

doi:10.6041/j.issn.1000-1298.2023.01.040

基于深度学习与高光谱成像的蓝莓果蝇虫害无损检测

田有文^{1,2} 吴伟¹ 林磊^{1,2} 姜凤利^{1,2} 张芳¹

(1. 沈阳农业大学信息与电气工程学院, 沈阳 110866;

2. 农业农村部园艺作物农业装备重点实验室, 沈阳 110866)

摘要: 针对蓝莓果蝇虫害分类识别存在效率低、准确度差等问题,采用深度学习方法对采集的蓝莓高光谱图像进行数据处理与分析,以实现蓝莓果蝇虫害的无损检测。首先蓝莓高光谱图像采用PCA进行降维,优选数据集PC2与PC3并进行拼接得到最佳数据集PC23,对数据集中图像进行旋转90°、旋转180°、模糊、高亮、低亮、镜像和高斯噪声共7种增强操作,使各数据集容量扩增为原始容量的18倍。然后采用VGG16、InceptionV3与ResNet50深度学习模型对蓝莓果蝇虫害图像进行检测,均取得了较高的识别准确率。其中ResNet50模型效率最高,且ResNet50模型的准确率最高,达到92.92%,损失率最低,仅有3.08%,因此ResNet50模型在蓝莓果蝇虫害无损检测方面整体识别效果最佳。为了进一步提高蓝莓果蝇虫害无损检测性能,从ECA注意力模块、Focal Loss损失函数与Mish激活函数3方面对ResNet50模型进行了改进,构建了改进的im-ResNet50模型。得出im-ResNet50模型识别准确率达95.69%,损失率为1.52%。试验结果表明,im-ResNet50模型有效提升了蓝莓果蝇虫害识别能力。采用Grad-CAM分析了im-ResNet50模型可解释性,能够快速、准确地无损检测蓝莓果蝇虫害。

关键词: 蓝莓果蝇虫害; 无损检测; im-ResNet50模型; 高光谱成像

中图分类号: S24; TP391.4 文献标识码: A 文章编号: 1000-1298(2023)01-0393-09

OSID:

Nondestructive Detection of Blueberry Fruit Fly Pests Based on Deep Learning and Hyperspectral Imaging

TIAN Youwen^{1,2} WU Wei¹ LIN Lei^{1,2} JIANG Fengli^{1,2} ZHANG Fang¹

(1. College of Information and Electrical Engineering, Shenyang Agricultural University, Shenyang 110866, China

2. Key Laboratory of Horticultural Equipment, Ministry of Agriculture and Rural Affairs, Shenyang 110866, China)

Abstract: Aiming at the problems of low efficiency and poor accuracy in the classification and recognition of blueberry fruit fly pests, a deep learning method was proposed to process and analyze the collected blueberry hyperspectral images, so as to realize the nondestructive detection of blueberry fruit fly pests. Firstly, the dimension of blueberry hyperspectral image was reduced by PCA. And the better data set PC2 and PC3 was selected. The best data set PC23 was obtained by splicing PC2 and PC3. The seven enhancement operations were performed on the images in the dataset, including 90° rotation, 180° rotation, blur, brightness adjustment, mirror image and Gaussian noise, so as to expand the capacity of each data set to 18 times of the original capacity. Then the three deep learning models of VGG16, InceptionV3 and ResNet50 were used to recognize and detect blueberry fruit fly pest images, and high recognition accuracy was achieved. Among them, ResNet50 model had the highest efficiency, and the accuracy of ResNet50 model was the highest, reaching 92.92%, and the loss rate was the lowest, only 3.08%. Therefore, ResNet50 model had the best overall recognition effect on the nondestructive detection of blueberry fruit fly pests. Finally, an improved im-ResNet50 model was constructed based on ResNet50 model from three aspects: ECA attention module, Focal Loss loss function and Mish activation function. The recognition accuracy of im-ResNet50 model was 95.69%, and the loss rate was reduced to 1.52%. The results showed that im-ResNet50 model effectively improved the pest identification ability of blueberry fruit fly. The interpretability of im-ResNet50 model was also analyzed by Grad-CAM. The research results can quickly and accurately detect the blueberry fruit fly pests, and it can provide theoretical support for the intelligent detection and online sorting of small berry quality.

Key words: blueberry fruit fly pests; nondestructive detection; im-ResNet50 model; hyperspectral imaging

收稿日期: 2022-02-07 修回日期: 2022-05-28

基金项目: 辽宁省教育厅基础研究项目(LSNJC201906)和辽宁省自然科学基金项目(20180550943)

作者简介: 田有文(1968—),女,教授,博士生导师,主要从事农产品品质无损检测研究,E-mail: youwen_tian10@163.com

0 引言

蓝莓生长过程中容易受到果蝇虫害侵染^[1-3], 果蝇会在蓝莓果实中产卵, 幼虫将蓝莓果肉作为养分, 蓝莓颜色较深, 且果蝇产卵虫眼较小, 人类肉眼难以分辨蓝莓遭受虫害情况, 而人工分类费时费力、效率低、准确性差, 因此实现蓝莓虫害自动、快速、准确的无损检测十分重要。

近年来, 高光谱成像作为一种新兴的无损检测技术, 集成了光谱信息和成像技术, 具有较高的光谱和空间分辨率, 已被证明是一种有效的水果质量和安全检测技术^[4]。利用高光谱成像技术检测水果虫害的研究已有报道^[5-8]。通过高光谱成像获得的综合信息有助于从不同方面研究水果品质, 其主要的挑战是处理大量数据并有效地学习有用信息。其中最关键的是引入各种机器学习方法来识别水果虫害, 从而取得良好的性能。除了传统的机器学习方法外, 深度学习模型已被引入高光谱数据分析^[9-14]。AGARWAL 等^[9]获得了约 2 000 幅高光谱图像, 通过卷积神经网络 (Convolutional neural networks, CNN) 和胶囊网络两种深度学习模型, 对谷仓中谷蠹和变形虫的全身及其碎片图像进行图像处理, 获得 90% 以上的识别准确率。HAN 等^[10]采集黄曲霉毒素污染前后 73 个花生样品的 146 幅高光谱图像, 提出一种像素光谱的图像重构方法。通过 CNN 方法与不同的识别模型进行比较, 发现深度学习识别模型优于传统的识别模型。SONIA 等^[11]采集马铃薯泥上死的和活的产孢梭菌孢子高光谱图像, 采用深度神经网络(CNN) 和随机森林模型(RF) 对不同孢子菌株数量进行检测, 结果表明 CNN 模型总体准确率达 90% ~ 94%。GAO 等^[12]对早熟和成熟草莓的高光谱图像提取前 3 个主成分空间特征图像, 采用预训练的 AlexNet 卷积神经网络对样品草莓成熟度进行实时分类, 测试数据集准确率达 98.6%。费婧怡^[13]提出了基于 A-ResNet 元学习模型的大豆食心虫虫害高光谱检测方法, 并进行了改进, 模型准确率达 $94.57\% \pm 0.19\%$ 。冯喆等^[14]分别采用一维神经网络 1DCNN 和二维卷积神经网络 2DCNN, 建立山核桃内源性异物的检测模型, 2DCNN 模型性能较好, 训练集和测试集分类准确率分别提高至 100% 和 98.5%。

