

文章编号: 2095-2163(2021)04-0117-07

中图分类号: TP181;TP183

文献标志码: J

基于微调优化的深度学习在果蔬识别中的应用

来 晓

(浙江农林大学 信息工程学院, 杭州 311300)

摘 要: 果蔬图像分类是图像识别的重要组成部分,是实现果蔬农产品自动化分类的关键技术。果蔬图像识别面临的主要挑战在于果蔬种类众多,缺乏大量的有标签数据,难以通过监督学习方法来实现果蔬图像分类。针对上述问题,本文构建果蔬图像数据集,提出将融合迁移学习的深度卷积网络用于果蔬图像识别。为了验证该方法的有效性,采用特定方式微调模型参数,在数据集上进行了实验。实验结果表明,通过微调优化方法,模型的准确性提升3%以上,为深度学习的微调优化提供一定的参考依据。

关键词: 果蔬图像分类;深度卷积网络;迁移学习;微调优化

Application of deep learning based on fine tuning optimization in fruit and vegetable recognition

LAI Xiao

(School of Information Engineering, Zhejiang A&F University, Hangzhou 311300, China)

【Abstract】 As an important part of image recognition, fruit and vegetable image classification is the key technology to realize automatic classification of fruit and vegetable products. The main challenge of fruit and vegetable image recognition lies in the lack of a large number of labeled data due to the variety of fruits and vegetables. It is difficult to realize the classification of fruit and vegetable images by supervised learning. Aiming at the above problems, a fruit and vegetable image data set was constructed, and a deep convolutional network based on fusion transfer learning was proposed for fruit and vegetable image recognition. In order to verify the validity of the method, the model parameters were fine-tuned in a specific way, and experiments were carried out on the data set. The experimental results show that the accuracy of the model is improved by more than 3%, and the fruit and vegetable recognition model based on resnet50 reaches 95.81%, which provides a reference for fine-tuning and optimization of deep learning.

【Key words】 Fruit and vegetable image recognition; Deep Convolutional Network; Transfer learning; Fine-tuning

0 引言

果蔬农产品种类繁多,对其进行自动分类识别在商品交易智能化以及无人零售推广方面具有重要意义。近年来物联网技术的广泛应用,贸易发展的主要方向趋于商品交易智能化^[1]。在新冠病毒疫情影响下,以智能取餐柜为代表的无人零售业率先兴起,国家鼓励全面推行“无接触”服务,无人零售迎来了新的机会,因此亟需设计表征效果更好的果蔬智能分类器,提高果蔬识别的准确率。

近年来,基于深度学习的计算机视觉研究取得了重大的进展。识别任务的成功与否很大程度上取决于能否获得大量的训练样本,标记训练样本是一个昂贵的过程。针对果蔬识别研究,目前大多处于构建数据集、优化分类模型阶段^[2]。随着深度学习的不断发展与完善,深度卷积神经网络(Convolutional neural network, CNN)广泛应用于各个领域,尤其是在图像识别、自然语言处理中取得了巨大的成果。深度神经

网络相比传统机器学习方法减少了人工干预过程,拥有自主学习特征和表达能力。AlexNet、VggNet16、Inception V3等经典的深度卷积神经网络,通过数据增强、Dropout方法防止过拟合,使模型适应性更强。

本文基于迁移学习方法对深度学习模型进行改进,使用全局池化技术解决全连接问题,在自主构建的F&V果蔬数据集上进行迁移学习,用较少的计算资源提高模型识别率。针对融合两个库出现的数据不平衡问题,利用模型融合的方法合并果蔬数据集。采用特定的迁移学习引入方式,设计多类实验,结合实验数据对比改进后的卷积神经网络模型在果蔬分类上的性能,与现有的深度学习算法相比,本文提出的果蔬识别方法提取到的特征对果蔬的识别分类更加高效,进而实现果蔬农产品的快速分类。

