

基于知识蒸馏的胡萝卜外观品质等级智能检测

倪建功, 李娟, 邓立苗, 韩仲志^{*}

(青岛农业大学理学与信息科学学院, 青岛 266109)

摘要: 胡萝卜等级分类是提高胡萝卜市场竞争力的关键环节。传统的胡萝卜外部缺陷检测采用特征提取+分类器模式, 需要手工定义特征, 客观性差。为了解决上述问题, 该研究提出一种基于知识蒸馏的网络模型, 通过引入教师模型来指导学生模型的训练, 在保证准确率的情况下减少网络模型的参数量和运行时间消耗。该试验采集了外观无缺陷以及黑斑、弯曲、带须根的四类胡萝卜样本图片, 将其导入网络模型中进行训练。通过使用 Resnet34、Resnet50、Resnet101 这 3 个不同教师模型来指导学生模型 Resnet18 的训练, 蒸馏模型平均准确率从 94.3% 分别提高到 94.8%、95.2%、95.8%, 其中 Resnet101 模型指导的 Resnet18 模型中正常胡萝卜识别率提高到 100%, 正常、黑斑、须根识别率提高约 2%, 模型训练时间为 11.3 h。此外, 传统 Resnet50 模型和 Resnet101 模型对数据集的识别准确率分别是 96.3% 和 96.9%, 模型训练时间分别是 19.3 和 31.3 h。试验发现: 蒸馏模型识别率大幅优于基于特征提取+分类器的传统模型, 且随着教师模型网络深度的增加, 模型识别率也进一步提高。从模型训练时间和模型部署上考虑, 知识蒸馏是很有必要的, 通过牺牲小部分准确率可以大大缩短模型训练时间和降低模型部署成本。该研究所提出的知识蒸馏模型作为一种轻量级前端部署方法, 对于改进胡萝卜外观品质自动检测装置的性能具有积极意义。

关键词: 深度学习; 模型; 品质控制; 胡萝卜; 等级分类; 知识蒸馏

doi: 10.11975/j.issn.1002-6819.2020.18.022

中图分类号: S126; TP391.4

文献标志码: A

文章编号: 1002-6819(2020)-18-0181-07

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.

doi: 10.11975/j.issn.1002-6819.2020.18.022 <http://www.tcsae.org>

Ni Jiangong, Li Juan, Deng Limiao, et al. Intelligent detection of appearance quality of carrot grade using knowledge distillation[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2020, 36(18): 181-187.
(in Chinese with English abstract) doi: 10.11975/j.issn.1002-6819.2020.18.022 <http://www.tcsae.org>

0 引言

胡萝卜是全球性十大蔬菜作物之一, 适应性强, 产量大, 种植十分普遍。在亚洲、欧洲和美洲分布最多, 其中中国是世界上第一大胡萝卜生产国^[1]。2017 年, 世界胡萝卜产量达到 4 283.19 万 t, 其中中国产量达到 2 027.43 万 t, 接近世界总产量的一半。胡萝卜营养丰富, 富含胡萝卜素和膳食纤维等多种营养物质, 具有提高机体免疫力、促进新陈代谢等功效^[2]。然而, 褐斑病、黑斑病等病害对胡萝卜的营养价值和外观品质影响较大^[3]。因此, 胡萝卜的外观品质检测是必不可少的。目前, 大多数胡萝卜生产加工企业主要采用手工分拣方式, 这种方式效率低、主观性强、标准宽松, 不适合大规模生产和推广。使用智能化的方法对胡萝卜进行等级分类可以大大提高胡萝卜的市场竞争力, 提高企业和种植户的效率^[4]。因此, 迫切需要一种智能化的技术解决胡萝卜外观

品质分类问题。

近年来, 国内外研究人员开始利用图像处理技术对果蔬品质进行自动检测和分级^[5]。但是这些研究主要集中于西红柿^[6]、苹果^[7]等相对容易处理的球形果蔬上, 对胡萝卜等非球形果蔬的研究还处于不成熟阶段。Xie 等^[8]使用手动提取胡萝卜的图像特征参数, 提出了一种基于机器视觉的胡萝卜表面缺陷关键参数提取算法将胡萝卜分为 4 个不同的等级, 准确率为 86.67%。韩仲志等^[9]使用计算机视觉技术来检测胡萝卜青头、须根与开裂情况。邓丽苗等^[10]使用图像处理技术, 通过构建影响胡萝卜分级的关键特征参数来实现胡萝卜须根、弯曲、开裂的检测, 并自主研发一条胡萝卜智能分选机生产线, 可以实现不同等级胡萝卜的在线分选。上述均为特征提取+分类器方法, 平均识别率在 85% 左右, 手工定义特征的非客观性限制了识别率的提高。这种方法需要对每一类胡萝卜构建大量特征标准, 工作量大且泛化能力不足。

