Apprentissage & Reconnaissance des Formes: Auto-encodeurs & modèle génératifs (GANs) (9/10)

S. Herbin, **B. Le Saux**, A. Chan Hon Tong

bls@ieee.org

18 février 2020

Introduction

Introduction

- Jusqu'ici, beaucoup de classification...
- et depuis peu la régression (et l'étude de concepts de régularisation)

Objectifs

- Aujourd'hui : de la régression encore plus poussée, sous forme d'apprentissage profond;
- Auto-encodeurs ➠ apprendre un espace de représentation;
- Modèles Génératifs Adversaires (GANs) ➠ régression par apprentissage profond.

Arbres de décision et méthodes ensemblistes : plan

Auto-encodeurs

Auto-encodeurs : principes

Définition

Réseau de neurones capable d'apprendre un code représentatif des données de manière non-supervisée.

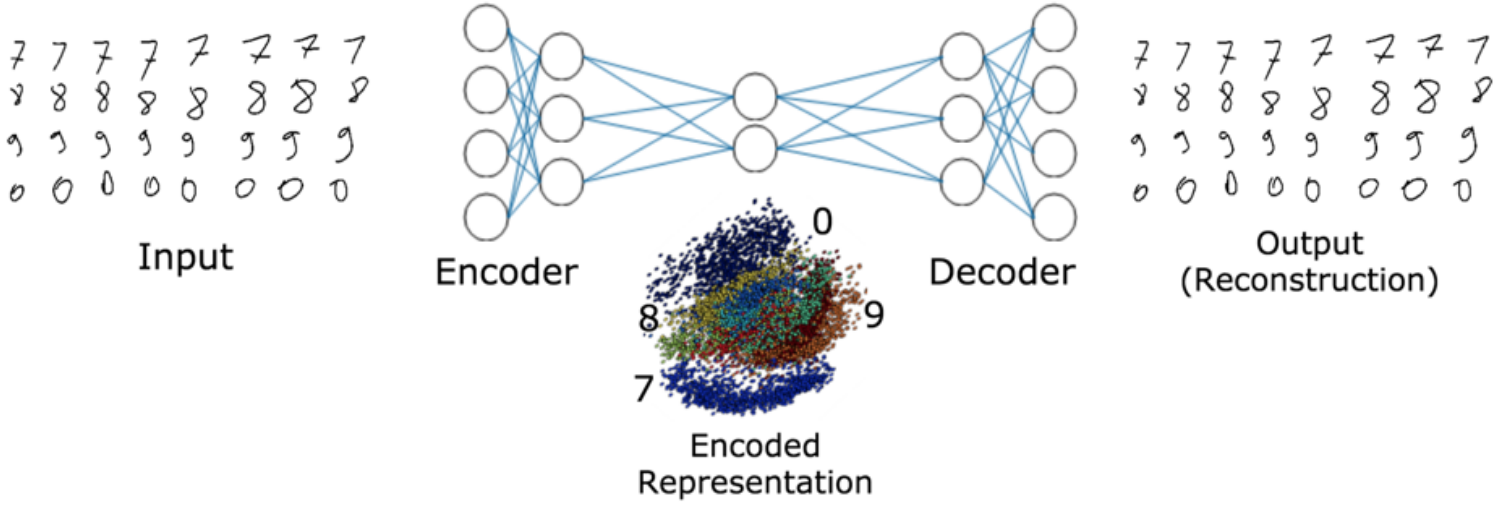

Auto-encodeurs : principes

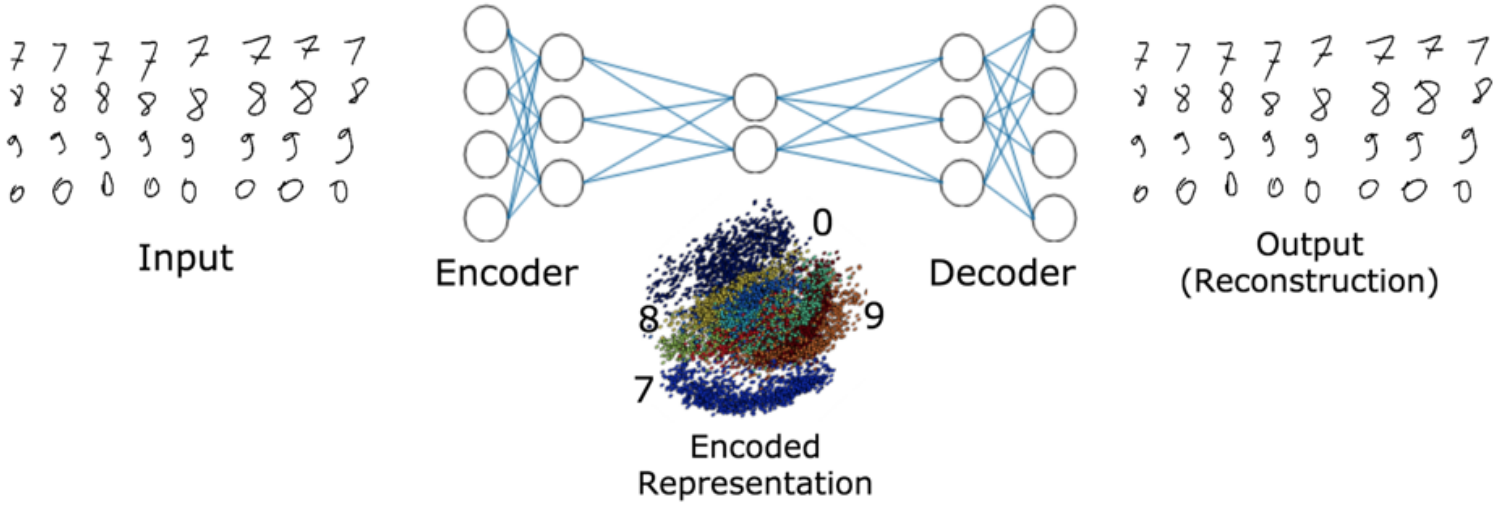

- Apprend un code capable de représenter complétement le signal d'entrée, c'est à dire suffisant pour revenir aux données d'origine;
