

自动化构建移动端神经网络的技术研究

宋存洋, 李欣

(中国电子科技集团公司第二十八研究所, 江苏 南京 210007)

摘要: 深度学习已在视觉、语音、自然语言等应用领域取得巨大成功,然而随着网络结构日趋复杂,神经网络参数量也迅速增长,设计网络结构和调节参数这一过程需要大量的专业知识与反复试验,成本极高。此外,由于功耗限制与存储空间等因素,移动端设备上的神经网络模型规模受限。设计了一种高效的移动端神经网络架构搜索算法,具体包括:(1)设计了一种在预先给定神经网络架构的情况下可以自动计算模型浮点数运算次数的算法;(2)改进现有的基于梯度的神经网络架构搜索算法,设计了一种带约束的架构搜索算法;(3)在神经网络架构搜索过程中加入对浮点数运算次数的约束,通过调节约束的强弱搜索到几种不同的神经网络架构。训练搜索到的神经网络,测试其在图像分类任务上的性能,并与业界常用的模型相比较。实验结果表明,该方法搜索到的模型能达到目前业界主流模型性能。

关键词: 轻量级神经网络;卷积;模型约束;架构搜索

中图分类号: TN919.3+1

文献标识码: A

DOI: 10.16157/j.issn.0258-7998.200835

中文引用格式: 宋存洋,李欣. 自动化构建移动端神经网络的技术研究[J].电子技术应用,2020,46(12):83-88.

英文引用格式: Song Cunyang, Li Xin. Research on the technology of automatic construction of mobile terminal neural networks[J]. Application of Electronic Technique, 2020, 46(12): 83-88.

Research on the technology of automatic construction of mobile terminal neural networks

Song Cunyang, Li Xin

(The 28th Research Institute of China Electronics Technology Corporation, Nanjing 210007, China)

Abstract: Deep learning has achieved great success in many areas such as computer vision, speech signal processing and natural language processing. However, as the neural architecture becomes more complex, the number of parameters increases rapidly. Designing efficient neural architectures requires expertise knowledge and quantities of repetitive experiments, which leads to high cost. Besides, the scale of neural networks running in mobile devices is strictly limited due to the power consumption limit and relatively small storage space. This paper proposes an efficient architecture searching algorithm for mobile devices. The main contributions include:(1)We propose an algorithm for calculating the number of floating point operations in neural networks under given architecture.(2)We improve an existing gradient based neural architecture search algorithm and propose a constraint NAS algorithm.(3)We search several efficient neural architectures by adding the constraint of the number of floating point operations to the architecture searching process and adjusting its strength. We train the searched neural networks, test their performance on image classification tasks and compare with other neural networks which are commonly used in industry. The experimental results show that the performance of the model searched by our method can reach the performance of mainstream models in industry.

Key words: lightweight neural network; convolution; model constraint; neural architecture search

0 引言

自 AlexNet 以巨大的优势在 ImageNet 图像识别比赛中夺冠后,深度学习在视觉、语音、自然语言处理等方面取得了飞速的进展和巨大的成功。深度学习发展主要依赖于算力的提升和算法的进步。算力的提升主要在于 GPU、TPU 等硬件的应用与发展;而算法的进步多种多样,例如优化方法的改进、激活函数的选择等。本文主要关注于使用神经网络架构搜索的方法构建轻量级神经

网络,主要工作包括:

(1)设计了一种自动计算模型浮点数运算次数的算法。浮点数运算次数是反映神经网络规模与运行速度的一个重要指标,也是一个动态的过程,可以看作架构参数的函数,除了具体的数值外,本文还计算了其架构参数的偏导数。

(2)基于梯度的神经网络架构搜索,改进设计了一种带约束的架构搜索方法。在实际任务中,为了使模型能

通信与网络 Communication and Network

运行在特定设备上,通常对模型的规模或运行速度等有一定的要求。不加约束的搜索,得到的模型很可能不满足要求。本文实现的约束算法并不限于某一种特定约束,而是实现了一种接口,加入了对模型运行时延、模型规模多种不同的约束。

(3)利用带有浮点数运算次数约束的架构搜索算法,搜索到几种高性能神经网络架构。在几个公开数据集上测试并对比其在图像分类任务上的准确率,并与工业界常用的神经网络模型进行比较。

