

# 基于 Shuffle – Net 的发芽马铃薯无损检测方法

王飞云<sup>1,2</sup> 吕程序<sup>1,2</sup> 吴金灿<sup>1,2</sup> 丛杰<sup>1,2</sup> 吕黄珍<sup>1,2</sup> 赵博<sup>1,2</sup>

(1. 中国农业机械化科学研究院集团有限公司, 北京 100083;

2. 土壤植物机器系统技术国家重点实验室, 北京 100083)

**摘要:** 针对发芽马铃薯在线检测需求, 提出使用轻量级卷积神经网络对发芽薯进行检测。首先将获取的马铃薯样本基于分级线进行图像采集, 经过数据增强扩充样本。搭建 Shuffle – Net 轻量级卷积神经网络, 对比了不同学习率与学习率衰减策略对模型的影响。试验发现, 当学习率为 0.001, 衰减策略为 W – EP 时表现最佳, 发芽薯与健康薯的总体识别准确率为 97.8%, 单个样本识别时间为 0.14 s, 模型内存占用量为 5.2 MB。对实验结果进行评价, 查准率为 98.0%, 查全率为 97.1%, 特异性为 98.4%, 调和均值为 97.5%。选择 VGG11、Alex – Net、Res – Net101 模型与本文模型进行对比, 发现本文模型识别准确率较 VGG11 与 Alex – Net 有大幅度提升, 单个样本识别速度较 Res – Net101 提高 5 倍、较 VGG11 提高近 7 倍, 模型体量较 VGG11、Alex – Net、Res – Net101 大幅度减少。将模型内部卷积进行了可视化分析并对结果进行了误判分析, 发现当芽体颜色暗、较短且处于薯体边缘的情况下, 会造成误判。由此可得本实验模型实现了发芽薯准确、有效的识别, 同时还具有识别速度快、体量小、移植性强的优点, 可为农产品外部无损检测分级提供理论支撑。

**关键词:** 发芽马铃薯; Shuffle – Net; 学习策略; 无损检测

中图分类号: S532 文献标识码: A 文章编号: 1000-1298(2022)S1-0309-07

## Non-destructive Detection of Sprouting Potatoes Based on Shuffle – Net

WANG Feiyun<sup>1,2</sup> LÜ Chengxu<sup>1,2</sup> WU Jincan<sup>1,2</sup> CONG Jie<sup>1,2</sup> LÜ Huangzhen<sup>1,2</sup> ZHAO Bo<sup>1,2</sup>

(1. Chinese Academy of Agricultural Mechanization Sciences Group Co., Ltd., Beijing 100083, China

2. State Key Laboratory of Soil – Plant – Machine System Technology, Beijing 100083, China)

**Abstract:** In view of the demand for online detection of sprouted potatoes, a lightweight convolutional neural network was proposed to detect sprouted potatoes. Firstly, the acquired potato samples were collected based on the grading line, and the samples were expanded through data enhancement. The Shuffle – Net lightweight convolutional neural network was built, and the effects of different learning rates and learning rate decay strategies on the model were compared. Experiment results showed that when the learning rate was 0.001 and the decay strategy was W – EP, the performance was the best. The overall recognition accuracy of sprouted potato and healthy potato was 97.8%, the single sample recognition time was 0.14 s, and the model memory footprint was 5.2 MB. The experimental results were evaluated, the precision was 98.0%, the recall was 97.1%, the specificity was 98.4%, and the harmonic mean was 97.5%. The VGG11, Alex – Net, and Res – Net101 models were selected for comparison with the model. It was found that the recognition accuracy of the model was greatly improved compared with that of the VGG11 and Alex – Net, and the recognition speed of a single sample was 5 times higher than that of Res – Net101. Compared with VGG11, it was nearly 7 times higher, and the model volume was greatly reduced compared with that of VGG11, Alex – Net, and Res – Net101. In the experiment, the internal convolution of the model was visually analyzed and the results were misjudged. It was found that when the buds were dark, short and at the edge of the tuber, misjudgment would be caused. It can be concluded that this experimental model realized the accurate and effective identification of sprouted potato, and it also had the advantages of fast identification speed, small size and strong portability, which can provide theoretical support for the external non-destructive testing and classification of agricultural products.

