

## 噪声稳健性的卡方生成对抗网络

李洪均<sup>1,2,3,4</sup>, 李超波<sup>1</sup>, 张士兵<sup>1</sup>

(1. 南通大学信息科学技术学院, 江苏 南通 226019; 2. 计算机软件新技术国家重点实验室(南京大学), 江苏 南京 210093;  
3. 南通大学智能信息技术研究中心, 江苏 南通 226019; 4. 南通大学通科微电子学院, 江苏 南通 226019)

**摘 要:** 针对不同分布噪声下生成对抗网络生成样本质量差异明显的问题, 提出了一种噪声稳健性的卡方生成对抗网络。所提网络结合了卡方散度量敏感性和稀疏不变性的优势, 引入卡方散度计算生成样本分布和真实样本分布的距离, 减小不同噪声对生成样本的影响且降低对真实样本的质量要求; 搭建了网络架构, 构建全局优化目标函数, 促进网络不断优化并增强博弈的有效性。实验结果表明, 所提网络在不同噪声下的生成样本质量和稳健性优于目前几种主流网络, 且图像质量差异较小。卡方散度的引入不仅提高了生成样本质量, 而且提升了网络在不同噪声下的稳健性。

**关键词:** 生成对抗网络; 卡方散度; 噪声分布; 图像质量

**中图分类号:** TP391.41

**文献标识码:** A

**doi:** 10.11959/j.issn.1000-436x.2020041

## Noise robust chi-square generative adversarial network

LI Hongjun<sup>1,2,3,4</sup>, LI Chaobo<sup>1</sup>, ZHANG Shibing<sup>1</sup>

1. School of Information Science and Technology, Nantong University, Nantong 226019, China

2. State Key Laboratory for Novel Software Technology, Nanjing University, Nanjing 210093, China

3. Research Center for Intelligent Information Technology, Nantong University, Nantong 226019, China

4. TONGKE School of Microelectronics, Nantong University, Nantong 226019, China

**Abstract:** Aiming at the obvious difference of image quality generated by generative adversarial network under different noises, a chi-square generative adversarial network (CSGAN) was proposed. Combing the advantages of quantification sensitivity and sparse invariance, the chi-square divergence was introduced to calculate the distance between the generated samples and the original samples, which could reduce the influence of different noises on the generated samples and the quality requirement of original samples. Meanwhile, the network architecture was built and the global optimization objective function was constructed to enhance the adversarial performance. Experimental results show that the quality of the images generated by the proposed algorithm has little difference, and the network is more robust to different noises than the state-of-the-art networks. The application of chi-square divergence not only improves the quality of generated images, but also increases the robustness of the network under different noises.

**Key words:** generative adversarial network, chi-square divergence, noise distribution, image quality

收稿日期: 2019-06-12; 修回日期: 2020-01-07

**基金项目:** 国家自然科学基金资助项目 (No.61871241); 教育部产学研合作协同育人基金资助项目 (No.201802302115); 中国交通教育研究会教育科学研究课题基金资助项目 (No.交教研 1802-118); 南通市科技计划基金资助项目 (No.JC2018025, No.JC2018129); 南通大学-南通智能信息技术联合研究中心基金资助项目 (No.KFKT2017B04); 南京大学计算机软件新技术国家重点实验室基金资助项目 (No.KFKT2019B15); 江苏省研究生科研与实践创新计划基金资助项目 (No.KYCX19\_2056)

**Foundation Items:** The National Natural Science Foundation of China (No.61871241), Ministry of Education Cooperation in Production and Education (No.201802302115), Educational Science Research Subject of China Transportation Education Research Association (No.Jiaotong Education Research 1802-118), The Science and Technology Program of Nantong (No.JC2018025, No.JC2018129), Nantong University-Nantong Joint Research Center for Intelligent Information Technology (No.KFKT2017B04), Nanjing University State Key Laboratory for Novel Software Technology (No.KFKT2019B15), Postgraduate Research and Practice Innovation Program of Jiangsu Province (No.KYCX19\_2056)

## 1 引言

深度学习<sup>[1]</sup>作为一种训练深层神经网络的机器学习算法,被广泛应用于图像<sup>[2-4]</sup>、语音<sup>[5-6]</sup>、自然语言处理<sup>[7-8]</sup>、大数据特征提取<sup>[9-10]</sup>等方面。生成式网络是深度学习的重要组成部分,在无监督情况下可以获取数据的高阶特性,主要包括深度置信网络<sup>[11]</sup>、受限玻尔兹曼机<sup>[12]</sup>、自编码器<sup>[13]</sup>和生成对抗网络(GAN, generative adversarial network)<sup>[14]</sup>等。

GAN 不同于其他生成式模型,其避免了马尔可夫计算、变分下限和近似推断的复杂性,大大提高了应用效率;GAN 通过对抗学习生成逼真样本,在图像合成<sup>[15-17]</sup>、修复<sup>[18-20]</sup>、分类<sup>[21-23]</sup>、转换<sup>[24-26]</sup>等任务中表现出色。但是 GAN 在训练和优化过程中存在着一些问题<sup>[27-28]</sup>。例如,对抗训练过程中生成器与判别器之间需要很好的平衡,如果生成器退化且判别器误判,会导致模式崩塌问题,使生成的图像单一;梯度下降在非凸函数的情况下很难达到纳什均衡;当真实样本分布和生成样本分布没有重叠或重叠可忽略时,延森-香农(JS, Jensen-Shannon)散度接近定值,容易出现梯度消失问题。

针对 GAN 存在的问题,研究者们提出了有效的改进方法<sup>[29-30]</sup>。Radford 等<sup>[31]</sup>采用卷积和解卷积的方式代替全连接结构,并使用归一化提升训练的稳定性,可以生成多样化图像,但是仍需要平衡训练生成器和判别器。Salimans 等<sup>[32]</sup>提出增加判别器中间层的输出作为优化目标之一,虽然不能保证达到均衡,但提高了网络的稳定性。Arjovsky 等<sup>[33]</sup>通过理论分析说明了 JS 散度判断 2 个无重叠或重叠可忽略分布的功能受限问题。因此, Wesserstein 生成对抗网络(WGAN, Wesserstein GAN)<sup>[34]</sup>引入 Wesserstein 距离,在连续的约束下改进损失函数,解决了梯度消失等训练不稳定问题,从而生成丰富多样的样本。为了解决模式崩塌问题, Ghosh 等<sup>[35]</sup>提出了包含多个生成器和一个判别器的多主体、多样化生成对抗网络,在判定真假样本的同时找到制造假样本的生成器并优化。Mao 等<sup>[36]</sup>提出了最小二乘生成对抗网络(LSGAN, least squares GAN),使用最小二乘损失函数代替交叉熵损失,使图像分布尽可能地接近决策边界,提高图像质量。Chen 等<sup>[37]</sup>提出了一种基于感知损失函数的生成对抗网络,使用密集块构建生成器,生成更自然、更真实的图像。Tan 等<sup>[38]</sup>提出了一种提高图像质量的新策略,将损

失函数的梯度从分类识别器反向传播到生成器,同时反馈标签信息,使生成器能够更有效地学习,生成高质量的图像。Kancharla 等<sup>[39]</sup>提出了基于多尺度结构相似度指标的生成对抗网络,将结构相似度作为 GAN 中鉴别器损失函数的约束,保证局部结构的完整性,提高生成样本的视觉质量。