1 模型设计

1.1 搜索空间

1.1.1 网络总体结构

搜索空间往往不可穷举,因此需要合适的算法缩减搜索范围,准确并快速地寻找最优的网络结构,常用的搜索算法包括强化学习^[1]、遗传算法^[2-3]、贝叶斯优化^[4]等。强化学习、遗传算法等策略需要过多的计算资源,为了利用梯度信息,研究人员提出了基于梯度下降法求解的方案,称为可微结构搜索(Differentiable Architecture Search, DARTS)^[5],其主要思想是把离散的搜索空间松弛为连续空间,使得损失函数对架构参数可导,并使用梯度下降法进行优化。

根据 DARTS 的设计思路,神经网络可由多个相同或相似计算单元堆叠起来,这样可以取得很好的性能。本文的搜索空间仅限于计算单元,在搜索到合适的计算单元之后进行堆叠,之后连接一个分类器,形成神经网络的主体。计算单元采用简单的堆叠方式,即每个计算单元接收其前面两个计算单元的结果作为输入,并输出到后面的两个计算单元中。本文的神经网络主体由 6 个普通计算单元和 2 个约简计算单元组成,网络总体结构如图 1 所示。

1.1.2 计算单元结构

计算单元包含 2 个输入节点、4 个中间节点和 1 个输出节点。输入节点等于该计算单元的前两个计算单元的输出,输出节点为 4 个中间节点的拼接。4 个中间节点形成层级关系,每个中间节点都接收所有的前驱节点作为输入(例如,第 4 个中间节点同时接收前 3 个中间节点作为输入),除此之外,每个中间节点都接收两个输入节点作为输入。

每个中间节点都基于其所有前置节点进行计算:

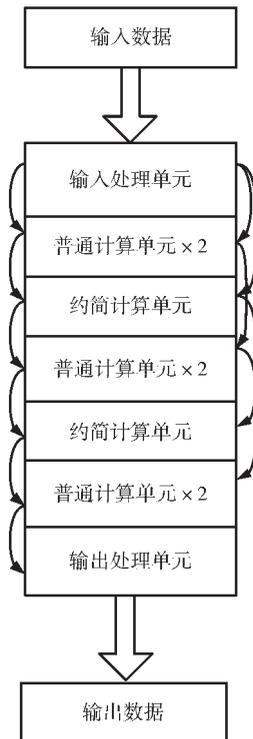


图 1 神经网络总体结构

$$x^{(j)} = \sum_{i < j} o^{(i,j)} x^{(i)} \quad (1)$$

计算单元结构如图 2 所示。

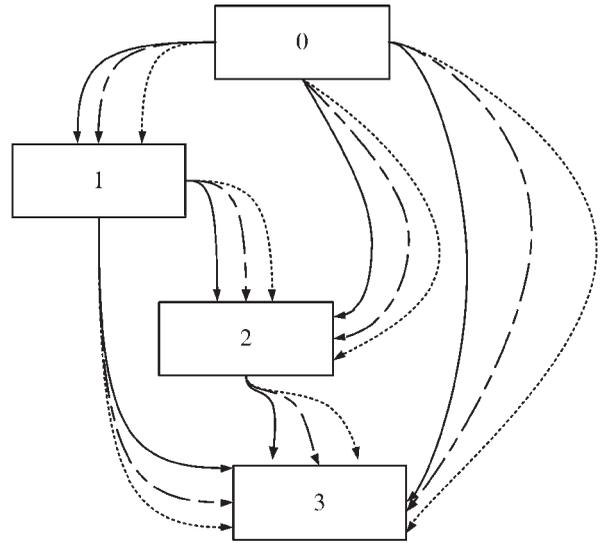


图 2 计算单元结构

1.1.3 搜索空间的松弛

假设 O 是候选操作的集合,其中候选操作包括卷积、最大值池化等,分组卷积最早源于 AlexNet^[6],它的思想是把特征通道分为多组,每个分组之内进行标准的卷积,而分组之间不进行通信。Depthwise Convolution^[7]最早由 Google 提出,是分组卷积的一种特例。它的思想是对每个特征图分别做卷积,每个特征图之间不做通信,这样可以显著地降低卷积操作的时间。每一个操作都是隐层张量为自变量的一个函数,表示为 $o(x^{(i)})$ 。操作通常被需要被选择,而选择通常是不连续的操作,无法计算梯度。为了使操作连续化,本文使用 softmax 的方法对选择这一步骤进行松弛:

$$\bar{o}^{(i,j)} = \sum_{o \in O} \frac{e^{\alpha_o^{(i,j)}}}{\sum_{o' \in O} e^{\alpha_{o'}^{(i,j)}}} o(x) \quad (2)$$

