

doi:10.6041/j.issn.1000-1298.2021.07.040

# 基于数据平衡和深度学习的开心果品质视觉检测方法

高霁月 倪建功 杨昊岩 韩仲志

(青岛农业大学理学与信息科学学院, 青岛 266109)

**摘要:** 为探究数据集中分类数量的平衡性对开心果品质检测的影响,将开心果图像与深度学习网络相结合,提出一种数据自动平衡的检测方法。根据行业标准将开心果数据集分为开口、闭口和缺陷3类,在此基础上再分为未经数据平衡和经过数据平衡2个数据集,分别使用 AlexNet、GoogLeNet、ResNet50、SqueezeNet、ShuffleNet 和 Xception 6种网络对2类数据集进行分类测试。结果表明,经过数据平衡的数据集网络准确率均得到了提高,6种网络平均测试准确率由96.75%提高到99.26%,SqueezeNet网络的测试集准确率提升最明显,由93.76%提高到99.02%,ResNet50网络的测试准确率最高,为99.96%。本文方法可用于开心果品质视觉检测。

**关键词:** 开心果; 深度学习; 数据平衡; 视觉检测

中图分类号: TP391.4 文献标识码: A 文章编号: 1000-1298(2021)07-0367-06

OSID:



## Pistachio Visual Detection Based on Data Balance and Deep Learning

GAO Jiyue NI Jianguo YANG Haoyan HAN Zhongzhi

(School of Science and Information Science, Qingdao Agricultural University, Qingdao 266109, China)

**Abstract:** “Happy or not” is an important content of pistachio quality detection. Combined with computer vision and deep learning network, a detection method of automatic data balance was proposed to explore the influence of data balance on pistachio quality detection. Firstly, a detection method of automatic data balance was proposed to explore the influence of data balance on pistachio quality detection. According to the industry standard, pistachio data sets were divided into three categories: open, closed and quality defect. Secondly, the data was formed into two data sets, one was the data set without data balance, the other was the data set after data balance. AlexNet, GoogLeNet, ResNet50, SqueezeNet, ShuffleNet and Xception were used to classify two kinds of datasets. The results showed that the accuracy of the network was improved after data balance, the average testing accuracy rate of six networks was increased from 96.75% to 99.26%. The accuracy rate of test set of SqueezeNet was improved the most obviously, which was from 93.76% to 99.02%, ResNet50 prediction accuracy rate was the highest, reached 99.96%. The rationality of network was verified by visualizing the location of high weight regions. The data balance method constructed had the same promotion value for other agricultural products quality detection, and also had a certain reference for other image classification projects.

**Key words:** pistachio; deep learning; data balance; vision detection

## 0 引言

开心果味香、营养丰富,具有很高的经济价值,但其果壳坚硬,人工难以将开口过小或者不开口的开心果剥开,开口与否直接关系到开心果的品质、经

济价值和消费者对品牌的评价。开心果果壳的开口率低、表面褐斑、果壳畸形和混入杂物(如石子、树枝)等现象会大大降低开心果产品的品质,所以在产品上架前对开心果进行开口检测非常必要。理想的果壳开口程度是消费者能用手指轻易取出核仁,

收稿日期: 2020-09-13 修回日期: 2020-11-24

**基金项目:** 国家自然科学基金项目(31872849)、山东省重点研发计划项目(2019GNC106037)、山东省高等学校青创计划团队项目(2020KJF004)和青岛市科技发展计划项目(19-6-1-66-nsh、19-6-1-72-nsh)

