计算机系统应用 ISSN 1003-3254, CODEN CSAOBN
[doi: 10.15888/j.cnki.csa.009720] [CSTR: 32024.14.csa.009720]

E-mail: csa@iscas.ac.cn
http://www.c-s-a.org.cn
Tel: +86-10-62661041

基于金字塔池化权值印记的训练后混合精度量化算法①

张瑞轩, 赵宇峰, 徐　飞, 禹婷婷, 张乐怡

(西安工业大学 计算机科学与工程学院, 西安 710021)
通信作者: 赵宇峰, E-mail: zhang1136797763@qq.com

摘　要: 模型量化方法现已广泛应用于深度神经网络模型快速推理和部署中. 由于训练后量化重新训练所需时间少, 性能损失小而备受研究人员关注, 但现有训练后量化方法在量化过程中大多以理论假设或是固定分配网络层的比特位宽, 导致量化后的网络会出现显著的性能损失, 尤其是在低位情况下. 为了提升训练后量化网络模型的精度, 本文提出一种新颖的训练后混合精度量化方法 (MSQ), 该方法通过在网络模型每一层后插入一个融合了金字塔池化模块和权值印记技术的任务预测器模块, 来对网络每一层进行准确度估计, 从而评估每一层网络的重要性, 根据重要性评估来确定每一层的量化比特位宽. 实验表明, 本文所提出的 MSQ 算法在多个流行的网络架构上都优于现有的一些混合精度量化方法, 量化后的网络模型在边缘硬件设备上测试性能更好, 延迟更低.

关键词: 模型量化; 混合精度量化; 金字塔池化; 权值印记; 比特位宽分配

引用格式: 张瑞轩,赵宇峰,徐飞,禹婷婷,张乐怡.基于金字塔池化权值印记的训练后混合精度量化算法.计算机系统应用. http://www.c-s-a.org.cn/1003-3254/9720.html

Post-training Mixed-accuracy Quantization Algorithm Based on Pyramid-pooled Weight Imprinting

ZHANG Rui-Xuan, ZHAO Yu-Feng, XU Fei, YU Ting-Ting, ZHANG Le-Yi

(School of Computer Science and Engineering, Xi'an Technological University, Xi'an 710021, China)

Abstract: Model quantization is widely used for fast inference and deployment of deep neural network models. Post-training quantization has attracted much attention from researchers due to its reduced retraining time and low performance loss. However, most existing post-training quantization methods rely on theoretical assumptions or use fixed bit-width allocations for network layers during the quantization process, which results in significant performance loss in the quantized network, especially in low-bit scenarios. To improve the accuracy of post-training quantized network models, this study proposes a novel post-training mixed-accuracy quantization method (MSQ). This method estimates the accuracy of each layer of the network by inserting a task predictor module, which incorporates the pyramid pooling module and weight imprinting, after each layer of the network model. With the estimations, it assesses the importance of each layer of the network and determines the quantization bit-width of each layer based on the assessment. Experiments show that the MSQ algorithm proposed in this study outperforms some existing mixed-accuracy quantization methods on several popular network architectures, and the quantized network model tested on edge hardware devices shows better performance and lower latency.

Key words: model quantization; mixed-accuracy quantization; pyramid pooling; weight imprinting; bit-width allocation

① 基金项目: 陕西省科技厅区域创新能力引导计划 (2022QFY01-14)
收稿时间: 2024-05-29; 修改时间: 2024-06-26; 采用时间: 2024-07-11; csa 在线出版时间: 2024-10-31

1 引言

近年来, 随着人工智能科技的快速发展, 深度神经网络已成熟应用于各类计算机视觉任务中, 且都具有较高的预测精度. 由于深度学习模型通常含大量占用存储空间的参数, 在推理阶段也需要大量得计算资源, 从而难以部署在一些资源受限的嵌入式设备或者边缘端设备上. 因此, 研究人员针对深度卷积神经网络模型的压缩与加速方法展开了大量研究, 现有的一些模型压缩方法有: 网络剪枝, 模型量化, 知识蒸馏以及低秩分解等. 模型量化由于近年来新兴硬件加速支持低精度快速推理而引起研究人员的兴趣. 模型量化技术通常是将全精度模型 (FP32) 参数通过某种量化方法将其量化为整型低位 (INT8、INT4、INT2 等), 量化后的模型可以大幅减少模型的计算量和存储需求, 提升模型整体推理速度等. 通过模型量化技术, 可以满足边缘计算需求并优化能效, 将复杂的深度学习模型高效的部署在一些移动设备和物联网设备如智能手机手表、平板电脑、智能家居、传感器等.

模型量化技术在学术界和工业界的研究与应用已取得了不错的进展, 如 Google 等公司推出的量化白皮书[1], 系统阐述了模型量化过程和原理, 并通过大量实验和研究表明, 模型量化在模型训练和推理加速方面都取得了巨大成功. 还有 Qualcomm 公司推出的 AIMET (AI model efficiency toolkit)[2]和 NVIDIA 公司推出的 TensorRT[3]等模型量化部署框架, 可以将量化后模型更加快速稳定的应用在自动驾驶和智能交通等行业.