**Key words:** sprouting potatoes; Shuffle – Net; learning strategies; non-destructive detection

收稿日期: 2022–06–25 修回日期: 2022–08–26

基金项目: 财政部和农业农村部:国家现代农业产业技术体系专项(CARS – 10)

作者简介: 王飞云(1997—),男,硕士生,主要从事图像处理与机器视觉研究,E-mail: wangfeiyunup@163.com

通信作者: 赵博(1981—),男,研究员,博士生导师,主要从事图像处理与机械设计研究,E-mail: zhaoboshi@126.com

## 0 引言

马铃薯是全球重要的粮食作物之一。发芽是马铃薯外部常见的一种缺陷,发芽马铃薯含有龙葵素,龙葵素是一种麻痹运动系统、呼吸系统的有毒物质。常寄生于芽、芽眼、芽体区域,误食轻则食物中毒,重则影响生命。同时在贮藏中马铃薯发芽导致劣变会造成严重损失,国家标准也明确规定发芽缺陷是商品薯分级的指标之一。因此,及时准确地识别出发芽马铃薯并进行剔除是必要的<sup>[1-3]</sup>。

现有传统图像处理技术<sup>[4]</sup>多以人工提取的马铃薯表面特征、芽体特征等作为研究对象。周竹等<sup>[5]</sup>提出交叉法来判别发芽马铃薯,分级准确率为91%。郁志宏等<sup>[6]</sup>将采集到的马铃薯进行通道处理后,利用欧氏距离算法进行发芽马铃薯检测,识别正确率达到94%。郑冠楠等<sup>[7]</sup>根据马铃薯颜色特征,提出一种灰度差值方法对发芽马铃薯检出,分级精度为88%。HASANKHANI等<sup>[8]</sup>为了实现马铃薯快速、准确的分级,利用机器视觉系统对图像进行分析,分选的准确率可以达到96.82%。YAO等<sup>[9]</sup>对马铃薯进行预处理后,使用发芽马铃薯芽体与块茎的灰度差异方法识别发芽马铃薯,识别准确率为85%。此类方法可以有效将一些发芽马铃薯进行剔除,但识别样本有限,未考虑多品种马铃薯表面的复杂性及芽体颜色多变的薯体。

卷积神经网络(CNN)<sup>[10]</sup>相比于传统方法具有适应性强、鲁棒性高、特征表达能力优等特点,在农产品检测中得到了许多应用<sup>[11]</sup>。DOR等<sup>[12]</sup>提出了深度学习模型进行马铃薯块茎病害(黑痣病、白痣病、黑点、常见疮痂、感染病毒)分类,准确率可达90%以上。MARINO等<sup>[13]</sup>使用弱监督学习的CNN方法对马铃薯缺陷分类、定位与分割,实验创建了包含健康、损伤、发绿、黑点、常见疮痂和黑痣病6个类别马铃薯样本,系统精度达到91%。CASAÑO等<sup>[14]</sup>基于CNN及自适应学习方法对马铃薯虫害进行了检测,得到结果的调和均值为88.2%。傅云龙等<sup>[15]</sup>采用机器视觉与YOLO算法,对腐烂、发芽、机械损伤、虫眼和病斑5类马铃薯缺陷进行检测,各类别识别精度均高于98%。MING等<sup>[16]</sup>根据马铃薯表面特征的多样性,使用手动特征提取与自动特征提取两种方法检测发芽马铃薯,并且提出MC-CNN(Multiple channels CNN)方法,此方法在较低的标准差下优于同期主流方法,预测准确率达到91.6%,调和均值达到90.5%。已有研究解决了传统方法的难点,但马铃薯图像是静态获取。

现在常用于各领域的卷积神经网络有MC-CNN、Alex-Net<sup>[17]</sup>、VGG<sup>[18]</sup>、Google-Net<sup>[19]</sup>、Res-

Net<sup>[20]</sup>等,这些模型是通过不断的卷积堆积与池化来加深网络深度,进而获得高维的图像特征来识别,加深网络的深度能够有效提高准确率但是也会造成模型参数增加、训练所需硬件设备要求过高、识别时间增加。Shuffle-Net<sup>[21-22]</sup>是一种高效的轻量级网络,该网络在中间层卷积堆积过程中首先进行了通道分离,并且通过可分离卷积代替不同卷积操作,最后进行了通道混淆来增加不同组中特征信息的交流。Shuffle-Net结合了Res-Net的重复卷积及分支操作与Mobile-Net<sup>[23]</sup>的可分离卷积操作,并且提出通道混淆操作,既降低了模型的参数计算量,加快了训练速度,也提高了模型特征的联系。

因此本文提出使用轻量级卷积网络Shuffle-Net进行发芽特征自动提取,对比不同衰减策略并提出使用全局预测策略进行优化,结合迁移学习算法实现高效、准确的识别效果。

## 1 数据集建立与检测模型构建

### 1.1 图像采集与处理

#### 1.1.1 样本获取

马铃薯样本来源于内蒙古、河北、山西、湖北等地,品种包括冀张薯、陇薯、大西洋、青薯、同薯、中薯等,共计851颗。将其中420颗马铃薯样本放置在18~23℃室温下避光保存4~5 d,培育出0~20 mm的芽体,剩余431颗作为健康马铃薯样本。