1.2 搜索及性能评估策略

在基于梯度的神经网络架构搜索方法中,搜索策略和性能评估策略密不可分。在基于梯度的算法中,神经网络架构用连续的参数 α 表示,不同的 α 表示不同的架构。这意味着神经网络的损失函数对架构 α 和权重 w 都可导,因此可以使用梯度下降法优化 α 和 w 。性能评估的另一个重要作用是通过损失函数得到 α 的梯度,从而优化架构 α 。本文把整个数据集划分为训练集和验证集两部分,在训练集上优化权重 w ,在验证集上评估性能并优化架构 α 。

1.2.1 优化目标

在搜索空间松弛之后,神经网络的优化目标转化为

通信与网络 Communication and Network

联合学习架构 α 和权重 w 。与使用强化学习或遗传算法的神经网络架构搜索类似,基于梯度的架构搜索目标也是优化验证集上的误差。假定 L_{train} 和 L_{val} 分别表示训练集和验证集上的误差。这两种误差不仅与架构 α 有关,还与网络中的权重 w 有关。架构搜索的目标是找到最优解 α^* ,之后通过最小化训练集误差来得到最优权重 w^* 。

这是一个嵌套优化问题,其中 α 为上层变量, w 为下层变量:

$$\begin{aligned} & \min_{\alpha} L_{val}(w^*(\alpha), \alpha) \\ \text{s.t.} \quad & w^*(\alpha) = \operatorname{argmin}_w L_{train}(w, \alpha) \end{aligned} \quad (3)$$

1.2.2 梯度近似

由于高昂的优化代价,无法精确地计算架构梯度,但是可以采用一种梯度近似的方案:

$$\nabla_{\alpha} L_{val}(w^*(\alpha), \alpha) \approx \nabla_{\alpha} L_{val}(w - \xi \nabla_w L_{train}(w, \alpha), \alpha) \quad (4)$$

式中, w 表示当前算法得到的权重, ξ 表示相应优化步骤的学习率。通常,对于架构 α ,需要进行多次梯度下降才可能得到最优解 w^* 。而梯度近似的思想是,并不需要得到权重最优解 w^* ,而只要保证 w 被优化就可以,因此只进行一次梯度下降,从而节省大量时间。

式(4)中,约等号右边第一项 $w - \xi \nabla_w L_{train}(w, \alpha)$ 和第二项 α 都与 α 有关,是复合函数的求导。为了求导方便,这里将链式法则应用到式(4),得到:

$$\nabla_{\alpha} L_{val}(w', \alpha) - \xi \nabla_{\alpha, w}^2 L_{train}(w, \alpha) \nabla_w L_{val}(w', \alpha) \quad (5)$$

其中, $w' = w - \xi \nabla_w L_{train}(w, \alpha)$ 表示只进行一次梯度下降得到的权重。式(5)中,第二项包含代价很大的矩阵向量积,但是可以通过有限差分近似的方法,大大降低计算复杂度。假定 ϵ 是一个数值极小的参数,并且 $w^{\pm} = w \pm \epsilon \nabla_w L_{val}(w', \alpha)$,那么:

$$\begin{aligned} & \nabla_{\alpha, w}^2 L_{train}(w, \alpha) \nabla_w L_{val}(w', \alpha) \approx \\ & \frac{\nabla_{\alpha} L_{train}(w^+, \alpha) - \nabla_{\alpha} L_{train}(w^-, \alpha)}{2\epsilon} \end{aligned} \quad (6)$$

计算有限差分只需要权重 w 两次向前传播、架构 α 两次向后传播,所以时间复杂度由原来的 $O(|\alpha||w|)$ 降低到 $O(|\alpha|+|w|)$ 。

1.3 考虑约束条件的搜索

本文采用一种通用性很强的间接指标——浮点运算数量(Floating Point Operations, FLOPs)作为限制模型搜索的约束条件。由于本文神经网络架构的可变部分只有计算单元,其他不变的部分不会影响搜索,因此这里只讨论与计算单元有关的 FLOPs。直接得到的 FLOPs 由于数值太大,不能直接并入损失函数,因此本文对 FLOPs 稍加变化,引入约束量:

$$F(\alpha) = k_1 (\ln(\sum_{i,j} m^{(i,j)} \alpha^{(i,j)}))^{k_2} \quad (7)$$

其中, k_1, k_2 和自然对数函数用于控制 FLOPs 的量级,

$m^{(i,j)}$ 表示 $o^{(i,j)}$ 操作的近似 FLOPs 数值。由于卷积操作的浮点运算次数远大于池化、激活函数等操作,架构搜索过程中算法会异常地偏向于不选择卷积操作。这样搜索得到的模型虽然规模小、速度快,但是准确度会低。为了防止这种现象,本文在所有操作的真实浮点运算次数的基础上加上一个定值:

$$m^{(i,j)} = \text{FLOPs}^{(i,j)} + k_3 \quad (8)$$

其中, $\text{FLOPs}^{(i,j)}$ 表示操作 $o^{(i,j)}$ 的真实浮点运算次数, k_3 是 FLOPs 正则化参数。当 $k_3=0$ 时,卷积操作和其他操作的近似 FLOPs 数值差距最大;随着 k_3 的增大,操作之间的区分度也逐渐趋于零;当 k_3 趋于正无穷时,约束将不起作用。