**作者简介:** 高霁月(1994—),女,博士生,主要从事图像处理与人工智能研究,E-mail: 761639015@qq.com

**通信作者:** 韩仲志(1981—),男,教授,博士,主要从事农业机器人与人工智能研究,E-mail: hanzhongzhi@qau.edu.cn

因此未开裂的开心果需要在产品上架前分拣出来,加工出理想的开口<sup>[1]</sup>。

目前,对开心果开口品质的检测绝大多数是通过声音判断<sup>[2-5]</sup>。钟晨玉等<sup>[4]</sup>设计了开心果碰撞声分拣试验装置,分析传声器位置、开心果下落高度及碰撞块倾斜角对碰撞声特征的影响;臧富瑶等<sup>[5]</sup>根据开心果撞击大理石的声音信息,测得开心果闭口、半开口、开口3种声音状态,获得80个不同样本开心果的碰撞声信号,经处理得到信号的时域和频域图形,从中提取分拣特征。郭晓伟<sup>[6]</sup>通过开心果的质心位置以及两条辅助线,开壳果正确分类率为93%,但此研究只检测了开口和闭口,并未提及褐斑、杂质、畸形等其他缺陷。

为验证图像检测农产品品质的可行性,韩仲志等<sup>[7]</sup>测量每个花生籽粒外观图像的形态、纹理、颜色共3大类54个特征,采用主分量分析(PCA)进行特征优化,然后导入神经网络(ANN)和支持向量机(SVM)模型进行比较,最终能够鉴别95%以上的不完善粒、霉变、杂质、异品种等不同品质的籽粒。近年来,图像处理技术已广泛应用于农产品品质检测中,特别是深度学习算法出现后,品质识别不需要人为定义特征,深度学习的简便性和准确性使其在图像检测领域得以快速发展。卷积神经网络(Convolutional neural network, CNN)是一类包含卷积计算且具有深度结构的前馈神经网络,是深度学习的代表算法之一,其设计灵感来自生物体的自然视觉感知机制,可以自动提取最具有代表性的图像特征<sup>[8-9]</sup>。图像分类是计算机视觉领域中的基本任务,通常指将图像分类到几个预定义的类中,构成其他计算机视觉任务的基础<sup>[10]</sup>。卷积神经网络在图像分类和目标检测领域应用广泛<sup>[11-12]</sup>,农业图像检测也越来越多运用了卷积神经网络的方法<sup>[13-17]</sup>。

基于深度学习的图像识别技术在理论上能更精确地识别开口程度和杂物,并进一步定位到开心果的位置,配合喷气装置可以精准挑拣出开口不合格和外观缺陷的开心果。然而,网络模型训练时数据量的平衡性会影响训练模型的性能,且数据不平衡现象经常发生<sup>[18-19]</sup>。传统分类方法通常假设数据类别分布均衡,但由于多数类和少数类在数量上的倾斜,以总体分类精度最大为目标,会使分类模型偏向于多数类而忽略少数类,从而造成少数类的分类精度较低<sup>[20]</sup>。同样在使用神经网络分类时,训练网络所用的数据集样本不均衡会影响神经网络的分类效率和准确率。针对上述问题,本文提出一种数据自动平衡检测方法,并采用6种不同的深度网络探究数据平衡算法对分类准确率的影响。

## 1 材料与方法

### 1.1 开心果图像数据库构建

按照中国食品工业协会坚果炒货专业委员会发布的《生干坚果质量等级要求》,将数据集分为3类:开口、闭口和外观缺陷及杂物(以下简称缺陷),其中开口标准为开口程度不小于 $2\text{ mm} \times 6\text{ mm}$ 的开心果,闭口的标准为开口小于 $2\text{ mm} \times 6\text{ mm}$ 的开心果,缺陷包括果壳表面褐斑以及混入杂物。

图1为开心果的图像采集环境,其中包括:摄像头及支架、光源、黑色背景板、开心果以及计算机。图像采集流程为:首先将市场上购买的未漂白开心果平铺于黑色背景板之上,固定摄像头位置和光源;然后通过摄像头拍摄开心果图像;最后导入计算机进行分类训练。图2是开心果感兴趣区域提取流程,图2a为原始图像,通过二值处理、膨胀、阈值分割得到图2b,然后设定连通区域面积,框选开心果轮廓得到图2c,再将红框坐标对应到原始图像对单个籽粒进行裁剪,最终得到单粒开心果的数据集。





