

光学学报

一种优化的可拓展激光雷达点云可学习二值量化网络

赵志^{1*}, 马燕新², 许可¹, 万建伟¹

¹ 国防科技大学电子科学学院, 湖南 长沙 410073;

² 国防科技大学气象海洋学院, 湖南 长沙 410073

摘要 为解决激光雷达点云深度学习网络模型在移动端嵌入式设备部署存在的耗时耗存储问题,提出了一种激光雷达点云可学习二值量化网络模型。该模型基于特征的知识蒸馏,将全精度网络各层统计特征知识转移到二值量化网络,较大幅度地提升了量化精度;提出基于遗传算法的二值量化尺度因子恢复可学习优化算法,通过逐层搜索初始最优尺度恢复因子,并通过网络自学习大幅减少网络参数量;提出一种统计自适应池化损失最小化算法,包括量化网络自调节和全精度网络转移调节两种方式,以解决量化网络中池化信息损失较大的问题。实验结果表明,所提算法在获取高精度的同时实现了较大压缩比和加速比,可将 PointNet 大小压缩为原来的 1/23、加速 35 倍以上,对其他点云主流深度网络具有良好的扩展性。

关键词 测量; 激光雷达; 点云; 可学习算法; 二值量化; 遗传算法

中图分类号 TP181

文献标志码 A

DOI: 10.3788/AOS202242.1212005

Optimized Scalable and Learnable Binary Quantization Network for LiDAR Point Cloud

Zhao Zhi^{1*}, Ma Yanxin², Xu Ke¹, Wan Jianwei¹

¹ College of Electronic Science, National University of Defense Technology, Changsha 410073, Hunan, China;

² College of Meteorology and Oceanography, National University of Defense Technology, Changsha 410073, Hunan, China

Abstract To solve the time-consuming and storage problems of the LiDAR point cloud deep learning network models in the deployment of embedded devices on the mobile terminal, a learnable binary quantization network model for LiDAR point clouds is proposed. The model refers to the idea of feature-based knowledge distillation and transfers the statistical feature knowledge of each layer of the full-precision network to the binary quantization network, which greatly improves quantification accuracy. A genetic-algorithm based learnable optimization algorithm for scale factor recovery of binary quantization is proposed, which searches for the initial optimal layer-wise scale recovery factor, and greatly reduces amount of network parameters through network self-learning. A statistical adaptive pooling loss minimization algorithm is proposed, including quantitative network self-adjustment and full-precision network transferring adjustment, which solves the problem of greater pooling information loss of quantitative networks. Experimental results show that the proposed algorithm achieves larger compression ratio and speedup ratio while obtaining high precision. Theoretically, it can compress PointNet by 23 times and accelerate it by 35 times at least or more, and also achieves good scalability for other mainstream point cloud deep networks.

Key words measurement; LiDAR; point clouds; learnable algorithm; binary quantization; genetic algorithm

收稿日期: 2021-12-29; 修回日期: 2022-03-10; 录用日期: 2022-03-25

基金项目: 国家自然科学基金(61871386)

通信作者: *zhaozhi@nudt.edu.cn

1 引言

近些年,随着激光雷达在自动驾驶、机器人、智慧城市、增强现实和可穿戴设备等领域的广泛应用^[1-3],基于深度学习的激光雷达点云数据处理受到国内外研究机构和学者的广泛关注^[4-5]。包括 PointNet^[6]、PointNet++^[7]、PointCNN^[8]、DGCNN^[9]和 PointConv^[10]在内的典型点云深度神经网络模型的成功应用使得基于深度学习的三维点云处理方法已成为国内外研究热点。然而,这些点云深度学习网络模型具有庞大的参数规模,与其相伴的计算开销与内存需求使其在计算资源受限平台(如嵌入式设备)的部署中遇到了巨大的挑战,移动端设备部署应用的迫切需求使得对资源消耗少、占用存储少、精度较高的压缩模型备受关注,因此对点云深度学习模型压缩的研究显得尤为迫切。

量化作为模型压缩的一种重要方法,在二维图像深度学习领域已得到广泛研究^[11]。特别地,二值量化作为一种极限量化,将浮点型位数量化为 1 位,具有极高压缩比,是当前深度模型压缩领域的前沿研究热点^[12-23],其代表性研究成果包括 BNN (Binarized Neural Networks)^[11]、XNOR-Net^[12]、Bi-Real Net^[13]和 IR-Net^[14]等。二维图像和三维点云存在根本区别^[1],使得这些方法不能直接转换到三维点云网络中去,如点云深度模型量化存在特征累加同质退化严重的问题^[24]。迄今唯一的针对点云深度网络二值量化压缩的研究成果为 2021 年计算机视觉领域顶会 (ICLR) 录用的 BiPointNet^[24],其主要贡献在于利用信息熵理论解决池化聚合引起的特征鉴别力大幅下降的问题,设计最大熵聚合 (EMA) 模块和分层尺度恢复模块虽然提升了全局特征表示能力,也一定程度减小了量化尺度变形,但在求最大熵平移变换量过程中,求解目标函数时采用线下蒙特卡罗仿真进行近似,无法准确求出复杂目标函数的闭合解析解。由于点云深度学习模型量化研究处于起步阶段,量化网络的整体性能还有较大的提升空间。

为进一步有效提升点云二值量化网络模型的整体性能,本文主要研究工作包括:实现基于层的统计特征知识转移,充分利用点云全精度网络来提升二值量化网络的性能;为平衡点云深度量化模型的压缩性能和精度性能,提出一种基于遗传算法的二值量化尺度因子可学习的方法,通过优化确定层初始最佳尺度恢复因子,并通过网络进行学习更新;为解决点云深度网络池化聚合操作造成的特征鉴别能力大幅下降

的问题,提出一种统计自适应池化损失最小化方法。本研究成果对激光雷达点云深度学习模型在移动端嵌入式设备上的部署方面具有潜在的应用价值。

2 点云可学习二值量化网络模型

本节首先介绍所提激光雷达点云可学习二值量化网络模型的整体架构,其次分别对基于遗传算法的二值量化尺度因子恢复可学习优化方法、统计自适应池化损失最小化算法进行原理分析。

2.1 模型整体架构

点云可学习二值量化网络通用模型框架如图 1 所示。该模型包括预训练的点云全精度网络、点云二值量化网络、尺度恢复模块 (SR) 和统计自适应池化损失最小化模块 (PLM)。全精度网络和量化网络之间进行基于层的统计特征知识转移,具体地,卷积层和全连接层通过 SR 得到二值量化最优尺度因子初始参数,池化层通过统计自适应 PLM 得到初始调整参数,从而量化模型,得到每层的基于统计特征知识转移的初始调整参数,进而通过量化网络自主学习过程不断地更新、最优化这些参数值。同时,每层仅设置一个调整参数,使得量化模型额外存储占用少,其在提升模型精度的同时保证了整体性能的优越性。点云可学习二值量化网络与对应的点云全精度网络的结构相同,不论选取何种点云网络模型进行二值量化,涉及的量化操作及尺度恢复、统计自适应池化损失最小化等优化操作不受相关采样层采样方式的影响,具有通用的优化性能。

本文以典型的点云深度网络模型 PointNet 二值量化为例进行分析,同时拓展到 PointNet++、PointCNN 和 PointConv 等其他主流模型。PointNet 可学习二值量化网络模型如图 2 所示,包括分类网络和分割网络。量化模型中所有卷积层和全连接层通过 SR 获取基于全精度统计特征转移的初始尺度因子,池化层通过 PLM 获取初始调整参数。由于网络中输入转换模块和特征转换模块包括了卷积层、池化层和全连接层,所以这两个模块均需通过 SR 和 PLM 获取初始参数。在分类网络和分割网络训练中,通过反向传播分别学习、更新相关参数。

问题定义:点云全精度网络模型卷积层和全连接层的输出特征用 $F_i(x_i; \alpha_i)$ 表示,其中下标 i 表示层数, x_i 为网络第 i 层输入, α_i 为全精度模型第 i 层参数;池化层输出特征用 $T_j^{(D)}(x_j)$ 表示,其中下标 j 表示池化层序数, x_j 为输入,上标 f 代表全精度;二值量化网络模型卷积层和全连接层的输出特征用

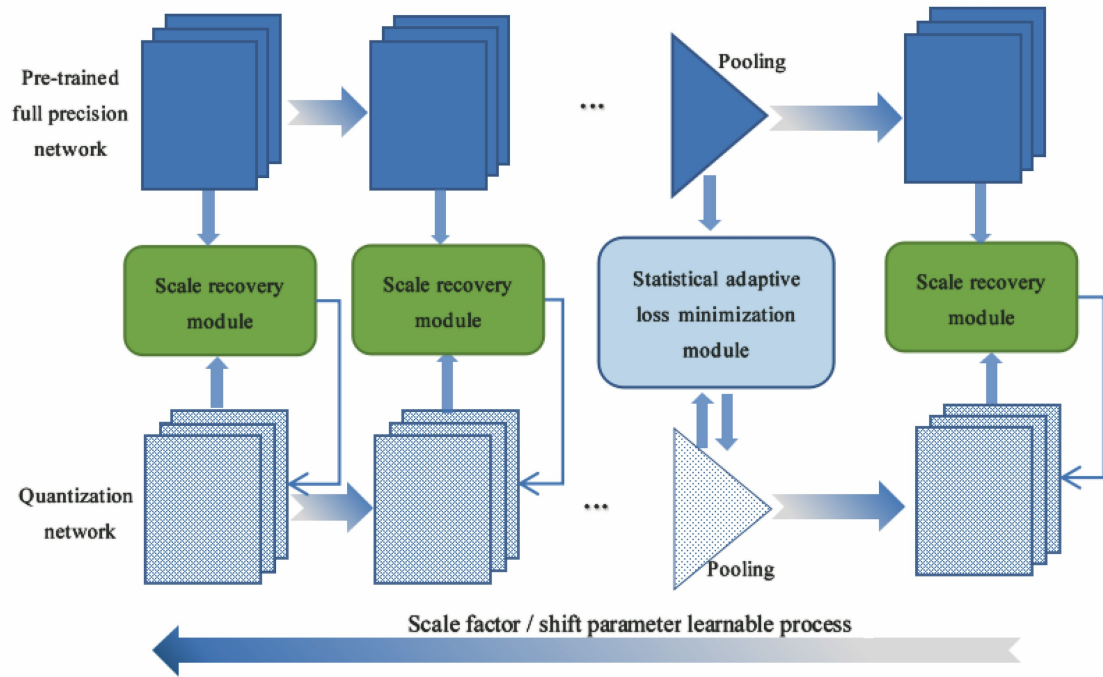


图 1 点云可学习二值量化通用网络模型框架

Fig. 1 General framework for point cloud learnable binary quantization network model