加入约束量的损失函数可以写成:

$$L_{total}(\alpha) = L_{val}(w^*(\alpha), \alpha) \cdot F(\alpha) \quad (9)$$

相应地, α 的梯度可写作:

$$\nabla_{\alpha} L_{total} = \nabla_{\alpha} L_{val} \cdot F + \nabla_{\alpha} F \cdot L_{val} \quad (10)$$

1.4 模型导出

由于搜索空间离散,搜索得到的模型很庞大,本文舍弃一些操作,减小模型的规模。为了形成这种离散的模型架构,对于每一条边 (i, j) ,本文选择所有非零候选操作中前 k 个最好的操作(这 k 个操作需要来自不同节点)。

操作的强度由 α 决定,它的定义为: $\frac{e^{\alpha_{o^{(i,j)}}}}{\sum_{o' \in O} e^{\alpha_{o'}}$ 。本文只研究卷积神经网络,因此取 $k=2$ 。模型导出如图 3 所示。

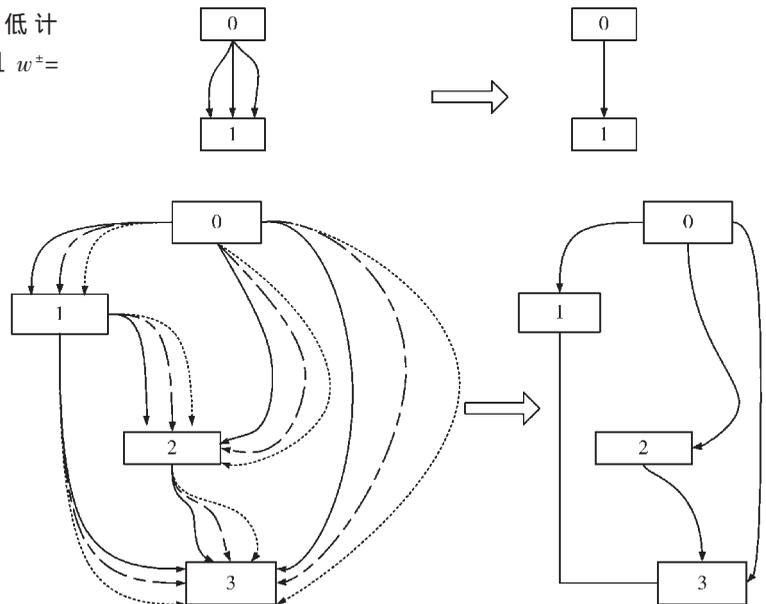


图 3 模型导出

2 实验和结果

本文的实验主要分为架构搜索和架构评估两部分。在架构搜索阶段,分别对比一阶近似与二阶近似的算法、不带约束的可微搜索算法和带约束的可微搜索算法;在

通信与网络 Communication and Network

架构评估阶段,训练并对前一阶段搜索得到的神经网络,并与工业界常用的两种神经网络对比。

2.1 实验环境及数据

在本文的实验中,架构搜索主要在 CIFAR-10 数据集上运行,共包含 10 个种类的 RGB 彩色图像,其中每张图像的尺寸为 32×32 ,数据集总共包含 50 000 张训练图像和 10 000 张测试图像。架构评估部分除了 CIFAR-10 数据集外,还使用 ImageNet 数据集。ImageNet 也是一个用于图像分类的大型数据库,它包含的种类超过两万种,共有超过 1 400 万张图像。

