

# 量化权值激活的生成对抗网络



郑哲<sup>1,2,3</sup> 胡庆浩<sup>2</sup> 刘青山<sup>1,3</sup> 冷聪<sup>2</sup>

1 南京信息工程大学自动化学院 南京 210044

2 中国科学院自动化研究所南京人工智能芯片创新研究院 南京 211100

3 江苏省大数据分析技术重点实验室 南京 210044

(z.zheng@nuist.edu.cn)

**摘要** 近年来,生成对抗网络(Generative Adversarial Networks, GAN)在图像超分辨率、图像生成等许多计算机视觉任务中展现出优异的性能。借助于GPU强大的计算力,人们可以设计计算复杂度更高的GAN网络。然而,对于资源受限的移动端设备,高功耗、计算需求大的GAN将很难被直接部署到实际应用中。得益于神经网络压缩技术取得的巨大进展,将GAN部署到移动端设备成为可能。为此,文中提出一种同时对网络权值和激活进行量化的方案来压缩GAN网络。通过量化敏感性分析发现,与量化分类网络不同,GAN中的量化权重比量化激活更敏感,因此在量化时给予权重更多的量化比特。文中比较了两种评价GAN生成图像的指标即Inception Score(IS)和Fréchet Inception Distance(FID),发现FID更适合评估量化后GAN的性能。基于敏感性分析在Mnist和Celeb-A数据集上进行量化实验,用FID指标来评估量化GAN的性能。实验结果表明:在生成图像质量不下降的情况下,所提方法依然可以取得4倍以上的压缩率,从而有效地解决了GAN的压缩问题。

**关键词:** 生成对抗网络;资源受限;移动端设备;神经网络压缩;量化

**中图分类号** TP391

## Quantizing Weights and Activations in Generative Adversarial Networks

ZHENG Zhe<sup>1,2,3</sup>, HU Qing-hao<sup>2</sup>, LIU Qing-shan<sup>1,3</sup> and LENG Cong<sup>2</sup>

1 School of Automation, Nanjing University of Information Science & Technology, Nanjing 210044, China

2 Artificial Intelligence Chip Research, Institute of Automation, Chinese Academy of Science, Nanjing 211100, China

3 Jiangsu Key Lab of Big Data Analysis Technology, Nanjing 210044, China

**Abstract** In recent years, generative adversarial network have shown excellent performance in many computer vision tasks such as image super resolution, image generation and so on. GANs can be designed to be much more greedy in computation complexity because of huge quantity uses of GPU application. For mobile devices that are resource-limited, however, on which it is intractable for GAN on be deployed due to high consumption both in energy and computation. Thanks for great success in neural network compression, it is possible to deploy GAN on mobile devices. This paper proposed a method to simultaneously quantize weights and activations in GANs. Sensitivity analysis shows that weights are more sensitive than activation in quantization process. This paper used Fréchet Inception Distance (FID) score to evaluate generated images of quantized GANs for Inception score is less applicable than FID. Motivated by sensitivity analysis, extensive experiments were conducted on Mnist and Celeb-A datasets. Results show that the proposed method can compress GANs by up to 4x and still achieve even higher performance than the original GANs. Thus, it effectively resolves the problem of compressing GANs.

**Keywords** Generative adversarial networks, Source-limited, Mobile devices, Neural network compression, Quantization

### 1 引言

近年来,生成对抗网络<sup>[1]</sup>在计算机视觉领域取得了巨大成功,被广泛应用于图像生成、图像超分辨率、视频生成等任务。早期的生成对抗网络由全连接层组成,网络较小,性能也差强人意。得益于深度学习<sup>[2]</sup>的快速发展,GAN将卷积神经网络作为主干网络,并在图像超分辨率、图像生成等计算机视觉任务上取得了优异的性能。在深度学习中,全连接层相对

