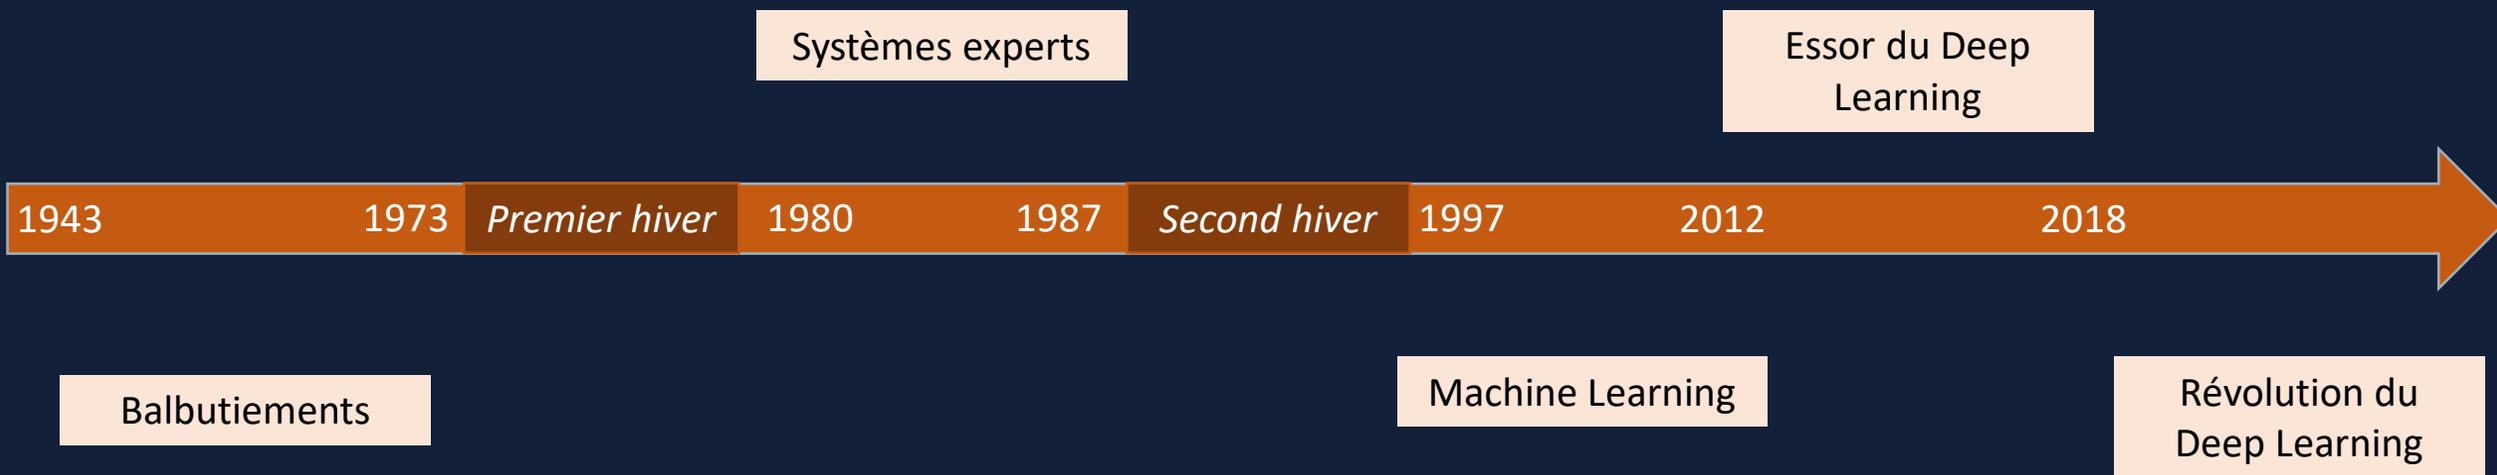


Une brève introduction à l'IA

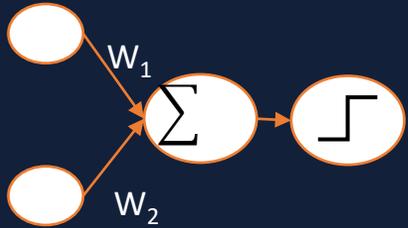
Françoise Bouvet

francoise.bouvet@ijclab.in2p3.fr

Petite histoire de l'IA

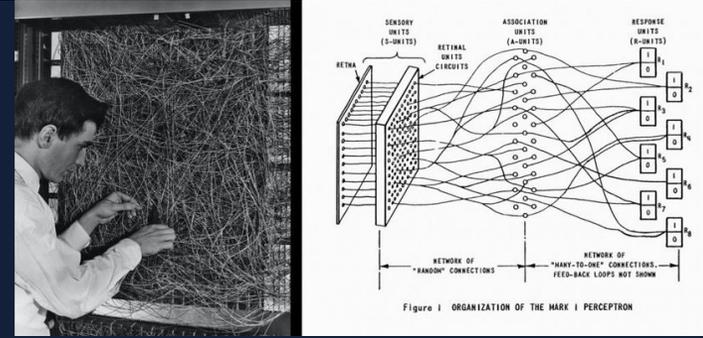


Petite histoire de l'IA : les balbutiements



Neurone formel
McCulloch, Pitts et Hebb, 1943

Perceptron F. Rosenblatt, 1957
Premier système d'apprentissage automatique



1943

1973

Premier hiver

1980

1987

Second hiver

1997

2012

2018

Test de Turing, 1950

Si une machine peut mener une conversation (par télécriteur interposé) qu'on ne puisse différencier d'une conversation avec un être humain, alors la machine peut être qualifiée d'« intelligente »



Conférence de
Dartmouth, 1956

Petite histoire de l'IA : les systèmes experts

Systemes experts

Logique floue

Approche symbolique : règles qui simulent le raisonnement humain

1989 : Tim Berners-Lee invente le World Wide Web (WWW) au CERN, introduisant les concepts de l'URL, HTTP, et HTML.



1973

Premier hiver

1980

1987

Second hiver

1997

2012

2018



Yann Le Cun



Rumelhart

Perceptron multi-couche
Algorithme de rétropropagation
du gradient (GBP), 1986

Petite histoire de l'IA : l'essor du Machine Learning

SVM : Support Vector Machine

Adoption croissante des SVM dans divers domaines, y compris la classification d'images, la bioinformatique et la reconnaissance de texte.

Explosion des données : L'avènement d'Internet a entraîné une explosion des données, fournissant des ensembles de données massifs pour l'entraînement des modèles.

1943

1973

Premier hiver

1980

1987

Second hiver

1997

2012

2018

Deep Blue, 1997



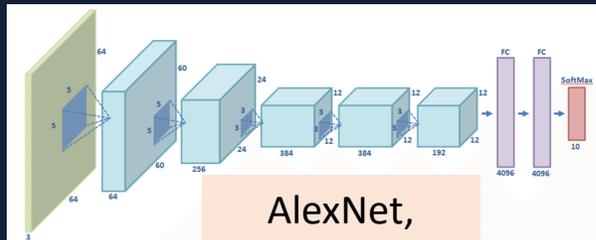
Nvidia : « première »
carte graphique,
Geforce256, 1999

2011

- GoogleBrain
- Siri (reconnaissance vocale)
- Watson (IBM), Jeopardy



Petite histoire de l'IA : l'essor du Deep Learning



Variational AutoEncoder, 2013

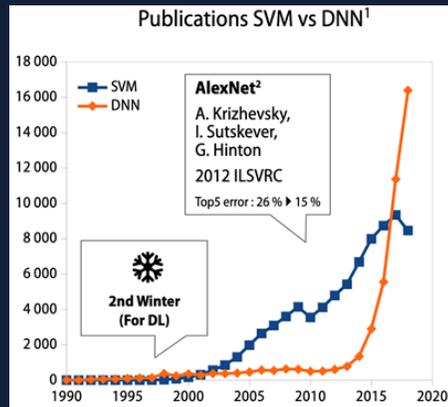
Modèles de diffusion, 2015

Transformers « Attention is all you need », 2017

LSTM (Recurrent Neural Network), 2014



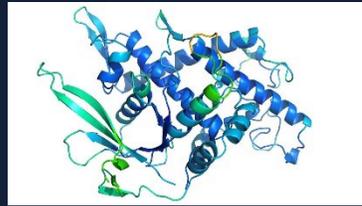
Modèles de fondation, 2018



BERT (LLM de Google AI), 2018

- 4 conditions réunies :**
- Progrès algorithmiques, éclosion des modèles
 - Puissance des GPUs
 - Framework Deep Learning
 - Masse de données

Petite histoire de l'IA : la révolution du Deep Learning



AlphaFold2,
2020



Dall'E : modèle de
diffusion, 2021

Dall'E 2, 2022

AlphaFold3,
2024

Multimodalité

- Image
- Audio
- Vidéo
- Texte

1943

1973

Premier hiver

1980

1987

Second hiver

1997

2012

2018

GPT2, 2019

GPT1, 2018
Generative Pre-trained
Transformers (OpenAI)

