

基于改进的 GoogLeNet 鸭蛋表面缺陷检测

Duck egg surface defect detection based on improved GoogLeNet

肖 旺 杨煜俊 申启访 单森森 黄 越

XIAO Wang YANG Yu-jun SHEN Qi-fang SHAN Sen-sen HUANG Yue

(广东工业大学机电工程学院, 广东 广州 510006)

(School of Electromechanical Engineering, Guangdong University of
Technology, Guangzhou, Guangdong 510006, China)

摘要: 文章提出了一种基于改进的 GoogLeNet (GoogLeNet-Mini) 的鸭蛋表面缺陷检测方法, 并对比其他 3 种神经网络 GoogLeNet、VGG16 和 AlexNet。结果表明, 4 种网络的测试集准确率分别为 95.88%, 94.16%, 92.75%, 85.43%。GoogLeNet-Mini 对测试集 3 类鸭蛋 (正常、脏污、破损) 的检测准确率分别为 98.43%, 97.45%, 95.88%。与 GoogLeNet、VGG16 和 AlexNet 相比, GoogLeNet-Mini 具有更高的准确率, 更好的泛化性与鲁棒性, 且对 3 类鸭蛋的检测准确度均能达到生产要求, 检测范围适用于脏污面积超过 5%, 破损面积超过 2% 的鸭蛋。

关键词: 鸭蛋; 表面缺陷; GoogLeNet-Mini; 神经网络

Abstract: A method of duck egg surface defect detection based on improved GoogLeNet (GoogLe Net-Mini) was proposed, and the other three neural networks include GoogLeNet, VGG16 and AlexNet were compared. The results showed that the accuracy of the four networks were 95.88%, 94.16%, 92.75% and 85.43% respectively. The detection accuracy of GoogLeNet-Mini for three kinds of duck eggs (normal, dirty and damaged) was 98.43%, 97.45% and 95.88% respectively. Compared with GoogLeNet, VGG16 and AlexNet, GoogLeNet-Mini had higher accuracy, better generalization and robustness, and the detection accuracy of three types of duck eggs can meet the production requirements. The detection range is applicable to duck eggs with more than 5% dirty area and more than 2% damaged area.

Keywords: duck eggs; surface defect; GoogLeNet-Mini; neural network

鸭蛋是日常生活中重要的食品之一, 味道鲜美, 价格便宜, 营养丰富, 一直备受消费者喜爱。其品质直接关乎鸭蛋的销量及其蛋制品 (如皮蛋、咸鸭蛋等) 品质。然而鸭蛋在出栏、运输、加工、储存等阶段容易造成外壳破损, 表面污染, 严重影响鸭蛋品质, 若加工和销售前不及时剔除, 会造成更大的污染和资源浪费, 甚至危及消费者的健康安全。目前, 鸭蛋的筛选可分为人工光检与声学检测。对于大多蛋品企业而言, 鸭蛋的挑选主要是依赖人工肉眼识别, 其成本高昂, 效率低下, 漏检率高, 且对眼损伤较大。此外, 近些年中国有部分厂家引进了日本声学裂痕检测模块, 通过小锤敲击蛋壳表面的几处关键点, 采集蛋壳表面的声纹振动反馈, 以此分析并判断鸭蛋表面是否完好。但此方法虽能检测出蛋壳破损的鸭蛋, 但易受蛋壳表面脏污影响出现误判, 需要人工二次检查。