于卷积层具有计算量小、参数多的特点;而卷积层由于卷积操作和参数共享的特点,其参数较少,但计算量较大。由于卷积层数的增多,主流的卷积网络模型往往具有空间占用多、计算消耗大的特点,所具有的特点在GAN中也有体现。GAN由于使用大量卷积层,在前向推理时需要耗费更多的时间。例如,谷歌开发的BigGAN<sup>[3]</sup>在图像生成任务中取得了最好的结果,但其模型占用空间达1.9GB,前向推理需每秒上亿次浮点运算,模型的参数量和计算量都十分巨大。因此,将GAN

应用到资源受限的移动端将变得非常困难。

目前,神经网络压缩在图像分类领域已经取得了巨大的进展。网络压缩方法主要有5种:网络剪枝、低秩、量化、知识蒸馏、轻量级网络设计。这些方法都可以保证原始网络精度和网络压缩率的折中,主要分为两种情况:1)网络精度优先,在模型性能损失不大的情况下尽可能提高压缩率;2)压缩率优先满足硬件需求,在此情况下尽可能提高模型的精度。本文方法属于第一种,在性能无损的情况下,采用量化方法将GAN网络的比特数由浮点表示量化成低比特表示,直接在硬件上加速并减少模型占用的空间,以获得较高的压缩率。

即使图像分类任务上的网络压缩取得了巨大的进展,应用于GAN上的压缩工作也不多<sup>[4-5]</sup>。QGAN<sup>[4]</sup>基于EM算法提出了新的量化函数对生成网络和判别网络进行权值量化,而网络激活依旧为浮点数表达,在低比特甚至1bit的情况下依然能取得可观的性能。Angeline等<sup>[5]</sup>运用知识蒸馏的方法,用一个大的教师GAN网络指导学习一个小的GAN网络来获得较高的压缩率。对于图像生成任务而言,其最终目标是生成逼真的图片,但判别器的量化会导致生成器很难获得最优的梯度,从而使得生成网络很难收敛。本文不对判别网络量化,只对生成网络进行量化压缩,因此需要对权重和激活的量化进行敏感性分析。而GAN中的权重和激活对量化的敏感性与量化分类网络相反(敏感性分析见4.1节):量化权重比量化激活更敏感,即量化权重对性能的影响比量化激活对性能的影响更大。

本文的主要工作如下:1)通过敏感性分析发现,GAN中的量化权重比量化激活更敏感,因此在量化时对生成网络的权重进行较高比特量化,对激活进行较低比特量化;2)通过分析评估GAN性能的两种主要方法即FID<sup>[6]</sup>和IS<sup>[7]</sup>发现,在评估量化GAN的性能时FID比IS更合适;3)首次将GAN模型的权重和激活同时量化,且实验表明本文方法在性能无损的情况下依然能取得较高的压缩率。

## 2 相关工作

### 2.1 生成对抗网络

生成对抗网络由两个网络组成:判别网络 $D$ 和生成网络 $G$ 。 $D$ 判断 $G$ 生成的图像是否满足真实图像分布,即图像是否为真, $G$ 从预设的分布 $z \sim N(0, 1)$ 或 $z \sim U(-1, 1)$ 中采样来尽可能生成逼真的图像以欺骗判别网络。通过二者的博弈,使得生成网络不断提升自身的能力,直到能够欺骗判别网络。其训练的损失函数如下:

$$\min_G \max_D V(D, G) = E_{x \sim p_{data}(x)} [\log D(x)] + E_{z \sim p(z)} [\log(1 - G(z))] \quad (1)$$

通过最小化图像生成分布和真实分布的JS散度来训练生成网络。针对GAN训练不稳定而容易出现模式崩塌的问题,早期的工作<sup>[8-9]</sup>已探索了更优的网络结构。目前先进的GAN网络结构大多采用DCGAN<sup>[10]</sup>中所用的网络设置。为了进一步提高GAN的性能,文献<sup>[11-12]</sup>提出了新的损失函数。目前,BigGAN生成的图像已经达到了以假乱真的效果。在此基础上,本文主要研究在性能无损的情况下,如何降低GAN的模型存储,加快其推理速度。