GPT3, 2020

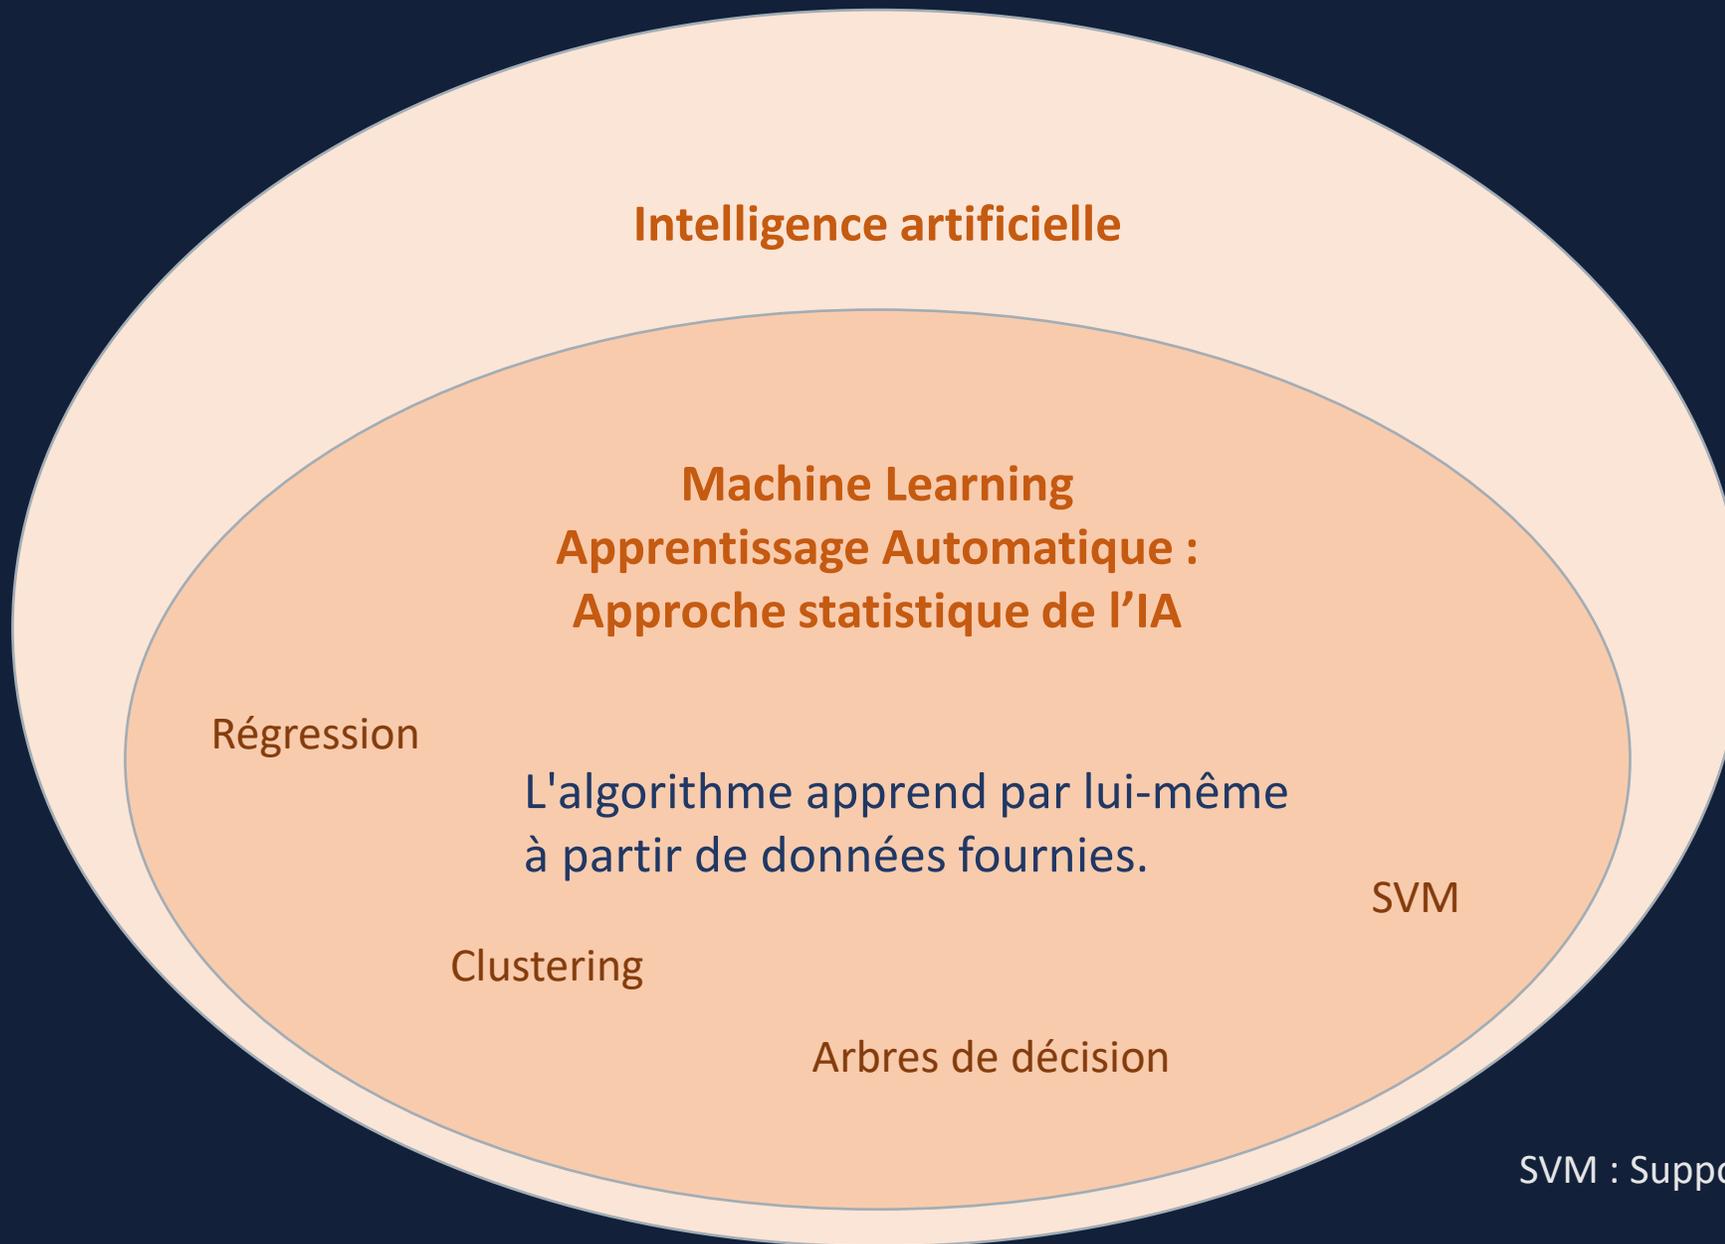
GPT4, 2023

Llama2, 2023
(MetaAI)

Gemini, 2024
(Google)

**Intelligence artificielle :
Simulation du comportement du cerveau**

L'ordinateur est programmé
explicitement pour effectuer une tâche.



Intelligence artificielle

**Machine Learning
Apprentissage Automatique :
Approche statistique de l'IA**

Régression

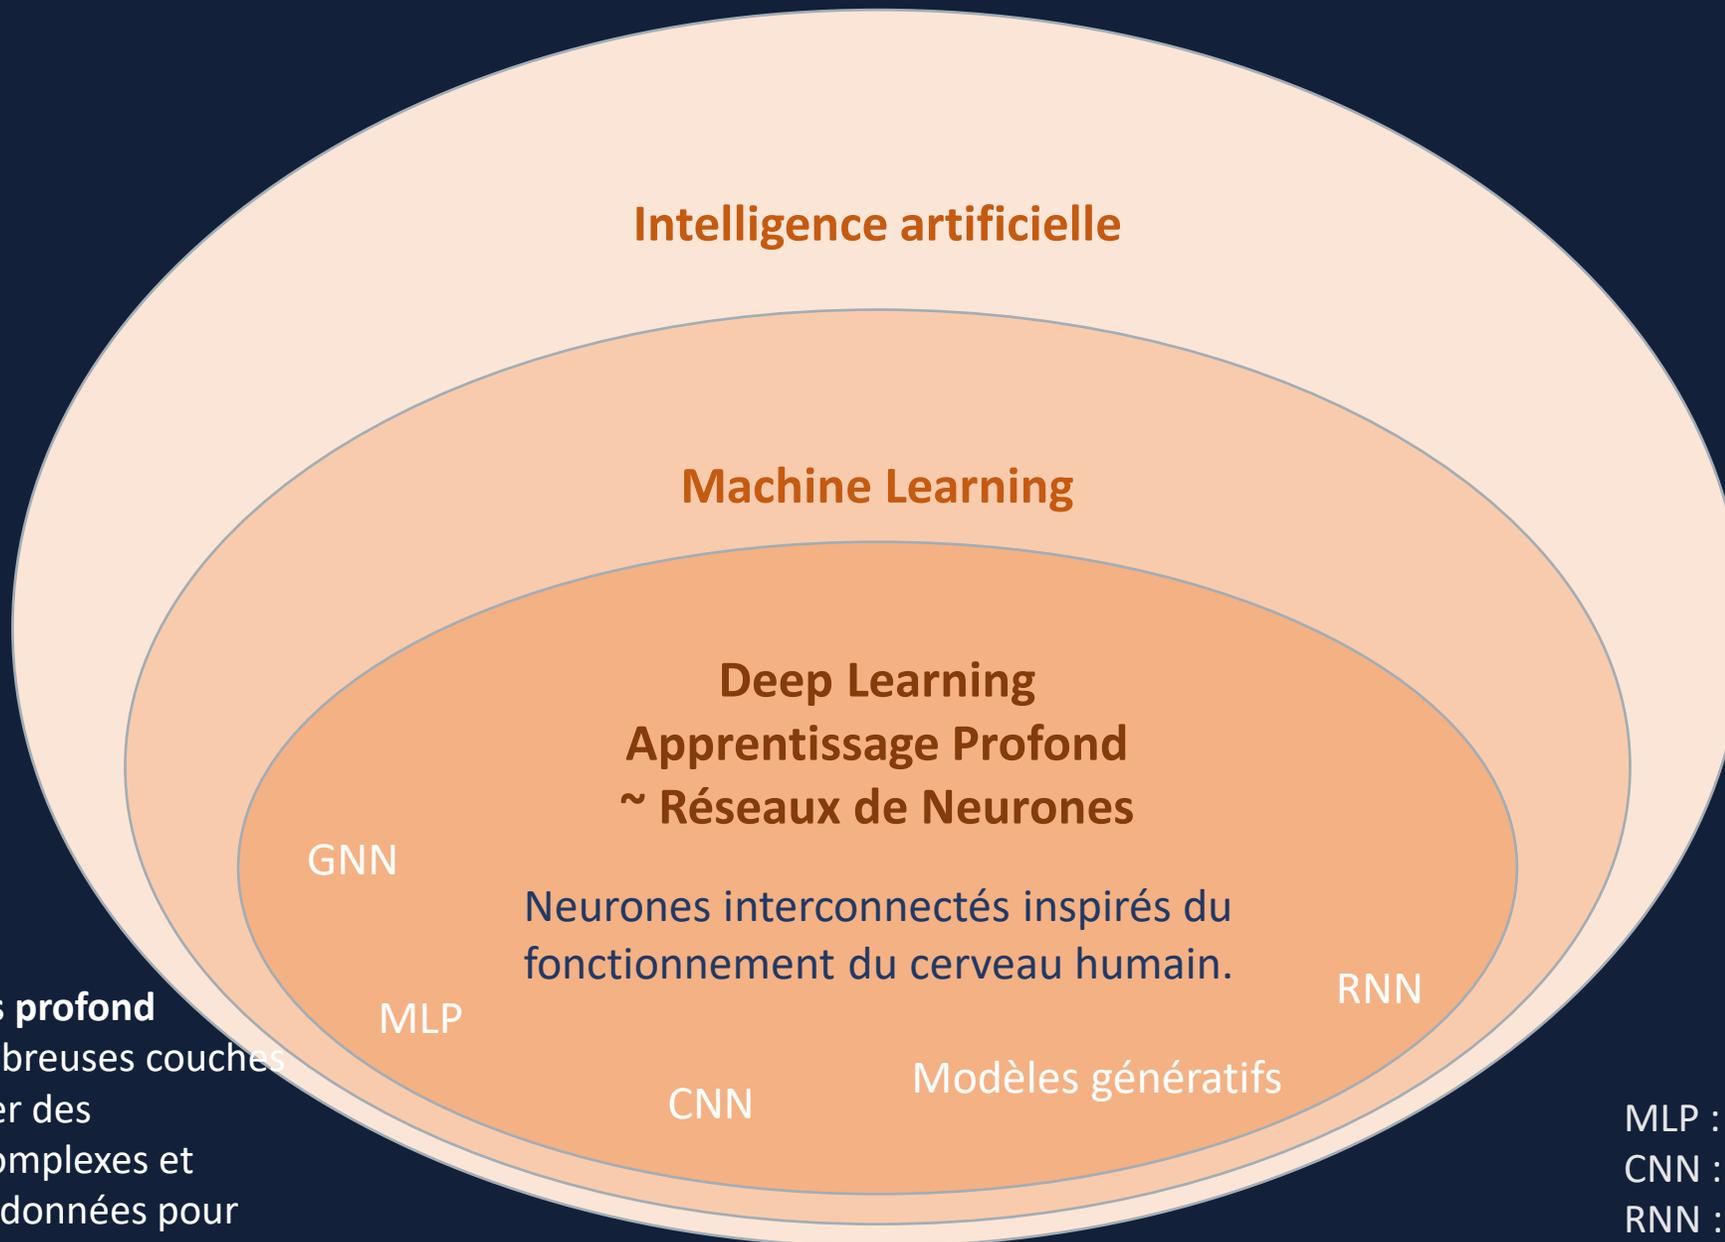
L'algorithmme apprend par lui-même
à partir de données fournies.