本文针对蓝莓受果蝇虫害侵染后存在人工分拣效率低、准确度差等问题, 采用高光谱成像技术采集蓝莓果蝇虫害高光谱图像并进行降维获取图像数据集, 然后构建 VGG16、InceptionV3 与 ResNet50 3 种深度学习模型对蓝莓果蝇虫害进行数据处理与无损

检测, 并提出对深度学习模型结构、损失函数和激活函数加以改进的方法。采用 Grad-CAM 进行可解释性分析, 以证明改进模型识别蓝莓果蝇虫害的准确性。

1 材料与方法

1.1 样本制备

本文所用蓝莓样本是在 2021 年 6—7 月期间采摘于沈阳农业大学小浆果实践教学与科研基地, 有杜克与蓝丰 2 个品种。采摘后置入 5℃ 冰柜中去除田间热, 4 h 后取出蓝莓, 选取大小与质量相似、果实外表匀称、无明显损伤或病虫害的健康果实进行试验。试验样本质量在 1.5 ~ 2.5 g 之间, 直径为 10 ~ 15 mm。选取 200 个杜克品种与 200 个蓝丰品种共计 400 个蓝莓样本, 混合后进行分组试验。将样本分为 8 组, 每组 50 个样本, 随机选取 6 组样本进行虫害试验, 其余 2 组作为健康样本进行培养。将每组蓝莓样本放置于培养器皿中并编号记录。

为了保证果蝇生存环境, 在培养器皿一侧打出若干个孔洞, 采用透气的纱布将孔洞部分盖住, 这样在保证空气流通的同时, 能够减少细菌和灰尘等杂质进入培养皿, 也能防止果蝇逃出培养器皿。随后在 6 组培养皿中各放入 15 只成熟期果蝇进行培养。将培养器皿置于 $25^\circ\text{C} \pm 3^\circ\text{C}$ 、相对湿度为 30% 的恒温培养箱中培育, 每 2 d 采集一次高光谱图像, 待到果蝇在蓝莓中产卵, 果蝇幼虫通过虫洞钻出蓝莓, 即可知该样本已遭受虫害, 筛选对应蓝莓的高光谱图像作为果蝇虫害图像。

1.2 数据采集

本文所用光谱成像系统包括^[15]: 1 个金属暗箱 ($120\text{ cm} \times 50\text{ cm} \times 140\text{ cm}$)、1 个成像光谱仪 (ImSpector V10E 型, Spectral Imaging Ltd., 芬兰)、1 台高性能 CCD 相机 (IGV-B1410M 型, IMPERX incorporated, 美国)、1 个可控位移平台 (IRCP0076-1 型, 中国)、2 个卤素灯 (150W, 3900 Illuminatior, Illumination Technologies Inc., 美国)、1 个 DELL 工作站 (Vostro 5560D-1528 型)。成像光谱仪光谱范围为 400 ~ 1 000 nm, 光谱分辨率 1.27 nm。CCD 相机配有一个相机镜头 (IGV-B1410 型, 分辨率 1 392 像素 \times 1 040 像素)。

采用高光谱成像系统采集健康蓝莓和受果蝇侵染的蓝莓高光谱图像。首先成像仪预热 30 min, 保证试验过程中成像仪正常运转。将 CCD 相机镜头与蓝莓样本之间距离设为 30 ~ 32 cm 并进行镜头调焦。然后设置位移控制平台的最佳横移速度, 采用

硬币进行反复测试后认为横移速度在 1.2 mm/s 时成像效果最佳。最后进行黑白板校正。因为试验所用高光谱成像系统中卤素灯位置固定,无法跟随位移平台移动,会导致光源照射强度发生变化;其次电流波动也会对光谱数据产生干扰。因此需要对采集的高光谱图像 R_o 进行校正操作,以减小外部环境带来的干扰,黑白板校正计算式为^[16]

$$R_x = \frac{R_o - R_d}{R_w - R_d} \times 100\% \quad (1)$$

式中 R_x ——校正后高光谱图像

R_w ——扫描标准白板得到的图像

R_d ——盖上镜头采集到的黑色图像

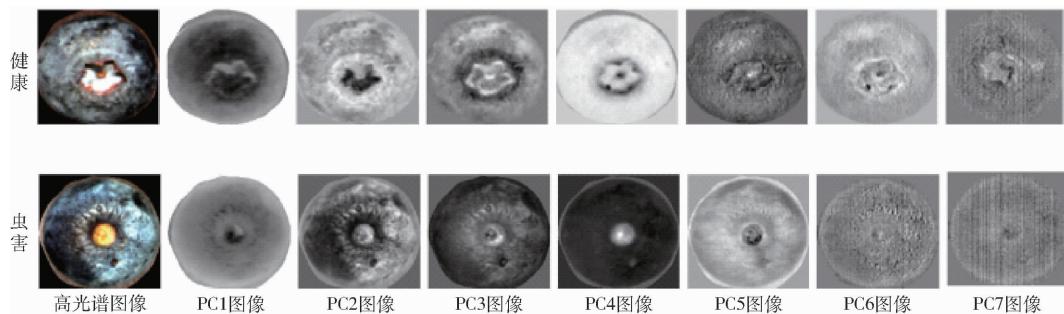


图 1 PCA 方法降维结果

Fig. 1 Dimensionality reduction result of PCA method

由图 1 可知,PC1 图像显示的虫害特异性不明显,PC4 以后的主成分图像相对于前几个主成分图像含有明显噪声,PC2 和 PC3 图像显示的虫害特异性比较明显,故本试验将优先选取 PC2 与 PC3 数据集进行后续试验。并在此基础上,将 PC2 与 PC3 图像进行拼接,组成 PC23 数据集。