### 2.2 量化

量化技术在网络压缩中直接有效,其将浮点型权重映射到对应的低比特定点表征空间,并利用低比特来压缩模型,利用定点数运算来提高运算速度。例如,文献<sup>[13]</sup>提出的XnorNet将网络中的权重和激活量化为1bit,相较于原始网络可以带来32倍的压缩率;由于激活的二值化,可以采用xnor操作快速地在硬件上实现前向推理,同时降低大量的内存占用和计算消耗。

在权重量化方面:BinaryConnect<sup>[14]</sup>将模型的权重二值化为一1和1,并在小数据集上取得了近乎无损的效果。文献<sup>[15]</sup>提出的BWN引入浮点型因子来提高网络表征能力,提升了二值化网络在大数据集上的性能,但在准确率上与原始网络仍有较大差距。文献<sup>[16]</sup>提出的BWNH从哈希保持内积的角度递进求解每层最优参数。文献<sup>[17]</sup>提出的ABCNet,将卷积核近似成若干二值基卷积核的线性组合。文献<sup>[18]</sup>提出了增量量化的策略。文献<sup>[19]</sup>提出的High-order通过不断近似量化的残差来减少量化误差。文献<sup>[20]</sup>提出的HBNN在神经元层次上学习到各自的量化比特。文献<sup>[21]</sup>将不同量化比特对硬件的影响作为输入,通过强化学习来自动学得网络每层的量化比特数。在权重激活量化方面:BNN在BinaryConnect基础上将权重和激活同时二值化。Dorefa<sup>[22]</sup>通过对浮点型权重、激活、梯度选择不同的量化比特数来取得模型在性能和大小上的折中。文献<sup>[23]</sup>提出的LQ-Net让网络学到最优的量化器来减少性能损失。文献<sup>[24]</sup>提出的GroupNet从网络结构近似的角度学得原始网络对应的二值网络。目前只有QGAN对GAN网络进行量化,其基于最大期望算法提出了新的量化函数对生成网络和判别网络进行权值的量化,在低比特甚至是1bit的情况下依然能取得可观的性能。本文方法仅对生成网络进行量化,同时量化生成网络的权重和激活,保持判别网络为浮点;而QGAN则是保持激活不变,对生成网络和判别网络的权值进行量化。

## 3 权重和激活的量化

本节分别介绍权重量化和激活量化及其对应的前向传播和反向传播,对权重进行多比特量化,并对激活进行二值量化。

### 3.1 量化方法

量化浮点权重和浮点激活为低比特,即将高比特空间的值映射到低比特空间,如图1所示。




图1 低比特量化

Fig. 1 Low bit quantization

图1中, $n$ 为量化比特数, $r_i$ 和 $r_o$ 分别表示原始浮点参数和量化后的定点数, $r_{\min}$ 和 $r_{\max}$ 分别表示 $r_i$ 的最小值和最大值。通过量化函数 $Q$ 将输入 $r_i$ 映射到 $r_o$ 上,即 $r_o = Q(r_i)$ 。显然,量化比特数越小,量化误差越大,由此带来的模型性能损

失也越大,因此在量化时需要在性能和压缩之间进行折中。在量化之前,有必要对 GAN 网络中的权重和激活进行敏感性分析,确定量化对权重和激活的具体影响来指导量化。与 HWGQ<sup>[25]</sup>一致,本文采用二值量化进行敏感性的验证,此时  $r_{o\_min} = -1, r_{o\_max} = 1$  (见 4.2 节量化敏感性分析)。由于量化 GAN 权重比量化激活对模型性能的影响更大,因此本文对权重给予更多的量化比特数,对激活给予较少的量化比特数。