- Non-supervisé ? ➠ ou bien supervisé avec l'entrée (reconstruction);
- Intuition: les données peuvent contenir du bruit, des valeurs non représentatives, et la transformation apprise permet d'extraire l'information importante.

Auto-encodeurs : principes

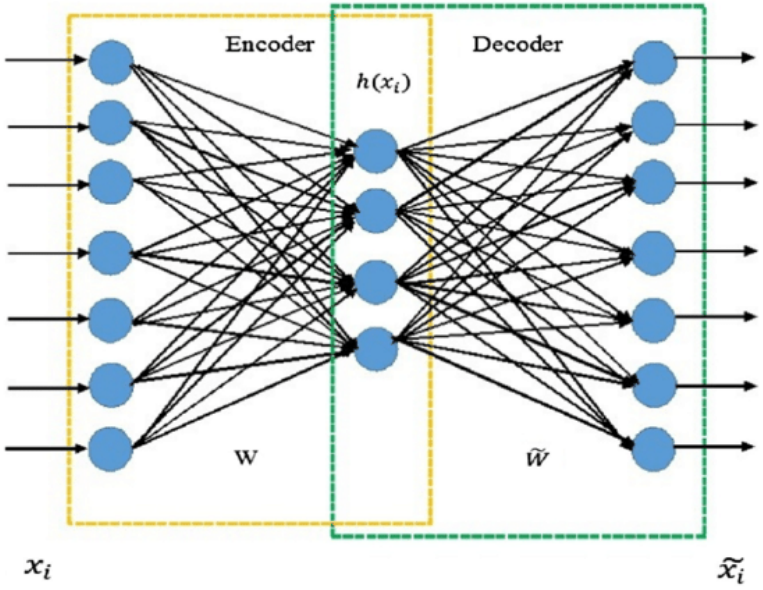

Partie encodeur

Historiquement, apprendre le code consiste à :

- Compresser les données. ➠ réduction de dimensionalité (lien avec l'ACP)
- Extraire des caractéristiques représentatives (*features*) ➠ sélection de caractéristiques

Auto-encodeurs : principes

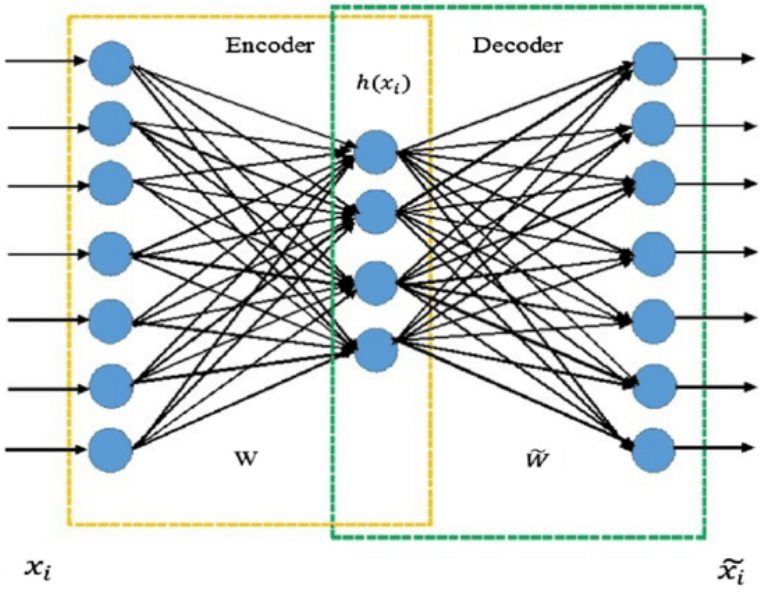

Partie encodeur

Aujourd'hui, apprendre le code, c'est :

- Construire un espace de représentation correspondant à des variables cachées ➠ *deep learning*
- Auto-encodeur = cas spécial de réseau *feed-forward*, qui peut être appris par les techniques classiques (descente de gradient par minibatchs et rétro-propagation)