图1 开心果拍摄环境

Fig. 1 Pistachio shooting environment

1. 计算机 2. 摄像头 3. 支架 4. 光源 5. 开心果 6. 黑色背景板



(a) 原始图像 (b) 二值化图像 (c) 轮廓选择

图2 开心果感兴趣区域提取流程

Fig. 2 Region of interest extraction of pistachio

图3为不同类型开心果示例图,经过数据预处理后,获得单粒开心果图像,包含开口图像1331幅,闭口图像415幅,缺陷图像92幅,共1838幅图像,各类数据数量相差很大,各个分类之间的数据量极不平衡,需要设计数据集平衡方法。

### 1.2 数据自动平衡算法

针对上述数据不平衡的问题,本文提出一种数据自动平衡的算法,目的是在数据导入网络分类模型之前将训练集数据集类别数量进行平衡,提高网络的准确率。基本流程为先获得每个分类的原始数量,再依次将所有数值小的分类集向数值最大的分




图 3 3 类品质开心果图像

Fig. 3 Data example of normal, closed and defective pistachios

类集数量扩增,具体方法为:

(1) 输入: 数据集  $S = [M_1, M_2, \dots, M_i] [N_1, N_2, \dots, N_j]^T$ , 输入中的  $M_i$  为数据集中样本种类,  $N_j$  为每一类样本的数量。

(2) 比较数据集中每一类的最大值  $M_i N_j$ , 找到所有类中最大值  $M_i N_{j_{\max}}$ 。

(3) 用所得最大值  $M_i N_{j_{\max}}$  依次除以剩余类的最大值  $M_i N_j$ , 得到除数  $C = [\{c_1, c_2, \dots, c_{i-1}\}]$ 。

(4) 按照除数  $C$  对剩余类进行扩增, 得  $M_i N'_j = M_i N_j C$ , 使所有类数量向  $M_i N_{j_{\max}}$  靠拢。

(5) 输出: 得到扩增后的数据集  $T = [M_1, M_2, \dots, M_i] [N'_1, N'_2, \dots, N'_{j_{\max}}]^T$ 。

以此开心果数据集为例, 原始数据中开口图像

1 331 幅, 闭口图像 415 幅, 缺陷图像 92 幅, 共 1 838 幅图像, 取出最大值 1 331, 将闭口组的数量与最大值 1 331 相除, 除数向下取整, 最大值为 12 (超过 12 的值按照 12 运算)。将闭口的 415 幅图像旋转 3 次得到 1 245 幅图像, 缺陷组也与最大值 1 331 相除得到数值 14, 但是为了方便旋转, 最大扩增值只能为 12, 通过 12 次旋转将缺陷扩增为 1 104 幅图像, 合格的开口开心果原始图像保持 1 331 幅不变, 至此, 平衡后的图像共 3 680 幅。

所用的 2 组数据集的来源为: 将 1.1 节中获得的未经过数据平衡的 1 838 幅图像通过保留原图、7 次旋转、水平镜像和垂直镜像, 扩充为原先的 10 倍, 得到 18 380 幅图像, 形成未平衡数据集  $A$ 。平衡数据集  $B$  的构成是将以上所述的 3 680 幅图像扩增至原来的 5 倍, 扩增方法包括原图、水平镜像、垂直镜像、尺寸缩小至原图 3/5 以及尺寸扩张为原图的 1.4 倍, 数据集  $B$  共包含 18 400 幅开心果图像,  $A$ 、 $B$  2 个数据集之间只相差 20 幅图像, 但在各组分类数量的比例上差别很大,  $A$  组开口、闭口和缺陷的图像数比例约为 100:30:7, 而数据平衡后的  $B$  组接近于 1:1:1。

### 1.3 分类模型

表 1 为实验所用 6 种网络, 其中 SqueezeNet 和 ShuffleNet 为轻量型网络, 各个网络之间存在一定的差异性, 使用数据平衡算法对不同神经网络的稳定性进行了验证。

