

刘嘉政. 基于深度迁移学习模型的花卉种类识别[J]. 江苏农业科学, 2019, 47(20): 231–236.

doi:10.15889/j.issn.1002-1302.2019.20.054

基于深度迁移学习模型的花卉种类识别

刘嘉政

(中国林业科学研究院资源信息研究所, 北京 100091)

摘要:为了解决传统花卉识别方法中特征提取主观性强、模型泛化能力差、错分率高的问题,提出一种基于 Inception_v3 的深度迁移学习模型的花卉图像识别方法。本研究对 5 种常见花卉图像进行识别分类,首先对原始图像进行预处理,通过对每张图像进行水平翻转、旋转操作,扩增数据集;其次,采用预训练完毕的 Inception_v3 模型,对其在 ImageNet 上训练好的网络参数进行迁移学习,对各个参数进行微调,并保留原模型的特征提取能力,并将原模型的全连接层替换为符合本研究要求的 5 分类 softmax 分类输出层,从而构建基于深度迁移学习的识别模型。对 5 种花卉共计 11 000 张图像进行训练和验证,平均识别正确率达到 93.73%,与传统的花卉识别方法相比,识别率得到提高,模型鲁棒性更强,具有一定的使用价值。

关键词:花卉种类;深度学习;迁移学习;识别分类

中图分类号: TP391.4 **文献标志码:** A **文章编号:** 1002-1302(2019)20-0231-05

花卉种类识别,一直是植物识别领域的热门话题之一。在国内,诸多学者在花卉种类识别的研究中,取得了一些进展。在传统方法上,吴笑鑫等采用 Grab Cut 分割算法,提取花卉图像特征,并将支持向量机(SVM)作为分类器,识别率达到 92.5%^[1];刘晶晶等通过提取牡丹纹理和形状特征,采用 BP 神经网络进行识别分类,提高了准确率和稳定性^[2];柯道等利用 Canny 算子对花卉雷同图片进行过滤分割,结合形状特征和纹理特征的边缘 LBP 算子,实现对花卉种类的识别^[3]。翟果等通过提取菊花的颜色、形状和纹理 3 个方面的特征,并以此建立特征模型,最后采用 KNN 算法对未知观赏菊品种进行分类识别,取得了理想的识别效果^[4]。但是,传统的花卉识别方法中,存在两大问题:(1)过分依赖人工提取特征,受到人的主观影响大,并且费时费力;(2)传统的方法只适合于小样本量的识别,对于海量图像数据,达不到识别要求。另外,由于花卉的种类繁多,花卉形态各式各样,目前而言,并没有一种普适性的方法能够识别所有花卉种类。

但随着理论知识和计算机技术的飞速发展,卷积神经网络在图像识别领域越来越受到欢迎。袁培森等以菊花为例,基于端到端的卷积神经网络对菊花花型和品种进行识别,并实现了移动端菊花识别系统,平均识别率达到 0.95 左右^[5];郭子琰等基于卷积神经网络模型,并选用 ReLu 激活函数代替传统的 Sigmoid 函数,取得了理想的识别效果^[6]。沈萍等基于多隐层的深度卷积神经网络,对 80 种常见花卉品种进行识别分类,识别率提高 10% 以上^[7];但是,以上都是针对相同场景的花卉图像识别,而且,面对海量数据,对于模型及计算机硬件要求都是极大的考验。因此,深度迁移学习方法可以较好地解决上述问题。刘德建等基于 LetNet 模型构建多层的花卉识别网络,识别效果良好^[8];王丽雯等将 AlexNet 模型进行迁移学习,对 Oxford 花卉种类进行识别,精度提升了