SVM

Clustering

Arbres de décision

SVM : Support Vector Machine



Réseau de neurones profond

- Comporte de nombreuses couches
- Permet de capturer des représentations complexes et hiérarchiques des données pour résoudre des problèmes complexes

MLP : Multi Layer Perceptron
CNN : Convolution NN
RNN : Recurrent NN
GNN : Graph NN

Généralités

Types d'apprentissage

Apprentissage **supervisé**

Les données sont **étiquetées**, l'algorithme apprend à **prédire**

- Classification
- Segmentation



Fleur

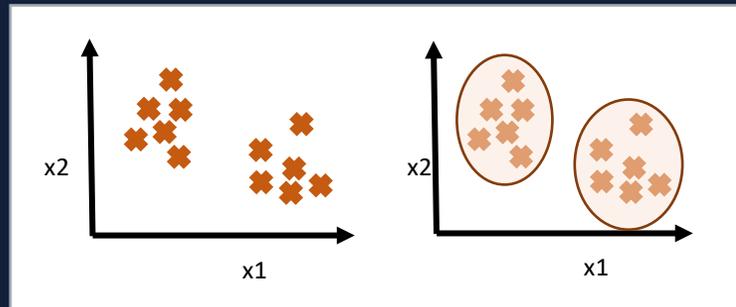


Animal

Apprentissage **non supervisé**

Les données ne sont **pas étiquetées**, l'algorithme apprend leur **structure** inhérente

- Détection d'anomalies
- Clustering



Apprentissage **semi-supervisé** (weak supervision)

Seules **certaines données** sont étiquetées

- Etiquetage d'images
- Analyse de texte
- Classification de contenu web

Apprentissage **par renforcement**

Basé sur un cycle **expérience / récompense**

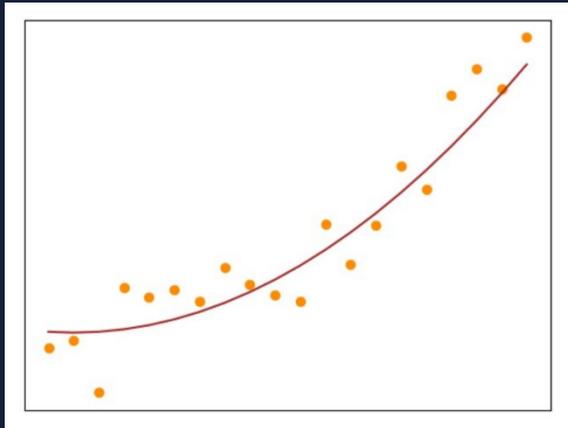
Améliore les performances à chaque itération

- Robot
- Réseaux sociaux (like, temps passé)
- Jeux vidéo

Classification / Régression

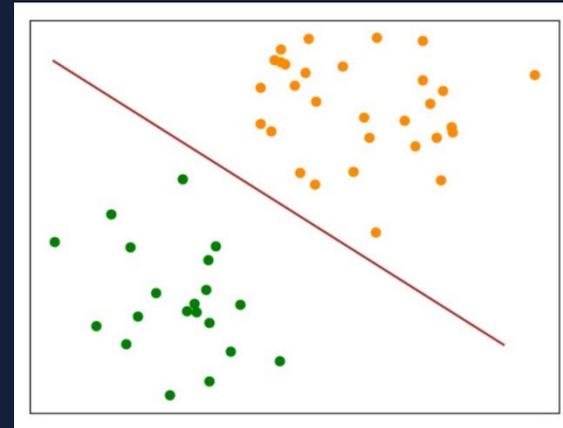
Régression

La valeur en sortie est **continue** (nombre réel)



Classification

La valeur en sortie est **discrète** (catégorie)



- Binaire (2 classes)
- Multi-classes
- Labels ordonnés

Machine Learning

Apprentissage non supervisé

Réduction de dimensionnalité

- ✓ Compression, réduction du bruit, éliminer des paramètres non significatifs, accélérer la convergence, visualiser en 2D ou 3D information
- ✓ Analyse en composantes principales Component Analysis (PCA) ; transformation linéaire
- ✓ t-SNE : T-distributed Stochastic Neighbor Embedding ; transformation non linéaire

Clustering

Regroupement de points qui ont des caractéristiques similaires

- Simplifier l'analyse ultérieure
- Quelques méthodes
 - K-Means
 - DBSCAN
 - Gaussian Mixtures

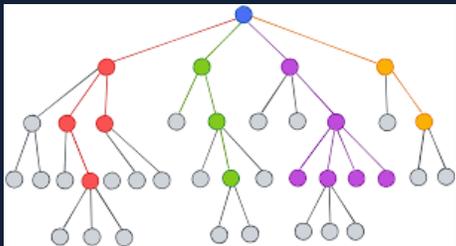


Apprentissage supervisé

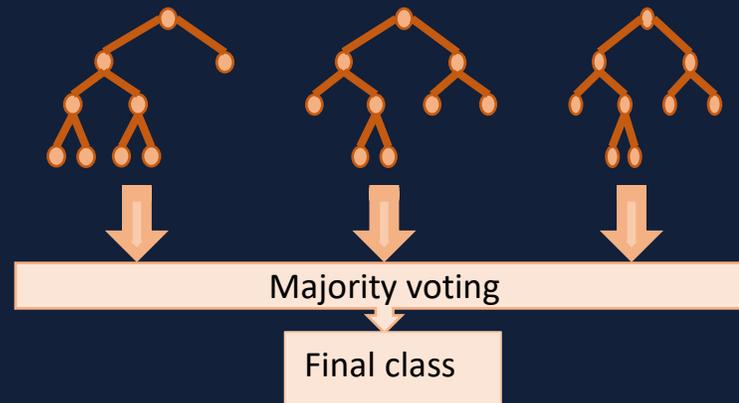
Support Vector Machine (SVM)

- Généralisation des classifieurs linéaires
- Basés sur les fonctions noyaux

Arbres de décision

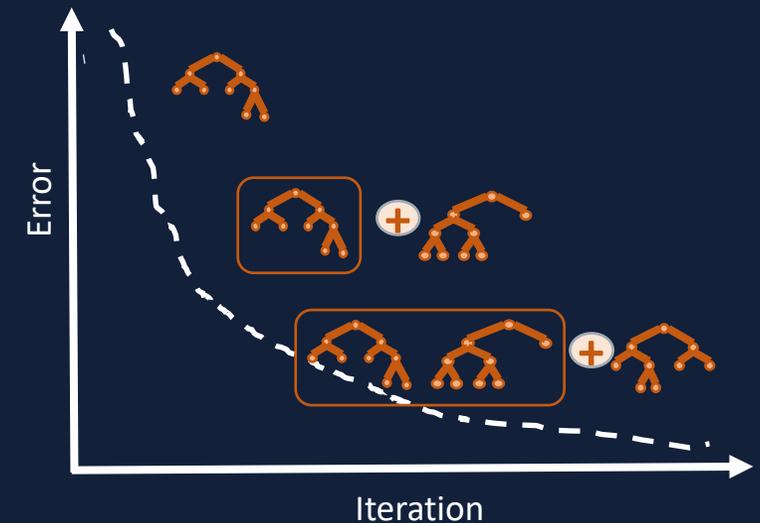


- Chaque nœud contient une condition sur un paramètre
- Chaque nœud terminal (feuille) contient une classe



Méthode de Bagging : Random Forest (RF)

- Construction de plusieurs arbres puis vote

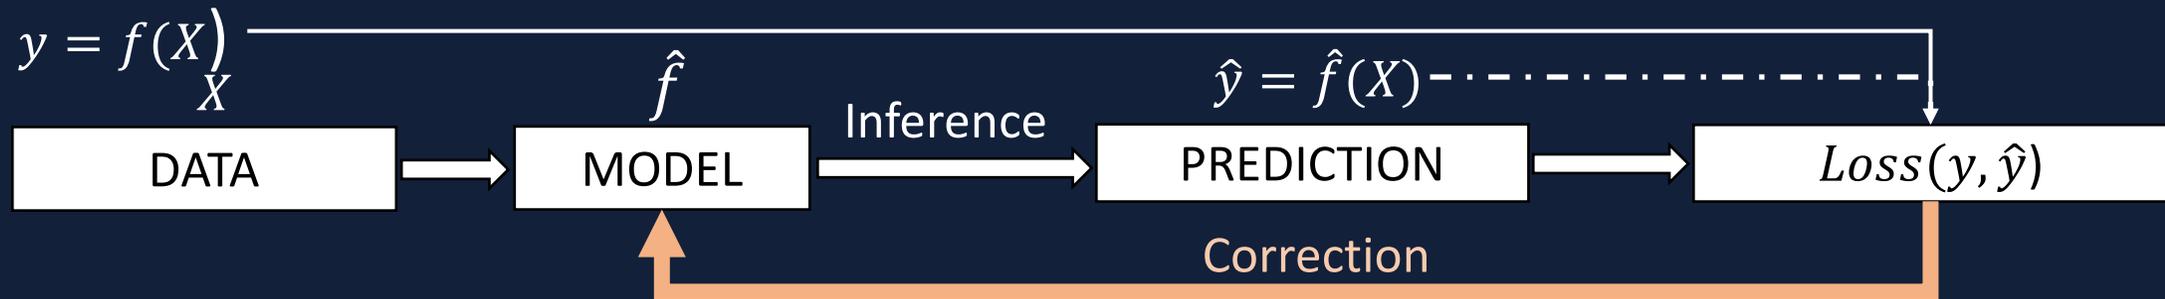


Méthode de Boosting : Gradient Boosted Decision Tree (GBDT)

- Construction successive de plusieurs arbres pour optimiser la précision globale