最近的一些量化方法大多是贴近工业应用的训练后量化, AdaRound[4]中利用泰勒展开方法分析量化带来的损失变化, 提出一种可学习的舍入取整来重建预训练模型特征的方法; 而文献[5]则认为 AdaRound 方法权值扰动较大, 因此使用 Gauss-Newton 矩阵分析二阶 Hessian 矩阵误差, 采用块重建的方式提出了 BRECQ 量化方法, 进一步提升训练后量化模型的精度; 在 PD-Quant[6]中发现现有的量化方法在确定量化参数时只考虑了局部信息, 并不能调解最佳量化参数, 从而提出一种使用量化前后的网络预测差异信息来确定量化参数的方法, 调整了 PTQ 中激活的分析, 缓解了过拟合问题. 然而, 对于训练后量化这种由人为或者简单的利用一些先验知识分配量化的比特位宽, 这可能是次优的且有偏差性, 会对模型的整体性能造成一定的损失.

由于神经网络模型中每一层网络具有不同的参数量和权值分布, 因此具有不同的量化敏感度, 通过优化网络模型中每一层的比特分布空间, 以此对网络每一层分配不同的量化位宽可能是更优的选择, 尤其是在低位量化的情况下. 所以, 在训练后量化过程中引入混合精度量化方法可以进一步提升网络模型性能. 在现有的训练后混合精度量化方法中, ZeroQ[7]算法使用知识蒸馏的思想来衡量网络模型每层的量化敏感度, 然后选择在模型特定约束条件下的总体量化敏感度最小的混合精度配置, 然而, 该方法是建立在假设其他层比特位宽选择不影响不同层的量化敏感度. AdaQuant[8]算法则是通过分析整数规划公式来分配每一层的量化比特位宽, 但在混合精度量化分配位宽过程中也没有考虑网络模型每一层之间的潜在影响. 因此, 在深度神经网络中更深层次的网络层必然会受到其他层的影响, 在训练后混合精度量化过程中, 我们要考虑网络每一层之间的关系并选择合适的度量标准来以此决定不同层的量化位宽.

在本文中, 我们提出一种基于金字塔池化权值印记的训练后混合精度搜索量化算法—MSQ (mixed-precision search quantization), 该算法从任务精度的角度来确定网络层的比特位宽, 具有更好的解释性. MSQ 通过在网络模型每一层后面加入一个改进的任务预测器模块来估计当前层的精度收益, 对低精度收益的网络层会降低量化比特并重新进行量化校准过程.

如图 1 所示, 改进的任务预测器模块结合了任务预测器模块、金字塔池化模块以及权值印记技术. 由于原始任务预测器模块只能单一的捕获网络每一层的参数信息, 在训练过程中无法衡量网络每一层的精度增益, 因此将金字塔池化模块[9]融入到任务预测器模块中, 用于提取网络模型中全局特征信息和局部细节信息进行分析, 并引入权值印记 (weight imprinting) 技术[10]来近似任务预测器模块中全连接层的权值, 其中, 印记就是用样本的特征来当作分类器对应类别的权值, 以解决在训练后量化过程中没有足够的训练数据和大量的计算资源, 从而无法准确获取网络模型每层网络的精度增益问题.

综上所述, 本文的主要贡献如下.

(1) 本文提出一种融合金字塔池化模块和权值印记技术的混合精度搜索量化方法 MSQ, 利用精度估计的思想对网络层进行评估, 以混合精度的优势来实现

训练后量化最终对模网络型的压缩效果. 相比一些现有的混合精度方法, MSQ 方法能够更好地度量网络每一层的比特位宽分配.

(2) 本文对现有的一些网络架构在 ImageNet 和 CIFAR-10 数据集上进行量化实验, 并在边缘硬件设备上进行测试, 在相似的实验约束下, 与一些 SOTA 量化方法进行对比, 经过 MSQ 量化后的网络模型整体性能更好. 此外, 在对一些网络模型混合精度量化与固定量化方法进行对比分析, 发现 MSQ 在整体量化过程中效果更佳.

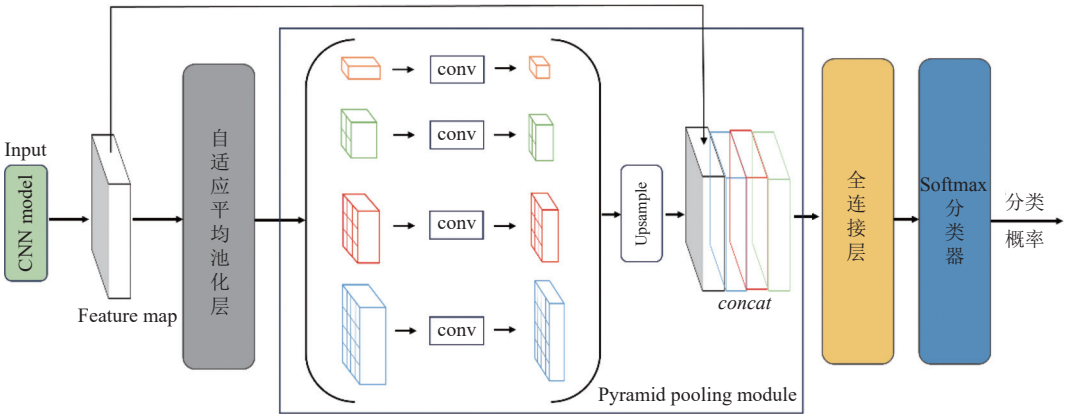

图 1 改进任务预测器模块

2 相关工作

模型量化技术一般可以分为量化感知训练和训练后量化两种类型. 量化感知训练一般是解决在量化过程中对神经网络模型的权值和激活值所造成的误差, 通过梯度下降等优化方法对量化模型进行重新训练, 从而使量化模型在优化过程中收敛到一个局部最优点. 目前一些较优的量化感知训练方法有: Esser 等人研究出可学习步长量化 LSQ[11]及其改进方法 LSQ+[12], 给出了数值在截断范围内外通过直通估计器的梯度. Liu 等人[13]提出使用自适应的直通估计器来进行梯度估计, 使其在训练过程中能够更准确地估计有利于量化神经网络优化的反向传播的梯度, 在低位宽量化达到了接近全精度网络模型的效果.