当前, 制约中国蛋品行业发展的一个主要因素就是蛋品深加工机械设备不足, 无法实现集约化发展, 导致蛋品加工率过低, 蛋品品质良莠不齐。俞玥等^[1-2]在蛋品无损检测与品质分级方面进行了大量研究, 按检测方法不同主要可分为声学检测^[3]、机器视觉检测^[4-6]以及深度学习检测^[7-9]。在声学领域, 孙力等^[10]通过蛋壳表面声学特性设计了一套在线蛋壳裂痕检测系统, 检测率达 90%; 陈诚等^[11]采用敲击响应方法, 对鸡蛋进行多角度敲击, 并精准采集敲击音频响应信号, 设计了基于声学响应信号分析的一套禽蛋蛋壳在线检测系统, 该系统对正常禽蛋检测准确率达 92%。在机器视觉领域, 魏莹等^[12]通过采用图像纹理特征参数对土鸡蛋微裂纹进行无损检测, 使用 LDA 模型判别效果最佳, 准确率达 96%; 王巧华等^[13]利用机器视觉技术采集鸭蛋动态图像, 通过 LIBSVM 建立分级模型, 在鸭蛋产地进行尺寸与扁平度分级检测, 准确率分别为 91.67%, 95.00%。Amin 等^[14]使用 VGG 网络对未处理的鸡蛋进行检测, 成功筛选出破损与带血斑的鸡蛋, 准确率达 94.84%。

上述方法或是对检测环境依赖较大, 或是对被检测

基金项目: 广东省重点领域研发项目 (编号: 2019B090916002); 广州市科技计划项目 (编号: 201902010054)

作者简介: 肖旺, 男, 广东工业大学在读硕士研究生。

通信作者: 杨煜俊 (1980—), 男, 广东工业大学副教授, 博士。

E-mail: 15195797@qq.com

收稿日期: 2021-03-15

蛋品要求严格,在应付复杂多变的检测环境与各类缺陷不均匀蛋品时,难以达到高精度、智能化检测。文章拟提出一种基于神经网络的鸭蛋表面缺陷检测方法,并与 GoogLeNet、VGG16 和 AlexNet 3 种神经网络进行对比,分析其对裂纹、脏污等多种表面缺陷的检测分类情况,旨在为实现鸭蛋表面多缺陷,高精度检测提供依据。

1 试验材料与预处理

1.1 试验样本

从当地农贸市场与养殖场收集 300 枚鸭蛋,其中表面干净无损 86 枚,带有裂纹、孔洞等缺陷 102 枚,表面带有鸭粪、血污、泥沙等脏污 112 枚。通过 CCD 相机、LED 光源、旋转传送装置搭建图像采集平台,利用相机对鸭蛋两端与鸭蛋表面进行拍照取样,共采集 1 200 张。通过人为筛选出不合要求的图像,最终采集样本图片 1 062 张,按照实际检测要求以图 1 方式进行样本分类,其中正常样本 403 张,表面破损样本 314 张,表面脏污样本 345 张。




图 1 鸭蛋样本分类方式

Figure 1 Classification of duck eggs

1.2 试验环境

在软件环境为 Window 系统下进行,搭载 TensorFlow-GPU 2.0 深度学习框架,使用 CUDA 11.0 版本搭配 cudnn 7.65 版本实现 GPU 并行加速计算。文中所有神经网络模型都在 Python3.7 版本下编程实现。计算机硬件配置 CPU 为 Inter 酷睿 I7-10875H @2.3 GHz,内存 16 GB;GPU 为 NVIDIA GeForce RTX2060,6 GB 显存。

1.3 图像预处理

图像预处理包括图像标签、图像分割、尺寸重定义、图像增强以及数据扩充^[15-16]。图像预处理是将原始数据(图 2)整理成标准规范的训练数据,使之能顺利送入神经网络并高效计算。

图像标签是指将所有采集到的图像按图像内容打上标签,试验中可分为正常、破损和脏污 3 类标签,使用 Labelimg 工具对所采集的图像进行标注。图像分割是预处理中重要的一环,正确的分割能够有效地过滤背景噪音,凸显图像要素,提升后续检测的正确率。其主要分割方法有阈值分割、区域分割与边缘分割,考虑到鸭蛋表面颜色均匀,成像前景与背景差别较大,采用 Otsu 阈值分割^[17],通过计算方差来确定一个恰当的阈值,使分割图像前景与背景之间的灰度值差异最大,去除背景后,计算出每个图像最小边界矩形,最后使用 OpenCV 工具包将所