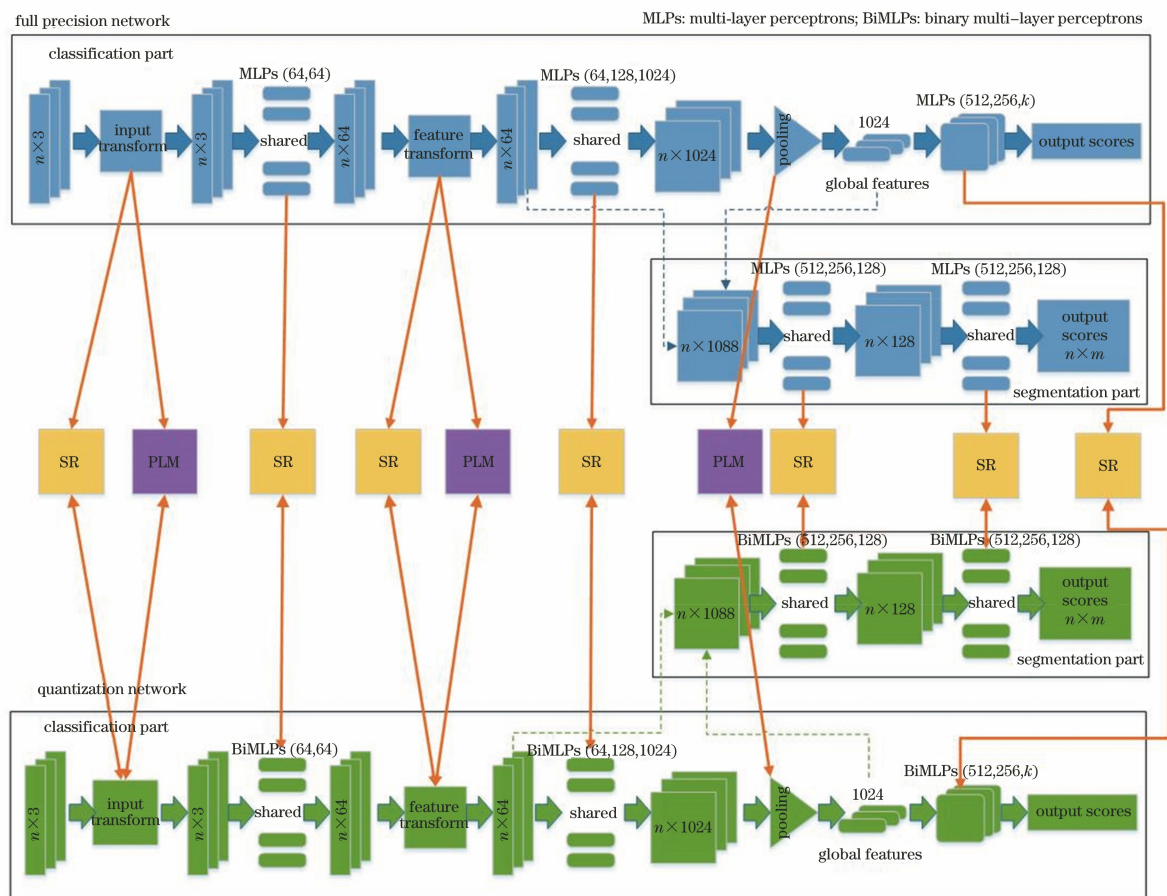


图 2 PointNet 可学习二值量化网络模型

Fig. 2 Learnable binary quantization network model of PointNet

$Q_i(x_i; \beta_i)$ 表示, 其中 β_i 为量化模型第 i 层参数; 池化层输出特征用 $T_i^{(b)}(x_i)$ 表示, 其中下标 i 表示池

化层序数, x_i 为输入, 上标 b 代表二值量化。通过将 $F_i(x_i; \alpha_i)$ 和 $Q_i(x_i; \beta_i)$ 输入 SR 得到第 i 层初始最优尺度恢复因子 λ_i ; 统计自适应 PLM 的输入既可以是 $T_i^{(b)}(x_i)$, 也可以是 $T_j^{(f)}(x_j)$ 和 $T_i^{(b)}(x_i)$, 分别对应量化网络自调节、全精度网络统计特征转移调节方式, 得到量化网络池化层特征初始调整参数 φ_i 。训练中通过量化网络反向传播更新 λ_i 和 φ_i 值, 进而不断优化量化网络性能。

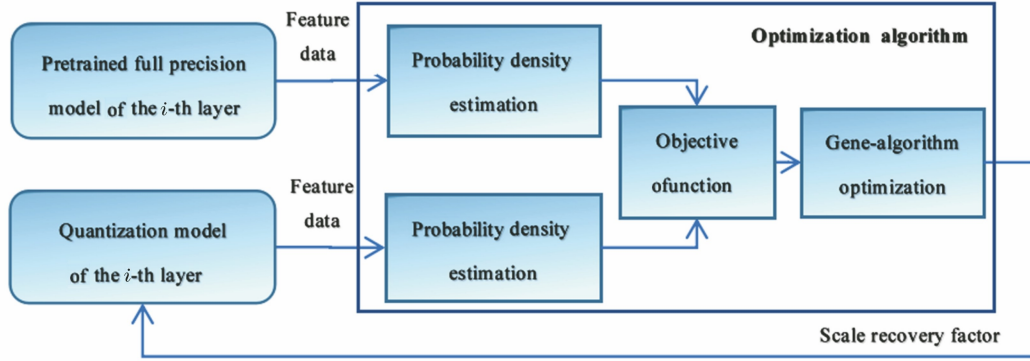


图 3 基于遗传算法优化的二值量化尺度因子恢复

Fig. 3 Gene-algorithm based binary quantization scale factor recovery

具体地, 对输入的全精度网络和量化网络对应层的特征数据采用无参估计法进行概率密度估计。本文选用常见的三种无参估计方法^[25], 包括直方图法(Hist)、核密度估计(KDE)法及 K 最近邻(KNN)法, 并进行对比分析。设点云全精度网络模型和二值量化网络模型所求的概率密度分别为 $p_i^{(f)}(F_i; x_i, \alpha_i)$ 和 $p_i^{(b)}(Q_i; x_i, \beta_i)$ 。对于直方图法, 全精度网络第 i 层输出特征 F_i 的取值范围为 $[l_1, l_2]$, 其中 l_1, l_2 为特征最小值和最大值, 总样本数为 $N^{(f)}$, 将取值范围分成 k 个等间隔区间, 统计每个区间内的样本个数 $N_j^{(f)}$, 其中 $j \in [1, k]$, 则第 j 个区间的概率密度为

$$p_{ij}^{(f)} = \frac{N_j^{(f)}}{N^{(f)}}, \quad (1)$$

则有

$$p_i^{(f)}(F_i; x_i, \alpha_i) = (p_{i1}^{(f)}, p_{i2}^{(f)}, \dots, p_{ik}^{(f)}) = \left(\frac{N_1^{(f)}}{N^{(f)}}, \frac{N_2^{(f)}}{N^{(f)}}, \dots, \frac{N_k^{(f)}}{N^{(f)}} \right), \quad (2)$$

同理, 有

$$p_i^{(b)}(Q_i; x_i, \beta_i) = (p_{i1}^{(b)}, p_{i2}^{(b)}, \dots, p_{ik}^{(b)}) = \left(\frac{N_1^{(b)}}{N^{(b)}}, \frac{N_2^{(b)}}{N^{(b)}}, \dots, \frac{N_k^{(b)}}{N^{(b)}} \right). \quad (3)$$

对于 KDE 法, 首先定义 R_N 为 n 维特征空间 n 维超立方体, 棱长为 h_N , 体积为 h_N^n , 选取核函数

2.2 基于遗传算法优化的二值量化尺度因子恢复方法

本节给出点云可学习二值量化模型的 SR 具体实现原理, 如图 3 所示。为提升量化网络卷积层和全连接层的特征表达能力, 通过将预训练全精度网络各层统计分布特征转移, 并联合量化特征统计分布进行搜索优化, 获取量化网络每层尺度恢复因子, 以减少二值量化带来的严重尺度失真。

$\varphi(\cdot)$: 当样本 $m_j \in F_i$ 落入以 m 为中心的超立方体 R_N 中, 计数 1; 否则, 计数 0。核函数可表示为

$$\varphi(m) = \varphi\left(\frac{m - m_j}{h_N}\right), \quad (4)$$

落入 R_N 的样本数 k_N 为

$$k_N = \sum_{j=1}^N \varphi\left(\frac{m - m_j}{h_N}\right), \quad (5)$$

概率密度估计值为

$$p_i^{(f)}(m; x_i, \alpha_i) = \frac{1}{N} \sum_{j=1}^N \frac{1}{V_N} \varphi\left(\frac{m - m_j}{h_N}\right), \quad (6)$$