### 3.2 权重量化

文献[15]提出了一种有效的二值量化方法 BWN,其将浮点权重近似为一个常数与二值矩阵的点乘。假设要量化的卷积核  $\mathbf{W} \in \mathcal{R}^{d \times w}$ ,其中  $c, h$  和  $w$  分别为卷积核的通道数、高和宽,则卷积核可近似表示为  $\mathbf{W} \approx \alpha \mathbf{B}$ ,其与输入  $\mathbf{I}$  的卷积表示为:

$$\mathbf{I} * \mathbf{W} \approx \alpha (\mathbf{I} \oplus \mathbf{B}) \quad (2)$$

其中,  $\oplus$  表示无乘法的卷积运算,  $\mathbf{B} = \text{sign}(\mathbf{W}), \alpha = \frac{1}{chw} \|\mathbf{W}\|_1$ 。

文献[22]提出的 Dorefa 使用多比特量化函数来量化卷积网络,可以将浮点参数量化至用户设定的比特数。其量化函数为:

$$r_o = \frac{1}{2^k - 1} \text{round}((2^k - 1)r_i) \quad (3)$$

其中,  $k$  为要量化的比特数,round 为取整操作。

训练时,由量化后的权重通过前向传播计算梯度。针对权重在量化后,损失函数将对其不可导的问题,本文采用 STE<sup>[26]</sup>,即在反向传播时损失函数  $c$  对  $r_i$  的导数近似为:

$$\frac{\partial c}{\partial r_i} = \frac{\partial c}{\partial r_o} \quad (4)$$

虽然量化权重可以极大地压缩模型占用的物理空间,但是其在计算复杂度上并无太大的提高,因此对激活进行量化显得十分必要。同时量化权重和激活,可以采用更快速、更易实现的逻辑和位计数运算<sup>[13,15]</sup>来极大地减少计算量。本文采用 BWN 进行 1 bit 量化,采用 Dorefa 来进行多比特量化。

### 3.3 激活二值量化

激活二值化中,通过 sign 函数来进行量化是最直接有效的方法。在 XnorNet 中,对权重进行二值化而引入的浮点因子在激活二值化中的影响可忽略,因此本文直接对激活进行二值量化,即前向的量化函数为:

$$r_o = \text{sign}(r_i) \quad (5)$$

由于 sign 函数不可导,因此采用 STE,近似损失函数对输入的导数为:

$$\frac{\partial c}{\partial r_i} = \frac{\partial c}{\partial r_o} I_{|r_i| \leq 1} \quad (6)$$

其中,  $I_{|r_i| \leq 1}$  为输入  $r_i$  绝对值小于 1 的参数,大于 1 的参数的梯度被截断为 0。

## 4 实验

本文在 DCGAN 和 WGAN<sup>[11]</sup>上进行实验,采用 pytorch 框架,在 Celeb-A 数据集上评估 IS 和 FID 能否反映生成图像质量的好坏,并对 GAN 中权重和激活的量化进行敏感性分析,最后在 Mnist 和 Celeb-A 两个数据集上给出不同比特数量化的结果。

### 4.1 生成图像评价

IS 和 FID 被广泛用于评估生成网络所生成图像的质量和多样性。IS 越大, FID 越小,则生成图像的质量越高,模型性能越好。然而,文献[27]指出用 IS 评价生成图像质量的效果并不理想, IS 越大并不能代表生成的图片越真实。因此,对于量化后 GAN 模型的性能评估,需要确定 IS 和 FID 是否能够反映生成图像的质量,以此来评估量化方法是否有效。本文共采样 5 万张量化后模型生成的图像,分别计算其与原始数据集图像的 IS 和 FID。


表 1 列出了 DCGAN 和 WGAN 在 Celeb-A 数据集上的 IS 得分。W/A 中的 W 代表权重量化的比特数, A 代表激活量化的比特数。可见, DCGAN 在 1/32 取得了最高 IS, WGAN 在 4/1 取得了最高 IS。