Auto-encodeurs : principes

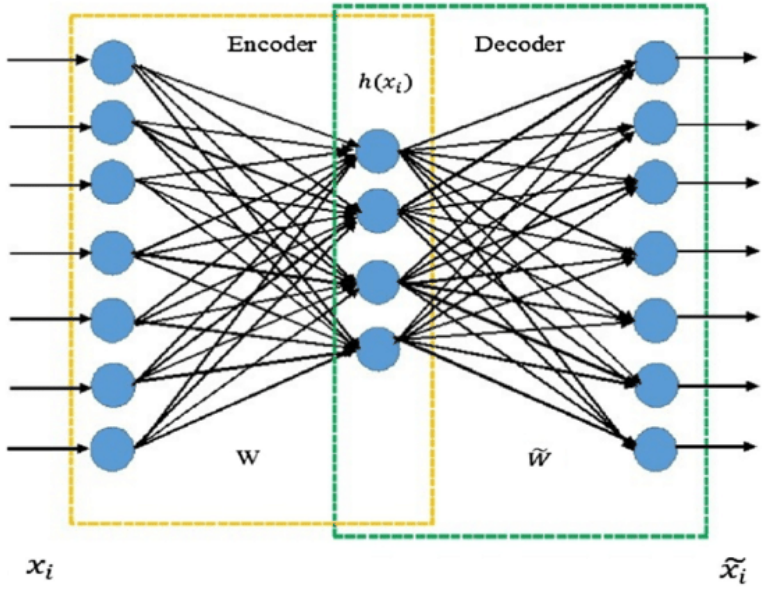

Partie décodeur

(Re-)construire à partir d'un code :

- Permet de reconstruire le plus fidèlement possible une donnée (signal, image, etc.)
- Générer une donnée jamais vue en combinant deux codes
  ➠ Modèle génératif

Auto-encodeurs : principes

Structure

- Encoder $\Phi : \mathcal{X} \longrightarrow \mathcal{F}$
- Decoder $\Psi : \mathcal{F} \longrightarrow \mathcal{X}$
- Code $z = \sigma(Wx + b)$
- Reconstruction
  $\hat{x} = \sigma'(Vz + b')$
- Fonction de pénalité:
  erreur de reconstruction
  $\mathcal{L}(x, \hat{x}) = ||x - \hat{x}||^2$

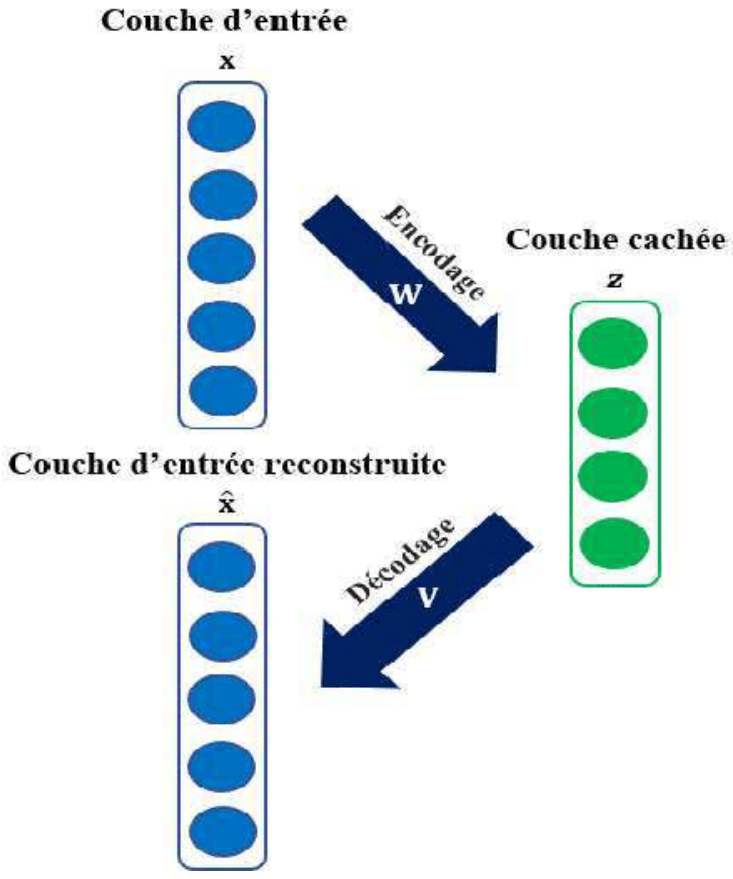

Auto-encodeurs : principes

Structure

- Fonction de pénalité:
  erreur de reconstruction
  $\mathcal{L}(x, \hat{x}) =$
  $||x - \sigma'(V\sigma(Wx + b) + b')||^2$
- Si $\dim(\mathcal{F}) \leq \dim(\mathcal{X})$,
  alors *compression*
- Si $\dim(\mathcal{F}) \geq \dim(\mathcal{X})$,
  alors risque d'apprendre la
  fonction *identité*...