式中: V_N 为窗域体积。同理求出量化网络的层概率密度估计 $p_i^{(b)}(m; x_i^{(b)}, \beta_i)$ 。

对于 KNN 法, 由于含 m 的序列区域 V_1, V_2, \dots, V_N 受落入 R_N 中的样本数 k_N 控制, 先确定参数 k_N 值, 以 m 为中心让体积扩张直至包含 k_N 个样本, 概率密度估计值为

$$p_i^{(f)}(m; x_i, \alpha_i) = \frac{k_N/N}{V_N}, \quad (7)$$

同理求出量化网络的层概率密度估计 $p_i^{(b)}(m; x_i^{(b)}, \beta_i)$ 。

得到第 i 层概率密度后, 利用估计得到的概率密度 $p_i^{(f)}(F_i; x_i, \alpha_i)$ 和 $p_i^{(b)}(Q_i; x_i, \beta_i)$ 构建评价函数(或目标函数、适应度函数), 采用 KL 散度来衡量所得两个概率分布之间的差异, 差异越小则 KL 散度越接近 0, 可表示为

$$\zeta_{\text{KL}}[p_i^{(b)}(Q_i; x_i, \beta_i) | p_i^{(f)}(F_i; x_i, \alpha_i)] =$$

$$E[\ln p_i^{(b)}(Q_i; x_i, \beta_i) - \ln p_i^{(f)}(F_i; x_i, \alpha_i)] =$$

$$\sum_{i=1}^n p_i^{(b)}(Q_i; x_i, \beta_i) \ln \frac{p_i^{(b)}(Q_i; x_i, \beta_i)}{p_i^{(f)}(F_i; x_i, \alpha_i)}, \quad (8)$$

式中: $E(\cdot)$ 为期望; ζ_{KL} 为 KL 散度值。

构建评价函数后, 利用遗传算法^[26]优化搜索初始最优尺度因子。记第 t 代种群为 $B_t = (b_{1,t}, b_{2,t}, \dots, b_{m,t})$, 其具体实现伪代码如图 4 所示。

```

Input: initial population size  $S$ ; max generation number  $m$ ;
      cross probability  $p_c$ ; mutation probability  $p_m$ ;
      the  $i$ -th layers' probability densities:  $p_i^{(f)}(F_i; x_i, \alpha_i)$ ,  $p_i^{(b)}(Q_i; x_i, \beta_i)$ ;
      fitness function or evaluation function  $\zeta_{\text{KL}}(\cdot)$ 
Output: initial scale factor  $\lambda_y$ 

 $t=0$ 
Coding operation;
compute initial population:  $B_0 = (b_{1,0}, b_{2,0}, \dots, b_{m,0})$ ;
While stopping condition not fulfilled do
Begin
  Evaluate population individuals' fitness:
     $\zeta_{\text{KL}}[p_i^{(b)}(Q_i; x_i, \beta_i) | p_i^{(f)}(F_i; x_i, \alpha_i)]$ ;

  Select individuals for reproduction:
    For  $i=1$  to  $m$  do
      Select an individual  $b_{i,t+1}$  from  $B_t$ ;

  Create off-springs by crossing individuals:
    For  $i=1$  to  $m-1$  do
      If  $\text{random}(\cdot) \leq p_c$  then
        Cross  $b_{i,t+1}$  with  $b_{i+1,t+1}$ ;

  Eventually mutate some individuals:
    For  $i=1$  to  $m$  do
      eventually mutate  $b_{i,t+1}$ ;

  Compute optimal fitness function value, adding to optimal variables' list  $L_{\text{opt}}$ ;
   $t=t+1$ 
  Compute new generations  $B_{t+1}$ ;
End
Compute optimal scale factor  $\lambda_y$  from  $L_{\text{opt}}$ 

```

图 4 基于遗传算法优化的最优尺度因子搜索

Fig. 4 Optimal search of scale factor based on gene-algorithm optimization

2.3 统计自适应池化损失最小化算法

从统计学习角度分析点云深度二值量化网络模型池化聚合对特征信息表达能力的影响。特征鉴别能力的大小反映了所包含信息量的多少, 熵^[27]是用来衡量所包含信息量的指标, 事件发生概率越高时, 携带的信息量就越少, 多随机事件同时发生的总不确定性具有累加性。

首先, 池化层的输入特征数据信息损失较大。池化层输入的是前序经二值量化的网络层输出特征, 二值量化将浮点数量化为 -1 或 1 , 量化概率为确定值 0 或 1 。熵的取值范围为 $[0, \log_2 n]$, 其中 n 为类别数。由于二值量化概率只取 0 或 1 , n 取 2 , 而对于全精度网络而言, n 的取值远大于 2 , 故量化后的熵最大值远小于全精度的最大熵值, 造成二值量化特征表征能力大幅下降。另外, 从表征量化不确定性的条件熵考虑, 有

$$\Phi(Q_i | F_i) =$$

$$\sum_{f_j} p_{F_i}(f_j) \left[\sum_{q_k} p_{Q_i|F_i=f_j}(q_k) \log_2 p_{Q_i|F_i=f_j}(q_k) \right] =$$

$$\sum_{f_j} p_{F_i}(f_j) \cdot 0 = 0, \quad (9)$$

式中: 下标 j 和 k 分别为全精度和量化网络层特征元素序号; $F_i = \bigcup_j f_j$; $Q_i = \bigcup_k q_k$; $p_{Q_i|F_i=f_j}(q_k) \in \{0, 1\}$, q_k 为第 k 个量化特征。二值量化条件熵为 0 , 意味着在全精度条件下二值量化结果有很大的确定性, 则量化特征信息量必然比全精度特征小得多, 特征表达能力十分受限。

其次, 池化操作造成特征信息的进一步损失。记最大池化函数为 $\Theta(\cdot)$, 量化网络池化层输入为 $Q_i(x_i; \beta_i)$, 输出为 $T_i^{(b)}(x_i)$, 根据 $\max(q_1, q_2, \dots, q_k)$ 统计分布求出概率质量函数为

$$P_a = \sum_{t_m} p_{T_i^{(b)}}(t_m) = (P_b)^n = \left[\sum_{q_k} p_{Q_i}(q_k) \right]^n, \quad (10)$$

式中:下标 a 表示池化后;下标 b 表示池化前; $P_b = \sum p_{Q_i}(q_k)$ 为池化前的概率质量函数; t_m 为池化层输出的第 m 个特征变量。随着 n 增大, n 次方计算后,最大池化后概率值大幅减小。根据二值量化特点符合伯努利分布熵特点,最大池化输出特征的熵值为

$$\Phi_{\text{pool}}(Q_i) = -P_a \log_2 P_a - (1 - P_a) \log_2 (1 - P_a). \quad (11)$$




图 5 池化前后特征熵对比曲线。(a) $n=5$; (b) $n=20$; (c) $n=50$; (d) $n=100$

Fig. 5 Curves of feature entropy before and after pooling. (a) $n=5$; (b) $n=20$; (c) $n=50$; (d) $n=100$

针对以上分析结果,为解决池化造成的特征表达能力下降的问题,提出基于量化网络统计自适应

分别取不同的 n 值,池化前后特征熵值变化曲线如图 5 所示,其中,BP 代表池化前,AP 代表池化后。可以看出,池化后的特征熵值比池化前下降幅度较大,随着 n 的增大,这种差异性更明显。点云网络池化核尺寸相比图像而言急剧增大,即 n 值较大(如常见的取值为 1024),池化后特征熵降幅更大,导致特征表示能力严重下降。

调节和基于全精度网络统计知识转移调节两种方法,如图 6 所示。

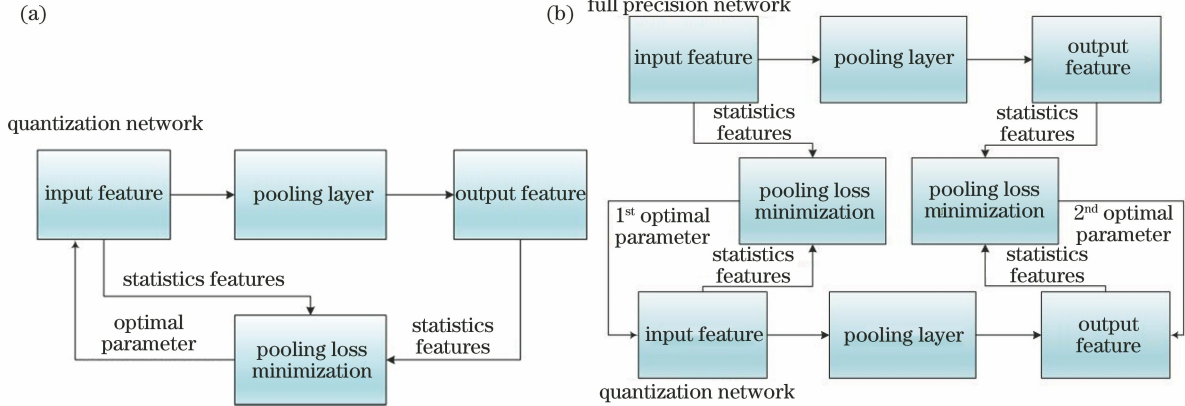


图 6 统计自适应池化损失最小化。(a) 量化网络自调节; (b) 全精度网络统计知识转移调节

Fig. 6 Minimization of statistically self-adaptive pooling loss. (a) Quantitative network self-regulation;

(b) statistical knowledge transfer regulation of full precision network

两种方式都最大限度地保持池化前后特征统计分布的一致性,尽量减小池化造成的特征信息损失。

第一种方式可表示为

$$\operatorname{argmin}_{\varphi_i} L[\Theta[Q_i(\varphi_i)], T_i^{(b)}], \quad (12)$$

第二种方式可表示为

$$\operatorname{argmin}_{\varphi_{i1}, \varphi_{i2}} L[Q_i(\varphi_{i1}), F_i] + L[T_i^{(b)}(\varphi_{i2}), T_i^{(f)}], \quad (13)$$

