

- 与生成器的收敛度和样本质量相关的有意义的损失度量。
- 优化过程的稳定性提高。

具体来说，这篇论文针对判别器和生成器提出了一种新的损失函数。用这种损失函数代替二值交叉熵就可以让 GAN 的收敛更加稳定。从数学的角度解释这个问题超出了本书的范围，网上有很多解释该损失函数基本原理的资源。

下面让我们看看 Wasserstein 损失函数的定义。

4.5.1 Wasserstein 损失

首先我们来复习一下二值交叉熵，目前我们在训练 GAN 判别器和生成器时就采用了这种损失函数：

二值交叉熵

$$-\frac{1}{n} \sum_{i=1}^n (y_i \log(p_i) + (1 - y_i) \log(1 - p_i))$$

为了训练 GAN 的判别器 D ，我们根据以下两者计算损失：真实图像的预测 $p_i = D(x_i)$ 与响应 $y_i = 1$ 之间的比较，以及生成图像的预测 $p_i = D(G(z_i))$ 与响应 $y_i = 0$ 之间的比较。因此，对于 GAN 的判别器来说，将损失函数最小化的过程可以表示为：

GAN 判别器的损失最小化

$$\min_D - \left(\mathbb{E}_{x \sim p_X} [\log D(x)] + \mathbb{E}_{z \sim p_Z} [\log (1 - D(G(z)))] \right)$$

为了训练 GAN 的生成器 G ，我们根据生成图像的预测 $p_i = D(G(z_i))$ 与响应 $y_i = 1$ 的比较计算损失。因此，对于 GAN 的生成器来说，将损失函数最小化的过程可以表示为：