

DOI:10.11918/202011092

熵启发的分级可微分网络架构搜索

李建明^{1,2}, 陈 斌^{2,3}, 孙晓飞^{1,2}

(1. 中国科学院 成都计算机应用研究所, 成都 610041; 2. 中国科学院大学, 北京 100049;
3. 哈尔滨工业大学(深圳) 国际人工智能研究院, 广东 深圳 518055)

摘 要: 网络架构是影响卷积神经网络性能的重要因素, 由于传统的人工设计方法效率较低, 通过算法自动设计网络架构的方法受到了越来越多的关注。可微分网络架构搜索(DARTS)方法, 能高效地自动设计网络架构, 但其超网络的构建和架构派生策略也存在不足之处。针对其不足之处, 本文提出了改进算法。首先, 通过量化分析该算法搜索过程中跳连(skip)操作数量的变化, 发现共享架构参数的设置导致 DARTS 算法的超网络存在耦合问题; 其次, 针对超网络的耦合问题, 设计了元胞(cell)分级的超网络, 以避免不同层级间 cell 的相互影响; 然后, 针对超网络与派生架构在性能表现上存在“鸿沟”的问题, 引入架构熵作为目标函数的损失项, 以启发超网络的训练。最后, 在 CIFAR-10 数据集上进行架构搜索实验, 并分别在 CIFAR-10 和 ImageNet 上进行了架构评测实验。在 CIFAR-10 上的实验结果表明, 本文提出的算法解除了不同层级 cell 间的耦合, 提升了自动设计的架构性能, 取得了仅 2.69% 的分类错误率; 该架构在 ImageNet 上的分类错误率为 25.9%, 实验结果表明搜得的架构具有良好的迁移性。

关键词: 网络架构搜索; 可微分架构搜索; 分级超网络; 架构熵

中图分类号: TP183 **文献标志码:** A **文章编号:** 0367-6234(2021)08-0022-07

Multi-level differentiable architecture search with heuristic entropy

LI Jianming^{1,2}, CHEN Bin^{2,3}, SUN Xiaofei^{1,2}

(1. Chengdu Institute of Computer Applications, Chinese Academy of Sciences, Chengdu 610041, China;
2. University of Chinese Academy of Sciences, Beijing 100049, China; 3. International Research Institute of Artificial Intelligence, Harbin Institute of Technology, Shenzhen, Shenzhen 518055, Guangdong, China)

Abstract: Network architecture is an important factor affecting the performance of convolutional neural networks. Due to the low efficiency of the traditional manual design of network architecture, the method of automatically designing network architecture through algorithms has attracted more and more attention. Although the approach of differentiable architecture search (DARTS) has the capacity of designing networks automatically and efficiently, there are still problems owing to its super network construction and derivation strategy. An improved algorithm was proposed to overcome these shortcomings. First, the coupling problem caused by sharing architecture parameters in the super network was disclosed by quantifying the changes in the number of the skip candidate operations during the algorithm search process. Next, aiming at the coupling problem of the super network, a super network with multi-level cells was designed to avoid the mutual influence of cells at different levels. Then, in view of the “gap” between the super network and the derived architecture, the entropy of architecture parameters was introduced as the loss term of the objective function to inspire the training of the super network. Finally, architecture search experiments were conducted on CIFAR-10 dataset, and architecture evaluation experiments were conducted on CIFAR-10 and ImageNet respectively. Experimental results on CIFAR-10 show that the proposed algorithm removed the coupling problem between cells at different levels and improved the performance of the automatically designed architecture, which achieved classification error rate of only 2.69%. The architecture had the classification error rate of 25.9% on ImageNet, which proved its transferability.