以上基于生成对抗网络的改进方法大致上可以分为 2 类:一类是为了缓解网络训练中出现的梯度消失、模式崩塌等问题,另一类是针对提高图像生成的质量进行改进。但是,很少研究工作考虑到不同输入噪声对图像生成质量的影响。文献[40]表明不同分布在数据拟合效果上具有一定的差异性,因而不同的噪声分布对生成样本质量有一定的影响。不同度量方法对计算分布间差异的准确性有直接影响,欧氏距离、L1 范数等只考虑绝对距离,忽视了相对距离。对于反映不同分布之间的距离,相对距离更有实际意义,卡方散度和熵可以有效反映相对距离。相比于熵,卡方散度没有对数和指数运算,其计算复杂度小,运算速度较快。此外,卡方散度还具有稀疏不变性和量化敏感性<sup>[41]</sup>,利于衡量不同分布间细微的差异。因此,有必要将卡方散度用于生成对抗网络中展开研究。

为了解决不同分布噪声下网络生成样本质量差异明显、稳健性差的问题,本文提出了一种噪声稳健性的卡方生成对抗网络(CSGAN, chi-square generative adversarial network)。该网络结合卡方散度稀疏不变性和量化敏感性的优势,构建网络优化的目标函数,引入卡方散度值作为评估生成样本和真实样本分布差异的依据,促进生成器和判别器在对抗中不断优化,使不同噪声下的生成样本分布能够尽量拟合真实样本分布,增强网络的稳健性。

## 2 相关工作

在大数据背景下,无监督的生成对抗网络得到广泛关注。同时,许多基于生成对抗网络的改进方法被提出,例如条件生成对抗网络<sup>[42]</sup>、深度卷积生成对抗网络<sup>[43]</sup>、能量生成对抗网络<sup>[44]</sup>等。下面详细介绍经典生成对抗网络和 Wasserstein 生成对抗网络。

### 2.1 经典生成对抗网络

经典生成对抗网络是一种典型的生成式网络,通过对抗学习并使用随机梯度下降法进行优化。这有效避免了马尔可夫链的反复使用,不需要进行变

分下限和近似推断,改善了生成式模型的训练难度和效率。如图1所示,生成对抗网络由以下两部分组成:生成器 $G$ 和判别器 $D$ 。生成器获取真实样本的分布,并根据所获取的分布重构样本;判别器相当于二分类器,用于判断输入数据来自真实样本还是由生成器产生的样本。GAN的基本思想是训练生成器 $G$ 和判别器 $D$ ,通过讨论极小极大化博弈问题寻求全局最优解,达到纳什均衡。

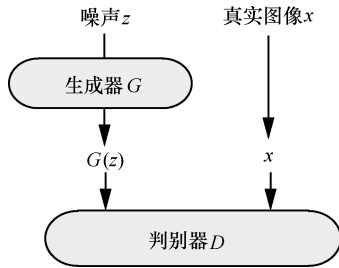


图1 生成对抗网络

生成器学习真实样本 $x$ 的分布 $p_d$ ,输入服从分布 $p_z(z)$ 的噪声 $z$ ,该噪声通过生成器映射到一个新的数据分布 $p_g$ ,得到 $G(z)$ 。然后,将真实样本 $x$ 与 $G(z)$ 共同输入判别器 $D$ 中,通过 $D(x)$ 表示输入的2个数据属于真实样本的概率并输出。初始状态下,真实样本的 $D(x)$ 值趋近于1,而生成样本的 $D(x)$ 值趋近于0;训练 $D$ 最大限度地正确区分生成样本和真实样本,同时训练 $G$ 混淆判别器 $D$ ,使其不能区分数据的来源。 $D$ 和 $G$ 的训练是关于值函数 $V(G,D)$ 的极小极大化博弈问题,如式(1)所示。

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

训练初期,当生成器 $G$ 的效果较差时,生成样本与真实训练的样本明显不同,判别器 $D$ 可以轻松判别生成样本为假图像。为了增加梯度信息,生成器 $G$ 选择最大化 $\log D(G(z))$ 代替最小化 $\log(1 - D(G(z)))$ 进行训练。当训练样本足够多时,对抗问题的全局最优解为 $p_d = p_g$ , $D^*(x) = \frac{1}{2}$ ,即真实样本分布与生成样本分布重合,网络达到纳什均衡状态。

## 2.2 Wasserstein 生成对抗网络

经典的GAN模型通过计算JS散度,比较 $p_g$ 和 $p_d$ 之间的距离,要求2个分布有重叠,但低维与高维之间有微小重叠或完全没有重叠的可能性非常大。因此,生成器存在无法逼近真实样本和模型崩塌的问题。Arjovsky等<sup>[34]</sup>从数据分布相似性度量

入手对GAN进行改进,提出Wasserstein生成对抗网络。通过将经典GAN中对概率分布的距离度量JS散度替换为Wasserstein距离,对于GAN算法进行部分调整,优化了经典GAN训练过程不稳定、训练后期生成器梯度消失、模型崩溃的问题,如式(2)所示。

$$W(p_d, p_g) = \sup_{\|f\|_L \leq 1} E_{x \sim p_d} [f(x)] - E_{x \sim p_g} [f(x)] \quad (2)$$

WGAN与经典GAN相比做了部分调整,具体如下。生成器和判别器的目标函数不取对数形式,采用RMSProp优化算法,判别器最后一层去掉Sigmoid激活函数;判别器参数更新后,通过截断方式将权重限定在一个固定区间,避免梯度消失。

## 3 卡方生成对抗网络

### 3.1 网络设计

不同评估方法会对计算不同分布间差异的准确性造成直接影响。欧氏距离、L1范数等考虑生成样本分布和真实样本分布之间的绝对距离,忽视了相对距离;卡方散度和熵可以有效反映不同分布之间的相对距离。对于计算不同分布之间的差异,相对距离往往更有实际意义。

卡方散度是F散度的一种形式,衡量2个分布,即 $P = (p_1, p_2, \dots, p_n)$ 和 $Q = (q_1, q_2, \dots, q_n)$ 差异的大小,其被定义为

$$\chi^2(P\|Q) = \sum_{i=1}^n \frac{(p_i - q_i)^2}{q_i} = \sum_{i=1}^n \frac{p_i^2}{q_i} - 1 \quad (3)$$

该散度满足非负性,当且仅当 $P$ 和 $Q$ 完全相同时, $\chi^2(P\|Q) = 0$ 。相比于熵,如GAN中典型的交叉熵

$$D(P\|Q) = \sum_{i=1}^n p_i \log \frac{p_i}{q_i}$$

数运算,其计算复杂度小,运算速度较快。卡方散度 $\chi^2(P\|Q)$ 与交叉熵 $D(P\|Q)$ 的关系满足 $0 \leq D(P\|Q) \leq \chi^2(P\|Q)$ ,表明基于卡方散度的方法比交叉熵法有更好的抗噪性能<sup>[45]</sup>。

此外,卡方散度具有量化敏感性和稀疏不变性<sup>[41]</sup>。量化敏感性表现为卡方距离对不同输入与标准模板之间的细微差异是敏感的。由于不同噪声服从不同的概率分布,当 $z$ 服从参数为 $\lambda$ 的泊松分布,且 $\lambda$ 充分大时, $z$ 渐近服从正态分布 $N(\lambda, \lambda)$ ;当 $z$ 服从参数为 $\alpha$ 和 $\beta$ 的伽马分布,且 $\alpha$ 趋于无穷大时, $z$

渐近服从正态分布  $N\left(\frac{\alpha}{\beta}, \frac{\alpha}{\beta^2}\right)$ 。虽然不同分布在极限条件下存在一定的关系，但是一般情况下很难达到极限条件。因此，不同输入噪声拟合出的生成样本分布具有一定的差异，即其与真实样本分布的距离也各不相同；卡方散度的量化敏感性可以度量不同噪声下生成样本分布与真实样本分布的差异，有利于减小不同噪声对生成样本分布的影响，因此使用卡方散度有助于缓解不同输入噪声下的稳健性问题。