表 1 不同比特数量化的 DCGAN 和 WGAN 在 Celeb-A 数据集上的 IS 得分

Table 1 IS score of DCGAN and WGAN on dataset Celeb-A with different quantization bits

W/A	DCGAN	WGAN
32/32	2.470	2.400
1/32	<b>2.870</b>	—
32/1	2.510	2.310
8/1	2.700	2.314
4/1	2.430	<b>2.637</b>

为了验证该指标是否能反映图像质量,本文给出了对应的可视化图像,如图 2 所示。从可视化生成的图像来看, IS 指标并不能反映图像质量的好坏。



(a) 32 bit/32 bit (IS=2.47) (b) 1 bit/32 bit (IS=2.87) (c) 4 bit/1 bit (IS=2.637)

图 2 DCGAN 与 WGAN 不同量化比特下的可视化结果

Fig. 2 Visualizations of DCGAN and WGAN under different quantization bits

可以看出,图 2(b)和图 2(c)的图像质量明显差于图 2(a);图 2(c)出现模式崩塌,却依然可以得到很高的 IS。可见,采用 IS 来评估模型的性能并不合适<sup>[27]</sup>。因此,与 QGAN<sup>[4]</sup>采用 IS 来评估量化后模型和原始模型所生成的图像质量不同,本文采用 FID 来评估模型性能。

### 4.2 量化敏感性分析

在量化图像分类模型中,激活量化比权重量化更敏感<sup>[25]</sup>,如表 2 所列。

表 2 AlexNet 在 ILSVRC12 数据集上的量化准确率<sup>[25]</sup>

Table 2 Accuracy of quantized AlexNet on dataset ILSVRC12 (单位: %)

W/A	Top-1 准确率	Top-5 准确率
1/32	53.9	77.3
32/1	46.7	71.0

可以看出,保持激活为浮点而只对权重量化的模型的性

能明显好于仅量化激活的模型的性能。因此,需要验证 GAN 的量化是否也有相同的现象。

本文在 Celeb-A 数据集上进行敏感性分析,并在 DCGAN 和 WGAN 上对比权重二值激活浮点和权重浮点激活二值的 FID 得分,结果如表 3 所列。

表 3 DCGAN 和 WGAN 的 FID 得分

Table 3 FID score of DCGAN and WGAN

W/A	DCGAN	WGAN
32/1	81.6	92.3
1/32	220.1	不收敛

可以看出,只量化激活的结果要好于只量化权重的结果。因此在 GAN 的量化中,权重量化比激活量化更加敏感。

由于 WGAN 在权重二值激活浮点的情况不能收敛,因此对剩余 3 种情况进行可视化。从图 3 中可以看出,在超参数设置和量化函数相同的情况下,只二值化激活生成的图片明显好于只二值化权重所生成的图片,这一现象与量化图像分类模型相反,即 GAN 中的量化权重比量化激活更敏感。因此,相较于激活,在对上述 GAN 进行量化时给予权重更多的量化比特数。




图 3 DCGAN 和 WGAN 在不同比特数量化下的可视化结果

Fig. 3 Visualization of DCGAN and WGAN in different W/A bits

### 4.3 Mnist 数据集

Mnist 数据集是一个黑白手写数字数据库,包含 0-9 的 55000 张训练集图像和 10000 张测试集图像,每张图片的通道数为 1,大小为  $28 \times 28$  像素。表 4 列出了 DCGAN 和 WGAN 在不同比特数量化下的 FID 得分。

