-50 模型各提取 1 000 个特征向量再利用 NCA 算法筛选得到特征权重较大的前 1 000 个特征向量再进行分类, 准确率达到 98.32%, 训练时间比 ResNet-50 模型仅多 19.41 s, 比基于 ResNet-18、ResNet-34、ResNet-50 模型得到的 3 000 个特征向量未经 PCA 算法筛选直接分类节约了 51.8% 的训练时间, 准确率提高了 0.90 个百分点。

基于 ResNet-18、ResNet-34、ResNet-50 模型各提取 1 000 个特征向量, 利用 NCA 算法筛选得到权重较大的前 1 000 个特征向量, 再利用不同分类模型进行分类, 分类结果如表 4 所示。从表中可以看出, Cubic

SVM 模型的准确率和 Kappa 值分别为 98.32% 和 0.932, 优于其他分类模型; 其次为 RBF SVM 模型和 RF 模型, 准确率分别为 98.01% 和 97.95%, 而 Linear SVM 模型分类精度相对较低, 为 97.45%。综上, 利用 ResNet-18、ResNet-34、ResNet-50 特征向量生成模型分别提取 1 000 个特征向量, 再利用 NCA 算法筛选 1 000 个权重较大的特征向量以消除冗余的特征向量, 既显著提高了分类的准确率, 又降低了训练时间。Cubic SVM 分类模型为葡萄园冠层图像叶片覆盖度最适分类模型。

表 3 特征向量生成方式对模型训练时间和测试精度的影响

Table 3 Impact of feature vector generation method on model training time and test accuracy

试验编号	准确率 (%)	精确率 (%)	召回率 (%)	训练时间 (s)
T1	93.52	91.58	92.57	38.42
T2	94.15	95.31	94.69	50.44
T3	96.79	96.54	97.24	63.01
T4	97.42	96.96	97.69	170.91
T5	98.32	97.39	98.98	82.42

试验编号 T1、T2、T3、T4、T5 见表 1。

表 4 不同分类模型的分类精度比较

Table 4 Comparison of classification accuracy of different types of classifiers

分类模型	准确率 (%)	精确率 (%)	召回率 (%)	Kappa 系数
决策树 (DT)	83.48	79.89	83.67	0.778
多项式核支持向量机 (Cubic SVM)	98.32	97.39	98.98	0.932
高斯核支持向量机 (RBF SVM)	98.01	97.24	97.87	0.921
高斯贝叶斯 (GNB)	88.63	88.96	88.34	0.839
K 最近邻 (KNN)	96.59	97.21	96.22	0.814
线性支持向量机 (Linear SVM)	97.45	96.17	98.78	0.839
余弦 K 最近邻 (Cosine KNN)	95.64	96.17	95.69	0.743
袋装树 (BT)	97.75	96.77	98.53	0.875
随机森林 (RF)	97.95	96.87	98.58	0.907

### 2.2 消融验证结果分析

依据表 2 消融验证试验设计方案进行验证, 结果如表 5 所示。仅利用 ResNet-18、ResNet-34、ResNet-50 模型分类时, 分类准确率仅为 82.15%、89.78%、



91.62%,而基于 ResNet-18、ResNet-34、ResNet-50 模型各提取3 000个特征向量结合 NCA 算法和 Cubic SVM 模型后,分类的准确率分别达到 94.32%、94.85%、97.16%,精确率和召回率亦有较大提升。同时亦可以看出,随着 ResNet 模型深度的增加,分类的准确率逐步提升。ResNet-50 模型生成特征向量后结合 NCA 算法和 Cubic SVM 模型的分类准确率高于 ResNet-18 与 ResNet-34 结合生成特征向量后融合 NCA 算法和 Cubic SVM 模型分类准确率,但低于 ResNet-18、ResNet-34 和 ResNet-50 结合生成特征向量后融合 NCA 算法和 Cubic SVM 模型分类准确率,说明单个 ResNet-18 模型或 ResNet-34 模型提取的特征向量代表性比 ResNet-50 模型要差,但 ResNet-18 模型或 ResNet-34 模型对 ResNet-50 模型起一定的补充作用。本研究中,ResNet 模型提取的特征向量结合 Cubic SVM 模型后,分类准确率一般都在 90%以上,说明本研究利用 3 种不同深度的 ResNet 模型提取葡萄园冠层图像的特征向量获得了不同尺度与多个维度的图像特征,具有较高的代表性和合理性。基于 ResNet-18、ResNet-34、ResNet-50 模型提取3 000个特征向量结合 NCA 算法获取1 000个权重较大的特征向量比分别基于上述模型直接获取1 000个特征向量,再结合 Cubic SVM 模型分类结果要略高(表 3、表 5),说明扩大输出特征值与使用 NCA 筛选权重较大的特征向量能够提升分类准确率,但可能要增加分类时间。另外,ResNet-50 模型无论是单独使用还是与 Cubic