表 1 实验所用 6 种网络

Tab.1 Six networks used in experiment

网络	特点	文献序号
AlexNet	AlexNet 首次在 CNN 中成功应用了 ReLU 为卷积神经网络的激活函数, 提出了数据增强和加入 dropout 层来防止训练过拟合	[21]
GoogLeNet	GoogLeNet 中 Inception 结构的主要贡献有: 使用 $1 \times 1$ 的卷积来进行升降维; 在多个尺寸上同时进行卷积再聚合	[22]
ResNet50	残差网络 ResNet 的特点是容易优化, 并且能够通过增加相当的深度来提高准确率。其内部的残差块使用了跳跃连接, 缓解了深度神经网络中增加深度带来的梯度消失问题	[23]
SqueezeNet	SqueezeNet 是一种轻量且高效的 CNN 模型, 参数量是 AlexNet 的 1/50, 但模型性能 (accuracy) 与 AlexNet 接近	[24]
ShuffleNet	ShuffleNet 网络提出了逐点群卷积帮助降低计算复杂度; 但是使用逐点群卷积会有副作用, 故在此基础上提出通道混洗帮助信息流通, 允许使用更多的特征映射通道, 在小型网络上有助于编码更多信息	[25]
Xception	Xception 是在 Inception 的基础上提出来的一种新网络, 其对 Inception 中的 Inception 模块进行了改进, 使用了深度可分离卷积来替换原来的 Inception 模块	[26]

## 2 实验与结果分析

### 2.1 数据平衡对模型准确率的影响

神经网络选取 AlexNet、GoogLeNet、ResNet50、SqueezeNet、ShuffleNet 和 Xception 训练网络进行迁移学习。将数据集按照 70:15:15 的比例随机划分为训练集、验证集和测试集。其中, 训练集和验证集

用于网络模型的训练, 测试集数据未用于网络模型训练, 而是用来测试网络的准确率。

表 2 是未平衡数据集  $A$  和平衡数据集  $B$  的分类准确率, 分别记录了 AlexNet、GoogLeNet、ResNet50、SqueezeNet、ShuffleNet 和 Xception 这 6 种网络在验证集、测试集的准确率以及网络训练时间。

表2 未平衡数据集A和平衡数据集B的分类准确率

Tab.2 Classification accuracy of unbalanced data set A and balanced data set B

网络模型	未平衡数据集A			平衡数据集B		
	验证集准确率/%	测试集准确率/%	时间/s	验证集准确率/%	测试集准确率/%	时间/s
AlexNet	98.59	97.79	818	99.89	99.89	826
GoogLeNet	98.22	97.86	1 791	99.75	99.49	1 951
ResNet50	99.13	98.77	3 089	99.78	99.96	3 065
SqueezeNet	93.69	93.76	950	99.17	99.02	903
ShuffleNet	97.06	96.52	1 861	98.77	98.88	1 875
Xception	96.37	95.79	9 065	97.50	98.33	8 885
均值	97.18	96.75	2 929	99.14	99.26	2 918

对于未平衡数据集A, ResNet50网络的分类效果最好,验证集准确率最高达到99.13%,在测试集上也达到98.77%;SqueezeNet在验证集的准确率为93.69%,测试集准确率为93.76%,在6种网络中准确率最低。除SqueezeNet之外,其他网络验证集的准确率均在96%之上,6种网络验证集平均准确率为97.18%,测试集平均准确率为96.75%。AlexNet在未平衡数据的验证集上,准确率高于SqueezeNet 4.9个百分点,在测试集上AlexNet准确率也比SqueezeNet高4.03个百分点。AlexNet、ResNet50和GoogLeNet在未平衡数据集A上性能优越,而SqueezeNet、ShuffleNet和Xception网络分类准确率可以接受但相对较差。从训练时间来看,AlexNet与SqueezeNet用时最短约15 min,Xception运行时间最长,为151 min,因此如果想用最少的训练时间得到一个性能高的网络,AlexNet最佳。

