

Deep Learning Szeminárium

Generative Adversarial Networks

Zombori Zsolt, Varga Dániel

MTA, Rényi Alfréd Matematikai Kutatóintézet

Felügyelet nélküli tanulás

- Nincs tanító címke, csak adatok
- Megfigyelések értelmezése
- Hasznos adatrepräsentáció létrehozása
- Hasznos "fogalmak" bevezetése magasabbrendű kognitív folyamatok támogatására
- Faktorok azonosítása, ami mentén a dolgok változhatnak
- Környezet viselkedésének előrejelzése
- Váratlan dolgok észrevétele

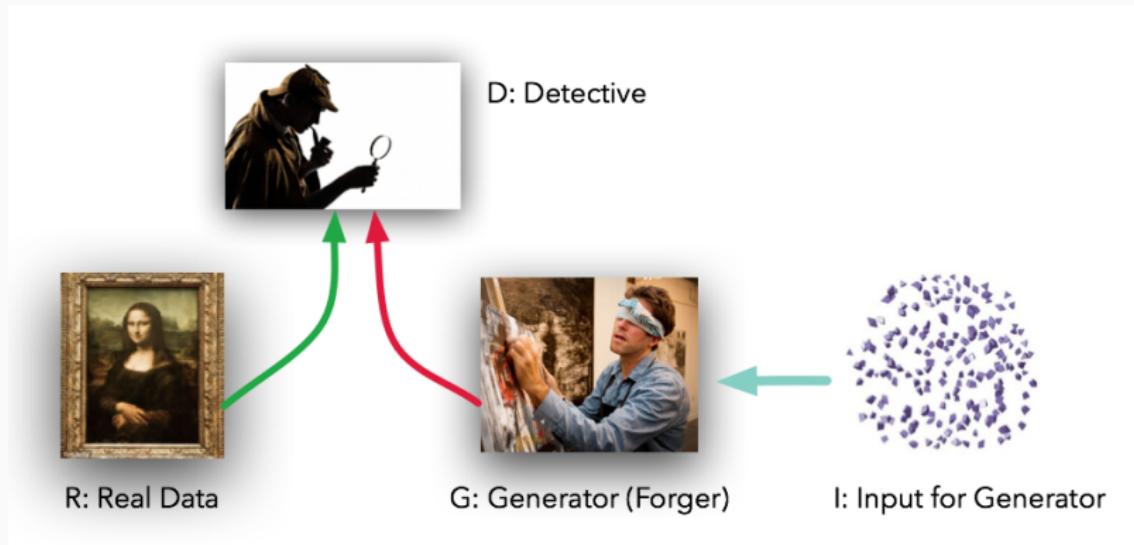
Generatív modell

- Explicit: adatok valószínűségét jósolja meg
- Implicit:
 - Csak normalizálatlan valószínűségek állnak rendelkezésünkre
 - Csak adatpontokat tud generálni
- Eszköz a felügyelet nélküli tanuláshoz

