

基于改进 Xception 的槟榔分类算法

Betel nut classification algorithm based on improved Xception

刘昌俊¹ 焦建格^{1,2} 邹国平¹

LIU Chang-jun¹ JIAO Jian-ge^{1,2} ZOU Guo-ping¹

(1. 中国计量大学机电工程学院, 浙江 杭州 310018;

2. 浙江省智能制造质量大数据溯源与应用重点实验室, 浙江 杭州 310018)

(1. College of Mechanical and Electrical Engineering, China Jiliang University, Hangzhou, Zhejiang 310018, China; 2. Key Laboratory of Intelligent Manufacturing Quality Big Data Tracing and Analysis of Zhejiang Province, Hangzhou, Zhejiang 310018, China)

摘要:目的:降低槟榔分类对人工的需求,同时提升槟榔分类的准确度和缩小分类模型。方法:以扩充 Xception 的输入层作为特征提取骨干网络;在特征提取网络后加入双路压缩激励模块;使用 ELU 激活函数代替 ReLU;使用数据增强扩充槟榔的数量,将数据集以 9:3:1 划分为训练集、验证集和测试集,用于训练改进 Xception 模型。结果:使用改进的 Xception 对测试集 1 100 张槟榔图像分类时达到了 99.182% 的分类准确度,同时模型大小仅有 15.7 MB。结论:改进后的模型能够满足对槟榔分类的准确度和模型大小的要求。

关键词: Xception; 双路注意力; ELU; 准确度; 轻量

Abstract: Objective: In order to reduce the manual demand of betel nut classification improve the accuracy of betel nut classification and reduce the size of classification model. **Methods:** Expanded the input layer of Xception as the feature extraction backbone network. Added a dual-channel squeeze and excitation module after the feature extraction network. Used the ELU activation function instead of ReLU. Used the data enhancement to expand the dataset of betel nuts, divided the dataset into training sets, validation sets and test sets in 9:3:1, and trained the improved Xception models. **Results:** When the improved Xception was used to classify 1 100 betel nut images in the test set, the classification accuracy reached 99.182%, and the model size was 15.7 MB. **Conclusion:** The improved model can meet the accuracy requirements and model size requirements for betel nut classification.

Keywords: Xception; dual channel attention; ELU; accuracy;

基金项目: 浙江自然科学基金(编号: LQ20E090006)

作者简介: 刘昌俊,男,中国计量大学在读硕士研究生。

通信作者: 焦建格(1988—),女,中国计量大学讲师,博士。

E-mail: careerjiao@cjl.u.edu.cn

收稿日期: 2022-08-30 **改回日期:** 2022-10-23

light weight

目前基于机器视觉进行图像分类主要有深度学习和传统的机器学习,传统机器学习的方法通过计算样本特征并结合样本特征进行图像分类;深度学习主要使用卷积神经网络自动学习有助于图像分类的特征。在图像分类领域以卷积神经网络作为图像特征提取器,诸如 VGG^[1]、Resnet^[2]、DenseNet^[3]、Inception^[4-5] 等系列的网络已经在 ImageNet 图像分类数据集中取得很好的效果。在槟榔分类领域, Mallaiah 等^[6] 将原始槟榔图像分成 8 个区域,对每个区域提取全局纹理特征,对提取到的槟榔图像特征使用 SVM 分类器进行分级,达到 92.5% 的分类精确度。Bharadwaj 等^[7] 同样使用局部图像进行特征提取,先获取图像 HSI 和 YCbCr 颜色模型,对两种模型分别提取 GLCM、Garbor 等纹理特征进行患病槟榔和未患病槟榔分类器,在 KNN 分类器上验证集达到 100% 的分类精度。许月明等^[8] 通过获取槟榔的纹理、颜色、形状特征,然后对 27 组参数使用主成分分析,选择主成分数为 12,最后使用支持向量机分类,达到 96.14% 的平均识别准确度。但是以上使用机器学习方法需要先人工设计特征,对于专家经验的依赖性大,对于流水线槟榔分类的鲁棒性差;同时槟榔分类精度仍有提升空间。舒军等^[9] 使用高分辨率网络增强槟榔片表面信息,在 Mask R-CNN 的结构上进行改进设计特征提取骨干网络,并且在网络中添加改进后的结合空间、通道信息的注意力模块,实现最终槟榔分类准确度 95.63%,但是使用高分辨率网络设计模型,同时添加组合空间和通道信息的注意力模块不利于模型轻量化设计。