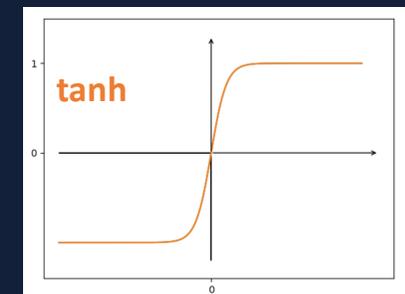
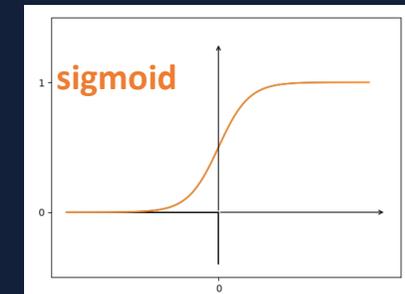
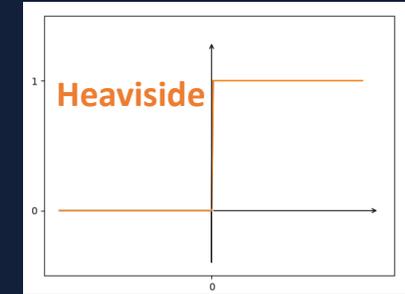
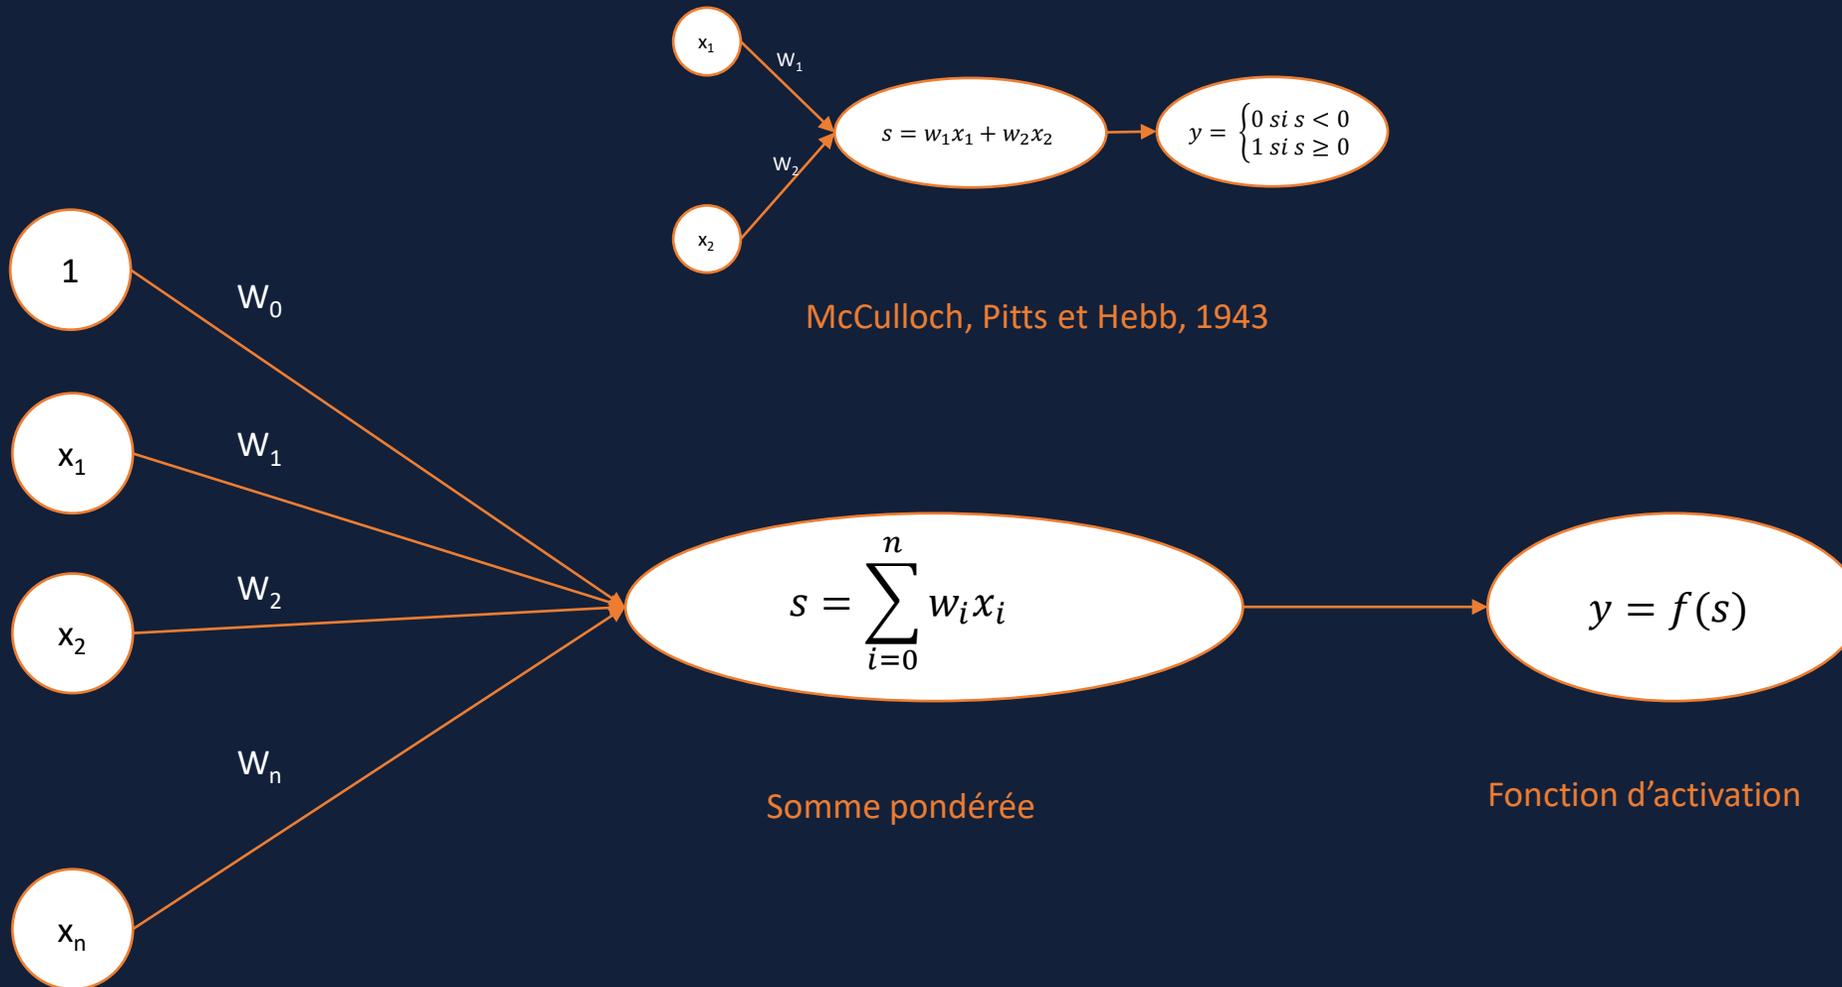
Deep Learning

Principe de l'apprentissage supervisé



- \hat{f} est une approximation de f
- \hat{f} peut approximer une fonction f non linéaire
- En DL, \hat{f} est implémentée par un réseau de neurones (profond)

Le neurone formel



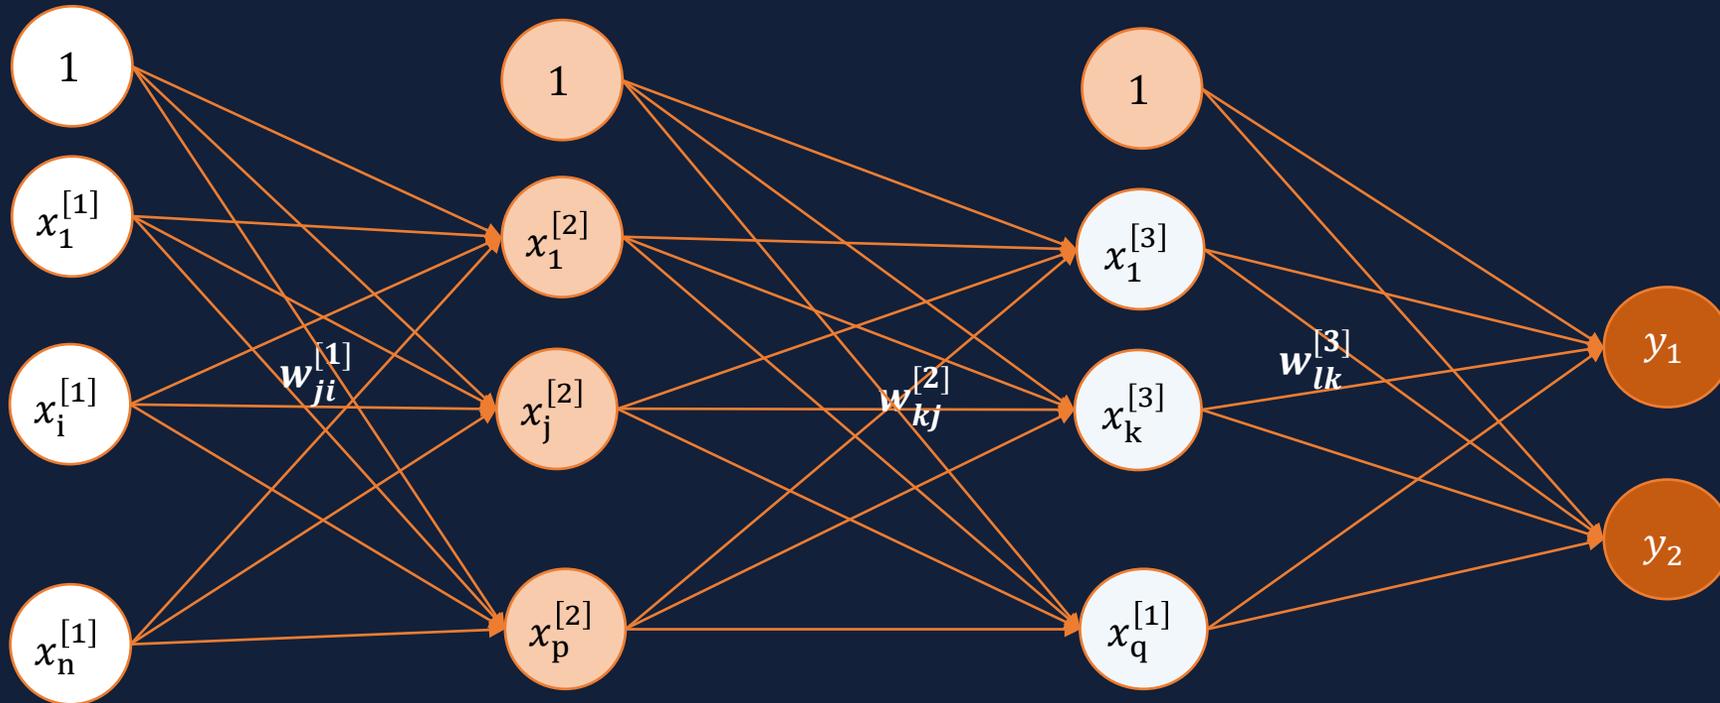
Perceptron Multi Couche (MLP) : propagation

