

# 基于轻量化模型和迁移学习的花卉识别

王军敏, 林 辉

(平顶山学院 信息工程学院, 河南 平顶山 467036)

**摘 要:**针对现有花卉识别方法存在的识别精度不高、模型体积大等问题,提出一种基于轻量化模型和迁移学习的花卉识别方法.首先,以 MobileNetV2 模型作为骨干网络构建轻量化的花卉识别模型;然后,采用迁移学习策略使模型具备良好的初始特征提取能力;最后,利用小规模的花卉图像数据集对模型进行逐级训练和微调,使模型获得最佳的花卉识别能力.实验结果表明,该花卉识别模型在花卉图像数据集 Oxford flower-102 上获得了 97.76% 的识别精度,并且模型体积只有 9.2 MB,具有识别精度高、模型体积小的优点,方便在移动设备上部署和应用.

**关键词:**花卉识别;迁移学习;深度学习;轻量化模型

**中图分类号:**TP391

**文献标识码:**A

**文章编号:**1673-1670(2023)05-0043-05

## 0 引言

花卉识别在日常的花卉鉴赏、植物物种研究与保护、园林花圃智能化管理中具有重要的应用价值.传统依靠人工鉴别的方法需要具备丰富的专业知识和经验,因此有必要设计一种快速、准确的花卉识别系统.尤其是随着移动终端设备特别是智能手机的广泛使用,人们可通过智能手机拍摄花卉图像,然后利用手机上的花卉识别系统获取该花卉的类别、栽培、花语等信息.但是,由于花卉种类繁多,并且花卉图像可能存在复杂背景、光照条件和尺度变化等诸多因素的干扰,使得花卉识别成为一项具有挑战性的任务.

传统的机器学习方法主要依靠人工设计的特征描述算子提取花卉的形状、纹理和颜色等特征,计算不同样本之间的特征距离,利用分类器对花卉的类别进行判定.例如,Nilsson 和 Zisserman<sup>[1]722</sup>先分割出花卉前景,再提取花卉的花瓣、边缘形状、纹理和颜色等特征并送入分类器,识别精度达到 72.80%.Angelova 和 Zhu<sup>[2]811</sup>在对花卉图像进行分割的基础上,提取方向梯度直方图特征并送入分类器,识别精度达到 80.70%.但是,传统的机器学习方法存在算法设计复杂、泛化能力差和识别精度低

等问题.目前,随着深度学习技术的快速发展,基于深度卷积神经网络(Convolutional Neural Network, CNN)的图像识别方法获得了广泛的研究,该类方法可直接将原始图像送入 CNN 模型获得分类结果,避免了传统机器学习方法中复杂的图像分割和特征提取算法设计.例如,Liu 等<sup>[3]110</sup>设计了一个包含 5 个卷积层和 3 个全连接(Fully-Connected, FC)层的 CNN 模型,在 Oxford Flower-102 花卉数据集上实现了 84.02% 的识别精度;Qin 等<sup>[4]310</sup>将注意力机制和线性判别损失函数相结合设计一种 CNN 模型,在 Oxford Flower-102 数据集上获得了 87.60% 的识别精度;为了抑制复杂背景的干扰,吴迪等<sup>[5]55</sup>先利用显著性检测方法将花卉区域从背景图像中分割出来,再采用 InceptionV3 模型和迁移学习方法进行花卉识别,识别精度达到 93.38%.虽然基于深度学习的方法能够取得比传统机器学习方法更好的识别效果,但是现有的深度学习方法存在模型体积大,不方便在移动端或便携式设备上部署,同时识别精度也有待进一步提高的问题.因此,笔者提出一种基于轻量化深度模型和迁移学习的花卉图像识别方法,具有重要的应用价值.