1.4 图像增强

由于数据集所含图像数据较少,每个数据集所含图像数量不足 1 000,而后续试验中深度学习算法需要大量的图像进行模型训练,为防止模型产生过拟合,故采用数据增强技术^[20],对各类图像增加水平、垂直翻转、模糊、高亮、低亮、镜像、随机添加噪声等操作(图 2),使各数据集容量扩增为原始容量的 18 倍,将每类图像样本由原来的 1 200 幅增加到 21 600 幅。因数据增强前后图像大小存在差异,使用 Matlab 自编函数将其统一调整至 224 像素 × 224 像素,图像增强结果如图 2 所示。进行图像增强之后各数据集 PC2、PC3、PC23 所含图像数量为 7 200 幅。

1.5 深度学习模型与评价指标

卷积神经网络模型 (Convolutional neural network,CNN) 在图像分类应用方面比较突出^[21],主要由输入层、卷积层、池化层、激活函数、全连接层、损失函数和输出层等部分组成。图像输入之后,经

采用蓝莓样本进行高光谱图像采集,按照虫害样本图像与健康样本图像进行分类保存,其中虫害样本图像 300 幅,健康样本图像 100 幅,共计 400 幅蓝莓样本高光谱图像。

1.3 蓝莓高光谱图像降维

采集到的蓝莓高光谱图像是一个数据立方体^[17],含有大量的冗余信息^[18]。本文采用 PCA 算法^[19]对蓝莓数据集进行降维操作。在试验过程中,保留每幅高光谱图像 99.9% 的特征,每幅高光谱图像获得 PC1、PC2、…、PC7 前 7 个主成分图像,基本能够反映出图像中蓝莓样本的形状、纹理、亮度、颜色和边缘等信息,结果如图 1 所示。

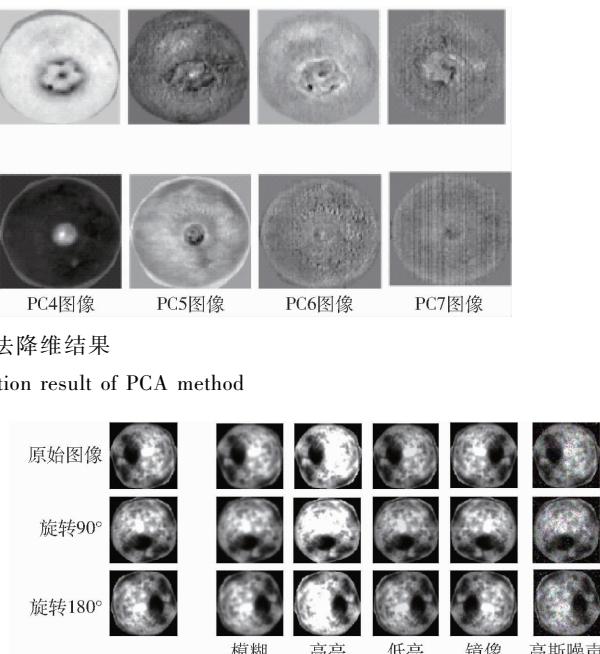


图 2 图像增强结果

Fig. 2 Result of image enhancement

过多层卷积层和池化层对图像进行特征提取,最后经过全连接层由输出层输出结果。常用卷积神经网络模型有 VGGNet、InceptionV3、ResNet50 等^[22-25]。

采用 VGG16、InceptionV3 和 ResNet50 3 种卷积神经网络模型进行果蝇虫害蓝莓深度学习试验,探究在虫害蓝莓无损检测试验中准确率最高、损失率最低的深度学习模型,并对模型进行改进,进一步提高模型检测准确率。

深度学习模型评价指标为准确率和损失函数值。

2 试验结果与分析

2.1 试验环境

试验均采用华硕 Rog 计算机,在 Anaconda 3 集成环境与 Pytorch 1.6.0 环境下完成。具体试验环境如表 1 所示。

表 1 试验环境

Tab. 1 Experimental environment

运行环境	详细信息
CPU	Intel(R) Core(TM) i7-9750H CPU 2.60 GHz
GPU	NVIDIA GeForce GTX 1660Ti GDDR6 6 GB
内存	16 GB
操作系统	Windows 10 64 bit
集成环境	Anaconda 3
深度学习框架	Pytorch 1.6.0
编程软件	Pycharm, Jupyter Notebook

2.2 数据集筛选

初步选择 3 个蓝莓样本图像数据集 PC2、PC3 和 PC23, 将各数据集按照 4:1 的比例分为训练集与测试集。对所有数据集分别采用 ResNet50、InceptionV3、VGG16 深度学习模型进行试验。采用不同数据集对 3 个模型分别进行训练与测试, 根据各数据集的识别准确率选取效果最佳的数据集进行后续深度学习试验。3 个模型的测试集识别准确率如表 2 所示。

表 2 蓝莓果蝇虫害数据集试验识别准确率

Tab. 2 Experimental performance of blueberry fruit fly pests in three data sets %

数据集	ResNet50	InceptionV3	VGG16
PC2	87.67	86.34	79.95
PC3	86.53	83.90	83.57
PC23	92.92	91.70	89.84

由表 2 可知, 在 3 个模型测试中 PC23 的数据集准确率均高于 PC2 与 PC3 数据集的检测准确率, 因此后续试验中将选取 PC23 数据集作为试验数据集。

2.3 模型对比分析

采用图像增强后的 PC23 数据集作为试验数据集, 将数据集按比例 9:1 分为训练集(6 480 幅)与测试集(720 幅)。

在试验之前, 采用集成环境中的 Resize 函数调整输入图像尺寸, 创建每次试验的记录文件。采用 VGG16、InceptionV3 与 ResNet50 3 种网络模型进行深度学习试验, 损失函数采用交叉熵损失函数, 激活函数采用 ReLU, 记录每次试验准确率与损失率。经多次试验, 设置处理批次为 16, 训练轮次为 50, 初始学习率为 0.001 时模型训练效果最佳。各个模型训练集评价指标如图 3 所示。