式中: $L(\cdot)$ 为池化前后特征统计差异度量; φ_{i1} 、 φ_{i2}

为平移参数。

PLM 对特征数据调整的形式可以有多种,本文采用的是平移加尺度缩放操作。图 7 为随机选取一次网络训练,采取量化网络自调节方式得到的池化层特征调整前后的概率密度分布对比图,其中,APS 代表池化+平移,APSS 代表池化+平移+缩放,横坐标 x 为变量取值,纵坐标 P 为概率密度值。可以看出,经平移和缩放两次调整的池化特征能更好地拟合池化层原输入特征的分布,二者熵差远小于经

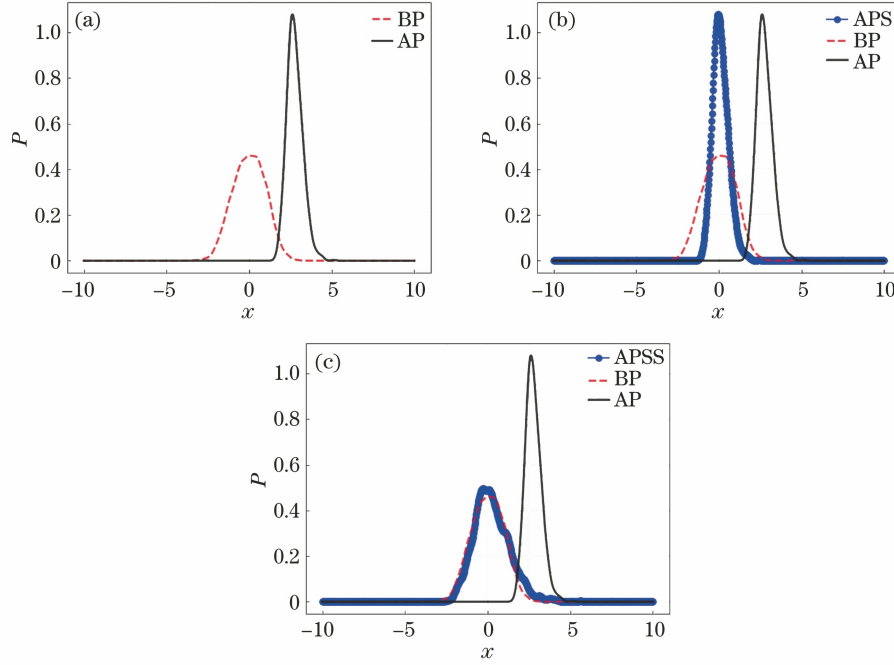


图 7 调整特征概率分布对比。(a)特征分布对比 1;(b)特征分布对比 2;(c)特征分布对比 3

Fig. 7 Comparison of adjusted feature probability distributions. (a) Feature distribution comparison 1; (b) feature distribution comparison 2; (c) feature distribution comparison 3

平移调整或未经平移调整的池化前后特征分布的熵差,可见特征信息得到较好的保留。

具体地,首先采用变异系数求取平移参数。变异系数可表示为

$$C = \frac{\sigma}{\mu}, \quad (14)$$

式中: C 为变异系数; σ 为特征标准差; μ 为特征均值。综合考虑特征离散程度及特征均值的影响,求取优化的平移参数,使得调整后的特征分布能更好地拟合基准特征分布。在求取平移参数的基础上,采用标准差约束条件进一步细化拟合,求取尺度缩放因子,以最大限度地保留特征信息。

第一种量化网络自调节方式引入平移参数 φ_i 和缩放因子 ζ_i ,调整后的特征为 $Q'_i = \zeta_i(Q_i + \varphi_i)$,令

$$C[\Theta(Q_i; \varphi_i)] = C[T_i^{(b)}], \quad (15)$$

即

$$\frac{\sigma[\Theta(Q_i; \varphi_i)]}{\mu[\Theta(Q_i; \varphi_i)]} = \frac{\sigma[T_i^{(b)}]}{\mu[T_i^{(b)}]}. \quad (16)$$

将(16)式按照标准差和均值的计算公式推导得出

$$\frac{\sigma[\Theta(Q'_i)]}{\mu[\Theta(Q'_i)] + \varphi_i} = \frac{\sigma[T_i^{(b)}]}{\mu[T_i^{(b)}]}, \quad (17)$$

进而求得

$$\varphi_i = \frac{\mu[T_i^{(b)}]\sigma[\Theta(Q'_i)] - \mu[\Theta(Q'_i)]\sigma[T_i^{(b)}]}{\sigma[T_i^{(b)}]}, \quad (18)$$

式中: $Q'_i = Q_i + \varphi_i$ 。求尺度缩放因子时,令

$$\sigma(Q_i + \varphi_i; \zeta_i) = \sigma[T_i^{(b)}], \quad (19)$$

求得

$$\zeta_i = \frac{\sigma[T_i^{(b)}]}{\sigma(Q_i + \varphi_i)}. \quad (20)$$

同理,第二种方式即全精度网络统计知识转移调节引入平移参数 φ_{i1} 、 φ_{i2} 和缩放因子 ζ_{i1} 、 ζ_{i2} ,令

$$C[F_i] = C[Q_i(\varphi_{i1})], C[T_i^{(b)}(\varphi_{i2})] = C[T_i^{(f)}], \quad (21)$$

即

$$\begin{aligned} \frac{\sigma(F_i)}{\mu(F_i)} &= \frac{\sigma[Q_i(\varphi_{i1})]}{\mu[Q_i(\varphi_{i1})]} = \frac{\sigma(Q'_i)}{\mu(Q'_i) + \varphi_{i1}}, \\ \frac{\sigma[T_i^{(b)}(\varphi_{i2})]}{\mu[T_i^{(b)}(\varphi_{i2})]} &= \frac{\sigma[T_i^{(b)' }]}{\mu[T_i^{(b)' } + \varphi_{i2}]} = \frac{\sigma[T_i^{(f)}]}{\mu[T_i^{(f)}]}, \end{aligned} \quad (22)$$

式中: $T_i^{(b)' } = T_i^{(b)} + \varphi_{i2}$ 。

求得

$$\begin{aligned} \varphi_{i1} &= \frac{\mu(F_i)\sigma(Q'_i) - \mu(Q'_i)\sigma(F_i)}{\sigma(F_i)}, \\ \varphi_{i2} &= \frac{\mu[T_i^{(f)}]\sigma[T_i^{(b)' }]}{\sigma(F_i)} - \mu[T_i^{(b)' }]\sigma[T_i^{(f)}], \end{aligned} \quad (23)$$

$$\zeta_{i1} = \frac{\sigma(F_i)}{\sigma(Q_i + \varphi_{i1})}, \zeta_{i2} = \frac{\sigma[T_i^{(f)}]}{\sigma[T_i^{(b)} + \varphi_{i2}]} \quad (24)$$

2.4 量化网络可学习过程

在通过 SR 和 PLM 分别得到卷积层和全连接层的初始尺度恢复因子 λ_i 、池化层的初始平移参数 φ_i 和缩放因子 ζ_i 后,这些参数均可以和网络其他参数进行端到端的学习优化。量化网络第 i 个卷积层或全连接层的输出为

$$Q_i(x_i) = \begin{cases} \lambda_i, & x_i > 0 \\ -\lambda_i, & x_i \leq 0 \end{cases} \quad (25)$$

则根据链式法则, λ_i 的梯度为

$$\frac{\partial L}{\partial \lambda_i} = \sum_{x_i} \frac{\partial L'}{\partial Q_i(x_i)} \cdot \frac{\partial Q_i(x_i)}{\partial \lambda_i} \quad (26)$$

式中: L' 为损失函数。偏导数 $\partial Q_i / (\partial \lambda_i)$ 为

$$\partial Q_i / (\partial \lambda_i) = I_{\{x_i > 0\}} - I_{\{x_i \leq 0\}}, \quad (27)$$

式中: I 为指示函数, 当 $\{\cdot\}$ 中的不等式成立时, $I_{\{\cdot\}} = 1$, 否则 $I_{\{\cdot\}} = 0$ 。

类似地, 对于量化网络自调节方式, 池化特征 $Q'_j = \zeta_j(Q_j + \varphi_j)$, 同样可以根据链式法则求出梯度。对于平移参数 φ_i 和缩放因子 ζ_i , 则有