有图像尺寸重定义成 3 通道 224×224 像素大小,以方便神经网络计算,预处理后的图像如图 3 所示。

神经网络需要大量的数据用于训练才能提高其检测准确率,由于采集样本数量有限,可通过数据增强^[18]来获得大量相关数据。数据增强主要包括图像的平移、翻转、旋转、比例缩放、随机裁剪等。试验通过数据增强最终在原有样本基础上扩大 10 倍数据量,得到 10 620 张图像,其中正常样本 4 030 张,表面破损样本 3 140 张,表面脏污样本 3 450 张。

2 神经网络模型

2.1 GoogLeNet-Mini 网络

GoogLeNet 网络^[19-21]是当年 ImageNet 图像竞赛的冠军,其 top5 错误率只有 6.67。GoogLeNet 共有 22 层,包含 3 个卷积层和 9 个 inception 块。GoogLeNet(图 4)引入了 Inception 结构块,使 GoogLeNet 即使在深度上超过了 VGG 和 AlexNet,但网络模型参数相比却小得多,GoogLeNet 通过增加网络的深度与宽度获得更好的性能,却对内存与计算资源的要求更低。

GoogLeNet 虽然性能优秀,学习能力强,但网络结构复杂,参数相对于 VGG 和 AlexNet 更少,但也达到 2.4×10^7 个。针对试验图像的特点,对 GoogLeNet 网络进行



(a) 正常 (b) 脏污 (c) 破损

图 2 正常、脏污、破损鸭蛋原始图像

Figure 2 Original image of normal, dirty and damaged duck eggs



(a) 正常 (b) 脏污 (c) 破损

图 3 正常、脏污、破损鸭蛋预处理后图像

Figure 3 Image of normal, dirty and damaged duck eggs after pretreatment




图 4 GoogLeNet 网络结构

Figure 4 GoogLeNet network structure




图 5 GoogLeNet-Mini 网络结构

Figure 5 GoogLeNet-Mini network structure

相应的改进,改进后的网络被命名为 GoogLeNet-Mini (图 5),由于试验图像特征大小相近,将原有前 3 层不同尺寸的卷积层精简为一层 3×3 大小卷积层。GoogLeNet 引入 inception 模块化结构,包含 4 个分支(图 6),分别为 1×1 卷积层, 1×1 卷积层与 3×3 卷积层, 1×1 卷积层与 5×5 卷积层, 3×3 池化层与 1×1 卷积层。卷积层的作用是提取图像特征,池化层作用在卷积层之后,对卷积层提取到的图像特征进行降维,减少特征数据量。Inception 结构块在同层网络中使用多个不同尺寸的卷积核,用于提取图像中不同尺寸的特征,提升整个模型的感知力,由于试验图像特征明显,可以减小 inception 模块数量与 inception 卷积核个数,将原有的 9 个 inception 块精简到 6 个, inception 块中卷积核尺寸保持不变,其中 inception 卷积核个数由 64 个呈倍数增加到 512 个,使得 inception 结构更加规整,有利于硬件加速和程序的编写,减少代码冗余。改进后的 inception 结构对于图像的特征提取数量会相对减少,但大大减少了模型参数量,通过 1×1 卷积核,作用到输入特征图的每个像素点,通过设定少于输入特征图深度的 1×1 卷积核个数,减少了输出特征图深度,起到了降维作用,减少了参数量和计算量,加快模型的收敛,减少过拟合。

GoogLeNet 网络去掉最后全连接层,使用一个分类层替代,分类层中包含了 Dropout 层与全局平均池化, Dropout 层通过随机失活部分神经元,减少参数的数量来




图 6 Inception 结构块

Figure 6 Inception structure block

防止模型过拟合。全局平均池化是针对特征图取平均值,用数值来代表特征图,将数值输入到 softmax 层,得到对应的概率分布,以达到分类效果。相比于全连接层,全局平均池化的参数数量与计算量比较少。