经过平衡的数据集B在每个网络上的验证集和测试集的准确率都有提升,而且对原先分类效果欠佳的网络准确率提升非常明显。平衡数据集B的验证集的平均准确率为99.14%,测试集的平均准确率为99.26%,验证和测试准确率均高于99%。在未平衡数据集中分类效果欠佳的SqueezeNet网络准确率提升最明显,其验证集准确率由93.69%提升到了99.17%,测试集的准确率从93.76%提升至99.02%。相对于数据集A,数据集B的测试集平均准确率提高了2.51个百分点,验证集平均准确率提

高了1.96个百分点,AlexNet、ResNet50和GoogLeNet这3种网络在验证集和测试集上的准确率接近1,SqueezeNet、ShuffleNet和Xception的验证集准确率都在98%以上,明显优于未平衡前的准确率。数据集A和B的训练时间在同一网络下无明显差异,训练时间与网络模型的结构、参数量以及训练数据量有关。

## 2.2 数据平衡前后的混淆矩阵

数据平衡前后测试集的混淆矩阵如表3和表4所示,表3展示了未平衡数据集A的开口、闭口以及缺陷图像在测试集的预测结果,数据集A的测试集共有2 756幅图像,其中标记为开口的图像1 996幅,闭口图像622幅、缺陷图像138幅。从表3中可以看出GoogLeNet和SqueezeNet网络的主要错误是将开口预测为缺陷,这是因为开口图像中有的果壳表面有面积较小的褐斑,神经网络会误将其归类为外表缺陷。和前者相反,AlexNet、ResNet50、ShuffleNet和Xception网络的主要错误之一是将缺陷预测为开口,说明ShuffleNet和Xception网络在分类时,对开口特征的权重大于缺陷特征的权重。在所有网络中将闭口预测为开口也是一种常见错误预测,这是因为有的闭口开心果开口接近开口标准2 mm×6 mm,而各组分类数据不平衡,网络无法学习足够多的闭口训练样本实现精确分类。

表4为平衡数据集B的开口、闭口以及缺陷图像在测试集上的预测结果,数据集B中共有2 760幅

表3 未平衡数据集A对于开口、闭口以及缺陷图像在测试集的预测结果

Tab.3 Detailed prediction results of open, closed and defect images in test set for unbalanced data set A

网络模型	开口预测为	开口预测为	开口预测为	闭口预测为	闭口预测为	闭口预测为	缺陷预测为	缺陷预测为	缺陷预测为
	开口	闭口	缺陷	开口	闭口	缺陷	开口	闭口	缺陷
AlexNet	1 987	4	5	27	593	2	22	2	115
GoogLeNet	1 965	3	28	20	600	2	4	2	132
ResNet50	1 989	4	3	14	606	2	10	1	127
SqueezeNet	1 850	16	130	18	599	5	2	1	135
ShuffleNet	1 983	7	6	48	574	0	33	2	103
Xception	1 983	6	7	58	559	5	36	4	98

测试图像,其中标记为开口的图像共 998 幅,闭口图像 934 幅,缺陷图像 828 幅。从表现结果来看,使用 ResNet50 分类后的开心果其网络准确率最高,达到了 99.9%, ResNet50 网络在这 2 760 幅图像中只将 1 个开口图像错误分类为闭口,这就最大程度保证

了开心果的品质,减少开心果分类时误判造成的浪费。SqueezeNet 与 GoogLeNet 相比,分类效果较差,分别有 12 个和 10 个缺陷开心果分类为开口开心果。ShuffleNet 和 Xception 是准确率最低的 2 种网络,与其他网络相比,分类错误的情况较为明显。

表 4 平衡数据集 B 对于开口、闭口以及缺陷图像在测试集的预测结果

Tab. 4 Detailed prediction results of open, closed and defect images in test set for balanced data set B