由图 3 可知, VGG16、InceptionV3 与 ResNet50 3 个模型准确率、损失率都在训练到达第 30 个轮次以后趋于平稳状态, 直至第 50 个轮次并未发生明显剧烈波动, 证明模型已收敛至稳定状态。由图 3a 可知, InceptionV3 模型训练收敛最快, ResNet50 模型

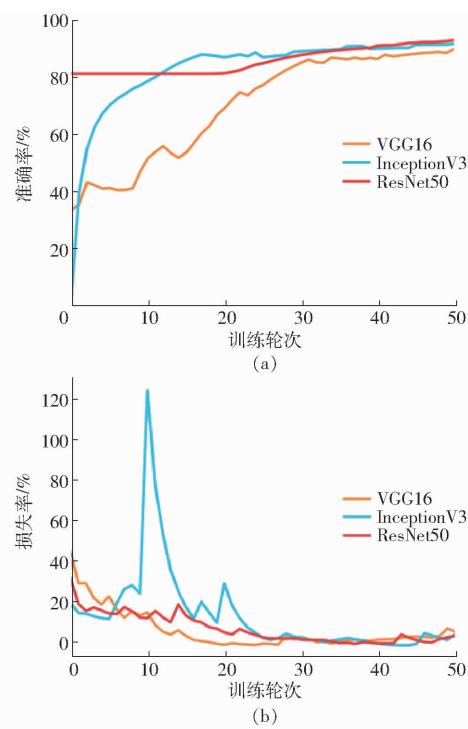


图 3 3 种模型训练集性能对比

Fig. 3 Performance comparison of three model training sets

次之, VGG16 最慢。由图 3b 可知, InceptionV3 模型收敛速度较慢, VGG16 模型收敛速度最快, 但最终出现了波动, 稳定性不如其他 2 个模型。总体 3 个模型都达到了较好的识别效果, ResNet50 模型训练用时明显低于 VGG16 与 InceptionV3 模型, 3 个深度学习模型的测试结果如表 3 所示。

表 3 3 种深度学习模型试验结果对比

Tab. 3 Comparison of experimental results of three deep learning models

模型	训练用时/s	测试集准确率/%	损失率/%
VGG16	1 982	89.84	5.25
InceptionV3	1 928	91.70	3.88
ResNet50	1 705	92.92	3.08

由表 3 可知, 3 个深度学习模型 VGG16、InceptionV3 与 ResNet50 在蓝莓果蝇虫害识别方面都取得了较好的效果, 准确率都不小于 89.84%, 其中 ResNet50 模型在 3 个模型中性能最好, 其准确率达到 92.92%。原因为 ResNet50 模型加深了网络层数, 并采用残差结构缓解梯度爆炸与梯度消失的问题。同时残差块的存在大幅减少了模型参数量, 提高了模型计算效率, 使其仅用较少的训练时间就获得了较高的识别性能, 因此 ResNet50 模型在蓝莓虫害无损检测方面性能较佳。

2.4 改进 ResNet50 模型

采用 ECA 注意力机制、Focal Loss 损失函数与 Mish 激活函数对 ResNet50 模型进行改进, 以期望能

够进一步提高果蝇虫害蓝莓的检测性能。

2.4.1 ECA 注意力机制

对蓝莓果蝇虫害进行识别时, 主要依靠卷积层识别蓝莓虫害部位的局部特征。近些年来, 注意力通道机制被证明在提高各种卷积神经网络模型局部特征识别性能及整体模型识别精度方面有很高的研究价值。注意力机制从数学原理可解读为加权求和, 从人类感知方面可解读为人类对环境的观察中所关注到的最重要的局部信息。在深度学习模型进行训练时, 加入注意力机制可以使模型在局部特征的识别过程中对贡献率较大的局部特征加以更高的权重, 以提高模型准确率。

为了提高模型性能, 多数注意力机制模块设计十分复杂, 导致注意力模块含有大量参数, 在提高性能的同时也不可避免增加了模型参数量, 占用更多计算资源, 增加了模型计算时间。本文采用高效注意力通道(Efficient channel attention, ECA)模块^[26], 通过允许跨通道交互, 避免了降维带来的损失, 而且 ECA 注意力模块仅包含少量参数, 同时能有效提高模型精度。

ECA 模块从输入信息中获取通道维度 C 后, 将图像进行全局平均池化, 自适应选择卷积核后进行卷积获取每个特征所含权重, 最后将带有权重信息的特征通过激活函数后将激活的权重信息赋值到对应的特征中, 作为 ECA 模块的输出。本文在保持数据集、降维所用方法不变的情况下, 将 ECA 模块添加至 ResNet50 模型的 Bottleneck 卷积过程中, 构建 ECA-ResNet50 模型, 果蝇虫害蓝莓检测的独立试验结果如图 4 与表 4 所示。

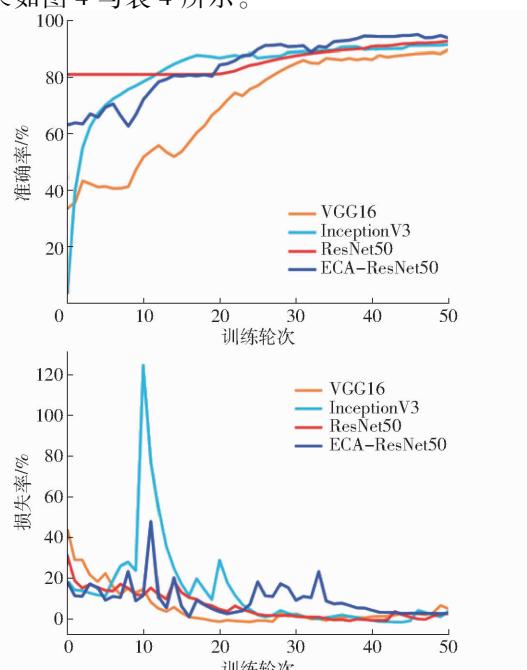


图 4 ECA-ResNet50 模型训练准确率与损失率对比

Fig. 4 ECA-ResNet50 model training accuracy and loss rate

表 4 ECA-ResNet50 模型与其他 3 种模型测试集结果对比

Tab. 4 Comparison of test set results between ECA-ResNet50 model and other three models