图像采用PointGrey公司GS3-U3-15S5C-C型CCD相机搭配KOWA公司LW5JCM镜头获得,图像分辨率为1384像素×1032像素,采集帧率为60 f/s。采集过程在暗箱中进行,暗箱中采用LED光源板照光。将相机、镜头、暗箱及光源等设备搭建在分级线上<sup>[24]</sup>上,调整分级线电机频率为25 Hz,分选速度为3~4幅/s。采集图像清晰,无虚化。如图1所示,进行马铃薯图像采集,采集单幅图像中包含3个马铃薯样本。



图1 采集装置

Fig. 1 Acquisition device

#### 1.1.2 图像预处理

图像预处理步骤如下:

(1)将原始图像裁剪为每幅图像中只包含一个马铃薯,并且裁剪掉边缘无关的特征,最终单薯图像

尺寸为 416 像素  $\times$  619 像素。

(2) 采用三次样条插值方法将步骤(1)中图像调整为 224 像素  $\times$  224 像素。

图像预处理后去除未包含马铃薯样本图像,共获得发芽马铃薯图像 831 幅,健康马铃薯样本 1 055 幅。将两类图像随机分为训练集、验证集及测试集,分配结果如表 1 所示。

表 1 数据集

Tab. 1 Data set

类别	健康薯	发芽薯
训练集	654	510
验证集	279	218
测试集	122	103

### 1.1.3 数据增强

数据增强可以提升模型的鲁棒性。当训练数据不足或者样本质量欠佳时,会影响数据模型的泛化能力和鲁棒性<sup>[25]</sup>。为了避免这种情况,试验将训练集数据进行数据增强,增强方法为图像亮度增强、对比度增强、图像翻转和图像缩放。每种方法处理后数据增加一倍,增强后训练集图像共 5 820 幅。图像增强方法处理效果如图 2 所示(上排图为健康薯,下排图为发芽薯)。

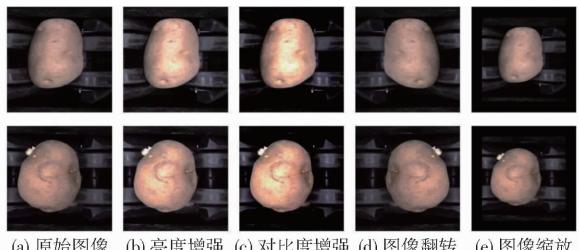


图 2 马铃薯样本数据增强效果

Fig. 2 Potato samples data augmentation

## 1.2 模型构建

### 1.2.1 实验平台

实验在 Linux 中进行,选择 Python 语言编程实现,IDE 为 Pycharm,设备信息如表 2 所示。

表 2 设备信息

Tab. 2 Device information

设备单元/软件	配置
中央处理器	Z7M - KP7GC Inter Core i7 - 8750H
图形处理单元	NVIDIA GTX1050Ti 4GGDDR5
操作系统	Ubuntu18.04
深度学习框架	Pytorch
编程语言	Python 3.8

### 1.2.2 模型结构

如图 3 所示,实验模型为 Shuffle - Net v2,首先输入图像尺寸为 224  $\times$  224  $\times$  3,通过 24 个尺寸为 3  $\times$  3 的卷积核进行卷积,输出特征图为 112  $\times$  112  $\times$  24;对特征图进行最大下采样,输出特征图的尺寸为 56  $\times$  56  $\times$  24。下采样结果输入 Block - Conv(图 4)中,在 Blcok - Conv1 中,步长为 2 进行 1 次操作,步长为 1 进行 3 次重复操作,输出为 28  $\times$  28  $\times$  116。在 Blcok - Conv2 中,步长为 2 进行 1 次操作,步长为 1 进行 7 次重复操作,输出为 14  $\times$  14  $\times$  232。在 Blcok - Conv3 中,步长为 2 进行 1 次操作,步长为 1 进行 3 次重复操作,输出为 7  $\times$  7  $\times$  464。完成对分支模块的多次重复卷积操作以后,连接了 1 024 个卷积核尺寸为 1  $\times$  1 的卷积层,输出为 7  $\times$  7  $\times$  1 024,最后通过卷积核尺寸为 7  $\times$  7 全局下采样提取主要信息,连接全连接层进行类别输出。