深度学习是近年来一种热门的模式分析方法, 广泛应用于语音识别^[11-12]、人脸识别^[13]、图像分类^[14]、行为分析^[15-16]等工业领域中, 而且也开始应用于农业领域^[17-19]。已经有研究者将其应用于粮食^[20-21]、水果^[22-23]、蔬菜^[24-25]等农产品的目标检测和质量评价。杨彩霞等^[26]利用深度卷积网络对外观无缺陷以及存在开裂、分枝和高刺缺陷的胡萝卜进行检测, 准确率可以达到 91.6%。深度神经网络高准确率的实现主要是依赖对更深和更广的

收稿日期: 2020-05-22 修订日期: 2020-09-12

基金项目: 国家自然科学基金项目 (31872849); 山东省重点研发计划 (2019GNC1 06037); 山东省高等学校青创计划团队 (2020KJF004); 青岛市科技发展计划 (19-6-1-66-nsh, 19-6-1-72-nsh)

作者简介: 倪建功, 主要从事图像处理与人工智能研究。

Email: 1106668767@qq.com

通信作者: 韩仲志, 博士, 教授, 主要从事农业机器人与人工智能研究。

Email: hanzhongzhi@qau.edu.cn


网络结构的探索研究。尽管现代深度神经网络的性能有了显著的提高，但是在模型训练时，仍然需要从巨大且冗余的数据中提取特征结构。通常情况下不考虑实时性要求，最后训练得到的模型参数量较多。由于计算资源和延迟的限制，深度神经网络较难在实际中得到应用。

Hinton 等^[27]最早提出知识蒸馏的思想，核心思想是利用一个大而准确的教师模型来指导一个小而快速的学生模型。本研究基于这一思想，尝试使用 Resnet101^[28]等模型为教师模型来指导 Resnet18 模型的训练，并将其首次应用于胡萝卜智能分选机生产线。通过知识蒸馏，使得到的模型能够在保证准确率的情况下减小网络模型的参数量和模型运行时间消耗，在牺牲少许准确率的基础上，大幅降低部署模型的成本。作为一种轻量化前端部署模型，特别适合于实际生产线应用。

1 材料与方法

1.1 材料与设备

本研究所用胡萝卜来自山东省青岛市莱西市店埠镇。采用特征提取+分类器^[9]的胡萝卜智能分选机生产线^[10]进行试验（如图 1），所有图像均采集于该生产线，图像包括 4 类不同品质的胡萝卜，具体为正常、弯曲、黑斑和带须根胡萝卜，如图 2 所示。这 4 类不同品质的胡萝卜的分类参考中华人民共和国农业部 NY/T 1983—2011 胡萝卜等级规格标准^[29]划分。其中弯曲、黑斑、带须根的胡萝卜是次品样本，与正常胡萝卜相比，都存在一定的缺陷。该生产线追求正品样本识别率，混入次品可再次人工分拣。



1.上料机 2.图像处理系统 3.图像采集系统 4.传送系统 5.分级系统 6.相机 7.真实物料 8.镜子 9.虚像
1.Feeding machine 2.Image processing system 3.Image acquisition system 4.Conveyor system 5.Grading system 6.Camera 7.Real material 8.Mirror 9.Virtual image

图 1 胡萝卜分选机实物图

Fig.1 Physical picture of carrot separator

生产线实时采集图像，图像处理所用计算机主要性能指标为：联想 E580，配置为 Intel(R)Core(TM) i5-8250U CPU @ 1.60GHz-1.80GHz，16.0G RAM，Windows10 操作系统。采用 Python3.6 下 PyTorch1.1 框架实现相关模型。数据采集由图像采集系统获取，图像采集系统原理图如图 1 所示。图像采集系统由一个照明室、一个线阵相机、两个角度约为 135° 的镜子和圆形 LED 灯条组成。其中线阵相机位于照明室顶部，圆形 LED 灯条位于线阵相机下方环绕分布，镜子位于胡萝卜的下方呈对称分布，

这样相机就可以获得 3 幅图像（1 幅真实图像和 2 幅镜子图像），得到完整的胡萝卜信息。图像采集系统位于分选机中间部位，如图 1 中虚线框所示。试验采集的图像约 3 266 张，基本可以满足神经网络训练需要，所以没有对数据进行扩增处理。为了更好的反映各类不同胡萝卜的数据分布，对各类胡萝卜数据的数量进行了统计，如表 1 所示。




图 2 4 类胡萝卜的示意图

Fig.2 Schematic diagram of four carrots

表 1 4 类胡萝卜的数量分布

Table 1 Quantitative distribution of four kinds of carrots

类别 Classes	训练集 Training dataset/piece	测试集 Test dataset/piece	总计 Total/piece
正常 Normal	700	300	1 000
弯曲 Curved	969	415	1 384
黑斑 Black spot	411	176	587
须根 Fibrous root	206	89	295