量化感知训练方法在训练过程中需要消耗大量计算、时间成本, 以及对数据集的高度依赖性, 使得网络模型难以快速部署到硬件边缘设备上, 因此, 人们对不需要对神经网络模型进行重新训练的训练后量化方法研究更多. 近年来, 基于重建的训练后量化方法不断突破低位量化的极限, 已成为目前训练后量化的主流方法之一.

AdaRound[4]使用泰勒展开式对全局损失进行二阶近似, 将全局损失转化为海森矩阵形式, 最终将对全局损失的优化问题转化为对每个参数层输出的均方误差的优化问题. 至此之后, 以自适应舍入的方式来优化量化效果的研究方法不断涌现. AdaQuant[8]方法将自适应舍入的范围扩大到了整个量化电平内; AQuant[14]为解决激活舍入的动态性问题, 在推理阶段通过一个简单的函数自适应的调整舍入边界, 以此来生成舍入方案; AttentionRound[15]基于高斯分布来确定舍入的取值在量化电平内的分布; 块级重建量化 BRECQ 在 AdaRound 的基础上, 提出将输出重建的优化粒度扩大到块级, 并引入了 Fisher 信息矩阵来提供更多权值参数之间的相关信息. QDrop[16]在输出重建的优化过程中同时进行对激活值量化, 使极低位宽下的优化损失平面变得平滑, 更有利于模型收敛. 此外, RAPQ[17]将 BRECQ 方法扩展到全整形量化来弥补精度损失; Mr. BiQ[18]则将 BRECQ 方法扩展到了非均匀量化, 以及 NWQ[19]通过激活正则化技术缓解了过拟合问题, 该技术更好地控制了激活分布.

在上述量化方法中, 采用固定位宽分配策略往往不能达到网络模型的最佳性能, 原因是不同的网络层对整个网络模型的推理时间和任务性能有不同的影响. 因此, 选择混合精度量化能够达到更优的量化效果. HAQ[20]提出了一种硬件感知的量化算法, 将硬件模拟器评估的推理速度信息反馈到训练周期中, 并主要通过深度强化学习来逐层分配位宽. HAWQ[21]提出一种基于海森矩阵特征值来计算每个网络层量化敏感度的方法, 以此决定不同网络层的量化位宽; TRQ[22]将权值

主体和残差部分进行二值化, 实现权值主体的重建, 提高量化模型任务性能; BSQ[23]将每一位量化权重视为独立的训练变量, 引入可微位稀疏正则化, 从诱导位级稀疏性的角度处理混合精度量化; FBM[24]通过模拟特定设备测量每层网络来找到最佳位宽分配; SAQ[25]提出锐度感知量化, 通过同时最小化损失值和损失曲率来提高模型的泛化性能; 以及随机可微量化 SDQ[26]在更加灵活和全局优化的空间中自动学习混合精度量化略, 在 SDQ 中将混合精度量化分为 3 类; 基于搜索的方法、基于度量的方法和基于优化的方法, 并指出 SDQ 属于量化感知训练和基于优化的混合精度方法, 根据 SDQ 对量化方法的分类, 本文的 MSQ 属于训练后量化和基于度量的混合精度方法.

3 方法

3.1 先验知识

在本节中, 首先根据文献[1]中的量化基本公式 (假设采用 8 位的非对称量化) 介绍模型量化的基本原理.

$$r = S(q - z) \tag{1}$$

$$q = clip\left(Round\left(\frac{r}{S} + Z\right), 0, 255\right) \tag{2}$$

其中, r和q分别表示量化前的浮点数和量化后的整数. S 和Z表示量化过程中的两个重要量化参数 scale 和 zero point. $Round$和$clip$分别表示四舍五入和截断操作. $r_{\min}$、 $r_{\max}$、 $q_{\min}$、 $q_{\max}$分别表示浮点数r和整数q的取值范围.

S、Z、$r_{\min}$、 $r_{\max}$是量化过程中 4 个最重要的量化参数, 几乎所有的训练后量化都是寻找这几个参数的优化方法, 这 4 个参数可以通过式 (3)、式 (4) 进行相互转换.

$$S = \frac{r_{\max} - r_{\min}}{q_{\max} - q_{\min}} \tag{3}$$

$$Z = clip\left(Round\left(q_{\max} - \frac{r_{\max}}{S}\right), 0, 255\right) \tag{4}$$

量化方法确定后, $q_{\min}$和$q_{\max}$的值就可以确定下来, 以 8-bit 量化为例, 量化后的数值范围一般就是 0–255, 即 $q_{\max}$=255, $q_{\min}$=0.

在训练后量化的过程中, 需要采用合适的量化策略来寻找量化参数, 以搜索最佳S和Z为例, 根据量化前后的信息损失来找出最优解.