10%^[9];Oquab 等利用迁移卷积神经网络在 VOC2012 上取得了很大的成功^[10]。

因此,本研究提出基于 Inception_v3 模型^[11]的迁移学习的花卉识别方法。利用预训练的源模型,此方法的优点在于不需要模型源数据与本研究具体图像数据一致,只是将 Inception_v3 模型的自动提取特征的能力移植过来,保留低层的结构参数,并对相关参数进行微调,从而构建适合本研究花卉识别的神经网络。为了验证本研究模型的性能,与传统的支 持 向 量 机 (SVM) 做 比 较。试 验 结 果 表 明,本 研 究 提 出 的 方 法 识 别 正 确 率 较 传 统 方 法 来 说,有 了 明 显 的 提 高。

1 数据与方法

1.1 数据集

本研究所用到的图像来自于中国植物主题数据库,主要选取了雏菊、蒲公英、玫瑰花、向日葵和郁金香 5 种常见花卉作为识别对象。5 类花卉试验样本图像共采集 3 670 张,其中雏菊 633 张,蒲公英 898 张,玫瑰花 641 张,向日葵 699 张,郁金香 799 张。

为避免训练过拟合,对原始数据集进行扩增。通过 Python 脚本语言,将图片进行水平翻转、旋转 90°,对样本量进行扩增。此时,共得到 11 010 张,其中雏菊 1 899 张,蒲公英 2 694 张,玫瑰花 1 923 张,向日葵 2 097 张,郁金香 2 397 张。每类花卉随机选取 200 张图片作为验证集,剩余 10 010 张作为训练集。表 1 列出了具体的数据集数量。每类花卉示例见图 1。

表 1 5 种常见花卉图像数据集

花卉名称	训练集(张)	验证集(张)
雏菊	1 699	200
蒲公英	2 494	200
玫瑰花	1 723	200
向日葵	1 897	200
郁金香	2 197	200

收稿日期:2018-07-09

作者简介:刘嘉政(1993—),男,山东诸城人,硕士研究生,主要从事研究林业信息技术应用。E-mail:liujiazheng0919@163.com。



图1 5种花卉图像示例

1.2 试验方法

1.2.1 程序运行环境 本试验环境为 Windows 10 系统,处理器为 Intel(R) Core™ i7 - 6700 CPU @ 3.40 GHz 3.41 GHz,运行内存为 8.00 GB。本试验所有代码均在 Pycharm 代码平台、基于 TensorFlow 开源框架^[12]、采用 Python3 语言编写实现。

1.2.2 卷积神经网络 卷积神经网络(convolutional neural network,简称 CNN)^[13]结构有输入层、卷积层、池化层、全连接层、输出层。近年来,卷积神经网络之所以在图像识别领域发展迅速,得益于它的几大特点:(1)自主进行学习,自动提取特征,无需过多的人工干预;(2)多卷积结构层,增强特征提取能力;(3)利用反馈机制,能够自动更新、共享权值,不断

提高正确率。

1.2.3 深度迁移学习 迁移学习属于机器学习的一种方法,是将一个任务训练得到的模型移植到其他任务的训练上来^[14]。在大数据时代,要想训练深度学习模型,得到理想的结果,须要耗费巨大的资源,对计算机硬件也更高。因此,深度迁移学习就成为很受欢迎的方法。和传统的机器学习方法相比,深度迁移学习可以应用于多分类识别中,不需要训练多个模型,只需要直接应用到其他的任务中即可。图2为迁移学习和传统机器学习的比较。