### 1.2.3 模型特点

如图 4 所示,Shuffle - Net v2 在版本 1 基础上进

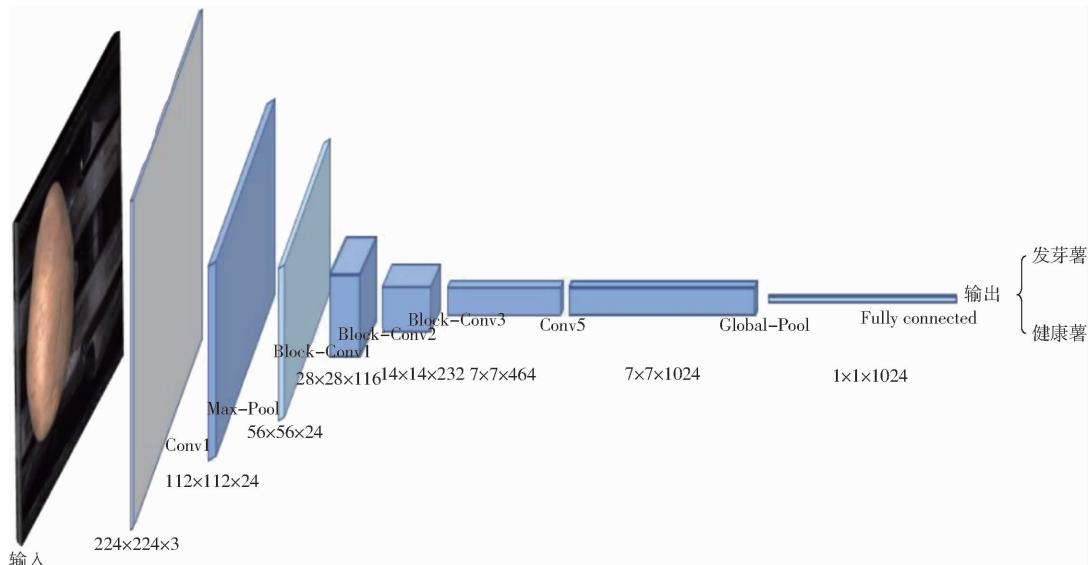


图 3 模型结构图

Fig. 3 Model structure

行优化,将版本1中 $1 \times 1$ GConv改为 $1 \times 1$ Conv,减少了组卷积,使内存访问成本最小。ReLU等操作在分支内进行,以及Concat、Channel Shuffle和Channel Split在同一个element-wise操作,减少了element-wise带来的影响,加快了运行速度。图4a中Channel Split操作与Concat连接,保证了卷积层输入输出特征矩阵channel相等。图4a中左分支没有进行任何操作,使得网络结构的碎片化程度降低。如图5所示,Channel Shuffle实现不同组之间特征图的融合,增加组与组间的信息交流。

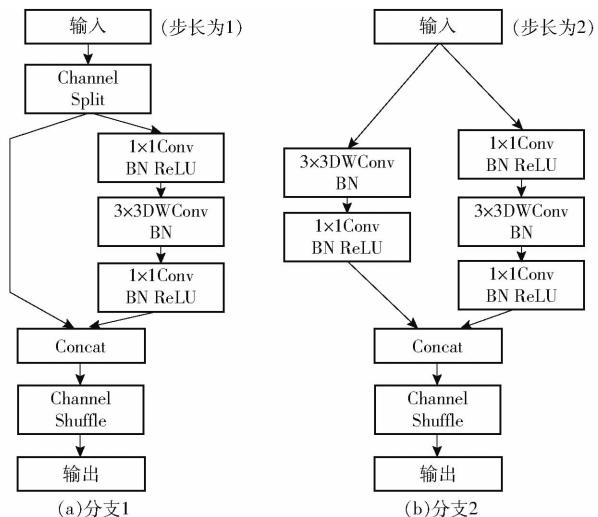


图4 模块卷积

Fig. 4 Block-Conv

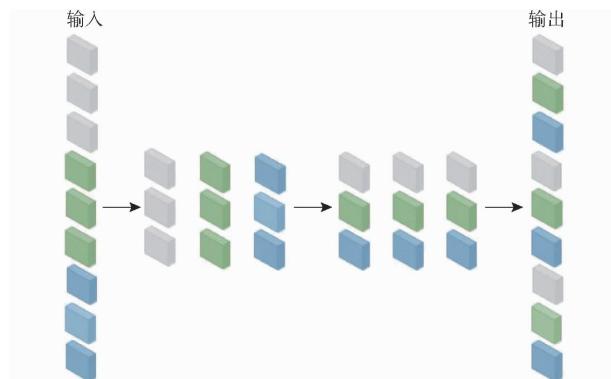


图5 通道混淆

Fig. 5 Channel shuffle

模型结合了迁移学习方法<sup>[26]</sup>,在训练模型时加载预训练权重并且冻结网络所有层,只在最后全连接层进行训练,去除原模型全连接层,增加本实验所需全连接输出类别。

#### 1.2.4 训练策略选择

模型训练技巧可以提高模型准确率,本文选择4种衰减策略进行研究,各策略实现如下:

(1) 梯形衰减( $T$ ):即在训练过程中,迭代一定的周期使初始学习率以一定周期进行衰减,直到迭代结束。表达式为

$$l_{r+1} = \delta(aT_1)wl_r \quad (1)$$

式中  $l_r$ —学习率  $w$ —伽马值

$T_1$ —梯形周期  $\delta$ —冲激函数

$a$ —周期因子

(2) 指数衰减( $E$ ):衰减系数作为基底,周期性衰减。表达式为

$$l_{r+1} = l_rw^t \quad (2)$$

式中  $t$ —当前轮数

(3) 全局预热-余弦退火策略<sup>[27]</sup>(W-COS)函数表示为

$$l_{r+1} = \begin{cases} b + \frac{tl_r}{T_2} & (t < T_2) \\ 2 \left( 1 + \cos \left( \frac{t\pi}{T - T_2} \right) \right) & (t \geq T_2) \end{cases} \quad (3)$$

式中  $T_2$ —全局预热周期

$T$ —训练总轮数

$b$ —预热初始值

(4) 全局预热-线性衰减(W-EP)函数表示为

$$l_{r+1} = \begin{cases} b + \frac{tl_r}{T_2} & (t < T_2) \\ \frac{t - T_2}{T_2 - T'}l_r & (t \geq T_2) \end{cases} \quad (4)$$

#### 1.2.5 模型评价指标

为衡量模型的识别精度<sup>[28]</sup>,选择准确率、查准率、查全率、特异性和F1值5个指标进行评价。

## 2 结果与讨论

### 2.1 马铃薯特性

图6为发芽马铃薯(图6a~6d)与健康马铃薯样本(图6e~6h)。

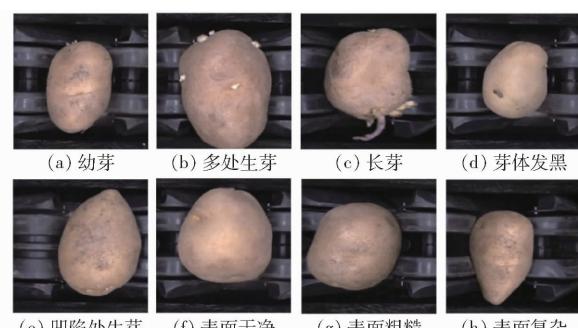


图6 样本特征

Fig. 6 Sample characteristics

### 2.2 模型优化

模型选取冲量为0.9的SGD(Stochastic gradient descent)优化算法,训练及验证的批量大小为16,训练损失通过交叉熵损失函数计算。对比不同的学习率与衰减策略,选择最优结果进行实验。

### 2.2.1 学习率选择

学习率是卷积神经网络中非常重要的超参数之一,为了更好地在网络中选择合适的学习率,实验在控制其他条件相同下,根据经验选择迭代轮数为 200,学习率分别为 0.1、0.01 和 0.001 进行分析。图 7 为实验验证集结果。由图 7a 可知,学习率为 0.01 比其他两种学习率损失值略低。对比图 7b 中曲线,迭代初期,学习率为 0.001 情况下准确率保持较低数值不变,学习率为 0.1 与 0.01 准确率在 90% 附近波动较大,迭代 100 轮时,学习率为 0.001 时随着迭代轮数的增加准确率较平稳,而其他两种学习率情况下准确率波动明显。迭代 200 轮,对比验证集准确率,结果表明当学习率为 0.001 时,泛化能力最佳,可以获得较好的结果。

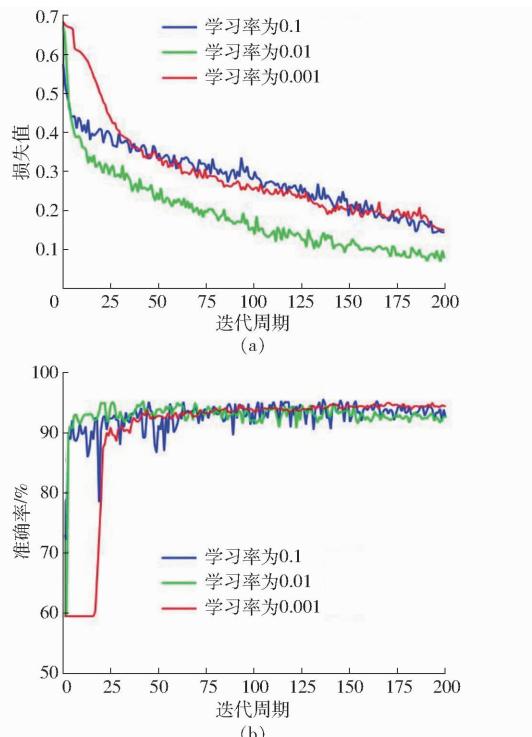


图 7 不同学习率时验证集实验变化曲线

Fig. 7 Change curves of validation sets test with different learning rates

### 2.2.2 衰减策略

实验选择学习率为 0.001, 对比 T、E、W-COS 和 W-EP 共 4 种策略, 模型训练 200 轮, 设置 T 中衰减周期为 10, Gamma 值为 0.8, E 中 Gamma 值为 0.99, 全局预热训练 9 轮, 预热结束后根据设定的策略进行衰减, 结果如图 8 所示。可以发现各策略准确率均高于 90%, 其中 W-EP 准确率最高为 94.53%, T 最低为 92.85%。可以证明学习率的衰减策略对验证集准确率非常重要, 对比 4 种衰减策略, 可以验证带有预热学习率衰减策略准确率优于其他方法, W-EP 较 W-COS 在验证集上表现更