$$\frac{\partial Q'_j}{\partial \varphi_j} = \zeta_j, \quad (28)$$

$$\frac{\partial Q'_j}{\partial \zeta_j} = Q_j + \varphi_j. \quad (29)$$

对于全精度网络统计知识转移调节方式, 梯度计算方法同上。

可学习二值量化网络训练过程如图 8 所示。

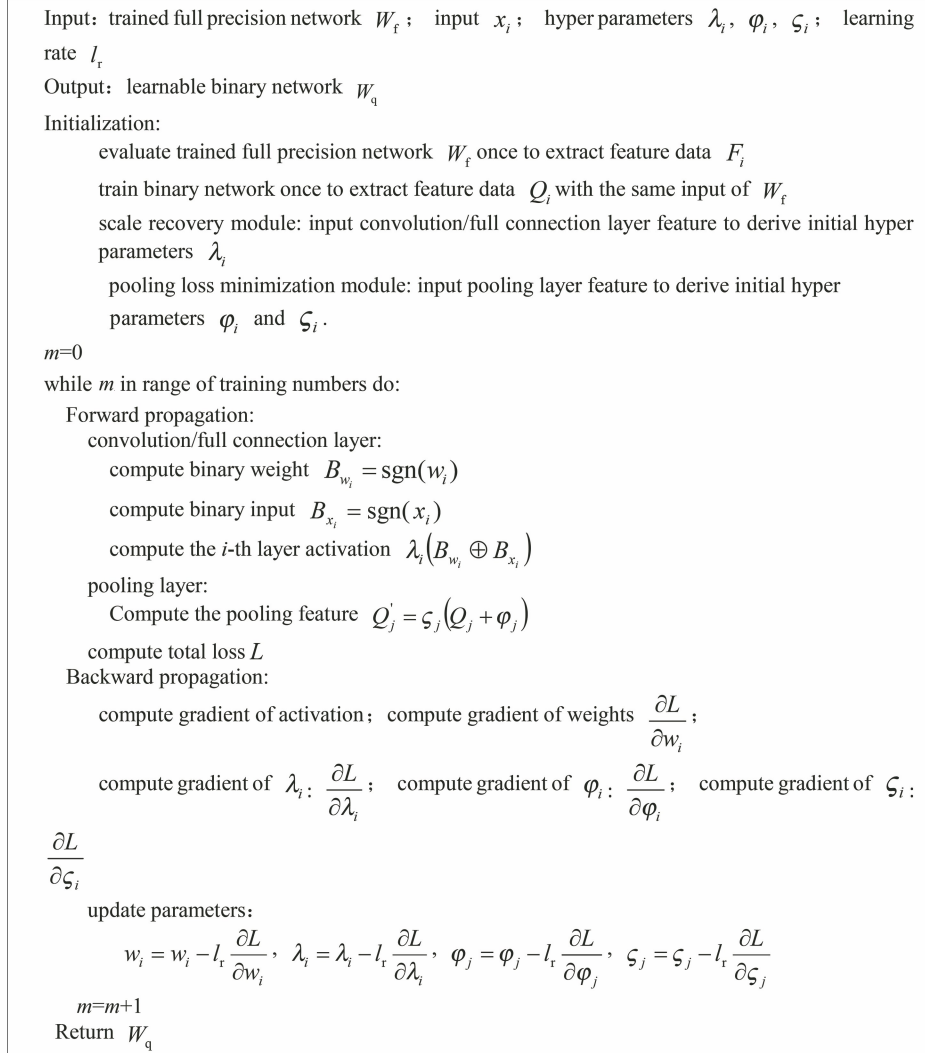


图 8 可学习训练过程

Fig. 8 Learnable training process

3 实 验

通过消融实验、对比实验、拓展实验和复杂度分析来综合评估所提点云可学习二值量化模型的性能。实验配置为: Intel® Core™ i5-9400, 内存 16G; 显卡 NVIDIA GeForce RTX 2080Ti。实验数据采用点云处理的三大主流公开数据集 ModelNet40^[28]、ShapeNet^[29] 与 S3DIS^[30], 其中 ModelNet40 包含 40 类人造目标共 12311 个 CAD 三维形状(训练用 9843 个、测试用 2468 个); ShapeNet 包含了 16 类 16881 个三维形状, 共有 50 个部件, 大部分目标类由 2~5 个部件组成; S3DIS 数据集包含来自 Matterport 扫描仪 3D 扫描得到的 6 个区域, 包括 271 个房间, 每个扫描点均用 13 类语义标签之一进行标注, 如桌子、椅子、墙壁和地

板等。

实验选取 4 种典型的二值量化算法 BNN、XNOR-Net、IRNet 和 BiPointNet 与本文算法进行对比分析, 实验中所采用的所有原算法运行结果与本文所提模型算法结果是基于相同的配置进行训练得出。所选 4 种方法与本文方法的简要对比分析如表 1 所示, 其中按位计算包括异或运算、位计数和位移量计算, 其计算复杂度分别为: 卷积层输出特征图尺寸计算复杂度 $O_1 = C_{out} \times W_{out} \times H_{out}$ (其中, C_{out} 为输出通道数, $W_{out} \times H_{out}$ 为输出特征图尺寸); 卷积层输入特征图尺寸计算复杂度 $O_2 = C_{in} \times W_k \times H_k$ (其中, C_{in} 为输入通道数, $W_k \times H_k$ 为核尺寸); 池化层输入特征图尺寸计算复杂度 $S = C_p \times W_{p,in} \times H_{p,in}$ (其中, C_p 为池化输入通道数, $W_{p,in} \times H_{p,in}$ 为池化输入特征图尺寸)。

表 1 二值量化算法对比

Table 1 Comparison of binary quantization algorithms

Method	Bit width N_w /bit	Bit width N_a /bit	Scaling/Shifting factor	Floating point calculation	Bitwise calculation
BNN	1	1	—	0	$O_1 \times O_2$
XNOR-Net	1	1	Scaling	O_1	$O_1 \times O_2$
IRNet	1	1	Shifting	0	$O_1 \times O_2 + O_1$
BiPointNet	1	1	Scaling	O_1	$O_1 \times O_2$
			Pooling shifting	S	0
Proposed model	1	1	Scaling	O_1	$O_1 \times O_2$
			Pooling shifting	S	0
			Pooling scaling	S	0

3.1 消融实验

消融实验主要对所提模型的尺度恢复算法和池化优化算法效果进行比较分析。表 2 是未池化优化只进行尺度恢复的分类实验结果, 池化类型均采用最大池化方法, 其中, MAX 代表最大池化。分析得

出, 4 种待比较算法 BNN、IRNet、XNOR-Net 和 BiPointNet 中的最高精度为 71.8%, 而本文所提的尺度恢复算法, 不论是基于直方图法、KDE 法还是 KNN 法, 精度都远大于 71.8%, 其中最大值为 81.7%。

表 2 未对池化优化的二值量化方法对比

Table 2 Comparison of binary quantization methods without optimized pooling

Method	Pooling type	Bit width N_w /bit	Bit width N_a /bit	Precision P_c /%
Full precision	MAX	32	32	88.2
BNN	MAX	1	1	26.8
IRNet	MAX	1	1	18.5
XNOR-Net	MAX	1	1	71.8
BiPointNet	MAX	1	1	4.1
Proposed method (Hist)	MAX	1	1	79.9
Proposed method (KDE)	MAX	1	1	80.2
Proposed method (KNN)	MAX	1	1	81.7

表 3 是对本文所提的池化优化算法进行验证的分类结果, 分别将两种优化方式嵌入 4 种待比较算法 BNN、IRNet、XNOR-Net 和 BiPointNet 中, 并与

最大池化方法进行比较, 其中, APSS1* 代表量化网络自调节的池化, APSS2* 代表全精度网络转移调节的池化。分析得出, 经池化优化的精度比原来最

大池化的精度均有大幅提升,基于量化网络自调节优化的 BNN、IRNet、XNOR-Net、BiPointNet 的精度分别比原最大池化算法提升了 53.4、63.8、14.2、77.2 个百分点,基于全精度网络转移调节优化的 BNN、IRNet、XNOR-Net、BiPointNet 的精度分别

提高 51.3、62.2、13.8、78.6 个百分点。量化网络自调节优化对三种量化方法整体精度的提升效果优于全精度网络转移调节优化的方法,两种方法的整体精度均有较大提升,这充分验证了两种方法的有效性。

表 3 基于池化优化的二值量化方法对比

Table 3 Comparison of binary quantization methods with optimized pooling

Method	Pooling type	Bit width N_w /bit	Bit width N_a /bit	Precision P_c /%
Full precision	MAX	32	32	88.2
	MAX	1	1	26.8
BNN	APSS1*	1	1	80.2
	APSS2*	1	1	78.1
	MAX	1	1	18.5
IRNet	APSS1*	1	1	82.3
	APSS2*	1	1	80.7
	MAX	1	1	71.8
XNOR-Net	APSS1*	1	1	86.0
	APSS2*	1	1	85.6
	MAX	1	1	4.1
BiPointNet	APSS1*	1	1	81.3
	APSS2*	1	1	82.7

图 9 以 XNOR-Net 量化方法为例,给出基于量化网络自调节和全精度网络转移调节两种优化的池化前后特征熵随训练次数的变化曲线。经分析可得,两种优化方法的池化特征熵值相比于原最大池

化均有较大提高,均接近于池化输入特征熵值,信息损失很少;最大池化随着训练次数的增加甚至出现了熵值整体下降的趋势,而两种池化优化方法的熵值均呈整体递增趋势,池化特征表达性能更趋稳定。




图 9 池化优化性能对比。(a)量化网络自调节方式;(b)全精度网络转移调节方式

Fig. 9 Comparison of optimized pooling. (a) Quantization network self-adjustment;

(b) full-precision network transfer adjustment

3.2 对比实验

本节主要将所提可学习二值量化模型与典型的二值量化方法 BNN、XNOR-Net、IRNet 以及 BiPointNet 进行对比,其池化方式均采取各自原成果中的池化类型,比较所提模型的整体精度提升的效果,如表 4 所示。所提可学习的二值量化模型根据 SR 与池化优化模块采取的方法可以细分为 6 种,分别为 Hist + APSS1*、Hist + APSS2*、KDE + APSS1*、KDE + APSS2*、KNN + APSS1* 和 KNN + APSS2*。分析得出:相比于 BNN、

XNOR-Net、IRNet 和 BiPointNet 4 种方法,6 种优化方法,精度均超 85.0%,最高达到 87.5%,平均精度约为 86.8%,整体精度显著提高,更接近全精度模型的 88.2%。除 Hist + APSS2* 方法外,其余 5 种方法均超过原精度最高的 BiPointNet。在概率密度无参估计算法中,直方图估计法精度本身要低于 KDE 法和 KNN 法, Hist + APSS1* 和 Hist + APSS2* 的精度整体不如其余 4 种优化方法,但相比 BNN、XNOR-Net 和 IRNet 精度仍有较大幅度的提高。

表 4 典型二值量化方法对比

Table 4 Comparison of typical binary quantization methods

Method	Pooling type	Bit width N_w /bit	Bit width N_a /bit	Precision P_c /%
Full precision	MAX	32	32	88.2
BNN	MAX	1	1	26.8
XNOR-Net	MAX	1	1	71.8
IRNet	MAX	1	1	18.5
BiPointNet	EMA	1	1	86.1
Proposed method (Hist)	APSS1*	1	1	86.5
	APSS2*	1	1	85.3
Proposed method (KDE)	APSS1*	1	1	87.5
	APSS2*	1	1	87.3
Proposed method (KNN)	APSS1*	1	1	86.6
	APSS2*	1	1	87.4