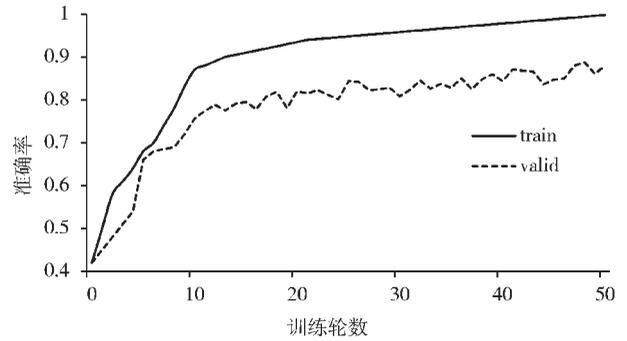
2.2 架构搜索

2.2.1 搜索空间及参数设置

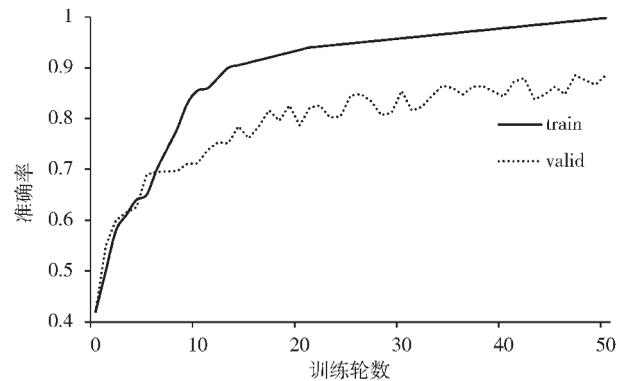
本实验中,模型训练轮数为 50。batch_size 设为 32,初始的输入通道设为 64,这样选择的目的是使整个网络可以很好地适应单个 GPU。本文使用带有动量的随机梯度下降法(SGD)来优化权重 w ,初始的学习率为 $\eta w = 0.025$ (随着迭代进行,使用余弦退火策略降低学习率),动量设为 0.9,衰减率为 3×10^{-4} 。初始化架构 α 时,矩阵中的所有值平均分布,这使得所有操作在一开始训练时都被平等地对待。本文使用 Adam 优化器来优化架构 α ,初始的学习率为 $\eta \alpha = 3 \times 10^{-4}$,动量 $\beta = (0.5, 0.999)$,衰减率为 10^{-3} 。

2.2.2 一阶近似与二阶近似

在本文的算法中,架构搜索涉及多维参数的嵌套优化问题,因此选用近似的方法降低复杂度。一阶近似和二阶近似搜索过程中训练集与测试集的准确率变化如图 4 所示。一阶近似和二阶近似搜索到的计算单元如图 5 所示。两种近似都可以达到较好的效果。一阶近似平均耗时 9 h,二阶近似平均耗时 20 h,二阶近似的收敛速度、稳定性、验证集准确率均略优于一阶近似。



(a) 一阶近似

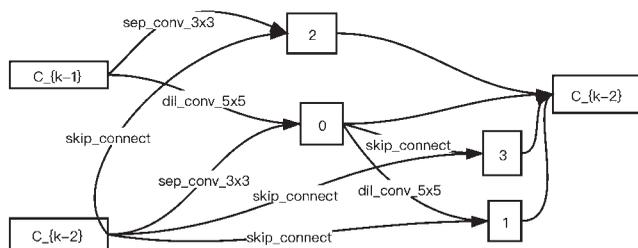


(b) 二阶近似

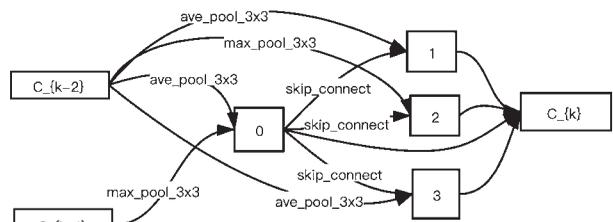
图 4 搜索过程中准确率变化

2.2.3 带约束的架构搜索

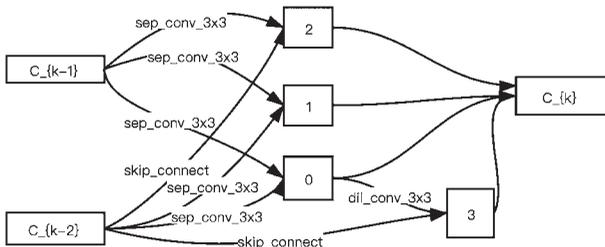
本文控制约束搜索的参数主要有 k_1, k_2, k_3 这 3 个,其中 k_1 和 k_2 对搜索过程影响较小,因此本文设定 $k_1 = 1, k_2 = 1$,只调节正则化项 k_3 。为了控制变量,整个实验都使用二阶近似,其他参数的设置也都相同。 k_3 的选择考虑到神经网络各层的 FLOPs,尤其是浮点运算数量占比远