模型	训练用时/s	测试集准确率/%	损失率/%
VGG16	1 982	89.84	5.25
InceptionV3	1 928	91.70	3.88
ResNet50	1 705	92.92	3.08
ECA-ResNet50	1 728	93.33	2.76

由图 4 可知, ECA-ResNet50 的准确率、损失率在训练时较快达到平稳状态。由于各模型最终训练差异在整体图像中显示不明显, 因此将最终阶段图像放大显示, 可以更清晰地观测各模型试验结果的差异。最终 ECA-ResNet50 模型训练集的准确率优于 VGG16、InceptionV3 和 ResNet50 模型的准确率。由表 4 可知, 将 ResNet50 模型中添加 ECA 注意力模块后, 损失率有所下降, 测试集准确率得到提升, 表明 ECA 注意力模块能够提升模型性能。由于在模型中添加了新的模块, 增加了参数量, 因此训练耗时也有一定程度增加。

2.4.2 损失函数改进

在蓝莓果蝇虫害检测试验过程中, 数据集内的部分早期果蝇虫害样本与健康蓝莓样本差异性较小, 在分类过程中属于较难分类样本; 而与健康蓝莓差异性较大的样本则可归类为较易分类样本。在 ResNet50 模型默认的交叉熵函数中, 对于较易分类样本和较难分类样本的计算权重相同, 不利于较难分类样本的计算。当较易分类样本所占比重较大时, 对损失率影响过大, 使得损失函数对参数的更新无法有效提高较难分类样本的预测能力。因此本文采用在二分类问题中效果较好的 Focal Loss 损失函数^[27], 构建 Focalloss-ResNet50 模型, 以降低较易分类样本对 Loss 的影响, 其原理为

$$FL_{(pt)} = -\alpha_t (1 - p_t)^\gamma \lg p_t \quad (2)$$

式中 γ 为聚焦参数, 取值大于等于 0, $(1 - p_t)^\gamma$ 是调制系数, 通过调制系数可以有效降低较易分类样本权重, 提高较难分类样本权重。在二分类问题中, γ 通常赋值为 2。通过改变参数 α_t 的赋值改变正负样本对总损失率共享权重, α_t 取值越小, 负样本权重越低。

在保持数据集、降维所用方法不变的情况下, 将 Focal Loss 损失函数代替 ResNet 模型中的交叉熵, 试验结果如图 5 与表 5 所示。

由图 5 与表 5 可知, 将 ResNet50 模型中的交叉熵损失函数改为 Focal Loss 损失函数后, 训练

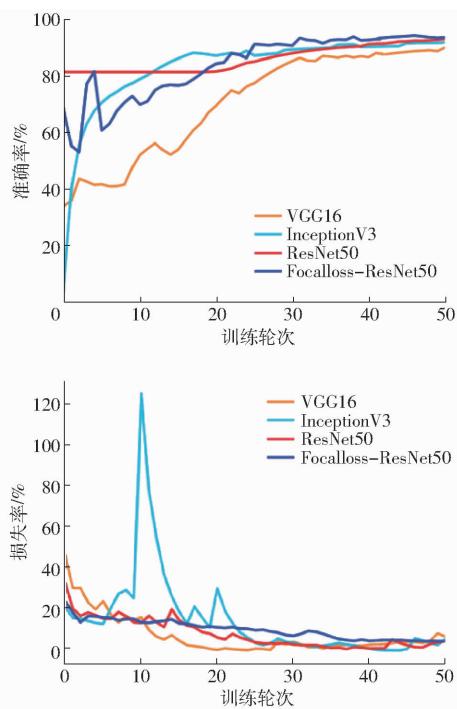


图 5 Focalloss - ResNet50 模型训练集准确率与损失率对比

Fig. 5 Focalloss - ResNet50 model training accuracy and loss rate

表 5 Focalloss - ResNet50 模型与其他 3 种模型测试集结果对比

Tab. 5 Comparison of test set results between Focalloss - ResNet50 model and other three models

模型	训练用时/s	测试集准确率/%	损失率/%
VGG16	1 982	89.84	5.25
InceptionV3	1 928	91.70	3.88
ResNet50	1 705	92.92	3.08
Focalloss - ResNet50	1 708	93.47	3.02

集的准确率、损失率都优于 VGG16、InceptionV3 和 ResNet50 模型, 测试集准确率得到提升, 训练耗时几乎没有变化, 表明更换的 Focal Loss 损失函数效果优于原始的交叉熵损失函数, 能够提升模型性能。

2.4.3 激活函数改进

本文深度学习模型采用激活函数 ReLU。当输入为负值时会被截断为 0, 通常情况下认为负值表示引入了背景信息或噪声信息, 因此将负值截断既排除了干扰信息也增加了网络稀疏性。但 ReLU 带来的稀疏性也可能阻碍网络训练过程, 负值并不表示必然存在干扰信息, 截断为 0 代表屏蔽该特征, 可能会导致模型学习过程中漏掉某些关键特征, 在学习率较大的情况下, 可能会使大部分神经元进入截断状态, 在当次训练中的被截断神经元都将无法再学习。为了解决负值截断问题, 本文采用 Mish 激活

函数^[28]代替 ResNet50 模型中的 ReLU 激活函数进行试验, Mish 激活函数为

$$f(x) = xtanh(\text{softplus}(x)) = xtanh(\ln(1 + e^x)) \quad (3)$$

Mish 激活函数是一个平滑、连续、自正则、非单调的激活函数。与 ReLU 激活函数类似, Mish 激活函数也存在有下界无上界的特点, 但是 Mish 在负值输入时理论上可接受, 虽随着负值越小而越趋近于 0, 但与 ReLU 的硬性截断并不相同。允许负值输入使得 Mish 激活函数拥有更好的梯度流, 其平滑性远优于 ReLU 激活函数, 在一定程度上提高对特征的接受能力, 提高模型训练效果。