1.2 方法

采用知识蒸馏的思想构建 3 个知识蒸馏模型。利用教师模型来指导学生模型的训练，其中教师模型是一种大规模，参数量大的复杂网络模型；学生模型是一种小规模，参数量小的精简网络模型。通过诱导训练，实现小模型得到高准确率的效果。训练方式如图 3 所示。

首先，训练教师模型，让其对目标数据集进行识别，并学习样本中的属性知识。然后，选择胡萝卜数据集，将教师模型中 logits 输出除以 T 参数之后做 Softmax 计算，得到 soft labels 值。之后，将数据集数输入到学生模型中，重复教师模型相同的操作并得到 logits 输出，而后分成两步计算：一是除以与教师模型相同的 T 参数之后做 Softmax 计算，得到 soft predictions，此输出与 soft labels 比较；二是做 Softmax 计算后，得出预测值，此预测值与 Ture labels 进行比较。两部分损失函数相加，得到总的损失函数 KD Loss。计算损失函数，梯度下降，更新参数。

1.2.1 知识蒸馏

神经网络的“softmax”输出层会将前面的卷积层得到的预测结果转化为概率值 p 。该层会对预测结果取自然对数得到某一类的 logit 值 Z_i ，通过与所有类的 logit 值 Z_j 进行比较，生成这个类的概率 p_i ；知识蒸馏通过对

进行修改, 增加一个系数 T , 使得输出层会产生一个“软化”后的概率向量 \mathbf{q}_i

$$\mathbf{q}_i = \frac{\exp(z_i/T)}{\sum_j \exp(z_j/T)} \quad (1)$$

其中 T 为温度系数。随着 T 参数的增大, 对应的分布概率越平缓。教师网络的预测输出结果除以温度参数 T 之后再做 softmax 变换, 可以获得软化后的概率分布 \mathbf{q}_i , 用于之后 KD Loss 的计算。

1.2.2 残差学习

通常在深度学习中, 深度卷积网络能够整合高中低不同层次的特征, 特征的层次通过加深网络的层次来丰富。所以现在的深度学习模型越来越倾向于使用更深层的网络结构, 以便于得到不同层次的特征, 从而提高网络的识别准确率。在使用深层次的网络结构时, 通常会遇到梯度消失和网络退化的问题。Resnet 系列网络的出现很好地解决了这个问题, 并且可以提高网络的识别准确率。解决这些问题的原因在于提出了残差学习^[23]单元这一模块, 它可以很好的解决网络退化问题, 残差学习单元结构如图 3 所示。通过图 3 可以得到

$$Y = F(x) + X \quad (2)$$

其中 Y 为下层输出, $F(x)$ 为上层输入 X 通过恒等映射 (Identity Mapping) 直接在输入和输出之间建立的一条关联通道, 从而可以学习到输入和输出之间的残差。




图 3 知识蒸馏流程图
Fig.3 Flow chart of knowledge distillation

1.2.3 损失函数

为了让学生模型更多地学习教师模型的知识, 使用了混合的相对损失函数 KD Loss。KD Loss 由相对熵损失函数和交叉熵损失函数结合而成。其中相对熵损失函数 (Kullback-Leibler Divergence) 用来衡量两个概率分布 A 和 B 差别的非对称性的度量, 通俗来讲就是定义了两个事件的不同程度。当两个概率分布相同时, 它们的相对熵的值为 0; 当两个概率分布差别很大时, 它们的相对熵值就会相应的增大。交叉熵损失函数 (Cross Entropy) 的作用是表示预测样本标签和真实样本标签之间的差值。当预测结果与真实结果一致时, 它们的交叉熵就为零; 如果预测结果偏差较大, 那么它们之间的交叉熵值就很大。通过将这两种损失函数进行混合, 可以更好地衡量

预测样本与真实样本之间的差异性和差值。在计算该混合函数的时候会对将教师模型进行知识蒸馏, 从而让学生模型学习到教师模型中的知识。混合损失函数的表达式如下:

$$\begin{aligned} \text{KD Loss} &= \text{KL}(m_2, n) \cdot \text{Lambda} \cdot T^2 \\ &\quad + \text{CE}(\text{label}, m_1) \cdot (1 - \text{Lambda}) \end{aligned} \quad (3)$$

式中 KL 为相对熵, CE 为交叉熵, q 为教师模型输出经过蒸馏后的结果, m_1 为学生模型中的 soft predictions, m_2 为学生模型中 hard predictions 经过蒸馏后的结果, label 为数据集的真实标签, Lambda 为比例系数。当系数 Lambda 为 0 时, KD Loss = CE(label, m_1), 混合损失函数相当于没有使用知识蒸馏, 只使用交叉熵损失函数的深度卷积神经网络。