卡方散度的稀疏不变性的定义是整体距离等于局部最优距离。由于真实样本中可能存在一些质量较差或不服从整体分布的独立样本，如果生成样本分布无限拟合真实样本分布，会产生独立样本，影响判别器和生成器的训练。此时，卡方散度的稀疏不变性有利于从整体数据中忽略独立样本，使用局部最优样本分布来代替整体分布。所以，将卡方散度作为样本分布差异的评价依据，可以降低对真实样本质量的要求，同时避免生成一些质量较差的独立样本。

因此，基于卡方散度构建卡方生成对抗网络的目标函数，如式(4)所示。根据极大极小值原理，判别器  $D$  希望生成器生成的图像质量较差，从而轻易地判别出真实样本和生成样本。生成器  $G$  根据判别器的反馈优化自身，直到可以混淆判别器的判断。

$$\max_G \min_D K(D, G) = E_{z \sim p_z(z)} [D^2(G(z))] - E_{x \sim p_d(x)} [D(x)] \quad (4)$$

其中，任意输入噪声  $z$  服从分布  $p_z$ ，且真实样本  $x$  服从分布  $p_d$ ，噪声经过生成器后形成生成样本  $G(z)$ 。判别器以卡方散度为衡量依据，当生成器生成样本与真实样本的卡方距离为 0 时，生成样本分布拟合真实样本分布，网络达到最优。

下面详细说明本文提出的卡方生成对抗网络中目标函数和卡方散度之间的关系，主要分为以下 2 个步骤：1) 假设生成器参数固定，寻找最优的判别器，且确定判别器的最优判别概率，目标函数取得最小值；2) 当判别器状态最优时，存在最优生成器使判别器可依据卡方散度计算出生成样本分布和真实样本分布的距离为 0，目标函数取得最大值。因此，通过相互博弈，以卡方散度为评价依据，网络的判别器和生成器均可达到最优状态。

一方面，以最小化目标函数为指导，先寻求最

优判别器。假设生成器固定，真实样本为  $x$  且服从分布  $p_d$ 。对于任意输入噪声  $z$  服从分布  $p_z$ ，噪声  $z$  经过生成器后得到服从分布  $p_g$  的生成样本  $G(z)$ 。当生成样本和真实样本同时输入判别器  $D$  时，目标函数可以写为

$$K(D, G) = \int_x (p_g(x)D^2(x) - p_d(x)D(x))dx \quad (5)$$

因此，根据生成样本分布和真实样本分布求目标函数的最优解，可得到定理 1。

**定理 1** 给定生成器，最优判别器为

$$D^*(x) = \frac{p_d(x)}{2p_g(x)} \quad (6)$$

当目标函数取最小值时，判别器达到最优。

**证明** 训练判别器的判别能力时，最小化目标函数  $K(D, G)$ ，即

$$\begin{aligned} K(D, G) &= E_{z \sim p_z(z)} [D^2(G(z))] - E_{x \sim p_d(x)} [D(x)] = \\ &= \int_z p_z(z)D^2(G(z))dz - \int_x p_d(x)D(x)dx = \\ &= \iint_{z,x} p_z(z)p(x|z)D^2(G(z))dzdx - \int_x p_d(x)D(x)dx = \\ &= \int_x p_g(x)D^2(x)dx - \int_x p_d(x)D(x)dx = \\ &= \int_x (p_g(x)D^2(x) - p_d(x)D(x))dx \end{aligned} \quad (7)$$

对于任意分布的  $p_g$  和  $p_d$ ，二次凸函数  $p_g(x)D^2(x) - p_d(x)D(x)$  在  $\frac{p_d(x)}{2p_g(x)}$  时取最小值，目标函数  $K(D, G)$  取得最小值。即生成器固定时，判别器最优为  $D^*(x) = \frac{p_d(x)}{2p_g(x)}$ 。证毕。

另一方面，当判别器达到最优时，以最大化目标函数为目的，寻找最优生成器。将最优判别器的表达式代入目标函数，可以写为

$$T(G) = K(D^*, G) = \int_x -\frac{p_d^2(x)}{4p_g(x)} dx \quad (8)$$

从式(8)可以看出生成样本分布和真实样本分布的关系，最优的生成器希望目标函数取最大值，因此，可以得到定理 2。

**定理 2** 当判别器达到最优时，存在最优生成器使  $p_g = p_d$ ，目标函数取得全局最大值  $-\frac{1}{4}$ 。

**证明**

1) 充分性。当  $p_g = p_d$  时， $D^*(x) = D^*(G(z)) = \frac{1}{2}$ ；

代入目标函数，可得  $T(G) = \left(\frac{1}{2}\right)^2 - \frac{1}{2} = -\frac{1}{4}$ 。

2) 必要性。当判别器达到最优时，目标函数可以写为  $T(G) = K(D^*, G)$ ，可得

$$\begin{aligned}
 T(G) &= \max_G K(D^*, G) = \\
 &E_{z \sim p_z(z)} [(D^*(G(z)))^2] - E_{x \sim p_d(x)} [D^*(x)] = \\
 &E_{x \sim p_g(x)} [(D^*(x))^2] - E_{x \sim p_d(x)} [D^*(x)] = \\
 &E_{x \sim p_g(x)} \left[ \left( \frac{p_d(x)}{2p_g(x)} \right)^2 \right] - E_{x \sim p_d(x)} \left[ \frac{p_d(x)}{2p_g(x)} \right] = \\
 &\int_x p_g(x) \left( \frac{p_d(x)}{2p_g(x)} \right)^2 dx - \int_x p_d(x) \frac{p_d(x)}{2p_g(x)} dx = \\
 &\int_x -\frac{p_d^2(x)}{4p_g(x)} dx \tag{9}
 \end{aligned}$$

根据卡方散度的定义，将式(9)转换为卡方散度的表示形式，如式(10)所示。

$$T(G) = -\frac{1}{4} - \frac{1}{4} \chi^2(p_d \| p_g) \tag{10}$$

其中， $\chi^2$ 表示卡方散度。最大化式(9)的值就等同于最大化式(10)的值，由于2个分布之间的距离非负，当 $p_g$ 和 $p_d$ 的卡方距离为0时， $T(G)$ 取最大值，即当 $p_g = p_d$ 时， $\chi^2(p_d \| p_g) = 0$ ， $T(G) = -\frac{1}{4}$ 最大，生成器学习到了真实样本的分布，网络达到最优。证毕。

因此，在判别器与生成器相互博弈过程中，以卡方散度为评价依据可以降低网络对真实样本质量的要求，有利于生成样本分布拟合真实样本分布，找到最优的生成器使生成样本逼近真实样本，直到判别器难以辨识，网络达到最优。

### 3.2 网络搭建

网络设计主要包括生成器和判别器2个部分，结构如图2所示。生成器相当于解码器，主要利用解卷积实现每一层特征图像的获取，生成最终图像。在图像生成过程中，首先输入噪声 $z$ ，经过全连接将噪声转换到张量空间；然后通过3层解卷积，每一层的输出作为下一层的输入，设置卷积核大小为 $5 \times 5$ ，步长为 $2 \times 2$ ，除最后一层卷积后使用Tanh激活外，其他网络层获取的特征都进行归一化处理并使用ReLU函数激活；最后生成样本。

判别器相当于编码器，对生成样本进行评估，其输入为真实样本和生成样本，通过3层卷积提取特征，设定卷积核为 $5 \times 5$ ，步长为 $2 \times 2$ 。与生成器不同，判别器中的激活函数采用Leakly ReLU函数。第一层卷积后采用Leakly ReLU激活函数，其他两层卷积后的特征归一化后再进行Leakly ReLU激活；卷积后学习到的特征经过全连接输出判别概率，判别图像的真实性。

生成器、判别器对抗的目标函数基于卡方散度，生成器的目标是最小化生成样本分布和真实样本分布的卡方距离，而判别器则相反。因此网络优化的损失函数可以根据目标函数进行确定，定义为