Couche d'entrée

Couche cachée

Couche cachée

Couche de sortie



$$s_j^{[2]} = \sum_{i=0}^n w_{ji}^{[1]} x_i^{[1]}$$

$$x_j^{[2]} = f(s_j^{[2]})$$

$$s_k^{[3]} = \sum_{j=0}^p w_{kj}^{[2]} x_j^{[2]}$$

$$x_k^{[3]} = f(s_k^{[3]})$$

$$y_l = \sum_{k=0}^q w_{lk}^{[3]} x_k^{[3]}$$

Notation matricielle

Couches intermédiaires :

$$X^c = f(W^{c-1} X^{c-1})$$

Couche de sortie :

$$Y = W^{C-1} X^{C-1}$$

f : fonction d'activation

Rétropropagation du gradient

Fonction de coût : $C(y, \hat{y}) = \frac{1}{2} \sum_{i=1}^N (\hat{y}_i - y_i)^2$

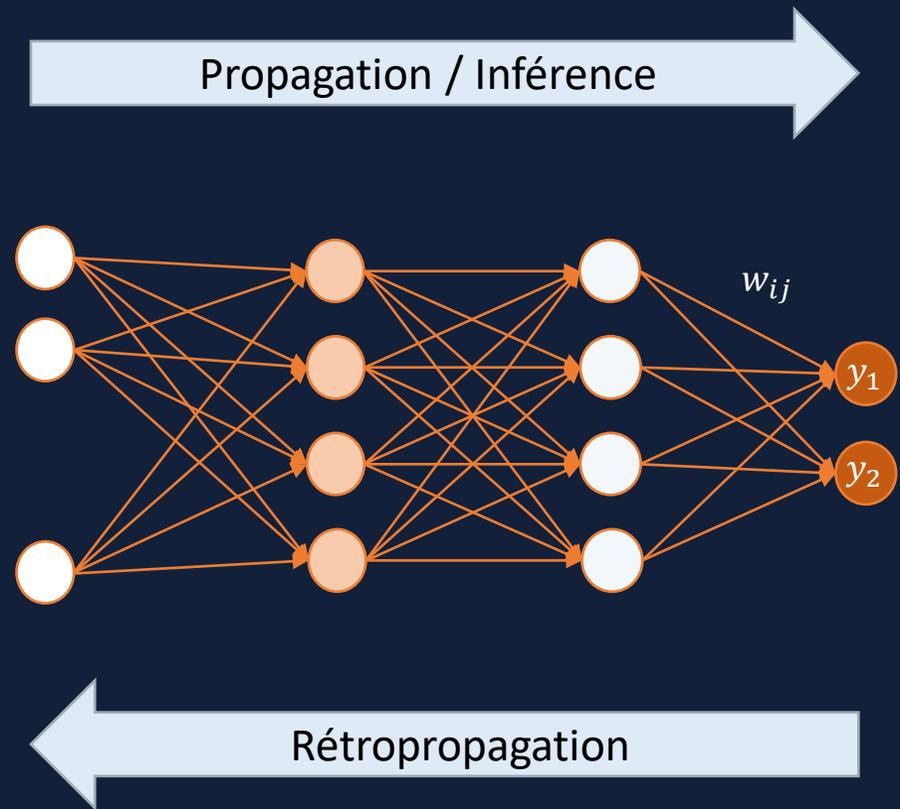
Algorithme de rétropropagation du gradient :

1. Calculer $\frac{\partial C}{\partial w_{ij}}$

2. Modifier rétroactivement les poids

$$w_{ij} := w_{ij} - \alpha \frac{\partial C}{\partial w_{ij}}$$

α : taux d'apprentissage (learning rate)



Points de vigilance

Les données

Le **prétraitement des données** est **essentiel** pour beaucoup de modèles.

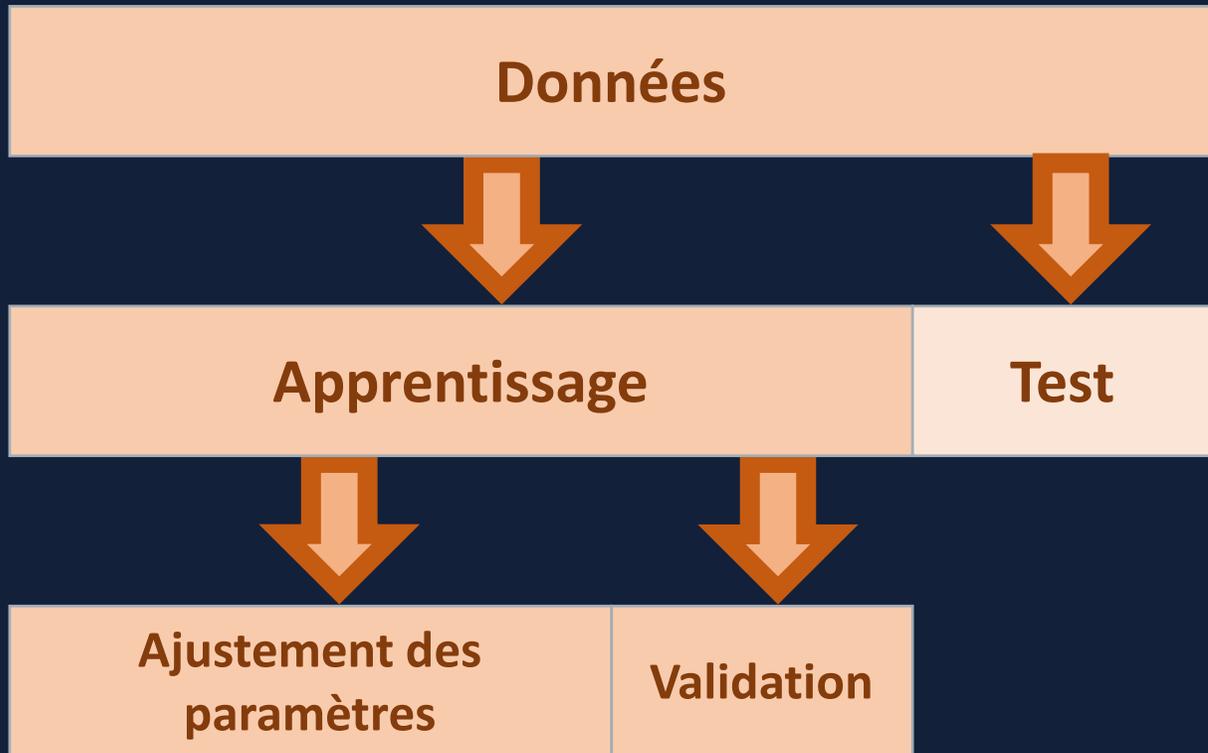
Prétraitement des données d'entraînement

- Données continues
 - Normalisation
 - Discrétisation
- Données discrètes
 - Encodage ordinal : bleu \rightarrow 1 ; vert \rightarrow 2 ; rouge \rightarrow 3
 - Encodage "one-hot" : bleu \rightarrow $\begin{pmatrix} 1 \\ 0 \\ 0 \end{pmatrix}$; vert \rightarrow $\begin{pmatrix} 0 \\ 1 \\ 0 \end{pmatrix}$; rouge \rightarrow $\begin{pmatrix} 0 \\ 0 \\ 1 \end{pmatrix}$

Problèmes courants

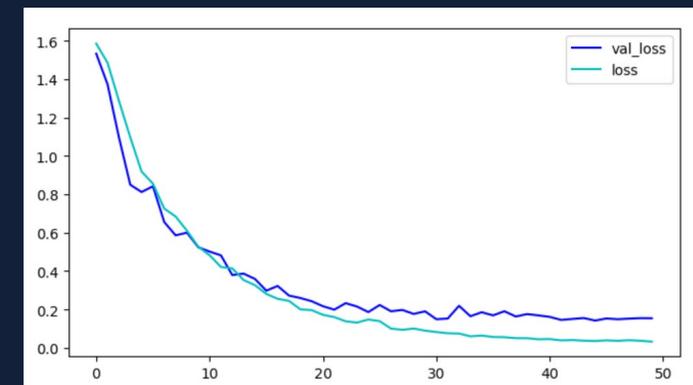
- Manque de données
- Données non représentatives (biais)
- Données de mauvaise qualité (incomplètes ou bruitées)
- Classes non équilibrées (imbalanced)

Séparation des données : test / apprentissage / validation



- L'échantillon d'apprentissage est divisé en 2 : une partie pour ajuster les paramètres du réseau ; une partie « validation » pour évaluer les performances du réseau à chaque itération.
- L'échantillon test sert uniquement à donner les performances finales du modèle.

Typiquement : 60%/20%/20% ; 70%/20%/10%



Evolution de la fonction de coût en fonction du nombre d'époques ; loss : coût calculé et utilisé pour la rétropropagation ; val_loss : coût calculé sur l'échantillon de validation

