

基于轻量级金字塔网络的种子分选方法研究

李卫杰¹, 桑肖婷¹, 李环宇², 魏平俊¹, 李 晓¹

(1. 中原工学院 电子信息学院, 郑州 450007

2. 中国石油大学(华东)海洋与空间信息学院, 山东 青岛 266580)

摘要: 针对目前卷积神经网络种子分选方法存在识别精度不高、模型参数量大、推理速度慢且难于部署等问题, 提出了基于轻量级金字塔空洞卷积网络的种子分选方法; 该网络提出了残差空间金字塔模块, 利用不同扩张率的空间卷积扩大感受野, 更有效地提取多尺度特征; 再结合深度可分离卷积技术减少模型参数量和计算复杂度; 在网络结构中引入轻量级注意力机制模块, 利用局部跨通道交互方式关注重要的信息, 提高种子关键特征提取能力; 实验结果表明, 提出网络参数量仅为 0.13 M, 在玉米和红芸豆数据集上准确率高达 96.00% 和 97.38%, 在 NVIDIA Quadro 板卡上识别单张图片时间仅为 4.51 ms, 均优于主流轻量级网络 MobileNetv2、Shufflenetv2 和 PPLC-Net 等, 可以满足工业现场实时识别的要求。

关键词: 种子分选; 轻量化网络; ECA 注意力机制; 深度可分离卷积; 空洞卷积

Research on Seed Sorting Method Based on Lightweight Pyramidal Network

LI Weijie¹, SANG Xiaoting¹, LI Huanyu², WEI Pingjun¹, LI Xiao¹

(1. School of Electrical and Information Engineering, Zhongyuan University of Technology, Zhengzhou 450007, China;

2. College of Marine and Spatial Information, China University of Petroleum (East China), Qingdao 266580, China)

Abstract: To address the problems of low recognition accuracy, large number of model parameters, slow inference speed and difficult deployment in current convolutional neural network seed sorting methods, a seed sorting method based on lightweight pyramidal dilated convolutional network is proposed. A residual spatial pyramid module is proposed to expand the perceptual field by using the convolution of dilated with different expansion rates, to effectively extract the multi-scale features. Then, deep-wise separable convolution techniques are used to reduce the model parameters and the computational complexity. A lightweight attention mechanism module is introduced into the network structure to improve the extraction of seed key feature, the local cross-channel interactions are adopted to focus on the important information. The experimental results show that the parameter quantity of the proposed network is only 0.13 M, with a accuracy on corn dataset and red kidney bean dataset of 96.00% and 97.38%, and the average time of 4.51 ms to recognize single image on NVIDIA Quadro board, the recognition time on the NVIDIA Quadro board is better than that of the mainstream lightweight networks, such as MobileNetv2, Shufflenetv2 and PPLC-Net, etc., which can meet the requirements of real-time recognition in industrial sites.

Keywords: seed sorting; lightweight networks; ECA attention mechanism; depth-wise separable convolution; dilated convolution

0 引言

种子在收获或存储的过程中, 可能混入部分杂交种和杂质, 直接影响后续加工或者育种, 给农业及农产品加工业带来不同程度的经济损失。因此, 快速有效的种子鉴别和分类可有利于提升种子质量, 成为研究的热点。目前, 种子分选可分为以下三类: 人工方法、基于传统模式识别的方法和基于深度学习的方法。基于人工方法费时、费力且效率低, 不能满足现代农业发展的需要。基于传统模式识别方法利用特征工程提取图像形状、颜色、尺寸和形状等特征, 并利用支持向量机和决策树等多种有效的分类器

识别种子^[1-3]。Li 等^[4]提取 12 种颜色特征, 并利用最大似然估计分类器区分不同类型的玉米病害, 对正常和病害玉米的分类精度达到了 74.76%; KokLu 等^[5]提取 16 个形态学特征, 并采用 SVM 分类器对干豆进行分类, 整体分类正确率为 93.13%。传统模式识别的方法采用手工描述子进行特征提取, 这种方法特征提取有效性不高且自适应性不强, 导致整体识别率较低。

深度学习由数据驱动可自适应学习到更多有效的特征, 被广泛应用到目标检测^[6]、图像识别^[7]及图像分割^[8]等领域, 并取得了很好的效果。目前相关学者已将深度学习技

收稿日期: 2023-03-06; 修回日期: 2023-06-06。

基金项目: 国家自然科学基金项目(U1804157, 62072489); 河南省教育厅科技创新团队(21IRTSTHN013)。

作者简介: 李卫杰(1996-), 女, 硕士研究生。

魏平俊(1963-), 男, 博士, 教授。

引用格式: 李卫杰, 桑肖婷, 李环宇, 等. 航天器展开机构压力传感器无线测控系统设计[J]. 计算机测量与控制, 2024, 32(3): 239-246.

术应用到种子分选中。范晓飞等人^[9]基于改进 YOLOV4 的目标检测模型，同时结合四通道 (RGB+NIR) 多光谱图像，对玉米种子外观品质进行了识别与分类，准确率达到 93.09%。侯俊铭等人^[10]针对水稻种子间识别率低等问题，提出基于卷积神经网络与支持向量机技术相结合的方法对 8 类水稻种子进行分类识别，最后 8 种水稻种子识别正确率分别为 96.2%、95.8% 和 96.1%，且识别单张图片推理时间为 5.57 ms。杨红云等人^[11]使用卷积神经网络对蓖麻种子损伤进行分类，模型分类准确率达到 94.82%。然而，上述方法的精度依赖于其网络的深度，这导致了计算成本较大，且难以有效部署到计算资源有限的边缘设备上。