1 实验数据

1.1 实验数据

标记训练样本是一个昂贵的过程,针对果蔬识别研究,目前大多处于构建数据集、优化分类模型阶

作者简介: 来 晓(1996-),女,硕士研究生,主要研究方向:图像识别、深度学习。

收稿日期: 2020-12-07

段。针对果蔬种类繁多的现状,以及面对光照、阴影、阳光带来变化的现实场景,采用融合两个数据集的方式构建果蔬数据集 F&V_1。

(1)通过网络爬虫技术采集包含苹果、香蕉、火龙果等 15 种常见的果蔬样本,果蔬图片按照种类区分,存放在对应果蔬命名的文件夹下。同时人工筛选网络爬取的数据,手动删除无法预览以及标签与实际不符合的数据,共计 3 542 张图片。

(2)选用 kaggle 公开数据集 Fruit Recognize 赋

予深度学习模型在真实环境中更强的感知学习能力。Fruit Recognize 是 Chris Gorgolewski 利用高清 Logitech 网络摄像头建立的一个多视角的果蔬图像数据库,包含 15 个类别 44 406 张果蔬图像,具体见表 1。该数据集在相对不受限制的条件下收集的,采集了一天的不同时间段以及不同天气环境下的果蔬图像,具有位于自然光、人工照明等不同照明条件下 15 种果蔬图片,能应对光线、阴影、阳光、姿势等变化情况,如图 1 所示。



图 1 果蔬样本示例

Fig. 1 Examples of fruit and vegetables images

1.2 数据增强

本文使用的数据增强方法具体包括:

- (1)水平翻转图像。
- (2)对图像进行透视变换,变换范围为 0~0.2。
- (3)将图像随机缩放 0~0.25 倍。

(4)水平平移、垂直平移图像。在数据集 F&V_1 中,定义来自 Fruit Recognize 的数据为 FP,样本量为 N1,来自 Online Picture 的数据为 OP。使用上述数据增强方式组合,将 F&V_1 数据集扩充了 5 倍,构成数据增强果蔬数据集 F&V_2,随机抽取 5 次 1/5 的 F&V_2 数据集样本得到 5 个 F&V 数据集,具体 F&V 见表 1。

1.3 研究内容技术路线

通过分析国内外基于图片识别技术的果蔬分类算法研究,提出了基于深度学习的果蔬识别研究。采用深度学习算法对果蔬图片自动进行特征提取,从而训练分类器进行果蔬图像分类,如图 2 所示。进行深度学习模型训练时,从头开始训练一个神经网络对于有限的计算资源是非常耗时的,往往难以直接训练出泛化能力足够强的深度神经网络。因此,采用迁移学习方法,利用在 ImageNet 数据集上已经训练好的网络,针对自己的任务再进行调整,有

效节省训练时间,提高学习精度。

表 1 实验数据

Tab. 1 Experimental data

| 类别 | 源数据 | | F&V | |
|-------------|-----------------|----------------|-------|-------|
| | Fruit Recognize | Online Picture | FR | OP |
| Apple | 5 024 | 306 | 502 | 306 |
| Banana | 3 027 | 261 | 302 | 261 |
| Carambola | 2 080 | 177 | 208 | 177 |
| Guava | 4 008 | 230 | 265 | 230 |
| Kiwi | 4 173 | 212 | 417 | 212 |
| Mango | 4 154 | 199 | 415 | 199 |
| Muskmelon | 2 078 | 338 | 342 | 338 |
| Orange | 3 012 | 299 | 302 | 299 |
| Peach | 2 629 | 275 | 374 | 275 |
| Pear | 3 012 | 160 | 302 | 160 |
| Persimmon | 2 072 | 308 | 485 | 308 |
| Pitaya | 2 501 | 168 | 250 | 168 |
| Plum | 2 398 | 170 | 239 | 170 |
| Pomegranate | 2 167 | 176 | 216 | 176 |
| Tomato | 2 171 | 263 | 308 | 263 |
| 总量 | 44 506 | 3 542 | 4 927 | 3 542 |