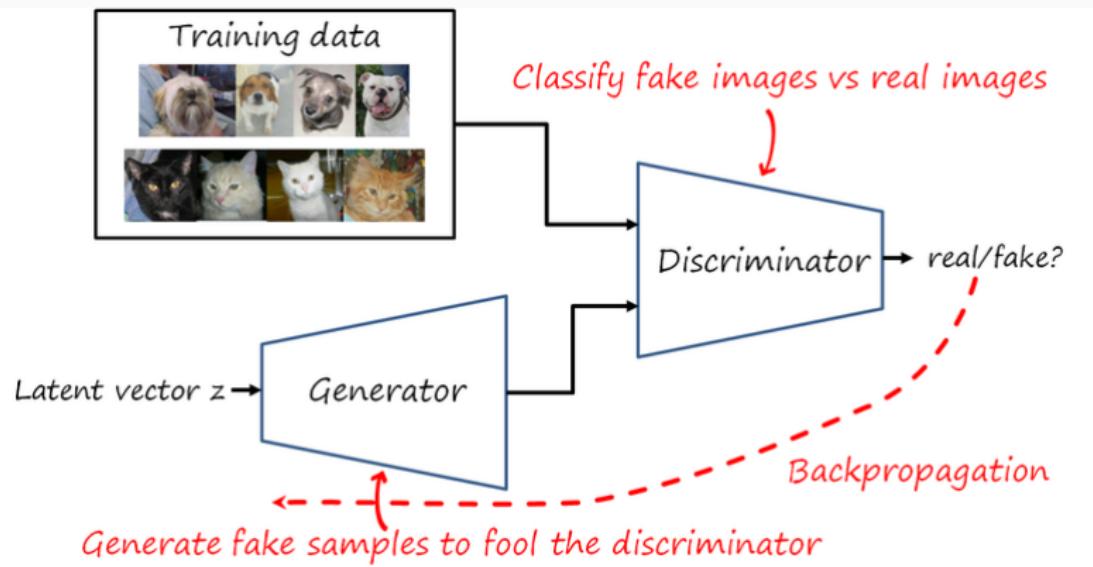
Generative Adversarial Networks

- Eredeti cikk: <https://arxiv.org/abs/1406.2661>
(Goodfellow et al, több, mint 42000 hivatkozás.)
- Adott egy adathalmaz, szeretnénk olyan modellt építeni, ami generálni tud "valósnak tűnő" adatokat.
- Két tanuló modell versengéséből születik meg az eredmény
- Implicit modell: csak adatpontokat tud generálni
- Látens (rejtett) változós modell: megfigyelhetetlen z változóból generálunk

Generative Adversarial Networks



Generative Adversarial Networks

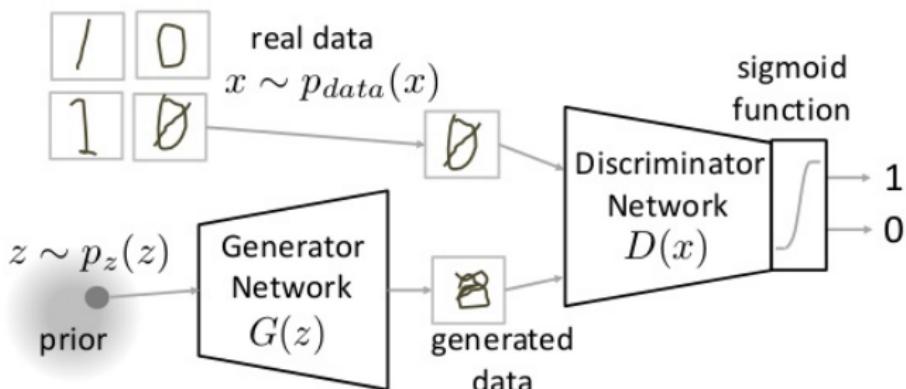


Generative Adversarial Networks

Generative Adversarial Networks

$$\min_G \max_D V(D, G)$$

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



GAN-ok tanításának nehézségei

- Nem konvergál, nem találunk Nash equilibrium-ot
- Mode collapse: Nem elég változatosak a generátumok
- Gyenge gradiens jel: generátor és diszkriminátor kényes egyensúlyt kell tartson
- Rendkívül érzékeny a hiperparamétereikre
- Érzékeny a véletlen perturbációkra
- Nincs inferencia modell

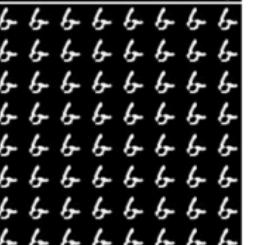
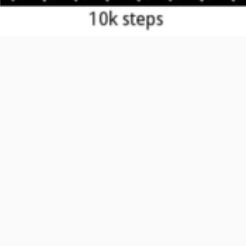
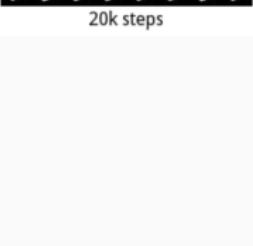
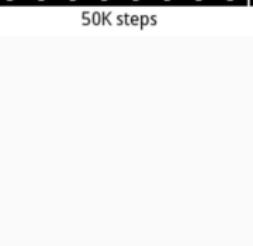
Nash Equilibrium

- Se a generátor, se a diszkriminátor nem akar változtatni.
- Nagyon tipikus, hogy egy GAN nem konvergál
- Mintapélda: $V(D, G) = xy$, ahol D állítja x -et és G y -t.
- Optimális diszkriminátor stratégia: $D(x) = \frac{p_{real}(x)}{p_{real}(x)+p_{gen}(x)}$
- Optimális diszkriminátort feltételezve, megmutatható, hogy a generátor a két eloszlás közti Jensen-Shannon divergenciát minimalizálja.