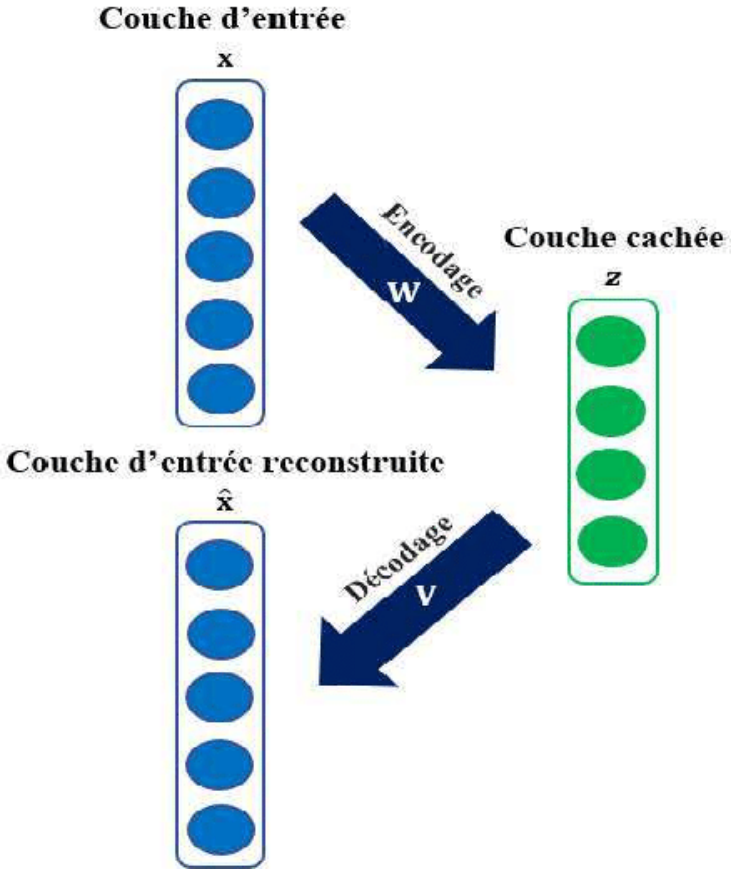

Auto-encodeurs : apprentissage

Entraînement

Pour chaque échantillon x:

1. Passe *feed-forward* pour activer les couches cachées et calculer $\hat{x}$
2. Mesure de l'erreur $\mathcal{L}(x, \hat{x})$
3. Rétro-propagation de l'erreur à travers le réseau et mise-à-jour des poids (W, V)

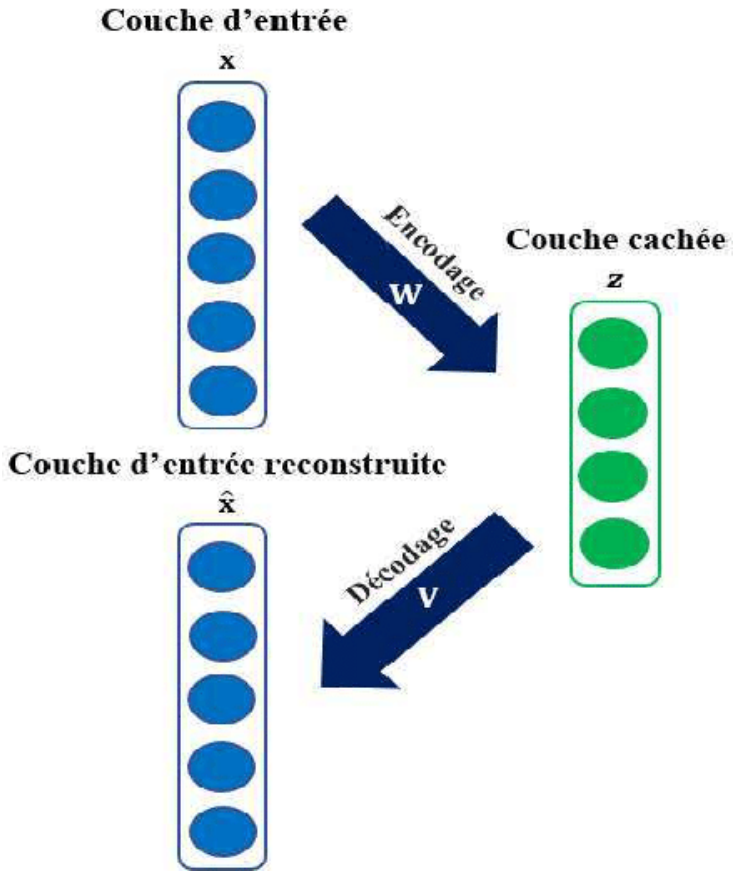

Auto-encodeurs parcimonieux

Principe général

Parcimonie (*sparsity* ou parfois *sparsité* par anglicisme) : principe consistant à n'utiliser qu'un minimum de causes pour expliquer un phénomène.

➠Objectif : Chercher des codes compacts

k-sparse auto-encoders

1. Identifier les k plus fortes activations des couches cachées
2. Mettre à 0 les autres activations

Auto-encodeurs parcimonieux

➠Objectif : Chercher des codes compacts

Régularisation parcimonieuse

- Soit $\dot{z}_j = \frac{1}{m} \sum_1^m z_j$ moyenne des activations cachées
- Objectif : $\dot{z}_j \simeq \rho$ avec ρ proche de 0
- Régularisation avec le terme de parcimonie:
  $\mathrm{KL}(\dot{z}||\rho) = \sum_j \left(\rho \log(\frac{\rho}{\dot{z}_j}) + (1-\rho) \log(\frac{1-\rho}{1-\dot{z}_j}) \right)$
  ➠ $\mathcal{L}(x, \hat{x}) = ||x - \hat{x}||^2 + \mathrm{KL}(\dot{z}||\rho)$

Auto-encodeurs de débruitage

Principe général

Utilisation des auto-encodeurs pour apprendre à débruiter un signal, une image.

