

# Generatív modellek

# Neurális háló

- Valós vektorokat valós vektorokba képző folytonos függvény
- Bemenetek lehetnek: kép, hang, videó, szöveg, ...
- Kimenet például egy klasszifikáció feladat esetén a valószínűségek vektora
- Veszteségfüggvény: például  $L(\hat{y}, y)$ , vagyis mennyire vagyunk elégedettek a kimenettel az elvárt kimenet ismeretében (pl. négyzetes hiba)
- tanítás (paraméterek hangolása)

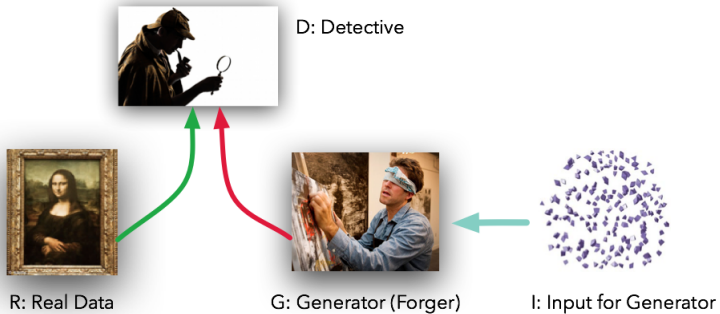
# Felügyelet nélküli tanítás

- Nincsenek címkék, csak adatok
- Hasznos adatrepresentáció létrehozása
- A jó reprezentációk szükségesek a hatékony tanításhoz
- Például faktorok azonosítása, dimenzió redukció
- Lényeges információk kinyerése

# Generatív modellek

- Cél: egy adott adathalmazhoz szeretnénk olyan modellt építeni, ami generálni tud új adatpontokat
- Ma a két legnépszerűbb generatív modell:
  - Variational Autoencoder (VAE)
  - Generative Adversarial Network (GAN)
- Látens változós modellek: egy megfigyelhetetlen  $z$  változóból generálunk
- Eredeti cikkek:
  - VAE: <https://arxiv.org/abs/1312.6114>
  - GAN: <https://arxiv.org/abs/1406.2661>

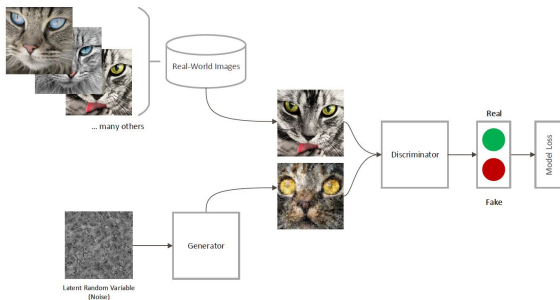
# Generative Adversarial Network



# Generative Adversarial Network

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

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




# Tanítási nehézségek



- Nem konvergál
- Mode collapse: Nem elég változatosak a generátumok
- Nagyon érzékeny a hiperparaméterekre, véletlen perturbációkra

# Autoencoder

Cél: Az identitás függvény megtanulása



Encoder:  $h = f(x)$


Decoder: Az eredeti input rekonstrukciója;  $r = g(h)$

Kellene, hogy  $\hat{x} = g(f(x))$  közel legyen  $x$ -hez.



# Korlátozások

Korlátozásokat kell bevezetnünk, hogy elkerüljük a memorizálást



Az adathalmaz rejtett összefüggéseit szeretnénk megtalálni

# Autoencoder

Sok esetben a loss függvény két részből áll:

- Reconstruction loss  $\mathcal{L}(x, g(f(x)))$
- Regularizer, ami megakadályozza a memorizálást.

Példák:

- Undercomplete Autoencoder: a látens dimenziót korlátozzuk (bottle neck)
- Sparse autoencoder: az aktivációkra bevezetünk korlátozást.

# Tömörítés

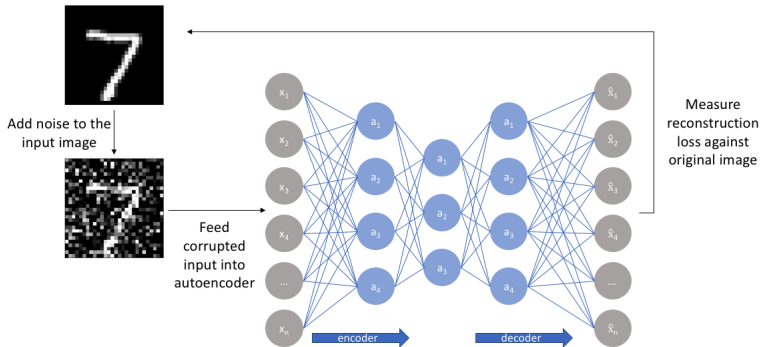
A be- meg kitömörítő függvények


- adatspecifikusak
- veszteségesek
- példák alapján automatikusan tanultak

Nem jó tömörítésre:

- adatspecifikus
- Nagyon nehéz olyat tanítani, ami jobb mint a JPEG

# Denoising autoencoder





Training an autoencoder on the MNIST dataset, and visualizing the encodings from a 2D latent space reveals the formation of distinct clusters. This makes sense, as distinct encodings for each image type makes it far easier for the decoder to decode them.



# Variational autoencoder

Van egy adathalmazunk:  $\mathcal{D} = \{\mathbf{x}^{(i)}\}_{i=1}^n$

Feltesszük, hogy az adathalmazunk a következőképpen van generálva:

- 1 A  $\mathbf{z}^{(i)}$  minta egy  $p(\mathbf{z})$  prior eloszlásból
- 2 Az  $\mathbf{x}^{(i)}$  pedig egy  $p(\mathbf{x} | \mathbf{z})$  feltételes eloszlásból.

$$p(\mathbf{x}) = \int p(\mathbf{x}|\mathbf{z})p(\mathbf{z}) d\mathbf{z}$$

A célunk, hogy minden  $\mathbf{x}^{(i)}$  adatpont valószínűségét maximalizáljuk.

# Variational Autoencoder

Olyan algoritmust szeretnénk, ami akkor is működik, ha

- a  $p(x)$  marginális és a  $p(z | x)$  posterior is nehezen számolható
- nagy az adathalmazunk

$$p(x) \approx \frac{1}{N} \sum_{i=1}^N p(x|z_i)$$

Feltesszük, hogy

- $p(z) = \mathcal{N}(z|0, I)$
- $p(x|z) = \mathcal{N}(x|f(z, \theta), \sigma^2 \cdot I)$




# Variational Autoencoder

A gyakorlatban a legtöbb  $z$ -re a  $p_{\theta}(x^{(i)} | z)$  majdnem 0.

$$p(x^{(i)}) \approx \frac{1}{N} \sum_{i=1}^N p(x^{(i)} | z_i)$$

A lényeg: olyan  $z$  értékeket szeretnénk mintavételezni, amire valószínű, hogy az  $x^{(i)}$ -t hozta létre.

A  $p_{\theta}(z | x^{(i)})$  posterior nehezen számolható, egy másik eloszlással közelítjük:  $q_{\phi}(z | x^{(i)})$ .



---


$$\text{loss} = \|x - \hat{x}\|^2 + \text{KL}[N(\mu_x, \sigma_x), N(0, I)] = \|x - d(z)\|^2 + \text{KL}[N(\mu_x, \sigma_x), N(0, I)]$$

## Variational lower bound


$$\begin{aligned} \log p_{\theta}(x^{(i)}) - D_{KL}(q_{\phi}(z|x^{(i)})||p_{\theta}(z|x^{(i)})) &= \\ = E_{q_{\phi}(z|x^{(i)})} \log p_{\theta}(x^{(i)}|z) - D_{KL}(q_{\phi}(z|x^{(i)})||p(z)). \end{aligned}$$

Jobb oldal a Variational lower bound (ELBO)


$$\mathcal{L}(\theta, \phi, x^{(i)}) = E_{q_{\phi}(z|x^{(i)})} \log p_{\theta}(x^{(i)}|z) - D_{KL}(q_{\phi}(z|x^{(i)})||p(z)).$$

# Látens tér


Only reconstruction loss



Only KL divergence



Combination



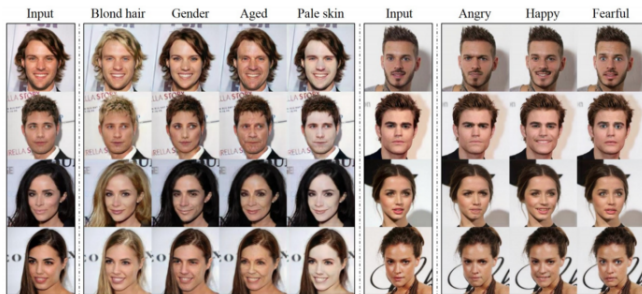


# Applications




Figure 7: Generated samples

# Applications



# Applications





# Deepfake