2 结果与分析

2.1 预训练模型参数与可视化

4 个网络模型 Resnet18、Resnet34、Resnet50、Resnet101 的参数^[28]如表 2 所示, 其中深度是指该网络模型所具有的层数, 层数越多代表网络深度越深, 其性能也越好; 大小是指模型存储所需要的空间大小; 计算力就是模型进行参数运算的次数, 其数值越大代表模型参数量越大, 模型越复杂; 输入尺寸是指网络模型输入层要求的图片尺寸大小。

表 2 模型的基本参数

Table 2 Basic parameters of the model

模型 Model	深度层数 Depth layer	大小 Size/MB	计算力 FLOPs/ 10^6	输入尺寸 Input size/pixels
Resnet18	18	44	1.8	224×224
Resnet34	34	93	3.6	224×224
Resnet50	50	98	3.8	224×224
Resnet101	101	170	7.6	224×224

通过对卷积层进行特征可视化, 可以更好地理解模型的运行过程。从浅层到深层选择卷积层进行可视化, 结果如图 4 所示。神经网络的前面卷积层为浅层卷积层, 后面的卷积层为深层卷积层, 它们所关注的重点不同。图 4 中, 每一个小图由不同卷积层可视化得到, 它们按照从浅层到深层递增的顺序排序。从图中可以看出图像的形状越来越不明显, 因为浅层的卷积层提取的特征强调的是纹理、细节信息, 物体的基本形状能够比较清晰地展现出来。随着层数的增加, 将会提取更多的抽象特征, 通过更多的变换操作来更加完整地描述一个物体^[30]。相对而言, 层数越深, 提取的特征越具有代表性。通过对网络的可视化, 可以更好地了解网络对物体进行识别时所着重关注的地方, 图像越亮的区域表示特征越明显。

2.2 蒸馏模型训练测试结果

首先将所有样本随机排序。选取其中 2286 个样本作为训练集, 将数据集导入到 Resnet18 中进行模型的训练。剩下的 980 个样本作为测试集来验证模型的性能。训练过程中先采用 SGD 优化器对模型进行优化, 再采用梯度下降法对模型进行精调, 设置初始学习率为 0.001, 批尺寸为 8。经过

20 个迭代后，模型 KD Loss 曲线趋于稳定，训练停止。训练完成后将其在测试集上进行测试，识别准确率为 94.3%。




图 4 特征可视化结果
Fig.4 Feature visualization results





图 5 模型训练结果图
Fig.5 Model training results

表 3 Resnet101 网络分类结果的混淆矩阵

Table 3 Confusion matrix of Resnet101 network classification

类别 Classes	result			
	正常 Normal	弯曲 Curved	黑斑 Black spot	须根 Fibrous root
正常 Normal	300	0	0	0
弯曲 Curved	1	388	26	0
黑斑 Black spot	0	15	160	1
须根 Fibrous root	0	1	0	88


其中使用 Resnet101 作为教师模型作为指导模型对 980 个未经模型训练的样本进行预测试验，准确率最高，达到了 95.8%。模型分类的混淆矩阵如表 3 所示。通过混淆矩阵可以看出，模型对 4 类胡萝卜的识别准确率都是很高的。尤其是对正常胡萝卜的分类，分类准确率达到 100%，即使是对黑斑类胡萝卜的分类准确率也达到了 90.9%，这说明模型是有效的。同时也可以看到，对模型最大的干扰来自于黑斑和弯曲这两类之间的误判。

2.3 知识蒸馏前后模型的影响

为了验证不同深度的网络模型作为教师模型对学生模型准确率的影响，分别利用 Resnet34、Resnet50、Resnet101 作为教师模型来指导学生模型 Resnet18 的训练，3 种教师模型蒸馏前后识别结果汇总如表 4 所示。

通过试验结果可以发现，知识蒸馏技术后单一类准确率及平均准确率都有提升，单一类准确率最高提高了 2.3%，平均准确率最高提高了 1.5%。这是在原有网络没有使用知识蒸馏前识别准确率已经很高的基础上带来的提高，这说明通过知识蒸馏技术，学生模型可以充分吸收教师模型中获取的知识，获得本身所忽略的一些信息，从而在准确率上获得一定的提高。此外，通过对数据集的深入分析，可以发现在 4 类胡萝卜中黑斑类的胡萝卜的识别率最低，这可能是因为黑斑比较小或者颜色比较