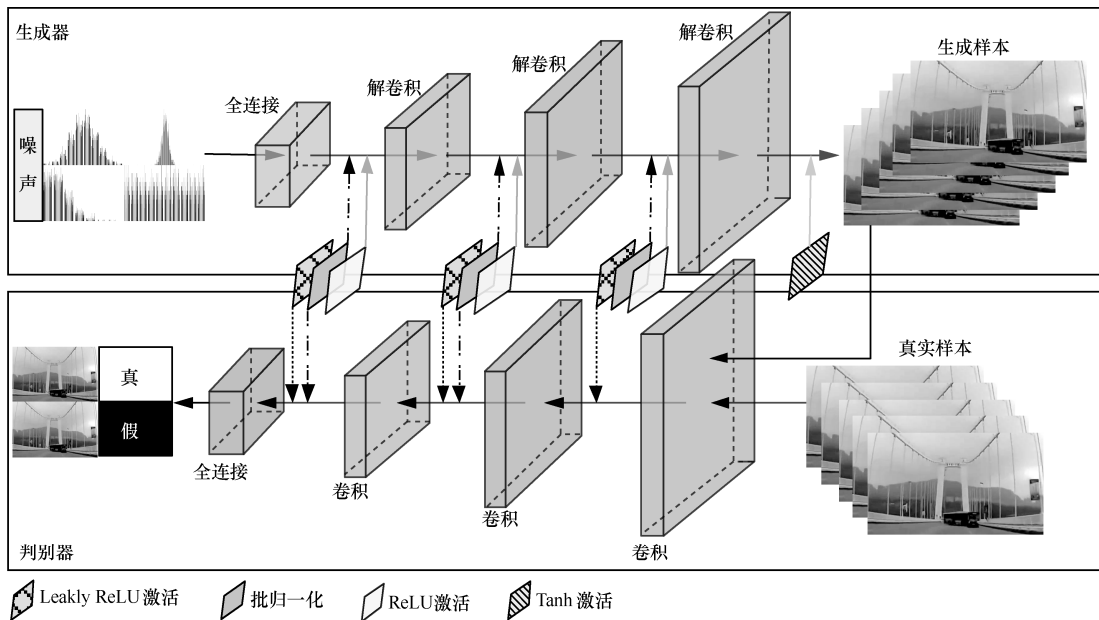


图2 CSGAN 结构

$$\begin{aligned} D\_loss &= D^2(G(z)) - D(x) \\ G\_loss &= -D(G(z)) \end{aligned} \quad (11)$$

优化过程中生成器和判别器的目标均为最小化损失函数的值。判别器判定输入真实样本的概率  $D(x) \in [0, 1]$ ，判定生成样本的概率  $D(G(z)) \in [0, 1]$ 。判别器在训练过程中希望  $D(G(z))$  尽可能小，那么可以对其进行缩小，因此判别器损失中使用  $D^2(G(z))$ ，而判断真实样本的概率  $D(x)$  不变。生成器希望  $D(G(z))$  的值尽可能大，因此在生成器优化时  $D(G(z))$  的值不进行缩放。这样主要有以下 2 个优势。1)  $D^2(G(z))$  作为生成样本属于真实样本的概率，相当于对  $D(G(z))$  自动按比例进行缩小，如果  $D(G(z))$  较大，即判别器判定生成样本接近真实样本，缩小的比例较小；反之，生成样本和真实样本差异大，缩小的比例较大，促使判别器分辨真实样本和生成样本的能力更强。2) 判别器分辨真实样本和生成样本能力强，避免了在生成样本质量较差时判别器给生成器错误的反馈；同时减少计算量，加快网络训练速度。由于自适应优化器的超参数一般不需要调整，且自动调整学习率，适用于梯度存在很大噪声的优化，因此生成器和判别器都采用 RMSProp 自适应优化器，初始化优化器的学习速率为  $5 \times 10^{-5}$ 。

训练时根据输入的真实样本优化判别器，生成器生成样本后输入判别器，判别器更新并向生成器反馈信息更新生成器，网络参数不断更新优化，实现生成器和判别器的相互对抗。

### 3.3 算法流程

卡方生成对抗网络算法流程如下。

迭代次数为  $m$ 。

1) 生成器

输入 噪声  $z$  服从分布  $p_z(z)$

更新生成器梯度， $\nabla \sum D(G(z))$

输出 生成样本  $G(z)$

2) 判别器

输入 噪声  $z$  服从分布  $p_z(z)$ ，真实样本  $x$  服从  $p_d$ ，生成样本  $G(z)$  服从  $p_g$

更新判别器梯度， $\nabla \sum (D^2(G(z)) - D(x))$

输出 真假图像判别概率

更新生成器和判别器参数。

重复  $m$  次 1) 和 2)，实现对抗，可视化生成样本。

## 4 实验与仿真

实验在深度学习框架 TensorFlow 上实现。实验的硬件环境为英特尔酷睿 i7 6800K 处理器，主频为 3.40 GHz，英伟达 GTX 1080 显卡；软件环境为 Windows 10 操作系统，Anaconda3 软件下的 Python3.5 平台，Cuda 9.0 和 Cudnn 6.0 支撑。该配置是目前深度学习计算的主流配置之一。在仿真实验中，算法采用相同的参数配置。在 CIFAR-10 和 MNIST<sup>[46]</sup>数据集上验证算法的有效性。

### 4.1 MNIST 验证

MNIST 是深度学习领域常见的数据集，共 70 000 张大小为 28 像素×28 像素的手写数字图像，有 60 000 张训练图片和 10 000 张测试图片，一部分来自人口普查局员工，另一部分从高中学生中收集。本次实验将标准高斯噪声作为输入，使用所有训练集图像进行训练，对比 GAN、LSGAN、WGAN 和 CSGAN 在相同迭代次数下生成样本的质量，比较网络的性能。训练和测试过程中网络参数设置均相同，即学习率为  $5 \times 10^{-5}$ ，批处理大小为 50，最大迭代次数为 30 000 次，生成样本大小为 28 像素×28 像素，经过不同迭代间隔，使用 1 000 张测试集图像对网络进行测试。图 3 展示了不同算法在不同迭代次数下生成的手写数字图像。

在不同迭代次数下可视化生成样本，图 3 坐标轴外是从测试数据集中随机抽取的真实样本，坐标轴内是生成样本，横坐标为迭代次数，纵坐标为使用不同的对抗网络。图 3 中可准确辨识图像用方框进行标记，从上到下依次是 GAN、LSGAN、WGAN 和 CSGAN 的生成样本。从图 3 中可以看出，迭代初期 4 个网络均生成无法辨识的图像，CSGAN 在迭代 2 000 次左右可以生成可辨识数字，而 WGAN 在迭代 3 000 次左右才开始生成可辨识数字，经典 GAN 和 LSGAN 需要更多次迭代才能生成可辨识数字。本文所提 CSGAN 在判别器的判别能力增强后给予生成器反馈，引入卡方散度评估生成样本分布和真实样本分布的差异，有利于增强生成器的对抗能力，可更快生成可辨识的样本。因此在相同迭代次数条件下，CSGAN 生成的可辨识数字多于其他网络，也就是说如果达到相同数量的可辨识图像，CSGAN 需要较少的迭代次数，有利于节约计算资源。