1.2.4 Inception_v3 模型 Inception_v3 模型是基于 GoogleNet 卷积神经网络进行的改进。卷积神经网络(CNN)的卷积层结构通常选用单一且固定尺寸的卷积核,Inception_

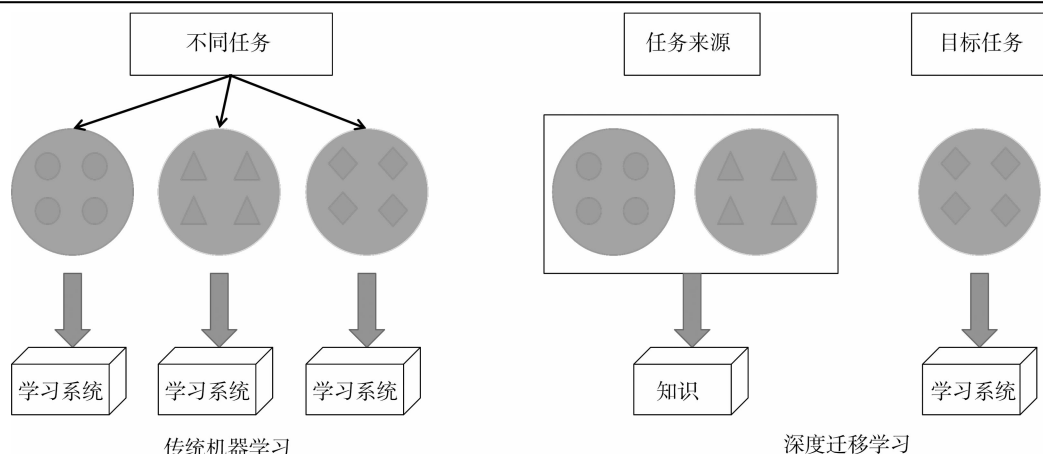


图2 传统机器学习与迁移学习

v3 模型在卷积层结构中尝试使用不同尺寸的卷积核,并且将尺寸较大的卷积核拆分成几个较小的卷积核。Inception_v3 模型的原数据集包含大约 120 万幅图像,1 000 多个种类,包含大约 2 500 万个结构参数。

1.2.5 模型构建 图 3 为本研究深度迁移学习模型的构建流程图。利用在 GoogleNet 上预先训练好的 Inception_v3 模型,将具有自动提取图像特征能力的卷积、池化层迁移到本研究的模型中。当输入 1 张花卉图像时,对该图像特征进行提取,并用 2048 维张量表示,并依次存入缓存文件中。本研究还对 Inception_v3 的全连接层、Dropout 层进行重新训练,对结构参数进行微调,以适应本研究要求。

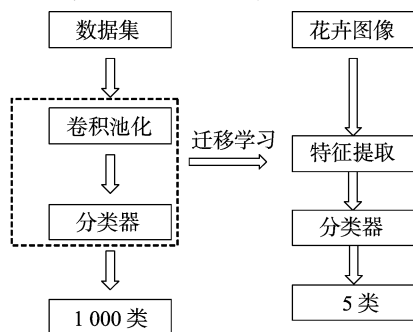


图3 花卉种类识别迁移学习模型

因此,根据试验具体要求,本研究提出花卉种类识别模型的网络结构参数设置见表 2。

表 2 本研究模型参数设置

结构参数	具体设置
池化方法	最大池化法、随机池化法
激励函数	修正线性单元
算法优化	学习率 = 0.010 0, 迭代次数 = 4 500, 随机梯度下降
损失函数	交叉熵函数

1.2.6 试验训练过程 本研究深度迁移学习过程分为 3 个阶段:(1) 初始化设置:对随机变换的图像与原始图像相结合,构成用于本研究训练的花卉图像数据库。基于预训练的 Inception_v3 模型自带的结构参数,将花卉数据库作为下一阶段模型训练的数据源;(2) 除了预训练模型和最后 1 层全连接层以外,要重新训练完整的全连接层,并将最后的全连接层

的结构参数作为下一阶段的特征提取输入源;(3) 最后 1 个阶段是对整个模型结构层数进行微调,以适应本研究要求。最后采用 Softmax 分类器,作为最后的分类输出层。

2 结果与分析

2.1 迭代次数对试验的影响

试验中,迭代次数初始设置为 1 000 次,每次试验迭代次数依次增加 1 000 次。当迭代次数达到 5 000 次时,识别正确率略有下降。此时将迭代次数减少,直到设置为 4 500 次时,识别正确率最高(图 4)。