为了减少深度模型存储量，使其易于部署到工业现场中的边缘设备上，基于轻量化网络种子分选成为该领域研究的重点。董燕等人^[12]提出联合剪枝深度模型压缩的种子分选方法，在玉米数据集上达到 95.56% 的准确度。李好等人^[13]针对农作物识别方法中存在模型较为复杂，实时准确率较差的问题，提出改进 ShuffleNetV2 轻量级农作物病害识别方法，在 PlantVillage 病害数据集上进行实验识别率达到了 99.24%。Xie 等人^[16]构建了一个轻量级的胡萝卜质量分类模型，对正常、破碎、裂纹、畸形、瘀伤和分叉 6 类胡萝卜的识别准确率为 97.04%。Zhao 等人^[17]利用改进的 MobileNetv2 模型对 6 种不同的大豆种子进行了识别，分类准确率达到 97.84%。然而，以上所提模型仍然占用较多的内存空间，且由于农产品产量的增加，执行速度仍需进一步的提升。因此，需要在保证较高识别率的前提下，进一步压缩模型大小，使其更易部署到边缘设备中。

针对种子分选方法仍存在识别精度不高、模型参数量大、推理速度慢且难于部署等问题，提出了一种基于轻量化空间金字塔网络的种子分选方法。首先，设计了多分支残差空间金字塔模块 (RSPM, residual spatial pyramid module)，为了更有效地提取多尺度特征，每个分支采用不同扩张率的空洞卷积增强感受野；采用深度可分离卷积技术减少模型参数数量和计算复杂度；同时提出轻量级注意力机制模块 (ECA, efficient channel attention)，利用局部跨通道交互方式生成各通道的注意力值，增强网络对关键特征的学习能力，在保持较高识别精度的前提下，最终构建一种有效的轻量化种子分类模型。

1 网络模型

针对种子形态多样、特征差异不明显，识别精度不高且现有深度识别模型参数量大，导致不宜部署等问题，本文提出了一种基于注意力的轻量高效的端到端种子识别分选模型。该模型主要由轻量残差空间金字塔模块 (RSPM) 和基本块深度可分离卷积成，如图 1 所示。首先，采用设计的 RSPM 模块将不同尺度的空洞卷积核进行多尺度融合，

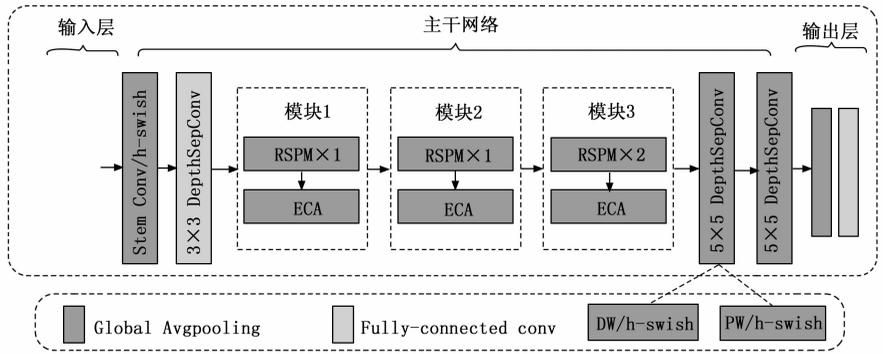


图 1 LPD-Net 网络结构

在保持更少参数和更低的计算复杂度的情况下提取有效的特征。然后进一步与深度可分离卷积结合，实现分类识别精度和效率之间的折衷。最后引入轻量化的注意力机制 ECA 模块提取细粒度特征，从而提升不同种子特征的区分度。

1.1 空间金字塔网络 LPD-Net

空间金字塔网络通过特征金字塔 (FPN)^[19]能够充分提取多尺度特征信息并将其融合，具有很强的特征表征能力。然而，由于不同尺度的特征都包含丰富的语义信息，导致金字塔网络占用较大内存，推理速度慢，从而影响在嵌入设备上的部署。本文基于空洞卷积多分支残差金字塔模块和深度可分离卷积对特征图进行重新采样，利用空洞卷积采样扩大感受野的结构特性，聚合多尺度上下文信息提出轻量级的空间金字塔网络 LPD-Net。该网络采用高效的空空间金字塔模块 (RSPM) 和深度可分离卷积，空间金字塔模块采用 3 个不同扩张率的空洞卷积层对特征图进行重新采样，获取丰富的多尺度特征的同时，减少模型参数数量，提高推理效率；再引入轻量 ECA 注意力机制来增强对特征的学习和表达，提高模型的识别精度，因此具有模型规模小、识别准确率高及推理速度快的特点。具体模型结构如表 1 所示，其中第六列代表不同的激活函数，“HS”代表 Hard_swish 激活函数，“RE”代表 ReLU 激活函数，第八列代表是否使用 ECA 注意力机制。

表 1 LPD-Net 网络结构图

阶段	模块	核大小	输入	输出	激活函数	步长	注意力模块
1	Conv2D	3×3	224 ² ×3	112 ² ×16	RE	2	—
2	DepthSepConv	3×3	112 ² ×16	112 ² ×32	HS	1	√
3	RSPM×1	—	112 ² ×32	56 ² ×64	RE	2	√
4	RSPM×1	—	56 ² ×64	56 ² ×64	HS	1	√
5	RSPM×2	—	56 ² ×64	28 ² ×128	RE	2	√
6	DepthSepConv	5×5	14 ² ×128	7 ² ×256	HS	2	—
7	DepthSepConv	5×5	7 ² ×256	7 ² ×256	HS	1	—
8	GAP	7×7	7 ² ×256	1 ² ×256	—	1	—
9	FC	—	1 ² ×256	1 ¹ ×2/4	—	1	—

为了进一步提取高层的语义信息和底层的纹理信息，首先使用 3×3 卷积提取初始特征 (如颜色、纹理和形状)，

然后设计轻量的残差空间金字塔模块 (RSPM) 实现多尺度特征图的高效融合, 分别在 3、4、5 层分别采用 1、1 和 2 个 RSPM 模块进行特征的提取。然而, 特征图分辨率的降低往往会导致信息丢失, 影响最终的预测结果。因此, 本文在 3、4、5 层使用注意力模块增强对空间和细节信息的提取能力。随着网络层数的增加, 为了减轻模型的计算效率并减少参数, 在 2 和 6、7 层使用了 3×3 和 5×5 深度可分离卷积和 H-Swish 激活函数增强全局信息的提取。最后, 在第 5 次下采样之后进行全连接层输出, 将 2D 特征映射转换为 1D 特征向量。