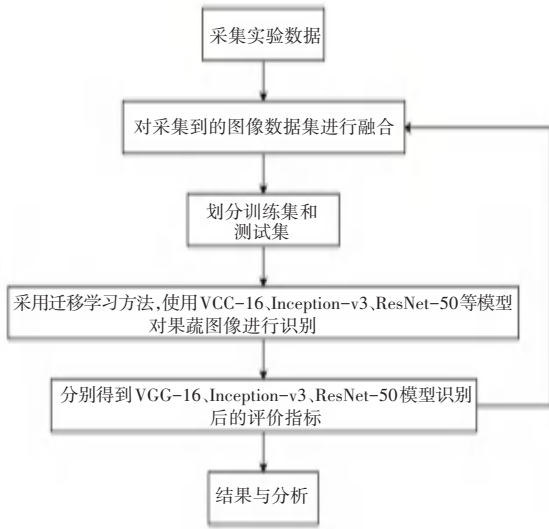


图2 技术路线

Fig. 2 Technical route

1.4 实验测量标准

为了验证果蔬分类算法的性能,选取合适的性能指标对实验结果进行评估^[3]。采用所有有待识别果蔬农产品的识别率指标平均精确率 (Mean Accuracy, MA)、正样本精确率 (Precision, P)、正样本召回率 (Recall, R)、负正类率 (FPR)、平衡 F 分数 (balanced F Score, F1-score)、kappa 系数 (K) 来衡量算法的识别率性能。对于每个分类,分别计算每个类正样本精确率,取不加权平均得到 $macro - P$, 由 $macro - P$ 的定义可知,某一方法若想获得较高的平均精确率,就需要每个正样本精确率都获得较高的精度。kappa 系数数值越高,代表模型实现的分类准确性越高,计算公式(1)~(6)如下:

$$MA = \frac{n_a}{n_{test}} \times 100\%. \quad (1)$$

其中, n_{test} 为待识别果蔬的总数量, n_a 为模型正确识别果蔬的数量。

$$macro - P = \frac{1}{N} \sum_i^N \frac{TP_i}{TP_i + FN_i}, \quad (2)$$

$$macro - R = \frac{1}{N} \sum_i^N \frac{TP_i}{TP_i + FN_i}. \quad (3)$$

$$F1 - score = \frac{2 \times macro - P \times macro - R}{macro - P + macro - R}, \quad (4)$$

$$p_e = \frac{\sum_{i=1}^N n_y \times n_{\hat{y}}}{n_{test}^2}, \quad (5)$$

$$K = \frac{p_0 - p_e}{1 - p_e}. \quad (6)$$

其中, TP_i 为正样本正预测; FP_i 为负样本负预测; FN_i 为正样本负预测; N 为类别数; n_y 为第 i 类真实样本数; $n_{\hat{y}}$ 为第 i 类预测样本数; n_{test} 为待识别果蔬的总数量。

2 基于深度学习的图像识别

2.1 迁移学习

迁移学习的常用方法有以下几种:

(1) 实例迁移,源域中部分与目标域相似的数据可以通过权重调整的方法重用,用于目标域的学习。

(2) 特征迁移,将源域和目标域的交叉特征变换到统一的特征空间,利用传统的机器识别方法进行分类识别。

(3) 参数迁移,源域和目标域共享模型参数,源域中通过大量数据训练好的模型参数可以应用到目标域上^[4]。参数迁移中,如果目标数据集很小而参数量很大,对目标网络所有参数进行调整,可能会导致过拟合,因此通常固定网络前 n 层参数,仅需初始化网络中的几层。迁移学习为机器学习领域深度神经网络训练,保留和重用网络模型提供了解决思路。

冯海林等提出基于树木整体图像和集成迁移学习的树种识别,预训练模型已经具备有助于图像分类的基本特征(边缘、颜色、纹理)提取能力,这里采用参数迁移方法^[5]。将在 ImageNet 数据库上训练好的模型 (VggNet16、ResNet、Inception-V3) 的通用特征迁移到果蔬识别的模型中,构成果蔬识别模型 Fruit&Vegetable_Model (FVM),以提高图像识别率、减少模型训练的参数数量提高训练效率。

2.2 深度学习模型

2.2.1 VggNet16 网络结构

VGG 卷积神经网络在图像分类和目标检测任务中都表现出较好的结果,因此 VGGNet 常被用作模型的特征提取器。VGG16 采用统一大小的 3×3 卷积核替代 AlexNet 中较大的卷积核 (11×11 , 5×5),简化了神经网络结构。反复堆叠 3×3 的小型卷积核和 2×2 的池化层,通过不断加深网络结构来提升性能。另一方面,随着网络的加深,图像的宽度和高度都以一定的规律不断地减小,每次池化后缩小一半,信道数目增加一倍,减少了训练参数。VGG16 由 13 个卷积层和 3 个全连接层以及 Softmax 输出层构成,训练的特征数量非常大,其中绝大部分参数来自全连接层,使用全局池化层 (Global Average Pooling, GAP) 替换全连接层以减少训练参数^[6],如图 3 所示。