图4 迭代次数对识别正确率的影响

2.2 学习率对试验的影响

当测试学习率对识别正确率的影响时,是在“2.1”节确定的最佳迭代次数的基础上进行的测试,测试结果见表 3。当学习率为 0.010 0 时,识别率达到 93.8%。

表 3 学习率对试验的影响

学习率	识别正确率 (%)
0.100 0	91.15
0.010 0	93.80
0.001 0	83.90
0.000 1	84.12

2.3 Dropout 层对试验的影响

在模型训练过程中,都会出现过拟合现象。所谓过拟合,具体表现为在模型识别率在训练集上效果好,测试集上效果差,这表明模型泛化能力弱,从而影响识别率。为防止训练过

拟合,除在数据处理时扩增数据集之外,本研究在模型中加入 Dropout 层。Dropout 策略是通过修改模型本身结构进行的一种防过拟合方法。试验中共运行程序 5 次,来测试 Dropout 层对试验的影响。测试结果见表 4。

表 4 Dropout 层对试验的影响

Dropout 层	正确率(%)					
	第 1 次	第 2 次	第 3 次	第 4 次	第 5 次	平均值
无	91.20	92.15	91.90	91.81	91.00	91.61
有	93.35	94.11	93.75	94.11	93.80	93.82

2.4 不同激励函数对试验的影响

在神经网络结构中,往往加入激励函数^[15],来保证网络输出的是非线性函数。常见的激励函数有 Sigmoid 函数、Tanh 函数、ReLU 函数。图 5 是采用不同激活函数对试验产生的结果。很明显,采用 ReLU 函数时,识别正确率最高。ReLU 激励函数^[16]为分段形式,使其前向、后向、导数的形式均为分段形式,更易于优化学习,从而解决模型收敛问题。




图5 激励函数对识别正确率的影响

2.5 特征图提取

为更加直观地了解训练过程中,神经网络对图像的特征提取情况,部分特征提取如图 6、图 7 所示。深度卷积神经网络,具有强大的自动提取特征功能,会依次提取图像低级乃至高级的抽象特征,人眼有时无法分辨出来。



图6 第 1 层卷积得到的特征




图7 最后 1 层全连接层得到的特征

2.6 识别结果

经过数据初始化、参数调整、训练模型,得到 accuracy 和

loss 迭代收敛结果(图 8、图 9)。当迭代次数达到 4 500 次时,准确率和损失值都接近收敛,数值不再有大的变化。




图8 准确率收敛




图9 损失值收敛

2.7 方法对比

为验证本研究方法的可行性,与传统的支 持 向 量 机 (SVM)、卷积神经网络(CNN)进行比较。对于 SVM 模型,通过提取全局特征和局部特征,对花卉图像进行识别,平均识别

率最低;对于 CNN 来说,平均识别率较高,达到 80% 以上;本研究提出的方法,对 5 种花卉图像的平均识别率达到 93.73%,比较结果见表 5。

表 5 提取方法比较

方法	分类识别率(%)					平均识别率(%)
	雏菊	蒲公英	玫瑰花	向日葵	郁金香	
SVM	50.61	47.58	45.69	54.25	54.27	50.48
CNN	82.52	81.25	84.19	80.11	81.24	81.86
本研究方法	94.25	95.14	92.21	93.17	93.89	93.73

3 结论与讨论

本研究提出一种基于深度迁移学习模型的花卉种类识别方法,构建了基于 Inception_v3 的花卉种类识别模型,实现了对雏菊、蒲公英、玫瑰花、向日葵、郁金香 5 种花卉的有效识别,平均识别率达到 93.73%。(1)基于迁移学习的花卉图像识别模型,对输入图像不用人工进行特征提取,只进行简单的类别标注即可,既节省了大量的人力和时间,又不用掌握过多的植物花卉方面的专业知识,提高了识别效率和精度。(2)本研究提出的方法,与传统的 SVM 方法相比,不仅识别率得到大大提高,而且更适合于处理海量数据,传统的方法仅仅适合对小样本数据集的处理。(3)本研究通过对原始图像进行随机旋转、水平翻转,扩增数据集,对模型结构权重参数进行微调,避免了过拟合现象的出现,且随着样本量的增加,模型泛化能力和鲁棒性都得到提高。