除了可视化图像外，网络中训练损失值和测试

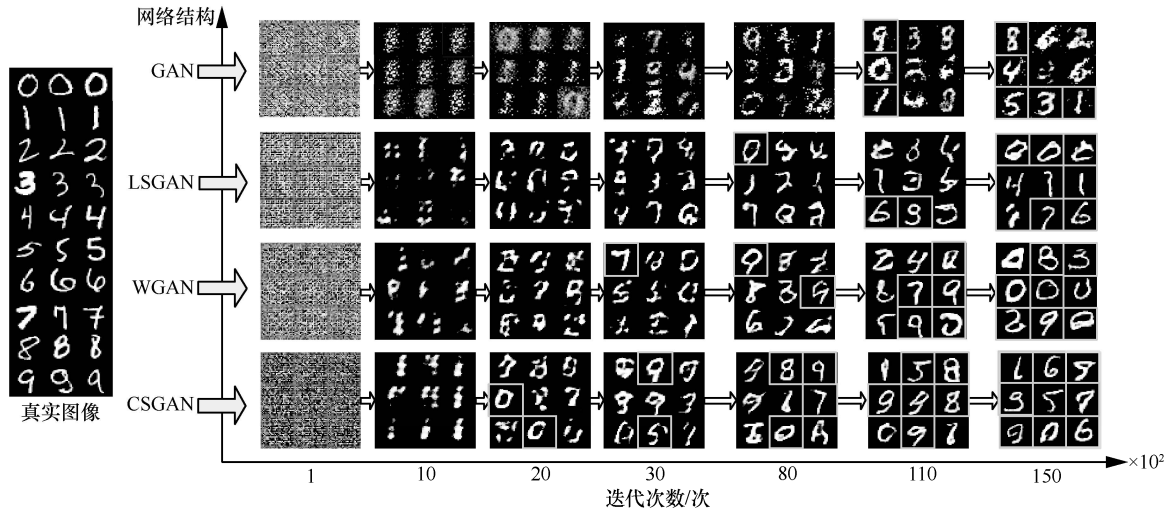


图 3 在不同迭代次数下不同方法的生成样本对比

损失值的变化趋势也反映了网络的收敛情况。因此为了进一步比较网络的性能，本节分析了不同迭代次数下网络损失值的变化趋势。

理论上，GAN 在达到最优时判别器和生成器损失分别为  $\ln 4$  和  $\ln 2$ <sup>[14]</sup>；LSGAN 中网络达到最优时，判别器损失值为 1.25 且生成器损失值为  $-0.125$ <sup>[36]</sup>；WGAN 中网络最优时判别器的损失值为 0，生成器的损失值为  $-0.5$ <sup>[34]</sup>；所提 CSGAN 达到最优时判别器的损失值为  $-0.25$ ，生成器的损失值为  $-0.5$ 。为了更直观地比较不同网络损失值的变化趋势，将 GAN 的判别器损失和生成器损失分别向下平移 1.4 和 1.2 个单位、LSGAN 的判别器损失向下平移 1 个单位后绘图。此时如果网络收敛，GAN 判别器和生成器损失分别趋近于 0 和  $-0.5$ ；LSGAN 判别损失趋近于 0.25。图 4(a)反映了训练过程中 4 个网络判别器损失值整体的变化趋势，均为先减小再增大最后趋于

平缓。产生这种趋势的原因是，训练初期相比于生成器，判别器的优化能力更强；随着迭代次数的增加，生成器的优化能力逐渐提升，提高了与判别器对抗的能力；直到最后生成器和判别器都达到最优。当损失趋于平缓时，CSGAN 的判别器损失趋近于  $-0.3$ ，与理论值接近，网络收敛；而 WGAN 的判别器损失值仍存在小幅度上升趋势，说明 WGAN 没有达到完全收敛；LSGAN 和 GAN 的损失值都稳定在  $-0.1$  左右，并没有收敛到理论值 0.25 和 0。这是由于 WGAN 需要权重裁剪而导致收敛速度较慢，LSGAN 和 GAN 在实际情况下受到网络优化的影响难以达到理论效果。其中，图 4(a)中局部放大图反映了迭代前 100 次判别器损失值的下降过程，可以直观地看出 GAN 的下降趋势与其他 3 种网络略有不同，判别器损失值并没有达到最小值，原因在于 GAN 判别器优化的速度较慢；相比于

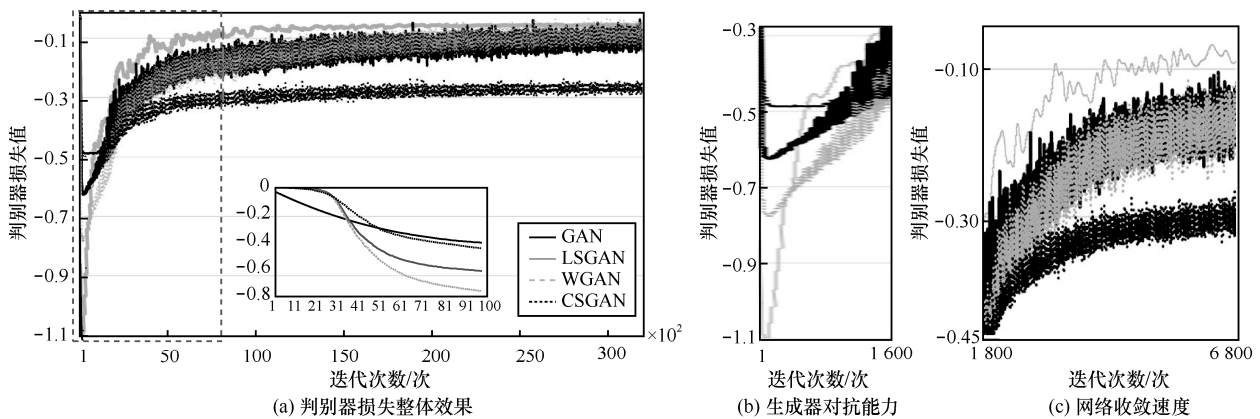


图 4 训练时判别器损失值的变化趋势

LSGAN 和 WGAN, 虽然 CSGAN 下降的幅度略小, 但是判别器开始下降的时间较早。图 4(b)和图 4(c) 是图 4(a)中虚线框内曲线的局部放大图, 图 4(b)反映了判别器损失达到最小后 CSGAN 的判别器损失值保持一段时间后才开始上升, 这是由于训练初期 CSGAN 中生成器的对抗能力较弱。但是如图 4(c)所示, 随着迭代次数的增加, CSGAN 判别器收敛更快, 因为增强判别器的判别能力后, 虽然网络训练初期生成器的性能较差, 但是后期生成器的对抗能力得到有效提高, 有利于生成更高质量的图像。

每迭代 100 次后进行网络测试, 图 5 展示了测试时不同网络生成器和判别器损失的变化趋势。测试和训练时判别器损失的趋势大致相似, 不同的是进行 100 次训练后判别器的损失下降幅度较小; GAN 和 WGAN 中生成器的损失下降速度先快后慢, 而 CSGAN 生成器损失的下降速度先慢后快, 主要是由于卡方散度计算复杂度小, CSGAN 收敛的速度较快。相比于其他网络, CSGAN 的生成器和判别器损失值在达到稳定时更加趋近于理论值, 收敛性更好。




图 5 测试时不同网络损失值的变化趋势

### 4.2 CIFAR-10

CIFAR-10<sup>[46]</sup>相比 MNIST 数据集所含的信息量更大。其共有 60 000 张三通道图像, 图像大小是 32 像素×32 像素, 包括飞机、汽车、鸟、猫、鹿、狗、青蛙、马、船和卡车 10 类图像, 每类 6 000 张图像。汽车和卡车之间没有重叠, 汽车包括轿车、SUV, 卡车只包括大型卡车。其中, 每 10 000 张图像作为一批, 五批用于训练, 一批用于测试。采用 CIFAR-10 中的训练集样本进行训练, 采用标准高斯噪声作为生成器的输入。设置学习率为  $5 \times 10^{-5}$ , 第一批处理 64 张图像, 迭代的最大次数为  $2 \times 10^5$  次, 生成样本大小为 32 像素×32 像素, 使用 10 000 张测试集图像对网络进行测试。实验中分别对 GAN、LSGAN、WGAN 和 CSGAN 在相同迭代次数下进行对比。图 6 展示了真实样本和不同算法生成样本的对比效果。