图 3 基于 VGG16 的果蔬识别模型

Fig. 3 Fruit and vegetable recognition model based on VGG16

2.2.2 Inception V3 网络结构

Inception 网络是卷积神经网络分类器发展史上一个重要的里程碑。Inception V3 模型基于卷积神经网络,在 ILSVRC (ImageNet large scale visual recognition challenge) 2012 分类挑战赛验证集上测试,取得了实质性的收益。Inception V3 使用更优秀的因子分解方法,分解卷积和积极降维让计算成本相对较低,同时可以保持高质量检测。Inception V3 整合 Inception V2 的所有升级,将 5×5 的卷积分解成两个 3×3 的卷积的堆叠,通过这种分解得到 28% 的相对增益。将空间卷积进一步分解为不对称卷积,替换 3×3 的卷积核,分解为 1×3 和 3×1 两个卷积,这种方法在成本上比单个 3×3 卷积降低 33%。Inception 模块中的滤波器扩展,使模型变得更宽,以解决表征性瓶颈局限。

2.2.3 ResNet50 网络结构

深度学习网络通过不断加深网络提升模型最后的分类和识别效果,常规堆叠网络随着网络深度的增加,出现梯度消失和梯度爆炸现象,在开始就阻碍网络的收敛,导致网络深度的增加,准确率达到饱和,然后迅速下降问题。针对上述退化问题,He K 等提出残差 (Residual) 结构,残差神经网络 (ResNet) 在浅层网络叠加残差模块 (Residual block),避免梯度消失和梯度爆炸问题,使得训练更深的网络的同时又能保证良好的性能^[7]。经典的残差网络模型有 ResNet50、ResNet101 和 ResNet152,分别是 50、101、152 层 ResNet。ResNet50 采用了 Inception 模块化的结构,利用残差模块训练更深的网络,结合 Inception 网络和 VGG 网络的优点,提升模型的训练效果。具体如图 4 所示。

2.3 实验环境与参数设置

实验基于 Windows10 操作系统,处理器为 Inter (R) Xeon (R) Silver 4110 CPU@2.10GHz。神经网络的搭建、训练、测试使用 python 语言编程,调用开源人工神经网络库 Keras 来实现。



图 4 残差神经网络

Fig. 4 ResNet

论文使用 ImageNet 数据集上训练好的模型来初始化 3 种深度学习模型权重。采用 Adam 优化器进行网络训练,通过自适应学习率迭代地更新网络权重,在较少的内存需求下达到高效的计算。设置的初始学习率为 $1e-4$,batch_size 为 32。3 个模型经过 30 个批次训练之后逐渐收敛,在相同的参数设置下得到最优果蔬分类模型,并对实验结果进行分析总结。数据集被随机分为训练集、验证集、测试集三部分,数据集占比为 6 : 2 : 2。