1.2 残差空洞金字塔模块 (RSPM)

在种子分类过程中, 不同种类种子特征在形状、纹理和颜色上具有高度相似性。为了更有效地提取种子的细节信息, 提升特征的区分度, 浅层特征提取尤为重用, 受轻量级网络 MobileNet、SqueezeNet 等设计思路的启发, 本文提出了一种新型的轻量级多分支空洞卷积金字塔 (RSPM) 模块, 将 1×1 的逐点卷积和多分支空洞卷积残差块进行特征融合, 有效提取细节信息, 具体如图 2 所示。

首先将高维特征映射通过一次 1×1 卷积投影到低维空间。然后为解决主干网络轻量化后带来输出特征表达不足问题, 采用 3 个不同扩张率的空洞卷积分支对特征图进行重新采样, 以获取更丰富的多尺度特征和语义信息。然而当扩张率扩大时, 需要大量填充来维持特征图的大小, 这将造成信息相关特性的损失并增加较大计算开销^[20, 32]。为了在不增加特征图分辨率的同时, 聚合多尺度信息, 采用扩张率分别为 1、2 和 3 的扩张卷积进行特征提取。最后为进一步减少参数数量和内存占用, 使用 1×1 卷积残差块来整合信息并保留原始细节, 并通过跨通道融合所有特征。通常下采样操作造成的信息丢失是不可逆的, RSPM 的优点就是在降采样过程中增加感受野而不损失使每个卷积输出包含更多的特征信息。

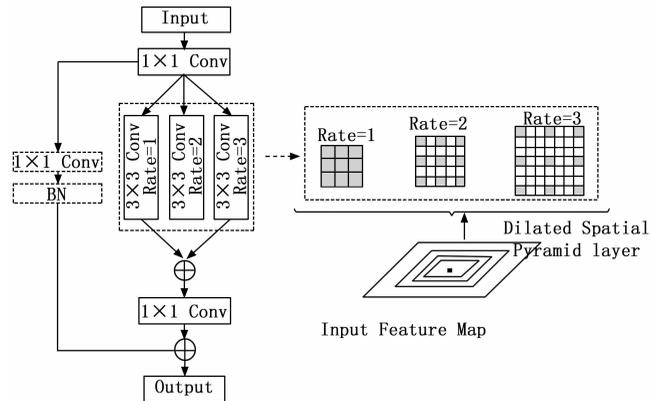


图 2 残差空洞金字塔模块

1.3 深度可分离卷积模块

随着特征通道数量的增加, 计算量也随之增加。在网络中间和最后两个卷积层, 本文采用 MobileNetV2^[14] 提出的深度可分离卷积作为主干网络的基本块进行特征提取,

并减少因卷积运算产生的参数量。如图 3 所示。首先, 深度可分离卷积是将标准卷积分解为两个单独的层 (图 3 (a)), 第一层使用深度卷积 (图 3 (b)), 卷积滤波器应用于各个输入通道以捕获更丰富的空间信息。然后第二层采用逐点卷积, 即 1×1 卷积来捕获跨通道信息。标准卷积的参数量计算为 $D_k \times D_k \times M \times N$; 深度可分离卷积的参数量计算包括两部分 (1) 逐深度卷积: $D_k \times D_k \times 1 \times M$, (2) 逐点卷积: $1 \times 1 \times N \times M$ 。参数量总数为: $D_k \times D_k \times M + N \times M$ 。参数量之比为: $\frac{D_k \times D_k \times M + N \times M}{D_k \times D_k \times M \times N} = \frac{1}{N} + \frac{1}{D_k^2}$ 。深度可分离卷积的参数量是标准卷积的 $\frac{1}{N} + \frac{1}{D_k^2}$ 倍。

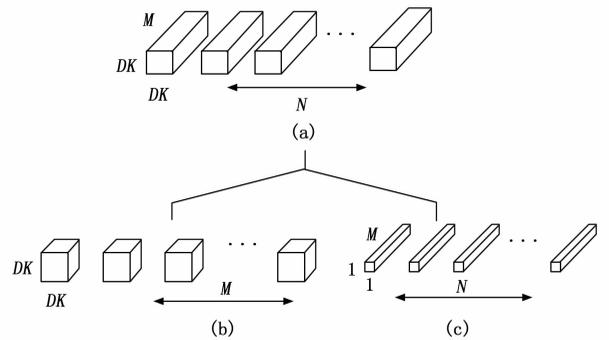


图 3 深度可分离卷积块

该卷积块不包含残差短连接, 没有 connect 或 element-wise-addition 等额外操作, 很大程度地降低了模型复杂度。如图 3 深度可分离卷积块, 此外, 卷积核的大小往往会影响网络的最终性能, 大小通常固定 (如 3×3), 不能适应种子图像姿态或形状的变化。本文在确保低延迟高精度的情况下, 在 2、6 和 7 层中不只是使用一种大小的卷积核。同时, 在网络的最后两层使用 5×5 卷积核, 这增强了种子全局信息提取并提高了特征表示能力^[22-23]。另外, 在深度可分离卷积中使用了 H-swish^[23] 激活函数, 避免了大量的索引操作。

1.4 ECA 轻量级注意力模块

大量研究表明, 通道注意力机制能够有效地提升模型的性能, 但是大多注意力机制在带来性能提升的同时也会带来很大的计算负担。因此, 在本文中为了提升模型性能引入了 ECA^[18] 轻量级注意力模块, 此模块通过学习不同通道的特征来表示不同通道的重要性, 为每个通道划分不同的注意力值。不同的通道通过学习不同的特征并赋予不同的注意力值, 使网络能够合理的分配计算资源, 最终模型的性能得到显著提升。

如图 4 所示。该模块将输入特征图进行全局平均池化, 提取种子的形状特征, 为了避免降维对通道注意力对特征学习的不利影响, 模块并不降低特征图维度。接着通过执行一定数量为 K 的 1D 卷积对每个通道及其邻近的 K 个通道进行信息交互, 只通过邻近通道间进行跨通道学习, 避免所有通道进行信息提取时而产生更多的冗余信息。然后