## 1 轻量化模型的设计

为了实现深度模型的轻量化,笔者采用 Mo-

收稿日期:2023-02-17

基金项目:河南省科技厅科技攻关项目(202102210331);平顶山学院博士科研启动基金项目(PXY-BSQD-202004)

作者简介:王军敏(1982—),男,河南省平顶山市人,工学博士,平顶山学院信息工程学院讲师,主要从事图像识别、机器学习研究.



MobileNetV2 模型<sup>[6]</sup>作为骨干网络,在此基础上设计花卉识别模型. MobileNetV2 模型一方面采用深度可分离卷积代替传统的标准卷积,可显著减少深度模型的计算量和参数规模;另一方面借鉴了 ResNet 模型<sup>[7]</sup><sup>770</sup>的残差结构,通过采用反向残差模块和线性瓶颈单元来提高模型的特征提取能力. 反向残差模块先通过  $1 \times 1$  的点卷积增大输出通道的个数,再利用  $3 \times 3$  的深度卷积提取更加丰富的特征,最后利用  $1 \times 1$  的点卷积实现通道降维;线性瓶颈

单元主要是去掉每个反向残差模块最后一个 ReLU6 激活层,以便保留更多的低维和高维信息. 笔者设计的花卉识别深度模型结构如表 1 所示,主要利用 17 个反向残差模块提取花卉图像的多层次特征,利用全局平均池化 (Global Average Pooling, GAP) 层实现特征降维,利用 Dropout 层提高模型的泛化能力,利用 FC 层输出当前样本对所有类别的分类得分,并将分类得分最高的类别判定为当前样本的所属类别.

表 1 笔者设计的花卉识别深度模型结构

模块编号	模块名称	说明	模块编号	模块名称	说明
0	Conv + BN + ReLU	输入模块	11	InvertedResidual_11	反向残差模块 11
1	InvertedResidual_1	反向残差模块 1	12	InvertedResidual_12	反向残差模块 12
2	InvertedResidual_2	反向残差模块 2	13	InvertedResidual_13	反向残差模块 13
3	InvertedResidual_3	反向残差模块 3	14	InvertedResidual_14	反向残差模块 14
4	InvertedResidual_4	反向残差模块 4	15	InvertedResidual_15	反向残差模块 15
5	InvertedResidual_5	反向残差模块 5	16	InvertedResidual_16	反向残差模块 16
6	InvertedResidual_6	反向残差模块 6	17	InvertedResidual_17	反向残差模块 17
7	InvertedResidual_7	反向残差模块 7	18	Conv + BN + ReLU	特征调整模块
8	InvertedResidual_8	反向残差模块 8	19	GAP	全局平均池化层
9	InvertedResidual_9	反向残差模块 9	20	Dropout	随机连接层
10	InvertedResidual_10	反向残差模块 10	21	FC	输出分类得分值

## 2 迁移学习策略的设计

在现实场景的样本分类问题中,深度学习方法通常面临两个重要的瓶颈问题:1)很多应用场景缺少大规模的训练样本,无法对深度模型进行充分的训练,导致深度模型的识别精度不高;2)对大规模训练样本进行充分训练时,需要高性能的计算平台和很长的训练时间. 为了解决上述问题,可采用迁移学习的方法. 迁移学习是将在一个源领域学习到的知识迁移应用到另一个不同但相关的目标领域的方法<sup>[8]</sup>,其中,源领域通常具有大规模的训练样本可利用,而目标领域通常存在训练样本数量不足的问题.

针对花卉图像识别问题,如果从零开始训练深度模型,需要收集大规模的花卉图像训练样本,并且需要高性能的计算平台和很长的训练时间,不利于深度学习方法的落地应用;同时,考虑到 ImageNet 数据集是含有大规模样本的通用图像数据集,该数据集也含有大量的花卉图像. 因此在该数

据集上训练后的模型已经具备了初步的花卉图像特征提取能力,可利用迁移学习方法将 ImageNet 数据集上训练后的深度模型参数迁移应用到花卉识别领域,从而有效解决将深度学习方法应用于花卉识别时的瓶颈问题.