佳, 因此选择 W-EP 策略。

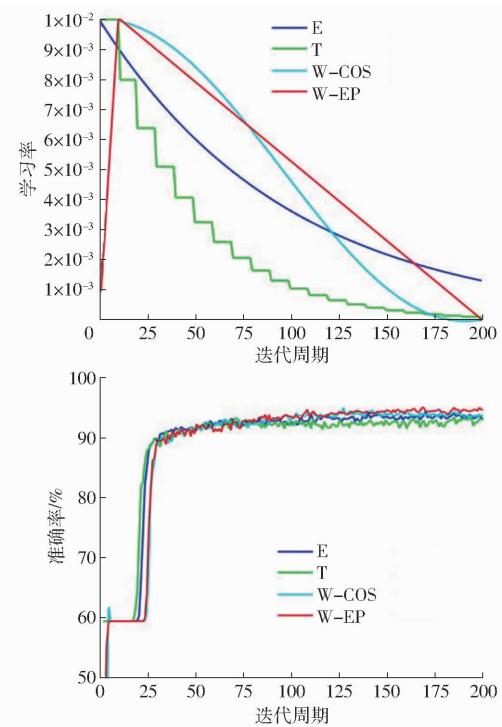


图 8 不同衰减策略时学习率与准确率变化曲线

Fig. 8 Change curves of learning rate and accuracy with different decay strategies

### 2.3 模型分析

#### 2.3.1 可视化特性分析

为进一步分析模型卷积过程, 实验将模型过程中初始卷积层、中间卷积层和最后卷积层的部分特征图进行了提取, 各层特征图如图 9 所示。在初始卷积层中, 卷积核更多关注图像颜色信息与亮度信息。中间卷积层则做了进一步处理, 更多关注特征的纹理, 同时也加深了特征的维度。最后卷积层特征高维化, 特征图的每一个方格代表一个像素点, 对前层输入量注意力更加集中, 关注各个特征图中的主要信息。分析了特征图的各卷积层的信息, 可以发现在卷积过程中, 层层卷积深入并下采样, 对特征进行逐步的高维化, 提取出主要的特征信息, 区分各个类别的不同点以实现识别。

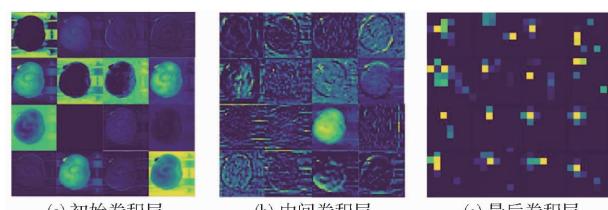


图 9 特征图

Fig. 9 Feature maps

#### 2.3.2 实验结果与评价

测试集样本包括 122 个健康马铃薯, 103 个发芽马铃薯。在 122 个健康马铃薯中, 120 个识别正

确,2个误判为发芽马铃薯,识别特异性为98.4%。103个发芽马铃薯中,100个正确识别,3个误判为健康马铃薯,识别查全率为97.1%。两类类别总体识别准确率达到97.8%。同时查准率、调和均值为98.0%、97.5%,可见本实验模型对发芽马铃薯识别效果良好。

### 2.3.3 误判分析

测试结果中共有5个误判马铃薯,如图10所示,其中图10a、10b为健康马铃薯误判为发芽马铃薯,图10c~10e为发芽马铃薯误判为健康马铃薯。图10a中薯体表面凹陷处明显,造成误判的原因可能是卷积过程中将此特征进行了提取,识别为发芽马铃薯。图10b中薯体表面有小区域凸起发黑,从而造成误判。针对图10c~10e,实验统计了测试集中发芽马铃薯芽体位于边缘的样本,识别正确的样本表现出芽体较长、颜色亮,且薯体、背景色差明显的特点;可以发现图10c中芽体颜色暗,图10d芽体处于薯体边缘且薯体表面较亮,图10e中芽体短且颜色暗,因此造成误判。由误判结果可知本实验模型对马铃薯边缘微小特征提取还存在一定的缺陷,但是总体上达到了预期效果,误判数量也在允许范围内。实验验证了模型的良好性能,也为马铃薯缺陷无损检测分级提供了新的方法。实验也存在一些不足需后续进行改进:①分级线上滚轴托盘为黑色,获取得到的图像背景会对待测物造成一定的影响。②数据样本需进一步的扩充,提高复杂发芽马铃薯的适应性。