SVM 模型结合使用,所获得的性能表现在同等试验条件下都表现最优,这说明较深的 ResNet 网络结构能够提取更加深层的特征。

表 5 ResNet 融合支持向量机(Cubic SVM)的消融试验

Table 5 ResNet fusion support vector machine (Cubic SVM) for ablation experiments

试验编号	准确率(%)	精确率(%)	召回率(%)
X1	82.15	80.72	81.59
X2	89.78	90.24	87.46
X3	91.62	89.98	88.96
X4	94.32	92.18	93.87
X5	94.85	95.69	94.92
X6	97.16	96.92	98.18
X7	96.26	95.98	96.94
X8	98.32	97.39	98.98

试验编号 X1、X2、X3、X4、X5、X6、X7、X8 见表 2。

### 2.3 数据增强性能分析

不同数据集下,验证集预测效果如表 6 所示。从表中可以看出,利用增强数据集的平均准确率达 98.32%,比利用原始数据集的提高 8.68 个百分点;平均精确率与平均召回率分别提高 8.23 个百分点和 9.87 个百分点。数据增强后 4 类叶片覆盖度的葡萄冠层图像的识别准确率均有不同程度的提高,其原因在于增强数据集中包含在机械抖动、环境干扰等因素下得到的数据,因而其图像特征更为丰富。

表 6 增强数据集下验证集的分类效果

Table 6 Classification accuracy of validation set under enhanced data set

数据集	评价指标 (%)	冠层叶片覆盖度等级				平均值
		33%	100%	66%	0%	
增强数据集	准确率	98.01	98.36	98.61	98.30	98.32
	精确率	97.46	96.89	97.54	97.74	97.41
	召回率	98.68	98.53	99.12	98.59	98.73
原始数据集	准确率	88.94	89.86	90.12	89.64	89.64
	精确率	88.72	89.22	89.35	89.44	89.18
	召回率	88.61	88.78	88.98	89.06	88.86

## 3 结 论

为了适应果园智慧化管理的需求,本研究在图

像增强的基础上,基于 ResNet 网络模型、NCA 算法及 SVM 模型,通过不同的特征向量提取方式及分类模型比较试验和消融试验,提出了葡萄园冠层图像

叶片覆盖度分类方法,结论如下:

①ResNet-18、ResNet-34 与 ResNet-50 组合提取的特征向量具有相互补充的作用,捕获的特征信息具备多尺度的特性。组合特征向量及 NCA 算法的应用既节约了训练时间又能提高分类器的分类精度。Cubic SVM 作为最优 SVM 分类器取得了 98.32% 准确率,与距离度量和集成学习分类器相比,该分类器具有明显优势。

②原始数据图像经过组合增强处理后,分类结果的准确率平均提高 8.68 个百分点,表明原始图像组合增强处理提高了 ResNet 网络模型的泛化和鲁棒性。相较于传统的数据增强方案,组合数据增强处理能够提高特征的表达能力,并适应自然环境下自动化喷洒装备的高效作业。