2.4 果蔬识别模型的构建

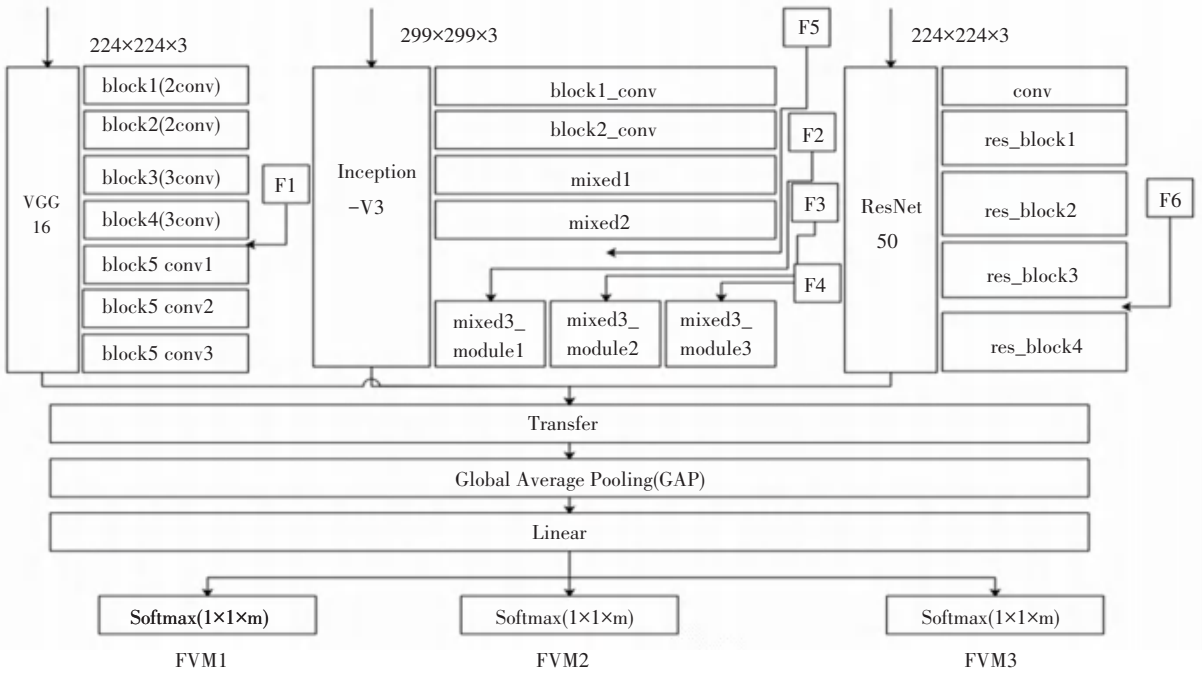
利用参数迁移方法将 3 种模型的共性知识进行迁移,除去模型的全连接层和 softmax 层,自定义新的顶层网络,采用全局池化技术替代原模型中的全连接层连接方式。构成果蔬识别模型 Fruit&Vegetable_Model (FVM),如图 5 所示。

自定义顶层网络,通过 2 种方式训练模型:直接迁移和特定地微调 (finetune) 方式。直接迁移即只训练网络的自定义层,特定地微调 (finetune) 方式引入 F1、F2、F3、F4、F5、F6 指针,指针位置指向网络的特定层,随着指针的变化,部分底层的权重也随着训练。

FVM 卷积神经网络使用交叉熵损失函数来评估真实值和预测值之间的差距,损失函数见式 (7)。

$$H(X, q)_\theta = - \sum_e p(e, \theta) \log q(e, \theta). \quad (7)$$

式中: $H(X, q)$ 为训练损失; θ 为权重参数; e 为训练批次样本; p 为期望概率; q 为预测概率。



注：其中 m 为 Fruit_Vegetable_15 数据集的种类，实验中 m 为 15

图 5 果蔬图像识别模型

Fig. 5 Image model FVM

Adam (adaptive moment estimation) 优化器在模型中用于参数的更新,式(8)~式(13):

$$g_t = \tilde{\nabla}_\theta J(\theta_{t-1}). \tag{8}$$

式中: g_t 计算 t 时间步的梯度, $J(\theta_{t-1})$ 为损失函数。

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t. \tag{9}$$

式中: m_0 初始化为 0, β_1 系数为指数衰减率,控制权重分配(动量与当前梯度),通常取接近于 1 的值,默认为 0.9。

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2. \tag{10}$$

式中: v_0 初始化为 0, β_2 系数为指数衰减率,控制之前的梯度平方的影响情况,默认为 0.999。

$$\hat{m}_t = m_t / (1 - \beta_1^t), \tag{11}$$

$$\hat{v}_t = v_t / (1 - \beta_2^t). \tag{12}$$

式中:对梯度均值 m_t, v_t 进行偏差纠正,降低偏差对训练初期的影响。

$$\theta_t = \theta_{t-1} - \alpha \times \hat{m}_t / (\sqrt{\hat{v}_t} + \epsilon). \tag{13}$$