Evaluation

Définir un critère d'évaluation du modèle est essentiel

Après l'apprentissage : évaluation

Pendant l'apprentissage : minimisation de l'erreur

➤ Le critère dépend de la classe de problème

- Régression
- Classification

➤ Le critère est souvent modifié pour s'adapter au problème à traiter

- Classes non balancées (imbalanced classes)
- Information a priori

fonction de coût (loss function) ≠ métrique

➤ Fonction de coût

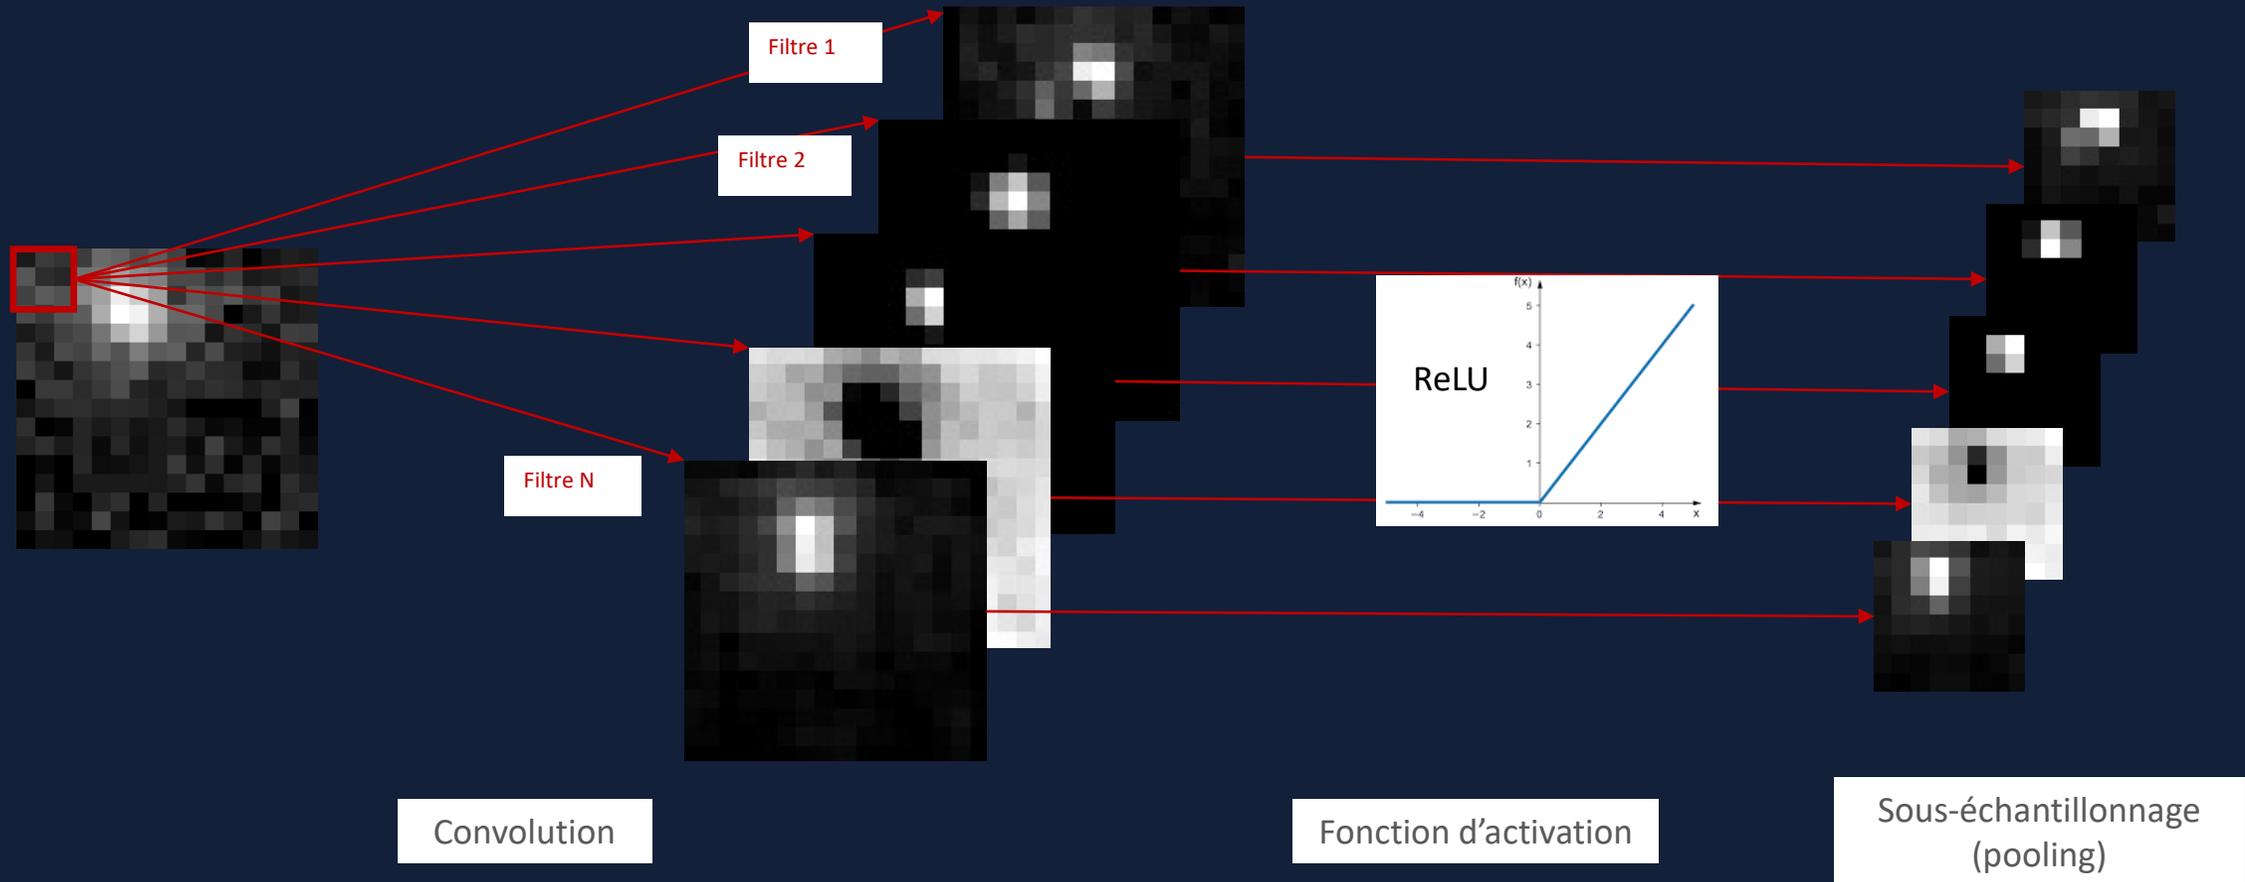
- critère à minimiser pendant l'apprentissage
- doit être différentiable

➤ Métrique

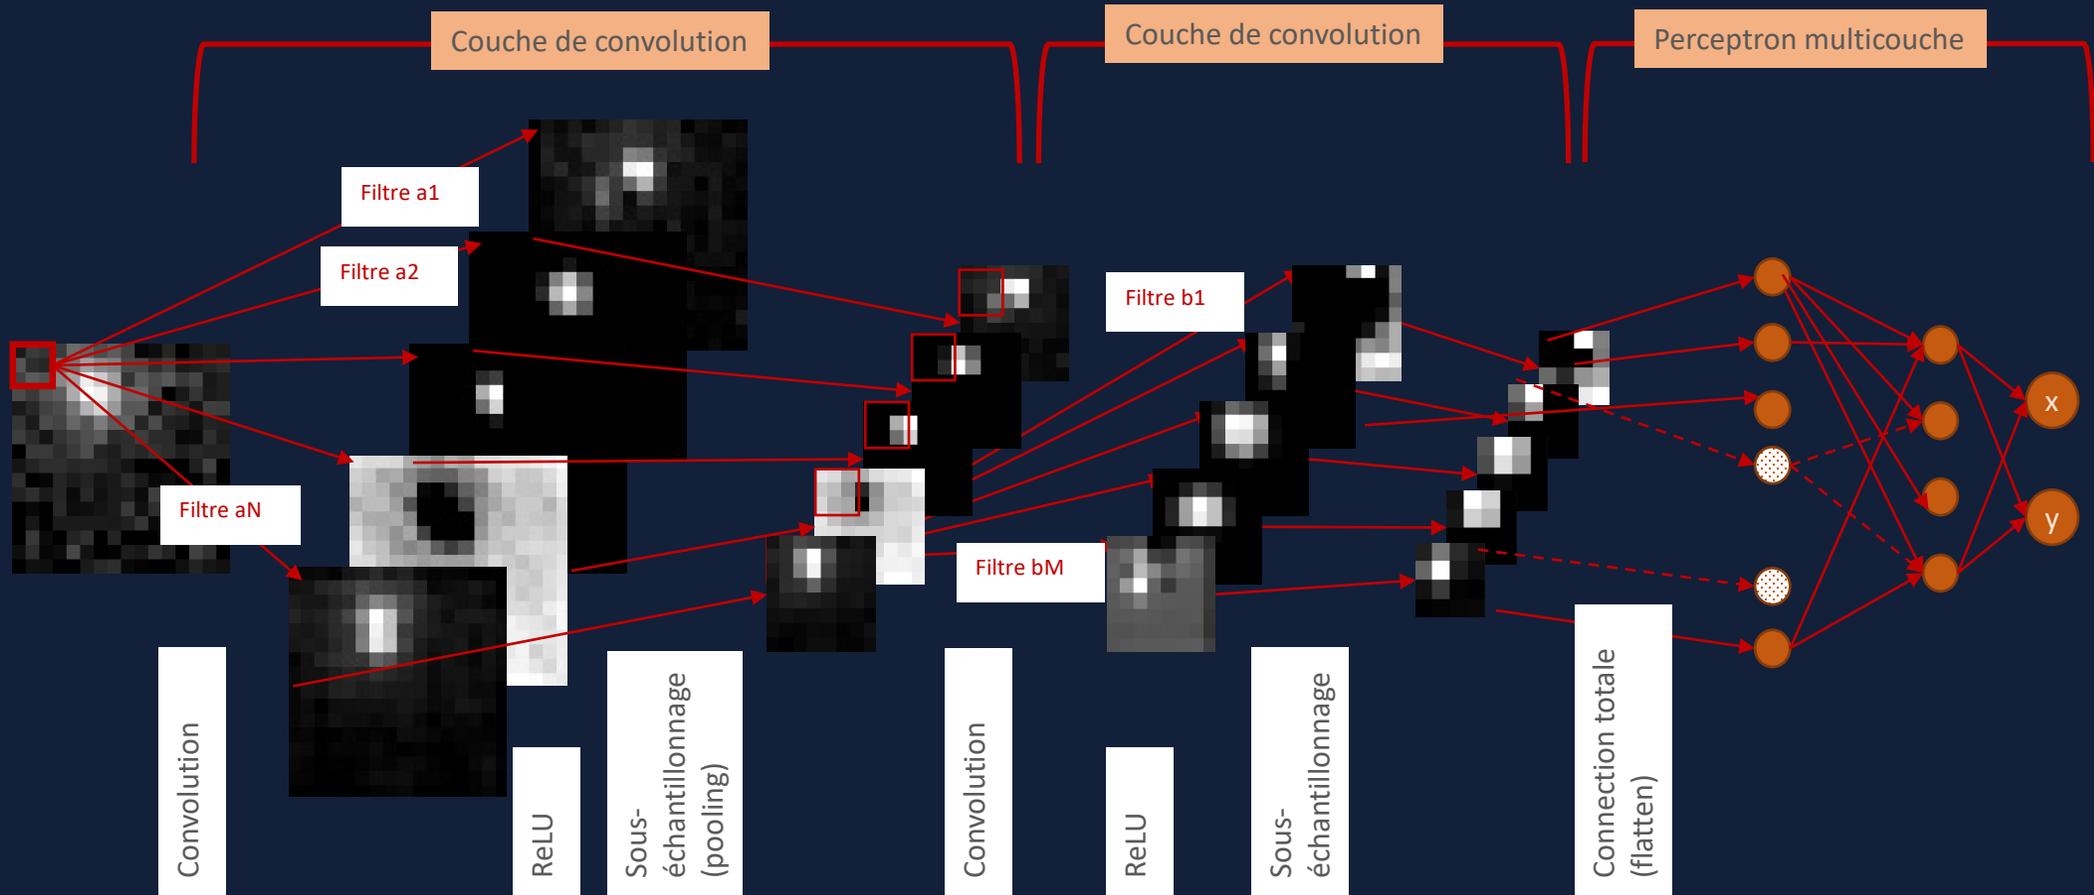
- sert à évaluer la qualité de l'apprentissage
- représentative du résultat attendu
- une bonne pratique est d'en avoir plusieurs