③融合 ResNet 与 Cubic SVM 对葡萄冠层进行精确分类体现出了一定的优势,平均准确率与精确率都得到了提高。

在冠层叶片覆盖度感知的基础上,进一步进行喷洒量的设计,进而实现农药与肥料的精准管控,因此,本研究对果园的智慧化管理具体一定的参考意义。当然本研究中冠层图像叶片覆盖度的分类标准有点少,在今后的研究中,还需要优化算法,实现更为精细的冠层图像叶片覆盖度预测。

## 参考文献:

- [1] ZHU M, LIU Z, ZENG Y, et al. Nordihydroguaiaretic acid reduces postharvest berry abscission in grapes[J]. *Postharvest Biology and Technology*, 2022, 183: 111748.
- [2] BALTAZAR A R, SANTOS F N, MOREIRA A P, et al. Smarter robotic sprayer system for precision agriculture[J]. *Electronics*, 2021, 10(17): 2061.
- [3] 胡玲艳,周 婷,刘 艳,等. 基于轻量级网络自适应特征提取的番茄病害识别[J]. *江苏农业学报*, 2022, 38(3): 696-705.
- [4] MALLIKARJUNA S B, SHIVAKUMARA P, KHARE V, et al. Multi-gradient-direction based deep learning model for arecanut disease identification [J]. *CAAI Transactions on Intelligence Technology*, 2022, 7(2): 156-166.
- [5] 赵恒谦,杨屹峰,刘泽龙,等. 农作物叶片病害迁移学习分步识别方法[J]. *测绘通报*, 2021(7): 34-38.
- [6] YANG J, ZHANG T, FANG C, et al. A defencing algorithm based on deep learning improves the detection accuracy of caged chickens [J]. *Computers and Electronics in Agriculture*, 2023, 204: 107501.
- [7] 李科岑,王晓强,林 浩,等. 深度学习中的单阶段小目标检测方法综述[J]. *计算机科学与探索*, 2022, 16(1): 41-58.
- [8] 翟先一,魏鸿磊,韩美奇,等. 基于改进 YOLO 卷积神经网络的水下海参检测[J]. *江苏农业学报*, 2023, 39(7): 1543-1553.
- [9] DAI G, FAN J, DEWI C. ITF-WPI: Image and text based cross-modal feature fusion model for wolfberry pest recognition [J]. *Computers and Electronics in Agriculture*, 2023, 212: 108129.
- [10] SHE J, ZHAN W, HONG S, et al. A method for automatic real-time detection and counting of fruit fly pests in orchards by trap bottles via convolutional neural network with attention mechanism added[J]. *Ecological Informatics*, 2022, 70: 101690.
- [11] CHEN X, CHENG Z, WANG S, et al. Atrial fibrillation detection based on multi-feature extraction and convolutional neural network for processing ECG signals[J]. *Computer Methods and Programs in Biomedicine*, 2021, 202: 106009.
- [12] TSALERA E, PAPADAKIS A, SAMARAKOU M, et al. Feature extraction with handcrafted methods and convolutional neural networks for facial emotion recognition[J]. *Applied Sciences*, 2022, 12(17): 8455.
- [13] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. *IEEE: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016: 770-778.
- [14] 李 颀,杨 军. 基于多分辨率特征融合的葡萄尺寸检测[J]. *江苏农业学报*, 2022, 38(2): 394-402.
- [15] SAEED A, ABDEL-AZIZ A A, MOSSAD A, et al. Smart detection of tomato leaf diseases using transfer learning-based convolutional neural networks[J]. *Agriculture*, 2023, 13(1): 139.
- [16] KOK Z H, MOHAMED S A R, ALFATNI M S M, et al. Support vector machine in precision agriculture: a review[J]. *Computers and Electronics in Agriculture*, 2021, 191: 106546.
- [17] WANG G, ZHENG H, LI X. ResNeXt-SVM: a novel strawberry appearance quality identification method based on ResNeXt network and support vector machine[J]. *Journal of Food Measurement and Characterization*, 2023, 17(5): 4345-4356.
- [18] BAL F, KAYAALP F. A novel deep learning-based hybrid method for the determination of productivity of agricultural products: Apple case study[J]. *IEEE Access*, 2023, 11: 7808-7821.
- [19] LIU B, TAN C, LI S, et al. A data augmentation method based on generative adversarial networks for grape leaf disease identification [J]. *IEEE Access*, 2020, 8: 102188-102198.
- [20] AL-WESABI F N, ALBRAIKAN A A, HILAL A M, et al. Artificial intelligence enabled apple leaf disease classification for precision agriculture[J]. *Cmc-Computers Materials & Continua*, 2022, 70(3): 6223-6238.
- [21] 李 颀,陈哲豪. 基于改进单次多目标检测器的果面缺陷冬枣实时检测[J]. *江苏农业学报*, 2022, 38(1): 119-128.
- [22] LI L, QIAO J, YAO J, et al. Automatic freezing-tolerant rapeseed material recognition using UAV images and deep learning [J]. *Plant Methods*, 2022, 18: 5.
- [23] KARTHIKEYAN M, RAJA D. Deep transfer learning enabled DenseNet model for content based image retrieval in agricultural plant disease images [J]. *Multimedia Tools and Applications*,