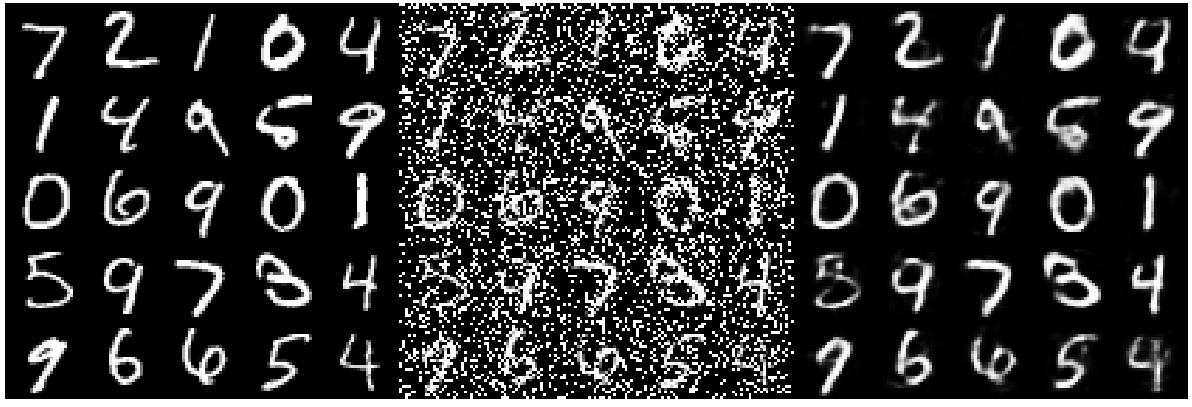

➠ Objectif : apprendre une *bonne* représentation, c'à-d. une représentation *robuste* à un signal d'entrée corrompu.

Auto-encodeurs de débruitage

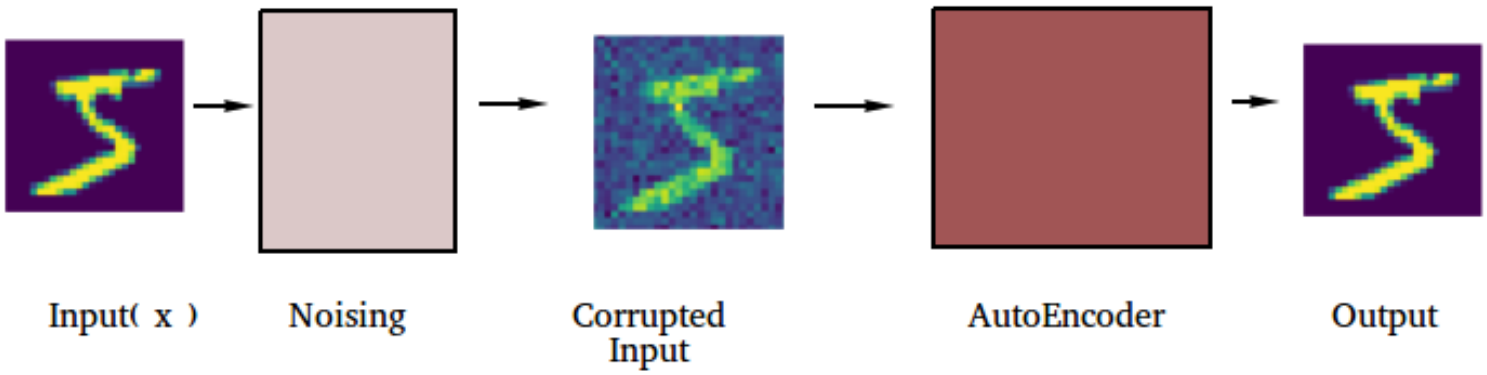

Denoising auto-encoder

1. Bruiter les échantillons : $x \mapsto \tilde{x}$
2. Optimiser les paramètres de l'auto-encodeur pour $\mathcal{L}(x, \hat{\tilde{x}})$

Auto-encodeurs : Résumé

Points clés des auto-encodeurs

+ Non-supervisé
+ Réduction de dimensionalité

Utilisations

+ Encodage (apprentissage de représentations)
+ Modèles génératifs
+ Débruitage

Modèles Génératifs Adversaires

Modèles Génératifs Adversaires

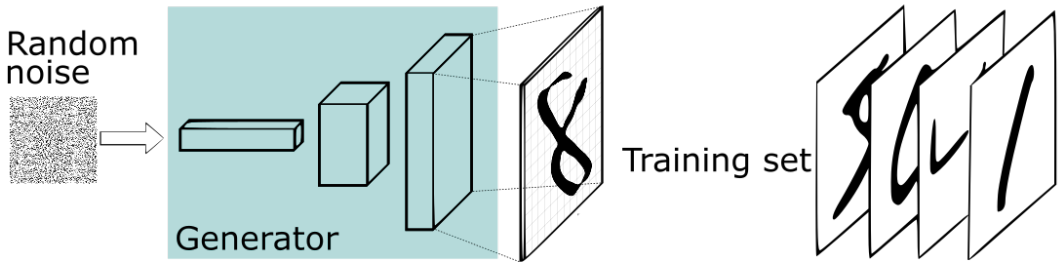

Problème

- Décodeur = Modèle génératif (ou Générateur)
- Peut-on entraîner un modèle génératif qui génèrerait des signaux x à partir d'un code aléatoire z ?
- *Par exemple par régression avec une norme L2 ?* ➠ pas si facilement...