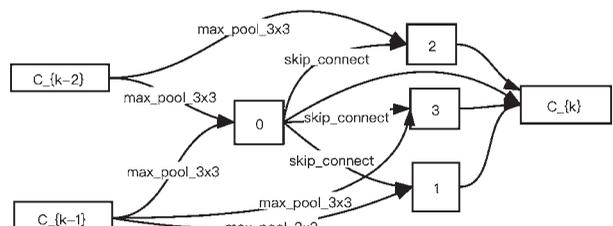
(a) 一阶普通计算单元



(b) 一阶简约计算单元



(c) 二阶普通计算单元



(d) 二阶简约计算单元

图 5 搜索到的计算单元

通信与网络 Communication and Network

大于其他操作的卷积操作。本文中,由于特征图维度的变化,卷积操作的 FLOPs 量级大概为 10^5 和 10^6 ,因此分别选择 $k_3=1 \times 10^5, 5 \times 10^5, 1 \times 10^6, 5 \times 10^6$,此外还选择 $k_3=0$ 用作对照。训练过程中,约束量 F 的变化如图 6 所示。 $k_3=0, 5 \times 10^6$ 时的普通计算单元结构如图 7 所示。可以看出,当 $k_3=0$ 时,计算单元所有边上的操作都是跳连操作;随着 k_3 逐渐增大,约束量 F 的减小趋势越来越小。

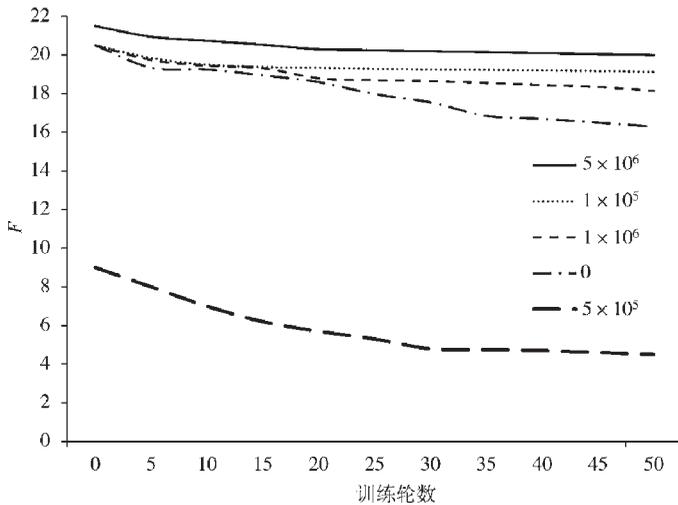


图 6 图片的一个简单应用场景

2.3 架构评估

搜索到神经网络架构之后,首先要对其进行充分的训练,最后在公开的数据集上进行性能评估。

2.3.1 一阶近似与二阶近似

分别使用一阶近似和二阶近似进行架构搜索,为了控制变量,保持其他参数相同。对得到的神经网络架构,从头开始训练,评估其在 CIFAR-10 和 ImageNet 上进行图像分类任务的准确率,如图 8 所示。可以看出,二阶近似在 CIFAR-10 和 ImageNet 数据集上的 Top-1 准确率均高于一阶近似得到的模型,这与 2.2.2 小节中的理论分析相符。

2.3.2 带约束的架构搜索

带约束的架构搜索目的是降低神经网络的 FLOPs,

同时尽可能地提高模型在分类任务上的准确率。分别设定 $k_3=0, 1 \times 10^5, 5 \times 10^5, 1 \times 10^6, 5 \times 10^6$,使用二阶近似,并使其他参数相同,进行架构搜索。搜索完成后,从头训练得到的模型,计算其 FLOPs,并分别在 CIFAR-10 和 ImageNet 数据集上测定其在图像分类任务上的准确率,如图 8 所示。

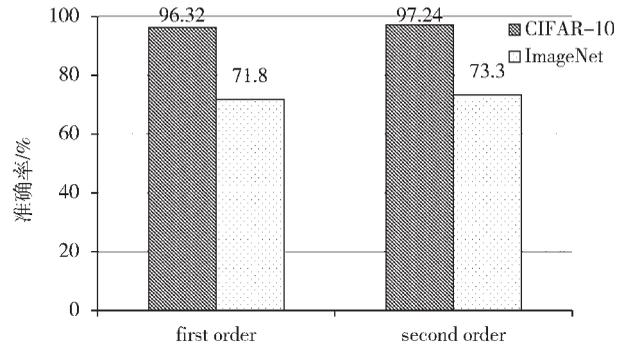


图 8 一阶近似与二阶近似的模型准确率

除此之外,为了说明带约束的架构搜索算法的有效性,本文还选择了不带约束的搜索得到的一种架构与两种工业界常用的神经网络用作对比。各个模型在 CIFAR-10、ImageNet 数据集上的准确率和 FLOPs 分别如图 9~图 11 所示。在 CIFAR-10 数据集上,综合 FLOPs 和准确率,本文搜索到的模型和工业界常用的反向传播(BP)^[8]、ShuffleNetV2^[9]、MobileNetV2^[10]性能相似。但在 ImageNet 数据集上,结合 FLOPs 和准确率来看,本文