假设量化前的浮点权值参数为r, 则量化后为式 (2), 再进行反量化可得:

$$\bar{r} = S \times (q - Z) = S \times \left(clip\left(Round\left(\frac{r}{S} + Z\right), 0, 255\right) - Z\right) \tag{5}$$

接下来度量量化信息损失, 以 EasyQuant[27]中的余弦相似性方法进行度量, 假设校正数据集共有N个样本, 则平均相似性为:

$$\frac{1}{N}\sum_i^N \cos(r_i, \bar{r}_i) = \frac{1}{N}\sum_i^N \frac{r_i \bar{r}_i}{\|r_i\|\|\bar{r}_i\|} \tag{6}$$

那么所要求解的就是使得相似性最大的S和Z (余弦相似性越大, 信息损失越小):

$$\max_{S,Z} \frac{1}{N}\sum_i^N \frac{r_i \bar{r}_i}{\|r_i\|\|\bar{r}_i\|} \tag{7}$$

在本文中, 首先通过上述训练后量化过程对一些网络模型进行量化, 再使用本文提出的混合精度搜索策略 (见第 3.2 节) 分配量化比特位宽, 从而得到最终量化结果. 此外, 我们还采用 AdaRound 和 PD-Quant 方法为本文训练后量化方法. AdaRound 量化方法大大降低了过拟合敏感度, 可以在非常小的校准集上使用, 并且在 ResNet50 上实现了所有层权重和激活 4 位量化, 精度下降不到 1%. 因此 AdaRound 量化后的网络模型更加适配本文所提出的混合精度搜索策略, 且在量化后精度对比方面可以更加体现出 MSQ 的优越性. 而 PD-Quant 是在低比特设置下仍有较高预测精度的量化方法, 以此作为本文训练后量化可以验证 MSQ 在低比特位时的有效性.

3.2 混合精度搜索策略

在网络模型每层后面插入一个任务预测器模块可以准确测量每一层网络的参数冗余度. 该模块由自适应平均池化层、一个或多个全连接层以及 Softmax 分类器组成. 在训练过程中, 该模块的参数会根据新任务的数据进行更新, 并学习新任务的特定特征. 通过在原始训练集上对其参数进行训练更新, 由训练完成后所得到的精度增益来对网络中的所有层进行排序.在训练后量化的过程中, 由于训练数据有限且计算资源不够充分没导致无法完成上述过程. 为了在训练后量化过程中准确地获取网络模型中每层网络的精度增益, 我们引入权值印记技术来近似任务预测器模块中全连接层的权值, 该过程无需对网络进行端到端的训练.

权值印记技术[10]是一种在小样本学习领域将 CNN 分类器和嵌入方法结合起来, 通过直接将样本的高维

嵌入特征设置为分类器的权值, 使得网络模型可以识别一些新的样本类别.

从本质上讲, 权值印记技术就是通过在卷积神经网络中的激活特征值在小样本数据上做一些合适的缩放操作, 那么就可以直接为新类别设置合适的分类权值. 其实也就是利用了全连接层中归一化输入和权值之间的对称性, 将新样本的嵌入特征复制到一组新的网络权值中. 此外, 将每一个任务预测器模块中的全连接层权值矩阵看作是对应类别的模板, 在网络的前向推理过程中, 首先得到输入待预测样本图片在网络中的高维嵌入特征$\varphi(x)$, 然后再和权值矩阵中的每一列W_c做内积, 该过程等价于在嵌入空间中用最近邻方法找到某个类别的模板[9], 即:

$$y=\arg\max_{c\in C} W_c^{\mathrm{T}}\varphi(\mathrm{x})=\arg\min_{c\in C} Dist(\varphi(x),W_c) \tag{8}$$

其中, $Dist$函数指的是最邻近方法, $\arg\max$和$\arg\min$表示该函数取最大值或最小值时变量的取值. 与其他最邻近模型相比, 权值印记技术不需要存储大量参数样本数据, 只需要为每个类别存储一个模版即可.

在一般情况下, 上述权值印记过程需要足够多的训练样本数据才能达到不错的效果, 而在一些现实场景中并不是所有训练数据都可以使用. 因此, 本文提出一种金字塔池化权值印记方法, 该方法通过将金字塔池化模块引入到任务预测器模块中, 使得不同网络层在做权值印记时的嵌入特征保持一致, 并且能够更加充分的利用有限的训练数据, 从而更加准确的度量网络中每一层的精度增益.

金字塔池化[9]是一种可以聚合不同区域的上下文信息, 以提高网络获取全局信息能力的模块. 其具体做法是在原始特征图上采用不同尺度的池化, 得到多个不同尺寸的特征图, 再在通道维度上拼接这些特征图, 最终输出一个融合了多种尺度的复杂特征图, 从而达到兼顾全局信息与局部细节信息的目的.

基于结合金字塔池化模块与权值印记技术的任务预测器, 如图 1 所示, 通过以下过程来度量网络层的精度增益.

首先, 对由卷积层所提取到的 feature map 进行d种不同尺度的自适应平均池化操作, 则通过池化操作得到的不同统计量下数据样本的特征为e_i^d:

$$e_i^d = AdaptiveAvgpool(F_i,d) \tag{9}$$

其中, d表示不同维度的特征($d\in N^+$), F_i表示网络第i层输出的激活特征图. $AdaptiveAvgpool$保证了不同网络层产生相同大小的特征, 进而确保在做权值印记时所有网络层的特征维度一致.

