

(7) Redes geradoras

Redes Neurais e Aprendizado Profundo

Moacir Ponti
CeMEAI/ICMC, Universidade de São Paulo
MBA em Ciência de Dados

www.icmc.usp.br/~moacir — moacir@icmc.usp.br

October 5, 2022

Agenda

Modelos geradores

Autoencoders variacionais (VAEs)

Redes adversárias geradoras (GANs)

Modelos baseados em Difusão

Agenda



Modelos geradores

Autoencoders variacionais (VAEs)

Redes adversárias geradoras (GANs)


Modelos baseados em Difusão

Geração de dados




Interpretação: aprender a distribuição

Aprender a distribuição que "gera" os dados permite amostrar a partir dela



Interpretação: aprender a gerar dados

Mas podemos querer apenas dados, não uma distribuição...



Tipos de métodos

Funções densidade explícitas


- ▶ Fully Visible Belief Nets
- ▶ Boltzmann Machines
- ▶ **Variational Autoencoders**

Funções densidade implícitas

- ▶ Métodos de Monte Carlo
- ▶ Likelihood-free inference via classification
- ▶ **Generative Adversarial Networks**

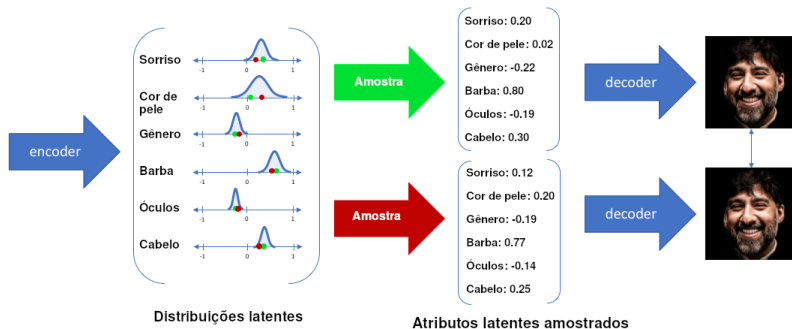
Autoencoders

Autoencoders convencionais tentam codificar atributos de forma discreta




Autoencoders variacionais (VAEs)

Autoencoders variacionais aprendem distribuições (seus parâmetros) de cada variável, a partir do qual se amostram valores



Autoencoders variacionais (VAEs)



VAE: função de perda ELBO

ELBO (Evidence Lower Bound)

\mathcal{L} = reconstrução + divergência de Kullback-Leibler

\mathcal{L} = MSE / Binary Cross Entropy + divergência de Kullback-Leibler

VAE: função de perda ELBO

ELBO (Evidence Lower Bound) com MSE para reconstrução

$$\begin{aligned}\mathcal{L} &= \|x - \tilde{x}\|^2 + D_{KL}(q_\phi(z|x), \mathcal{N}(0, 1)) \\ &= \|x - \tilde{x}\|^2 + D_{KL}(\mathcal{N}(\mu, \sigma), \mathcal{N}(0, 1)) \\ &= \|x - \tilde{x}\|^2 - \frac{1}{2} \sum (1 + \log(\sigma^2) - \mu^2 - \sigma^2)\end{aligned}$$

Redes adversárias geradoras (GANs)

- ▶ **Adversária** pois há dois componentes que "disputam"
- ▶ **Geradora** pois o objetivo central é aprender a gerar dados

Redes adversárias geradoras (GANs)

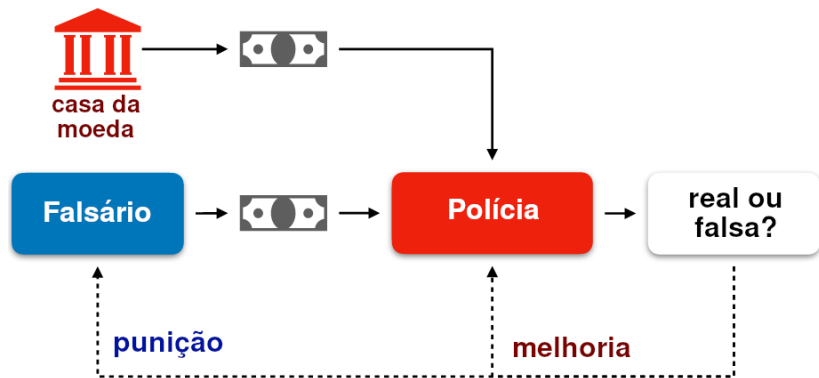
Gerador \mathcal{G}

- ▶ recebe um exemplo z' obtido de uma distribuição, i.e. $z' \sim q(z)$
- ▶ gera x por meio de uma função $x = \mathcal{G}_\Theta(z')$

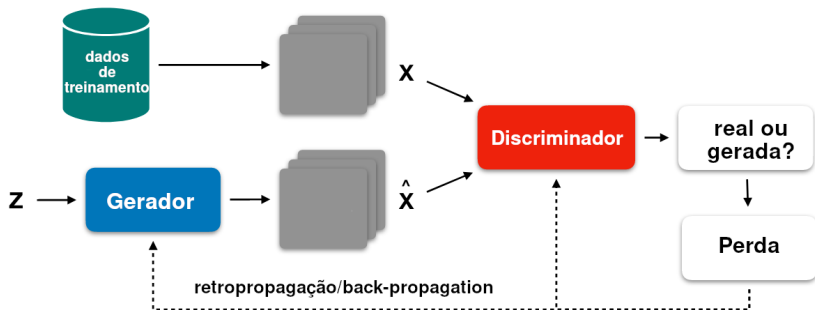
Discriminador \mathcal{D}

- ▶ recebe x e classifica se esse foi produzido pela distribuição original ou pela aproximação do gerador

Redes adversárias geradoras (GANs)



Redes adversárias geradoras (GANs)



Redes adversárias geradoras (GANs)


Formulação

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


Função original

$$-(1/2) E_{x \sim p_{data}(x)} [\log(D(x))] - (1/2) E_z [\log(1 - D(G(z)))]$$


Aritmética no espaço latente




Exemplos gerados por uma GAN de 2017



2019 (SAGAN)



2021 (StyleGAN)



2021 (Diffusion-based Model)



Agenda

Modelos geradores

Autoencoders variacionais (VAEs)

Redes adversárias geradoras (GANs)

Modelos baseados em Difusão

Difusão



Difusão: forward




forward
→

$$x_0 \longrightarrow x_1 \longrightarrow \dots \longrightarrow x_T$$

$$q(x_{1:T} | x_0) = \prod_{t=1}^T q(x_t | x_{t-1})$$

Difusão: forward



$$q(x_T | x_0) \approx \mathcal{N}(0, I)$$

reverse
←


$$x_0 \longleftarrow \dots \longleftarrow x_{T-1} \longleftarrow x_T$$

$$p_{\theta}(x_{0:T}) := p(x_T) \prod_{t=1}^T p_{\theta}(x_{t-1} | x_t)$$


$$p(x_T) = \mathcal{N}(x_T; 0, I)$$

Difusão vs VAEs

VAE



Diffusion model



Perda: analogia com VAEs

$$\mathbb{E}_{q(x_{1:T}|x_0)}[\log p_\theta(x_0 | x_{1:T})] - D_{\text{KL}}(q(x_{1:T} | x_0) \parallel p_\theta(x_{1:T}))$$

$$\text{loss}_{\text{simple}} = \mathbb{E}_{x_0, \epsilon, t} [\|\epsilon - \epsilon_{\theta}(x_t, t)\|^2]$$

Difusão vs BigGAN