笔者设计的迁移学习策略为:

1)将在 ImageNet 数据集上预先训练好的 MobileNetV2 模型参数值迁移应用于笔者设计的花卉识别深度模型骨干网络,使模型具备良好的初始花卉特征提取和识别能力,避免对大规模训练样本、高性能训练平台和长时间训练的要求.

2)冻结花卉识别深度模型的特征提取模块(即表 1 中的第 0 ~ 20 号模块),利用现有的花卉图像数据集对模型最后的 FC 层进行微调训练,使 FC 层获得较好的初始化参数值.

3)对花卉识别深度模型的 17 个反向残差模块进行逐个冻结,利用现有的花卉图像数据集对 FC 层和可训练的反向残差模块进行微调训练,使模型获得最佳的花卉图像识别能力.



### 3 实验及结果分析

#### 3.1 实验数据

实验采用牛津大学 Visual Geometry Group 小组搜集整理的花卉图像数据集 Oxford flower-102, 该数据集一共包含 102 类花卉图像,属于大规模的花卉图像数据集,每个花卉类别的样本数量为 40 ~ 258 张,该数据集中的花卉图像种类繁多,并且包含不同的照明条件和视角变化,存在复杂的背景干扰和形态、颜色变化等因素,使其成为一个极具挑战性的花卉图像识别数据集。笔者从每个类别选择 10 个样本加入验证集,每类 10 个样本加入测试集,即最终构建的验证集包含 1 020 个样本,测试集包含 1 020 个样本,其他样本均作为训练集。

#### 3.2 实验环境与超参数设置

实验采用的硬件环境为一台计算机(Intel Core i5 CPU@3.10 GHz,16 GB RAM),显卡 Nvidia RTX2070S GPU,软件环境为 Python 3.5,Pytorch 1.8.1。

超参数的设置如下:1)训练深度模型时,采用性能较好且收敛速度快的 Adam 优化器,损失函数选择适用于多分类的交叉熵损失函数。2)最大的训练轮数设为 50 个 Epoch。3)关于学习率的设置,考虑到如果学习率过大,可能会越过最优值;反之,如果学习率太小,则优化效率太低,可能导致模型长时间无法收敛。因此,笔者采用动态变化的学习率,即在训练初期采用较大的学习率,以便加快模型的训练和收敛;当靠近最优解时采用较小的学习率,以便更精确地收敛到最优解。具体设置为前 30 个 Epoch 设学习率为 0.001,随后每经过 10 个 Epoch 学习率变为上次的 0.1 倍。4)批尺寸设为 32,即每次将一批(32 个)花卉图像样本送入模型进行训练和验证。5)Dropout 层的随机连接概率设为  $p = 0.2$ 。