Keywords: neural architecture search; differentiable architecture search; super network with multi-level cells; architecture entropy

收稿日期: 2020-11-20
基金项目: 广东省云计算与大数据管理技术重大科技专项 (2017B030306017)
作者简介: 李建明(1989—), 男, 博士研究生;
陈 斌(1970—), 男, 研究员, 博士生导师
通信作者: 李建明, lugeeljm@gmail.com;
陈 斌, chenbin2020@hit.edu.cn

自深度学习技术兴起以来, 神经网络架构设计一直是计算机视觉中最重要的基础研究之一, 人类专家手工设计了大量优秀的神经网络架构(如 AlexNet^[1]、ResNet^[2]、DenseNet^[3]、SENet^[4]等)。手工设计的神经网络架构, 往往需要专家进行大量的

试错实验。因此在限定的搜索空间中,采用网络架构搜索(neural architecture search, NAS)方法模拟专家自动设计更好神经网络架构的研究,受到了越来越多的关注^[5-13]。

不同于采用强化学习^[6](reinforcement learning, RL)和进化算法^[7](evolutional algorithm, EA)作为优化策略的 NAS 方法,文献[8]提出了可微分架构搜索算法(differentiable architecture search, DARTS),创造性地把离散空间的架构搜索问题转化为连续空间的参数优化问题^[8]。在相同的搜索空间中,采用性能相近的图形处理单元(graphics processing unit, GPU),该方法可更高效地搜索架构。例如,后者计算资源需求仅为 4 GPU·d,前两者则分别需要 2 000 GPU·d^[6]和 3 150 GPU·d^[7]。同时,在 CIFAR-10^[14]和 ImageNet 数据集上,后者搜得架构的性能也能达到前两种方法相近的水平^[8],且 3 种方法搜得的架构都超越了先前人类专家设计的架构。

DARTS 算法高效的架构搜索能力,吸引了众多学者的关注,并出现了一系列的改进方法^[15-20]。文献[15]提出了渐进的可微分架构搜索算法(progressive differentiable architecture search, P-DARTS),以改善搜索架构的超网络与架构评测网络在网络深度上存在“鸿沟”(depth gap)的问题。文献[16]提出了随机神经网络架构搜索算法(stochastic neural architecture search, SNAS),通过限制架构参数为独热(one-hot)编码形式构建超网络,以改善 DARTS 因派生 cell 的方法而导致超网络与派生架构出现性能“鸿沟”的问题。文献[17]注意到,DARTS 算法中各级 cell 共享架构参数的超网络本身可能存在潜在问题。本文通过跟踪超网络各级 cell 的 skip 数量变化趋势,进一步发现,共享架构参数容易造成各级 cell 通过架构参数相互耦合。在超网络优化后期,耦合会导致各级 cell 的 skip 操作通过架构参数叠加,并产生包含过多 skip 操作的 cell,从而严重影响搜得架构的性能^[15,17]。

针对上述的后两项问题,本文提出了改进算法:熵启发的分级可微分网络架构搜索。首先,针对 DARTS 的耦合问题,设计了新颖的分级超网络,对 DARTS 超网络的耦合问题进行解耦。其次,针对超网络与派生架构间的“鸿沟”问题,引入架构熵作为超网络目标函数的损失项,促使目标函数缩小超网络与派生架构因派生引起的“鸿沟”,以启发超网络在巨大的搜索空间中搜得更好的架构。最后,在图像分类数据集 CIFAR-10 上进行了实验,搜索阶段算法耗时仅 11 h,最终构建的评测网络在该数据集上的分类错误率仅为 2.69%,优于 DARTS^[8]、高效

的网络架构搜索(efficient neural architecture search, ENAS)^[13]和 SNAS^[16]等算法。同时其参数量仅为 2.95×10^6 ,比性能相近的架构少约 10%。在大规模图像分类数据集 ImageNet 上,本文所得架构的分类错误率仅为 25.9%(对应评测网络的参数量为 4.3×10^6),优于 MobileNets^[21]等手工设计的架构,也优于 DARTS^[8]、SNAS^[16]等算法自动设计的架构,该结果表明本文搜得的架构具有较好的图像分类能力和良好的可迁移性。综合性能与参数量两项指标来看,本文搜得的架构达到了领先水平。

1 分级可微分网络架构搜索

1.1 DARTS 算法简介

DARTS 算法以 cell^[6-7]为搜索的基本单元。cell 由若干有序结点组成的有向无环图(directed acyclic graph, DAG)表示^[8],见图 1。DAG 中的结点表示特征图,连接结点的有向边表示候选操作。DARTS 定义的 cell 共包含 7 个结点。其中,前两个结点为输入结点,分别代表最近临的前两个 cell 的输出;中间的 4 个结点,每个都通过有向边与其所有前序结点相连,如式(1)所示^[8];最后一个结点按通道合并(concatenation, concat)4 个中间结点代表的特征图^[8],作为该 cell 的输出(output)。