针对机器学习算法需要人工选择特征用于分类,选择特征时对专家经验具有较大的依赖,另一方面目前槟

榔分类领域中使用深度学习进行特征提取和分类选择的模型过于庞大,不利于部署。研究拟采用卷积神经网络模型,基于改进已有的卷积神经网络搭建特征提取网络,并加入注意力机制搭建槟榔图像分类模型,以期实现槟榔端到端分类模型的轻量化、准确度、高效率的要求。

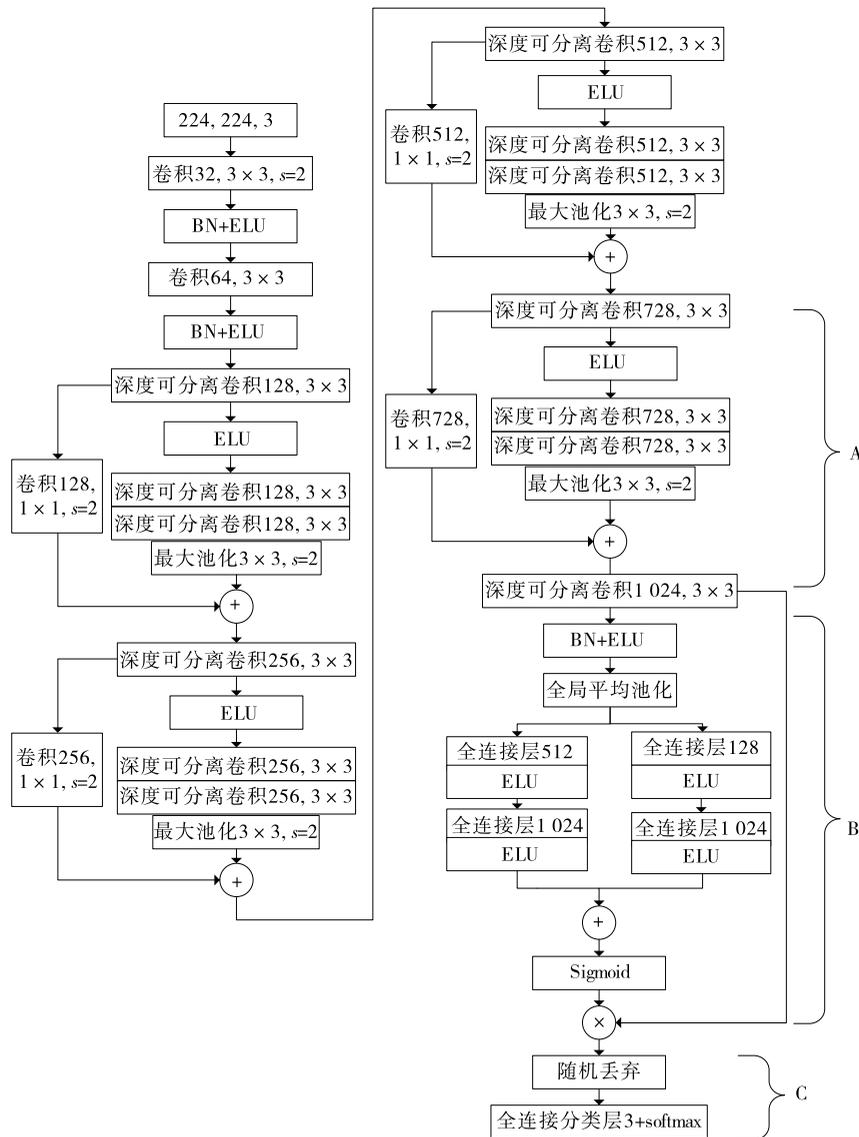
1 算法设计

在保证满足槟榔加工企业分类要求准确度 95% 以上的同时,以更小的模型和更高的分类准确度为目标。选取 Xception 的输入流作为网络骨干部分,通过对 Xception 模型结构、压缩激励模块和激活函数进行改进,设计改进后的 Xception 如图 1 所示,输入数据的尺寸由

Xception 要求的 (229, 229, 3) 调整为 (224, 224, 3)。

1.1 Xception

Xception 是将卷积神经网络中的 Inception 模块做到极致,每个通道都进行一次卷积,是由谷歌团队提出的基于深度可分离卷积的神经网络,相比于在其之前的 InceptionV3 网络,分类准确度和速度都有所提升,且模型的参数量大幅度下降,提升了模型的部署性能^[10-11]。Xception 的主要提升是使用深度可分离卷积代替 Inception 模块,在降低模型参数量的同时提升了模型参数的使用效率;在 Xception 中大量使用残差结构,加速网络收敛。