2.2 VGG16 网络

VGG16 网络诞生于 2014 年,由 16 层网络组成,其中包含 13 个卷积层和 3 个全连接层^[22]。VGG16 卷积层均由 3×3 卷积核组成,因此 VGG16 网络结构非常规整,有利于硬件计算,其模型识别准确度有所提升,并且网络参数大大减小,每个卷积层均使用 relu 作为激活函数。VGG 网络随着学习深度的加深,卷积核个数从 64 增加到

512,避免了因特征图尺寸逐渐减小而出现网络信息能力承载不足的情况。

2.3 AlexNet 网络

AlexNet 网络由 5 个卷积层和 3 个全连接层组成,结构上与 LeNet5 网络有相似之处,但也存在许多改动,AlexNet 网络将激活函数由 Sigmoid 函数改为 Relu 函数,有效地解决了梯度弥散问题^[23]。AlexNet 网络训练时成功引入 Dropout,随机舍弃部分参数,有效避免模型过拟合,提升模型鲁棒性。同时引入局部相应归一化层(LRN),增强模型泛化能力。

3 模型训练与结果分析

3.1 模型训练

模型训练实际上就是一个不断修正误差的过程,一批图像数据被送入神经网络经前向传播计算出预测结果,并与实际标签进行比较得出损失值,再将该值通过反向传播不断迭代,修正权重偏置,使得损失函数不断减小,预测精度不断提高。损失函数代表网络预测值与实际标签值的差距,当损失函数输出最小时,模型权重与偏置达到最优值,文中采用交叉熵损失函数:

$$L = \frac{1}{N} \sum_i L_i = \frac{1}{N} \sum_i - \sum_{c=1}^M y_{ic} \log(p_{ic}), \quad (1)$$

式中:

M ——类别数量;

y_{ic} ——与样本 i 类别相同为 1,不同则为 0;

p_{ic} ——样本属于类别 c 的预测概率;

N ——样本总量。

优化器采用 RMSprop, RMSprop 算法采用加权平均,能自适应调节学习率,避免学习率过低的问题,其计算公式为:

$$m_t = g_t = \nabla f(W_t) = \frac{\partial f}{\partial W_t}, \quad (2)$$

$$V_t = \beta_2 \cdot V_{t-1} + (1 - \beta_2) \cdot g_t^2, \quad (3)$$

$$\eta_t = \frac{\alpha}{\sqrt{V_t}} \cdot m_t, \quad (4)$$

$$W_{t+1} = W_t - \eta_t, \quad (5)$$

式中:

W ——待优化参数;

g_t ——当前参数的梯度;

m_t/V_t ——一阶/二阶动量;

η_t ——当前时刻的下降梯度;

α ——学习率;

β_2 ——超参数,取 0.99。

网络模型建立完成后,将由图像增强后的图像按 4:

1 随机划分成训练集与验证集送入模型进行训练,其中训练集 8 496 张(正常、破损、脏污分别为 3 224,2 512,2 760 张),验证集 2 124 张(正常、破损、脏污分别为 806,628,690 张)。为进一步评估网络的鲁棒性,另外采集 510 张图像为测试集。初始学习率设置为 0.000 1,通过指数衰减法更新学习率,根据 GPU 硬件条件设置 BatchSize 为 16。为保证试验结果公平性,VGG16 和 AlexNet 网络使用相同的数据集进行训练、验证与测试。

3.2 结果分析

GoogLeNet-Mini 训练的准确率与损失值变化如图 7 所示。由图 7 可知,当 epoch 为 0~160 时,验证集数据结果反复振荡,说明此时得到的模型还不够稳定;当 epoch 为 160~260 时,验证集结果逐渐趋于稳定,此时模型的训练集准确率为 100.00%,验证集准确率为 97.83%,保存模型参数。

