

引用格式:李鹏,蒋品群,曾上游,等.基于分组残差结构的轻量级卷积神经网络设计[J].微电子学与计算机,2019,36(7):43-47. [LI P, JIANG P Q, ZENG S Y, et al. Design of lightweight convolution neural network based on group residual structure [J]. Microelectronics & Computer, 2019, 36(7): 43-47.]

基于分组残差结构的轻量级卷积神经网络设计

李 鹏,蒋品群,曾上游,夏海英,廖志贤,范 瑞
(广西师范大学 电子工程学院,广西 桂林 541004)

摘 要: 针对传统深度卷积神经网络参数数量过多,很难在移动设备上应用的问题,提出基于分组残差结构的轻量级卷积神经网络架构 GResNets. 利用三个卷积层的瓶颈结构将上层输出特征图分为数量相等的四组,根据组内的瓶颈模块加入恒等映射的方式和组外相邻模块是否加入残差学习,设计了三种轻量级卷积神经网络架构. 试验阶段,在 Caltech-256, Food-101 和 GTSRB 图像分类数据集上评测了三种网络架构的性能. 实验结果表明,与传统深度卷积神经网络相比, GResNets 能在网络参数较少的情况下,具有同样、甚至更优越的分类性能,适合在移动设备上应用.

关键词: 卷积神经网络; 分组; 残差; 分类性能; 轻量

中图分类号: TP391. 4

文献标识码: A

文章编号: 1000—7180(2019)07—0043—05

Design of lightweight convolution neural network based on group residual structure

LI Peng, JIANG Pin-qun, ZENG Shang-you, XIA Hai-Ying, LIAO Zhi-xian, FAN Rui

(College of Electronic Engineering, Guangxi Normal University, Guilin 41004, China)

Abstract: In order to solve the problem that the parameters of traditional deep convolution neural network are too large to be used in mobile devices, a lightweight convolution neural network architecture GResNets based on group residual structure is proposed. Using the bottleneck structure with three convolution layers, the output feature maps of the previous layer are divided into four equal groups. Three lightweight convolution neural network architectures are designed according to the way of adding identical mapping to the bottleneck module in the group and whether or not the adjacent module outside the group joins residual learning. In the experimental stage, the performance of the three network architectures was evaluated on three image recognition datasets, Caltech-256, Food-101 and GTSRB. The experimental results show that GResNets has the same or even better classification performance than traditional deep convolution neural networks under the condition of fewer network parameters, and is suitable for mobile devices.

Key words: convolution neural network; group; residual; classification performance; lightweight

1 引言

自 2012 年 AlexNet^[1] 在 LSVRC 比赛中崭露头角以来,卷积神经网络(Convolutional Neural Net-

works, CNN)在图像分类^[2]、目标检测、语义分割等领域取得了巨大的成功. 为了提高网络模型的准确率,研究人员不断地加深卷积网络的层数,相继提出了各种各样性能更加优越的卷积神经网络. 虽然这

些网络的准确率都比较高,但是大多都是建立在层次较深、模型复杂、参数数量庞大的情况下,其运行所需要的计算资源和存储资源也比较多,不利于网络移植到计算资源和存储资源都十分有限的移动设备.因此,一些研究人员提出了一些轻量级卷积神经网络^[3-6].受以上工作的启发,本文提出基于分组残差结构的轻量级卷积神经网络架构 GResNets.

2 基于分组残差结构的轻量级卷积神经网络设计

2.1 分组瓶颈结构

瓶颈结构(Bottleneck)的思想来源于 1×1 的卷积,目的是减少网络参数.图1给出了标准卷积和改进后的瓶颈结构示意图.从图中可以看出,假设输入输出特征图数量 $N=128$,标准卷积层参数量 $P=128\times 3\times 3\times 128=147\ 456$,瓶颈结构卷积层参数量 $P=128\times 1\times 1\times 32+32\times 3\times 3\times 32+32\times 1\times 1\times 128=17\ 408$.通过瓶颈结构可以将标准卷积层参数量减少到原来的近九分之一.由于瓶颈结构加深了网络深度,使得网络非线性表达能力更强,进一步提升网络准确率.文献[6]指出要提高网络准确率,增加基数比增加深度和宽度更有效,所谓基数就是平行堆叠某个模块的个数.受此启发,本节通过瓶颈结构的第一个 1×1 卷积核将上层输出分为四组,如图2所示.图2中四组的特征图数量均保持一致,每组的第一个 1×1 卷积用来降维,第三个 1×1 卷积用来升维,并行输出通过级联的方式整合在一起.当多个分组瓶颈结构进行堆叠,每组的第一个 1×1 卷积核对各分组信息进行跨通道融合.