在保持数据集、降维所用方法不变的情况下, 将 ResNet50 模型中的 ReLU 激活函数替换为 Mish 激活函数后, 构建 Mish - ResNet50 模型, 果蝇虫害蓝莓检测的独立试验结果如图 6 与表 6 所示。

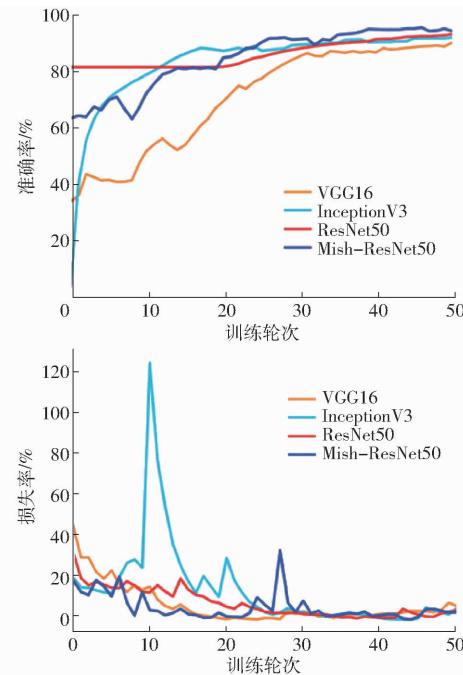


图 6 Mish - ResNet50 模型训练准确率与损失率对比

Fig. 6 Mish - ResNet50 model training accuracy and loss rate

表 6 Mish - ResNet50 模型与其他 3 种模型测试集结果对比

Tab. 6 Comparison of test set results between Mish - ResNet50 model and other three models

模型	训练用时/s	测试集准确率/%	损失率/%
VGG16	1 982	89.84	5.25
InceptionV3	1 928	91.70	3.88
ResNet50	1 705	92.92	3.08
Mish - ResNet50	1 713	94.17	2.05

由图 6 与表 6 可知, 采用 Mish - ResNet50 模型对果蝇虫害蓝莓检测, 训练集准确率有较大提升、损失率有较大下降, 都优于 VGG16、InceptionV3 和

ResNet50 模型, 测试集准确率从 92.92% 提升至 94.17%, 效果较为明显, 同时训练耗时略有增加, 表明 Mish 激活函数提升能够提升 ResNet50 模型在虫害蓝莓检测性能。

2.4.4 结果与分析

将 ECA 注意力模块、Focal Loss 损失函数、Mish 激活函数引入 ResNet50 模型后, 均有利于准确率与损失率, 故将这三者一同引入 ResNet50 模型中, 构

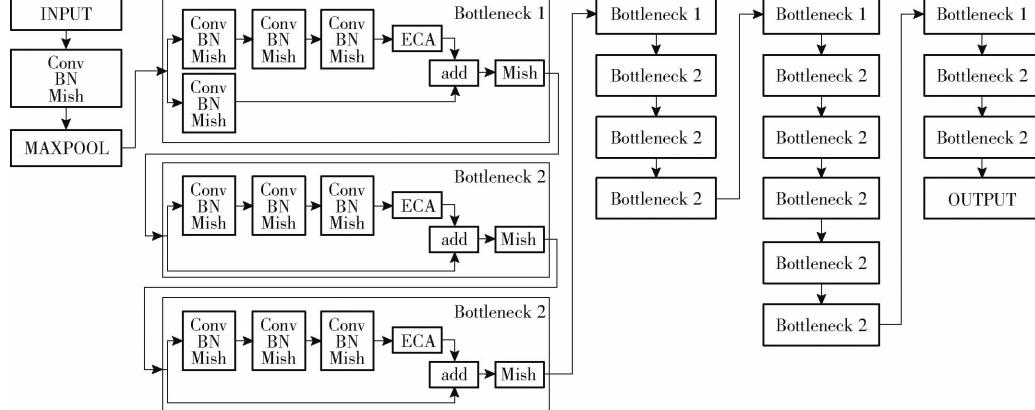


图 7 im-ResNet50 网络结构图

Fig. 7 Architectures for im-ResNet50

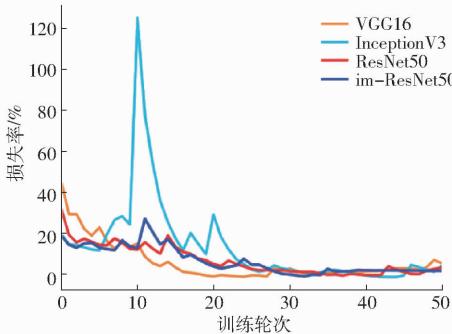
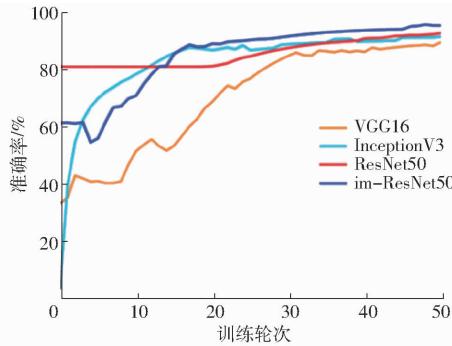


图 8 4 种模型训练集性能对比

Fig. 8 Performance comparison of training sets of four model trainings

由图 8 和表 7 可知, 改进后的 im-ResNet50 模型准确率最高与损失率最低。但也可以看出, 由于引入了 ECA 模块, 替换了损失函数与激活函数, 增加了模型的参数量, 模型训练用时相较于 ResNet50 模型略有增加, 但仍低于 VGG16 模型与 InceptionV3 模型, 以少量的计算代价获得了较为明显的识别性

能提升。建 im-ResNet50 模型, 进行果蝇虫害蓝莓检测训练与测试。得出 im-ResNet50 模型的训练集损失率降为 1.52%, 降低 1.56 个百分点, 测试集准确率提高到 95.69%, 提高 2.77 个百分点。改进后的网络结构图如图 7 所示。将训练结果的准确率与损失率与 VGG16 模型、ResNet50 模型、InceptionV3 模型进行对比, 如图 8 所示, 4 个模型的测试集性能指标如表 7 所示。

表 7 im-ResNet50 模型与其他 3 种模型测试集结果对比

Tab. 7 Comparison of test set results between im-ResNet50 model and other three models

