

基于轻量级深层卷积神经网络的花卉图像分类系统

徐光柱^{1,2}, 朱泽群¹, 尹思璐^{1,3}, 刘高飞¹, 雷帮军^{1,2}

(1. 三峡大学计算机与信息学院, 宜昌 443002; 2. 三峡大学水电工程智能视觉监测湖北省重点实验室, 宜昌 443002; 3. 国药葛洲坝中心医院信息中心, 宜昌 443002)

摘要:为解决深层卷积神经网络(Deep convolutional neural network, DCNN)模型在算力弱、存储成本高的AI边缘计算设备上难以高效应用的现实问题,本文利用重量级网络辅助训练轻量级网络,设计了一种基于轻量级神经网络的花卉图像分类系统。首先利用重量级DCNN并结合迁移学习、爬虫技术与最大连通区域分割方法,构建了适用于轻量级网络训练的扩充花卉数据集。然后基于Tiny-darknet与Darknet-reference两种网络及扩充后的花卉数据集训练得到两种面向弱算力设备的轻量级DCNN模型。训练得到的两种花卉分类网络在Oxford102花卉数据集上的平均分类准确率可达98.07%与98.83%,模型大小分别为4 MB与28 MB,在AI边缘计算设备中具有较好的应用前景。

关键词: 花卉图像分类; 深层卷积神经网络; 深度学习

中图分类号: TP391.41; TP183 **文献标志码:** A

Flower Image Classification System Based on Lightweight DCNN

XU Guangzhu^{1,2}, ZHU Zequn¹, YIN Silu^{1,3}, LIU Gaofei¹, LEI Bangjun^{1,2}

(1. College of Computer and Information Science, Three Gorges University, Yichang 443002, China; 2. Hubei Key Laboratory of Intelligent Vision Based Monitoring for Hydroelectric Engineering (Three Gorges University), Yichang 443002, China; 3. Information Center, Sinopharm Gezhouba Central Hospital, Yichang 443002, China)

Abstract: To solve the problem that deep convolutional neural network (DCNN) models with heavy weights are difficult to be effectively applied on AI edge devices with weak computing power and high storage costs, a flower image classification system equipped with a lightweight DCNN is proposed with the help of a heavyweight DCNN during training process. First, an extended flower data set suitable for lightweight DCNN training is constructed by using a heavyweight DCNN combined with transferring learning, the crawler technology and the maximum connected region segmentation method. Then, two lightweight DCNN models, Tiny-Darknet and Darknet-Reference, oriented for devices with weak computer power are trained based on the specially built flower image gallery. Experimental results show that the two optimized models obtained can achieve 98.07% and 98.83% average classification accuracy respectively on Oxford102 flower dataset while keeping the model size as 4 MB and 28 MB, which have promising application potentials for AI edge computer devices.

Key words: flower image classification; deep convolutional neural network; deep learning

引言

在农、林业发展中,花卉种类的快速准确鉴别具有重要的意义^[1]。传统的花卉识别方法易受到花卉形态多样性、背景环境复杂性及光照条件多变性的影响,其准确率与泛化性能有待提升。而深层卷积神经网络(Deep convolutional neural network, DCNN)在高速计算设备的辅助下可以自动学习视觉目标语义特征的特点,解决了复杂环境下的视觉目标的鲁棒性识别问题,在花卉识别应用中具有较大潜力。但在实际应用中,人们更希望能够利用便携式设备及时获得花卉的种类信息,从而在数据产生地点实时进行分析,以便于最有效地对花卉资源进行开发利用。因此在算力弱、存储成本高但是便于携带的AI边缘计算设备上高效运行DCNN花卉分类模型对于户外实时花卉识别具有重大的研究价值与意义。

目前,相关研究人员已构建出多种DCNN模型来进行花卉的识别,Prasad等^[2]提出一种新型的深度卷积神经网络,该网络使用4种不同尺寸的卷积核进行特征提取,在两层全连接层后应用Softmax回归函数进行分类,并结合随机池化技术,显著改善了花卉的分类准确率。吴迪等^[3]针对花卉分类任务对InceptionV3网络进行了适应性修改,将激活函数调整为在负值具有软饱和特性的Tanh-ReLu函数,利用迁移学习技术训练出了分类效果出众的网络权重,其分类准确率达到92.85%。Cibuk等^[4]将AlexNet^[5]和VGG16^[6]的混合模型应用于花卉的物种分类,以带有径向基函数(Radial basis function, RBF)核的支持向量机(Support vector machine, SVM)作为分类器。该方法在Oxford Flower17^[7]和Oxford Flower102^[8]的准确度分别达到96.39%和95.70%。Wu等^[9]构建了一个利用多GPU并行训练的深度学习系统,在分类任务上采用图像的多尺度训练,该方法结合了高分辨率图片中细节信息与低分辨率图片中的位置信息,从而提高了神经网络特征提取能力,在Oxford102数据集上取得了98.73%的平均准确率。

为了追求更好的分类效果,大多数的网络模型结构变得愈发庞杂。虽然相关任务准确率得到了提升,但通过加深网络来提高准确率会增加较大的参数量,导致网络的运算量增加,需要花费极大的运算资源,使得其难以应用到AI边缘计算设备上。为解决这一问题,研究者们通常使用模型压缩的方法^[10],即在已训练好的模型上进行参数的修剪或对其数据类型进行变换,进而使得网络权重参数的存储变得更加紧实,从而解决内存消耗与模型速度问题。相比于压缩模型权重而言,轻量级DCNN模型^[11]的优势主要在于构建出更加高效的卷积网络计算方式,在减少网络参数的同时兼顾良好的网络性能。Tian等^[12]通过改进的Tiny-darknet模型结合Softmax分类器,训练得到结构简单、参数少的轻量级花卉分类模型,实现了92%的准确率。相较于重量级网络而言,轻量级网络的预测时间、运算力需求以及模型储存占用量都得到了极大减少,使得该类网络更加适合于移动平台的应用。