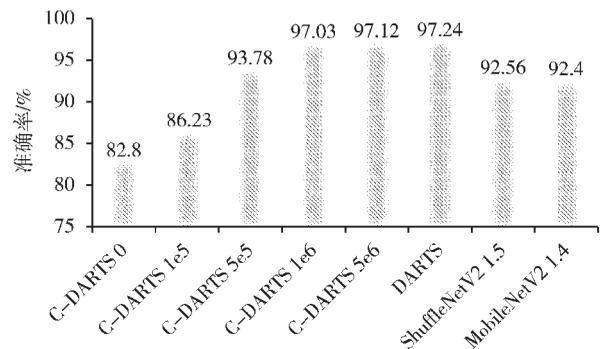
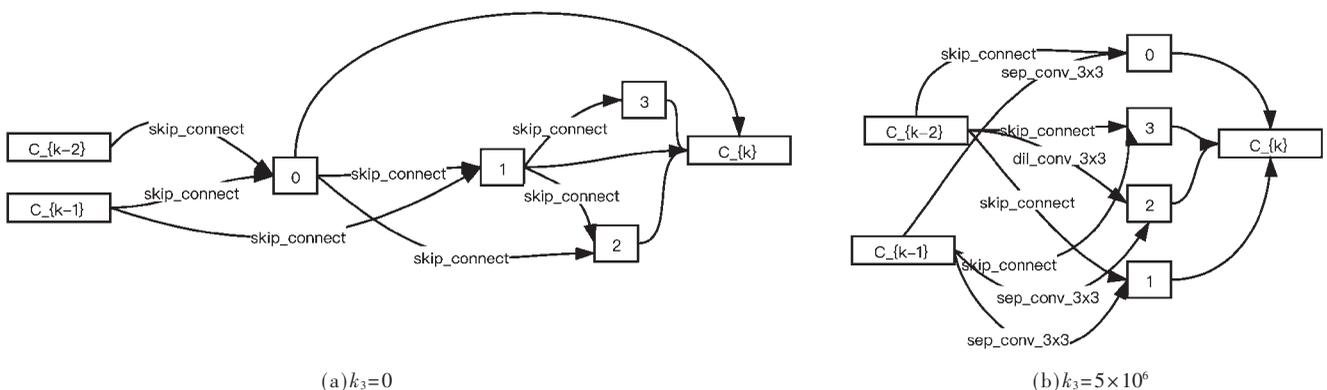


图 9 各模型在 CIFAR-10 数据集上的 Top-1 准确率



(a) $k_3=0$

(b) $k_3=5 \times 10^6$

图 7 搜索到的普通计算单元

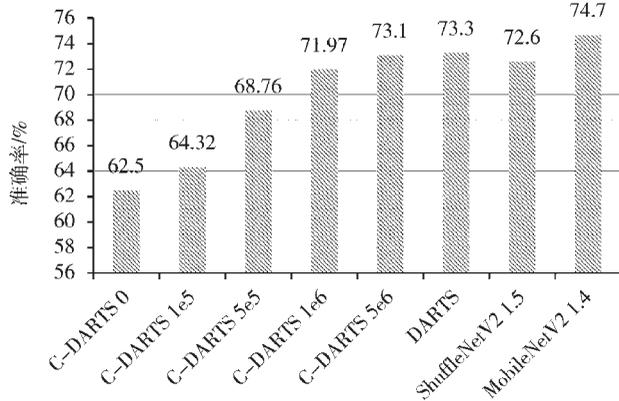


图 10 各模型在 ImageNet 数据集上的 Top-1 准确

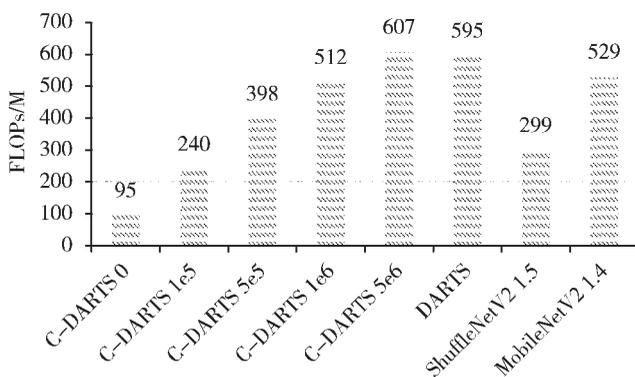


图 11 各模型的 FLOPs

搜索到的模型效果差于 ShuffleNetV2、MobileNetV2。主要原因是本文进行架构搜索时使用的数据集是 CIFAR-10，这会导致搜索到的结构更加适合 CIFAR-10，而对于 ImageNet 上的图像分类任务，本文直接使用了在 CIFAR-10 上的搜索到的架构。