作为对照试验，通过知识蒸馏使用 Resnet34、Resnet50、Resnet101 等 3 个网络来指导 Resnet18 进行模型的训练，同样选取其中 2286 个样本作为训练集，进行模型的训练。剩下的 980 个样本作为测试集，与原先只使用 Resnet18 网络的结果进行对比，来验证知识蒸馏后模型的性能。使用 Resnet18 和分别使用 Resnet34、Resnet50、Resnet101 对 Resnet18 知识蒸馏后模型对胡萝卜进行训练和识别，4 个模型训练和识别结果如图 5 所示。



浅，给网络识别带来了困难，这是在今后的研究中要特别关注的。

表 4 知识蒸馏前后的准确率对比结果

Table 4 Comparison results of accuracy before and after knowledge distillation

类别 Classes	% knowledge distillation						
	Resnet34		Resnet50		Resnet101		
蒸馏前 Before distillation	蒸馏后 After distillation	蒸馏前 Before distillation	蒸馏后 After distillation	蒸馏前 Before distillation	蒸馏后 After distillation		
正常 Normal	98.6	99.3	98.6	100	98.6	100	
弯曲 Curved	92.9	92.6	92.9	92.7	92.9	93.5	
黑斑 Black spot	89.2	90.3	89.2	90.4	89.2	90.9	
须根 Fibrous root	96.6	97.1	96.6	97.8	96.6	98.9	
平均准确率 Average accuracy	94.3	94.8	94.3	95.2	94.3	95.8	

采用不同深度的教师模型指导学生模型，来验证不同深度教师模型对学生模型的指导能力大小，平均识别率结果如表 4 所示。通过表 4 可以看出，随着教师模型网络深度的加深，识别准确率也越来越高。当教师网络为 Resnet101 时，学生模型的准确率最高。这说明通过使用层数更深的网络作为教师网络可以有效提高学生网络的识别能力。同时，从表 4 可以看出，针对不同品质特征（正常、弯曲、黑斑、带须根）蒸馏操作对识别效果影响不同，其中 3 种模型的蒸馏操作对黑斑类胡萝卜均不起作用，其模型的失效机理有待深入研究。

试验发现，当教师模型为 Resnet101 时，学生模型 Resnet18 的识别准确率最高，准确率为 95.8%。将它与传统的 resnet50 和 Resnet101 模型的准确率等进行比较，

汇总结果如表 5 所示。通过表 5 可以看到, 在参数方面, Resnet50 模型的参数量是 Resnet18 模型的 2.19 倍, Resnet101 模型的参数量是 Resnet18 模型的 3.81 倍。参数量越多意味着模型越大, 部署到相应设备上就越困难; 在训练时间上, 蒸馏后的 Resnet18 的总训练时间为 11.3 h, Resnet50 的总训练时间是 Resnet18 的 1.71 倍, Resnet101 的总训练时间是 Resnet18 的 2.77 倍; 在准确率方面, 蒸馏后的 Resnet18 模型的准确率为 95.8%, Resnet50 模型的准确率为 96.3%, Resnet101 模型的准确率为 96.9%。通过对比可以发现在知识蒸馏后, Resnet18 这一小模型的准确率可以接近 Resnet50 和 Resnet101 这些大模型的准确率。从模型训练时间和模型部署上考虑, 知识蒸馏是很有必要的, 通过牺牲小部分准确率可以大大缩短模型训练时间和降低模型部署成本。

表 5 模型使用知识蒸馏与未使用知识蒸馏的对比

Table 5 Comparison of models using knowledge distillation versus not using knowledge distillation

模型 Model	参数量 Parameter/ 10^6	大小 Size/MB	训练时间 Training time/h	准确率 Accuracy/%
Resnet18-distilled	11.7	44	11.3	95.8
Resnet50-undistilled	25.6	98	19.3	96.3
Resnet101-undistilled	44.6	170	31.3	96.9

3 讨 论

本试验基于知识蒸馏对 4 种不同品质的胡萝卜进行等级检测。使用不同教师模型来指导学生模型的训练, 从而获得更高的准确率。本试验中, 当教师模型为 Resnet101 时, 学生模型 Resnet18 的试验结果较好, 这说明越复杂的教师模型对学生模型的指导能力越好。试验结果表明, 相对于传统机器学习方法, 本试验所使用方法对检测不同等级的胡萝卜是更具有优势的。

在采集胡萝卜数据集的时候发现有一些胡萝卜既具有黑斑, 本身又带须根, 这是多目标识别问题, 给模型的识别造成了困难。在实际生活中, 这种情况是存在且无法避免的, 因为相对于工业产品来说, 农产品具有多样性, 没有一个统一标准来界定。因此通过收集大批量数据集来处理这个问题, 当上述特殊的胡萝卜的数量远小于正常的数量时, 这些具有两种特性的胡萝卜对模型识别的干扰也就会降到最低。在对试验结果进行分析时, 发现模型的误判大多集中在黑斑和弯曲这两类之间。这可能是因为有的黑斑类胡萝卜黑斑不够明显和本身有些弯曲, 或者是拍照时光线原因造成了分类错误。实际应用中因为这两类都是次品, 对正品分类影响不大。