目前花卉图像分类面临花卉类内差异大、大规模带标签数据集匮乏等问题,即使是重量级网络分类准确率也受到严重限制,轻量级模型下更难以达到理想的效果。而在重量级网络训练中,往往可以使用基于ImageNet的预训练权重进行迁移学习^[13],通过微调来改善数据集匮乏的问题;但对于轻量级网络,迁移学习有时并不是一个可行的解决方法。其主要原因在于该类网络较浅,而预训练模型前几层的特征与源目标任务联系仍紧密,难以迁移重用,虽然模型前3层是通用特征,具有普适性,理论上可迁移,但是需要重新利用ImageNet进行训练,还受到训练技巧的影响,严重增加训练成本。与重量级神经网络的庞大参数量不同,轻量级神经网络运用小巧的结构设计大幅度减少了参数量,因而对于新任务,从头开始训练出优良的网络成本将得到降低,但性能却无法得到保证。迁移学习的不可行性使得轻量级模型需要从头开始学习,而数据集的缺乏使得轻量级模型的准确率提升较为困难,导致目前轻量级网络虽然可以流畅地在边缘移动设备上运行,但是对于花卉分类的准确率却无法达到应用的需求。针对这一问题,本文利用重量级网络的优良性能,辅助训练来改善轻量级网络的准确率。

1 花卉分类系统组成

本文所设计的基于轻量级DCNN的花卉图像分类系统包括两个主要部分,如图1所示。一是数据集的构建,采用迁移学习的方法提升重量级花卉分类网络模型的准确率,并利用此重量级网络,结合图像最大连通区域分割方法得到适用于轻量级网络训练的扩充花卉数据集;二是轻量级分类系统的搭建,运用扩充花卉数据集来训练得到轻量级花卉分类网络,并将其部署于边缘计算设备。

1.1 重量级DCNN辅助下的花卉数据构建

为构建适应于轻量级模型的花卉数据集,首先运用迁移学习方法训练一种高精度的重量级花卉分类网络,然后采用图像最大连通区域分割方法得到花卉数据,利用训练好的高精度重量级花卉分类网络对分割后的花卉数据进行分类与筛选,得到新的扩充花卉数据集,其具体流程如图2所示。

1.1.1 重量级花卉分类模型构建

由牛津大学 Visual Geometry Group (VGG) 小组^[8]搜集整理的公开花卉数据集 Oxford102 应用广泛,总计 8 189 张共 102 类花卉图片,每种类别的数量大概在 40~258 张之间。其中 6 149 张图片用作训练集,1 020 张图片用作验证集,1 020 张图片用作测试集。图3给出了其中一部分样图。可以看出,各种花卉颜色与形态各异。

目前,常用图像分类方法均采用在超大规模图像集(如 ImageNet)上预先训练,然后迁移至目标数据集进一步学习实现网络参数微调的做法。这一方面是因为特定应用领域的数据集规模相对较小,无法保证深层神经网络模型的有效训练,易于产生过拟合现象;另一方面是因为底层图像特征提取方式具有共用性。但如前言所述,对于(超)轻量级网络,这种方式往往不奏效。因此,本文采用 Oxford102 公开花卉数据集并结合迁移学习的方法,构建高精度的重量级花卉分类网络模型,以便于后续对花卉数据进行筛选处理。权重的迁移分为冻结权重参数和微调权重参数两种,前者冻结所选层数中的所有权重参数,在训练过程中不进行改变,而后者在训练过程中对迁移的权重参数进行微调。在本实验中,选取的权重为可有效识别 ImageNet 中 1 000 类目标的权重参数,由于本任务着重于花卉的细粒度分类,因此需要采用微调形式,在训练过程中能够较好地克服数据间的差异,使其原有的权重更适应于本任务。

实验中所采用的花卉分类模型为 Darknet53 网络^[14],其具体结构如图4所示。该网络模型主要是由一系列的 1×1 和 3×3 的卷积层组成,每个卷积层后会连接一个批归一化(Batch normalization, BN)层和一个修正线性单元(Leaky ReLU)层。其中,大量使用的网中网(Network in Network)^[2],不仅有利