幅

网络模型	开口预测为	开口预测为	开口预测为	闭口预测为	闭口预测为	闭口预测为	缺陷预测为	缺陷预测为	缺陷预测为
	开口	闭口	缺陷	开口	闭口	缺陷	开口	闭口	缺陷
AlexNet	998	0	0	0	934	0	3	0	825
GoogLeNet	998	0	0	3	930	1	10	0	818
ResNet50	997	1	0	0	934	0	0	0	828
SqueezeNet	992	2	4	4	926	4	12	1	825
ShuffleNet	988	8	2	5	929	0	15	1	812
Xception	986	1	11	10	909	15	8	1	819

## 2.3 数据可视化

图 4 是利用 Grad-CAM 算法将网络判断模型可视化,Grad-CAM(类激活热力图)将最后一层特征图所有像素的权值计算,最后按照每个像素的权值可视化<sup>[27]</sup>,在本实验中,最后输出的特征图分辨率不一定与输入图像一致,无论输入图像的尺寸大小,所有经过 Grad-CAM 算法后的特征图都统一尺寸。特征图中红色表示神经网络判定开心果类别的高权重区域,蓝色表示网络分类低权

重的区域,色彩越红表示这块区域对分类结果的影响越大。可以看出,网络在分类为开口时的重要部位在开口处及周围,分类为闭口图像时会找到大面积的白色果壳区域,分类为缺陷和异物时网络的关注点在于检测目标物的形状、畸形区域或者是褐斑的位置。

## 3 结论

(1)数据平衡方法可以提高网络准确率,其平均测试准确率提高了 2.51 个百分点,平均验证准确率提高了 1.96 个百分点,其中 SqueezeNet 网络提高幅度最大,分别提高了 5.26 个百分点和 5.48 个百分点。

(2)神经网络可适用于开心果品质检测分类,本实验 6 种网络平均测试准确率为 99.26%,平均验证准确率为 99.14%,其中 ResNet50 的测试准确率达到 99.96%,可作为开心果检测分类的首选网络。

(3)可视化网络分类高权重的区域与人工判别开心果所关注的区域基本一致,从而验证了网络分类的合理性。

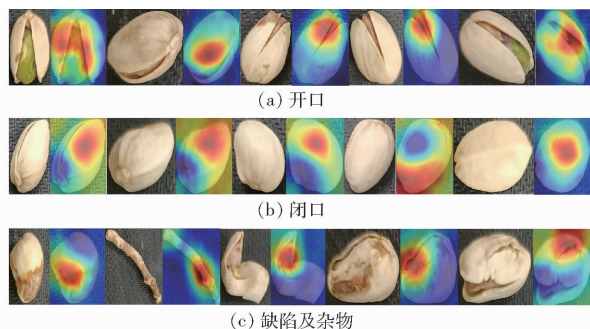


图 4 Grad-CAM 可视化平衡数据集 B 特征区域

Fig. 4 Visualization of balanced data set B's feature region using Grad-CAM

## 参 考 文 献

- [1] 梁理. 开心果生产工艺及安全卫生规范[J]. 农业与技术, 2006, 26(3): 167-168. LIANG Li. Pistachio production technology and safety and health standards[J]. Agriculture and Technology, 2006, 26(3): 167-168. (in Chinese)
- [2] 王涛, 冯涛, 钟晨玉. 碰撞位姿对开心果碰撞声离散性的影响[J]. 食品与机械, 2016, 32(8): 6-8, 16. WANG Tao, FENG Tao, ZHONG Chenyu. Research on the influence of impact pose on the discreteness of pistachio's impact sound[J]. Food and Machinery, 2016, 32(8): 6-8, 16. (in Chinese)
- [3] 梅亚敏, 郭敏. 基于碰撞声信号的农产品品质检测技术综述[J]. 西北农林科技大学学报(自然科学版), 2013, 41(4): 213-219. MEI Yamin, GUO Min. Review on impact acoustic signal based quality evaluation technologies for agricultural products[J]. Journal of Northwest A&F University (Natural Science Edition), 2013, 41(4): 213-219. (in Chinese)
- [4] 钟晨玉, 冯涛, 王涛, 等. 多因素对开心果碰撞声特征的影响[J]. 食品与机械, 2016, 32(7): 32-35. ZHONG Chenyu, FENG Tao, WANG Tao, et al. Effects on impact acoustics characteristics of pistachio by multiple factors[J]. Food and Machinery, 2016, 32(7): 32-35. (in Chinese)
- [5] 臧富瑶, 冯涛, 王晶, 等. 基于碰撞声的开心果分拣技术研究[J]. 农产品加工(学刊), 2014(21): 65-67. ZANG Fuyao, FENG Tao, WANG Jing, et al. Pistachio sorting technique research using impact acoustics[J]. Academic