为了便于计算在任务预测分类器模块中全连接层的权值矩阵, 对统计到的高维特征进行维度变化, 将其转变为一维向量, 然后用来计算全连接层中的权值矩阵W_i^d:

$$W_i^d[:,C]=\frac{\sum_{j=1}^{Num_c} Conf(x^{(j)})e_{i,j}^d}{\sum_{j=1}^{Num_c} Conf(x^{(j)})} \tag{10}$$

其中, C是类别样本, $x^{(j)}$和Num_c分别代表校准数据集中的第j个样本和类别C的总样本数, $Conf(x^{(j)})$表示目标网络对该样本$x^{(j)}$预测分类的概率.

利用校准数据集对目标网络进行前向计算得到任务预测器模块中全连接层的权值矩阵W_i^d之后, 为了估计目标网络每一层的精度增益, 我们使用验证集来逐层计算任务预测器模块所得到的预测精度. 通过池化后的 feature map 的特征维度各不相同, 在金字塔池化模块中, 池化后的特征图通过双线性插值上采样将所有特征维度变为一致, 再通过$concat$对这些不同维度的特征信息进行融合拼接操作, 即:

$$e_i^{\mathrm{fuse}} = concat(e_i^1,e_i^2,\cdots,e_i^n) \tag{11}$$

使用融合后的特征信息对权值矩阵W_i^d进行查询, 进而可以计算出每个网络层对应任务预测分类器模块的预测精度, 查询结果记为$S_{i,j}^d$:

$$S_{i,j}^d = W_i^d e_{i,j}^{\mathrm{fuse}} (d=1,2,\cdots,n) \tag{12}$$

对查询结果值利用 Softmax 操作将其转换为对应物体类别的概率向量:

$$P_{i,j}^d[k]=\frac{\exp(S_{i,j}^d[k])}{\sum_{k=1}^{nclass}\exp(S_{i,j}^d[k])} \tag{13}$$

其中, $nclass$表示每类样本的个数. 由于熵值反映一个概率分布的确定性和信息量, 我们使用熵衡量概率向量的信息量, 以对上述结果进行进一步融合:

$$H_{i,j}^d = -\sum_{k=1}^{nclass} p_{i,j}^d[k]\log(p_{i,j}^d[k]) \tag{14}$$

熵值越大, 确定性和信息量就越大, 反之同理. 因此我们对最后查询结果值$S_{i,j}^d$进行融合时, 利用其熵值进行归一化处理, 再进行加权求和:

$$S_{i,j}=\frac{H_{i,j}^{1}S_{i,j}^{1}+H_{i,j}^{2}S_{i,j}^{2}+\cdots+H_{i,j}^{n}S_{i,j}^{n}}{H_{i,j}^{1}+H_{i,j}^{2}+\cdots+H_{i,j}^{n}} \tag{15}$$

以$S_{i,j}$中元素值最大项所对应的类别作为预测结果, 并与验证集样本x_j的真实标签类别计算精度. 通过对验证集中所有样本进行以上操作, 即可统计到每个网络层相关的任务预测器模块的分类精度.

3.3 MSQ

基于上述所提出的训练后量化策略和混合精度搜索策略, 本文提出一种用于调整训练后量化比特位宽的混合精度搜索算法 (MSQ), 通过引入精度估计的思想, 使用金字塔池化权值印记度量策略来获取量化网络每一层的精度增益, 并对其全局进行排序, 从而确定量化网络中每一层的量化比特位宽. 在训练后混合精度比特搜索过程中, 对每一次迭代更新后所得的混合精度配置MPC_{cur}, 使用训练后量化方法在校准数据集D_{cali}上对该配置下的混合精度模型进行校准, 详细算法过程如算法 1.

算法 1. MSQ 算法

输入: 校准数据集D_{cali}和验证数据集D_{val}, 最高和最低量化比特$B_{\max}$和$B_{\min}$.

初始化: 设置所有网络层权值和激活值比特位宽为$B_{\max}$, 记为MPC_{cur}. While 混合精度配置MPC_{cur}下的模型参数量大于期望模型的参数量; do

1) 在网络当前混合精度配置MPC_{cur}下, 对校准数据集D_{cali}上对网络模型进行训练后量化;

2) 采用金字塔池化权值印记混合精度搜索策略在验证数据集D_{val}上得到与每一个网络层相关的任务预测器模块分类精度$Acca=(Acc_1,Acc_2,\cdots,Acc_N)$;

3) 计算量化网络模型每一层的精度增益$Diff=(\|Acc_i-Acc_{i-1}\|, \forall i\in[2,N])$;

4) 查询 Diff 最小值对应下标$idx=\arg\min(Diff)$, 若$MPC_{\text{cur}}[idx]=B_{\min}$, 则继续搜寻次小值所对应下标;

5) 更新第idx+1层权值和激活值比特位宽$MPC_{\text{cur}}[\text{idx}]=MPC_{\text{cur}}[idx]-1$;

6) 保存当前网络的混合精度配置MPC_{cur}.

输出: 目标网络在不同参数量下混合精度配置集合$MPCa=\{MPC_1, MPC_2,\cdots\}$.

与 ZeroQ 算法中使用的量化敏感度指标和 AdaQuant 算法中使用的整数线性规划方法相比, MSQ 算法的准确率感知标准可以更加准确地获得不同网络层的比特位宽, 并从任务精度的角度来度量网络层的重要性, 因而具有更好的解释性.