Modèles Génératifs Adversaires

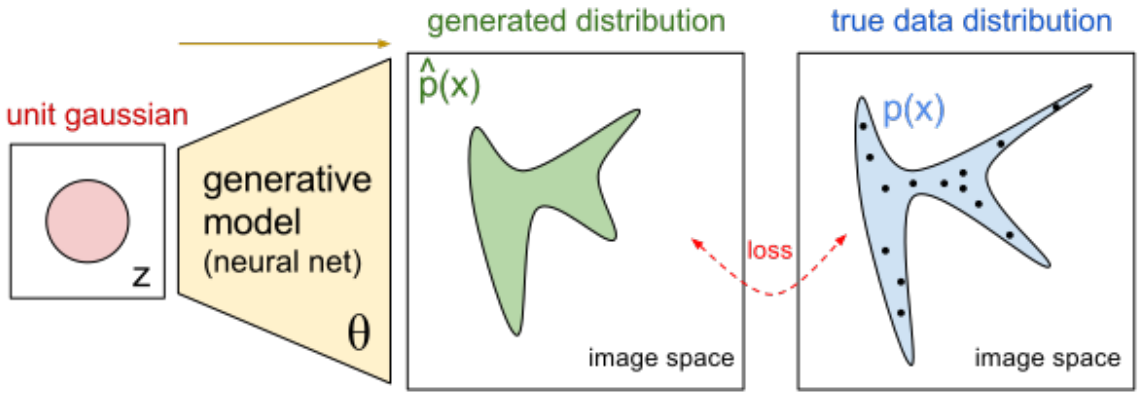

Problème

- Décodeur = Modèle génératif (ou Générateur)
- Peut-on entraîner un modèle génératif qui génèrerait des signaux x à partir d'un code aléatoire z ?
- *Objectif* : on veut maximiser la vraisemblance de l'image produite, c'à-d. minimiser l'écart de distribution entre les images générées et les réelles.

Modèles Génératifs Adversaires

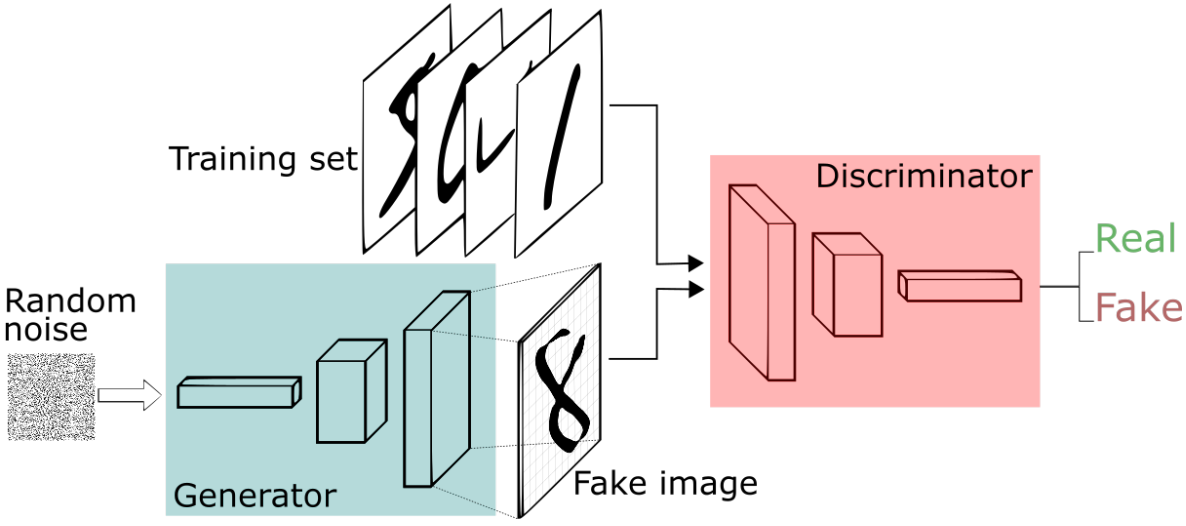

Solution

Goodfellow et al, *"Generative Adversarial Networks"*, NIPS'2016

- Un réseau générateur G apprend à générer des images...
- Un réseau discriminateur D apprend à valider la vraisemblance des images produites (*log loss*).
- Les 2 réseaux rivalisent dans un cycle d'optimisations alternées:

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

Modèles Génératifs Adversaires

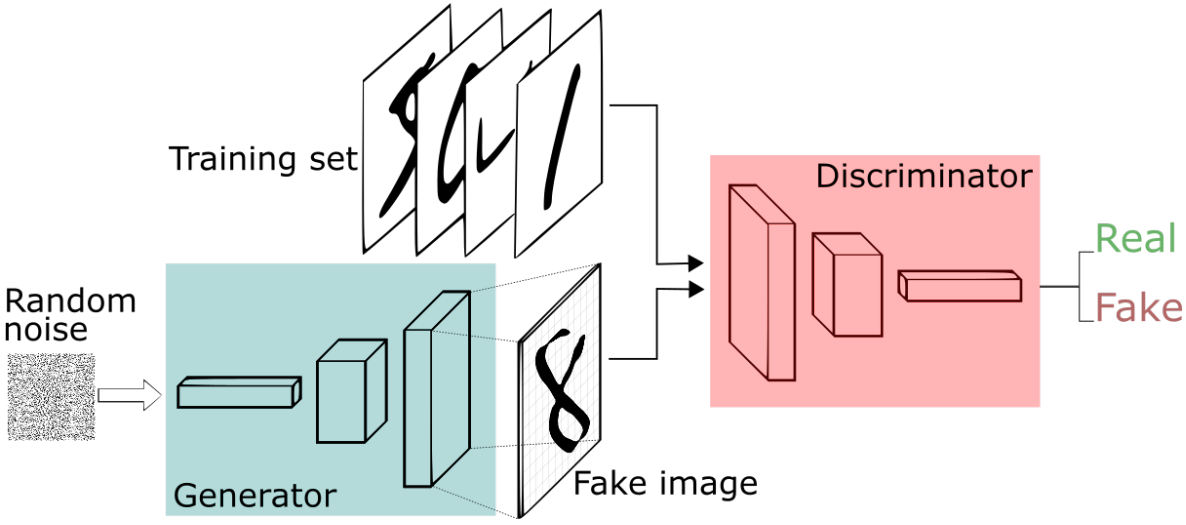

Pénalités permettant une optimisation plus stable

- *Least-square loss*:

$$\min_D V(D) = \mathbb{E}_{x\sim p_{data}(x)}[(D(x)-1)^2] + \mathbb{E}_{z\sim p_z(z))}[(D(G(z)))^2]$$

$$\min_G V(G) = \mathbb{E}_{z\sim p_z(z))}[(D(G(z))-1)^2]$$

- Wasserstein distance...