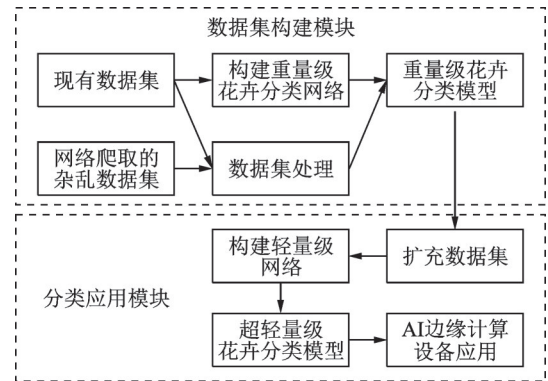


图1 轻量级花卉分类系统

Fig.1 Lightweight flower classification system

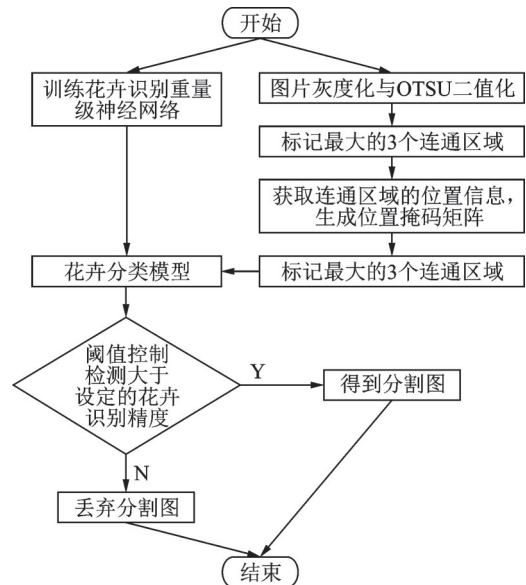


图2 花卉的分割与识别流程图

Fig.2 Flowchart of the flower segmentation and recognition



图3 Oxford102花卉数据集示例

Fig.3 An example of Oxford102 flower dataset

于加深网络结构,还增强了网络的非线性表达能力。

Darknet53 中第 1~74 层用于提取特征,为找到用于花卉分类的最佳迁移层,以快速连接层为分界,通过逐次测试迁移层数为前 $N(N=74, 68, 61, 36)$ 层时网络经过花卉数据集训练后的分类表现选择最佳迁移层数(图 5)。图中 W_i 表示第 i 层的权重矩阵, N 表示选择的迁移层数。

寻找到最佳迁移层后,提取出这些层的参数,并利用目标数据集 Oxford 对模型进行后续训练与参数微调,实现迁移学习,如图 6 所示。为了能够有效训练网络,本文通过实验确定了最佳的网络学习率、激活函数及迁移层的选取,以适应花卉分类要求,具体情况如下:

(1) 学习率

学习率的设定会对网络模型训练产生较大影响。梯度下降法是目前深度学习常采用的自适应优化算法,也叫一阶收敛算法,它是目前各种优化算法的核心基础,其中,初始学习率的设定决定了深层网络收敛的快慢与优劣。梯度下降法权重的更新公式如下

$$W := W - \alpha \frac{\partial}{\partial W} \text{loss}(W) \quad (1)$$

	类型	卷积核数目	卷积核尺寸	输出
	卷积层	32	3×3	256×256
	卷积层	64	3×3/2	128×128
1×	卷积层	32	1×1	128×128
	卷积层	64	3×3	
	残差层			
	卷积层	128	3×3/2	64×64
2×	卷积层	64	1×1	64×64
	卷积层	128	3×3	
	残差层			
	卷积层	256	3×3/2	32×32
8×	卷积层	128	1×1	32×32
	卷积层	256	3×3	
	残差层			
	卷积层	512	3×3/2	16×16
8×	卷积层	256	1×1	16×16
	卷积层	512	3×3	
	残差层			
	卷积层	1 024	3×3/2	8×8
4×	卷积层	512	1×1	8×8
	卷积层	1 024	3×3	
	残差层			
	平均池化层		全局	
	全连接层		1 000	
	Softmax			

图4 Darknet53结构图

Fig.4 Structure of Darknet53




图5 Darknet53在不同网络深度上的迁移学习示意图

Fig.5 Transferring learning illustration of Darknet53 under different network depths

式中： W 为权重， α 为学习率。过小的学习率会导致权重更新缓慢，降低优化效率，从而大大增加训练成本；过大的学习率会导致权重过大跨度更新从而错过最佳权值，陷入局部收敛，更严重的将导致损失不断上升。经对比研究发现，当初始学习率设定为0.1时，网络的分类准确率最好。

(2) 激活函数

激活函数在神经网络的非线性表达能力上发挥着重要作用，Sigmoid, Tanh, ReLu 及其改进版 Leaky ReLu 等都是目前深度学习中常用的几种激活函数，选用不同的激活函数对 Darknet53 网络性能的影响如图 7 所示。由结果可知，Leaky ReLu 最适合 Darknet53 网络，而相较于 Leaky ReLu，选用 Tanh 时网络平均损失降到 3 后快速发散。由此可见激活函数的选择对模型训练起着至关重要的作用。

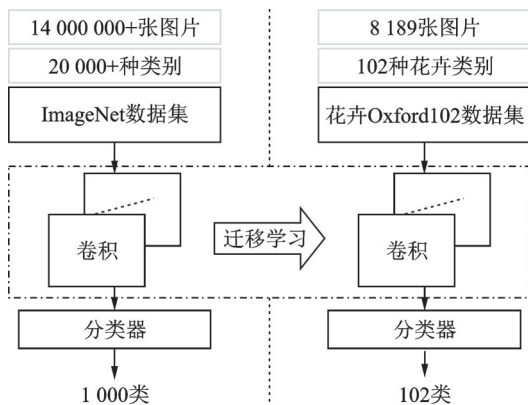


图6 面向花卉分类的Darknet53网络的迁移学习

Fig.6 Flower classification-oriented transferring learning for Darknet53 network




图7 激活函数对Darknet53网络训练的影响

Fig.7 Effect of different activation functions on Darknet53 network training

(3) 最佳迁移层

Darknet53 的 74 层及以下为网络的特征提取层，因此首先选择对 74 层以内的子模型进行迁移学习的应用，以快速连接层为分界，逐次测试前 74, 68, 61 及 36 层作为迁移层时 Darknet53 网络的花卉分类