图 6 真实样本以及 GAN、LSGAN、WGAN、CSGAN 生成图对比

图 6 展示了 CIFAR-10 数据库部分图像和不同网络在标准高斯噪声下的部分生成图, 由于原始图像尺寸较小且分辨率较低, 很难观察出不同生成样

本质量的差异。为了定量评价生成样本的质量，文献[47]使用了目前主流的起始分（IS, inception score）和 Fréchet 起始距离（FID, Fréchet inception distance）对不同网络生成的样本进行评估。其中，IS 值是通过网络 InceptionNet 在 ImageNet 数据库上进行预训练计算得到的，值越高表示图像的不确定度越低，图像的生成质量越好；FID 表示真实样本和生成样本在特征空间上的距离，值越低表示生成样本越接近真实样本。

为了探究所提出网络的性能，在 CIFAR-10 上比较不同输入噪声对网络稳健性和生成样本质量的影响。实验主要探究离散型的泊松分布  $z \sim P(1)$  和连续型的正态分布  $z \sim N(0,0.1)$ 、标准高斯分布  $z \sim N(0,1)$ 、均匀分布  $z \sim U(0,1)$ 、伽马分布  $z \sim \text{Ga}(0,1)$ 、截断高斯分布下的噪声。

LSGAN 的参数设置参考文献[42]。在不同噪声下分别训练网络并测试，从生成样本中随机抽取 1 000 张，从迭代停止前 30 000 次开始每隔 1 000 次计算 IS 值，获取最大值并求取平均值。表 1 展示了不同噪声下各网络生成样本质量的评价指标。从整体来看，IS 平均值和最大值具有一致性，相同噪声条件下，所提 CSGAN 生成样本的 IS 值普遍高于经典 GAN、LSGAN 和 WGAN，这是由于 CSGAN 生成样本的质量优于其他网络。在不同噪声下，GAN 和 WGAN 在均匀噪声下效果较好，IS 均值分别达到 5.14 和 5.47；LSGAN 在标准高斯分布的噪声下 IS 均值较高，为 5.17；CSGAN 在服从任意分布的输入噪声下，评估生成样本得到的 IS 均值在 5.40 左右，最高均值达到 5.53。这是由于卡方散度具有稀疏不变性，会忽略真实样本中可能存在一些质量较差或不服从整体分布的独立样本，避免生成一些质量较差的独立样本，从而提高生成样本的整体质量。同一方法中最大 IS 均值和最小值的差定义为

IS 波动值，波动值越小说明生成样本质量越稳定。4 种网络的 IS 波动值分别为 1.45、0.26、0.36 和 0.16，CSGAN 的 IS 波动值小于其他网络，原因是卡方散度具有量化敏感性，有利于减小不同噪声对生成样本分布的影响，因此网络受输入噪声的影响较小，稳健性较强。

为了进一步探究训练过程中生成样本质量的变化情况及不同网络的优化情况，在不同迭代次数下进行实验。表 2 反映了不同噪声下生成样本 IS 值随迭代次数的变化情况。每迭代 1 000 次后对生成样本进行测试，每隔 10 000 次计算一次平均 IS 值。从表 2 中可以直观地看出，在同一迭代范围内，同一网络在不同输入噪声下生成样本的质量有一定的差异，不同网络在相同噪声下的生成质量也不相同；训练后期，由于 GAN 优化过程中梯度消失，在伽马分布、泊松分布、截断高斯分布、正态分布这 4 种噪声下出现网络崩塌问题，对噪声的稳健性差；CSGAN 在训练中期生成样本的质量开始优于 3 种对比网络，并在后期一直保持优势。其原因是判别器判别真假的能力增强后给予生成器反馈，在训练中期促进生成器增强对抗能力，更有利于生成更高质量的样本。

为了进一步验证网络在不同噪声下的性能，从测试样本中抽取 1 000 张图像作为标准数据集，随机抽取 128 张生成样本计算 FID 值。图 7 显示了不同网络在不同噪声下生成样本的 FID 值。由于伽马噪声和正态分布噪声对生成样本质量的影响较大，不同网络在这 2 种噪声下的 FID 出现峰值。不同噪声下由于卡方散度具有量化敏感性和稀疏不变性，CSGAN 生成样本的 FID 普遍较小，最大值和最小值分别为 186 和 175，波动范围小，这进一步说明了 CSGAN 有利于提高生成样本的质量且对噪声的稳健性较强。

表 1 CIFAR-10 不同噪声分布下各网络生成样本的 IS 值

噪声分布	GAN		LSGAN		WGAN		CSGAN	
	均值	最大值	均值	最大值	均值	最大值	均值	最大值
标准高斯 $N(0,1)$	5.04	5.21	<b>5.17</b>	<b>5.47</b>	5.37	5.51	5.52	5.77
正态分布 $N(0,0.01)$	4.47	4.83	5.10	5.40	5.27	5.53	5.44	5.72
截断高斯分布	4.87	5.07	5.11	5.30	5.11	5.42	5.49	5.74
均匀分布 $U(0,1)$	<b>5.14</b>	<b>5.39</b>	5.12	5.41	<b>5.47</b>	<b>5.77</b>	5.43	5.72
泊松分布 $P(1)$	4.42	4.75	5.00	5.27	5.36	5.51	<b>5.53</b>	<b>5.84</b>
伽马分布 $\text{Ga}(0,1)$	3.69	4.02	4.91	5.16	5.22	5.50	5.37	5.59