考虑到有缺陷的中弯曲和带须根相对于正常的来说, 它们只是在果形上存在一定缺陷, 但是不影响食用, 而带黑斑的是不能食用的。所以本研究把它们分为 4 类, 目的是更加准确的对胡萝卜进行分级。等级分类越细化, 其经济价值转化就更大。此外, 本试验只分类了 4 类不同等级的胡萝卜, 这在实际中是不够充分的, 下一步应该考虑扩大要检测的胡萝卜类型。比如说, 胡萝卜损伤检测和其他不规则胡萝卜的也是十分有必要的。对于这

些类别的胡萝卜, 其核心思想与本研究一致。通过采集对应的数据集, 导入网络训练后就可以进行相应分级。同时, 在试验过程中采用的都是 Resnet101 一系列的网络模型, 这可能造成了相类似的模型之间所学习到的特征也是类似的, 进而导致存在许多没有利用起来的特征。一些文献中提到了通过调整模型参数等来提高模型的准确率, 比如说更换不同的优化器、调整学习率等。上述问题将是课题组下一步要研究的内容。

4 结 论

本研究针对神经网络训练中模型数据利用率不充分和模型过大的问题, 提出使用知识蒸馏技术建立了识别 4 种不同等级的胡萝卜的分类模型。主要结论如下:

- 1) 通过使用不同的教师模型优化, 使用混合损失函数, 提高了网络的识别准确率。对试验随机采集的 980 个胡萝卜图像的测试, 平均准确率达到了 95.8%。
- 2) 当教师模型为 Resnet101 时, 学生模型 Resnet18 的试验准确率为 95.8%。相比较未蒸馏前的 94.3%, 模型平均准确率提高 1.5%, 蒸馏后模型训练时间也相应的得到了减少, 说明该研究所使用的方法是可行的。
- 3) 通过知识蒸馏可以使得一个模型准确率接近大的模型的准确率, 这在模型部署及实际生产线应用是十分重要的。

[参 考 文 献]

- [1] 谭国飞, 王枫, 马静, 等. 室温贮藏过程中胡萝卜口感及部分营养成分含量变化[J]. 植物资源与环境学报, 2014, 23(1): 107-109.
Tan Guofei, Wang Feng, Ma Jing, et al. Changes of taste and content of some nutritional components of carrot during storage period under room temperature[J]. Journal of Plant Resources and Environment, 2014, 23(1): 107-109. (in Chinese with English abstract)
- [2] 易建勇, 侯春辉, 毕金峰, 等. 果蔬食品中类胡萝卜素生物利用度研究进展[J]. 中国食品学报, 2019, 19(9): 286-297.
Yi Jianyong, Hou Chunhui, Bi Jinfeng, et al. Review on carotenoid bioavailability in fruit and vegetable products[J]. Journal of Chinese Institute of Food Science and Technology, 2019, 19(9): 286-297. (in Chinese with English abstract)
- [3] Watson A, Pung H, Hall B H. Managing leaf diseases of carrots with traditional and alternative fungicides including baseline sensitivity studies[J]. Crop Protection, 2017, 93: 52-59.
- [4] Xie W, Wang F, Yang D. Research on carrot surface defect detection methods based on machine vision[J]. IFAC-PapersOnLine, 2019, 52(30): 24-29.
- [5] 陶华伟, 赵力, 奚吉, 等. 基于颜色及纹理特征的果蔬种类识别方法[J]. 农业工程学报, 2014, 30(16): 305-311.
Tao Huawei, Zhao Li, Xi Ji, et al. Fruits and vegetables recognition based on color and texture features[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2014, 30(16): 305-311. (in Chinese with English abstract)