图 10 所示为本文所提模型与当前精度最高的 BiPointNet 以及全精度模型的训练性能对比结果。其中,对分类网络进行训练时,超参数选取如下:输入点数为 1024,输入点云大小为 1024×3 (3 对应坐标维数),epoch 取 200,批大小 batch size 为 32,优化器为 Adam,学习率为 0.001;二值化 PointNet 与全精度网络一样,其每层卷积都是对单个点样本进行处理,所有卷积核的大小为 1×1 ,使用可学习的偏置 bias 参数(其初始值为 0)。图 10(a)~(c)的比较对象分别为基于直方图估计、KDE 和 KNN 的方

法。从图 10(b)、(c)可以看出,基于 KDE 和 KNN 方法的收敛稳定性能远好于 BiPointNet,随着训练次数的增加更加接近全精度网络的性能。图 10(a)中基于直方图估计方法的 Hist+APSS1* 和 Hist+APSS2* 方法的收敛稳定性能整体不如图 10(b)中 KDE 方法和图 10(c)中 KNN 方法,Hist+APSS1* 整体优于 BiPointNet,而对于前 140 次训练,Hist+APSS2* 不如 BiPointNet 收敛快,但训练 140 次后 Hist+APSS1* 和 Hist+APSS2* 方法的收敛稳定性均好于 BiPointNet。

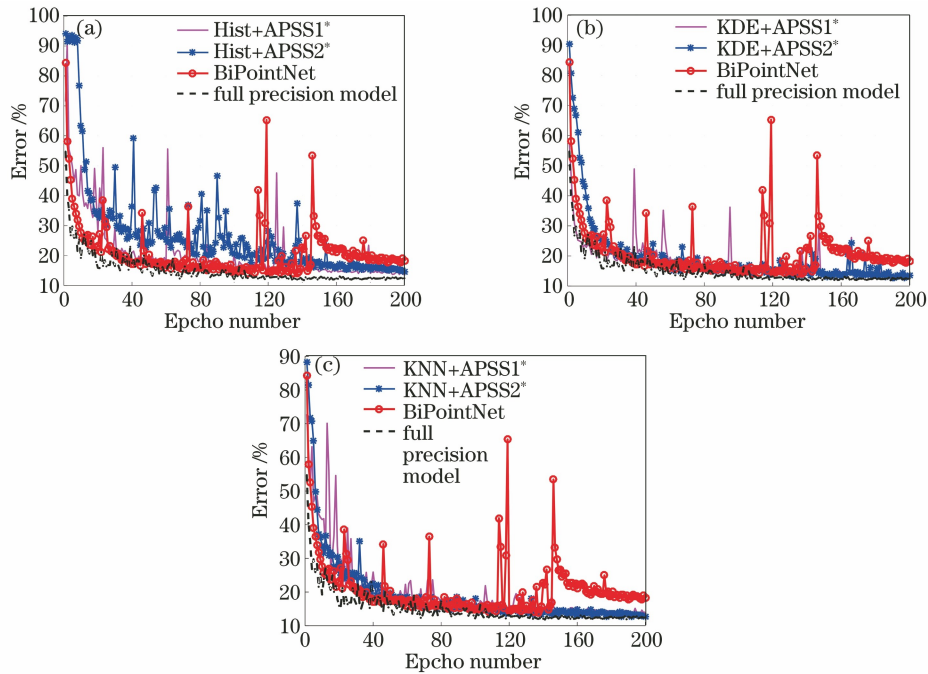


图 10 训练性能对比。(a)对比结果 1;(b)对比结果 2;(c)对比结果 3

Fig. 10 Training performance comparison. (a) Comparison result 1; (b) comparison result 2; (c) comparison result 3

3.3 拓展实验

拓展实验主要将所提算法应用到点云分割及点

云处理等其他典型的深度模型上,进行效果对比分析。首先,基于可学习的二值量化网络 PointNet 进

行部件分割和语义分割实验,本文算法选取 KDE+APSS1*与目前最优的 BiPointNet 进行实验对比,部件分割和语义分割结果分别如表 5、6 所示。表 6 中,mIoU 代表平均交并比,acc 代表精度。表 5 结果显示,本文算法对于 16 个类别中的 13 个类别的部件分割精度高于 BiPointNet,只有 3 个类别(bag、car、chair)精度低于 BiPointNet;本文算法的部件分割平均精度约为 76.8%,高于 BiPointNet 的平均精

度(约 75.1%)。表 6 为语义分割结果,经对比分析可以看出所提模型优于 BiPointNet。其次,基于本文算法选取 PointNet++、PointCNN 和 DGCNN 典型深度模型进行点云分类实验,同样以 KDE+APSS1*方法为例进行实验,结果如表 7 所示,可以看出本文算法应用在不同的点云深度模型框架上的精度也均有提升,这验证了本文算法良好的拓展性。

表 5 部件分割精度

Table 5 Precision of part segmentation

/%

Method	Aero	Bag	Ca	Car	Chair	Ear phone	Guitar	Knife	Lamp	Laptop	Motor- bike	Mug	Pistol	Rocket	Skate board	Table
Full precision	83.1	89.0	95.2	78.3	90.4	78.1	93.3	92.9	81.9	97.9	70.7	95.9	81.6	57.4	74.8	81.5
BiPointNet	79.6	69.6	86.3	67.5	88.6	69.8	87.5	83.3	75.0	95.3	45.1	91.6	76.8	47.9	57.5	79.6
Proposed model	80.2	64.8	87.0	66.8	87.0	77.6	89.7	84.3	76.3	96.7	50.2	92.3	79.6	50.1	66.2	80.1

表 6 语义分割实验结果

Table 6 Semantic segmentation experiment results

/%

Method	Overall mIoU	Overall acc	mIoU/acc of area1	mIoU/acc of area2	mIoU/acc of area3	mIoU/acc of area4	mIoU/acc of area5	mIoU/acc of area6
Full precision	51.9	82.0	59.7/85.1	34.7/73.6	60.9/87.2	43.6/80.9	43.1/82.0	66.2/88.1
BiPointnet	43.4	76.3	50.1/77.9	29.7/69.8	53.3/81.6	36.2/73.3	36.5/77.0	57.8/82.4
Proposed model	43.9	77.5	51.8/78.9	27.1/68.3	55.1/83.2	37.5/75.1	36.9/78.8	59.1/84.0

Method	IoU of ceiling	IoU of floor	IoU of wall	IoU of beam	IoU of column	IoU of window	IoU of door	IoU of table	IoU of chair	IoU of sofa	IoU of bookcase	IoU of board	IoU of clutter
Full precision	89.7	93.7	71.0	50.2	34.0	52.9	53.4	56.7	46.6	9.5	38.5	36.4	41.3
BiPointNet	84.2	85.6	62.0	32.8	22.9	41.7	47.3	45.2	39.5	9.1	35.3	25.8	33.2
Proposed model	85.0	86.3	60.3	33.7	24.2	43.4	46.5	46.6	41.1	8.7	34.2	26.5	34.7

表 7 典型网络模型对比实验结果

Table 7 Comparative experiment results for typical network models

Methods		Bit width N_w /bit	Bit width N_s /bit	Precision P_c /%
PointNet	Full precision	32	32	88.2
	BiPointNet	1	1	86.1
	Proposed method	1	1	87.2
PointNet++	Full precision	32	32	90.7
	BiPointNet	1	1	88.5
	Proposed method	1	1	89.0
PointCNN	Full precision	32	32	89.7
	BiPointNet	1	1	81.5
	Proposed method	1	1	82.8
DGCNN	Full precision	32	32	90.9
	BiPointNet	1	1	75.0
	Proposed method	1	1	83.6

3.4 可视化

本节分别对本文优化过程及结果进行了可视化。重点针对二值化 PointNet 网络,对提出的基于遗传算法的二值量化尺度因子恢复可学习优化方

法、统计自适应池化损失最小化算法进行验证,对卷积层、池化层等网络隐藏层的中间结果等进行了可视化,如图 11~14 所示。输出的部分结果如图 15、16 所示。

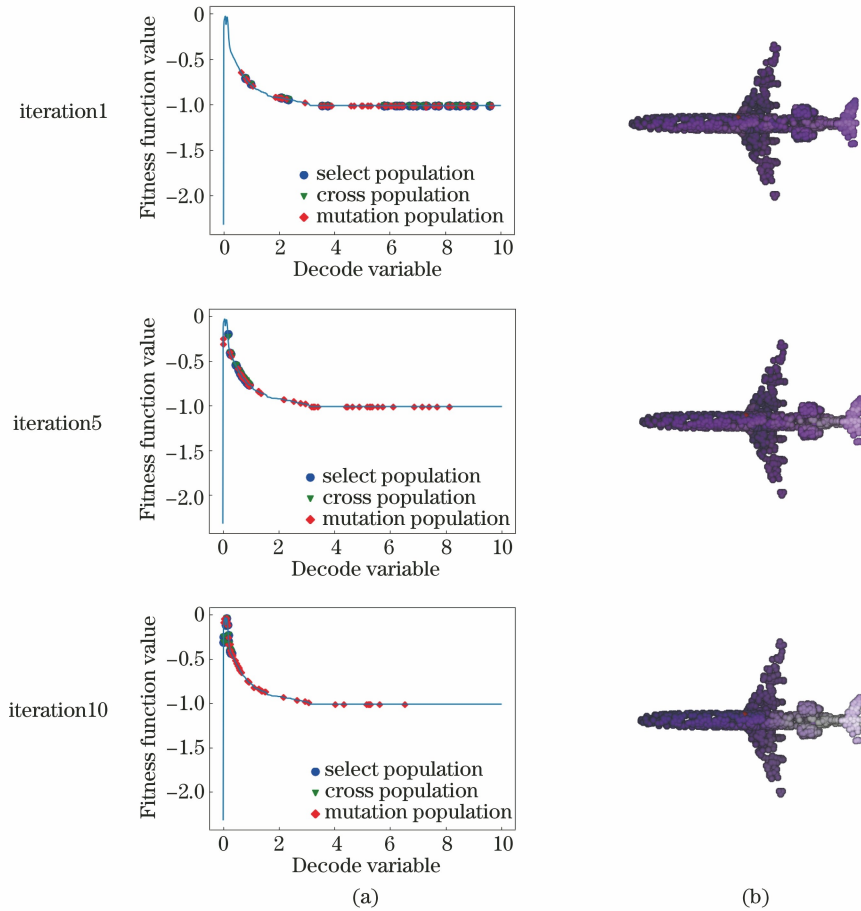


图 11 基于遗传优化算法搜索尺度因子。(a)迭代搜索过程;(b)二值化卷积层输出特征图

Fig. 11 Scaling factor searching based on gene-optimized algorithm. (a) Iterative searching process; (b) feature maps produced by binary conv layer