模型	训练用时/s	测试集准确率/%	损失率/%
VGG16	1 982	89.84	5.25
InceptionV3	1 928	91.70	3.88
ResNet50	1 705	92.92	3.08
im-ResNet50	1 747	95.69	1.52

能提升。

2.5 模型可解释性分析

采用梯度-分类激活图 (Grad-class activation mapping, Grad-CAM)^[29], 将 Softmax 分类的结果进行可视化, 得到每个输入图像的激活热力图, 可通过颜色差异明显反映对模型分类做出贡献的局部特征。Grad-CAM 首先计算 Softmax 输出中蓝莓虫害概率 y^c 对最后一层特征图所在层的偏导数, 求得每个像素的偏导数后, 进行一次全局平均池化, 得到类别 c 对特征图中第 k 个通道的敏感度 α_k^c 为

$$\alpha_k^c = \frac{1}{Z} \sum_i \sum_j \frac{\partial y^c}{\partial A_{ij}^k} \quad (4)$$

式中 y —概率 c —类别标签

A_{ij}^k —特征图第 k 个通道中第 (i, j) 个位置的像素

Z —特征图分辨率

最后, 将敏感度 α_k^c 作为 A^k 的权重进行线性组合, 得

到 Grad - CAM 为

$$L_{\text{Grad-CAM}}^c = \text{ReLU} \left(\sum_k \alpha_k^c A^k \right) \quad (5)$$

采用 Grad - CAM 将模型识别结果贡献率最高部分可视化,如图 9 所示。

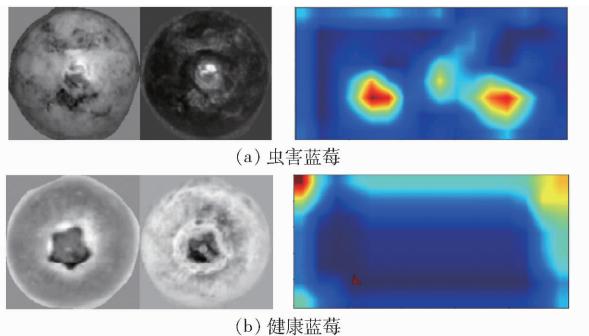


图 9 蓝莓 Grad - CAM 可视化结果

Fig. 9 Visualization results of Grad - CAM

由图 9 可知,颜色越蓝,表示特征所占权重越低;颜色越红,表示特征所占权重越高,对检测分类判别贡献越大。由图 9a 可看出,im - ResNet 模型在识别性能较高的同时,对果蝇虫害部位的识别也比较准确,模型中占有较高权重的局部特征与蓝莓遭受虫害部位相符合,由图 9b 可看出,蓝莓所在部位皆为深蓝色,即没有虫害特征。通过 Grad - CAM 热力图可以直观地显示出对模型检测分类最有价值部分,提高了模型可解释性。

3 结论

(1) 对蓝莓高光谱图像采用 PCA 进行降维,从 7 个主成分数据集中选取最佳数据集为 PC2 与 PC3 两个数据集,将其进行拼接得到 PC23 数据集试验效果更优,选用 PC23 数据集作为蓝莓果蝇虫害图像试验数据集。对数据集中图像进行 90° 旋转、180° 旋转、模糊、高亮、低亮、镜像和高斯噪声共计 7 种增强操作,使各数据集容量扩增为原始容量 18 倍。

(2) 采用 VGG16、ResNet50 与 InceptionV3 深度学习模型对蓝莓虫害图像进行识别检测,均取得了较高的识别准确率。其中 ResNet50 模型效率最高,训练用时明显少于 VGG16 模型与 InceptionV3 模型,而且 ResNet50 模型的准确率最高,达到 92.92%,损失率最低,仅有 3.08%。

(3) 从 ECA 注意力模块、Focal Loss 损失函数与 Mish 激活函数 3 方面对 ResNet50 模型进行改进,构建了改进的 im - ResNet50 模型,提升了蓝莓虫害识别能力,其相对于 ResNet50 模型将识别准确率提升 2.77 个百分点,同时损失率降低 1.56 个百分点,但由于增加了参数量,训练用时也略有增加。整体而言,im - ResNet50 模型以少量的计算代价获得了较为明显的识别性能提升。

参 考 文 献

- [1] QIAO S C, TIAN Y W, WANG Q B, et al. Nondestructive detection of decayed blueberry based on information fusion of hyperspectral imaging (HSI) and low-field nuclear magnetic resonance (LF - NMR) [J]. Computers and Electronics in Agriculture, 2021, 184: 106100.
- [2] 沈建炜,李林,魏新华. 丘陵地区蓝莓园智能灌溉决策系统设计[J]. 农业机械学报, 2018, 49(增刊): 379 - 386.
SHEN Jianwei, LI Lin, WEI Xinhua. Design of intelligent irrigation decision system for blueberry garden in hilly area [J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(Supp.): 379 - 386. (in Chinese)
- [3] 张小艳,郑姗,谢丽雪,等. 福建省蓝莓病虫害调查[J]. 福建农业学报, 2019, 34(3): 338 - 343.
ZHANG Xiaoyan, ZHENG Shan, XIE Lixue, et al. A report on insect infestation and disease on blueberry bushes in Fujian [J]. Fujian Journal of Agricultural Sciences, 2019, 34(3): 338 - 343. (in Chinese)
- [4] CHANDRASEKARAN I, PANIGRAHI S S, RAVIKANTH L, et al. Potential of near-infrared (NIR) spectroscopy and hyperspectral imaging for quality and safety assessment of fruits: an overview [J]. Food Analytical Methods, 2019, 12: 2438 - 2458.
- [5] XING J, GUYER D, ARIANA D, et al. Determining optimal wavebands using genetic algorithm for detection of internal insect infestation in tart cherry [J]. Sensing and Instrumentation for Food Quality and Safety, 2008, 2(3): 161 - 167.
- [6] HAFF R P, SARANWONG S, THANAPASE W, et al. Automatic image analysis and spot classification for detection of fruit fly infestation in hyperspectral images of mangoes [J]. Postharvest Biology & Technology, 2013, 86: 23 - 28.
- [7] 王帅帅. 基于高光谱成像的鲜桃虫害检测特征向量的选取[J]. 信阳农林学院学报, 2015, 25(4): 119 - 123.
WANG Shuaishuai. Feature vectors selection for fresh peach pest detection based on hyperspectral imaging [J]. Journal of Xinyang Agriculture and Forestry University, 2015, 25(4): 119 - 123. (in Chinese)
- [8] 刘德华,张淑娟,王斌,等. 基于高光谱成像技术的山楂损伤和虫害缺陷识别研究[J]. 光谱学与光谱分析, 2015, 35(11): 3167 - 3171.
LIU Dehua, ZHANG Shujuan, WANG Bin, et al. Detection of hawthorn fruit defects using hyperspectral imaging [J]. Spectroscopy and Spectral Analysis, 2015, 35(11): 3167 - 3171. (in Chinese)
- [9] AGARWAL M, AL-SHUWAILI T, NUGALIYADDE A, et al. Identification and diagnosis of whole body and fragments of