表现,结果见表1。可以看出,迁移学习应用到Darknet53花卉分类网络的效果显著,且选取61层的权重进行迁移学习的效果达到最佳。而通过表中数据对比结果,可以发现当迁移层的选择从74层到61层时,分类准确率不断增加,而选择61层之后的网络权重时,准确率反而降低了,产生这一现象的原因是卷积神经网络特征提取的机制。在较浅的特征提取层中,卷积层专注于通用特征的提取,而到达较高的特征提取层时,网络学习到的是高级特征融合后的相关任务特定特征,因此,当采用61层权重进行迁移学习时,花卉分类网络充分利用了ImageNet上获得的大量通用基础特征,同时又避开了与花卉无关的高级特征干扰,达到最好的花卉分类效果。

1.1.2 花卉图像的分割与筛选方法

对于不能采用迁移层的(超)轻量级网络而言,需要更多的有效数据才能提升并达到接近重量级网络模型分类精度。而对于花卉数据的扩充,一般的方法是人为地进行收集高质量图像并将其归类到相应的花卉类别中。但是此方法不仅耗费工作量大,而且人类大脑对图像的感知与机器算法不尽相同,人眼分辨出的高质量花卉图像并不一定同样适应于机器算法,有时反而会因为存在过大的特征差异而降低深度学习模型的准确率。基于这种考虑,本文选择采用同为机器认知的重量级花卉分类网络来对花卉数据集进行辅助筛选,从而扩充轻量级网络的数据集,间接实现从重量级花卉分类网络到轻量级花卉分类网络的知识迁移,达到构建适用于轻量级网络训练的有效花卉数据集的目的。

为了获取更多的花卉图像,提升数据集规模,本文采用爬虫程序从Google搜索引擎上下载与Oxford102数据集上种类相应的102种花卉图片共计52 753张,花卉图像数据下载完毕后,采用图像最大连通区域分割方法并结合训练好的重量级花卉分类模型筛选整合得到新的花卉数据。

数据筛选时,先对图片进行灰度化操作,并对其使用高斯滤波以降低图像噪声;然后使OTSU算法^[15]确定阈值分离图片的前景区域与背景区域,分别将前景区域与背景区域像素设定为1和0,完成图片的二值化,如图8所示。

接着采用最大连通区域法标记出最大的3个连通区域,并将3个待选的连通域的位置信息提取出来,生成3个与原图像尺寸一致的掩码矩阵(图9)。接着,将掩码矩阵与原始图片相乘得到原始图片中对应区域的花卉目标,并通过外接最小矩形分割将花卉目标逐个提取出来,最终得到3个候选分割图(图10)。从图中

表1 权重固定层数对花卉分类的影响

Table 1 Influence of the weight-fixed layer number on flower classification

权重固定层数	平均分类准确率	平均训练损失率
74	0.981 0	0.034 3
68	0.994 4	0.011 2
61	0.995 2	0.008 3
36	0.994 4	0.010 0



图8 花卉图片的二值化

Fig.8 Binarization of flower picture




图9 掩码矩阵图

Fig.9 Mask matrix




图10 初步分割结果

Fig.10 Preliminary segmentation results

可以看到,分割结果 10(c)不是花卉图片,应该丢弃。最后,将候选分割图输入到训练完成的重量级神经网络中进行预测筛选,利用重量级网络的经验,辅助扩充轻量级网络的数据集,以此实现重量级网络到轻量级网络的间接知识迁移。通过比较设定的准确度,自动丢弃误分割的花卉图,完成数据集的扩充。

1.2 轻量级花卉分类网络

针对边缘计算设备计算力的限制问题,本文采用易于部署于嵌入式设备的 Darknet^[16]深度学习框架下的 Darknet-reference 和 Tiny-darknet 两种轻量级网络,网络结构如图 11 所示。

	类型	卷积核数量	尺寸	输出		类型	卷积核数量	尺寸	输出
	卷积	16	3×3	224×224		卷积	16	3×3	256×256
	最大池化		2×2/2	112×112		最大池化		2×2/2	128×128
	卷积	32	3×3	112×112		卷积	32	3×3	128×128
	最大池化		2×2/2	56×56		最大池化		2×2/2	64×64
2×	卷积	16	1×1	56×56		卷积	64	3×3	64×64
	卷积	128	3×3	56×56		最大池化		2×2/2	32×32
	最大池化		2×2/2	28×28		卷积	128	3×3	32×32
2×	卷积	32	1×1	28×28		最大池化		2×2/2	16×16
	卷积	256	3×3	28×28		卷积	256	3×3	16×16
	最大池化		2×2/2	14×14		最大池化		2×2/2	8×8
2×	卷积	64	1×1	14×14		卷积	512	3×3	8×8
	卷积	512	3×3	14×14		最大池化		2×2/2	4×4
	卷积	128	1×1	14×14		卷积	1 024	3×3	4×4
	卷积	102	1×1	14×14		平均池化			1 024
	平均池化			<i>N</i>		卷积	102	1×1	1×1
	Softmax			<i>N</i>		Softmax			<i>N</i>

(a) Tiny-darknet

(b) Darknet-Ref

图 11 Tiny-darknet 与 Darknet-Ref 网络结构对比图

Fig.11 Comparison of Tiny-darknet and Darknet-Ref network structures

Darknet-reference 模型包含 7 层特征提取网络(不含池化层),卷积核数目逐层成倍数增长,从第 1 层的 16 个增长到最后 1 层的 1 024 个,同时每一层的特征输出尺寸逐层成倍数减小,从第 1 层的 256×256 减小到最后 1 层的 4×4。