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

式中: $x^{(j)}$ 为 cell 的中间结点, $x^{(i)}$ 为输入结点或中间结点, $o^{(i,j)}$ 为连接 $x^{(j)}$ 和 $x^{(i)}$ 的混合操作, i 和 j 均为结点序号。

有向边关联的候选操作集合 O ,共包含 8 个操作函数,分别是 $3 \times 3/5 \times 5$ 可分离卷积(sep_conv)、 $3 \times 3/5 \times 5$ 空洞可分离卷积(dil_conv)、 3×3 平均/最大池化(avg/max_pool)、跳跃连接(skip)和无连接(none)。




图 1 DARTS 算法的 cell 图示

Fig. 1 Schematic of cell in DARTS

DARTS 创造性地在 cell 中引入了架构参数 α ,把离散的架构搜索问题转化为连续参数空间的参数

优化问题^[8],并以可学习的架构参数作为候选操作的权重,构建了加权的混合操作,最终把架构搜索简化为对候选操作权重的学习。该算法还采用软最大 (softmax) 函数对架构参数进行松弛化操作,把架构参数的值归一化到 (0,1) 区间。松弛化操作后,式(1)中的混合操作 $o^{(i,j)}$ 变形为^[8]

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

式中: $\bar{o}^{(i,j)}(x)$ 为松弛化后的混合操作, $\alpha_o^{(i,j)}$ 和 $\alpha_{o'}^{(i,j)}$ 均为连接 $x^{(j)}$ 和 $x^{(i)}$ 的某个候选操作 o 对应的架构参数。

为了高效地学习 cell 中的参数,DARTS 构建了以 cell 为模块的超网络(深度记为 d),见图 2。超网络含有两种类型的 cell,分别是常规元胞 (normal cell) 和降维元胞 (reduction cell)^[8]。Reduction cell 位于超网络 $d/3$ 和 $2d/3$,步幅为 2,起降维作用;normal cell 特征图维度保持不变,主要起特征提取作用。超网络被 reduction cell 分为 3 个层级,每级包含 M 个堆叠的 normal cell,后级 normal cell 的特征图大小则是前一级的 1/2。该超网络中各级 cell 共享架构参数,即超网络中不同层级的 cell 结构完全相同^[8]。超网络训练完成后,算法根据架构参数由完整 cell 保留部分候选操作得到派生的 cell,再以派生的 cell 构建评测网络对架构进行性能评测。




图 2 DARTS 构建的超网络

Fig. 2 Super network constructed by DARTS

1.2 分级 cell 构建的搜索超网络

1.2.1 DARTS 算法的耦合问题

DARTS 算法中不同层级的 cell 共享架构参数,意味着同一个架构参数会出现在超网络的不同深度。而超网络目标函数关于参数的梯度,是逐层求导累积得到的,那么超网络中不同深度的同一架构参数的梯度也不同。架构参数共享的设置,导致超网络优化位于不同层级 cell 的相同架构参数时,不同趋势的更新要在同一套架构参数中共享。这就造成不同层级 cell 学习到的架构参数相互影响,即产生了耦合效应。

架构参数耦合容易带来两方面的影响:1) 同一架构参数,在超网络不同位置的梯度有很大差异,当不同层级 cell 的架构参数变化趋势不同时,造成共享的架构参数主要体现了梯度较大处的选择;2) 随着超网络的训练,混合操作中含有卷积的候选操作逐渐被优化,超网络便逐渐偏向 skip 和 pooling 这类容易优化的无参数操作,由于架构参数共享,这种偏好被叠加,容易造成最后学到的架构包含大量的 skip 操作,导致其性能欠佳(文献[17]也注意到了这种现象)。