图1 标准卷积与瓶颈结构

2.2 残差结构

卷积神经网络通过不断学习来更新网络的参数,从而得到输入与输出之间的映射关系,但是当网络层次较深时,这个映射关系不容易优化,网络会出现退化的问题.若在输入与输出之间添加一个恒等映射(Identity Mapping)来学习输入数据与




图2 分组瓶颈结构

输出数据之间的残差,可以解决深层网络训练困难的问题.具体做法分两种,一种是当输入与输出维度相等时,在输入与输出之间添加一个短接线;一种是输入输出维度不相等时,使用线性投影方式来匹配维度.由此,图1的瓶颈结构加入残差连接后如图3所示.




图3 残差结构

图3中若 x 为输入,经三个卷积层运算后输出为 $F(x, W_i)$,卷积层后加入归一化BN层,激活函数采用ReLU,残差结构的输出 y 定义为式(1):

$$\begin{cases} y = F(x, W_i) + x & m = n \\ y = F(x, W_i) + W_s x & m \neq n \end{cases} \quad (1)$$

式中, W_i 为第 i 个卷积层学习的权重参数, m 为输入特征图数量, n 为输出特征图数量, $W_s x$ 是利用 1×1 卷积核实现的线性投影.

2.3 分组残差结构

基于分组瓶颈结构和残差结构,在给定的准确率水平下,设计一种轻量级的网络架构是可能的.本节在保证网络参数较少的条件下,根据2.1节和2.2节的描述设计了三种分组残差结构.第一种网络模块示意图如图4所示.主要是对图2中每两组添加经线性变换后的恒等映射,即G1和G2、G3和G4分别共用一个线性投影,称为GResNet1.第二种是在每组瓶颈结构中均加入线性投影,如图5所示.目




图 4 GResNet1 模块示意图

的是与 GResNet1 进行对比,网络参数也较前者有所增加,称为 GResNet2. 第三种是在 GResNet2 基础上改进,在组外输入输出维度相等的相邻模块加

入残差连接,如图 6 所示,称为 GResNet3. 这样做本质上等价于组内的瓶颈结构通过残差学习与组外模块继续进行残差学习,方便网络的信息传输与优化.




图 5 GResNet2 模块示意图




图 6 GResNet3 网络整体架构

借鉴 SqueezeNet 网络的设计思想,模块化的方式使得网络的扩展性更好,用图 4 和图 5 的模块替换图 6 的 Block 可完成 GResNet1 和 GResNet2 的设计. GResNets 的基本网络参数设置如表 1 所示. 通过堆叠 Block 模块以及在模块中间穿插多个池化层而形成,池化层的操作采用 Max-Ave-Ave-Ave (Max 指最大值池化,Ave 指平均池化.)架构,括号中是瓶颈结构的三个卷积层参数,G=4 表示输入分为四组,网络架构清晰明了,易于扩展.

表 1 GResNets 网络的基本参数设置

操作类型	卷积核大小/ 步长/pad/数量	深度	输出维度
Input	—	—	227×227×3
Conv1	7×7/2/0/96	1	111×111×96
Conv2	5×5/2/2/128	1	56×56×128
MaxPool2	3×3/2/0	1	28×28×128
Block	$\begin{bmatrix} 1\times1/1/0/8 \\ 3\times3/1/1/8 \\ 1\times1/1/0/32 \end{bmatrix}, G=4$	3	28×28×128
AvePool5	2×2/2/0	1	14×14×128
Block	$\begin{bmatrix} 1\times1/1/0/16 \\ 3\times3/1/1/16 \\ 1\times1/1/0/64 \end{bmatrix}, G=4$	3	14×14×256
AvePool8	2×2/2/0	1	7×7×256
Block	$\begin{bmatrix} 1\times1/1/0/32 \\ 3\times3/1/1/32 \\ 1\times1/1/0/128 \end{bmatrix}, G=4$	3	7×7×512
AvePool11	3×3/2/0	1	3×3×512
FC	—	1	256/101/43

3 实验

3.1 实验设置

数据集: 实验在 Caltech-256, Food-101 和 GTSRB 三个数据集上进行. Caltech-256 包含 256 个类别共29 781张图片,原数据集未划分训练集和测试集,其识别难度也比较大. 本文按 4:1 的比例将其分为训练集23 919张图片 and 测试集5 862张图片. Food-101 包含 101 种食物共101 000张图片,每类食物有1 000张图片,750 张作为训练图片,250 张作为测试图片,共75 750张训练图片和25 250张测试图片. GTSRB 包含 43 类德国交通标志共51 839张图片,分为训练集39 209张图片,测试集12 630张图片. 在图像识别方面的研究,这三个数据集的使用比较广泛.