表 4 Mnist 数据集上的 FID 得分

Table 4 FID score on dataset Mnist

W/A	DCGAN	WGAN
32/1	4.66	64.02
8/1	14.98	56.08
4/1	102.75	-

进一步地,本文将不同比特数量化后 GAN 所生成的图像进行可视化。从图 4 和图 5 可见,量化后模型依然取得了较好的效果。




图 4 DCGAN 在不同比特数量化下的结果

Fig. 4 Results of quantized DCGAN by different bits



(a)32 bit/32 bit (b)32 bit/1 bit (c)8 bit/1 bit

图 5 WGAN 在不同比特数量化下的结果

Fig. 5 Results of quantized WGAN by different bits

### 4.4 Celeb-A 数据集

Celeb-A 是一个大规模的名人人脸属性数据集,其中有 10177 位名人的 202599 张人脸图片。该数据集由香港中文大学开放提供,被广泛用于人脸相关的计算机视觉训练任务,可用于人脸属性标识训练、人脸检测训练以及 landmark 标记。设置原始模型和量化模型的训练超参数相同,共生成 5 万张图片用于计算 FID。量化结果如表 5 所列。

表 5 DCGAN 和 WGAN 在不同比特数下的 FID 得分

Table 5 FID score of quantized DCGAN and WGAN with different bits

W/A	DCGAN	WGAN
32/32	103.86	91.07
32/1	81.56	92.30
8/1	85.37	88.39
4/1	81.45	189.64

从表 5 中可以看出,量化后 DCGAN 和 WGAN 的 FID 明显小于原始模型。生成图像分别如图 6 和图 7 所示。



(a)32 bit/32 bit (b)32 bit/1 bit (c)8 bit/1 bit (d)4 bit/1 bit

图 6 DCGAN 在不同比特数量化下的结果

Fig. 6 Results of quantized DCGAN by different bits

从图 6 可以看出,DCGAN 即使在权重为 4 bit、激活为 1 bit 的情况下,生成的图像质量仍媲美原始模型生成的图像。

图 7 中,WGAN 在量化权重为 8 bit、激活为 1 bit 的情况下,性能较原始模型并没有损失;而当权重量化为 4 bit 时,由于过低比特量化导致模型表征能力受限,模型性能显著下降。因此,在一定比特数下对 GAN 进行量化,其生成的图像质量甚至优于原始模型,这得益于量化的正则化<sup>[14]</sup>作用。



(a)32 bit/32 bit (b)32 bit/1 bit (c)8 bit/1 bit (d)4 bit/1 bit

图 7 WGAN 在不同比特数量化下的结果

Fig. 7 Results of quantized WGAN by different bits

**结束语** 本文同时对 GAN 的权重和激活量化,发现 FID 比 IS 更能对量化模型进行准确评估。通过权重和激活的量化敏感性分析发现,与量化分类网络不同,在量化 GAN 中,量化权重比量化激活更敏感;与分类网络量化相似,当权重和激活都量化为较低比特时,模型性能显著下降,这是由于低比特表示的参数使得模型相较于浮点型缺少强大的表征能力。未来将着重解决低比特量化下模型性能显著下降的问题。