A 区为仿照 Xception 的输入流扩展的结构;B 区为骨干网络后连接的双路压缩激励模块;C 区为随即丢弃和分类层;其他为原始 Xception 结构

图 1 改进 Xception 的结构
Figure 1 The structure of the improved Xception

深度可分离卷积由深度卷积和点卷积组成,深度卷积使用卷积核个数与输入特征通道数相同的分组卷积,实现输入特征间空间相关性的映射;点卷积和普通的卷积类似,只是卷积核的大小设置为 1×1 ,可以获取输入特征通道相关性的映射,深度可分离卷积先进行深度卷积提取每个输入通道的空间特征,再使用点卷积获取特征间的通道相关性。深度可分离卷积各个步骤的表达式如下:

$$V_{DW}(m, i, j) = \sum_{\omega, h}^{W_k, H_k} V_F(m, i + \omega, j + k) \cdot V_{KDW}(m, \omega, h), \quad (1)$$

$$V_{PW}(n, i, j) = \sum_{m=0}^M V_{DW}(m, i, j) \cdot V_{KPW}(m, 1, 1), \quad (2)$$

式中:

$V_F(m, i, j)$ ——输入特征图 F 第 m 个通道上第 $(i + \omega, j + k)$ 个像素的值;

M ——输入特征图的通道数;

$V_{DW}(m, i, j)$ ——深度卷积第 m 个输出通道上第 (i, j) 个像素的输出值;

$V_{KDW}(m, \omega, h)$ ——深度卷积第 m 个输入通道上大小为 (W_k, H_k) 的卷积核在 (ω, h) 处的值;

$V_{PW}(n, i, j)$ ——点卷积第 n 个输出通道上第 (i, j) 个像素的输出值;

$V_{KPW}(m, 1, 1)$ ——点卷积第 n 个输出通道上对应第 m 个输入通道大小为 $(1, 1)$ 的卷积核的值。

深度可分离卷积在参数量上有些明显的优势,是实现轻量化模型的首选。深度可分离卷积和传统卷积的参数量对比如式(3)所示。

$$\frac{P}{P_{conv}} = \frac{\omega \cdot h \cdot m + m \cdot n \cdot 1 \cdot 1}{\omega \cdot h \cdot m \cdot n} = \frac{1}{n} + \frac{1}{\omega \cdot h}, \quad (3)$$

式中:

P ——深度可分离卷积的参数量;

P_{conv} ——传统卷积的参数量;

ω, h ——卷积核的宽和高,像素;

n ——点卷积输出的特征图个数。

由于输出特征图的个数 n 和深度卷积部分卷积核的宽高都是大于 1 的值,所以 P/P_{conv} 始终小于 1,以三通道、卷积核大小 $(3, 3)$ 为例,代入计算式(3)得到深度可分离卷积参数量为普通卷积的 44.44%。

1.2 改进的压缩激励模块

压缩激励模块是在模型训练时通过调节特征通道的权重提高准确度的一种方法,在特征提取的骨干网络之后加入压缩激励模块,目的是对骨干网络学习到的特征图引入竞争机制,通过特征图对于分类结果的重要性调整不同特征图的权重,从而提升模型的分类准确

度^[12-13]。压缩激励模块通过全局平均池化、压缩层和激励层学习权重,然后将权重与输入的特征图相乘,压缩激励模块原理如图 2(a)所示^[14]。

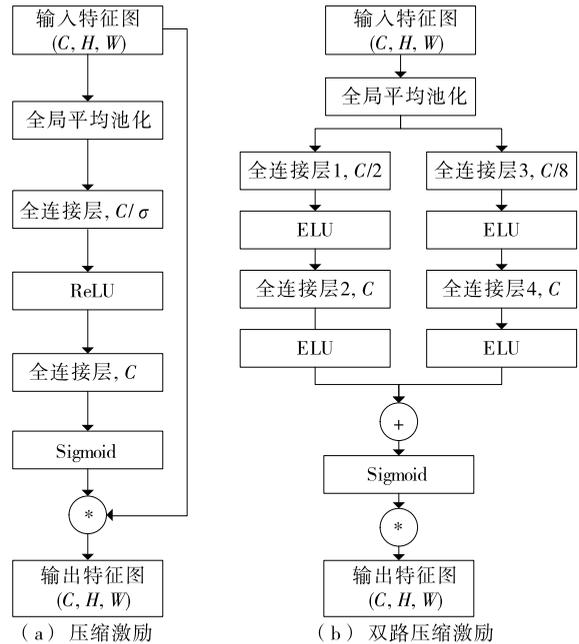


图 2 压缩激励及双路压缩激励
C. 特征图通道数 H. 特征图高 W. 特征图宽

Figure 2 Squeeze-and-excitation and dual squeeze-and-excitation

为了提升模型的表达能力,借鉴 Inception 结构改进压缩激励模块,采取双路处理骨干网络的特征图的方法,一方面先全局平均池化,然后使用全连接层分别做压缩层和激励层,缩放因子 $\sigma=2$,压缩层和激励层的激活函数设置为 ELU;另一方面使用缩放因子 $\sigma=8$ 的压缩层和激励层;最后将双路学到的权重值求和,并使用 Sigmoid 的激活函数激活,避免特征值溢出,再与输入的特征图相乘,双路压缩激励模块原理如图 2(b)所示。

