

Generative Adversarial Nets

实验室交流周报告

报告人：汪继龙

时 间：2017.09.29

Generative Adversarial Nets

—— NIPS 2014, Ian J. Goodfellow

主要贡献:

- 提出一种新型的网络模型，生成对抗网络GAN；
- 不再使用“近似推理”和“马尔可夫链”，简化了复杂度；

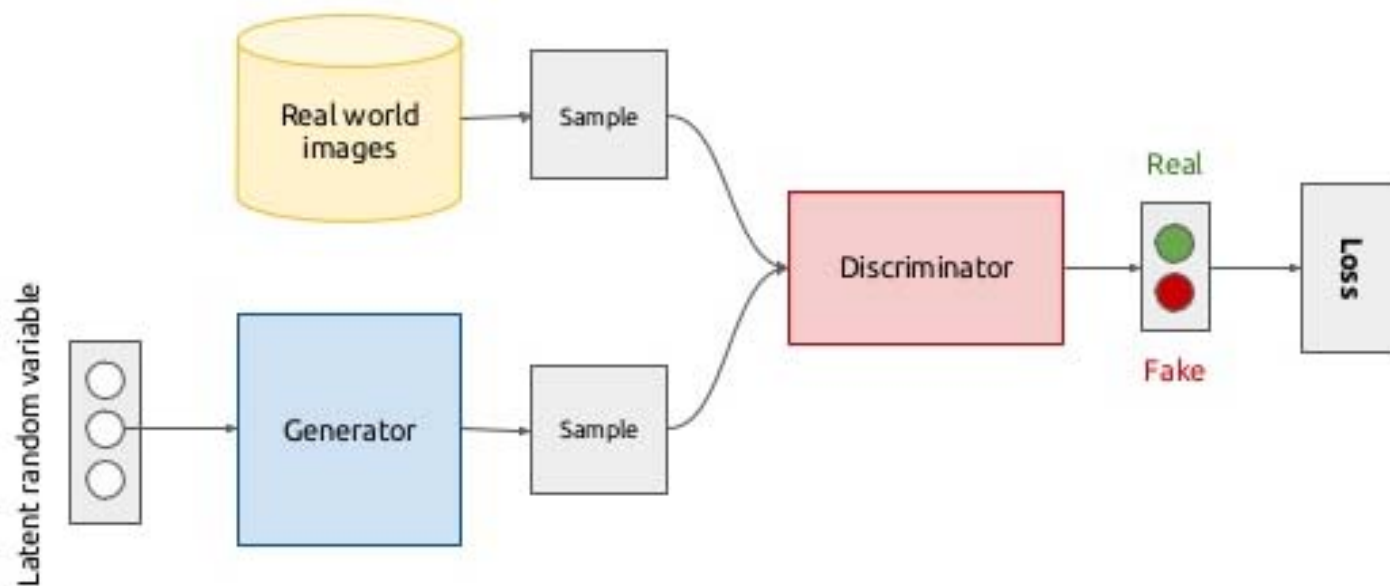
模型组成:

- 一个生成器； Generator
- 一个判别器； Discriminator

Structure

真实样例

随机变量



训练过程:

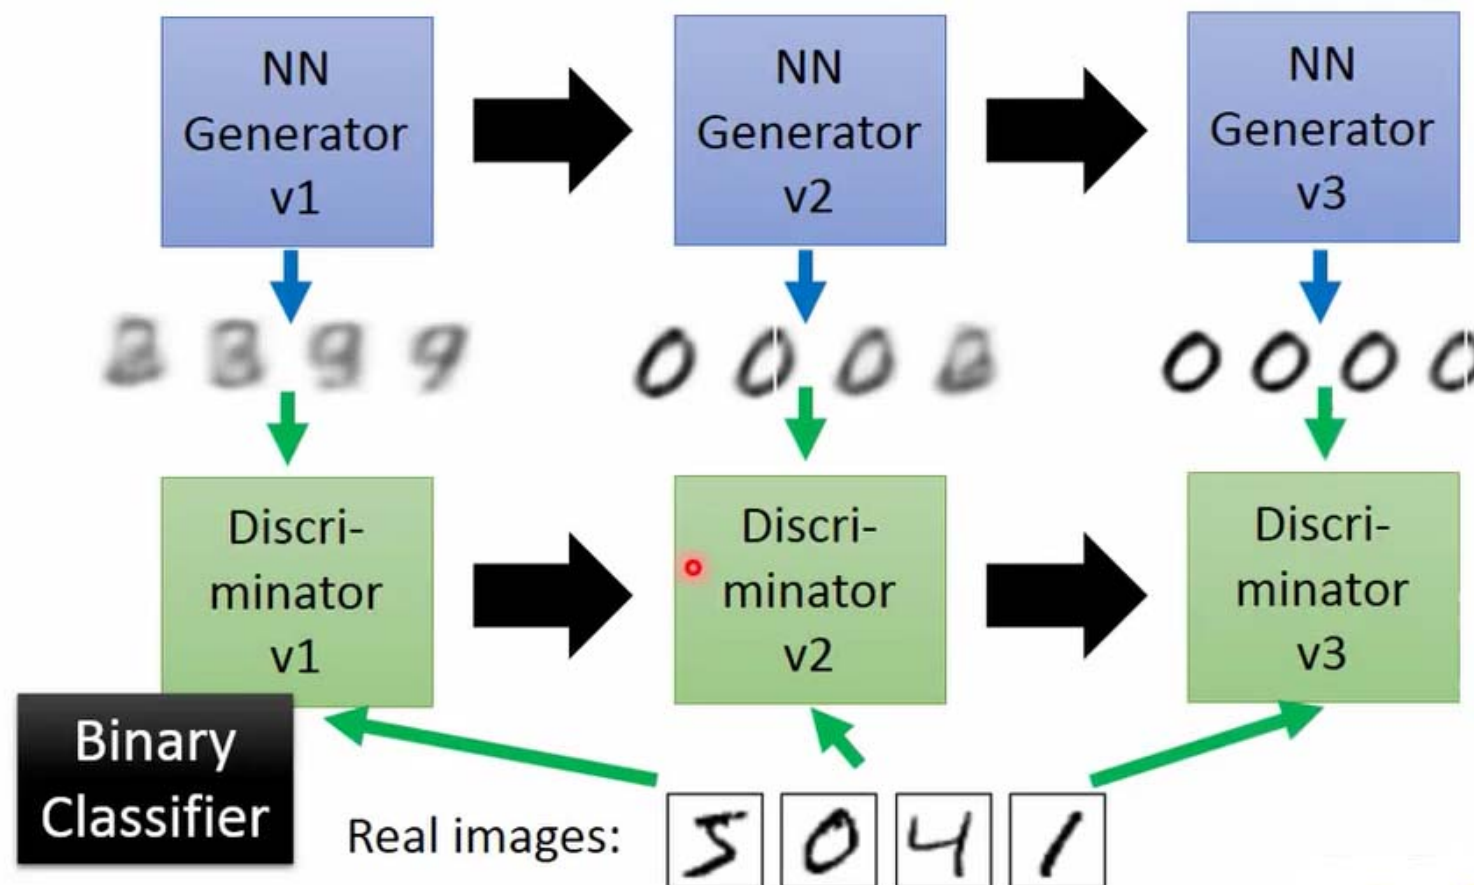
1. G和D都是任意自选神经网络，随机初始化；
2. G通过服从某一分布的随机变量，生成假样例；
3. 真假样例分别放入D中判别训练，G和D的训练同步进行；

The evolution of generation

生成器G每次的更新迭代都会产生更加真实的数据；

判别器每次更新为了更好的区分真假样例；

从而两者产生了对抗



Loss function

- z 为随机噪声；
- x 为真实数据；
- GAN的目标函数中， $D(x)$ 表示一种概率，指数据来自真实数据而不是生成器生成数据的概率；
- 训练判别器 D 最大化其区分真实数据和生成数据的概率；
- 同时训练生成器 G 使得 $\log(1-D(G(z)))$ 最小，这样 $1-D(G(z))$ 就要减小， $D(G(z))$ 增大，而 D 的目的要减小 $D(G(z))$ ，从而产生了对抗。

$$\min_G \max_D V(D, G) = \mathbb{E}_{\mathbf{x} \sim p_{\text{data}}(\mathbf{x})} [\log D(\mathbf{x})] + \mathbb{E}_{\mathbf{z} \sim p_z(\mathbf{z})} [\log(1 - D(G(\mathbf{z})))] .$$

Algorithm

Algorithm 1 Minibatch stochastic gradient descent training of generative adversarial nets. The number of steps to apply to the discriminator, k , is a hyperparameter. We used $k = 1$, the least expensive option, in our experiments.