表 2 不同噪声分布下生成图像 IS 值随迭代次数的变化情况

迭代次数 $10^3$ 次	标准高斯 $N(0,1)$			正态分布 $N(0,0.01)$			截断高斯分布			均匀分布 $U(0,1)$			泊松分布 $P(I)$			伽马分布 $Ga(0,1)$									
	GAN	LSGAN	WGAN	CSGAN	GAN	LSGAN	WGAN	CSGAN	GAN	LSGAN	WGAN	CSGAN	GAN	LSGAN	WGAN	CSGAN	GAN	LSGAN	WGAN	CSGAN	GAN	LSGAN	WGAN	CSGAN	
	0~10	2.24	2.32	2.24	2.13	2.23	2.31	2.32	2.37	2.49	2.18	2.44	2.21	2.13	2.24	2.21	2.20	2.32	2.30	2.32	2.26	2.23	2.53	2.32	2.23
11~20	2.99	2.68	2.68	2.90	2.98	2.73	2.77	2.64	3.11	2.68	2.71	2.60	2.63	2.80	2.52	2.59	2.84	2.89	2.84	2.66	2.79	3.26	2.78	2.50	2.72
21~30	3.30	2.91	2.79	2.99	3.29	3.06	3.04	2.84	3.20	2.94	2.89	3.00	3.16	2.97	2.68	2.87	3.01	3.04	2.77	2.88	3.07	3.07	2.94	2.54	2.84
31~40	3.38	3.20	2.97	3.24	3.69	3.46	3.40	3.20	4.20	3.26	3.21	3.33	3.84	3.10	2.83	3.20	3.24	3.47	3.03	3.25	3.39	3.27	2.69	2.84	
41~50	4.00	3.66	3.28	3.76	3.74	3.73	3.75	3.64	3.46	3.44	3.68	3.37	3.73	3.39	3.22	3.42	3.83	3.69	3.41	3.35	3.51	3.59	2.90	3.29	
51~60	3.38	4.05	3.60	4.02	3.18	4.03	4.16	3.94	3.39	3.74	3.77	3.58	3.58	3.61	3.50	<b>3.72</b>	4.01	3.92	3.74	3.66	3.61	3.97	3.13	3.41	
61~70	3.50	4.21	3.59	4.07	4.01	4.29	4.26	4.14	3.66	3.93	3.81	3.71	3.69	3.70	3.67	<b>4.03</b>	4.24	4.21	3.95	4.05	3.94	4.09	3.51	3.70	
71~80	3.68	4.49	3.73	4.21	4.33	4.45	4.35	<b>4.43</b>	3.93	4.02	3.86	<b>4.11</b>	4.24	3.96	3.94	<b>4.36</b>	4.27	4.36	4.30	4.32	—	4.23	3.89	3.96	
81~90	4.01	4.56	4.13	4.45	3.99	4.60	4.50	<b>4.78</b>	4.05	4.16	4.03	<b>4.41</b>	4.45	4.18	4.28	<b>4.64</b>	4.75	4.40	4.53	<b>4.78</b>	—	4.41	4.30	4.37	
91~100	4.32	4.71	4.42	4.61	4.18	4.66	4.58	<b>4.94</b>	4.72	4.43	4.17	<b>4.78</b>	4.44	4.39	4.60	<b>4.84</b>	—	4.55	4.81	<b>5.04</b>	—	4.49	4.67	<b>4.79</b>	
101~110	4.49	4.83	4.78	4.81	4.47	4.73	4.74	<b>5.12</b>	4.42	4.53	4.33	<b>5.00</b>	3.99	4.63	4.90	<b>5.01</b>	—	4.56	4.94	<b>5.17</b>	—	4.60	4.86	<b>4.98</b>	
111~120	4.70	4.91	4.92	<b>5.01</b>	4.77	4.79	4.83	<b>5.31</b>	4.58	4.64	4.48	<b>5.08</b>	4.74	4.73	5.07	<b>5.19</b>	—	4.61	5.05	<b>5.21</b>	—	4.69	4.96	<b>5.10</b>	
121~130	4.73	5.03	5.00	<b>5.14</b>	—	4.85	4.97	<b>5.34</b>	4.80	4.76	4.63	<b>5.20</b>	4.67	4.83	5.24	<b>5.28</b>	—	4.76	5.03	<b>5.31</b>	—	4.79	4.93	<b>5.18</b>	
131~140	4.84	5.02	5.07	<b>5.29</b>	—	4.95	5.02	<b>5.44</b>	4.97	4.86	4.76	<b>5.29</b>	4.82	4.99	5.30	<b>5.33</b>	—	4.75	5.05	<b>5.27</b>	—	4.82	5.03	<b>5.23</b>	
141~150	5.07	5.08	5.16	<b>5.33</b>	—	5.00	5.12	<b>5.44</b>	4.84	4.99	4.89	<b>5.35</b>	4.68	4.94	5.35	<b>5.36</b>	—	4.85	5.14	<b>5.37</b>	—	4.80	5.10	<b>5.25</b>	
151~160	5.07	5.12	5.26	<b>5.43</b>	—	5.02	5.15	<b>5.39</b>	—	5.02	5.01	<b>5.37</b>	5.10	5.01	5.32	<b>5.45</b>	—	4.85	5.21	<b>5.47</b>	—	4.90	5.05	<b>5.26</b>	
161~170	4.90	5.16	5.33	<b>5.43</b>	—	5.08	5.17	<b>5.43</b>	—	5.10	5.01	<b>5.38</b>	5.16	5.06	5.39	<b>5.42</b>	—	4.97	5.26	<b>5.42</b>	—	4.95	5.10	<b>5.31</b>	
171~180	4.92	5.14	5.36	<b>5.44</b>	—	5.17	5.19	<b>5.36</b>	—	5.10	5.06	<b>5.47</b>	5.01	5.07	5.46	<b>5.44</b>	—	4.94	5.33	<b>5.48</b>	—	4.86	5.17	<b>5.32</b>	
181~190	5.08	5.18	5.40	<b>5.52</b>	—	5.04	5.30	<b>5.49</b>	—	5.10	5.10	<b>5.45</b>	5.18	5.12	5.49	<b>5.40</b>	—	5.02	5.37	<b>5.54</b>	—	4.91	5.24	<b>5.39</b>	
191~200	5.11	5.19	5.35	<b>5.59</b>	—	5.08	5.32	<b>5.48</b>	—	5.15	5.18	<b>5.54</b>	5.24	5.16	5.45	<b>5.46</b>	—	5.04	5.38	<b>5.57</b>	—	4.98	5.24	<b>5.39</b>	

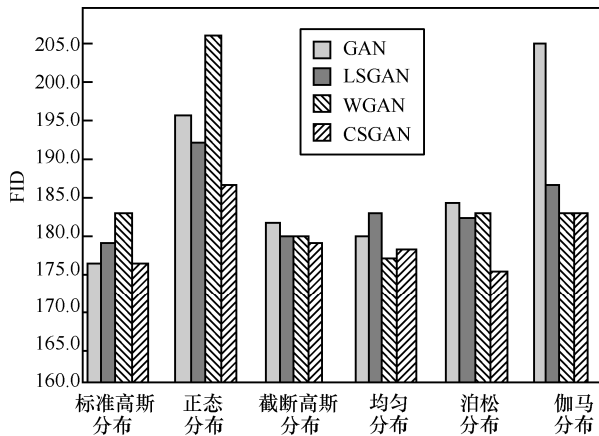


图7 不同噪声下生成样本的FID值

## 5 结束语

针对生成对抗网络在不同噪声下的稳健性及生成样本质量差异明显的问题, 本文提出了一种噪声稳健性的卡方生成对抗网络。引入卡方散度判别真实样本分布和生成样本分布的距离, 减小输入噪声对网络的影响并增强网络稳定性; 搭建卡方生成对抗网络, 构建全局优化目标函数, 促进生成器生成更加逼真的图像。研究表明, 不同网络在不同噪声下的稳健性不同, 基于卡方散度的 CSGAN 能够生成更高质量的样本, 具有较强的稳健性。未来的工作重心是提高网络效率, 降低计算损耗, 并将该网络扩展用于检测、预测等更多实际应用领域。