4 实验设置与结果

本文使用 ResNet18/20/50[28] 和 MobileNet-V2 [29] 等模型作为量化架构, 并在不同压缩率下进行了验证实验, 其中所有全精度预训练模型均来自文献 [4,5], 量化数据集包括 ImageNet、CIFAR-10 等. 用于实验的服务器配备了 NVIDIA GeForce RTX 3080 Ti GPU、11 GB 显存和 256 GB 内存.

在训练后量化过程中, 从原始数据集的所有类别中选取适当数量的图像样本作为校准数据集, 并保持与文献 [1,4,6] 所用方法相同的量化设置. 在训练后的混合精度搜索中, 对校准数据集中的样本进行随机裁剪和水平翻转等数据扩增, 然后再执行金字塔池化权重印记度量. 通过与现有的 SOTA 方法进行比较, 验证了 MSQ 的优越性.

4.1 MSQ 在 CIFAR-10 数据集上实验

如第 3.1 节所述, 首先以 EasyQuant[23]中余弦相似性作为训练后量化方法, 在训练后量化过程中使用 MSQ 进行混合精度搜索分配比特位宽, 表 1 展示了 MSQ 在 CIFAR-10 数据集上使用 ResNet20 网络与现有的一些量化方法进行比较.

表 1 CIFAR-10 上 MSQ 与一些混合精度量化方法的比较

方法	Bit-width (W/A)	Mixed	Top-1 *Acc* (%)	压缩比	FP Top-1 *Acc* (%)
PACT	2/32	—	89.7	16×	
LQnet	2/32	—	91.1	16×	
TTQ	2/32	√	91.2	16×	92.4
Uhlich	2/32	√	91.4	16×	
DDQ	2/32	√	91.6	16×	
MSQ	1.97/32	√	91.8	16.67×	

表 1 中, Bit-width (W/A) 表示权重和激活值量化的比特位宽, Mixed 表示是否为混合精度量化, FP Top-1 *Acc* 表示全精度模型精确度. 将权重同样量化到 2 位以下以此来验证 MSQ, 可以看出 MSQ 方法相较于一些固定量化方法和混合精度量化方法在压缩比更高的情况下精确度也更高.

4.2 MSQ 在 ImageNet 数据集上实验

表 2 是在 ImageNet 数据集中 MSQ 方法与一些现有的 SOTA 量化方法实验比较结果. 其中, MP 表示混合精度量化, MSQ[Ada]和 MSQ[PD]分别表示使用第 3.1 节所述的 AdaRound 和 PD-Quant 训练后量化方法, 在量化过程中再使用 MSQ 进行混合精度搜索分配比特位宽, 以此来验证本文所提出的训练后混合精度量化方法的有效性.

从表 2 中可以看出, 将各类网络模型的激活值和

权值进行 4-bit 量化时, MSQ 相比原训练后量化方法在实现更高压缩比情况下, 精度也都有所提升, 尤其是在轻量级神经网络模型 MobileNet-V2 中, 经过 MSQ 混合精度搜索后的 PD-Quant 精度提升 0.92%. 在权值和激活值的平均比特大约为 3-bit 低比特位量化中, MSQ 对 ResNet18 和 ResNet50 网络实现了 10.87 倍和 10.96 倍更高压缩比, 且与 AdaRound 原始量化方法相比, 模型精度均提升了近 2% 左右, 在 MSQ 对 PD-Quant 量化方法进行混合精度搜索后, ResNet50 达到 70.25% 的 Top-1 精度, 而轻量化神经网络 MobileNet-V2 也取得了 60.04% 的精度以及 11.23 倍的高压缩比. 在更低位的 2-bit 量化中, MSQ 算法也展现出其强大的性能, 虽然压缩比有所减小, 但所有模型的 Top-1 精度均有所提升. 可见, 无论是与低位或是更低位的量化方法相比, MSQ 始终具有不错的性能效果.

为了进一步验证混合精度量化之后对网络模型带来的性能提升, 在图 2 中比较了 MSQ 混合精度量化和固定精度量化 (Base) 的差异, 并采用了 MSQ[Ada]对 ResNet50 网络模型在不同大小下进行混合精度搜索配置.

表 2 MSQ 与其他量化方法在 ImageNet 数据集上的性能比较

方法	Bit-width		ResNet18		ResNet50		MobileNet-V2	
	W-Bits	A-Bits	Top-1 *Acc*	压缩比	Top-1 *Acc*	压缩比	Top-1 *Acc*	压缩比
FP Top-1 *Acc*	32	32	71.08	1.0×	77.00	1.0×	72.49	1.0×
ZeroQ	4	4	21.71	8.0×	2.94	8.0×	26.24	8.0×
AdaQuant	4	4	69.60	8.0×	75.22	8.0×	47.16	8.0×
AdaRound	4	4	69.36	8.0×	74.76	8.0×	64.33	8.0×
BRECQ	4	4	69.60	8.0×	75.06	8.0×	66.57	8.0×
PD-Quant	4	4	69.23	8.0×	75.16	8.0×	68.19	8.0×
MSQ[Ada]	MP	MP	69.22	8.14×	75.27	8.42×	66.02	8.22×
MSQ[PD]	MP	MP	69.26	8.14×	75.20	8.42×	69.11	8.22×
AdaQuant	3	3	64.66	10.67×	66.66	10.67×	15.20	10.67×
AdaRound	3	3	60.09	10.67×	67.46	10.67×	2.23	10.67×
BRECQ	3	3	65.76	10.67×	68.96	10.67×	23.41	10.67×
MSQ[Ada]	MP	MP	62.31	10.87×	69.10	10.96×	—	—
MSQ[PD]	MP	MP	65.81	10.87×	70.25	10.96×	60.04	11.23×
BRECQ	2	2	45.54	16×	29.01	16×	0.24	16×
PD-Quant	2	2	53.14	16×	57.16	16×	13.76	16×
MSQ[PD]	MP	MP	55.06	15.6×	60.02	15.2×	21.33	15.59×