判别器D部分



for number of training iterations **do**

for k steps **do**

- Sample minibatch of m noise samples $\{z^{(1)}, \dots, z^{(m)}\}$ from noise prior $p_g(z)$.
- Sample minibatch of m examples $\{x^{(1)}, \dots, x^{(m)}\}$ from data generating distribution $p_{\text{data}}(x)$.
- Update the discriminator by ascending its stochastic gradient:

$$\nabla_{\theta_d} \frac{1}{m} \sum_{i=1}^m \left[\log D(x^{(i)}) + \log (1 - D(G(z^{(i)}))) \right].$$

end for

生成器G部分




- Sample minibatch of m noise samples $\{z^{(1)}, \dots, z^{(m)}\}$ from noise prior $p_g(z)$.
- Update the generator by descending its stochastic gradient:

$$\nabla_{\theta_g} \frac{1}{m} \sum_{i=1}^m \log (1 - D(G(z^{(i)}))).$$

end for

The gradient-based updates can use any standard gradient-based learning rule. We used momentum in our experiments.

Experiment




a)



b)



c)




d)

GANs paper

Cumulative number of named GAN papers by month

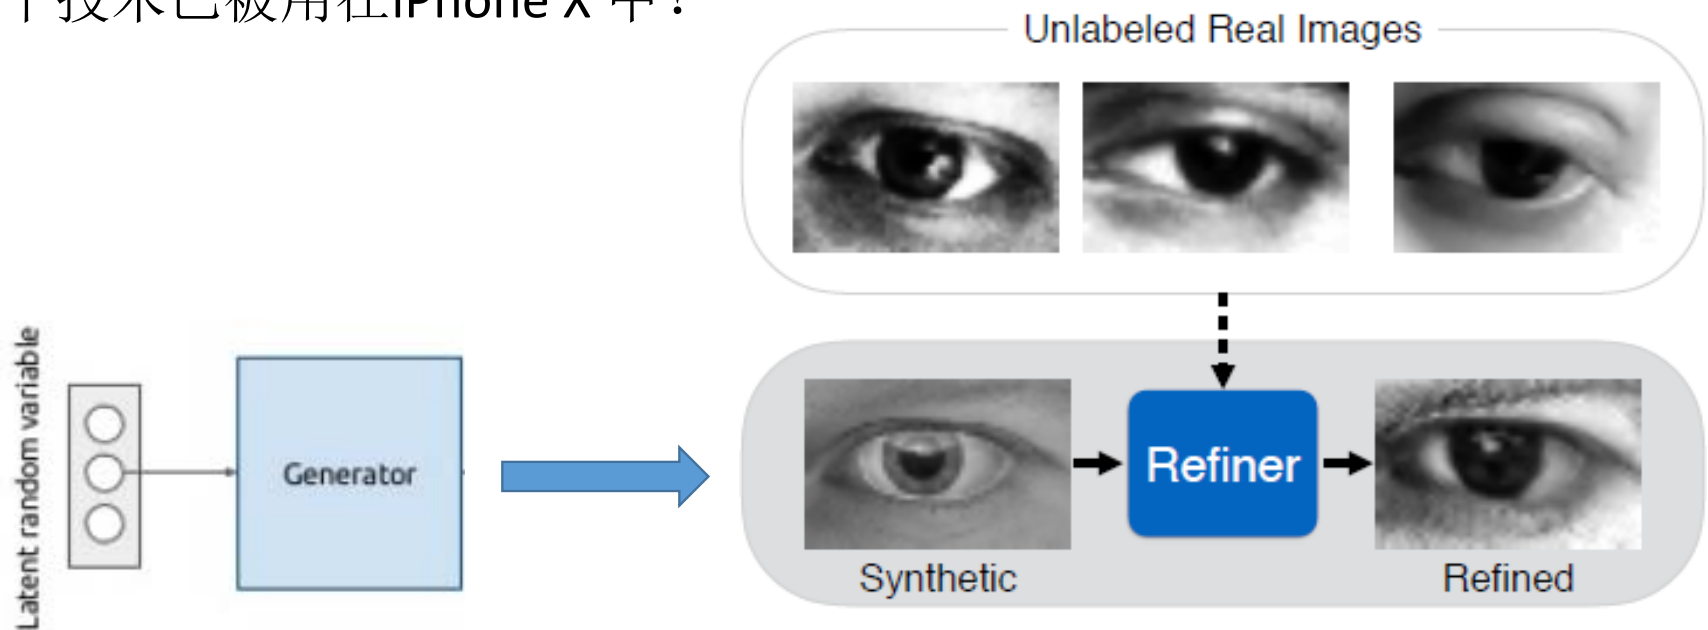
目前基于GAN的
衍生模型数量



For example—SimGAN

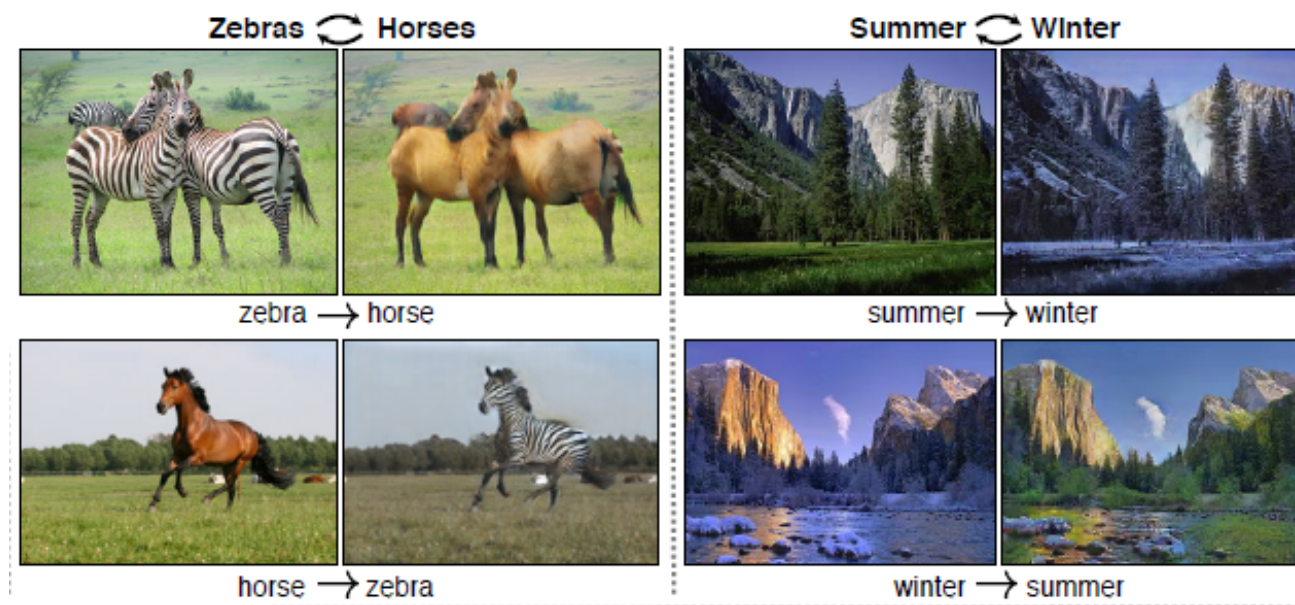
SimGAN: CVPR 2017 best paper

- 旨在提高网络生成图片的真实性;
- 用以假乱真的图片训练模型，从而提高图像识别的准确度;
- 也许这个技术已被用在iPhone X中？



For example——CycleGAN (ICCV 2017)

CycleGAN实现了不相关领域图像之间的相互转换。



Conclusions

优点:

1. 通过反向梯度传播, 不需要马尔科夫链;
2. 灵活性高, G、D的模型根据需要自己选择;
3. 为训练数据较少的模型训练提供了一种数据生成方法;

缺点:

1. G和D训练中必须同步的很好;
2. 生成图像质量与真实具有一定差距;
3. 缺乏理论指导;