Mao et al., *Least Squares Generative Adversarial Networks*, ICCV'2017.

Générateurs: encodeurs-décodeurs

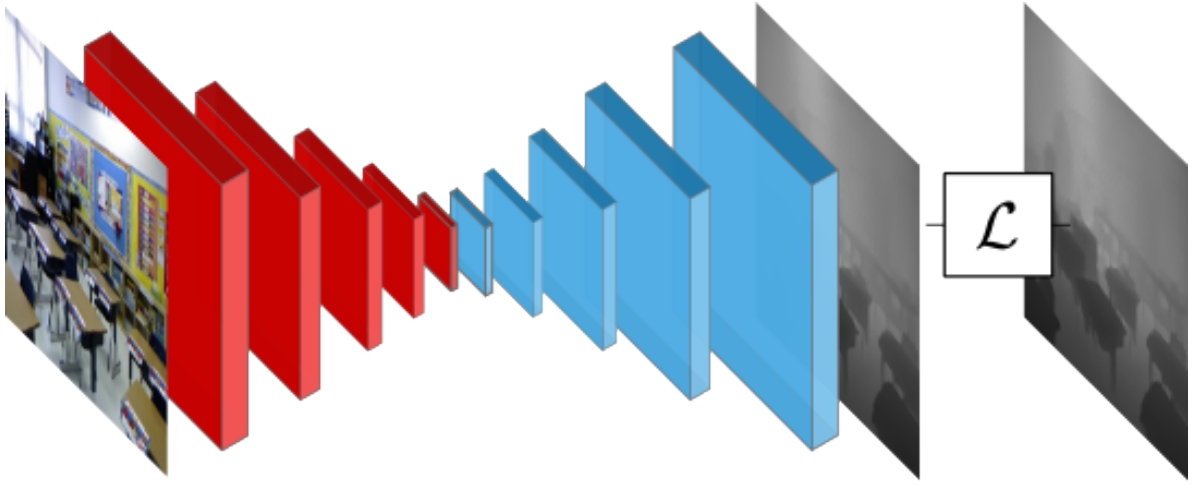

- Un réseau encodeur-décodeur a la même structure qu'un auto-encodeur...
- mais l'espace cible n'est pas le même !
  - En classification : segmentation sémantique (voir cours deep learning)
  - En régression : estimation d'une fonction du signal d : signal débruité, image super-résolue, profondeur...

Générateurs: encodeurs-décodeurs

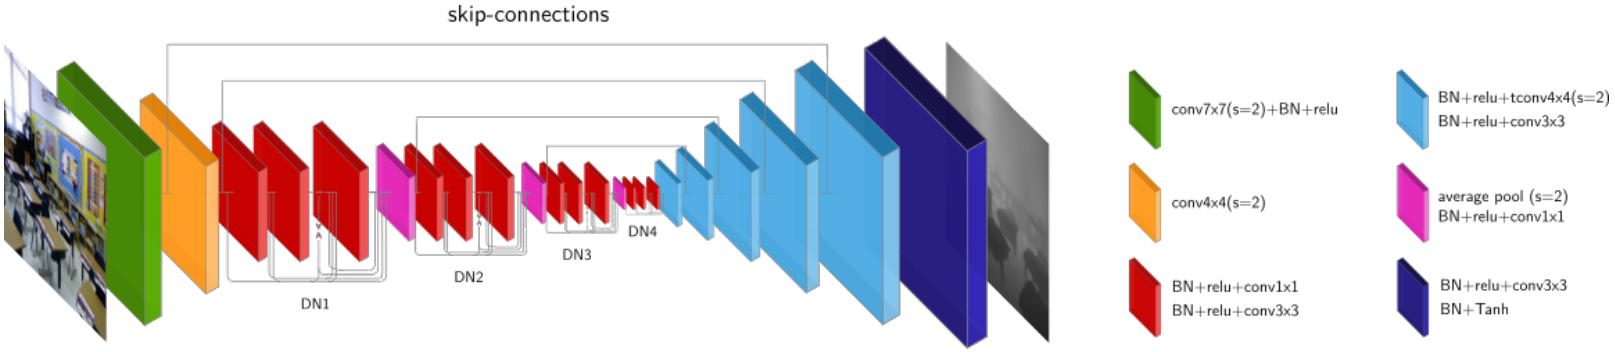

- Seule la fonction de perte $\mathcal{L}$ change, en régression :
  - L2 : $\mathcal{L}(x, d) = ||x - G(z)||^2$
  - L1 : $\mathcal{L}(x, d) = |x - G(z)|$
- Concernant le réseau, toutes les techniques sont utilisables : *skip connections* (U-Net), couches résiduelles (resnet), blocs denses (DenseNet), etc...
- Pour en faire un modèle génératif, rajouter du bruit aléatoire :
  - Soit par bruit ajouté au signal, à l'image
  - Soit par dropout : extinction aléatoire des poids du réseau, y compris en prédiction