#### 3.3 实验步骤

本文方法的具体实现步骤如下所述。

**Step 1** 图像的预处理和数据增强。首先,对输入图像进行随机的左右翻转、上下翻转,增加训练样本的数量;然后,将图像尺寸统一调整到  $224 \times 224$  像素;最后,将图像数据归一化为均值为 0,标准差为 1。

**Step 2** 模型参数迁移。将在 ImageNet 数据集

上预先训练好的深度模型参数值根据参数匹配原则迁移到笔者设计的花卉识别深度模型骨干网络。

**Step 3** 训练 FC 层。先冻结本文模型的第 0 ~ 20 号模块,根据设置的优化器、损失函数、训练轮数 Epoch、动态学习率、批尺寸等超参数,对模型最后的 FC 层进行 5 轮训练,使 FC 层获得合理的初始化参数值。

**Step 4** 逐级训练反向残差模块。先冻结本文模型的全部反向残差模块,将 17 个反向残差模块从后向前逐个解冻(即设为可训练),利用设定的超参数和数据增强后的花卉图像数据集对整个模型进行微调训练。

**Step 5** 验证模型。利用花卉图像的验证集对训练好的模型进行验证,当验证精度最高时,表明模型获得了最佳的花卉图像识别能力,保存此时的模型,将其作为最佳的花卉识别模型。

**Step 6** 测试模型。利用花卉图像的测试集对保存的最佳花卉识别模型进行测试,获得测试识别精度。

#### 3.4 实验结果及分析

##### 3.4.1 模型的训练和验证效果

根据笔者设计的花卉识别深度模型和迁移学习策略,利用花卉图像训练集和验证集对模型进行训练和验证,对应的训练和验证损失曲线、识别精度曲线分别如图 1 和图 2 所示。从图 1 的损失曲线可以看出,训练和验证的损失值很小,并且能够快速下降到 0.4 以下,表明模型具有较快的收敛速度;从图 2 的识别精度曲线可以看出,模型的训练和验证识别精度较高,并且能够快速提升到 90% 以上,表明模型具有较好的花卉识别能力。




图 1 训练和验证阶段的损失曲线






图 2 训练和验证阶段的识别精度曲线

### 3.4.2 冻结不同反向残差模块的影响

根据笔者设计的花卉识别深度模型和迁移学习策略,通过冻结不同的反向残差模块可获得不同的迁移学习效果,表 2 给出了冻结不同反向残差模块个数  $N$  时本文模型在花卉图像测试集上的识别精度.从表 2 可以看出,当冻结全部反向残差模块 ( $N=17$ ) 时,模型的识别精度不够理想,这是因为此时反向残差模块的参数值均来自 ImageNet 数据集预先训练的模型参数,缺乏针对花卉图像的识别能力;当冻结  $N=12$  个反向残差模块时,模型的识别精度达到最高的 97.76%,此时模型具有最佳的花卉图像识别能力;当冻结反向残差模块的个数  $N$  逐渐减少时,模型的识别精度总体呈下降趋势,这是因为现有的花卉图像数据集样本个数较少,无法对深度模型进行充分训练.所以,最终确定冻结  $N=12$  个反向残差模块,使本文模型具有最佳的花卉识别精度.

表 2 冻结不同反向残差模块个数  $N$  的测试精度

$N$	测试精度/%	$N$	测试精度/%
17	93.73	8	95.55
16	94.90	7	94.80
15	95.88	6	94.17
14	96.35	5	94.38
13	96.82	4	93.56
12	97.76	3	93.33
11	96.19	2	92.86
10	95.76	1	92.27
9	95.43		

### 3.4.3 不同方法的识别精度对比

为了展示本文方法的识别性能,将笔者提出的方法与其他先进的方法进行对比,它们在 Oxford flower-102 花卉图像数据集上的识别精度如表 3

所示.

表 3 不同方法的识别精度对比

对比方法	识别精度/%
文献 <sup>[1]</sup> 728	72.80
文献 <sup>[2]</sup> 817	80.70
文献 <sup>[3]</sup> 115	84.02
文献 <sup>[4]</sup> 3116	87.60
VGG16 迁移微调 <sup>[9]</sup> 147	89.41
文献 <sup>[7]</sup> 770	92.75
ResNet50 迁移微调 <sup>[9]</sup> 147	92.94
文献 <sup>[5]</sup> 55	93.38
Inceptionv3 迁移微调 <sup>[9]</sup> 147	94.71
本文方法	97.76

从表 3 可以看出,笔者提出的方法取得了最高的识别精度(97.76%),一致超过了其他方法(包括传统的机器学习方法和目前先进的深度学习方法)的识别精度,这表明笔者设计的深度模型结构和迁移学习策略能够更有效地提取富有鉴别力的花卉图像特征,从而有效解决了现有方法识别精度不高的问题.

此外,笔者设计的花卉识别深度模型具有轻量化的特点,模型体积只有 9.2 MB,与 VGG-16 模型的 528 MB、VGG-19 模型的 549 MB、ResNet152 模型的 232 MB、InceptionResNetV2 模型的 215 MB 相比,笔者设计的深度模型更适合在存储空间和计算能力有限的嵌入式或移动设备上部署和使用.