- 2023,82:36067-36090.
- [24] LI K, WANG J, JALIL H, et al. A fast and lightweight detection algorithm for passion fruit pests based on improved YOLOv5[J]. Computers and Electronics in Agriculture,2023,204:107534.
- [25] SINGH P, SINGH P, FAROOQ U, et al. CottonLeafNet: cotton plant leaf disease detection using deep neural networks[J]. Multimedia Tools and Applications,2023,82:37151-37176.
- [26] QIAN S, DU J, ZHOU J, et al. An effective pest detection method with automatic data augmentation strategy in the agricultural field [J]. Signal, Image and Video Processing,2023,17(2):563-571.
- [27] NAN Y, ZHANG H, ZENG Y, et al. Faster and accurate green pepper detection using NSGA-II-based pruned YOLOv5l in the field environment[J]. Computers and Electronics in Agriculture, 2023,205:107563.
- [28] KHALIFA N E, LOEY M, MIRJALILI S. A comprehensive survey of recent trends in deep learning for digital images augmentation [J]. Artificial Intelligence Review, 2022,55:2352-2377.
- [29] BUSLAEV A, IGLOVNIKOV V I, KHVEDCHENYA E, et al. Albumentations: fast and flexible image augmentations[J]. Information,2020,11(2):125.
- [30] WENG Z, MENG F, LIU S, et al. Cattle face recognition based on a Two-Branch convolutional neural network[J]. Computers and Electronics in Agriculture,2022,196:106871.
- [31] DAI G, HU L, FAN J, et al. A deep learning-based object detection scheme by improving yolov5 for sprouted potatoes datasets [J]. IEEE Access,2022,10:85416-85428.
- [32] 储鑫,李祥,罗斌,等. 基于改进 YOLOv4 算法的番茄叶部病害识别方法[J]. 江苏农业学报,2023,39(5):1199-1208.
- [33] DAI G, HU L, FAN J. Da-actnn-yolov5: hybrid yolo v5 model with data augmentation and activation of compression mechanism for potato disease identification [J]. Computational Intelligence and Neuroscience,2022,2022:1-16.
- [34] 阮子行,黄勇,王梦,等. 基于改进卷积神经网络的番茄品质分级方法[J]. 江苏农业学报,2023,39(4):1005-1014.
- [35] KOC M, SUT S K, SERHATLIOGLU I, et al. Automatic prostate cancer detection model based on ensemble VGGNet feature generation and NCA feature selection using magnetic resonance images [J]. Multimedia Tools and Applications, 2022, 81(5): 7125-7144.
- [36] TAO T, WEI X. A hybrid CNN-SVM classifier for weed recognition in winter rape field[J]. Plant Methods,2022,18(1):29.
- [37] ZENONE T, VITALE L, FAMULARI D, et al. Application of machine learning techniques to simulate the evaporative fraction and its relationship with environmental variables in corn crops[J]. Ecological Processes,2022,11(1):758-771.

(责任编辑:石春林)