对于图 2(b)双路压缩激励模块由左侧和右侧两个并行的子模块组成,生成最终映射的表达式:

$$M_{out} = F \cdot \sigma_2[\sigma_1 \cdot \omega_2(\sigma_1 \cdot \omega_1(f_g(F))) + \sigma_1 \cdot \omega_4(\sigma_1 \cdot \omega_3(f_g(F)))] \quad (4)$$

式中:

M_{out} ——输出特征图;

F ——输入特征图;

f_g ——全局平均池化函数;

$\omega_1, \omega_2, \omega_3, \omega_4$ ——图 2(b)中全连接层 1、全连接层 2、全连接层 3、全连接层 4;

σ_1, σ_2 ——ELU 激活函数和 Sigmoid 激活函数。

1.3 激活函数

为了提升特征提取模块在浅层到深层学习到非线性

映射的特征,在每个卷积层之后使用激活函数来增加模型的非线性。在深度学习做图像分类中,最常用的激活函数是 ReLU 激活函数,Xception 中使用 ReLU 激活函数增加模型的学习能力,ReLU 激活函数公式:

$$f(x)_{\text{relu}} = \begin{cases} x, & x > 0 \\ 0, & x < 0 \end{cases} \quad (5)$$

由式(5)可以看出,当提取的特征值为非负值时,ReLU 激活函数才会激活神经元;当提取的特征值为负值时,神经元的响应值在 ReLU 激活函数的作用下置为 0。可见 ReLU 在负值时抑制神经元的激活,导致神经元失活,从而降低特征值的利用率。

为了避免出现神经元失活现象,使用 ELU 代替 ReLU 激活函数,式(6)为 ELU 激活函数的计算公式。

$$f(x)_{\text{elu}} = \begin{cases} \alpha(e^x - 1), & x \leq 0 \\ x, & x > 0 \end{cases} \quad (6)$$

其中 α 设置为文献[15]中推荐的 1.0,使用 ELU 激活函数不仅能够避免神经元失活,使激活的平均值更接近零,接近零的平均激活使梯度更接近自然梯度,可以加快学习速度;而且激活值在输入特征值为负值时趋于饱和,在反向传播时能够减小下一层的变化和信息,提升模型的抗噪能力。

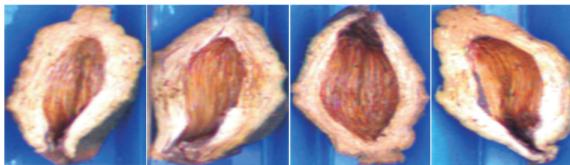
2 试验与结果

2.1 槟榔数据集

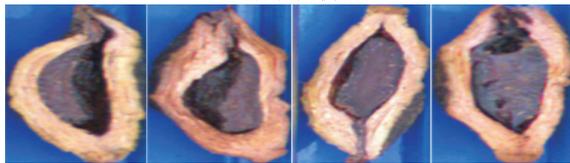
在训练模型时使用的数据集来自于杭州三也科技有限公司,在槟榔数据集中槟榔图像主要分为全翻、无核、有核 3 种类别,高速有效地对槟榔图像进行分级,对于槟榔加工企业来说至关重要。全翻即图 3(a),在图片中只能看到槟榔外壳,无法观察内部情况的槟榔,这种形态的



(a) 全翻



(b) 无核



(c) 有核

图 3 槟榔图

Figure 3 Image of betel nut

槟榔特征容易提取,且全翻槟榔无法判断其内属于有核还是无核需要进行二次分级判断;无核是图 3(b),槟榔内部图像清晰可见,且内部无核,部分存在点卤后的卤渍;有核的图 3(c),图像在槟榔内部有清晰完整的核存在。