在使用相同的样本数据对 GoogLeNet、VGG16 与 AlexNet 进行试验后,其结果如表 1 所示,GoogLeNet-Mini 网络训练集、验证集、测试集的准确率分别为 100.00%,98.25%,96.88%。GoogLeNet 网络训练集、验证集、测试集的准确率分别为 100.00%,99.16%,94.46%。VGG16 网络训练集、验证集、测试集的准确率分别为 99.26%,94.78%,92.75%。AlexNet 网络表现稍差,训练集、验证集、测试集的准确率分别为 95.61%,89.72%,85.43%。综上,GoogLeNet-Mini 网络的检测效果优于其他 3 个网络,说明改进后的 GoogLeNet-Mini 相





图 7 准确率与损失值变化曲线

Figure 7 Curve of acc and loss

表 1 4 种网络试验结果

Table 1 Experimental results of four networks %

网络模型	训练准确率	验证准确率	测试准确率
GoogLeNet-Mini	100.00	97.83	95.88
GoogLeNet	100.00	99.16	94.16
VGG16	99.26	94.78	92.75
AlexNet	95.61	89.72	85.43

比于原网络,不仅参数量更少,而且减少了模型过拟合,提升了网络的泛化能力与准确度。

对于网络模型的评估分析,采用测试准确率(A_{cc})、精确度(P_{re})、召回率(R_{ec})、受试者工作特征曲线下面积(A_{UC})作为所选模型优劣的评定指标^[14]。选定指标计算公式为:

$$A_{cc} = \frac{n_{TP} + n_{TN}}{n_{TP} + n_{TN} + n_{FP} + n_{FN}}, \quad (6)$$

$$P_{re} = \frac{n_{TP}}{n_{TP} + n_{FP}}, \quad (7)$$

$$R_{ec} = \frac{n_{TP}}{n_{TP} + n_{FN}}, \quad (8)$$

$$A_{UC} = \frac{1}{2} \left[\frac{n_{TP}}{n_{TP} + n_{FN}} + \frac{n_{TN}}{n_{TN} + n_{FP}} \right], \quad (9)$$

式中:

- n_{TP} ——实际与预测都为正样本的数量;
- n_{TN} ——实际与预测都为负样本的数量;
- n_{FP} ——实际为负样本预测为正样本的数量;
- n_{FN} ——实际为正样本预测为负样本的数量。

使用 GoogLeNet-Mini 对测试集(正常 160 张,脏污 200 张,破损 150 张)进行检测,得到分类检测混淆矩阵如图 8 所示,其中正常与脏污图像各 7 张被误分为破损,破损图像中有 6 张被误认为脏污,1 张被误认为正常,按式(6)~式(9)分别计算正常、脏污、破损三分类的准确度、精确度、召回率及 AUC,结果见表 2。

由表 2 可知,GoogLeNet-Mini 网络对正常的鸭蛋检测效果最好,准确率达 98.43%,脏污鸭蛋检测准确率为 97.45%,破损鸭蛋检测准确率为 95.88%,3 种分类检测准确度均能达到生产企业要求。破损类准确度偏低可能




图 8 测试集混合矩阵图

Figure 8 The mixture matrix of test set

表 2 各类鸭蛋的检测结果

Table 2 Test results of various duck eggs

类别	$A_{cc}/\%$	$P_{re}/\%$	$R_{ec}/\%$	A_{UC}
正常	98.43	95.63	99.35	0.995
脏污	97.45	96.50	96.98	0.975
破损	95.88	95.33	91.08	0.936
平均	97.25	95.82	95.80	0.969

是由于拍摄角度与鸭蛋旋转导致部分破损类图像中破损信息被边缘化未占据图像信息主体,使得网络产生误判。后续可通过增加拍摄角度进一步提高破损检测准确率。

为了进一步评价 GoogLeNet-Mini 网络的缺陷检测有效范围,试验重新筛选一批脏污鸭蛋与破损鸭蛋数据,通过 opencv 的阈值分割和边缘检测算法分别对鸭蛋的脏污和破损部位进行特征提取,并计算面积(图 9),按缺陷面积所占整个鸭蛋面积的比重分为 4 种类别。使用 GoogLeNet-Mini 进行检测,得到脏污鸭蛋与破损鸭蛋的检测结果分别见表 3 与表 4。