$$\min_G V(D^*; G) = 2D_{JS}(p_{real} || p_{gen}) - 2 \log 2$$

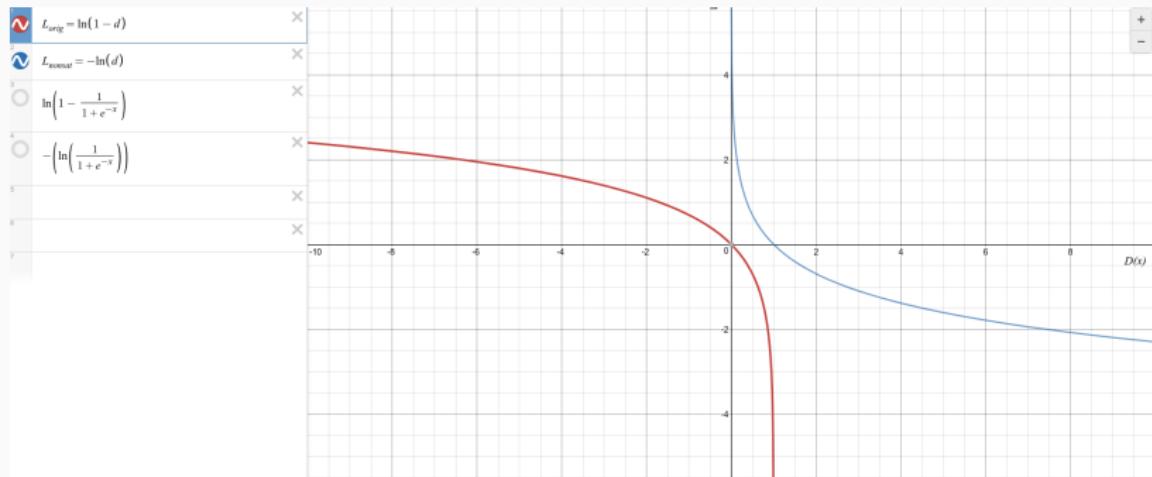
- $D_{JS}(p || q) = \frac{1}{2}D_{KL}(p || \frac{p+q}{2}) + \frac{1}{2}D_{KL}(q || \frac{p+q}{2})$
- $D_{KL}(p || q) = \int p(x) \log \frac{p(x)}{q(x)}$

Mode collapse

			
			
			
10k steps	20k steps	50K steps	100k steps

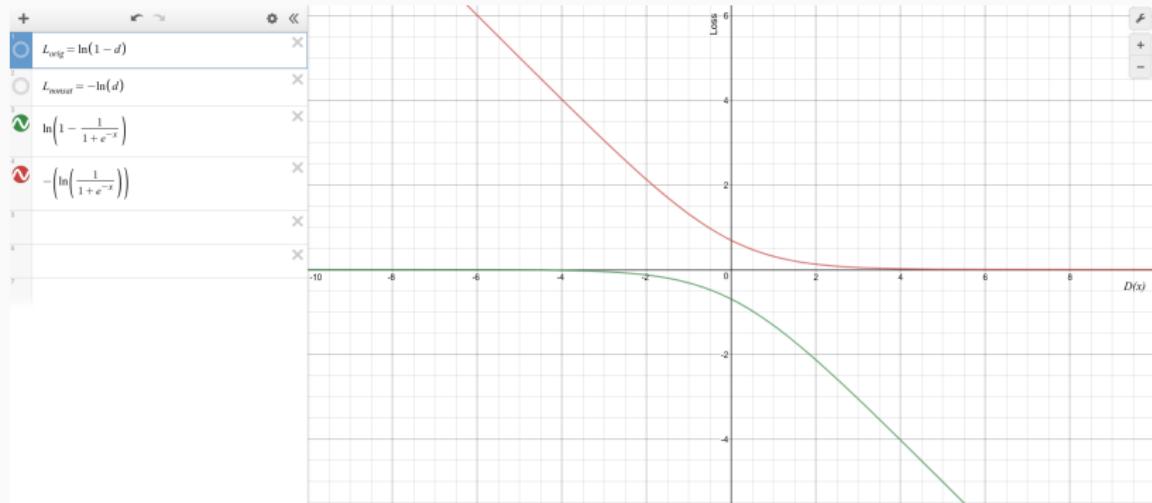
Gyenge gradiens jel

- Generátor veszteségfüggvény:
 $V(G) = \mathcal{E}_{z \sim p_z}(\log(1 - D(G(z))))$
- Nem szaturáló veszteségfüggvény:
 $V(G) = \mathcal{E}_{z \sim p_z}(-\log(D(G(z))))$