采用 Sigmoid 函数评估各通道间的重要性, 根据各通道间的相关性计算出各通道的注意力值, 其中 K 的值由通道系数 C 的映射自适应决定并成正比关系, 可以有效避免实验中通过交叉验证手动调优 K 。通过自适应学习通道注意力权重, 强化重要的通道特征, 弱化不重要的特征, 从而提升模型准确度。

$$K = \varphi(C) = \left\lfloor \frac{\log_2 C}{r} + \frac{b}{r} \right\rfloor_{\text{odd}} \quad (1)$$

如公式 (1) 所示, C 为通道数; odd 表示向上取最近的奇数, 取 $r=2, b=1, K$ 表示局部跨通道信息交互的通道个数。

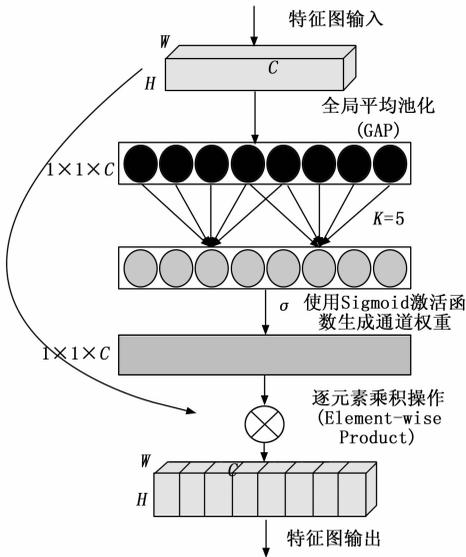


图 4 ECA 注意力模块结构

如图 5 所示, 把高效的通道注意力 ECA 模块加入到轻量 RSPM 残差空洞卷积金字塔基本单元中, 能够带来明显的性能提升。该模块只涉及到极少量参数, 可以在带来性能增益的同时保持网络轻量化。

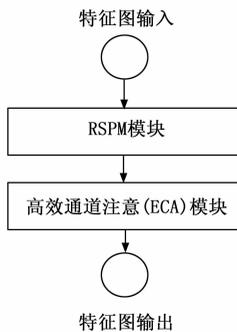


图 5 RSPM-ECA 模块结构

2 实验与结果分析

本文选择两个数据集来验证所提出的网络架构的有效性。所有实验都是在 64 位的 Linux 系统上进行的, 具体采用 Anaconda 环境, 使用 Python3.7.3、Pytorch1.9.1。硬

件采用 Intel (R) Xeon (R) CPU E5-2680 v4@2.40 GHz 和 NVIDIA Quadro M5000 GPU, CUDA11.0 加速计算。

2.1 数据集及参数设置

实验采用了随机梯度下降优化器训练网络, 动量参数为 0.9, 权重衰减参数为 $4e-5$ 。通过水平翻转将输入图像随机裁剪到 224×224 , 并将图片统一进行归一化处理。初始学习率为 0.01, 每经过 25 个 epoch 后学习率下降, 衰减率为 0.1, 总共进行了 200 个迭代训练, 批量大小 batchsize 设置为 32。

玉米数据集: 采用的玉米数据集是来自土耳其 Sakarya 的一个公共的单倍体和二倍体玉米种子分类数据集^[2]。它包含 3 000 张 RGB 图像, 其中 1 230 张单倍体图像和 1 770 张二倍体图像。根据种子的尺寸, 图像的分辨率在 300×289 像素和 610×637 像素之间变化, 一些典型的图像如图 6 所示。其中 738 个单倍体图片和 1 062 个二倍体图片作为训练集, 246 个单倍体和 354 个二倍体作为验证集, 其余用于测试。

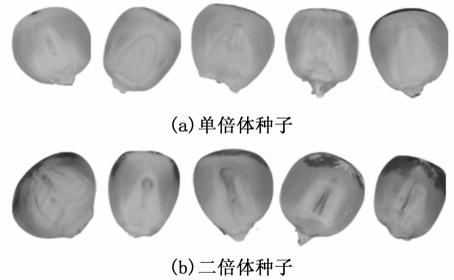


图 6 玉米种子数据集

考虑在识别种子过程中, 现实状态下存在很多的不确定性, 需要对玉米种子数据集进行随机旋转、水平翻转和标准化。本文通过增强图像和样本图像对模型进行训练, 提高模型的可靠性和精度, 进一步提高了模型的适用性。

红芸豆数据集: 玉米数据集是针对二分类种子分选问题, 为了综合评价所提算法在多分类种子分选中的有效性, 在工业生产线上构建红芸豆种子数据集进行实验。图像通过彩色线扫描相机进行采集, 采集设备为一台“1/2.5” CMOS 相机, 采集的图像分辨率为 224×224 像素。采用白色? 环形光源进行补光, 并利用白色背景板使红芸豆种子和背景更容易区分。根据企业进行质量评价的分级标准, 将样本分为四类: 饱满豆 (1 661 粒)、去皮豆 (509 粒)、干豆 (1 173 粒)、碎豆 (488 粒), 典型图像如图 7 所示。

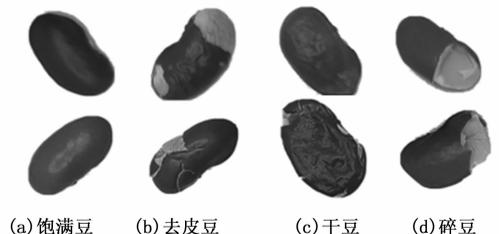


图 7 红芸豆数据集

2.2 评价指标

本文选择精确度 (precision)、准确率 (accuracy)、召回率 (recall)、F1 分数 (F-score) 等评价指标验证模型性能, 并利用混淆矩阵对 CNN 模型的性能进行可视化。混淆矩阵表示样本内的真实类别和 CNN 分类器预测的类别。如表 2 所示, 这 4 个指标包括以下内容: 真阳性 (全称, TP)、真阴性 (全称, TN)、假阳性 (全称, FP) 和假阴性 (全称, FN)^[25]。在研究中, 其中 TP (真阳性) 表示种子中的正类样本被正确识别为正类; 真阴性 (TN) 表示种子中负样本被正确识别为负类; 假阳性 (FP) 表示种子中负样本被错误识别为正类; 假阴性 (FN) 表示种子中正类样本被错误识别为负类。