以 normal cell 的 skip 为例,本文分别跟踪各级 cell 的 skip 数量变化,发现随着超网络的优化,其数量都有所增长,如图 3(a) 所示。初始化相同情况下,共享架构参数的 normal cell 在超网络训练的后期,由于耦合效应,造成 skip 数量大幅增加。该 cell 中 skip 占据操作总数的 4/8 (如图 3(b) 所示, CIFAR-10 上测试错误率为 3.10%)。这导致 cell 中含有卷积参数的候选操作数量偏少,从而影响了 cell 的表征能力。




图 3 相同初始化,架构搜索过程 cell 包含的 skip 数量对比

Fig. 3 Comparison of skip numbers during architecture search with identical initialization

1.2.2 cell 分级的超网络

针对 DARTS 算法构建的超网络出现的耦合问题, 本文基于 DARTS 的超网络, 设计了 cell 分级的超网络, 以避免不同层级间 cell 的相互影响。如图 4 所示, 该超网络被 reduction cell 分为 3 个层级, 分别为低层次常规 (low normal)、中层次常规 (mid normal) 和高层次常规 (high normal) 层级。每级包含 M 个堆叠的 normal cell, 各级 cell 的搜索空间相同, 但各自拥有独立的结构。由于 reduction cell 的降维作用, 不同层级的 normal cell 对应的特征图维度则依次减小, 更深一级 cell 中的候选操作提取的特征也更加抽象。本文超网络的设置, 既允许各层级 cell 搜索到相同的结构, 也允许更深的 cell 在更抽象的特征图上搜索到不同于低层 cell 的结构。




图 4 cell 分级的超网络

Fig. 4 Super network constructed by multi-level cells

与分级的超网络结构相对应, 本文分别设置了低 (low)、中 (mid) 和高 (high) 3 个层级 cell 对应的架构参数: $\alpha_l = \{\alpha_l^{(i,j)}\}$, $\alpha_m = \{\alpha_m^{(i,j)}\}$, $\alpha_h = \{\alpha_h^{(i,j)}\}$ 。超网络需要学习的架构参数矩阵则为 $\alpha_{all} = (\alpha_l \quad \alpha_m \quad \alpha_h)^T$ 。本文超网络的训练沿用 DARTS 的策略, 即在训练集上更新候选操作的卷积核参数 w , 在验证集上更新架构参数 α ^[8], 并采用 DARTS 的一阶近似优化算法训练超网络。超网络待优化的目标函数定义如下式所示:

$$\min_{\alpha_{all}} (L_{val}(w^*(\alpha_{all}), \alpha_{all})) \quad (3)$$

$$\text{s. t. } w^*(\alpha_{all}) = \arg \min_w L_{train}(w, \alpha_{all}) \quad (4)$$

式中: w 为卷积核参数, L_{train} 为训练集损失, L_{val} 为验证集损失, w^* 为使当前训练集损失最小的卷积核参数。超网络训练完成后, 按式 (5) 保留各级 cell 有向边中权重最大的候选操作。并沿用 DARTS 的派生策略, 保留中间结点含有候选操作权重 top-2 的边^[8], 得到最终的派生架构, 以构建评测网络。

$$o_k^{(i,j)} = \arg \max_{o_k \in O} \alpha_o^{(i,j)} \quad (5)$$

式中: $\alpha_o^{(i,j)}$ 为候选操作的权重, $o_k^{(i,j)}$ 为权重最大的候选操作。 $k \in \{l, m, h\}$, 为 cell 处于低、中、高层级的表示。 O 代表候选操作集合, 与 DARTS 算法一样包含 8 个候选操作^[8], o_k 代表集合 O 中的候选操作之一。

本文设计的 cell 分级的超网络, 从根本上改变了网络架构搜索空间的设置。按照文献[8]的计算方法, 本文超网络的搜索空间包含约 10^{63} 种形态的网络架构 (文献[8]为 10^{25} 种); 由派生 cell 构建的评测网络形成的空间, 包含约 10^{45} 种 (文献[8]为 10^{18} 种)。从搜索空间的规模上看, 本文远多于文献[8]。