与 Darknet-reference 相比,轻量级的 Tiny-darknet 模型中 3×3 卷积核的数量只有 Darknet-reference 的 1/8。其借鉴 MobileNet^[13]网络中的深度可分解卷积结构,即 1×1 卷积与 3×3 卷积的交替重复,其中 3×3 的卷积用于滤波,而 1×1 的卷积用于转换通道。此结构相较于标准卷积大大减少了计算量与参数量,同时还有效保证了模型的性能。整个模型包含 21 层网络,输入的 224×224 尺寸图像经历 4 次最大池化,随着网络逐层增加,两种卷积核数目成倍增长,不断抽象出高层特征,最后输出 14×14 的特征图。

2 结果与分析

2.1 数据集及实验平台

实验所用硬件平台如表 2 所示。

表 2 实验软硬件平台

Table 2 Software and hardware platform for experiments

类别	重量级花卉分类网络构建	轻量级花卉分类网络构建	轻量级花卉分类网络应用
操作系统	Ubuntu16.04	Ubuntu16.04	iOS13
深度学习框架	Darknet	Darknet	Core ML
CPU	Intel(R)_Core(TM)_i7-7700K_CPU	Intel(R)_Core(TM)_i7-7700K_CPU	Cortex-A9
GPU	NVIDIA GeForce GTX 1080	NVIDIA GeForce GTX 1080	无

所用数据集为牛津大学 Visual Geometry Group (VGG) 小组贡献的公开的花卉数据集 Oxford102^[8], 如 1.1.1 节所述, 包含 102 类鸟类图片总计 8 189 张, 其中训练集 6 149 张, 验证集 1 020 张, 测试集 1 020 张。

2.2 花卉分类结果分析

2.2.1 扩充数据集质量验证

扩充后的数据集在数量上较 Oxford102 有明显的提升, 具体情况如图 12 所示。整个花卉图像的总量由 8 189 张扩充到了 20 554 张, 对于 Oxford102 中的 102 类花卉, 每类扩充了 2~4 倍, 其中, 最少的 Pink primrose (粉红色报春花) 类图片由 40 张增加到了 100 张, 最多的 Petunia (矮牵牛) 类由 258 张增加到了 644 张。

为验证扩充数据集对提升轻量级花卉分类模型性能的有效性, 将扩充后的数据集对 Tiny-darknet 与 Darknet-reference 网络模型进行训练, 分别统计两个模型中每一类花卉的准确率, 并与扩充前的准确率进行对比, 如图 13 所示。结果表明两个模型在使用扩充数据集训练后 102 类花卉的分类准确率都有较明显的提升, 其中 Tiny-darknet 模型对 sweet William (须苞石竹) 的分类准确率提升 68.18%; Darknet-reference 模型中最明显的是 Canterbury bells (风铃草) 类, 其准确率提升了 55.45%, 直接证明了扩充数据集的有效性。

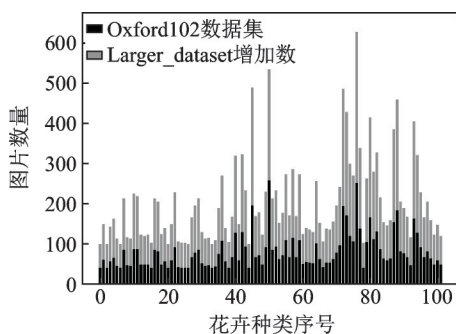


图 12 两个数据集的图片数量分布

Fig.12 Picture number distribution of two data sets

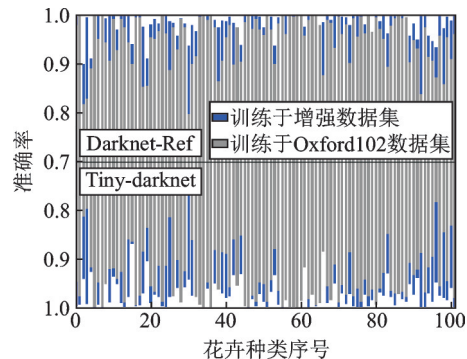


图 13 训练于两种数据集上的两种网络在 102 类花卉上的准确率

Fig.13 Accuracy of two networks trained on two data sets for 102 kinds of flowers

虽然在使用 darknet 框架用于模型训练的过程中, 框架本身就对原数据集和增广数据集进行了对比度、色相和饱和度调整, 对图片旋转角度、翻转图像等进行增广处理, 但是首先本文所采用的扩充方法指的是数据集物理扩充, 不是深度学习技术常用的一般概念的图像处理方式的增广, 所以本文方法与框架本身的一系列增广处理并不冲突; 其次, 数据一般的增广方式 (如翻转、镜像、加噪等) 都是在已有的数据基础上进行优化与增强, 模拟出不同环境与场景下的数据情况, 使得训练出来的模型适应于各

种环境,从而增强模型的泛化能力(图 14),此类增广方式并未从根本上增加真实花卉的数据量。而本文方法通过带有先验知识的重量级深度学习模型来有选择性地增加模型未见过的有效数据,在数据集扩充的同时,间接实现重量级网络对轻量级网络的知识迁移。此外,在验证准确率的过程中,使用的测试数据集都是原数据集中的 1 020 张测试图片,在相同的测试集上验证分类准确率的提升,结果更具说服力。