式中: $\epsilon = 10^{-8}$, 避免除数变为 0, α 为学习率默认为 0.001。

3 实验结果与分析

3.1 三种模型直接迁移训练结果展示

基于 VggNet16、ResNet50、Inception V3 模型改进的果蔬分类模型 FVM1、FVM2、FVM3,在原始数据集上采用直接迁移学习方法迁移共性知识的训练结果。15 种果蔬正样本精确率 P 和正样本召回率的对比结果,如图 6 所示。




图 6 15 种果蔬正样本精确率 P 和正样本召回率的对比

Fig. 6 Precision and recall of fruits and vegetables

把 3 种网络结构估测的评价指标进行对比,见表 2。VGG16 的正样本精确率 $macro - P$ 、正样本召回率 $macro - R$ 、 $F1 - Score$ 、kappa 系数 K 分别为 92.13%、92.22%、91.55%、98.12%,其平均准确率略低于 ResNet50;Inception V3 作为检测模型得到的正样本精确率 $macro - P$ 、正样本召回率 $macro - R$ 、 $F1 - Score$ 、kappa 系数 K 分别为 87.78%、87.26%、87.52%、86.15%;基于 ResNet50 的果蔬识别模型具有最高的正样本精确率 $macro - P$ (0.9344)、最高的正样本召回率 $macro - R$ (0.9240)、最高的 $F1 - Score$ (0.9292) 及最大的 kappa 系数 K (0.9151)。因此,从综合结果来看,基于 ResNet50 构建识别模型略优于基于 VGG-16 构建的模型,基于 Inception V3 的识别模型效果略差。

3.2 果蔬识别模型算法对比分析

如图 7~图 9 这 3 个线性图所示,以 F&V 测试

集数据作为输入,分别表示每种果蔬基于 FVM1 和 VGG16 的正样本准确率 (P) 及正样本召回率 (R);基于 FVM2、FVM2-1、FVM2-2、FVM2-3 和 Inception V3 的正样本准确率 (P) 及正样本召回率 (R);基于 FVM3 和 ResNet50 的正样本准确率 (P) 及正样本召回率 (R)。

表 2 基于直接迁移的各项评价指标系数

Tab. 2 Evaluation index coefficients based on direct transfer

| 评价指标 | 网络结构 | | |
|-------------------|-------|--------------|----------|
| | VGG16 | Inception V3 | ResNet50 |
| $macro - P / \%$ | 92.13 | 87.78 | 93.44 |
| $macro - R / \%$ | 92.22 | 87.26 | 92.40 |
| $F1 - Score / \%$ | 92.17 | 87.52 | 92.92 |
| $K / \%$ | 91.36 | 86.15 | 91.51 |
| $MA / \%$ | 91.84 | 87.17 | 92.03 |




图 7 FVM1 和 VGG16 正样本准确率和正样本召回率的对比

Fig. 7 Precision and recall between FVM1 and VGG16





图 8 FVM2、FVM2-1、FVM2-2、FVM2-3 和 Inception V3 正样本准确率和正样本召回率的对比

Fig. 8 Precision and recall between FVM2、FVM2-1、FVM2-2、FVM2-3 and Inception V3






图 9 FVM3 和 ResNet50 正样本准确率和正样本召回率的对比

Fig. 9 Precision and recall between FVM3 and ResNet50



把 6 种模型估测的评价指标进行对比见表 3, FVM1 的正样本精确率 $macro - P$ 、正样本召回率 $macro - R$ 、 $F1 - Score$ 、kappa 系数 K 分别为 94.65%、94.19%、94.42%、94.68%, 其平均准确率 (MA) 比 VGG16 提升了 2.84%; 基于 Inception V3 优化得到模型中, FVM2-1 的正样本精确率 $macro - P$ 、正样本召回率 $macro - R$ 、 $F1 - Score$ 、kappa 系数的正样本准确率 (P) 及正样本召回率 (R) 数 K 在 FVM2

-模型中指标值最高, 可以发现仅调整 Inception V3 混合层的第二个模块的参数对识别模型的优化效果最佳, 其平均准确率提升了 7.33%; 基于 ResNet50 的果蔬识别模型具有最高的正样本精确率 $macro - P$ (0.9588)、最高的正样本召回率 $macro - R$ (0.9481)、最高的 $F1 - Score$ (0.9534) 及最大的 kappa 系数 K (0.9549)。因此, 从综合结果来看, FVM3 略优于 FVM1 和 FVM2-1。