- Periodical of Farm Products Processing, 2014(21):65-67. (in Chinese)
- [6] 郭晓伟. 基于机器视觉的开心果闭壳与开壳识别[J]. 计算机应用, 2011, 31(2):426-427,434.  
GUO Xiaowei. Discrimination between closed and open shell pistachio nuts using machine vision[J]. Journal of Computer Applications, 2011, 31(2):426-427,434. (in Chinese)
- [7] 韩仲志, 赵友刚. 基于计算机视觉的花生品质分级检测研究[J]. 中国农业科学, 2010, 43(18):3882-3891.  
HAN Zhongzhi, ZHAO Yougang. Quality grade detection in peanut using computer vision[J]. Scientia Agricultura Sinica, 2010, 43(18):3882-3891. (in Chinese)
- [8] 杨斌, 钟金英. 卷积神经网络的研究进展综述[J]. 南华大学学报(自然科学版), 2016, 30(3):66-72.  
YANG Bin, ZHONG Jinying. Review of convolution neural network[J]. Journal of University of South China (Science and Technology), 2016, 30(3):66-72. (in Chinese)
- [9] 卢宏涛, 张秦川. 深度卷积神经网络在计算机视觉中的应用研究综述[J]. 数据采集与处理, 2016, 31(1):1-17.  
LU Hongtao, ZHANG Qinchuan. Applications of deep convolutional neural network in computer vision [J]. Journal of Data Acquisition and Processing, 2016, 31(1):1-17. (in Chinese)
- [10] 陈超, 齐峰. 卷积神经网络的发展及其在计算机视觉领域中的应用综述[J]. 计算机科学, 2019, 46(3):63-73.  
CHEN Chao, QI Feng. Review on development of convolutional neural network and its application in computer vision[J]. Computer Science, 2019, 46(3):63-73. (in Chinese)
- [11] 宋超. 基于深度迁移学习的舌象特征分类方法研究[D]. 南京:南京财经大学, 2020.  
SONG Chao. Research on tongue feature classification methods based on deep transfer learning [D]. Nanjing: Nanjing University of Finance and Economics, 2020. (in Chinese)
- [12] 顾恭, 徐旭东. 改进YOLOv3的车辆实时检测与信息识别技术[J]. 计算机工程与应用, 2020, 56(22):173-184.  
GU Gong, XU Xudong. Real-time vehicle detection and information recognition technology based on YOLOv3 improved algorithm[J]. Computer Engineering and Applications, 2020, 56(22):173-184. (in Chinese)
- [13] 许景辉, 邵明焯, 王一琛, 等. 基于迁移学习的卷积神经网络玉米病害图像识别[J/OL]. 农业机械学报, 2020, 51(2):230-236,253.  
XU Jinghui, SHAO Mingye, WANG Yichen, et al. Recognition of corn leaf spot and rust based on transfer learning with convolutional neural network[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(2):230-236, 253. [http://www.j-csam.org/jcsam/ch/reader/view\\_abstract.aspx?flag=1&file\\_no=2002025](http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=2002025). DOI:10.6041/j.issn.1000-1298.2020.02.025. (in Chinese)
- [14] 倪建功, 李娟, 邓立苗, 等. 基于知识蒸馏的胡萝卜外观品质等级智能检测[J]. 农业工程学报, 2020, 36(18):181-187.  
NI Jianguo, LI Juan, DENG Limiao, et al. Intelligent detection of appearance quality of carrot grade using knowledge distillation[J]. Transactions of the CSAE, 2020, 36(18):181-187. (in Chinese)
- [15] 熊俊涛, 戴森鑫, 区炯洪, 等. 基于深度学习的大豆生长期叶片缺素症状检测方法[J/OL]. 农业机械学报, 2020, 51(1):195-202.  