图像预处理: 主要包括尺度归一化、数据增强和去均值三个操作. 尺度归一化操作是将三个数据集的所有图片尺寸缩放到 256×256 大小. 为了提高网络泛化能力和防止过拟合,训练时对图片使用数据增强操作,具体做法是从每张图片的 5 个方位(左上角,左下角,右上角,右下角以及中间方位)随机裁剪得到 227×227 大小像素的图像块,再加上水平翻转可以将数据扩大为原来的 10 倍. 值得注意的是, GTSRB 交通标志数据中个别交通标志翻转后不符合实际,这里不进行水平翻转操作.

实验环境:实验所依赖的深度学习框架为 Caffe^[7],计算机配置为 i7-6700K 四核 CPU、Ubuntu14.04 Linux 操作系统、32GB 内存以及 NVIDIA-GTX 1070 GPU.

网络训练参数设置:实验在 Caltech-256 数据集上训练时,solver 文件配置为:初始学习率为 0.01,学习率变化方式为 multistep,gamma 为 0.1,学习率每 24 000 次迭代衰减一次,共衰减两次,最大迭代 70 000 次,每训练 500 次测试一次网络性能.同样的在 Food-101 和 GTSRB 数据上实验时,训练参数基本保持一致,只是初始学习率为 0.005,在 Food-101 上每 40 000 次迭代衰减一次,共衰减三次,最大迭代 150 000 次.在 GTSRB 上学习率每 24 000 次迭代衰减一次,共衰减两次,最大迭代 60 000 次.

3.2 实验结果及分析

实验在上述三个数据集上对所设计的三种网络模型进行评测.表 2、表 3 和表 4 分别给出了在 Caltech-256、Food-101 和 GTSRB 上三种网络性能对比.

表 2 各模型在 Caltech-256 上的性能

网络模型	参数数量 /M	识别精度 /%	训练时间 /min	模型大小 /M
GResNet1	2.38	57.21	302	9.6
GResNet2	2.82	58.44	327	11.4
GResNet3	2.82	59.28	330	11.4

表 3 各模型在 Food-101 上的性能

网络模型	参数数量 /M	识别精度 /%	训练时间 /min	模型大小 /M
GResNet1	1.66	68.21	982	6.8
GResNet2	2.10	69.76	1 075	8.5
GResNet3	2.10	72.69	1 090	8.5

表 4 各模型在 GTSRB 上的性能

网络模型	参数数量 /M	识别精度 /%	训练时间 /min	模型大小 /M
GResNet1	1.40	98.36	305	5.7
GResNet2	1.83	98.49	313	7.1
GResNet3	1.83	98.78	320	7.1

从表 2、表 3 和表 4 可以看出,GResNet2 的准确率均高于 GResNet1,说明在每组内的瓶颈结构中添加恒等映射对提高模型准确率是有贡献的.虽然参数量有所增加,进而使得生成的模型变大,但是仍在同一数量级之内.对比 GResNet2 和 GResNet3 的性能可以看出组外模块加入残差连接,准确率可

以进一步提高,但是不会增加参数数量和模型大小,只是训练时间稍有增加.另外,随着识别种类的减少,生成的 Caffe 模型变小,主要因为网络中全连接层占据了网络的主要参数,识别种类越少,模型越小.总体来看,GResNet3 的性能最优,用比较少的参数在 Caltech-256 上达到 59.28%,Food-101 上达到 72.69%,GTSRB 上达到 98.78%的识别率.实验结果表明,GResNets 具有参数少、分类性能优越以及模型较小的优点,实现了网络轻量化.

图 7、图 8 和图 9 分别是在三种数据集上各模型的测试准确率曲线对比.




图 7 各模型在 Caltech-256 上的准确率曲线




图 8 各模型在 Food-101 上的准确率曲线




图 9 各模型在 GTSRB 上的准确率曲线

另外,在 GResNet1 组外加入残差连接,分类准确率会进一步提升,参数量保持不变,使得网络的可控性和扩展性很好.

表 5 给出了在三种数据集上 GResNet3 与其它

方法的模型大小和准确率对比. 在 Caltech-256 上, 与传统 AlexNet 网络相比, 模型大小仅是其 1/21. 在 Food-101 和 GTSRB 上, 与轻量级 SqueezeNet 网络相比, 虽然模型略大, 但仍在同一级别, 其准确率却分别超过 SqueezeNet 方法 16.39% 和 4.56%. 与其它的一些方法相比, GResNet3 取得了较好地分类效果, 证明了该网络的有效性.