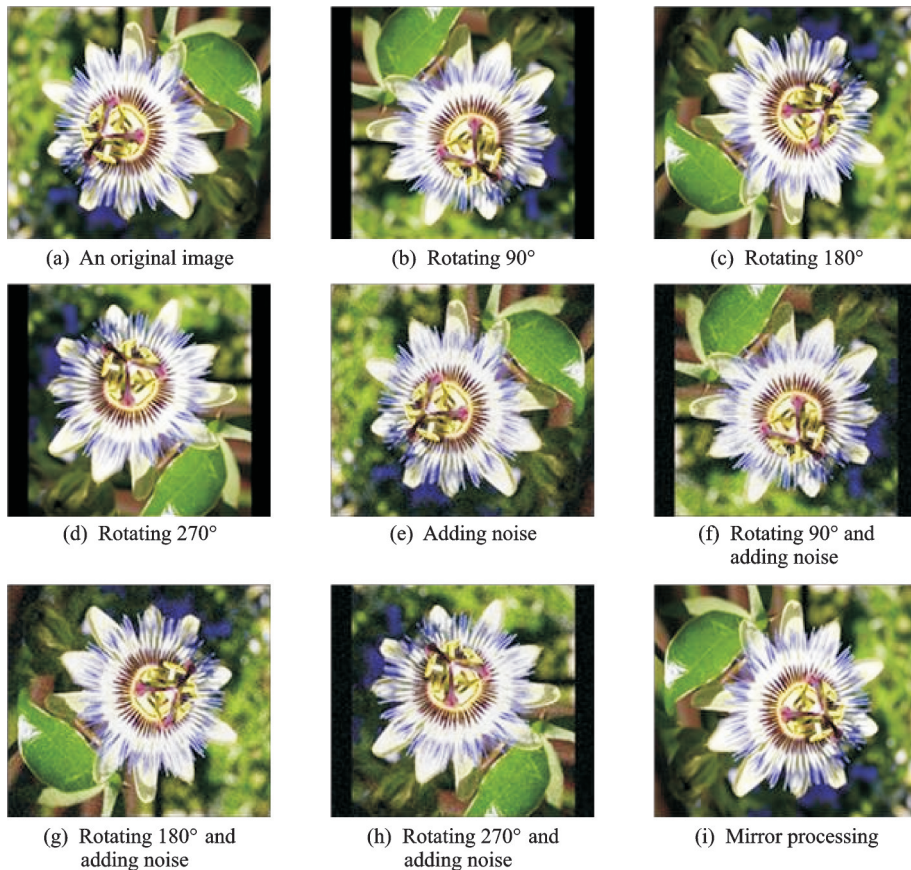


图 14 增广处理示意图

Fig.14 Illustration of the augmented processing

为了进一步验证扩充数据集的质量,统计了扩充数据集下两模型的 Top1 准确率,并与原数据集下的 Top1 准确率做了对比,如表 3 所示。从对比结果可看出,扩充数据集对应的训练结果相较于扩充前而言,具有更高的分类准确率,轻量级网络 Tiny-darknet 与 Darknet-reference 性能提升明显。

表 3 扩充前后两种网络的分类准确率对比

Table 3 Comparison of classification accuracy of networks trained with different data sets

模型	训练数据集	训练时间/min	Top1 平均准确率/%	准确率方差/%
Darknet-reference	扩充后的数据集	123.40	98.83	0.341
	原数据集	44.51	97.41	0.773
Tiny-darknet	扩充后的数据集	119.50	98.07	0.267
	原数据集	43.00	94.79	0.682

2.2.2 Tiny-darknet与Darknet-reference其他性能分析

为了评估两个轻量级网络的其他性能,本文将扩充后的20 554张图片对其进行训练,所用参数设置如表4所示。数据集中17 525张图片用于训练,2 009张图片作为验证集,Oxford102中的原测试集1 020张图片用于测试。

表4 训练参数设置值

Table 4 Training parameter setting value

训练参数	设置值
激活函数	Leaky ReLu
梯度下降算法	初始学习率为0.01,动量为0.9,迭代次数为30 000次
分类器函数	Softmax函数

两模型的训练损失曲线如图15所示,可以看出,Darknet-reference初始平均损失远高于Tiny-darknet,但是迭代到5 000次之前,损失下降速度远快于Tiny-darknet。在迭代到25 000次时,两模型平均损失率降低至最低点,达到一致水平。由于Darknet-reference参数更多,权重文件大,导致其初始平均损失高于Tiny-darknet,但是其网络层数和计算量却低于Tiny-darknet,更少的网络层数和计算量,使其拥有更快的收敛速度。虽然训练前期有所差别,但在整个过程中,Darknet-reference训练成本与Tiny-darknet没有很大区别。




图15 两种网络在扩充数据集上的训练损失
Fig.15 Training losses of the two networks on the enhanced data set

预测时,两种网络的性能指标对比如表5所示。可以看出,虽然Darknet-reference的准确率更高一些,但其权重大小是Tiny-darknet的7倍,计算时间也高出15.6%。两者均为轻量级模型,但相对于Darknet-reference,Tiny-darknet更加轻量级,但准确率也低一些,在应用时可根据实际需求与平台情况选择使用。Tiny-darknet有21层,计算量高于具有7层网络结构的Darknet-reference,但是其采用 1×1 卷积与 3×3 卷积的交替重复的深度可分解卷积结构,大大减少了模型尺寸与权重文件所占内存。虽然Tiny-darknet计算量更多,但是每秒浮点运算次数(FLOPs)作为评判模型的间接指标,不能作为衡量模型速度的评价标准,在模型运行过程中,内存访问成本与并行度也会对速度造成较大影响,Tiny-darknet的计算量基本集中在 1×1 卷积上,其计算过程不需要 3×3 卷积过程内存重组,底层能够更快地实现,而Darknet-reference完全采用 3×3 卷积,其内存访问成本远高于Tiny-darknet,所以Tiny-darknet拥有更快的检测速度。