XIONG Juntao, DAI Senxin, OU Jionghong, et al. Leaf deficiency symptoms detection method of soybean based on deep learning[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(1):195-202. [http://www.j-csam.org/jcsam/ch/reader/view\\_abstract.aspx?flag=1&file\\_no=20200121&journal\\_id=jcsam](http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20200121&journal_id=jcsam). DOI:10.6041/j.issn.1000-1298.2020.01.021. (in Chinese)
- [16] 陶震宇, 孙素芬, 罗长寿. 基于Faster-RCNN的花生害虫图像识别研究[J]. 江苏农业科学, 2019, 47(12):247-250.  
TAO Zhenyu, SUN Sufen, LUO Changshou. Study on peanut pest image recognition based on Faster-RCNN[J]. Jiangsu Agricultural Sciences, 2019, 47(12):247-250. (in Chinese)
- [17] 谢为俊, 丁冷春, 王凤贺, 等. 基于卷积神经网络的油茶籽完整性识别方法[J/OL]. 农业机械学报, 2020, 51(7):13-21.  
XIE Weijun, DING Yechun, WANG Fenghe, et al. Integrity recognition of *Camellia oleifera* seeds based on convolutional neural network[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(7):13-21. [http://www.j-csam.org/jcsam/ch/reader/view\\_abstract.aspx?flag=1&file\\_no=20200702&journal\\_id=jcsam](http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20200702&journal_id=jcsam). DOI:10.6041/j.issn.1000-1298.2020.07.002. (in Chinese)
- [18] 肖鹰, 吴哲夫, 张彤, 等. 一种基于特征选择的不平衡数据分类算法[J]. 集成技术, 2016, 5(1):68-74.  
XIAO Ying, WU Zhefu, ZHANG Tong, et al. Feature selection based classification algorithm with imbalanced data [J]. Journal of Integration Technology, 2016, 5(1):68-74. (in Chinese)
- [19] 陈圣灵, 沈思琪, 李东升. 基于样本权重更新的不平衡数据集学习方法[J]. 计算机科学, 2018, 45(7):31-37.  
CHEN Shengling, SHEN Siqi, LI Dongsheng. Ensemble learning method for imbalanced data based on sample weight updating [J]. Computer Science, 2018, 45(7):31-37. (in Chinese)
- [20] 李艳霞, 柴毅, 胡友强, 等. 不平衡数据分类方法综述[J]. 控制与决策, 2019, 34(4):673-688.  
LI Yanxia, CHAI Yi, HU Youqiang, et al. Review of imbalanced data classification methods[J]. Control and Decision, 2019, 34(4):673-688. (in Chinese)
- [21] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [C] // International Conference on Neural Information Processing Systems. Curran Associates Inc., 2012:1097-1105.
- [22] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions [C] // IEEE Computer Society, 2014:1-9.
- [23] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016:770-778.
- [24] IANDOLA F N, HAN S, MOSKEWICZ M W, et al. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size [J]. arXiv preprint arXiv:1602.07360, 2016.
- [25] MA N, ZHANG X, ZHENG H T, et al. Shufflenet v2: practical guidelines for efficient cnn architecture design [C] // Proceedings of the European Conference on Computer Vision, 2018:116-131.
- [26] CHOLLET F. Xception: deep learning with depthwise separable convolutions [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017:1251-1258.
- [27] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-CAM: visual explanations from deep networks via gradient-based localization [C] // IEEE International Conference on Computer Vision (ICCV), 2017:618-626.