本研究用到的 5 种花卉的图像特征差别较明显,提出的模型对 5 种花卉种类有较理想的识别结果,但是否能应用到其他花卉种类识别,还有待进一步验证。同时,下一步的工作

是继续增加样本集种类和数量,改进网络结构,提高分类精度,使其应用性更强。

参考文献:

- [1] 吴笑鑫,高良,闫民,等. 基于多特征融合的花卉种类识别研究[J]. 北京林业大学学报,2017,39(4):86-93.
- [2] 刘晶晶,侯凌燕,杨大利. 牡丹花特征提取及识别技术研究[J]. 北京信息科技大学学报(自然科学版),2017,32(1):65-71.
- [3] 柯道,陈小芬,李绍滋. 基于多特征融合的花卉图像检索[J]. 计算机科学,2010,37(11):282-286.
- [4] 翟果,李志敏,路文超,等. 基于图像处理技术的观赏菊品种识别方法研究[J]. 中国农机化学报,2016,37(2):105-110,115.
- [5] 袁培森,黎薇,任守纲,等. 基于卷积神经网络的菊花花型和品种识别[J]. 农业工程学报,2018,34(5):152-158.
- [6] 郭子琰,舒心,刘常燕,等. 基于 ReLU 函数的卷积神经网络的花卉识别算法[J]. 计算机技术与发展,2018,28(5):154-157,163.
- [7] 沈萍,赵备. 基于深度学习模型的花卉种类识别[J]. 科技通报,2017,33(3):115-119.

欧阳爱国,邵 福,舒盛荣,等. 一种单轨悬挂式采茶机结构设计及通风管流场仿真分析[J]. 江苏农业科学,2019,47(20):236-240.
doi:10.15889/j.issn.1002-1302.2019.20.055

一种单轨悬挂式采茶机结构设计及通风管流场仿真分析

欧阳爱国,邵 福,舒盛荣,刘燕德,吴 建,曾祥文

(华东交通大学光机电技术及应用研究所,江西南昌 330013)

摘要:随着茶叶种植面积的不断扩大,收获机械化的实现变得越来越迫切。以单轨悬挂式采茶机械为基础,为改善茶园采茶机中茶叶在收集板上堆积的状况,提高剪切下来的茶叶到集叶袋的输送能力,根据流场动力学原理,对通风系统的结构进行流场仿真分析与优化设计。利用 FLUENT 软件对通风管内部流动进行仿真,得到了通风管内速度矢量图,揭示了其内部的流动情况,为采茶机通风管装置的进一步设计改进提供可靠的理论依据。

关键词:单轨悬挂式采茶机;通风管;流场仿真分析;优化设计

中图分类号: S225.99 **文献标志码:** A **文章编号:** 1002-1302(2019)20-0236-05

我国是茶文化大国,也是茶叶种植生产大国,茶区辽阔,气候多样,茶类品种繁多,栽茶历史悠久,形成了形状各异,许多地方品种,现有国家级认定的地方品种 30 个,省级认定(审)定的地方品种 29 个。全国现有 20 个产茶省,8 000 万以上茶农,2008 年全国茶园面积 171.96 万 hm^2 ,年产茶叶 125.96 万 t,产值超过 300 亿元。茶产业是集经济效益、社会效益和生态效益于一体的特色农业产业。茶叶是一种季节性和时效性要求较高的产品^[1]。如果不能在规定时间内之前完成茶叶采摘,那么就会对茶叶的品质产生重要的影响。因此,及时采摘茶叶尤为重要。研究发现,采茶工 1 d 8 h 约采摘 3 kg 茶叶。虽然茶叶的质量能够得到保证,但效率太低且成本太高。因此,收获机械化的实现变得越来越迫切;结合机械化手段,研究相关机械设备,提高茶叶采摘的效率,降低茶叶采摘的损耗极为必要^[2]。