Réseau de convolution

Couche de convolution

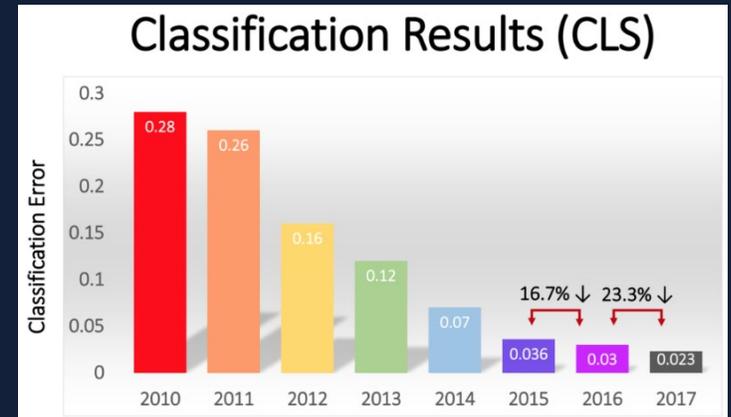


Réseau de convolution

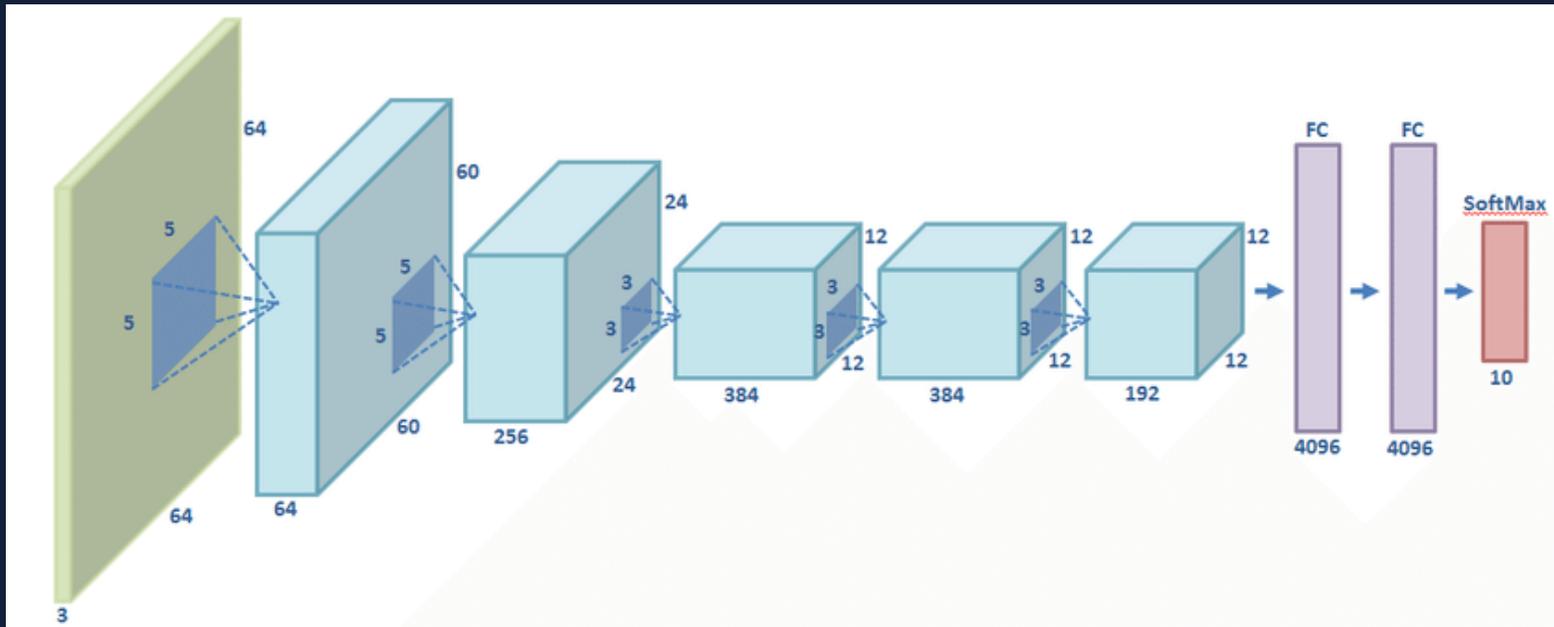


AlexNet, 2012

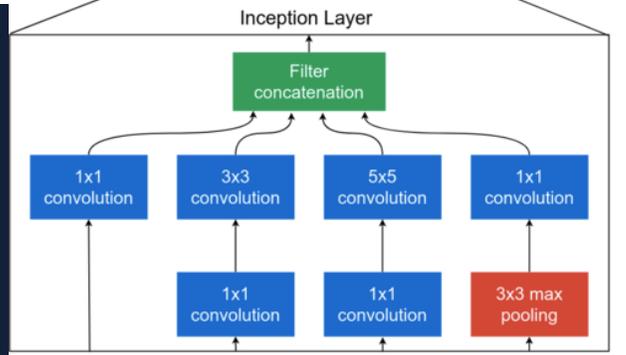
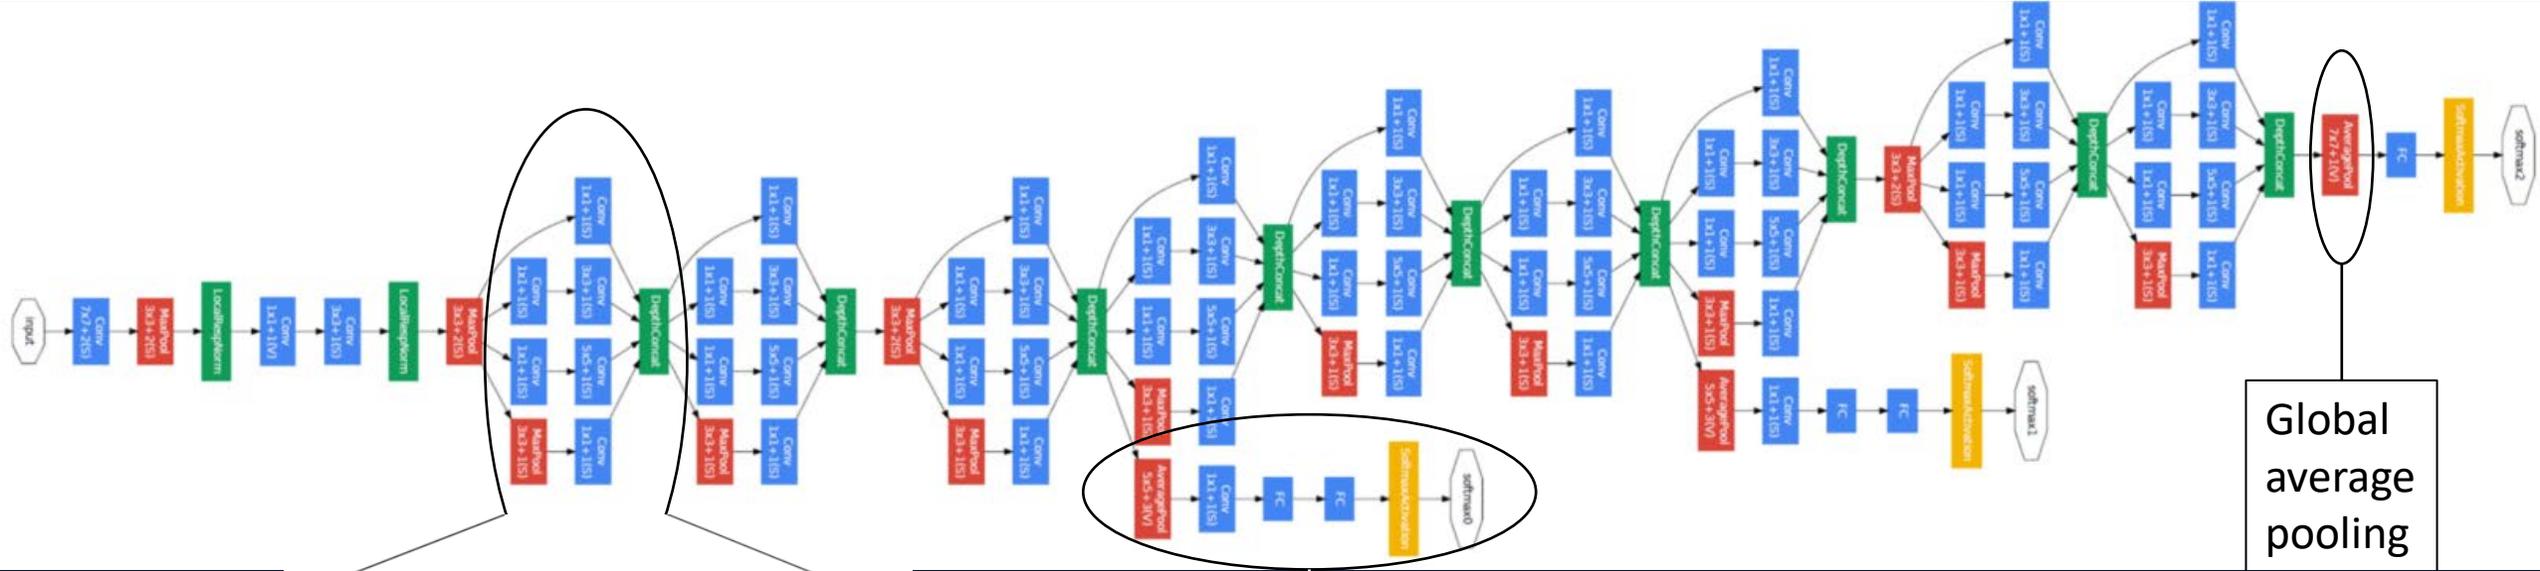
- A partir de 2006, constitution d'une grande base d'images labellisées
- ImageNet Large Scale Visual Recognition Challenge (ILSVRC)
 - $\sim 1.5 \cdot 10^6$ images (90% entraînement - 3% validation - 7% de test)
 - ~ 1000 catégories