Gyenge gradiens jel

Figyelembe véve, hogy a diszkriminátor utolsó nemlinearitása
sigmoid: $D(x) = \frac{1}{1+e^{-h(x)}}$

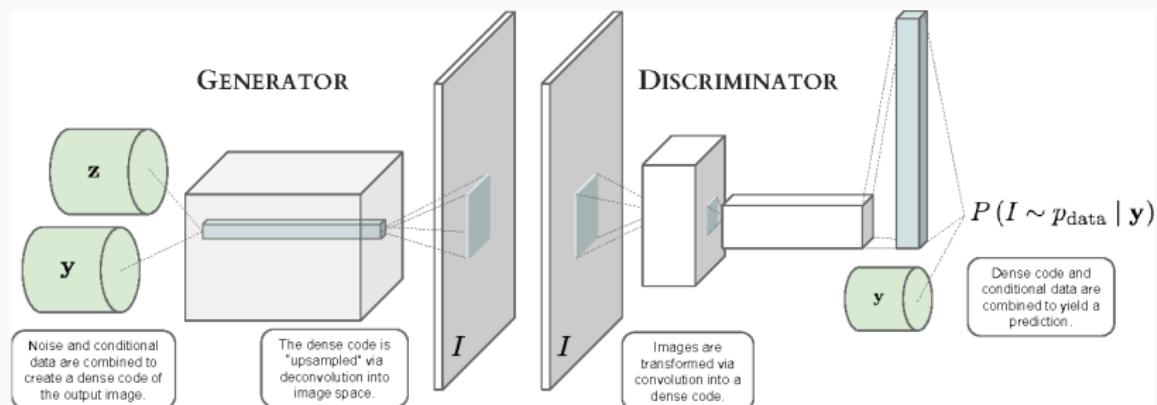


Generatív modellek kiértékelése

- Szabad szemmel
- Valamilyen divergenciát közelítünk véges mintahalmazok alapján
 - Wasserstein divergencia
 - Véletlen vetítés alacsony dimenzióba, majd ott valamilyen statisztikai teszt
- Egy neurális háló (tanuló rendszer) által kinyert reprezentációs térben végzünk összehasonlítást
 - FID: Frechet Inception Distance

Conditional Generative Adversarial Nets

- <https://arxiv.org/abs/1411.1784>
- A generátor és a diszkriminátor egyaránt kapnak egy plusz bemenetet



Progressive Growing of GANs for Improved Quality, Stability, and Variation

- <https://arxiv.org/abs/1710.10196>
- Generátort/diszkriminátort fokozatosan növeljük új rétegekkel
- Kis felbontású képekből indulunk, fokozatosan jutunk el a nagy felbontáshoz

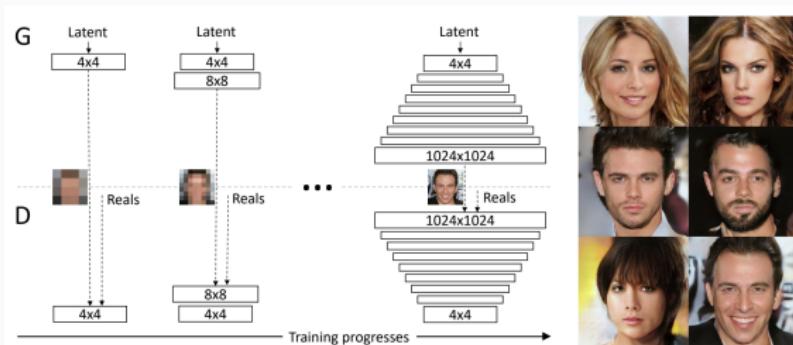


Figure 1: Our training starts with both the generator (G) and discriminator (D) having a low spatial resolution of 4x4 pixels. As the training advances, we incrementally add layers to G and D, thus increasing the spatial resolution of the generated images. All existing layers remain trainable throughout the process. Here $[N \times N]$ refers to convolutional layers operating on $N \times N$ spatial resolution. This allows stable synthesis in high resolutions and also speeds up training considerably. One on the right we show six example images generated using progressive growing at 1024 × 1024.

Arckép generálás megoldva?



2014



2015



2016



2017



2018

<https://thispersondoesnotexist.com/image>