表5 不同网络在花卉测试集上的表现

Table 5 Performance of different networks on the flower test set

模型	平均准确率/%	预测时间/ms	FLOPs/ 10^3	权重/MB
Darknet-Ref	98.83	126.9	81	25.6
Tiny-darknet	98.07	109.8	98	3.7

为验证所提出的花卉分类解决方案的有效性,将所训练的Tiny-darknet和Darknet-reference两种模型与其他模型在同一测试集下的分类结果进行了对比。模型的准确率、尺寸与计算量如表6所示。从网络的尺寸对比可以发现,杨固亮等^[17]、Cibuk等^[4]、Ge等^[18]、Hiary等^[19]和Prasad等^[2]均采用重量级网

络模型, Tian^[12]等虽然也采用轻量级模型(4 MB),但准确率较低。整体来看, Tiny-darknet和 Darknet-reference相比于其他网络具有较为明显优势。虽然,本文所用的网络训练时采用了扩充的数据集,但其他重量级网络也通过 ImageNet等超大规模数据集获得的迁移层;另外,评测所用测试集是一样的。因此认为这种比较在一定程度上还是具有说服力的,能够说明本文所设计的花卉分类系统的有效性。

此外,本文还采用非 Oxford 数据集中的花卉图像来验证模型的泛化能力,分别使用扩充前后训练的两种轻量级模型对采集的 10 张花卉数据进行测试,如表 7 所示的结果显示使用扩充后数据集训练的两模型准确性皆有提升。其中在面对背景画面大、花卉本体只占有一部分区域的图像时,由于背景区域的影响,轻量级模型检测结果偏低,但是使用扩充数据集训练后,检测结果仍有明显提升。

表 6 模型的准确率、尺寸与计算量对比











Table 6 Comparison of model accuracy, size and calculation amount

模型	准确率/ %	尺寸/ MB	FLOPs/10 ³
Yang ^[17]	85.75	>200	720
Musa ^[4]	95.70	>700	16 200
Tian ^[12]	92.00	4	98
Ge ^[18]	97.00	~50	2 000
Hiary ^[19]	97.10	90~100	5 000
Prasad ^[2]	97.78	>150	550
Tiny-darknet	98.07	4	98
Darknet-reference	98.83	28	81

表 7 数据集扩充前后两种网络的实际测试结果

Table 7 Actual test results of two networks before and after dataset expansion

%

花卉种类					
	Sweet pea	Moon orchid	Monkshood	Globe thistle	Fire lily
扩充前-tiny	82.45	63.36	58.20	81.28	66.92
扩充后-tiny	99.50	72.48	82.68	96.36	77.85
扩充前-reference	92.41	85.01	71.86	97.70	95.31
扩充后-reference	99.98	94.54	83.27	99.12	98.85
花卉种类					
	Wild pansy	Sunflower	Bishop of llandaff	Thorn apple	Ball moss
扩充前-tiny	93.96	93.56	98.77	98.81	99.58
扩充后-tiny	98.86	99.66	99.85	99.90	99.98
扩充前-reference	99.77	99.99	99.45	96.25	96.14
扩充后-reference	99.96	99.99	99.99	99.79	99.99

为验证本系统在 AI 边缘计算设备上的有效性,首先在运行 iOS 平台的移动设备上评估了两模型的实际预测性能。所用实验平台采用苹果 A11(64 位六核)处理器,2 GB 内存,在 224×224 输入下,Darknet-reference 花卉分类模型预测时间(不包括加载模型时间)约为 200 ms,而 Tiny-darknet 约为 160 ms,

能够满足实际应用需要。随后在其他的常见嵌入式设备上对两模型的实际预测性能进行测试,各嵌入式设备的参数以及其模型实际推理速度如表8所示,对比结果证明两模型在iOS及其他主流的嵌入式设备上均能满足实际应用的需求。

表8 不同嵌入式设备上性能对比

Table 8 Performance comparison on different embedded devices

类别	Raspbian 3B+ NCS2	NVIDIA Jetson TX2	Android	iOS
CPU	1.4 GHz 64位4核 ARM Cortex-A53	HMP Dual Denver 2/2 MB L2 + Quad ARM A57/2 MB L2	骁龙™ 8X74AC 801 处理器 主频 2.5 GHz	Cortex-A9
图像处理加速单元	Neural Compute Stick 2	NVIDIA Pascal™, 256个CUDA 核心		
Tiny耗时/ms	41.8	28.6	83.6	160.0
Reference耗时/ms	52.06	35.62	104.12	200.00

3 结束语

本文针对AI边缘计算设备上轻量级神经网络模型在花卉图像分类任务上准确率不足的问题,设计了一种面向弱算力设备的基于轻量级DCNN的花卉图像分类系统。首先,通过Darknet53与迁移学习构建高准确率的重量级花卉分类网络,然后利用此网络结合爬虫技术与图像最大连通区域分割法辅助构建适用于轻量级网络的有效数据集。随后,在两个不同规模的数据集上对基于Darknet深度学习框架的两种轻量级深度神经网络进行了训练验证,同时将本方法得到的轻量级花卉分类模型部署到iOS移动设备上验证,并进一步通过其他的常见嵌入式设备对两种模型的实际预测性能进行测试。结果显示本文方法处理后的扩充数据集对轻量级网络的性能有明显提升,本文方法训练的两种模型在Oxford102花卉数据集上达到了98.07%和98.83%的平均分类准确率,同时在扩展的环境下检测也能取得不错的检测效果,模型大小分别为4 MB和28 MB,在iOS移动设备及其他主流的嵌入式设备上推理的速度均能够满足实际应用需要,具有良好的应用前景。虽然本文方法在AI边缘计算设备上处理花卉目标占比较大比例的花卉图像分类问题上具有较好的效果,但面对背景画面大且花卉本体只占有一小部分区域的图像情况,由于花卉区域所占全图比例小,使得分类网络容易将非花卉区域的特征识别成花卉特征,造成误检。未来可以将分类网络进一步扩充,通过分割网络将目标与背景区域分离,利用目标分割图进行分类训练来祛除背景区域对分类性能的影响,并采用提取出来的目标计算标注区域并整合到一个大背景下形成密集目标数据集,再结合目标检测网络做进一步的研究,实现花卉的检测与识别。