3 结论

本文改进了基于梯度的架构搜索算法，设计了一种自动计算模型浮点数运算次数的算法和带约束的架构搜索方法；利用该算法，通过调节约束的大小，搜索到几种不同的神经网络架构。训练搜索到的神经网络，并利用开放的图像识别数据集验证了其有效性。

参考文献

[1] ZOPH B, LE Q V. Neural architecture search with reinforcement learning[C]. ICVR, 2017.

- [2] REAL E, MOORE S, SELLE A, et al. Large-scale evolution of image classifiers[C]. ICML, 2017.
- [3] SUGANUMA M, OZAY M, OKATANI T. Exploiting the potential of standard convolutional autoencoders for image restoration by evolutionary search[C]. Proceedings of the 35th International Conference on Machine Learning, ICML 2018, Stockholm, Sweden, 2018: 4778-4787.
- [4] KANDASAMY K, NEISWANGER W, SCHNEIDER J, et al. Neural architecture search with bayesian optimisation and optimal transport[C]. Advances in Neural Information Processing Systems 31: Annual Conference on Neural Information Processing Systems 2018, NeurIPS 2018, Montréal, Canada, 2018: 2020-2029.
- [5] LIU H, SIMONYAN K, YANG Y. DARTS: differentiable architecture search[C]. 7th International Conference on Learning Representations, ICLR 2019, New Orleans, LA, USA, 2019.
- [6] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[C]. Proceedings of the 25th International Conference on NIPS'12, 2012, 1: 1097-1105.
- [7] GUO Y, LI Y, WANG L, et al. Depthwise convolution is all you need for learning multiple visual domains[C]. The Thirty-Third AAAI Conference on Artificial Intelligence, AAAI 2019, Honolulu, Hawaii, USA, 2019: 8368-8375.
- [8] 阮昌, 李印凤, 高旗. 基于 BP 神经网络的终端区拥挤等级预测[J]. 指挥信息系统与技术, 2019, 10(4): 83-86.
- [9] MA N, ZHANG X, ZHENG H, et al. Shufflenet V2: practical guidelines for efficient CNN architecture design[C]. ECCV, 2018.
- [10] SANDLER M, HOWARD A G, ZHU M, et al. Inverted residuals and linear bottlenecks: Mobile networks for classification, detection and segmentation[J]. arXiv Preprint arXiv: 1801.04381, 2018.

(收稿日期: 2020-08-11)

作者简介:

宋存洋(1977-), 男, 高级工程师, 主要研究方向: 信息系统总体及人工智能。

李欣(1985-), 女, 硕士, 高级工程师, 主要研究方向: 信息工程管理及大数据应用。

(上接第 82 页)

identification and mitigation approach for target tracking in wireless sensor networks[J]. IEEE Access, 2017: 2798-2807.

(收稿日期: 2020-05-22)

作者简介:

王钦锐(1998-), 男, 本科, 主要研究方向: 无线传感器

网络定位。

黄越洋(1981-), 通信作者, 女, 博士, 讲师, 主要研究方向: 无线传感器网络定位、网络控制, E-mail: huangyueyang_1981@126.com。

石元博(1981-), 男, 博士, 主要研究方向: 无线传感器网络控制。

版权声明

经作者授权，本论文版权和信息网络传播权归属于《电子技术应用》杂志，凡未经本刊书面同意任何机构、组织和个人不得擅自复印、汇编、翻译和进行信息网络传播。未经本刊书面同意，禁止一切互联网论文资源平台非法上传、收录本论文。

截至目前，本论文已经授权被中国期刊全文数据库（CNKI）、万方数据知识服务平台、中文科技期刊数据库（维普网）、DOAJ、美国《乌利希期刊指南》、JST 日本科技技术振兴机构数据库等数据库全文收录。

对于违反上述禁止行为并违法使用本论文的机构、组织和个人，本刊将采取一切必要法律行动来维护正当权益。

特此声明！

《电子技术应用》编辑部

中国电子信息产业集团有限公司第六研究所