国内对采茶机研究较少,尤其对采茶机通风管内部流场的研究较为薄弱,韩余等分析了往复式采茶机切割器的运动,并对往复式采茶切割器刚柔耦合进行了仿真,得到了刀片的动能、应变能、受力情况,同时得到了偏心轮轴承在旋转过程中的受力变化情况^[3]。王中玉等根据现阶段茶园管理的要求,设计出一种适用于茶园管理机全液压传动与控制的底盘,可以用于茶园中耕、施肥、喷药管理作业,操纵简单,达到一机多用的目的^[4]。余顺火等阐述抬式采茶及剪枝机所采用的小动力振动烈度的测定方法与分级的意见,并对如何减少振动进行了研究^[5]。韩余等设计了一种跨行自走式采茶机机架,该机架具有质量轻、地隙高、重心稳定等特点,运用有限元技术对采茶机机架进行了静力学与动力学特性分析,采茶机正常作业时,机架不会发生共振^[6]。

目前国内外尚未检索到基于 FLUENT 软件对采茶机通风管内部流场的相关研究报道。茶叶种植面积逐年递增,对茶叶采摘以及收集的效率有了较高的要求,通风管在茶叶收集过程中起着至关重要的作用。通风管的结构不合理会引起茶叶收集过程中出现因通风管堵塞而不能把茶叶吹向收集袋内等现象。基于这一问题,本研究针对丘陵山地设计了一种轨道悬挂式采茶机,采茶过程可以做到精确控制且无需人为操作,节省劳动力,同时可以根据不同的茶树需要控制不同的采茶高度,适应性好,应用范围广,提高了采茶的效率;利用

收稿日期:2018-07-05

基金项目:江西省协同创新专项基金(编号:赣财教指[2014]156号)。

作者简介:欧阳爱国(1968—),男,江西泰和人,教授,硕士生导师,研究方向为交通工具及设施安全检测。E-mail:ouoyang1968711@163.com。

通信作者:刘燕德,教授,博士生导师,研究方向为光电检测技术及智能化装置。Tel:(0791)87046173;E-mail:jxliuyd@163.com。

[8]刘德建. 基于 LeNet 的花卉识别方法[J]. 电子技术与软件工程, 2015(23):13-14.

[9]王丽雯. 基于 AlexNet 的 Oxford 花卉识别方法[J]. 科技视界, 2017(14):83.

[10]Oquab M,Bottou L,Laptev I,et al. Learning and transferring mid-level image representations using convolutional neural networks[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2014.

[11]Yosinski J,Clune J,Bengio Y,et al. How transferable are features in deep neural networks? [C]. Advances in Neural Information Processing Systems,2014.

[12]Wongsuphasawat K,Smilov D,Wexler J,et al. Visualizing dataflow graphs of deep learning models in tensorflow[J]. IEEE Transactions on Visualization and Computer Graphics,2017,24(1):1-12.

[13]周飞燕,金林鹏,董 军. 卷积神经网络研究综述[J]. 计算机学报,2017,40(6):1229-1251.

[14]王 惠. 迁移学习研究综述[J]. 电脑知识与技术,2017,13(32):203-205.

[15]张 彤,刘 志,庄新卿. 基于开发者平台和深度学习的智能识花与护花系统[J]. 工业控制计算机,2018,31(1):90-92.

[16]王双印,滕国文. 卷积神经网络中 ReLU 激活函数优化设计[J]. 信息通信,2018(1):42-43.