这种设计的优点有: 1) 解除不同层级 cell 间的耦合; 2) 增加架构的多样性; 3) 超网络在架构搜索出现问题时, 有利于定位来源, 以便进一步优化。

当然, 搜索空间的指数级增涨, 也为搜索算法带来了巨大的挑战, 这便要求更有启发性的搜索策略以应对该挑战。

1.3 熵启发正则项

DARTS 算法搜索架构时, 超网络中各候选操作和架构参数以加权求和的方式对特征图作变换计算, 并在反向传播时被更新。搜索完成后, 根据该算法的派生规则^[8], 权重最大的架构参数对应的候选操作被认为对超网络的贡献最大, 因而在派生 cell 中保留下来, 其他候选操作则被遗弃。文献[16]指出, 这种派生操作造成了超网络与派生得到的架构在验证集上的表现出现“鸿沟” (gap) 问题, 即超网络在验证集上的准确率较高, 但派生得到的架构 (未重新训练时) 在验证集上的准确率与前者相差很大。文献[16]认为出现这种情况的原因是, DARTS 的超网络在搜索训练完成后, 每条边的架构参数分布仍然拥有相对较高的熵, 较高的熵意味着搜索方法对搜索到架构的确定性偏低。从这个环节看来, 以 L_{val} 优化超网络的架构参数 α 的过程中, 超网络中结点对之间的架构参数呈现独热向量形态时, 熵最低, 是最理想的优化结果。

本文构建的超网络, 沿用了 DARTS 算法的派生策略^[8], 所以架构派生也存在类似问题。受文献[16]启发, 本文将已归一化的架构参数向量与熵联系起来, 定义了架构熵, 见式 (6)。该指标衡量了搜索算法对搜索结果的确定性, 降低架构熵能提升超网络与派生架构在验证集上表现的相关性。

$$L_{entropy} = - \sum \bar{\alpha}_k^{(i,j)} \times \ln(\bar{\alpha}_k^{(i,j)}) \quad (6)$$

式中: $L_{entropy}$ 为架构熵, $\bar{\alpha}_k^{(i,j)}$ 为归一化的架构参数, $k \in \{l, m, h\}$ 为 cell 的层级。

以 $L_{entropy}$ 作为该目标函数的损失项, 可启发超网络在逐渐更新架构参数时, 兼顾架构参数的分布, 使架构参数在参数空间中向独热向量收敛。架构搜索环节, 超网络的目标函数由式 (3) 变为式 (7)。

$$\min_{\alpha_{all}} (L_{val}(w^*(\alpha_{all}), \alpha_{all}) + \gamma \times L_{entropy}) \quad (7)$$

式中 γ 为平衡 L_{val} 和 $L_{entropy}$ 的超参数, 其他变量与以

上公式定义一致。 γ 值的选择见 2.2 节。

2 实验及结果

本文搜索阶段实验采用的操作系统为 Windows 10, 处理器为 Intel i7-7800X, GPU 为 NVIDIA GeForce GTX 1080Ti。评测阶段实验采用的操作系统为 Ubuntu 16.04, 处理器为 Xeon E5, 训练和测试 CIFAR-10 使用的显卡为 NVIDIA GeForce GTX 1080Ti, 训练和测试 ImageNet 使用的显卡为 NVIDIA Titan RTX。编程语言均为 Python 3.6, 深度学习框架均为 Pytorch。

2.1 实验数据集

如 DARTS 等算法一样, 本文采用图像分类数据集 CIFAR-10^[14] 和 ImageNet 作为实验数据集。算法的架构搜索环节在 CIFAR-10 上完成, 并分别在 CIFAR-10 和 ImageNet 上进行架构评测。

CIFAR-10 数据集包含 60 000 张分辨率为 32×32 的图像, 共 10 类。其中训练集包含 50 000 张图像, 测试集包含 10 000 张图像。搜索架构时, 把训练集均分为两个子集(分别为 S_{train} 和 S_{val}), S_{train} 用于更新超网络中候选操作的卷积核参数 w , S_{val} 用于更新超网络中的架构参数 α ^[8]。搜索架构完成后, 以完整 cell 得到派生的 cell, 再以后者构建评测网络^[8]。评测网络在训练集上重新开始训练, 结束后在测试集上进行评测, 并以该测试准确率作为搜得架构的性能评价指标。在超网络训练和评测网络训练时, 测试集均未使用, 仅在测试评测网络时, 测试集才被使用。