## 4 结论

笔者提出了一种基于 MobileNetV2 模型和迁移学习策略的花卉图像识别方法,该方法能够获得良好的花卉识别精度,有效解决了将深度学习方法应用于花卉识别领域时面临的瓶颈问题,不再需要大规模的花卉图像训练样本、高性能的计算平台和很长的训练时间;同时,笔者构建的花卉识别模型更加轻量化,模型体积只有 9.2 MB,有利于在嵌入式或移动设备上部署,具有重要的应用价值.



### 参考文献:

[1] NILSBACK M E, ZISSERMAN A. Automated flower clas-

- sification over a large number of classes [ C ]. Bhuvaneshwar; the Sixth Indian Conference on Computer Vision, Graphics and Image Processing, 2008.
- [2] ANGELOVA A, ZHU S H. Efficient object detection and segmentation for fine-grained recognition [ C ]. Portland; the IEEE Conference on Computer Vision and Pattern Recognition, 2013.
- [3] LIU Y Y, TANG F, ZHOU D W, et al. Flower classification via convolutional neural network [ C ]. Shanghai; Proceedings of the IEEE International Conference on Functional-Structural Plant Growth Modeling, 2016.
- [4] QIN M, XI Y H, JIANG F. A new improved convolutional neural network flower image recognition model [ C ]. Xiamen; the IEEE Symposium Series on Computational Intelligence, 2019.
- [5] 吴迪, 刘秀磊, 侯凌燕, 等. 基于显著性检测和迁移学习的花卉图像分类 [ J ]. 北京信息科技大学学报(自然科学版), 2019(1).
- [6] SANDLER M, HOWARD A, ZHU M, et al. MobileNetV2: inverted residuals and linear bottlenecks [ C ]. Salt Lake City; the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 4510 – 4520.
- [7] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [ C ]. Las Vegas; the IEEE Conference on Computer Vision and Pattern Recognition, 2016.
- [8] 王军敏, 樊养余, 李祖贺. 基于深度卷积神经网络和迁移学习的纹理图像识别 [ J ]. 计算机辅助设计与图形学学报, 2022(5): 701 – 710.
- [9] 曹晓杰, 么娆, 严雨灵. 应用迁移学习的卷积神经网络花卉图像识别 [ J ]. 计算机应用与软件, 2020(8).

(责任编辑:王彦江)

## Study on Flower Recognition Based on Lightweight Model and Transfer Learning

WANG Junmin, LIN Hui

(School of Information Engineering, Pingdingshan University, Pingdingshan, Henan 467036, China)

**Abstract:** For the available flower recognition methods, there are such disadvantages as low recognition accuracy and large model volume. Thus, the paper proposes a flower recognition method based on lightweight model and transfer learning. Firstly, the MobileNetV2 model is used as the backbone network to build a lightweight flower recognition model, and then the transfer learning strategy is used to improve initial feature extraction ability. Finally, the small-scale flower image data set is used to train and fine-tune the model step by step, so that the model can obtain the best flower recognition ability. The experimental results show that the proposed flower recognition model achieves recognition accuracy of 97.76% on the flower image data set Oxford flower-102. The model volume is only 9.2 MB, which has the characteristics of high recognition accuracy and small size and is convenient for deployment and application on mobile devices.

**Key words:** flower recognition; transfer learning; deep learning; lightweight model

## 版权声明

本刊已被中国知网、万方数据知识服务平台、维普网、超星期刊、国家哲学社会科学文献中心收录,并通过其对外提供无偿或有偿信息服务. 作者文章著作权使用费与稿酬本刊一次性给付. 如作者不同意文章被收录,请在来稿时向本刊声明,本刊将做适当处理,否则将被视为同意我刊上述声明.