Conditional GANs (cGANs)

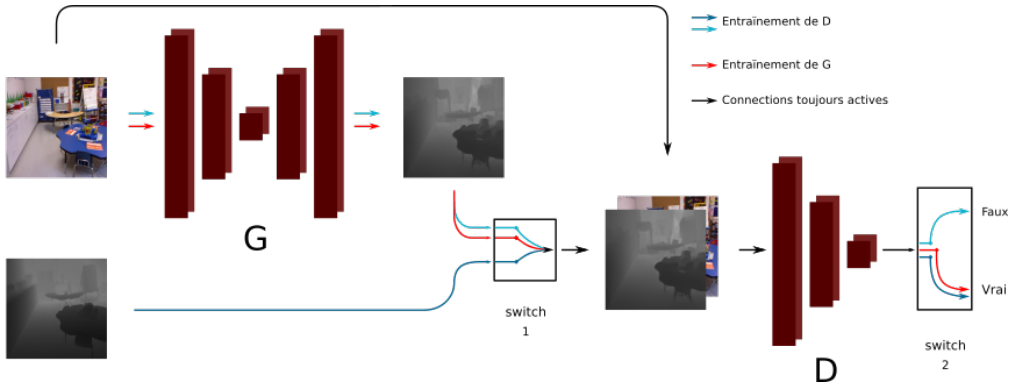

Pour que G traduise une image d'un domaine à un autre (*Pix2pix*):

- Conditionner l'image générée $G(z)$ a une image existante z
- Dropout sur les poids du générateur
- D estime la validité de la paire d'image $(z, G(x))$ ou (z, x)
- Pénalité:

$$\min_D V(D) = \mathbb{E}_{x\sim p_{data}(x)}[(D(x)-1)^2] + \mathbb{E}_{z\sim p_z(z))}[(D(G(z)))^2] + \lambda|x - G(z)|$$

$$\min_G V(G) = \mathbb{E}_{z\sim p_z(z))}[(D(G(z))-1)^2]$$

Isola et al., *Image-to-Image Translation with Conditional Adversarial Networks*, CVPR'2017.

Application : estimation de la 3D (profondeur)

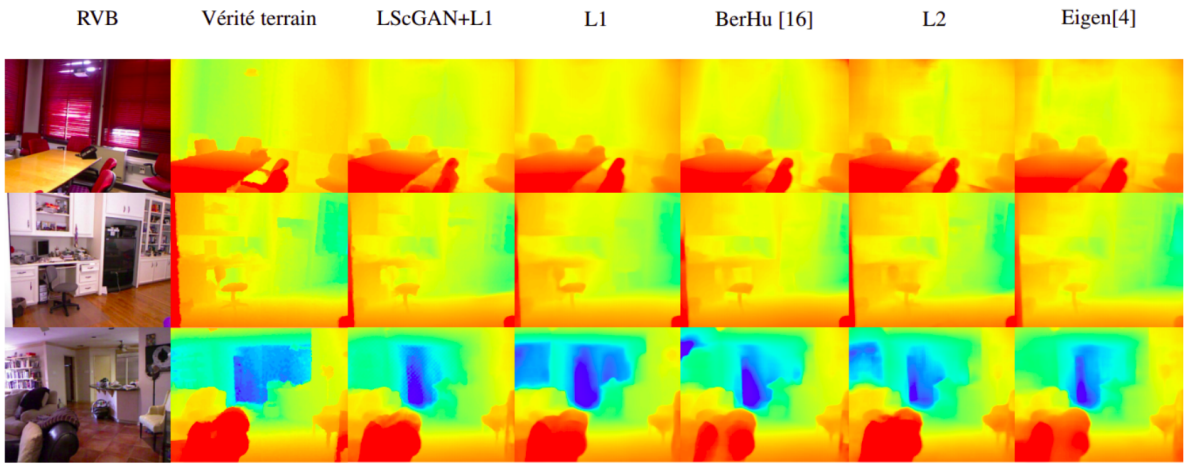

- Entraînement sur des paires (image,profondeur)
- L_1 suffit, mais L_{LSGAN} si suffisament d'exemples...
- Vidéo : [`img-AE-GANs/D3Net.mp4`]

Carvalho et al., *On Regression Losses for Deep Depth Estimation*, ICIP'2018.

Application : transfert de style

- Générer des visages ressemblants à une personne, vieillir ...
- Vidéo : [`img-AE-GANs/karras2018stylegan-video.mp4`]

Karras et al., *A Style-Based Generator Architecture for Generative Adversarial Networks*, NIPS'2018.

GANs : Résumé

Points clés des GANs

+ Modèles génératifs
+ Rendu réaliste par optimisation de la vraisemblance du résultat
- Entraînement facilement instable ➟ LS-GANs, Wassersteins-GANs
- Détails incertains ➟ Version multi-échelle
- *Mode collapse*

Utilisations

- Régression, régression conditionnée à un signal
- Qualité image : super-résolution, débruitage...
- CGI : transfert de style, morphing, synthèse de films...
- Shopping online : essai de vêtements...
- Traduction de texte en image...

Conclusion

Cours n°9: Auto-encodeurs et GANs

Notions phares du jour

- Auto-encodeurs
- *Generative Adversarial Networks*

Concepts généraux

- Modèles génératifs
- Apprentissage de code (représentations)
- Apprentissage adversaire (lien avec le test de Turing)