ImageNet 是图像分类研究中最权威的常用数据集之一。其训练集包含约 128 万张图像, 验证集包含 50 000 张图像, 共 1 000 类。在该数据集上, 本文采用与 DARTS 等算法一样的实验设置, 通过剪切原图像得到分辨率为 224×224 的样本, 并将这些样本作为评测网络的输入, 对其进行训练和测试。

2.2 熵启发损失项的超参数选择

本文设计了实验, 以确定式(7)中熵启发损失项的超参数如何设置。如表 1 所示, 本文分别设置了 $\gamma = 0, 0.1, 1, 5, 10$, 共 5 组实验。每组重复进行 4 次完整的架构搜索与评测实验, 以评测结果的平均值作为该超参数选择的依据。由实验结果可知, 熵启发项的系数为 0 时, 超网络在 10^{63} 搜索空间中, 仅依靠可微分方法搜索网络架构具有一定的难度; $\gamma = 1$ 时, 搜得的架构表现最好; 当熵启发项的系数增大到 5 时, 损失函数中熵启发损失项所占比重过大, 影响了可微分方法的搜索。因此, 本文以 $\gamma = 1$ 作为熵启发项的超参数值。

表 1 γ 不同取值在 CIFAR-10 平均性能

Tab. 1 Average performance of different values of γ on CIFAR-10

超参数 γ	错误率/%
0	3.14
0.1	3.05
1	3.00
5	3.28
10	3.64

2.3 搜得的网络架构

本文的超网络按不同层级分级设置 cell, 相应地搜得的各级 cell 也可能不同。DARTS 搜得的架构仅包含一个 normal cell 和一个 reduction cell^[8], 而本文算法搜得的架构包含 3 个层级的 cell, 各级 cell 如图 5 所示。由于高层级 cell 与池化层相接, 所以不包含 reduction cell。

由图 5 所示, 本文采用分级超网络后, 搜得的架构解除了参数共享带来的耦合效应, 不同层级 cell 包含的 skip 操作仅影响本层级的 cell 结构。如图 5(a)所示, 该 cell 不包含 skip 操作, 而图 5(b)、图 5(c)各 cell 都含有两个 skip 操作。此外, DARTS 搜得的 normal cell 包含的候选操作类别较少, 分别是 sep_conv_3 $\times$ 3、dil_conv_3 $\times$ 3 和 skip_connect。而本文搜得的 cell, 包含的候选操作更加多样, 能提取更丰富的特征。

2.4 实验结果

2.4.1 CIFAR-10 实验结果

沿用 DARTS 算法的架构筛选策略^[8], 本文也重复了 4 次架构搜索实验, 并分别构建评测网络。在 CIFAR-10 上随机初始化卷积参数 w 后, 训练评测网络, 以最优测试结果的架构作为算法的最终架构。如表 2 所示, 以人工设计的 DenseNet^[3] 为基准, NAS 算法搜得的网络架构在 CIFAR-10 上都超越了该基准架构, 这表明了网络架构搜索算法的潜力。与其他自动搜索网络架构方法相比, 本文搜得的网络架构取得了具有竞争力的结果。

从测试错误率上看, 仅采用本文分级策略构建的超网络搜得的架构, 在 CIFAR-10 上的错误率为 2.88%, 优于 DARTS_V1^[8] 搜得的架构, 并与 SNAS^[16] 相近; 增加熵启发损失项后, 本文搜得架构的错误率进一步降低到 2.69%, 与 NASNet-A^[6] 相近。从参数量指标看, 与性能相近的 NASNet-A^[6] 相比, 本文架构的参数量更低。其原因是本文分级设置 cell 的超网络构建方法, 得到的 mid normal 和 high normal 两级 cell 的参数量都较低。同时, 本文采用 DARTS 算法的一阶近似优化策略, 搜索时间远

低于 NASNet-A^[6], 且与 P-DARTS^[15] 相近。综上, 实验结果证明了本文所提方法的有效性, 并且本文所

提方法计算资源需求低、分类表现好、搜得架构的参数量少。




图 5 分级超网络搜得的各级 cell(搜索采用了熵启发损失项)