表 3 基于改进模型的试验结果
Tab. 3 Result base on direct transfer

| 评价指标 | FVM1 | FVM2 | FVM2-1 | FVM2-2 | FVM2-3 | FVM3 |
|------------|-------|-------|--------|--------|--------|-------|
| macro-P/% | 94.65 | 94.23 | 94.65 | 94.07 | 92.88 | 95.88 |
| macro-R/% | 94.19 | 93.05 | 94.05 | 93.14 | 93.37 | 94.81 |
| F1-Score/% | 94.42 | 93.64 | 94.35 | 93.61 | 93.12 | 95.34 |
| K/% | 94.28 | 93.95 | 94.08 | 93.54 | 92.93 | 95.49 |
| MA/% | 94.68 | 94.37 | 94.50 | 93.99 | 93.42 | 95.81 |

3 结束语

本文提出了一种基于深度学习和迁移学习的果蔬识别方法, 解决自然场景中不同光照条件下果蔬图像识别问题。首先, 自行建立一个新的果蔬图像数据集 F&V, 采用多种采集方式下数据融合, 打破不同识别系统之间的信息壁垒, 建立新的识别模型, 保障果蔬数据分类的全面性、互补性和准确性; 其次, 利用数据增强, 增强了预测模型的泛化能力, 提升了模型的性能。传统果蔬识别模型人工提取特征困难, 对深度学习网络模型进行改进, 使用全局池化技术替换全连接技术连接网络, 结合迁移学习方法构成果蔬识别模型 FVM, 进一步提升了网络的准确性。通过微调优化方法, 模型的准确性至少提升了 3%, 文中特定方式的迁移可为不同的模型微调提供参考依据, 具有一定的实用价值。在后续的研究中, 还可以引入新的预测模型进一步实现农产

品自动分类任务。

参考文献

- [1] 秦毅, 彭力. Design and Implementation on Supermarket Shopping Guide System Based on RFID and Internet of Things [J]. 计算机研究与发展, 2010, 47(2): 350-354.
- [2] RAHNEMOONFAR M, SHEPPARD C. Deep count: fruit counting based on deep simulated learning [J]. Sensors, 2017, 17(4): 905.
- [3] 李俊峰. 基于 RGB 色彩空间自然场景统计的无参考图像质量评价 [J]. 自动化学报, 2015 (9): 1601-1615.
- [4] HOULSBY N, GIURGIU A, JASTRZEBSKI S, et al. Parameter-efficient transfer learning for NLP [J]. arXiv preprint arXiv:1902.00751, 2019.
- [5] 冯海林, 胡明越, 杨垠晖, 等. 基于树木整体图像和集成迁移学习的树种识别 [J]. 农业机械学报, 2019, 50(8): 235-242, 79.
- [6] LIN M, CHEN Q, YAN S. Network in network [J]. arXiv preprint arXiv:1312.4400, 2013.
- [7] WU S, ZHONG S, LIU Y. Deep residual learning for image steganalysis [J]. Multimedia tools applications, 2018, 77(9): 10437-10453.

(上接第 116 页)

关技术进行选型以及研究后, 采用 ARKit 技术来设计导航系统。针对游客在游览时存在的寻找艺术品位置不便的问题, 提供了线路和路径导航的解决方案。系统的应用, 将在很大程度上解决了馆内人流无序的问题, 更有利于维护馆内的秩序, 以及更好地利用艺术品被欣赏的文化价值。

参考文献

- [1] 张赛东, 邓晓军, 李玉龙, 等. 基于 ARKit 技术的文物交互式手机 App 设计与实现 [J]. 湖南工业大学学报, 2020, 184(5): 45-51.
- [2] 戴也. 基于 ARKit 的增强现实空间交互设计及相关技术研究 [D]. 北京: 北京邮电大学, 2019.
- [3] 田宝平, 李瑾博, 李卓然, 等. 基于 ARkit 的现实测距技术研究与实现 [C]// 第十二届全国信号和智能信息处理与应用学术会议论文集, 2018.