在最初获取的槟榔数据集中包括全翻槟榔 544 张,无核槟榔 9 898 张,有核槟榔 7 664 张,其中全翻槟榔的数量较小,基于全翻槟榔的特征较为明显,通过图像增强技术将全翻槟榔扩充到 1 300 张,其余两种类型的槟榔选取 6 500 张。为了方便训练和模型评估,将槟榔图像按照 9 : 3 : 1 划分为训练集、验证集和测试集。训练集用于特征提取器的参数训练及更新,验证集主要作为损失函数中选择最优权重系数时的参照,测试集用来评估最终模型性能,统计各类别槟榔图片数量见表 1。

表 1 数据集

Table 1 Datasets

数据集	全翻	有核	无核	合计
训练	900	4 500	4 500	9 900
验证	300	1 500	1 500	3 300
测试	100	500	500	1 100

2.2 试验设置

在 Tensorflow2.6.0 框架下基于 Python3.8 编程,将槟榔数据集及所有代码上传到 Kaggle 平台,使用 Kaggle 提供的 NVIDIA TESLA P100 GPU 加速训练。

在使用训练数据训练模型时,损失函数使用交叉熵损失函数;参数优化算法设置为随机梯度下降,学习率设置为 0.01,每经过 5 个 Epoch 学习率降低 0.05 倍;训练的批量大小设置为 32,即一次输入 32 张槟榔图像训练;每个模型训练 50 个 Epoch,每经过一个 Epoch,都将验证集输入此刻的模型记录在验证集上的准确度和损失值,并保存损失值最小的模型用于测试集上的性能测试。

2.3 算法对比测试

为了验证基于改进 Xception 的槟榔分级算法的性能,使用改进 Xception 模型与 DenseNet201、Inception_ResNet、ResNet152V2、VGG19、Xception 进行对比试验,各个模型训练过程中都使用 ELU 作为增强模型非线性的激活函数,其余的参数设置与 2.2 中试验设置一致。将测试集输入到训练好的模型中,记录整体分类准确度、各类别分类准确度、模型大小见表 2。

从表 2 可以看出,使用改进 Xception 模型在测试集中各个指标都达到了最优,在所有模型测试集结果中都达到了 95% 以上的分类准确度,能够满足企业在筛选全翻、有核、无核槟榔的精度要求。相比于在所有模型中分类准确度排名第二的 Xception 模型,改进的 Xception 模型在槟榔图像分类准确度上提升了 0.546% (Xception 模

表 2 模型的性能对比

Table 2 Performance comparison of models

模型	整体准确度/%	全翻/%	无核/%	有核/%	模型大小/MB
VGG19	97.818	100	97.4	97.8	532.0
DenseNet201	98.182	100	97.6	98.4	71.7
Xception	98.636	100	98.4	98.6	79.9
Inception_resNet	97.727	100	98.2	96.8	209.0
Resnet152V2	98.273	100	98.6	97.6	224.0
改进 Xception	99.182	100	99.4	98.8	15.7

型 98.636%；改进 Xception 模型 99.182%），模型的大小缩小了 80%（Xception 模型 79.9 MB；改进 Xception 模型 15.7 MB），同时在测试集分类中达到了每秒分类 249 张槟榔图像的速度，证明改进 Xception 模型在保证分类精度的同时具备轻量化和高效的优势。

2.4 激活函数对比试验

为了进一步分析改进 Xception 模型的有效性，在改进 Xception 模型的架构下激活函数分别使用 ELU 和 Xception 使用的 ReLU 训练，记录模型在训练过程中的验证集损失如图 4 所示。

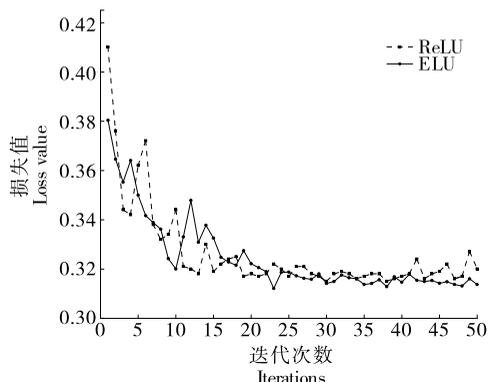


图 4 不同激活函数的损失曲线

Figure 4 Loss curves for different activations

通过图 4 可以发现，使用 ELU 激活函数比 ReLU 能更快地学习到特征，ELU 在迭代 48 次时达到最小损失 0.313 1，在后续的训练中损失在小范围内上下浮动；而 ReLU 在迭代 30 次时达到最小损失，在后续的训练中出现较大浮动，且损失值都高于 ELU 损失。

将训练保存的损失值最小的模型用于测试集测试，得到两个激活函数保存的模型在测试集上的准确度如表 3 所示。

综合图 4 和表 3 可以发现，使用改进的 ELU 激活函数相比于 ReLU 激活函数更适用于改进 Xception 模型，在槟榔分类任务中的准确度提升 0.182%，在测试集上的损失为 0.319。