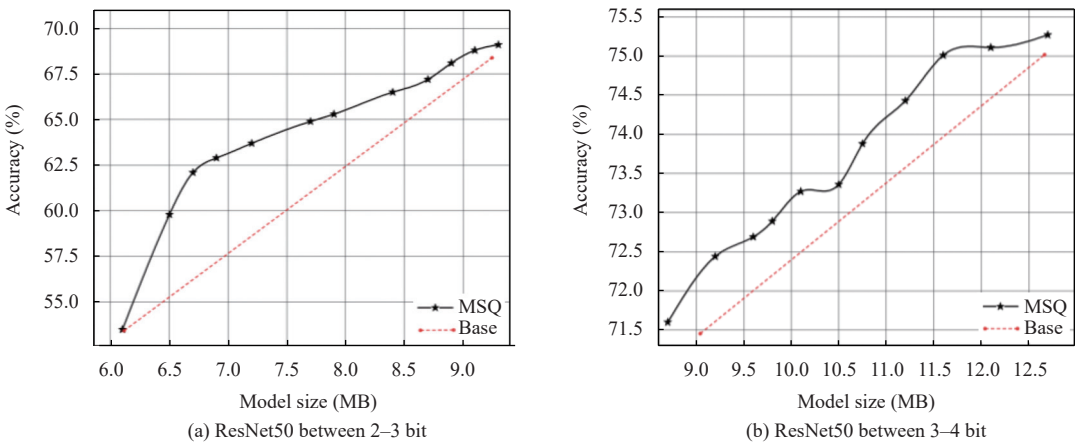

(a) ResNet50 between 2–3 bit (b) ResNet50 between 3–4 bit

图 2 ResNet50 在 ImageNet 上混合精度和固定精度量化比较

从图 2 中可以看出, 无论是在低位或更低位量化过程中, 混合精度量化网络模型始终整体优于固定量化网络模型, 因此, 混合精度量化由于其可以拥有不同模型大小的比特配置, 可以更加灵活高效的适用于不同的边缘设备端.

4.3 在硬件设备上评估结果

本文将量化后的 ResNet50 网络模型部署在边缘硬件设备上评估其性能, 所使用硬件设备是 NIVIDIA

公司的边缘硬件设备 Jetson Nano 作为验证实验平台, 操作系统为以 Linux 为内核的 Ubuntu 系统, GPU 采用 Maxwell 架构, 浮点计算速度为 0.5 TFLOPs, CPU 为 Cortex-A57 MPCore 处理器, eMMC5.1-16 GB 内存. 主要测试 ResNet50 网络模型在使用混合精度量化后部署在硬件设备边缘设备端的时延对比.

表 3 中使用了 MSQ 混合精度量化方法以及 AdaRound 和 PD-Quant 训练后量化方法对 ResNet50 进行量化部署, 通过对比可以发现, MSQ 在实现更高量化压缩比的情况下, 时延得到大幅提升. 近年来, 资源受限的边缘硬件设备在我们的生活中越来越多, 设计更加高效的模型量化方法, 可以更好地满足我们的生活所需. MSQ 在边缘硬件设备端的表现, 更加体现出混合精度量化的优越性与高效性, 在后续的工作中, 我们会验证 MSQ 量化方法到更多的主流网络模型中, 并在更多的硬件设备中测试效果.

表 3 MSQ 在边缘硬件设备端上的性能分析

方法	压缩比	Top-1 *Acc*	延迟 (ms)
AdaRound	8×	74.76	26.22
MSQ[Ada]	8.42×	75.27	9.31
PD-Quant	8×	75.16	19.67
MSQ[PD]	8.42×	75.20	6.54

5 总结

本文通过分析现有的训练后混合精度量化方法中忽略对网络模型层与层之间存在潜在影响, 从而导致网络层比特位宽分配存在分配不当等问题, 提出一种基于金字塔池化权值印记技术的训练后混合精度量化算法 (MSQ), 以精度估计的思想更好的度量网络每一层的精度增益, 从而提供了一个可以评判网络模型每一层量化敏感度的标准, 以该标准搜索网络层的比特位宽并进行分配, 可以提升训练后量化模型的整体性能. 通过在 CIFAR-10 和 ImageNet 数据集上对不同网络模型架构进行实验验证, 证明了 MSQ 混合精度搜索算法的高效性, 且经过 MSQ 量化后的网络模型由于可以有不同的比特位宽, 在部署到一些硬件或者边缘端设备上时更具鲁棒性.

参考文献

1 Krishnamoorthi R. Quantizing deep convolutional networks for efficient inference: A whitepaper. arXiv:1806.08342, 2018.