表 2 CNN 模型性能指标

真实分类	预测分类	
	正类	负类
正类	TP	FP
负类	FN	TN

Precision 定义为公式 (2) 所示, 表示正确分类的正样本占总正样本的比率。

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

Accuracy 表示整体的准确率, 识别分类正确的样本占总样本的比率。如公式 (3) 所示。

$$Accuracy = \frac{TP + TN}{TP + FN + FP + TN} \quad (3)$$

Recall 的定义如公式 (4) 所示, 表示被识别成正样本占总样本的比例。

$$Recall = \frac{TP}{TP + FN} \quad (4)$$

F1-score 表示召回率和精确度的调和平均值。其公式为式 (5)。

$$F1\text{-score} = 2 \frac{Precision + Recall}{Precision + Recall} \quad (5)$$

2.3 实验结果分析

为了验证所提分类算法的性能, 建立了一个混淆矩阵, 并通过混淆矩阵 (TP, TN, FP, FN) 上的值进行了可视化的性能评估。CNN 模型在玉米和红芸豆测试集上的混淆矩阵结果如图 8 (a) 和 8 (b) 所示。其中在玉米数据集上的单倍体和二倍体识别率分别为 95.47% 和 96.73%。在红芸豆数据集上, 饱和豆类别的识别率高达 99.7%, 去皮豆、干豆和破碎豆的识别率分别为 96.04%、96.28% 和 96.91%。

玉米数据集: 表 2 给出了混淆矩阵所描述的性能指标, 包括准确性、精确度、查全率和 F1 评分的平均值。本文提出方法与 ResNet^[26]、GoogleNet^[27]、DenseNet^[28]、SENet^[29]、MobileNetV2^[11]、PPLCNet^[22]、ShuffleNetV2^[15]、GhostNet^[30]、MixNet^[23] 和 EfficientNet 共 10 个代表性的 CNN 模型在玉米数据集上进行了实验对比。实验结果由表 3 可知, 所提出的方法对目标分类准确率较高, 在相似的实验条件

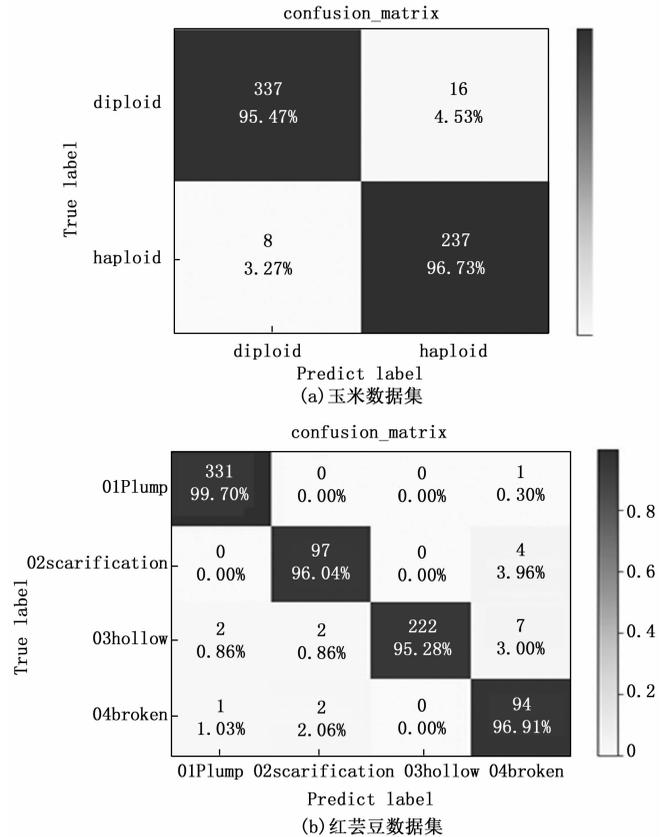


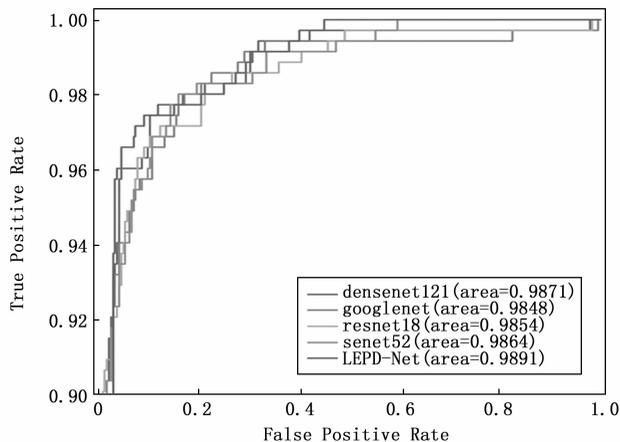
图 8 混淆矩阵

下可达到 96% 以上, 其他各项指标准确率、查准率、查全率和 F1score 分别为 96.00%、96.00%、96.00% 和 95.18%, 其计算复杂度和模型规模都相对较低。另外, 与经典的轻量化网络相比, 在参数量较少的情况下, 也得到了最好的分类准确度和推理速度。如在玉米数据集上, 在参数量仅为 0.26 M 的条件下, 本文算法获得了 96.11% 的分类准确度和 4.51 ms 的推理速度, 这也说明本文方法在实际部署中具有高效性和良好的性能。