表 3 不同激活函数的精度

Table 3 Accuracy for different activation

激活函数	测试准确度/%
ReLU	99.000
ELU	99.182

2.5 双路压缩激励模块试验

在验证双路压缩激励模块对于模型性能的影响时，分别训练将训练数据和验证数据输入基于拓展 Xception 输入层、拓展 Xception 输入层连接压缩激励模块和拓展 Xception 输入层连接双路压缩激励模块的 3 个模型，记录每个 Epoch 结束后模型在验证集上的损失，结果见图 5。

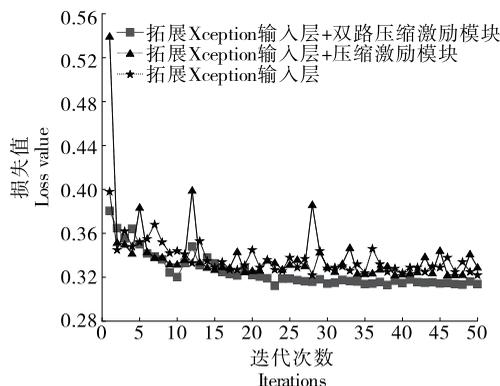


图 5 压缩激励和双路压缩激励的损失曲线

Figure 5 Loss curves for squeeze-and-excitation and dual squeeze-and-excitation

通过图 5 可以看出，仅使用压缩激励在模型训练后期的损失值甚至高于不使用压缩激励模块的模型；使用双路压缩激励模块时，模型的损失值在模型训练后期时 3 个模型中始终是最小的，并且通过观察损失随迭代次数变化的曲线发现使用双路压缩激励模块模型的收敛更加稳定。

为进一步验证改进后双路压缩激励模块的性能，将测试集输入 3 个模型在训练保存的验证集损失值最小的模型，记录测试集的准确度见表 4。

梯度类激活图可以体现模型对于输入图像哪些区域有着更高的关注度^[16-18]，在验证双路压缩激励模块的工作原理时，从测试集中任取一张槟榔图像，然后绘制 3 个模型在最后一个特征提取层的梯度类激活图，结果见图 6。

表 4 不同注意力模块的精度

Table 4 Accuracy of different attention modules

模型	测试准确度/%
拓展 Xception 输入层	98.364
拓展 Xception 输入层+压缩激励	98.545
拓展 Xception 输入层+双路压缩激励	99.182

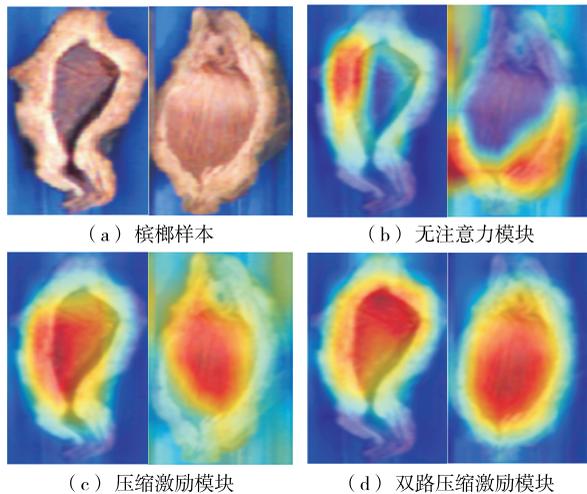


图 6 梯度类激活图

Figure 6 Gradient class activation map

从图 6 可以看出,使用压缩激励模块相比于不使用注意力模块会提升模型对槟榔分割面的关注度,而使用双路压缩激励模块时模型对于槟榔内部特征的关注更加准确,能降低槟榔分割面对分类时的影响,可以证明双路压缩激励模块对于槟榔特征定位更为准确,模型有更好的抗干扰能力。

2.6 改进 Xception 模型性能

利用训练好的基于 Xception 融合双路压缩激励模块的模型对测试集中的图像进行测试,试验结果如表 5 所示。

表 5 改进 Xception 模型的性能

Table 5 The performance of the model in this article

图像类型	测试准确度/%
全翻	100.000
无核	99.400
有核	98.800
整体准确度	99.182

从表 5 可以看出,在槟榔测试集分类中,三类槟榔图像都达到了 98% 以上的分类准确度,其中全翻槟榔分类正确率为 100.000%,无核槟榔分类准确度为 99.400%,有核槟榔分类准确度为 98.800%,整体分类准确度达到 99.182%。