2 Siddegowda S, Fournarakis M, Nagel M, *et al*. Neural network quantization with AI model efficiency toolkit (AIMET). arXiv:2201.08442, 2022.

3 Reed JK, DeVito Z, He H, *et al*. torch.fx: Practical program capture and transformation for deep learning in Python. Proceedings of the 5th Machine Learning and Systems. Santa Clara: mlsys.org, 2022. 638–651.

4 Nagel M, Amjad RA, van Baalen M, *et al*. Up or down? adaptive rounding for post-training quantization. Proceedings of the 37th International Conference on Machine Learning. JMLR.org, 2020. 667.

5 Li YH, Gong RH, Tan X, *et al*. BRECQ: Pushing the limit of post-training quantization by block reconstruction. Proceedings of the 9th International Conference on Learning Representations. OpenReview.net, 2021.

6 Liu JW, Niu L, Yuan ZH, *et al*. PD-quant: Post-training quantization based on prediction difference metric. Proceedings of the 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver: IEEE, 2023. 24427–24437.

7 Cai YH, Yao ZW, Dong Z, *et al*. ZeroQ: A novel zero shot quantization framework. Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020. 13166–13175.

8 Hubara I, Nahshan Y, Hanani Y, *et al*. Improving post training neural quantization: Layer-wise calibration and integer programming. arXiv:2006.10518, 2020.

9 Zhao HS, Shi JP, Qi XJ, *et al*. Pyramid scene parsing network. Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017. 6230–6239.

10 Qi H, Brown M, Lowe DG. Low-shot learning with imprinted weights. Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Lake City: IEEE, 2018. 5822–5830.

11 Esser SK, McKinstry JL, Bablani D, *et al*. Learned step size quantization. Proceedings of the 8th International Conference on Learning Representations. Addis Ababa: OpenReview.net, 2020.

12 Bhalgat Y, Lee J, Nagel M, *et al*. LSQ+: Improving low-bit quantization through learnable offsets and better initialization. Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Seattle: IEEE, 2020. 2978–2985.

13 Liu ZG, Mattina M. Learning low-precision neural networks without straight-through estimator (STE). Proceedings of the

28th International Joint Conference on Artificial Intelligence. Macao: ijcai.org, 2019. 3066–3072.

14 Li ZY, Guo C, Zhu ZD, *et al*. Efficient adaptive activation rounding for post-training quantization. arXiv:2208.11945, 2022.

15 Diao HB, Li GY, Xu SY, *et al*. Attention Round for post-training quantization. Neurocomputing, 2024, 565: 127012. [doi: 10.1016/j.neucom.2023.127012]

16 Wei XY, Gong RH, Li YH, *et al*. QDrop: Randomly dropping quantization for extremely low-bit post-training quantization. Proceedings of the 10th International Conference on Learning Representations. OpenReview.net, 2022.

17 Yao HY, Li P, Cao J, *et al*. RAPQ: Rescuing accuracy for power-of-two low-bit post-training quantization. Proceedings of the 31st International Joint Conference on Artificial Intelligence. ijcai.org, 2022. 1573–1579.

18 Jeon Y, Lee C, Cho E, *et al*. Mr. BiQ: Post-training non-uniform quantization based on minimizing the reconstruction error. Proceedings of the 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans: IEEE, 2022. 12319–12328.

19 Wang CB, Zheng DD, Liu YL, *et al*. Leveraging inter-layer dependency for post-training quantization. Proceedings of the 36th International Conference on Neural Information Processing Systems. New Orleans: Curran Associates Inc., 2022. 483.

20 Wang K, Liu ZJ, Lin YJ, *et al*. HAQ: Hardware-aware automated quantization with mixed precision. Proceedings of the 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE, 2019. 8604–8612.

21 Dong Z, Yao ZW, Gholami A, *et al*. HAWQ: Hessian aware quantization of neural networks with mixed-precision. Proceedings of the 2019 IEEE/CVF International Conference on Computer Vision. Seoul: IEEE, 2019. 293–302.

22 Li Y, Ding WR, Liu CL, *et al*. TRQ: Ternary neural networks with residual quantization. Proceedings of the 35th AAAI Conference on Artificial Intelligence. AAAI, 2021. 8538–8546.

23 Yang HR, Duan L, Chen YR, *et al*. BSQ: Exploring bit-level sparsity for mixed-precision neural network quantization. Proceedings of the 9th International Conference on Learning Representations. OpenReview.net, 2021.

24 Kimhi M, Rozen T, Kopetz T, *et al*. FBM: Fast-bit allocation for mixed-precision quantization. arXiv:2205.15437, 2022.

25 Liu J, Cai JF, Zhuang BH. Sharpness-aware quantization for deep neural networks. arXiv:2111.12273, 2021.

26 Huang XJ, Shen ZQ, Li SC, *et al*. SDQ: Stochastic differentiable quantization with mixed precision. Proceedings of the 39th International Conference on Machine Learning. Baltimore: PMLR, 2022. 9295–9309.

27 Wu D, Tang Q, Zhao YL, *et al*. EasyQuant: Post-training quantization via scale optimization. arXiv:2006.16669, 2020.

28 He KM, Zhang XY, Ren SQ, *et al*. Deep residual learning for image recognition. Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016. 770–778.

29 Sandler M, Howard A, Zhu ML, *et al*. MobileNet-V2: Inverted residuals and linear bottlenecks. Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018. 4510–4520.

(校对责编: 张重毅)