- Trogoderma granarium and Trogoderma variabile using visible near infrared hyperspectral imaging technique coupled with deep learning[J]. Computers and Electronics in Agriculture, 2020, 173: 150438.
- [10] HAN Z Z, GAO J Y. Pixel-level aflatoxin detecting based on deep learning and hyperspectral imaging[J]. Computers and Electronics in Agriculture, 2019, 164: 104888.
- [11] SONIA A, AL-SARAYREHA M, REIS M M, et al. Hyperspectral imaging and deep learning for quantification of *Clostridium sporogenes* spores in food products using 1D-convolutional neural networks and random forest model[J]. Food Research International, 2021, 147: 110577.
- [12] GAO A M, SHAO Y Y, XUAN G T, et al. Real-time hyperspectral imaging for the in-field estimation of strawberry ripeness with deep learning[J]. Artificial Intelligence in Agriculture, 2020, 4: 31–38.
- [13] 费婧怡. 基于高光谱成像的大豆食心虫小样本检测方法研究[D]. 杭州: 浙江理工大学, 2021.
FEI Jingyi. Few-shot *Leguminivora glyciniivorella* (Matsumura) detection method based on hyperspectral imaging [D]. Hangzhou: Zhejiang Sci-Tech University, 2021. (in Chinese)
- [14] 冯皓, 李卫豪, 崔笛. 基于高光谱成像和深度学习的山核桃内源性异物检测[J]. 农业机械学报, 2021, 52(增刊): 467–471.
FENG Zhe, LI Weihao, CUI Di. Inspection of endogenous foreign body in Chinese hickorynut based on hyperspectral imaging and deep learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(Supp.): 467–471. (in Chinese)
- [15] 刘思伽, 田有文, 张芳, 等. 采用二次连续投影法和BP神经网络的寒富苹果病害高光谱图像无损检测[J]. 食品科学, 2017, 38(8): 277–282.
LIU Sijia, TIAN Youwen, ZHANG Fang, et al. Hyperspectral imaging for nondestructive detection of Hanfu apple diseases using successive projections algorithm and BP neural network[J]. Food Science, 2017, 38(8): 277–282. (in Chinese)
- [16] ZHANG J J, MA Y H, LIU G S, et al. Rapid evaluation of texture parameters of Tan mutton using hyperspectral imaging with optimization algorithms[J]. Food Control, 2022, 135: 108815.
- [17] 姜妍, 王琳, 杨月, 等. 无人机高光谱成像技术在作物生长信息监测中的应用[J]. 东北农业大学学报, 2022, 53(3): 88–96.
JIANG Yan, WANG Lin, YANG Yue, et al. Application of UAV hyperspectral imaging technology in crop growth information monitoring[J]. Journal of Northeast Agricultural University, 2022, 53(3): 88–96. (in Chinese)
- [18] 邵园园, 王永贤, 玄冠涛, 等. 基于高光谱成像的肥城桃品质可视化分析与成熟度检测[J]. 农业机械学报, 2020, 51(8): 344–350.
SHAO Yuanyuan, WANG Yongxian, XUAN Guantao, et al. Visual detection of SSC and firmness and maturity prediction for Feicheng peach by using hyperspectral imaging[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(8): 344–350. (in Chinese)
- [19] ZHANG C, WU W Y, ZHOU L, et al. Developing deep learning based regression approaches for determination of chemical compositions in dry black goji berries (*Lycium ruthenicum* Murr.) using near-infrared hyperspectral imaging[J]. Food Chemistry, 2020, 319: 126536.
- [20] 张宪超. 深度学习(上)[M]. 北京: 科学出版社, 2019.
- [21] KETKAR N. Convolutional neural networks[M]. Cham: Springer International Publishing, 2021: 63–78.
- [22] PARDEDE J, SITOAHNG B, AKBAR S, et al. Implementation of transfer learning using VGG16 on fruit ripeness detection[J]. International Journal of Intelligent Systems & Applications, 2021, 13(2): 52–61.
- [23] ZHUANG X L, ZHANG T M. Detection of sick broilers by digital image processing and deep learning[J]. Biosystems Engineering, 2019, 179: 106–116.
- [24] 肖德琴, 蔡家豪, 林思聪, 等. 基于IFSSD卷积神经网络的柚子采摘目标检测模型[J]. 农业机械学报, 2020, 51(5): 28–35, 97.
XIAO Deqin, CAI Jiahao, LIN Sicong, et al. Grapefruit detection model based on IFSSD convolution network [J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(5): 28–35, 97. (in Chinese)
- [25] SHIN J Y, CHANG Y K, HEUNG B D, et al. A deep learning approach for RGB image-based powdery mildew disease detection on strawberry leaves[J]. Computers and Electronics in Agriculture, 2021, 183: 106042.
- [26] WANG Q, WU B, ZHU P, et al. ECA-Net: efficient channel attention for deep convolutional neural networks[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2020: 11531–11539.
- [27] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 42(2): 2999–3007.
- [28] MISRA D. Mish: a self regularized non-monotonic neural activation function[EB/OL]. (2020-08-13) [2022-02-26].
<https://arxiv.org/pdf/1908.08681v3.pdf>.
- [29] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-CAM: visual explanations from deep networks via Gradient-based localization[J]. International Journal of Computer Vision, 2017, 128(2): 336–359.