为了进一步分析模型对槟榔分类的效果,绘制模型分类测试集图片的混淆矩阵,通过图 7 混淆矩阵可以发现,模型将无核槟榔误分为有核槟榔的数量为 2 张,而分类为全翻的数量为 1 张,结合槟榔图片发现,部分无核槟榔中存在卤渍,模型会将卤渍误判为槟榔核从而造成误分类;同时也导致模型在分类有核槟榔对于较小的槟榔核,误分为无核槟榔。

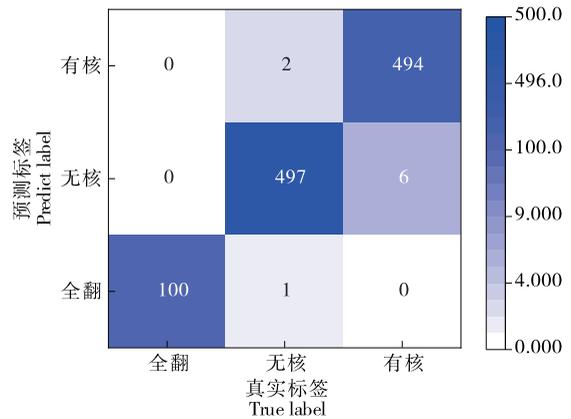


图 7 混淆矩阵

Figure 7 Confusion matrix

3 结论

利用卷积神经网络自动学习槟榔图像特征,减少通过机器学习选择特征进行分类时人工干扰,在保证分类准确度的同时,通过使用拓展 Xception 输入层作为特征提取的骨干网络;在骨干网络之后连接双路压缩激励模块给骨干网络输出的特征图赋予权重;使用 ELU 替代 ReLU 激活函数构建槟榔分类算法,避免出现神经元失活,实现了模型轻量化和分类速度的提升。

将改进 Xception 模型用于测试集预测时,整体分类准确度比 Xception 提升了 0.546% (改进 Xception 模型 99.182%; Xception 模型 98.636%),模型大小减少了 80% (改进 Xception 模型 15.7 MB; Xception 模型 79.9 MB),每秒能够分类的槟榔图像数量为 249 张,实现了槟榔分类的高准确度、部署性能和实时性要求。

参考文献

- [1] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6): 84-90.
- [2] E K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]// Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: Institute of Electrical and Electronics Engineering, 2016: 770-778.
- [3] LI S, DENG M, LEE J, et al. Imaging through glass diffusers using densely connected convolutional networks[J]. Optica, 2018, 5(7): 803-813.
- [4] CHRISTIAN S, PIERRE S, SCOTT E, et al. Going deeper with convolutions[C]// Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition, Boston, 2015. Washington: IEEE Computer Society, 2015: 1-9.
- [5] SZEGEDY C, VANHOUCHE V, LOFTE S, et al. Rethinking the inception architecture for computer vision[C]// Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2015: 2 818-2 826.