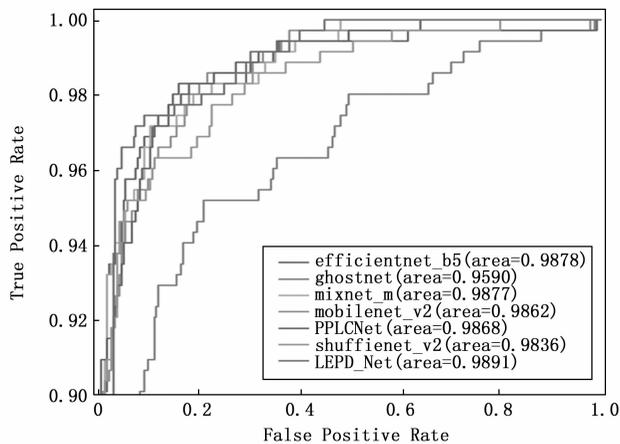
表 3 主流算法模型与本文方法对比

Model	Parameters/M	Flops	Acc/%	Precision/%	Recall/%	F1-score/%	推理时间/ms
Resnet18	11.18	1.82 G	94.48	94.48	94.48	93.30	3.80
DenseNet	6.96	2.88 G	94.65	94.81	94.81	93.60	20.87
Googlenet	9.94	1.51 G	94.30	94.65	94.65	93.67	9.6
SENet52	42.61	7.0 G	94.15	94.15	94.15	92.90	14.12
Efficientnet_b5	28.35	2.35 G	95.15	95.15	95.15	94.14	29.03
PPLC-Net	1.63	154.26 M	93.98	93.97	93.97	92.74	6.9
Shufflenetv2_1.5x	2.48	301.90 M	94.48	94.48	94.48	93.27	8.94
MobileNetV2	2.23	566.33 M	94.15	93.98	93.98	92.65	7.58
Ghostnet_1x	3.91	150.68 M	89.46	89.46	89.46	86.79	8.7
Mixnet-m	3.48	337.64 M	94.65	94.64	94.64	93.54	18.62
LPD-Net	0.13	75.3 M	96.11	96.10	96.10	95.10	4.51

为了进一步证明所提方法的有效性，也采用 ROC 曲线来测量模型性能。如图 9 所示对比了本文方法与其他网络模型的 ROC 曲线和 AUC 得分。从 AUC 得分来看，与其他 CNN 模型相比，该方法在玉米种子数据集上获得了 98.91% 的最佳结果，优于上述具有代表性的 CNN 模型和轻量级网络，说明 LPD-Net 具有很好的分类性能。



(a) 四种典型的网络



(b) 轻量级网络

图 9 CNN 模型对玉米数据集的 ROC 曲线

红芸豆数据集：表 4 展示了在红芸豆数据集上所提方法与不同网络模型计算复杂度、准确性、召回率和 F1 得分对比。从表中可以得出，在具有最少的 FLOPS 和参数量情况下，所提出的方法仍具有最高的准确度、召回率、精确度和 F1 得分。与在玉米数据集上识别类似，此方法在红芸豆种子数据集上与图像识别领域常见的模型如 ResNet^[26]、DenseNet^[28]、GoogleNet^[27]、MobileNetv2^[11]、ShuffleNetv2^[12]、GhostNet^[30] 和 PPLCNet^[22] 等进行了对比。实验结果如表 4 所示，为保证实验的公平性，所有模型训练时设置参数相同。从表 4 可以看出，所提方法与 ResNet18 等模型相比，准确度提升了 0.66%，精确度提升了 0.66%，召回率和 F1 得分分别提升了 0.66% 和 2.39%，参数量比 ResNet 减少了 10.92M。与其他轻量化网络相比，LPD-Net

模型的识别准确率，精确度和 F1 得分都优于 MobileNetv2 等，参数量比 MobileNetv2 减少 1.97M 同时推理速度达到最快为 4.51 ms。综上所述，LPD-Net 模型在种子分选任务中效果最佳，并且在确保高识别精度和高效率的同时，大大减少了对硬件部署的负担。

表 4 主流算法模型与本文方法对比

Model	Parameters(M)	Flops	Acc/%	Precision/%	Recall/%	F1_score/%	推理时间/ms
Resnet18	11.18	1.82 G	96.72	96.72	96.72	94.99	3.88
DenseNet	6.96	2.88 G	96.07	96.06	96.06	94.21	21.56
GoogleNet	9.94	1.51 G	95.94	95.93	95.93	93.72	9.71
SENet	44.66	7.0 G	97.60	97.60	97.60	96.05	14.08
Efficientnet_b5	28.35	2.35 G	96.10	96.10	96.10	94.51	31.48
PPLC-Net	1.63	154.26 M	95.28	95.28	95.28	95.28	7.06
Mobilenetv2	2.23	566.33 M	95.15	95.15	95.15	92.64	7.58
ShuffleNetv2 1.5x	2.48	301.90 M	96.85	96.85	96.85	95.10	8.94
Mixnet-m	3.48	337.64 M	96.59	96.72	96.72	94.91	19.04
LPD-Net	0.13	75.3 M	97.38	97.38	97.38	97.20	4.51

2.4 消融实验

为了兼顾精度和效率，本研究设计了 RSPM 模块和深度可分离卷积模块并引入了 ECA 注意力机制。本节在两个数据集上进行三组消融实验来验证各个模块在识别结果上的影响。实验在保证数据集、超参数设置等其他实验条件都相同的情况下，通过控制累加单一变量的方式完成。

实验结果详见表 5，第一组实验以 RSPM 模块作为主干特征提取网络，模型在极其轻量化的情况下在玉米和红芸豆数据集上准确率分别为 95.02% 和 96.99%，处理每张图片的推理时间仅为 4.25 ms，充分证明 RSPM 提取信息的能力较好而且更加高效。随着深度可分离卷积的加入，在几乎不增加参数数量的情况下，在玉米数据集上和红芸豆数据集上识别准确率分别提高了 0.30% 和 0.68%，表明加入深入可分离卷积可以有效的优化模型性能。此外也深入研究了注意力机制对模型性能的影响，引入注意力机制后在第二组的实验结果上准确度分别增加 0.11% 和 0.28%，同时参数量和推理速度几乎没有增加，充分验证了注意力机制作用在种子分选任务上的有效性。从实验中可以看出本文工作在减少大量参数数量的同时，也有效提升了模型的识别性能和推理速度。

表 5 消融模块在玉米和红芸豆数据集上的测试结果

RSPM	Depth SepConv	ECA	Acc (玉米)/%	Acc (红芸豆)/%	参数量/M	Flops /M	推理时间/ms
✓	×	×	95.02	96.99	0.12	75.3	4.25
✓	×	✓	95.32	97.10	0.12	75.3	4.36
✓	✓	✓	96.00	97.38	0.13	75.3	4.51