Fig. 5 Cell architectures searched by proposed algorithm (search algorithm with entropy loss term)

表 2 搜得架构在 CIFAR-10 上与其他 NAS 算法搜得架构的性能对比

网络架构	错误率/%	参数量/ 10^6	搜索耗时/(GPU · d)	搜索方法
文献[3]	3.46	25.60		人工设计
文献[8]	3.00	3.30	1.5	基于梯度
文献[13]	2.89	4.60	0.5	强化学习
文献[16]	2.85	2.80	1.5	基于梯度
文献[6]	2.65	3.30	2 000.0	强化学习
文献[15]	2.50	3.40	0.3	基于梯度
本文	2.88	2.88	0.5	基于梯度
本文(熵启发)	2.69	2.95	0.5	基于梯度

2.4.2 ImageNet 实验结果

为了验证本文搜得架构的可迁移性, 本文进一步在 ImageNet 上进行了评测实验。构建评测网络的方式与 DARTS 算法保持一致, 即网络深度 $d = 14$, 网络初始通道数 $C_0 = 48$ 。该评测网络的训练采用与文献[15]相同的策略。沿用 DARTS 算法的限制条件, 本文也选择输入样本分辨率为 224×224 时, 运算乘加次数 $< 600 \times 10^6$ (移动设备运算要求) 的网络进行对比。本文架构及对比算法所得架构在 ImageNet 上的性能表现见表 3。其中, “ $\approx$ ” 表示约等于。

表 3 搜得架构在 ImageNet 与其他 NAS 算法搜得架构的性能对比

Tab.3 Performance comparison of architectures searched by proposed algorithm and other NAS methods on ImageNet

网络架构	错误率/%		参数量/ 10^6	搜索耗时/(GPU · d)	乘加次数/ 10^6	搜索方法
	前 1	前 5				
文献[22]	30.2	10.1	6.6		1 448	人工设计
文献[21]	29.4	10.5	4.2		569	人工设计
文献[23]	26.3		≈ 5.0		524	人工设计
文献[8]	26.7	8.7	4.7	1.5	574	基于梯度
文献[16]	27.3	9.2	4.3	1.5	522	基于梯度
文献[6]	26.0	8.4	5.3	2 000.0	564	强化学习
文献[15]	24.4	7.4	4.9	0.3	557	基于梯度
本文(熵启发)	25.9	8.1	4.3	0.5	533	基于梯度

以本文搜得架构构建的评测网络,在 ImageNet 上取得了 25.9% 的分类错误率,不仅优于 Inception^[22]、MobileNet^[21]、ShuffleNet^[23]等手工设计的网络架构,还优于 DARTS^[8]、SNAS^[16]等算法自动设计的网络架构,这表明了本文架构的可迁移性。同时本文评测网络的参数量仅为 4.3×10^6 ,比参数量相同的 SNAS^[16]分类错误率低 1.4%。与分类错误率相近的 NASNet-A^[6]相比,本文评测网络的参数量低 1.0×10^6 。本文评测网络的乘加次数也只有 533×10^6 ,但比乘加次数相近的 ShuffleNet^[23]和 SNAS^[16]有更好的分类性能。结合分类错误率、参数量和乘加次数 3 项指标,ImageNet 上的实验结果表明,本文搜得的架构具有更好的特征提取和图像分类能力。

3 结 论

设计了 cell 分级的超网络,对 DARTS 算法各层级 cell 存在耦合的现象进行了解耦。实验结果表明,采用本文设计的超网络,避免了架构参数共享引起的耦合效应,并提升了搜得架构的性能。引入熵启发的损失项后,降低了超网络与派生架构的“鸿沟”,进一步提升了搜得架构的表现。最后,本文按层级构建超网络和评测网络的设计,可启发探索新的网络架构搜索范式。