## 参 考 文 献

- [1] GOODFELLOW IAN J. Generative adversarial nets[C]// Proceedings of the Neural Information Processing Systems. 2014: 2672-2680.
- [2] KRIZHEVSKY A. ImageNet classification with deep convolutional neural networks[C]// Proceedings of the Neural Information Processing Systems. 2012:1106-1114.
- [3] BROCK A, DONAHUE J, SIMONYAN K. Large Scale GAN Training for High Fidelity Natural Image Synthesis[J]. arXiv: 1809. 11096.
- [4] WANG P, WANG D, JI Y, et al. QGAN: Quantized Generative Adversarial Networks[J]. arXiv:1901. 08263.
- [5] ANGELINE A, CHIANG P, GAIN A, et al. Compressing gans using knowledge distillation[J]. arXiv:1902. 00159.
- [6] HEUSEL M, RAMSAUER H, UNTERHINER T, et al. GANs Trained by a TWO Time-Scale Update Rule Converge to a Local Nash Equilibrium[J]. arXiv:1706. 08500.
- [7] SALIMANS T, GOODFELLOW I, ZAREMBA W, et al. Improved Techniques for Training GANs[C]// Proceedings of the Neural Information Processing Systems. 2016:2234-2242.
- [8] MIRZA M, OSINDERO S. Conditional generative adversarial-nets[J]. arXiv:1411. 1784.
- [9] KARRAS T, AILA T, LAINE S, et al. Progressive growing of gans for improved quality, stability, and variation [J]. arXiv: 1710. 10196.
- [10] RADFORD A, METZ L, CHINTALA S. Unsupervised representation learning with deep convolutional generative adversarial networks[J]. arXiv:1511. 06434.
- [11] ARJOVSKY M, CHINTALA S, BOTTOU L. Wasserstein gan [J]. arXiv:1701. 07875.
- [12] GULRAJANI I, AHMED F, ARJOVSKY M, et al. CImproved training of wasserstein gans[C]// Proceedings of the Neural Information Processing Systems. 2017:5767-5777.
- [13] HUBARA I, COURBARIAUX M, SOUDRY D, et al. Binarized neural networks[C]// Proceedings of Neural Information Processing Systems. 2016:4107-4115.
- [14] COURBARIAUX M, BENGIO Y, DAVID J. Binaryconnect: Training deep neural networks with binary weights during propagations[C]// Proceedings of the Neural Information Processing. 2015:3123-3131.
- [15] RASTEGARI M. XNOR-Net: ImageNet Classification Using Binary Convolutional Neural Networks[C]// Proceedings of the European Conference on Computer Vision. 2016:525-542.
- [16] HU Q H, WANG P S, CHENG J. From Hashing to CNNs: Training Binary Weight Networks via Hashing[C]// Proceedings of the AAAI Conference on Artificial Intelligence. 2018: 3247-3254.
- [17] LIN X, ZHAO C, PAN W. Towards accurate binary convolutional neural network. [C]// Proceedings of the Neural Information Processing Systems. Montreal, 2017:345-353.
- [18] ZHOU A J, YAO A B, GUO Y W, et al. Incremental Network Quantization: Towards Lossless CNNs with Low-Precision Weights[J]. arXiv:1702. 03044.
- [19] LI Z, NI B, ZHANG W, et al. Performance guaranteed network acceleration via high-order residual quantization[C]// Proceedings of the International Conference on Computer Vision. 2017:2584-2592.
- [20] FROMM J, PATEL S, PHILIPPOSE M. Heterogeneous Bitwidth Binarization in Convolutional Neural Networks [C] // Proceedings of the Neural Information Processing Systems. 2018:4006-4015.
- [21] WANG K, LIU Z J, LIN Y J, et al. HAQ: Hardware-Aware Automated Quantization[J]. arXiv:1811. 08886.
- [22] ZHOU S C, WU Y X, NI Z K, et al. DoReFa-Net: Training Low Bitwidth Convolutional Neural Networks with Low Bitwidth Gradients[J]. arXiv:1606. 06160.
- [23] ZHANG D Q, YANG J L, YE D Q Z, et al. LQ-Nets: Learned Quantization for Highly Accurate and Compact Deep Neural Networks[C]// Proceedings of European Conference on Computer Vision. 2018.
- [24] ZHUANG B H, SHEN C H, TAN M K, et al. Structured Binary Neural Networks for Accurate Image Classification and Semantic Segmentation[J]. arXiv:1811. 10413.
- [25] CAI Z, HE X, SUN J, et al. Deep learning with low precision by halfwave gaussian quantization[C]// Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. New York: IEEE Press. 2017:5918-5926.
- [26] BENGIO Y, LÉONARD N, COURVILLE A. Estimating or propagating gradients through stochastic neurons for conditional computation[J]. arXiv:1308. 3432.
- [27] SHANE B, RISHI S. A Note on the Inception Score[J]. arXiv: 1801. 01973.



**ZHENG Zhe**, postgraduate. His main research interests include deep network compression and so on.



**LIU Qin-shan**, professor. His main research interests include image and vision analysis, including face image analysis, graph and hypergraph-based image and video understanding, medical image analysis, and event-based video analysis.