此外, 为了能够更直观地验证 ECA 注意力机制对种子分选任务的有效性, 使用 Grad-CAM^[31]对随机选择的输入图像区域进行可视化, 可视化出模型所关注的重点区域信息, 以此来定性分析模型对关键特征提取能力。此方法通过坐标注意力层应用目标特征的梯度, 创建一个粗略的局部特征图, 它突出了图像中该特征重要的区域。如图 10 所示, 分别选取 5 张玉米图像和红芸豆种子图像作为示例, 第一行和第三行分别为原始图像, 第二行和第四行为加入 ECA 模块的热力图。从图中可以清楚的看到该方法在玉米和红芸豆种子图像上的可视化结果, ECA 注意力机制能够帮助模型图像中关键信息, 提升模型对种子纹理和形状特征的表达能力。同时, 从表 5 中也可以看出, 注意力机制并没有引入太多的参数量和计算负担。

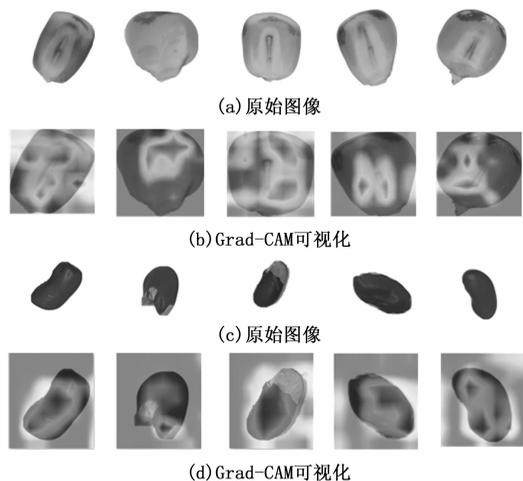


图 10 原始图像和 Grad-CAM 可视化

3 结束语

本文提出了一种轻量级金字塔空洞卷积网络, 即 LPD-Net, 用于种子分选任务中。该模型能够取得较高的识别准确率, 同时也兼顾了推理速度。首先, 设计了一种新型的轻量级金字塔空洞卷积模块 (即 RSPM), 利用不同扩张率的空洞卷积扩展感受野, 有效提取多尺度特征。接着进一步该模块与深度可分离卷积结合, 提升模型的特征提取能力并实现参数量和计算复杂度的降低。为了提高种子质量分选和鉴定的准确性, 通过引入一种轻量级的注意力模块 (ECA), 让模型更加关注关键信息从而提高整体分类性能。大量的实验也证明了该算法的有效性, 在两个种子数据集上都能达到最先进的识别效果。此外, 利用对输入的种子图像进行区域可视化, 提高了工作的效率。在未来的工作中, 我们将部署这个高准确度的轻量化模型到嵌入式设备中。

参考文献:

[1] SHIQING WU, ZHONGHOU WANG, BIN SHEN, et al. Human-computer interaction based on machine vision of a smart

assembly workbench [J]. *Assembly Automation*, 2020, 40 (3): 475-482.

[2] ALTUNTAS Y, KOCAMAZ, CENGIZ R, et al. Classification of haploid and diploid maize seeds by using image processing techniques and support vector machines [C] //Proceedings of the 26th Signal Processing and Communications Applications Conference (SIU), Izmir, Turkey, 2018: 1-4.

[3] LIU D, NING X, LI Z, et al. Discriminating and elimination of damaged soybean seeds based on image characteristics [J]. *Journal of Stored Products Research*, 2014, 60: 67-74.

[4] LI X, DAI B, SUN H, et al. Corn classification system based on computer vision [J]. *Symmetry*, 2019 11 (4): 591.

[5] KOKLU M, OZKAN IA. Multiclass classification of dry beans using computer vision and machine learning techniques [J]. *Computers and Electronics in Agriculture*, 2020, 174: 105507.

[6] 范晓飞, 王林柏, 刘景艳, 等. 基于改进 YOLO v4 的玉米种子外观品质检测方法 [J]. *农业机械学报*, 2022, 53 (7): 226-233.

[7] 杨红云, 黄琼, 孙爱珍, 等. 基于卷积神经网络和支持向量机的水稻种子图像分类识别 [J]. *中国粮油学报*, 2021: 36 (12): 144-150.

[8] 侯俊铭, 姚恩超, 朱红杰, 等. 基于卷积神经网络的蓖麻种子损伤分类研究 [J]. *农业机械学报*, 2020, 51 (s1): 440-449.

[9] 董燕, 李环宇, 李卫杰, 等. 基于联合剪枝深度模型压缩的种子分选方法研究 [J]. *河南农业科学*, 2022, 51 (1): 162-170.

[10] 李好, 邱卫根, 张立臣, 等. 改进 ShuffleNet V2 的轻量级农作物病害识别方法 [J]. *计算机工程与应用*, 2022, 58 (12): 1-9.

[11] SANDLER M, HOWARD A, ZHU M, et al. MobileNetV2: Inverted Residuals and Linear Bottlenecks [C] //Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, UT, USA, 2018: 1-14.

[12] ZHANG X, ZHOU X, LIN M, et al. ShuffleNet: An Extremely Efficient Convolutional Neural Network for Mobile Devices [C] //Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, UT, USA, 2018: 6848-6856.

[13] XIE W, WEI S, ZHENG Z, et al. A CNN-based lightweight ensemble model for detecting defective carrots [J]. *Biosystems Engineering*, 2021, 208 (2): 287-299.

[14] ZHAO G, QUAN L, LI H, et al. Real-time recognition system of soybean seed full-surface defects based on deep learning ScienceDirect [J]. *Computers and Electronics in Agriculture*, 2021, 187: 106-230.

[15] 邢金昊, 饶颖露, 张恒, 等. 基于改进 YOLO 的建筑预埋件检测算法 [J]. *计算机应用与软件*, 2021, 38 (11): 179

- 184.