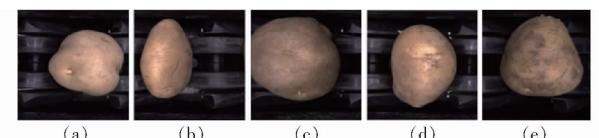


图10 结果误判

Fig. 10 Results misjudgment

### 2.4 模型对比

在相同数据集下,训练轮数为200,选择Alex-Net、VGG11、Res-Net与本文模型进行对比分析。Alex-Net在初代的CNN中加深了网络深度。VGG在Alex-Net的基础上,通过卷积核增加了通道数,参数量也随之增加,训练时间加长。Res-Net网络通过残差网络结构加深网络结构的深度,可实现特

征的有效提取。模型对比实验结果如表3所示,本文模型测试集总体识别准确率最高,较VGG11与Alex-Net得到了大幅度的提升,较Res-Net101模型提高了2.2个百分点。在识别时间方面,本文模型与Alex-Net识别时间相当,识别时间为0.14 s,可适应于分级线分选要求。识别时间较Res-Net101快5倍、较VGG快近7倍。在模型体量方面,本文模型内存占用量为5.2 MB,较其它3种模型大幅度降低,可以更好的应用于移动端。实验结果表明,本文模型对发芽马铃薯检测有良好的表现,同时具有识别准确率高、体量小、识别分级速度快、实用性强的优点。

表3 模型对比结果

Tab. 3 Model comparison results

模型	识别	识别	准确率/%	识别单个	模型内存
	正确	错误		样本平均	占用量/MB
	样本	样本		时间/s	
VGG11	175	50	77.8	1.11	515.1
Res-Net101	215	10	95.6	0.84	170.7
Alex-Net	170	55	75.6	0.14	58.3
本文模型	220	5	97.8	0.14	5.2

### 3 结束语

实验对比了不同学习率与衰减策略下模型的准确率,并提出使用带全局预测策略进行优化,验证了当学习率为0.001,衰减策略为W-EP时,本文模型性能最佳。可视化分析了模型特征图,最后卷积层高维化实现对发芽特征提取,进而可实现准确识别。对测试集样本进行评价,本文模型的总体识别准确率达到97.8%,查准率为98.0%,查全率为97.1%,特异性为98.4%,F1值为97.5%。各项评价指标表明本文模型对发芽马铃薯识别的稳定性较好。实验结果表明芽体颜色暗、芽体较短是造成误判的主要原因。与VGG11、Alex-Net、Res-Net101模型进行了对比,得出本文模型在总体识别准确率、单个样本识别时间、模型体量方面相比VGG11、Alex-Net、Res-Net101最优。根据实验可以发现,本文模型有识别效率高、体量小、易移植的特点,同时也为马铃薯缺陷检测分级提供了新的方法。

### 参 考 文 献

- [1] 金瑞. 基于高光谱图像和光谱信息融合的马铃薯品质检测方法[D]. 武汉:华中农业大学,2016.
- JIN Rui. Detection of quality of potatoes based on fusion of hyperspectral imaging and spectral information [D]. Wuhan: Huazhong Agricultural University, 2016. (in Chinese)
- [2] 苏文浩. 马铃薯外部缺陷的高光谱技术无损检测研究[D]. 银川:宁夏大学,2014.
- SU Wenhao. Non-destructive detection of hyperspectral imaging in detecting potato external defects [D]. Yinchuan: Ningxia University, 2014. (in Chinese)
- [3] GOMES J F S, LETA F R. Applications of computer vision techniques in the agriculture and food industry: a review [J].