基于遗传算法的二值量化尺度因子恢复可学习优化过程如图 11 所示,逐层搜索初始最优尺度恢复因子。图 11(a)给出了二值化 PointNet 输入变换 T-Net 的第一个二值化卷积层分别在第 1,5,10 次搜索的尺度因子结果图,经选择、交叉、变异等遗传操作后的种群分别用不同形状和颜色表示;图 11(b)为上述经尺度优化的二值化卷积层输出的某 Airplane 样本部分特征图,表示特征空间中其他点与红点的欧氏距离,颜色越深代表距离越近,特征越相似,可以看出,随着迭代次数的增加,红点与其他不同结构的点的语义特征区别不断增大(如机身、机翼和机尾),尺度优化后的特征表示能力增强。

图 12 为二值化网络卷积层的通道特征结构对比图示。选取本文所提二值量化 PointNet 部件分

割网络,图 12(a)~(c)分别为 3 个卷积层,卷积层数递增,每个子图从左至右选取通道 3、通道 4 和通道 20 对应的特征图,表示特征空间中各点与红点的欧氏距离,距离越近,则颜色越深,特征越相似。红点位置位于椅子靠背,经分析得出,卷积层 1 中各通道特征图中红点与座面和椅腿的特征混淆,随着网络层的逐渐加深,红点与座面和椅腿的特征区别不断显现出来,卷积层 3 各通道特征图的结构语义信息更为清晰。

图 13 为三个不同结构位置点的特征图随二值量化网络卷积层数增加的特征图对比结果。子图从左到右卷积层数递增,与红点特征距离的远近代表特征的相似度,颜色越深越相似。图 13(a)中红点位于椅背,随着网络层的加深,从第三个特征图可以




图 12 不同二值化卷积层的不同通道特征图对比(子图从左至右依次对应 3 个通道)。(a)二值化卷积层 1 的不同通道特征图;(b)二值化卷积层 2 的不同通道特征图;(c)二值化卷积层 3 的不同通道特征图

Fig. 12 Comparison of different channel feature maps of different binary convolution layers (sub-figures from left to right are 3 corresponding channels in sequence). (a) Feature maps of different channels of 1st binary convolution layer; (b) feature maps of different channels of 2nd binary convolution layer; (c) feature maps of different channels of 3rd binary convolution layer




图 13 二值化卷积层不同位置的特征图对比(子图从左至右依次对应 3 个顺序递增的卷积层)。

(a)位置 1 特征图;(b)位置 2 特征图;(c)位置 3 特征图

Fig. 13 Comparison of feature maps of binary convolution layers at different locations (sub-figures from left to right are 3 convolution layers in sequence). (a) Feature map of location 1; (b) feature map of location 2; (c) feature map of location 3

看出椅背点特征与座面、椅腿特征区别明显;类似地,随着卷积层数的增加,图 13(b)、(c)中红点所在结构特征与其他结构的区分度也逐渐增大。

图 14 为二值 PointNet 分类网络池化层特征对比结果。图 14(a)作为特征多样性对比基准,为 1 个 batch 样本池化前的激活值。经分析可得,未优化二值网络池化特征[图 14(b)]存在严重的同质化

问题,特征区分能力十分有限,而经本文池化优化的二值网络池化特征[图 14(c)]多样性得到改善;特别地,经本文所提的尺度和池化联合优化[图 14(d)]的池化层的输出特征鉴别能力得到较大提升。

图 15 为本文方法与 BiPointNet 部件分割部分结果对比图,与真实标签对比,本文方法整体具有更高的部件分割精度。




图 14 池化特征图。(a)池化前激活特征;(b)未优化二值网络池化特征;(c)仅池化优化的二值网络池化特征;(d)经尺度和池化优化的二值网络池化特征

Fig. 14 Feature maps of pooling. (a) Activation features before pooling; (b) pooling features of non-optimized binary network; (c) pooling features of binary network with pooling optimization; (d) pooling features of binary network with scaling and pooling optimization




图 15 部件分割部分结果。(a)刀;(b)摩托车;(c)灯

Fig. 15 Partial results of part segmentation. (a) Knife; (b) motorbike; (c) lamp

语义分割部分结果对比如图 16 所示。选取 S3DIS 数据集 area1 中三个场景(Area 1_Conference Room 2、Area 1_Office Room 2、Area 1_Hallway 1),

本文算法选取量化网络自调节的池化方式对比真实标签,与 BiPointNet 相比,本文方法的语义分割精度更高。




图 16 语义分割部分结果。(a) Area 1_Conference Room 2; (b) Area 1_Office Room 2; (c) Area 1_Hallway 1

Fig. 16 Partial results of semantic segmentation. (a) Area 1_Conference Room 2; (b) Area 1_Office Room 2;

(c) Area 1_Hallway 1

3.5 复杂度分析

量化模型性能的综合评价指标一般选取时间复杂度和空间复杂度[时间复杂度即浮点运算次数(FLOPs),空间复杂度即参数量],以及二者分别对应的加速比和压缩比。实验指标具体包括单样本浮

点运算数(FLOPs/sample)、加速比、参数量和压缩比 4 项。本文主要对 PointNet 分类量化模型的复杂度进行对比分析,分割量化模型及其余主流点云量化模型的复杂度分析方法与其类似。表 8 列出基于不同量化方法的 PointNet 量化分类模型理论层

表 8 复杂度对比结果

Table 8 Complexity comparison results

Method	Pooling type	FLOP per sample /Mbit	Speedup ratio S_r	Parameter P_s /Mbit	Compression ratio C_r
Full precision	MAX	443.38	1	3.48	1
	MAX	8.35	53	0.15	23
BNN	APSS1*	10.45	42	0.15	23
	APSS2*	12.56	35	0.15	23
IRNet	MAX	8.94	50	0.16	22
	APSS1*	11.05	40	0.16	22
	APSS2*	13.15	34	0.16	22
	MAX	9.89	45	0.62	6
XNOR-Net	APSS1*	11.99	37	0.62	6
	APSS2*	14.09	31	0.62	6
	EMA	10.56	42	0.15	23
BiPointNet	APSS1*	10.56	42	0.15	23
	APSS2*	12.66	35	0.15	23
	MAX	8.46	52	0.15	23
Proposed model	APSS1*	10.56	42	0.15	23
	APSS2*	12.66	35	0.15	23

面的复杂度性能。分析得出,相比于全精度模型,本文所提算法的加速比为 35 以上,未进行池化优化的加速比甚至达到 52,仅次于未优化 BNN 的 53;压缩比可达到 23,是所列不同算法的最大值;不论是采用 APSS1* 还是 APSS2* 优化,引入参数量均很小,相比原模型的总参数量可忽略不计,所以压缩比均约为 23。另外,采用 APSS1* 或 APSS2* 优化的 BNN、IRNet、XNOR-Net 和 BiPointNet,利用 APSS1* 的平均加速比为 40,利用 APSS2* 的平均加速比为 34,而引入的参数量可忽略不计,所以压

缩比基本保持不变。XNOR-Net 基于通道量化,虽然精度较高,但相比于其他方法参数量大,压缩比仅为 6;从精度和复杂度理论层面综合分析,发现 BiPointNet 优于 BNN、IRNet、XNOR-Net,但在整体复杂度与 BiPointNet 相同的条件下,本文所提模型的精度更高。如图 17 所示,除 Hist+APSS2* 外的其他 5 种方法的综合性能优于 BiPointNet。综上所述,本文所提可学习二值量化模型在大幅提高精度的同时,具有较好加速和压缩效果,理论上其性能整体优于其他量化模型。

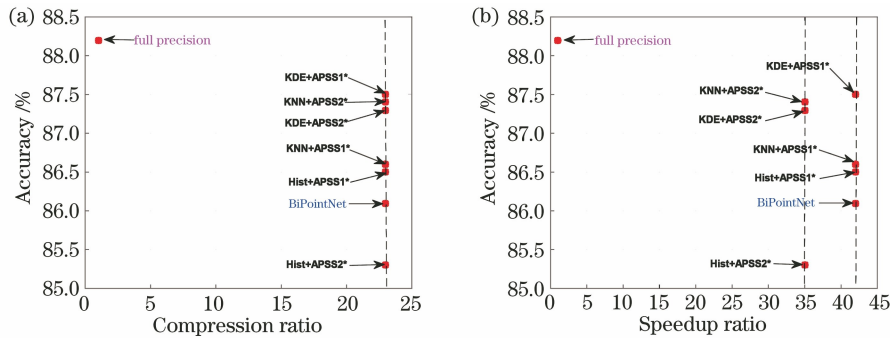


图 17 综合性能对比。(a)性能比较 1;(b)性能比较 2

Fig. 17 Overall performance comparisons. (a) Performance comparison 1; (b) performance comparison 2