- [16] 许志勇, 马小林, 陈 壮, 等. 基于深度学习的普通金属矿石快速分拣系统的研究 [J]. 计算机应用与软件, 2022, 39 (4): 32-38.
- [17] 张 达, 熊 凌. 基于改进 PSPNet 的氩花图像分割算法 [J]. 计算机工程与设计, 2022, 43 (10): 2843-2849.
- [18] WANG Q, WU B, ZHU P, et al. ECA-Net: efficient channel attention for deep convolutional neural networks [C] // Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Salt Lake City, UT, USA, 2020: 11531-11539.
- [19] MEHTA S. ESPNet: efficient spatial pyramid of dilated convolutions for semantic segmentation [C] // Proceedings of the 2018 European Conference on Computer Vision Springer, Cham, 2018: 552-568.
- [20] YUF V KOLTUN. Multi-Scale context aggregation by dilated convolutions [EB/OL]. arXiv preprint arXiv, 2016: 1-13. <https://arxiv.org/abs/1511.07122>.
- [21] WU Y H. P2T: pyramid pooling transformer for scene understanding [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022: 1-12.
- [22] CUI C, GAO T, WEI S, et al. PP-LCNet: a lightweight CPU convolutional neural network [J]. Computer Science-Computer Vision and Pattern Recognition, CoRR, abs/2109.15099, 2021: 1-8.
- [23] TAN, M, Q. V. Le, et al. MixConv: mixed depthwise convolutional kernels [EB/OL]. arXiv preprint arXiv, 2019: 1-13. <https://arxiv.org/abs/1907.09595v1>.
- [24] RAMACHANDRAN P, ZOPH B, LE Q V, et al. Searching for activation functions [J]. CoRR, abs/1710.05941 2017: 1-13.
- [11] 荆学东, 杜黎童, 王旭飞. 多旋翼无人机航迹规划算法 [J]. 船舶工程, 2023, 45 (2): 140-144.
- [12] 唐嘉宁, 杨 昕, 周思达, 等. 未知环境下改进 DDQN 的无人机探索航迹规划研究 [J]. 电光与控制, 2023, 30 (4): 23-27.
- [13] 陈 丽, 陈 洋, 杨艳华. 面向三维结构视觉检测的无人机覆盖路径规划 [J]. 电子测量与仪器学报, 2023, 37 (2): 1-10.
- [14] 苗 苗, 牛樱清, 李晓辉, 等. 带有禁飞区约束的物流无人机群路径规划 [J]. 兰州大学学报 (自然科学版), 2023, 59 (1): 98-105.
- [15] 刘 艳, 李文波, 刘新彪, 等. 复杂环境下无人机三维航迹规划及避障算法 [J]. 电光与控制, 2023, 30 (5): 93-98.
- [16] 范力元, 张浩哲, 徐 钊, 等. 基于安全飞行走廊的无人机密集障碍规避算法 [J]. 西北工业大学学报, 2022, 40 (6): 1288-1296.
- [17] 吕石磊, 范仁杰, 李 震, 等. 基于改进蝙蝠算法和圆柱坐标系的农业无人机航迹规划 [J]. 农业机械学报, 2023, 54 (1): 20-29.
- [25] SJ A, SHMA B, FJV A, et al. Computer-vision classification of corn seed varieties using deep convolutional neural network [J]. Journal of Stored Products Research, 2021, 92: 101800.
- [26] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C] // Proceedings of the 2016 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Las Vegas, NV, USA, 2016: 770-778.
- [27] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions [C]. Proceedings of the 2015 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Boston, MA, USA, 2015: 1-9.
- [28] IANDOLA F, MOSKEWICZ M, KARAYEVS, et al. Densenet: implementing efficient convnet descriptor pyramids [EB/OL]. arXiv preprint arXiv, 2014: 1-14. <https://arxiv.org/abs/1404.1869v1>.
- [29] HU J, SHEN L, SUN G, et al. Squeeze-and-excitation networks [C] // Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, UT, USA, 2018: 7132-7141.
- [30] HAN K, WANG Y, TIAN Q, et al. GhostNet: more features from cheap operations [C] // Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Seattle, WA, USA, 2020: 1580-1589.
- [31] SELVARAJU R, COGSWELL M, DAS A, et al. Grad-cam: visual explanations from deep networks via gradient-based localization [J]. Proceedings of the IEEE International Conference on Computer Vision. 2017: 618-626.
- [32] 马 利, 刘新宇, 李皓宇, 等. 应用空洞卷积的神经网络轻量化方法 [J]. 计算机工程与应用, 2022, 58 (5): 85-93.
- [33] 马金林, 张 裕, 马自萍, 等. 轻量化神经网络卷积设计研究进展 [J]. 计算机科学与探索, 2022, 16 (3): 512-528.
- [18] 蒯文轩, 谢文俊, 张 鹏, 等. 基于分组优化改进粒子群算法的无人机三维路径规划 [J]. 火力与指挥控制, 2023, 48 (1): 20-25.
- [19] 王晓东, 杨 昆. 基于近邻算法的无人机采集森林数据航迹路线的规划 [J]. 森林工程, 2023, 39 (1): 123-128.
- [20] 张瑞鑫, 王 伟, 田 泽, 等. 基于模型约束 A~* 算法的无人机三维航迹规划 [J]. 国外电子测量技术, 2022, 41 (9): 163-169.
- [21] 冒 燕, 杨家鼎, 徐小强. 基于改进速度障碍算法的无人机反侦察路径规划研究 [J]. 弹箭与制导学报, 2022, 42 (6): 13-19.
- [22] 许文瑶, 贺继林. 基于改进速度障碍法的水下机器人动态避障 [J]. 电光与控制, 2021, 28 (12): 86-90.
- [23] 毕可心, 吴明功, 张文斌, 等. 基于速度障碍法的飞行冲突网络建模与分析 [J]. 系统工程与电子技术, 2021, 43 (8): 2163-2173.
- [24] 洪晓斌, 徐郑攀, 魏新勇, 等. 基于改进速度障碍法的水面无人艇动态避障 [J]. 光学精密工程, 2021, 29 (9): 2126-2139.