## 参考文献:

- [1] CHOI H Y. Deep learning in nuclear medicine and molecular imaging: current perspectives and future directions[J]. *Nuclear Medicine and Molecular Imaging*, 2017, 52(2): 109-118.
- [2] XING F Y, XIE Y P, SU H, et al. Deep learning in microscopy image analysis: a survey[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2018, 29(10): 4550-4568.
- [3] 王珠珠. 基于 U 型检测网络的图像篡改检测算法[J]. *通信学报*, 2019, 40(4): 171-178.  
WANG Z Z. Image forgery detection algorithm based on U-shaped detection network[J]. *Journal on Communications*, 2019, 40(4): 171-178.
- [4] NARDELLI P, JIMENEZ-CARRETERO D, BERMEJO-PELAEZ D, et al. Pulmonary artery-vein classification in CT images using deep learning[J]. *IEEE Transactions on Medical Imaging*, 2018, 37(11): 2428-2440.
- [5] WU B, LI K H, GE F P, et al. An end-to-end deep learning approach to simultaneous speech dereverberation and acoustic modeling for robust speech recognition[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2017, 11(8): 1289-1300.
- [6] WANG D L, CHEN J T. Supervised speech separation based on deep learning: an overview[J]. *IEEE Transactions on Audio, Speech, and Language Processing*, 2018, 26(10): 1702-1726.
- [7] TOM Y, DEVAMANYU H, SOUJANYA P, et al. Recent trends in deep learning based natural language processing[J]. *IEEE Computational Intelligence Magazine*, 2018, 13(3): 55-75.
- [8] LI H. Deep learning for natural language processing: advantages and challenges[J]. *National Science Review*, 2018, 5(1): 28-30.
- [9] ZHANG Q C, YANG L T, CHEN Z K. Privacy preserving deep computation model on cloud for big data feature learning[J]. *IEEE Transactions on Computers*, 2016, 65(5): 1351-1362.
- [10] PENG L, PENG M M, LIAO B, et al. The advances and challenges of deep learning application in biological big data processing[J]. *Current Bioinformatics*, 2018, 13(4): 352-359.
- [11] ROUX N L, BENGIO Y. Representational power of restricted boltzmann machines and deep belief networks[J]. *Neural Computation*, 2008, 20(6): 1631-1649.
- [12] HINTON G E, OSINDERO S, TEH Y W. A faster learning algorithm for deep belief nets[J]. *Neural Computation*, 2014, 18(7): 1527-1554.
- [13] HOCHREITER S, SCHMIDHUBER J. Feature extraction through lococode[J]. *Neural Computation*, 1999, 11(3): 679-714.
- [14] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[C]// *International Conference on Neural Information Processing Systems*. Berlin: Springer, 2014: 2672-2680.
- [15] PHILIP C, JONG L H. Face sketch synthesis using conditional adversarial networks[C]// *IEEE 2017 International Conference on Information and Communication Technology Convergence*. Piscataway: IEEE Press, 2017: 373-378.
- [16] GALDRAN A, MEYER M I, COSTA P, et al. End-to-end adversarial retinal image synthesis[J]. *IEEE Transactions on Medical Imaging*, 2018, 37(3): 781-791.
- [17] HUANG Q, JACKSON P J B, PLUMBLEY M D, et al. Synthesis of images by two-stage generative adversarial networks[C]// *2018 IEEE International Conference on Acoustics, Speech and Signal Processing*. Piscataway: IEEE Press, 2018: 1593-1597.
- [18] QIN X, CHEN W, SHEN Q, et al. Image inpainting: a contextual consistent and deep generative adversarial training approach[C]// *Asian Conference on Pattern Recognition*. Nanjing, 2017: 588-593.
- [19] CHEN Y, CHEN W, WEI C, et al. Occlusion-aware face inpainting via generative adversarial networks[C]// *IEEE International Conference on Image Processing*. Piscataway: IEEE Press, 2017: 1202-1206.
- [20] WANG W, HUANG Q, YOU S, et al. Shape inpainting using 3D generative adversarial network and recurrent convolutional networks[C]// *2017 IEEE International Conference on Computer Vision*. Piscataway: IEEE Press, 2017: 2317-2325.
- [21] GONG M, YANG Y, ZHAN T, et al. A generative discriminatory classified network for change detection in multispectral imagery[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2019, 12(1): 321-333.
- [22] ZHU L, CHEN Y, GHAMISI P, et al. Generative adversarial networks for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(9): 5046-5063.
- [23] ZHAN Y, HU D, WANG Y, et al. Semisupervised hyperspectral image classification based on generative adversarial networks[J]. *IEEE Geoscience and Remote Sensing Letters*, 2018, 15(2): 212-216.
- [24] CHEN X, XU C, YANG X, et al. Gated-GAN: adversarial gated networks for multi-collection style transfer[J]. *IEEE Transactions on Image Processing*, 2019, 28(2): 546-560.

- [25] KIM T, CHA M, KIM H, et al. Learning to discover cross-domain relations with generative adversarial networks[J]. arXiv Preprint, arXiv: arXiv 1703.05192v1, 2017.
- [26] ZHU J Y, PARK T, ISOLA P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks[J]. arXiv Preprint, arXiv: arXiv 1703. 10593v6, 2017.
- [27] ADIGA S, ATTIA M A, CHANG W, et al. On the tradeoff between mode collapse and sample quality in generative adversarial networks[C]// IEEE Global Conference on Signal and Information Processing. Piscataway: IEEE Press, 2018: 1184-1188.
- [28] 王万良, 李卓蓉. 生成式对抗网络研究进展[J]. 通信学报, 2018, 39(2): 135-148.  
WANG W L, LI Z R. Advances in generative adversarial network[J]. Journal on Communications, 2018, 39(2):135-148.
- [29] VITORIA P, SINTES J, BALLESTER C. Semantic image inpainting through improved Wasserstein generative adversarial networks[J]. arXiv Preprint, arXiv: arXiv 1812.01071v1, 2018.
- [30] FU Y C, LIU Y. BubGAN: bubble generative adversarial networks for synthesizing realistic bubbly flow images[J]. arXiv Preprint, arXiv: arXiv 1809. 02266v1, 2018.
- [31] RADFORD A, METZ L, CHINTALA S. Unsupervised representation learning with deep convolutional generative adversarial networks[J]. arXiv Preprint, arXiv: arXiv 1611.02163, 2015.
- [32] SALIMANS T, GOODFELLOW I, ZAREMBA W, et al. Improved techniques for training GANs[C]// Advances in Neural Information Processing Systems. Barcelona: NIPS, 2016: 2234-2242.
- [33] ARJOVSKY M, BOTTOU L. Towards principled methods for training generative adversarial networks[J]. arXiv Preprint, arXiv: arXiv 1701.04862, 2017.
- [34] ARJOVSKY M, CHINTALA S, BOTTOU L. Wasserstein GAN[J]. arXiv:arXiv 1701.07875, 2017.
- [35] GHOSH A, KULHARIA V, NAMBOODIRI V P, et al. Multi-agent diverse generative adversarial networks[C]// 2018 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2018: 8513-8521.
- [36] MAO X, LI Q, XIE H, et al. Least squares generative adversarial networks[J]. arXiv Preprint, arXiv: arXiv 1611.04076v3, 2017.
- [37] CHEN B, LIU T, LIU K, et al. Image super-resolution using complex dense block on generative adversarial networks[C]//2019 IEEE International Conference on Image Processing. Piscataway: IEEE Press, 2019: 2866-2870.
- [38] TAN W R, CHAN C S, AGUIRRE H, et al. Improved ArtGAN for conditional synthesis of natural image and artwork[J]. IEEE Transactions on Image Processing, 2019, 28(1): 394-409.
- [39] KANCHARLA P, CHANNAPPAYYA S S. Improving the visual quality of generative adversarial network (GAN)-generated images using the multi-scale structural similarity index[C]// 25th IEEE International Conference on Image Processing. Piscataway: IEEE Press, 2018: 3908-3912.
- [40] MASCIALINO B, PFEIFFER A, PIA M G, et al. Evaluation of the power of goodness-of-fit tests for the comparison of data distributions[C]//IEEE Nuclear Science Symposium Conference Record. Piscataway: IEEE Press, 2006: 101-103.
- [41] PELE O, WERMAN M. The quadratic-chi histogram distance family[C]// European Conference on Computer Vision. Berlin: Springer, 2010: 749-762.
- [42] MIRZA M, OSINDERO S. Conditional generative adversarial nets[J]. arXiv Preprint, arXiv: 1411.1784v1, 2014.
- [43] RADFORD A, METZ L, CHINTALA S. Unsupervised representation learning with deep convolutional generative adversarial networks[J]. arXiv Preprint, arXiv: arXiv 1511.06434v2, 2016.
- [44] ZHAO J, MATHIEU M, LECUN Y. Energy-based generative adversarial network[J]. arXiv Preprint, arXiv: arXiv 1609.03126v4, 2017.
- [45] 乔鞞鞞, 吴成茂. 基于卡方散度阈值方法的图像分割研究与实现[J]. 计算机应用与软件, 2008, 25(10): 78-81.  
QIAO W W, WU C M. Study on image segmentation of image thresholding method based on chi-square divergence and its realization[J]. Computer Applications and Software, 2008, 25(10): 78-81.
- [46] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [47] XU Q, HUANG G, YUAN Y, et al. An empirical study on evaluation metrics of generative adversarial networks[J]. arXiv Preprint, arXiv: 1806.07755v2, 2018.

## [作者简介]



李洪均(1981-), 男, 江苏南通人, 博士, 南通大学副教授、硕士生导师, 主要研究方向为图像处理、模式识别和人工智能。



李超波(1995-), 女, 山西大同人, 南通大学硕士生, 主要研究方向为计算机视觉和深度学习。



张士兵(1962-), 男, 江苏南通人, 博士, 南通大学教授、博士生导师, 主要研究方向为无线通信、智能信号处理、机器学习和认知无线电。