表 5 不同方法在各数据集上的性能对比

网络模型	大小/M	准确率/%	数据集
AlexNet+BN	236.8	54.2	Caltech-256
GResNet3	11.4	59.28	Caltech-256
SqueezeNet ^[3]	3.2	56.3	Food-101
CNN+Bottleneck ^[8]	—	65.4	Food-101
Ensemble Net ^[9]	—	72.12	Food-101
GResNet3	8.5	72.69	Food-101
SqueezeNet ^[3]	3.0	94.22	GTSRB
Random Forests ^[10]	—	96.14	GTSRB
Multi-Scale ^[11]	—	98.31	GTSRB
GResNet3	7.1	98.78	GTSRB

4 结束语

本文提出的轻量级网络是通过瓶颈结构和恒等映射使网络能够提取更本质、更抽象、更具有辨识度的特征, 进而提升网络的分类性能. 同时结合了一些轻量化方法和训练技巧, 主要包括瓶颈结构、分组思想、残差学习、以及批量归一化等, 使得网络可以克服训练上的困难并得到更优的性能. 网络采用模块化设计, 使得网络需要改进或扩展时更加容易. 实验结果表明, 与传统深度卷积神经网络相比, 基于分组残差结构的轻量级网络能在参数较少的情况下, 具有同样、甚至更优越的分类性能, 适合在移动设备上应用.

参考文献:

[1] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[C]//Advances in neural information processing systems. [s. l.]2012: 1097-1105.

[2] 杨远飞, 曾上游, 冯燕燕, 等. 基于并行和切片的深度卷积网络设计研究[J]. 微电子学与计算机, 2018, 35(3): 120-124.

[3] IANDOLA F N, HAN S, MOSKEWICZ M W, et al. Squeezenet: Alexnet-level accuracy with 50x fewer parameters and< 0.5 mb model size[J]. arXiv preprint

arXiv:1602.07360, 2016.

[4] HOWARD A G, ZHU M, CHEN B, et al. Mobile-nets: Efficient convolutional neural networks for mobile vision applications[J]. arXiv preprint arXiv:1704.04861, 2017.

[5] CHOLLET F. Xception: Deep learning with depth-wise separable convolutions[J]. arXiv preprint arXiv:1610.02357, 2017.

[6] XIE S, GIRSHICK R, DOLLAR P, et al. Aggregated residual transformations for deep neural networks [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). USA, Honolulu, IEEE, 2017: 5987-5995.

[7] JIA Y, SHELHAMER E, DONAHUE J, et al. Caffe: Convolutional architecture for fast feature embedding[C]//Proceedings of the 22nd ACM international conference on Multimedia. ACM, 2014: 675-678.

[8] HERAVI E J, AGHDAM H H, PUIG D. An optimized convolutional neural network with bottleneck and spatial pyramid pooling layers for classification of foods[J]. Pattern Recognition Letters, 2018(105): 50-58.

[9] PANDEY P, DEEPTHI A, MANDAL B, et al. FoodNet: recognizing foods using ensemble of deep networks[J]. IEEE Signal Processing Letters, 2017, 24(12): 1758-1762.

[10] GONZALEZ-REYNA S E, AVINA-CERVANTES J G, LEDESMA-OROZCO S E, et al. Traffic sign recognition based on linear discriminant analysis[C]//Mexican International Conference on Artificial Intelligence. Springer, Berlin, Heidelberg, 2013: 185-193.

[11] SERMANET P, LECUN Y. Traffic sign recognition with multi-scale convolutional networks[C]//Neural Networks (IJCNN), The 2011 International Joint Conference on. USA, San Jose, IEEE, 2011: 2809-2813.

作者简介:

李 鹏 男, (1992-), 硕士研究生. 研究方向为图像处理.

蒋品群(通讯作者) 男, (1970-), 博士, 副教授. 研究方向为复杂网络理论及其应用.

E-mail: pqjiang@mailbox.gxnu.edu.cn.

曾上游 男, (1974-), 博士, 教授. 研究方向为生物神经网络理论及其应用.

夏海英 女, (1983-), 博士, 副教授. 研究方向为图像处理.

廖志贤 男, (1986-), 硕士, 讲师. 研究方向为复杂网络理论及其应用.

范 瑞 女, (1993-), 硕士研究生. 研究方向为图像处理.