- [6] 龙燕, 连雅茹, 马敏娟, 等. 基于高光谱技术和改进型区间随机蛙跳算法的番茄硬度检测[J]. 农业工程学报, 2019, 35(13): 270-276.
Long Yan, Lian Yaru, Ma Minjuan, et al. Detection of tomato hardness based on hyperspectral technology and modified interval random frog algorithm[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2019, 35(13): 270-276. (in Chinese with English abstract)
- [7] 黄辰, 费继友. 基于图像特征融合的苹果在线分级方法[J]. 农业工程学报, 2017, 33(1): 285-291.
Huang Chen, Fei Jiyou. Online apple grading based on decision fusion of image features[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2017, 33(1): 285-291. (in Chinese with English abstract)
- [8] Xie W, Wang F, Yang D. Research on carrot grading based on machine vision feature parameters[J]. IFAC-PapersOnLine, 2019, 52(30): 30-35.
- [9] 韩仲志, 邓立苗, 徐艳, 等. 基于图像处理的胡萝卜青头、须根与开裂的检测方法[J]. 农业工程学报, 2013, 29(9): 156-161.
Han Zhongzhi, Deng Limiao, Xu Yan, et al. Image processing method for detection of carrot green-shoulder, fibrous roots and surface cracks[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2013, 29(9): 156-161. (in Chinese with English abstract)
- [10] Deng L, Du H, Han Z. A Carrot sorting system using machine vision technique[J]. Applied Engineering in Agriculture, 2017, 33(2): 149-156.
- [11] 苍岩, 罗顺元, 乔玉龙. 基于深层神经网络的猪声音分类[J]. 农业工程学报, 2020, 36(9): 195-204.
Cang Yan, Luo Shunyuan, Qiao Yulong. Classification of pig sounds based on deep neural network[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2020, 36(9): 195-204. (in Chinese with English abstract)
- [12] 黎煊, 赵建, 高云, 等. 基于连续语音识别技术的猪连续咳嗽声识别[J]. 农业工程学报, 2019, 35(6): 174-180.
Li Xuan, Zhao Jian, Gao Yun, et al. Pig continuous cough sound recognition based on continuous speech recognition technology[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2019, 35(6): 174-180. (in Chinese with English abstract)
- [13] 郑秋梅, 谢换丽, 王风华, 等. 一种基于局部三值模式的深度学习人脸识别算法[J]. 计算机与现代化, 2018(2): 112-117.
Zheng Qiumei, Xie Huanli, Wang Fenghua, et al. A deep learning face recognition algorithm based on local ternary pattern[J]. Computer and Modernization, 2018(2): 112-117.
- [14] 林相泽, 张俊媛, 朱赛华, 等. 基于 K-SVD 和正交匹配追踪稀疏表示的稻飞虱图像分类方法[J]. 农业工程学报, 2019, 35(19): 216-222.
Lin Xiangze, Zhang Junyuan, Zhu Saihua, et al. Sparse representation classification method of rice planthop-per image based on K-SVD and orthogonal matching pursuit algorithm[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2019, 35(19): 216-222. (in Chinese with English abstract)
- [15] Li Juan, Xu Chen, Jiang Lingxu, et al. Detection and analysis of behavior trajectory for sea cucumbers based on deep learning[J]. IEEE Access, 2020, 8: 18832-18840.
- [16] Xu Wenkai, Zhu Zhaohu, Ge Fengli, et al. Analysis of behavior trajectory based on deep learning in ammonia environment for fish[J]. Sensors, 2020, 20(16): 1-11.
- [17] Kamilaris A, Francesc X Prenafeta-Boldú. Deep learning in agriculture: A survey[J]. Computers and Electronics in Agriculture, 2018, 147(1): 70-90.
- [18] 戴建国, 张国顺, 郭鹏, 等. 基于无人机遥感可见光影像的北疆主要农作物分类方法[J]. 农业工程学报, 2018, 34(18): 122-129.
Dai Jianguo, Zhang Guoshun, Guo Peng, et al. Classification method of main crops in northern Xinjiang based on UAV visible waveband images[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2018, 34(18): 122-129. (in Chinese with English abstract)
- [19] 韩文霆, 郭聪聪, 张立元, 等. 基于无人机遥感的灌区土地利用与覆被分类方法[J]. 农业机械学报, 2016, 47(11): 270-277.
Han Wenting, Guo Congcong, Zhang Liyuan, et al. Classification method of land cover and irrigated farm land use based on uav remote sensing in irrigation[J]. Transactions of the Chinese Society of Agricultural Machinery, 2016, 47(11): 270-277. (in Chinese with English abstract)
- [20] Ni Chao, Wang Dongyi, Vinson Robert, et al. Automatic inspection machine for maize kernels based on deep convolutional neural networks[J]. Biosystems Engineering, 2019, 178: 131-144.
- [21] 陈进, 顾琰, 练毅, 等. 基于机器视觉的水稻杂质及破碎籽粒在线识别方法[J]. 农业工程学报, 2018, 34(13): 187-194.
Chen Jin, Gu Yan, Lian Yi, et al. Online recognition method of impurities and broken paddy grains based on machine vision[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2018, 34(13): 187-194. (in Chinese with English abstract)
- [22] 王丹丹, 何东健. 基于 R-FCN 深度卷积神经网络的机器人疏果前苹果目标的识别[J]. 农业工程学报, 2019, 35(3): 156-163.
Wang Dandan, He Dongjian. Recognition of apple targets before fruits thinning by robot based on R-FCN deep convolution neural network[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2019, 35(3): 156-163. (in Chinese with English abstract)
- [23] Olaniyi E O, Oyedotun O K, Adnan K. Intelligent grading system for banana fruit using neural network arbitration[J]. Journal of Food Process Engineering, 2015, 40: e12335.
- [24] Juncheng M, Keming D, Feixiang Z, et al. A recognition method for cucumber diseases using leaf symptom images based on deep convolutional neural network[J]. Computers & Electronics in Agriculture, 2018, 154: 18-24.
- [25] 谢忠红, 徐焕良, 黄秋桂, 等. 基于高光谱图像和深度学