- European Food Research and Technology, 2012, 235(6):989–1000.
- [4] COSTA C, ANTONUCCI F, PALLOTTINO F, et al. Shape analysis of agricultural products: a review of recent research advances and potential application to computer vision [J]. Food and Bioprocess Technology, 2011, 4(5):673–692.
- [5] 周竹, 黄懿, 李小昱, 等. 基于机器视觉的马铃薯自动分级方法 [J]. 农业工程学报, 2012, 28(7):178–183.  
ZHOU Zhu, HUANG Yi, LI Xiaoyu, et al. Automatic detecting and grading method of potatoes based on machine vision [J]. Transactions of the CSAE, 2012, 28(7):178–183. (in Chinese)
- [6] 郁志宏, 郝慧灵, 张宝超. 基于欧氏距离的发芽马铃薯无损检测研究 [J]. 农机化研究, 2015, 37(11):174–177.  
YU Zhihong, HAO Huiling, ZHANG Baochao. Research on sprouted potato non-destructive detection based on euclidean distance algorithm [J]. Journal of Agricultural Mechanization Research, 2015, 37(11):174–177. (in Chinese)
- [7] 郑冠楠, 谭豫之, 张俊雄, 等. 基于计算机视觉的马铃薯自动检测分级 [J]. 农业机械学报, 2009, 40(4):166–168, 56.  
ZHENG Guannan, TAN Yuzhi, ZHANG Junxiong, et al. Automatic detecting and grading method of potatoes with computer vision [J]. Transactions of the Chinese Society for Agricultural Machinery, 2009, 40(4):166–168, 56. (in Chinese)
- [8] HASANKHANI R, NAVID H. Potato sorting based on size and color in machine vision system [J]. Journal of Agricultural Science, 2012, 4(5):235–244.
- [9] YAO L, LU L, ZHENG R. Study on detection method of external defects of potato image in visible light environment [C] // 10th International Conference on Intelligent Computation Technology and Automation, 2017:118–122.
- [10] LECUN Y, BOTTOU L. Gradient-based learning applied to document recognition [J]. Proceedings of the IEEE, 1998, 86(11):2278–2324.
- [11] 田有文, 吴伟, 卢时铅, 等. 深度学习在水果品质检测与分级分类中的应用 [J]. 食品科学, 2021, 42(19):260–270.  
TIAN Youwen, WU Wei, LU Shiqian, et al. Application of deep learning in fruit quality detection and classification [J]. Food Science, 2021, 42(19):260–270. (in Chinese)
- [12] DOR O, GUY S, ORLY E, et al. Using deep learning for image-based potato tuber disease detection [J]. Phytopathology, 2019, 109(6):1083–1087.
- [13] MARINO S, BEAUSEROY P, SMOLARZ A. Weakly-supervised learning approach for potato defects segmentation [J]. Engineering Applications of Artificial Intelligence, 2019, 85:337–346.
- [14] CASAÑO C D L C, SÁNCHEZ M C, CHAVEZ F R, et al. Defect detection on andean potatoes using deep learning and adaptive learning [C] // Proceedings of the 2020 IEEE Engineering International Research Conference, 2020:1–4.
- [15] 傅云龙, 梁丹, 梁冬泰, 等. 基于机器视觉与 YOLO 算法的马铃薯表面缺陷检测 [J]. 机械制造, 2021, 59(8):82–87.  
FU Yunlong, LIANG Dan, LIANG Dongtai, et al. Detection of potato surface defects based on machine vision and YOLO algorithm [J]. Machinery, 2021, 59(8):82–87. (in Chinese)
- [16] MING W, DU J, SHEN D, et al. Visual detection of sprouting in potatoes using ensemble-based classifier [J]. Journal of Food Process Engineering, 2018, 41(3):e12667.
- [17] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks [J]. Commun. ACM, 2017, 60(6):84–90.
- [18] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [J]. arXiv:1409.556.
- [19] SZEGEDY C, WEI L, YANGQING J, et al. Going deeper with convolutions [C] // Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition, 2015:1–9.
- [20] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C] // Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition, 2016:770–778.
- [21] ZHANG X, ZHOU X, LIN M, et al. ShuffleNet: an extremely efficient convolutional neural network for mobile devices [C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018:6848–6856.
- [22] MA N, ZHANG X, ZHENG H, et al. ShuffleNet V2: practical guidelines for efficient cnn architecture design [C] // Computer Vision-ECCV 2018, 2018:122–138.
- [23] HOWARD A G, ZHU M, CHEN B, et al. MobileNets: efficient convolutional neural networks for mobile vision applications [J]. arXiv:1704.04861.
- [24] 李亚硕, 邱雁楠, 毛文华, 等. 香梨自动称量分级系统 [J]. 农业工程, 2018, 8(5):63–68.  
LI Yashuo, QI Yannan, MAO Wenhua, et al. Automatic weighing and grading system for Korla fragrant pear [J]. Agricultural Engineering, 2018, 8(5):63–68. (in Chinese)
- [25] LIU B, DING Z, ZHANG Y, et al. Kiwifruit leaf disease identification using improved deep convolutional neural networks [C] // Proceedings of the 2020 IEEE 44th Annual Computers, Software, and Applications Conference, 2020:1267–1272.
- [26] PAN S J, YANG Q. A survey on transfer learning [J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10):1345–1359.
- [27] HE T, ZHANG Z, ZHANG H, et al. Bag of tricks for image classification with convolutional neural networks [J]. arXiv:1812.01187.
- [28] 杨森, 冯全, 张建华, 等. 基于轻量卷积网络的马铃薯外部缺陷无损分级 [J]. 食品科学, 2021, 42(10):284–289.  
YANG Sen, FENG Quan, ZHANG Jianhua, et al. Nondestructive classification of defects in potatoes based on lightweight convolutional neural network [J]. Food Science, 2021, 42(10):284–289. (in Chinese)