图 9 鸭蛋脏污与破损特征的面积占比

Figure 9 Area ratio of dirty and damaged duck eggs

表 3 不同面积的脏污鸭蛋检测结果

Table 3 Detection results of dirty duck eggs in different areas

脏污面积/%	脏污样本数	检测结果	准确率/%
0~2	30	5	16.00
2~5	24	19	54.17
5~10	38	36	94.74
10~100	50	50	100.00

表 4 不同面积的破损鸭蛋检测结果

Table 4 Detection results of damaged duck eggs with different areas

破损面积/%	破损样本数	检测结果	准确率/%
0~2	25	17	68.00
2~5	32	30	93.38
5~10	40	38	95.00
10~100	35	34	97.14

由表 3 可知,当脏污面积 $>5\%$ 时,准确率超过 94.74%。由表 4 可知,当破损面积 $>2\%$ 时,准确率超过 93.38%。故文章提出的 GoogLeNet-Mini 网络较适用于检测脏污面积 $>5\%$,破损面积 $>2\%$ 的鸭蛋。

4 结论

运用改进后的卷积神经网络 GoogLeNet-Mini 对鸭蛋的表面缺陷进行了检测,相比于传统机器上视觉算法更加方便准确,不需要依赖人工提取图像特征。GoogLeNet-Mini、GoogLeNet、VGG16、AlexNet 4 种网络的测试准确率为别为 95.88%,94.16%,92.75%,85.43%,其中 GoogLeNet-Mini 网络效果最优,且网络模型参数更少,一定程度上减少了过拟合。GoogLeNet-Mini 对正常、脏污、破损的检测准确率分别为 98.43%,97.45%,95.88%,满足企业检测准确度要求。GoogLeNet-Mini 网络较适用于检测脏污面积 $>5\%$,破损面积 $>2\%$ 的鸭蛋。

参考文献

- [1] 俞玥,张守丽,李占明.禽蛋品质无损检测及分级技术研究进展[J].食品安全质量检测学报,2020,11(23): 8 740-8 745.
- [2] 王栓巧,郁志宏.基于有限元法的禽蛋检测机构蛋壳破损率研究[J].食品与机械,2017,33(8): 76-78, 84.
- [3] 张魁,彭佳伟,李帅.一种蛋品质无损检测分选装置及其蛋品质声学信号采集单元: CN111642420A[P]. 2020-09-11.
- [4] 吴林峰,余怀鑫,祝志慧.基于机器视觉的孵化早期群体受精蛋鉴别[J].食品与机械,2019,35(4): 152-156.
- [5] 裴悦琨,连明月,姜艳超.基于机器视觉的樱桃缺陷检测与识别[J].食品与机械,2019,35(12): 137-140, 226.
- [6] 高辉,马国峰,刘伟杰.基于机器视觉的苹果缺陷快速检测方法研究[J].食品与机械,2020,36(10): 125-129, 148.
- [7] 程鸿芳,张春友.自然场景下基于改进 LeNet 卷积神经网络的苹果图像识别技术[J].食品与机械,2019,35(3): 155-158.
- [8] 杨志锐,郑宏,郭中原,等.基于网中网卷积神经网络的红枣缺陷检测[J].食品与机械,2020,36(2): 140-145, 181.

(上接第 134 页)

参考文献

- [1] 余安琪.基于游戏化思维的儿童食品包装设计[J].湖南包装,2019,34(4): 109-112.
- [2] 马更.基于儿童心理及认知的食品包装设计[J].包装工程,2015,36(10): 93-96.
- [3] 张梓滢.基于认知心理学的儿童食品包装设计研究[D].济南:齐鲁工业大学,2020: 3-10.
- [4] 邱莉莉.多维趣味表达儿童休闲食品包装设计[J].食品与机械,2020,36(12): 119-122, 158.
- [5] 宣秀元.多感官设计在现代广告中的应用与研究[D].济南:齐鲁工业大学,2013: 1-3.
- [6] 张大鲁.多感官设计趋势下的食品包装设计创新[J].食品与机械,2020,36(7): 122-126.