- 习的菠菜新鲜度检测[J]. 农业工程学报, 2019, 35(13): 277-284.
- Xie Zhonghong, Xu Huanliang, Huang Qiugui, et al. Spinach freshness detection based on hyperspectral image and deep learning method[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2019, 35(13): 277-284. (in Chinese with English abstract)
- [26] 杨彩霞, 刘克成. 基于深度卷积神经网络的胡萝卜外观缺陷分类实现[J]. 南阳理工学院学报, 2019, 11(4): 41-43. Yan Caixia, Liu Kecheng. Classification of carrot shape defects based on dcnn[J]. Journal of Nanyang Institute of Technology, 2019, 11(4): 41-43.
- [27] Hinton G, Vinyals O, Dean J. Distilling the knowledge in a neural network[J]. Computer Science, 2015, 14(7): 38-39.
- [28] He K, Zhang X, Ren S, et al. Deep Residual Learning for Image Recognition[C]// IEEE Conference on Computer Vision & Pattern Recognition. IEEE Computer Society, 2016.
- [29] 农业标准出版研究中心. 最新中国农业行业标准: 种植业分册[M]. 北京: 中国农业出版社, 2013.
- [30] Tang Pengjie, Wang Hanli, Sam Kwong. G-MS2F: GoogLeNet based multi-stage feature fusion of deep CNN for scene recognition[J]. Neurocomputing, 2017, 225: 188-197.

Intelligent detection of appearance quality of carrot grade using knowledge distillation

Ni Jiangong, Li Juan, Deng Limiao, Han Zhongzhi[※]

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

Abstract: Carrot has widely been served in the human diet, due to its rich in nutrients, particularly on carotene and dietary fiber. However, the brown and black spot disease can ruin the appearance and nutritional quality of carrot during the planting. Therefore, the classification of carrot grades has become an essential part, to improve the competitiveness of carrots in the market. Specifically, the detailed grading can greatly contribute to the commercial value of carrots. Traditionally, a feature extraction with classifier mode was generally adopted to detect the carrot appearance, where the manual definition of features was required, leading to time consuming, less accuracy, and erroneous judgement. In this study, a novel network was proposed to solve the problem, based on a lightweight front-end deployment method, the knowledge distillation technique. Teacher and student models were selected, where a teacher model was introduced to guide the training of student model. The model in this network can be used to reduce the number of parameters and running time, while achieve high accuracy. 3 266 high-resolution images of carrot were collected from the sorting machine as the experimental data sets. Four grades were divided, including the normal, curved, black spot and fibrous root, according to the carrot grading standards of Ministry of Agriculture of the People's Republic of China NY/T 1983—2011. 70% of the dataset was randomly divided into the training sets, whereas, the remaining 30% into test sets. The dataset of carrot was first imported into the network model for training. A teacher model was then introduced, when training to induce a student model, where the teacher model was a large-scale and complex network with many participants, whereas, the student model was a small-scale and streamlined network with a small number of parameters. By inducing training, small models can finally achieve high accuracy. Three teacher models were used, including Resnet34, Resnet50, and Resnet101, in order to guide the training of student model of Resnet18. Correspondingly, the average accuracy of distillation model increased from 94.3% to 94.8%, 95.2%, and 95.8%, respectively. The recognition rate of normal carrot was improved to 100%, where the Resnet18 student model was guided by the Resnet101 teacher model. The recognition rate of normal, black spot and fibrous root increased by about 2%, while, the training time of the model was 11.3 h. In addition, the recognition accuracies of Resnet50 and Resnet101 teacher model were 96.3% and 96.9% respectively, whereas, the training time of models can be 19.3 h and 31.3 h, respectively. The experimental results showed that the recognition rate of distillation model was much higher than that of the traditional model based on feature extraction with classifier. The recognition rate of model can further improved as the increase in the depth of teacher model. Knowledge distillation can perform well from the perspective of training time and arrangement in the model. The training time and deployment of model can be greatly shortened with a tradeoff of accuracy. Consequently, the knowledge distillation model can be used to provide a promising significant support to improve the performance of automatic detection device for the appearance quality of carrots.

Keywords: deep learning; models; quality control; carrot; rank classification; knowledge distillation