参考文献

- [1] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6): 84. DOI: 10.1145/3065386
- [2] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 770. DOI: 10.1109/CVPR.2016.90
- [3] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks [C]//Proceedings of the IEEE Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017: 4700. DOI: 10.1109/CVPR.2017.243
- [4] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]//Proceedings of the IEEE Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 7132. DOI: 10.1109/CVPR.2018.00745
- [5] ZOPH B, LE Q V. Neural architecture search with reinforcement learning [EB/OL]. [2017-02-15]. <https://arxiv.org/pdf/1611.01578>
- [6] ZOPH B, VASUDEVAN V, SHLENS J, et al. Learning transferable architectures for scalable image recognition [C]//Proceedings of the IEEE Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 8697. DOI: 10.1109/CVPR.2018.00907
- [7] REAL E, AGGARWAL A, HUANG Y, et al. Regularized evolution for image classifier architecture search [C]//Proceedings of the AAAI Conference on Artificial Intelligence. Honolulu: AAAI,

- 2019, 33: 4780. DOI: 10.1609/aaai.v33i01.33014780
- [8] LIU H, SIMONYAN K, YANG Y. DARTS: differentiable architecture search [EB/OL]. [2019-04-23]. <https://arxiv.org/abs/1806.09055>
- [9] LIU H, SIMONYAN K, VINYALS O, et al. Hierarchical representations for efficient architecture search [EB/OL]. [2018-02-22]. <https://arxiv.org/abs/1711.00436>
- [10] BROCK A, LIM T, RITCHIE J M, et al. SMASH: one-shot model architecture search through HyperNetworks [EB/OL]. [2017-08-17]. <https://arxiv.org/abs/1708.05344>
- [11] BAKER B, GUPTA O, RASKAR R, et al. Accelerating neural architecture search using performance prediction [EB/OL]. [2017-11-08]. <https://arxiv.org/abs/1705.10823>
- [12] RADOSAVOVIC I, KOSARAJU R P, GIRSHICK R, et al. Designing network design spaces [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020: 10428. DOI: 10.1109/CVPR42600.2020.01044
- [13] PHAM H, GUAN M Y, ZOPH B, et al. Efficient neural architecture search via parameter sharing [EB/OL]. [2018-02-12]. <https://arxiv.org/abs/1802.03268>
- [14] KRIZHEVSKY A, HINTON G. Learning multiple layers of features from tiny images [R]. Toronto: University of Toronto, 2009
- [15] CHEN X, XIE L, WU J, et al. Progressive differentiable architecture search: bridging the depth gap between search and evaluation [C]//Proceedings of the IEEE International Conference on Computer Vision. Long Beach: IEEE, 2019: 1294. DOI: 10.1109/ICCV.2019.00138
- [16] XIE S, ZHENG H, LIU C, et al. SNAS: stochastic neural architecture search [EB/OL]. [2019-01-12]. <https://arxiv.org/abs/1812.09926>
- [17] LIANG H, ZHANG S, SUN J, et al. DARTS+: Improved differentiable architecture search with early stopping [EB/OL]. [2020-10-20]. <https://arxiv.org/abs/1909.06035>
- [18] XU Y, XIE L, ZHANG X, et al. PC-DARTS: partial channel connections for memory-efficient differentiable architecture search [EB/OL]. [2020-04-07]. <https://arxiv.org/abs/1907.05737>
- [19] FANG J, SUN Y, ZHANG Q, et al. Densely connected search space for more flexible neural architecture search [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020: 10628. DOI: 10.1109/CVPR42600.2020.01064
- [20] WU B, DAI X, ZHANG P, et al. FBNet: hardware-aware efficient ConVnet design via differentiable neural architecture search [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE, 2019: 10734. DOI: 10.1109/CVPR.2019.01099
- [21] HOWARD A G, ZHU M, CHEN B, et al. MobileNets: efficient convolutional neural networks for mobile vision applications [EB/OL]. [2017-04-17]. <https://arxiv.org/abs/1704.04861>
- [22] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Boston: IEEE, 2015: 1. DOI: 10.1109/CVPR.2015.7298594
- [23] ZHANG X, ZHOU X, LIN M, et al. ShuffleNet: an extremely efficient convolutional neural network for mobile devices [C]//Proceedings of the IEEE conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 6848. DOI: 10.1109/CVPR.2018.00716