参考文献:


- [1] 齐博. 中国花卉产业国际竞争力研究[D]. 北京:中国农业科学院, 2015.
QI Bo. Research on international competitiveness of Chinese flower industry[D]. Beijing: Chinese Academy of Agricultural Sciences, 2015.
- [2] PRASAD M V D, PRASAD R, INTHIYAZ S, et al. An efficient classification of flower images with convolutional neural networks[J]. International Journal of Engineering & Technology, 2017, 7(1): 384-391.
- [3] 吴迪, 侯凌燕, 刘秀磊, 等. 一种改进的深度学习的花卉图像分类[J]. 河南大学学报:自然科学版, 2019, 49(2): 192-203.
WU Di, HOU Lingyan, LIU Xiulei, et al. An improved deep neural network for floral image classification[J]. Journal of Henan University: Natural Science, 2019, 49(2): 192-203.
- [4] CIBUK M, BUDAK U, YAN H G, et al. Efficient deep features selections and classification for flower species recognition[J]. Measurement, 2019, 137: 7-13.

- [5] KRIZHEVSKY A, SUTSKEVER I, HINTON G. ImageNet classification with deep convolutional neural networks[J]. *Advances in Neural Information Processing Systems*, 2012, 25(2): 84-90.
- [6] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[EB/OL].(2014-09-4)[2021-7-12]. <https://arxiv.org/abs/1409.1556>.
- [7] NILSBACK M E, ZISSERMAN A. A visual vocabulary for flower classification[C]//*Proceedings of 2006 Conference on Computer Vision and Pattern Recognition*. [S.l.]: IEEE, 2006, 2: 1447-1454.
- [8] NILSBACK M E, ZISSERMAN A. Automated flower classification over a large number of classes[C]//*Proceedings of ICVGIP*. Bhubaneswar, India: Institute of Electrical and Electronics Engineers, 2008: 722-729.
- [9] WU R, YAN S, SHAN Y, et al. Deep image: Scaling up image recognition[EB/OL]. (2015-01-13)[2021-07-12]. <https://arxiv.org/abs/1501.02876v5>.
- [10] CHENG J, WANG P S, GANG L I, et al. Recent advances in efficient computation of deep convolutional neural networks[J]. *Frontiers of Information Technology & Electronic Engineering*, 2018, 19(1): 64-77.
- [11] 胡挺, 祝永新, 田犁, 等. 面向移动平台的轻量级卷积神经网络架构[J]. *计算机工程*, 2019, 45(1): 17-22.
HU Ting, ZHU Yongxin, TIAN Li, et al. A lightweight convolutional neural network architecture for mobile platforms[J]. *Computer Engineering*, 2019, 45(1): 17-22.
- [12] TIAN M, CHEN H, WANG Q. Flower identification based on deep learning[J]. *Journal of Physics: Conference Series*, 2019, 1237: 022060.
- [13] KORNBLITH S, SHLENS J, LE Q V. Do better imagenet models transfer better?[EB/OL].(2018-5-23)[2019-6-17]. <https://arxiv.org/abs/1805.08974>.
- [14] REDMON J, FARHADI A. YOLOv3: An incremental improvement[EB/OL].(2018-4-8)[2021-7-12]. <https://arxiv.org/abs/1804.02767>.
- [15] OTSU N. A threshold selection method from gray-level histograms[J]. *IEEE Transactions on Systems Man & Cybernetics*, 2007, 9(1): 62-66.
- [16] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Los Alamitos, USA: IEEE Computer Society Press, 2016: 779-788.
- [17] 杨国亮, 王志元, 张雨. 一种改进的深度卷积神经网络的精细图像分类[J]. *江西师范大学学报(自然科学版)*, 2017, 41(5): 476-483.
YANG Guoliang, WANG Zhiyuan, ZHANG Yu. An improved deep convolutional neural network for fine image classification [J]. *Journal of Jiangxi Normal University (Natural Science edition)*, 2017, 41(5): 476-483.
- [18] GE W, YU Y. Borrowing treasures from the wealthy: Deep transfer learning through selective joint fine-tuning[C]//*Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*. Hawaii, USA: IEEE, 2017: 2102-2113.
- [19] HIARY H, SAADEH H, SAADEH M, et al. Flower classification using deep convolutional neural networks[J]. *IET Computer Vision*, 2018, 12(6): 855-862.

作者简介:



徐光柱(1979-),男,博士,教授,研究方向:图像处理、人工智能、模式识别,E-mail: xgz@ctgu.edu.cn。



朱泽群(1994-),男,硕士研究生,研究方向:深度学习、神经网络,E-mail:1152966090@qq.com。



尹思璐(1990-),男,硕士,研究方向:深度学习、神经网络,E-mail: kandade@163.com。



刘高飞(1997-),男,硕士研究生,研究方向:深度学习、图像处理,E-mail:924774948@qq.com。



雷帮军(1973-),通信作者,男,博士,教授,研究方向:计算机视觉、机器学习,E-mail: bangjun.lei@ieee.org。