- [9] 王淑青,黄剑锋,张鹏飞,等.基于 YOLOv4 神经网络的小龙虾质量检测方法[J].食品与机械,2021,37(3): 120-124, 194.
- [10] 孙力,蔡健荣,林颖,等.基于声学特性的禽蛋裂纹实时在线检测系统[J].农业机械学报,2011,42(5): 183-186.
- [11] 陈诚,强敏,蔡健荣,等.禽蛋蛋壳裂纹在线检测系统设计[J].农业工程,2020,10(6): 22-27.
- [12] 魏萱,何金成,郑书河,等.基于图像纹理特征的生鸡蛋微裂纹无损检测[J].福建农林大学学报(自然科学版),2017,46(6): 716-720.
- [13] 王巧华,芦茜,马美湖,等.基于机器视觉的产地脏污鸭蛋外形扁平度在线检测[J].中国食品学报,2017,17(5): 200-207.
- [14] NASIRI A, OMID M, TAHERI-GARAVAND A. An automatic sorting system for unwashed eggs using deep learning[J]. Journal of Food Engineering, 2020, 283(1): 110036.
- [15] 王伟男,杨朝红.基于图像处理技术的目标识别方法综述[J].电脑与信息技术,2019,27(6): 9-15.
- [16] 张继凯,赵君,张然,等.深度学习的图像实例分割方法综述[J].小型微型计算机系统,2021,42(1): 161-171.
- [17] 李德新.基于 Otsu 阈值的 MSI 不连续破损边缘提取[J].计算机仿真,2020,37(9): 358-362.
- [18] 林成创,单纯,赵淦森,等.机器视觉应用中的图像数据增强综述[J].计算机科学与探索,2021,15(4): 583-611.
- [19] SZEGEDY C, LIU W, JIA Y Q, et al. Going deeper with convolutions[C]// 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Boston: [s.n.], 2015: 1-9.
- [20] 薛勇,王立扬,张瑜,等.基于 GoogLeNet 深度迁移学习的苹果缺陷检测方法[J].农业机械学报,2020,51(7): 30-35.
- [21] 薛晨兴,张军,邢家源.基于 GoogLeNet Inception V3 的迁移学习研究[J].无线电工程,2020,50(2): 118-122.
- [22] 徐昭洪,刘宇,全吉成,等.基于 VGG16 预编码的遥感图像建筑物语义分割[J].科学技术与工程,2019,19(17): 250-255.
- [23] 陈立潮,闫耀东,张睿,等.融合迁移学习的 AlexNet 神经网络不锈钢焊缝缺陷分类[J/OL].智能系统学报. (2020-11-25) [2021-05-05]. <http://kns.cnki.net/kcms/detail/23.1538.TP.20201125.1015.002.html>.

- [7] KRISHNA A, CIAN L, NILÜFER Z. Sensory aspects of package design[J]. Journal of Retailing, 2017(1): 43-54.
- [8] 王嫵舒,周飞碟.多感官交互式包装设计形式研究[J].包装学报,2020,12(3): 88-92.
- [9] 宫甜甜.基于多感官理念对通用包装设计的应用研究[D].北京:北京印刷学院,2015: 1-20.
- [10] 陈莹燕,李蔓丽.现代包装设计中的多感官表达之探讨[J].装饰,2011(2): 96-97.
- [11] 李檬.“多感官”理念在包装设计中的运用研究[D].无锡:江南大学,2008: 5-12.
- [12] 周雨,张任远.多感官整合理念在食品包装设计中的应用[J].工业设计,2017(1): 117-120.
- [13] How food packaging color influences consumer behavior[EB/OL]. [2016-04-12] [2020-04-08]. <https://hartdesign.com/industry-news/food-packaging-color-influences-consumer-behavior/>.