在上述理论层面复杂度分析的基础上,下面将所提二值量化模型部署到实际移动端设备进行推理测试。本实验采取文献[24]方法,选取京东 AI 提出的二值推理框架 dabnn 在树莓派(Raspberry Pi 4B with 1.5 GHz 64-bit quad-core ARM CPU Cortex-A72)来测试模型实际推理速度,其中 dabnn 是针对移动平台优化的二值网络推理框架,使用 ARM 程序集实现二值卷积。实验中利用 ARM NEON 扩展结构 SIMD(Single Instruction Multiple Data)指令,将 PointNet 二值量化分类模型转换为 dabnn 模型,在树莓派上的推理时间对比如图 18 所示,量化模型池化方式均采用 APSS1*,本文所提方法实现 12.5 倍的加速,与 BNN、BiPointNet 加速性能相当,为最优加速。但受限于当前二值推理框架在硬件支持、指令优化及系统算法协同等方面存在的不完备性,实际推理加速与理论分析加速相差还比较大。

4 结 论

针对点云深度网络二值量化过程中的尺度严重变形及池化特征表达能力大幅下降的问题,提出基于遗传算法优化的二值量化尺度因子恢复方法以及统计自适应池化损失最小化方法。为了体现灵活性

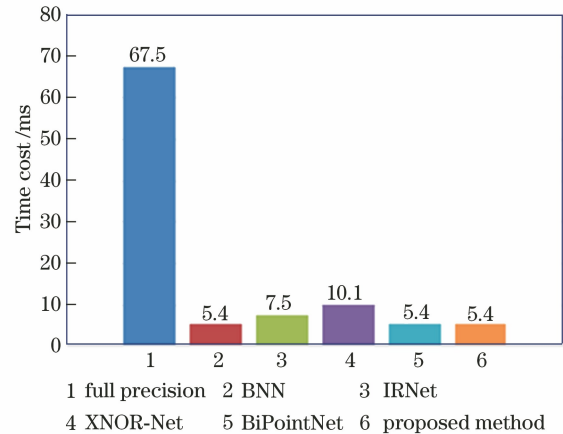


图 18 推理时间对比

Fig. 18 Inference time comparisons

并多方验证所提方案的有效性,SR 采取包括直方图估计、KDE 与 KNN 在内的多种概率密度估计方法,PLM 给出两种方案。消融实验分别证明了 SR 和 PLM 的有效性。通过与典型的二值量化方法进行对比实验,发现本文方法的结果更接近全精度模型的精度,这充分表明所提点云可学习二值量化网络模型在精度提升上的优越性。拓展实验主要包括点云分割和其他主流点云深度学习模型二值量化实验,实验结果显示本文方法的可移植性强,具有一定的拓展性和实用性。复杂度分析主要从空间复杂度

和时间复杂度方面考虑模型整体性能,结果显示本文方法在提升精度的同时并没有明显增加模型复杂度,压缩比和加速比性能与当前最优模型BiPointNet相当。综合实验分析,发现本文所提点云可学习二值量化网络模型在精度、加速和压缩性能方面总体优于当前最好的点云二值量化网络模型BiPointNet,更好地解决了量化尺度变形及池化特征匀质化问题。当然,点云深度网络模型二值量化表现出来的特殊性以及如何解决面向不同任务的点云深度网络模型二值量化问题仍然是该领域研究的热点与难点,值得进一步探索。

参 考 文 献

- [1] 宋召奇,朱精果,解天鹏,等. 安防激光雷达研究进展[J]. 激光与光电子学进展, 2021, 58(1): 0100002.
Song Z Q, Zhu J G, Xie T P, et al. Research progress on security LiDAR [J]. Laser & Optoelectronics Progress, 2021, 58(1): 0100002.
- [2] 李绕波,袁希平,甘淑,等. 一种基于对偶四元素描述的线面特征约束的点云配准方法[J]. 光学学报, 2022, 42(2): 0214003.
Li R B, Yuan X P, Gan S, et al. Point cloud registration method based on dual quaternion description of line-planar feature constraints[J]. Acta Optica Sinica, 2022, 42(2): 0214003.
- [3] 王爱丽,张宇泉,吴海滨,等. 基于空洞卷积胶囊网络的激光雷达数据分类[J]. 中国激光, 2021, 48(11): 1110003.
Wang A L, Zhang Y X, Wu H B, et al. LiDAR data classification based on dilated convolution capsule network[J]. Chinese Journal of Lasers, 2021, 48(11): 1110003.
- [4] Guo Y L, Wang H Y, Hu Q Y, et al. Deep learning for 3D point clouds: a survey[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, 43(12): 4338-4364.
- [5] 龙霄潇,程新景,朱昊,等. 三维视觉前沿进展[J]. 中国图象图形学报, 2021, 26(6): 1389-1428.
Long X X, Cheng X J, Zhu H, et al. Recent progress in 3D vision [J]. Journal of Image and Graphics, 2021, 26(6): 1389-1428.
- [6] Charles R Q, Hao S, Mo K C, et al. PointNet: deep learning on point sets for 3D classification and segmentation [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 77-85.
- [7] Qi C, Yi L, Su H, et al. Pointnet ++: deep hierarchical feature learning on point sets in a metric space [C] // Proceedings of Neural Information Processing Systems (NeurIPS), December 4-9, 2017, Long Beach, CA, USA. Massachusetts: The MIT Press, 2017: 1-10.
- [8] Li Y, Bu R, Sun M C, et al. PointCNN: convolution on x -transformed points [C] // Proceedings of Neural Information Processing Systems (NeurIPS), December 3-8, 2018, Montreal, Canada. Massachusetts: The MIT Press, 2018: 1-11.
- [9] Wang Y, Sun Y B, Liu Z W, et al. Dynamic graph CNN for learning on point clouds [J]. ACM Transactions on Graphics, 2019, 38(5): 1-12.
- [10] Wu W X, Qi Z A, Li F X. PointConv: deep convolutional networks on 3D point clouds [C] // 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 9613-9622.
- [11] Simons T, Lee D J. A review of binarized neural networks[J]. Electronics, 2019, 8(6): 661.
- [12] Hubara M, Courbariaux D, Soudry R, et al. Binarized neural networks [C] // Proceedings of Neural Information Processing Systems (NeurIPS), December 5-10, 2016, Barcelona, Spain. Massachusetts: The MIT Press, 2016: 1-9.
- [13] Rastegari M, Ordonez V, Redmon J, et al. XNOR-net: ImageNet classification using binary convolutional neural networks [M] // Leibe B, Matas J, Sebe N, et al. Computer vision-ECCV 2016. Lecture notes in computer science. Cham: Springer, 2016, 9908: 525-542.
- [14] Liu Z C, Wu B Y, Luo W H, et al. Bi-real net: enhancing the performance of 1-bit CNNs with improved representational capability and advanced training algorithm [EB/OL]. (2018-08-01) [2021-02-03]. <https://arxiv.org/abs/1808.00278>.
- [15] Qin H T, Gong R H, Liu X L, et al. Forward and backward information retention for accurate binary neural networks [C] // 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 2247-2256.
- [16] Courbariaux M, Bengio Y, David J P. BinaryConnect: training deep neural networks with binary weights during propagations [EB/OL]. (2015-11-02) [2021-03-05]. <https://arxiv.org/abs/1511.00363>.
- [17] Zhang D Q, Yang J L, Ye D, et al. LQ-nets: learned quantization for highly accurate and compact deep neural networks [M] // Ferrari V, Hebert M,

- Sminchisescu C, et al. Computer vision-ECCV 2018. Lecture notes in computer science. Cham: Springer, 2018, 11212: 373-390.
- [18] Gong R H, Liu X L, Jiang S H, et al. Differentiable soft quantization: bridging full-precision and low-bit neural networks [C] // 2019 IEEE/CVF International Conference on Computer Vision (ICCV), October 27-November 2, 2019, Seoul, Korea (South). New York: IEEE Press, 2019: 4851-4860.
- [19] Li Z F, Ni B B, Zhang W J, et al. Performance guaranteed network acceleration via high-order residual quantization [C] // 2017 IEEE International Conference on Computer Vision, October 22-29, 2017, Venice, Italy. New York: IEEE Press, 2017: 2603-2611.
- [20] Lin X, Zhao C, Pan W. Towards accurate binary convolutional neural network [C] // Proceedings of Neural Information Processing Systems (NeurIPS), December 4-9, 2017, Long Beach, CA, USA. Massachusetts: The MIT Press, 2017: 1-9.
- [21] Wang P S, Hu Q H, Zhang Y F, et al. Two-step quantization for low-bit neural networks [C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 4376-4384.
- [22] Faraone J, Fraser N, Blott M, et al. SYQ: learning symmetric quantization for efficient deep neural networks [C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 4300-4309.
- [23] Martinez B, Yang J, Bulat A, et al. Training binary neural networks with real-to-binary convolutions [EB/OL]. (2020-03-25) [2021-02-05]. <https://arxiv.org/abs/2003.11535>.
- [24] Qin H T, Cai Z G, Zhang M Y, et al. BiPointnet: binary neural network for point clouds [C] // Proceedings of International Conference on Learning Representations (ICLR), May 3-7, Virtual Event, Austria. [S.l.: s.n.], 2021: 1-24.
- [25] Bishop C M. Pattern Recognition and Machine Learning [M]. New York: Springer Press, 2006: 120-126.
- [26] Mitchell M. An introduction to genetic algorithms [M]. Massachusetts: The MIT Press, 1996: 27-59.
- [27] Robert M G. Entropy and information theory [M]. 2nd ed. New York: Springer, 2011: 61-96.
- [28] Wu Z R, Song S R, Khosla A, et al. 3D ShapeNets: a deep representation for volumetric shapes [C] // 2015 IEEE Conference on Computer Vision and Pattern Recognition, June 7-12, 2015, Boston, MA, USA. New York: IEEE Press, 2015: 1912-1920.
- [29] Chang A X, Funkhouser T, Guibas L, et al. ShapeNet: an information-rich 3D model repository [EB/OL]. (2015-12-09) [2021-02-03]. <https://arxiv.org/abs/1512.03012v1>.
- [30] Armeni I, Sener O, Zamir A R, et al. 3D semantic parsing of large-scale indoor spaces [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 1534-1543.