- [6] MALLAIAH S, DANTI A, NARASIMHAMURTHY S K. Classification of diseased arecanut based on texture features[J]. International Journal of Computer Applications, 2014, 1(1): 1-6.
- [7] BHARADWAJ N K, DINESH R. Classification and grading of areca nut using texture based block-wise local binary patterns[J]. Turkish Journal of Computer and Mathematics Education, 2021, 12(11): 575-586.
- [8] 许月明, 蔡健荣, 龚莹辉. 基于计算机视觉的槟榔分级研究[J]. 食品与机械, 2016, 32(8): 91-94, 102.
XU Y M, CAI J R, GONG Y H. Betel nut grading study based on computer vision[J]. Food & Machinery, 2016, 32(8): 91-94, 102.
- [9] 舒军, 何俊成, 李振亚. 基于 Mask R-CNN 的槟榔片分割算法研究[J]. 湖北工业大学学报, 2022, 37(1): 46-53.
SHU J, HE J C, LI Z Y. Research on grading algorithm of betel nut slices based on Mask R-CNN[J]. Hubei University of Technology, 2022, 37(1): 46-53.
- [10] CHRISTIAN S, SERGEY I, VINCENT V. Inception-v4, inception-ResNet and the impact of residual connections on learning [C]// Proceedings of the 31st AAAI Conference on Artificial Intelligence. San Francisco: AAAI, 2017: 4 278-4 284.
- [11] CHOLLET F. Xception: Deep learning with depthwise separable convolutions[C]// Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017: 1 800-1 807.
- [12] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-excitation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(8): 2 011-2 023.
- [13] 陈朝一, 许波, 吴英, 等. 医学图像处理中的注意力机制研究综述[J]. 计算机工程与应用, 2022, 58(5): 23-33.
CHEN C Y, XU B, WU Y, et al. Overview of research on attention mechanism in medical image processing[J]. Computer Engineering and Applications, 2022, 58(5): 23-33.
- [14] 宋建锋, 韦玥, 苗启广, 等. 压缩激励机制驱动的尿液细胞图像分类算法[J]. 西安电子科技大学学报, 2020, 47(2): 39-45.
SONG J F, WEI Y, MIAO Q G, et al. Urine cell image classification algorithm based on the squeeze and excitation mechanism[J]. Journal of Xidian University, 2020, 47(2): 39-45.
- [15] CLEVERT D A, UNTERTHINER T, HOCHREITER S. Fast and accurate deep network learning by exponential linear units (ELUs) [J]. Computer Science, 2015, 5(6): 43-51.
- [16] 王宪保, 肖本督, 姚明海. 一种结合类激活映射的半监督图像分类方法[J]. 小型微型计算机系统, 2022, 43(6): 1 204-1 209.
WANG X H, XIAO B D, YAO M H. Semi-supervised image classification method combined with class activation mapping[J]. Journal of Chinese Computer Systems, 2022, 43(6): 1 204-1 209.
- [17] 司念文, 张文林, 屈丹, 等. 卷积神经网络表征可视化研究综述[J]. 自动化学报, 2022, 48(8): 1 890-1 920.
SI N W, ZHANG W L, QU D, et al. Representation visualization of convolutional neural networks: A survey [J]. Acta Automatica Sinica, 2022, 48(8): 1 890-1 920.
- [18] RAMPRASAATH R, MICHAEL C, ABHISHEK D, et al. Grad-CAM: Visual explanations from deep networks via gradient-based localization[J]. International Journal of Computer Vision, 2020, 128(2): 336-359.
-
- (上接第 37 页)
- [10] JIA J M, ZHOU X F, LI Y, et al. Establishment of a rapid detection model for the sensory quality and components of Yuezhou Longjing tea using near-infrared spectroscopy [J]. LWT-Food Science and Technology, 2022, 164: 113625.
- [11] LIU Y, PENG Q W, YU J C, et al. Identification of tea based on CARS-SWR variable optimization of visible/near-infrared spectrum[J]. Journal of the Science of Food and Agriculture, 2020, 100(1): 371-375.
- [12] SOYEURT H, GRELET C, MCPARLAND S, et al. A comparison of 4 different machine learning algorithms to predict lactoferrin content in bovine milk from mid-infrared spectra[J]. Journal of Dairy Science, 2020, 103(12): 11 585-11 596.
- [13] WU X, LI G L, HE F Y. Nondestructive analysis of internal quality in pears with a self-made near-infrared spectrum detector combined with multivariate data processing[J]. Foods, 2021, 10(6): 1 315.
- [14] WANG S J, GUAN R F, HUANG H Z, et al. Effects of different smoking materials and methods on the quality of Chinese traditional bacon (larou) [J]. Journal of Food Protection, 2021, 84(3): 359-367.
- [15] MORAIS C L M, SHORE R F, PEREIRA M G, et al. Assessing binary mixture effects from genotoxic and endocrine disrupting environmental contaminants using infrared spectroscopy[J]. ACS Omega, 2018, 3(10): 13 399-13 412.
- [16] 韩佳柳, 林华, 刘玉柱, 等. 苯并[a]芘分子构型和特征光谱的研究[J]. 科技创新与应用, 2016(17): 72.
HAN J L, LIN H, LIU Y Z, et al. Study on molecular configuration and characteristic spectra of benzo[a]pyrene [J]. Technology Innovation and Application, 2016, 17: 72.
- [17] 韩颖, 郭明, 魏艳玲, 等. 苯并[a]芘的拉曼光谱计算及分析[J]. 吉林化工学院学报, 2012, 29(7): 9-12.
HAN Y, GUO M, WEI Y L, et al. Calculation and analysis for raman spectroscopy of benzo[a]pyrene[J]. Journal of Jilin Institute of Chemical Technology, 2012, 29(7): 9-12.
- [18] FU X S, HONG X Z, LIAO J Y, et al. Fingerprint approaches coupled with chemometrics to discriminate geographic origin of imported salmon in China's consumer market[J]. Foods, 2021, 10(12): 2 986.
- [19] SIVAKUMAR C, CHAUDHRY M M A, PALIWAL J. Classification of pulse flours using near-infrared hyperspectral imaging[J]. LWT-Food Science and Technology, 2022, 154: 112799.
- [20] ZHAO M, PENG Y K, LI L. A robot system for the auto detection and classification of apple internal quality attributes[J]. Postharvest Biology and Technology, 2021, 180: 111615.