ILSVRC : évolution du taux d'erreur



GoogLeNet 2014



Couche d'inception

Classificateur auxiliaire pour l'entraînement

Global average pooling

1D CNN

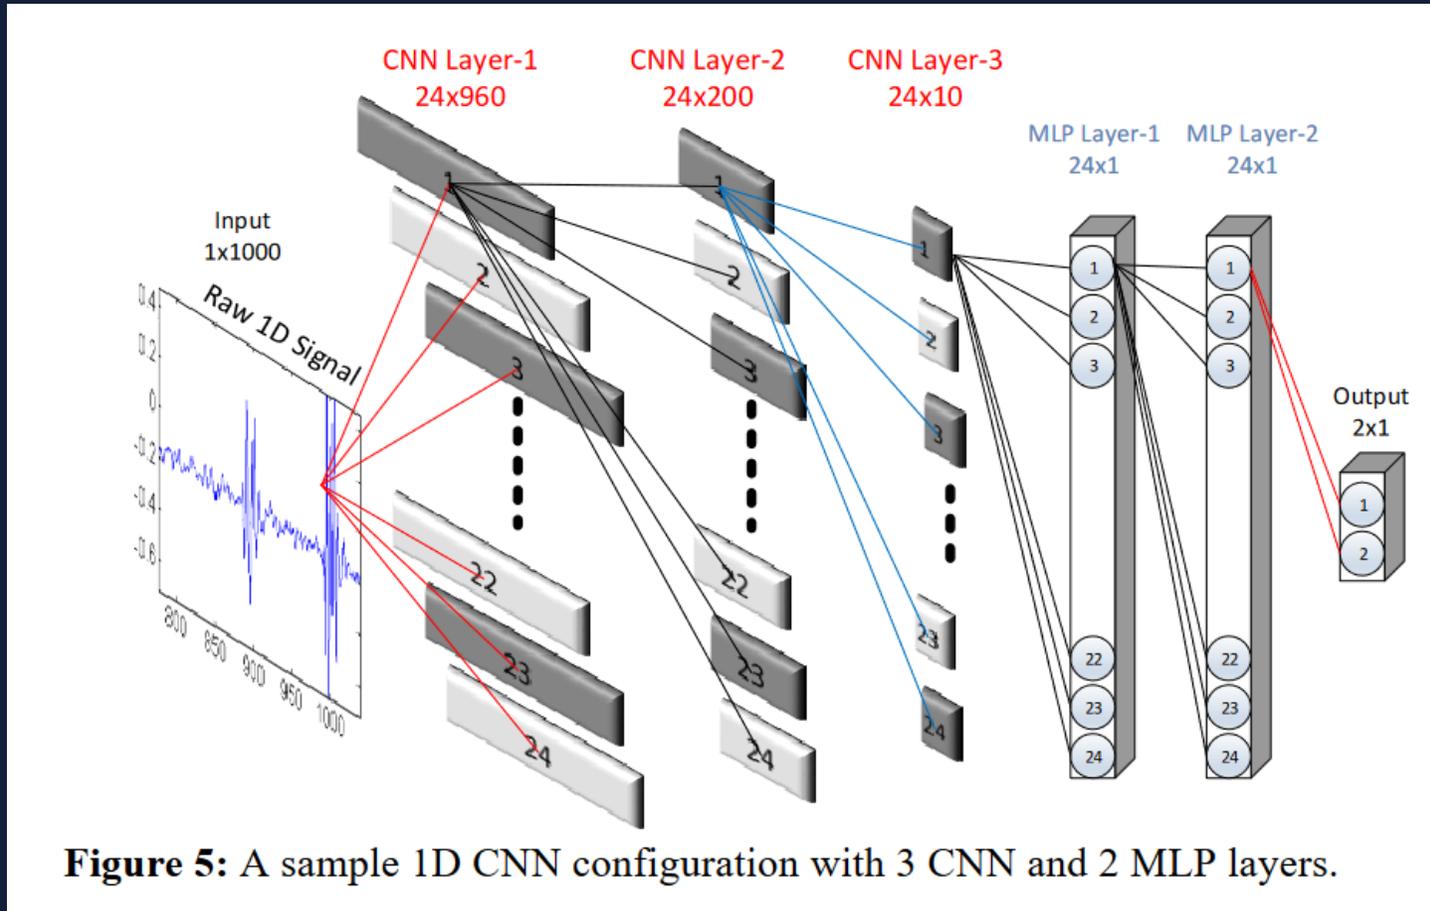


Figure 5: A sample 1D CNN configuration with 3 CNN and 2 MLP layers.

<https://arxiv.org/ftp/arxiv/papers/1905/1905.03554.pdf>

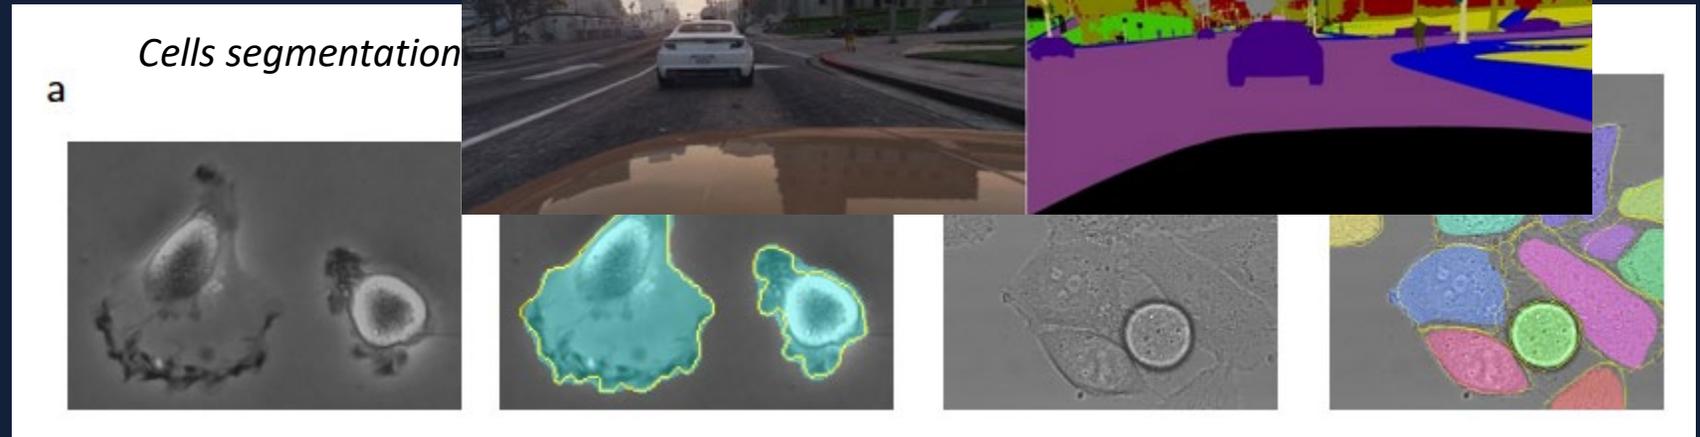
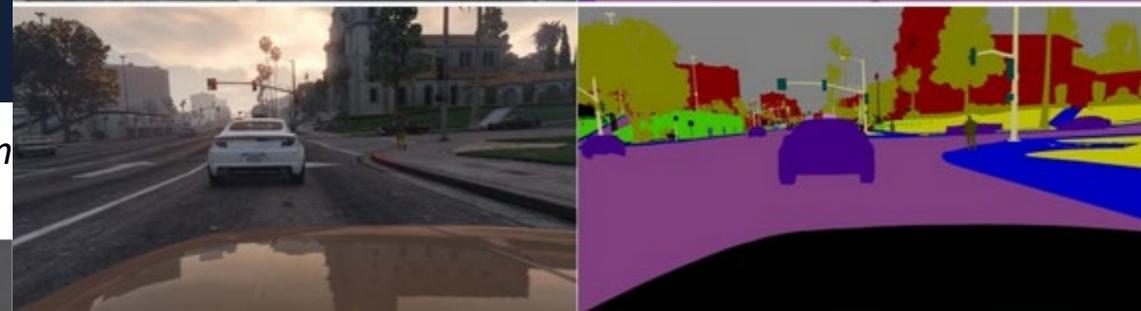
CNN : applications

CNN 2D : Analyse d'images

- Détection d'objets
- Classification
- Segmentation

Domaines

- Reconnaissance faciale
- Imagerie médicale
- Conduite automatique

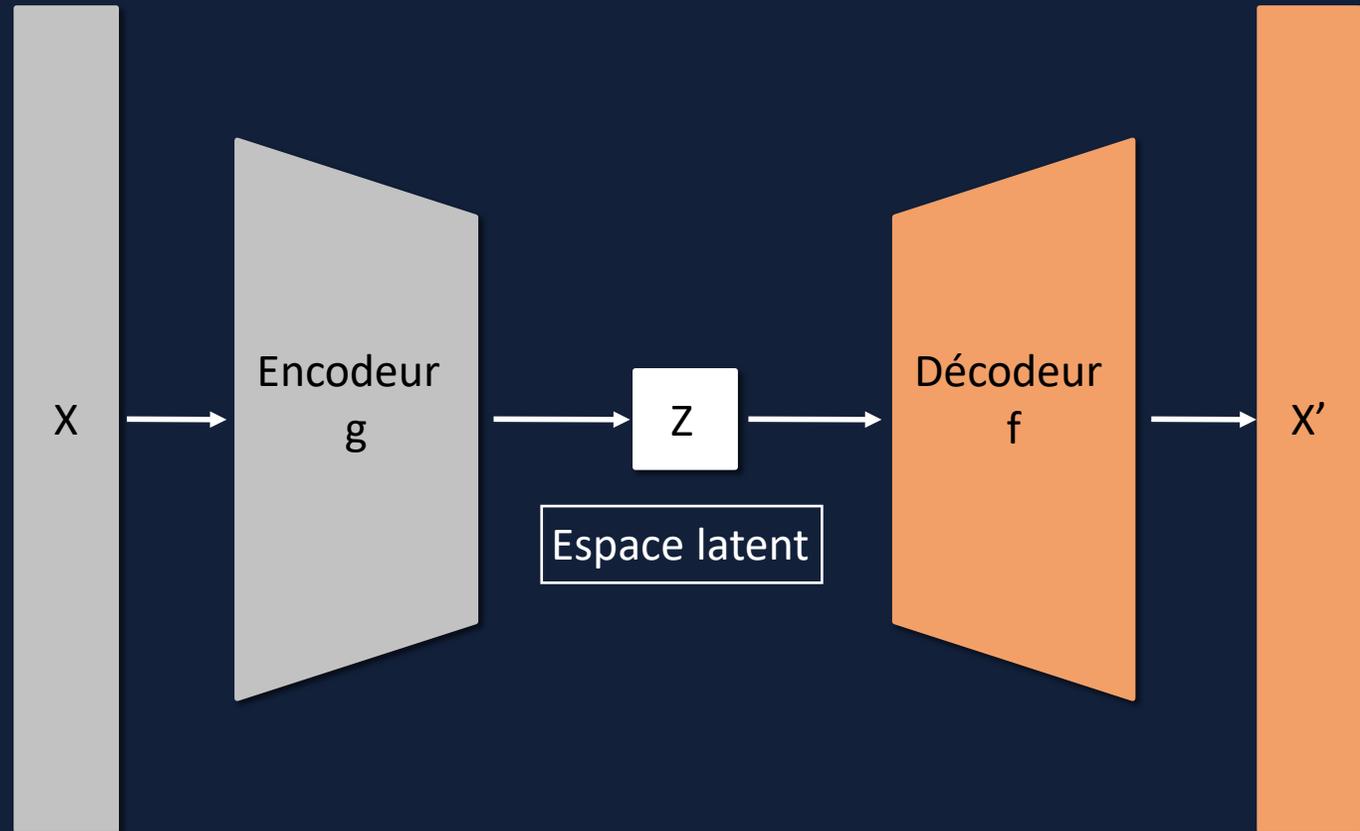


Autres réseaux de neurones

Auto Encodeur

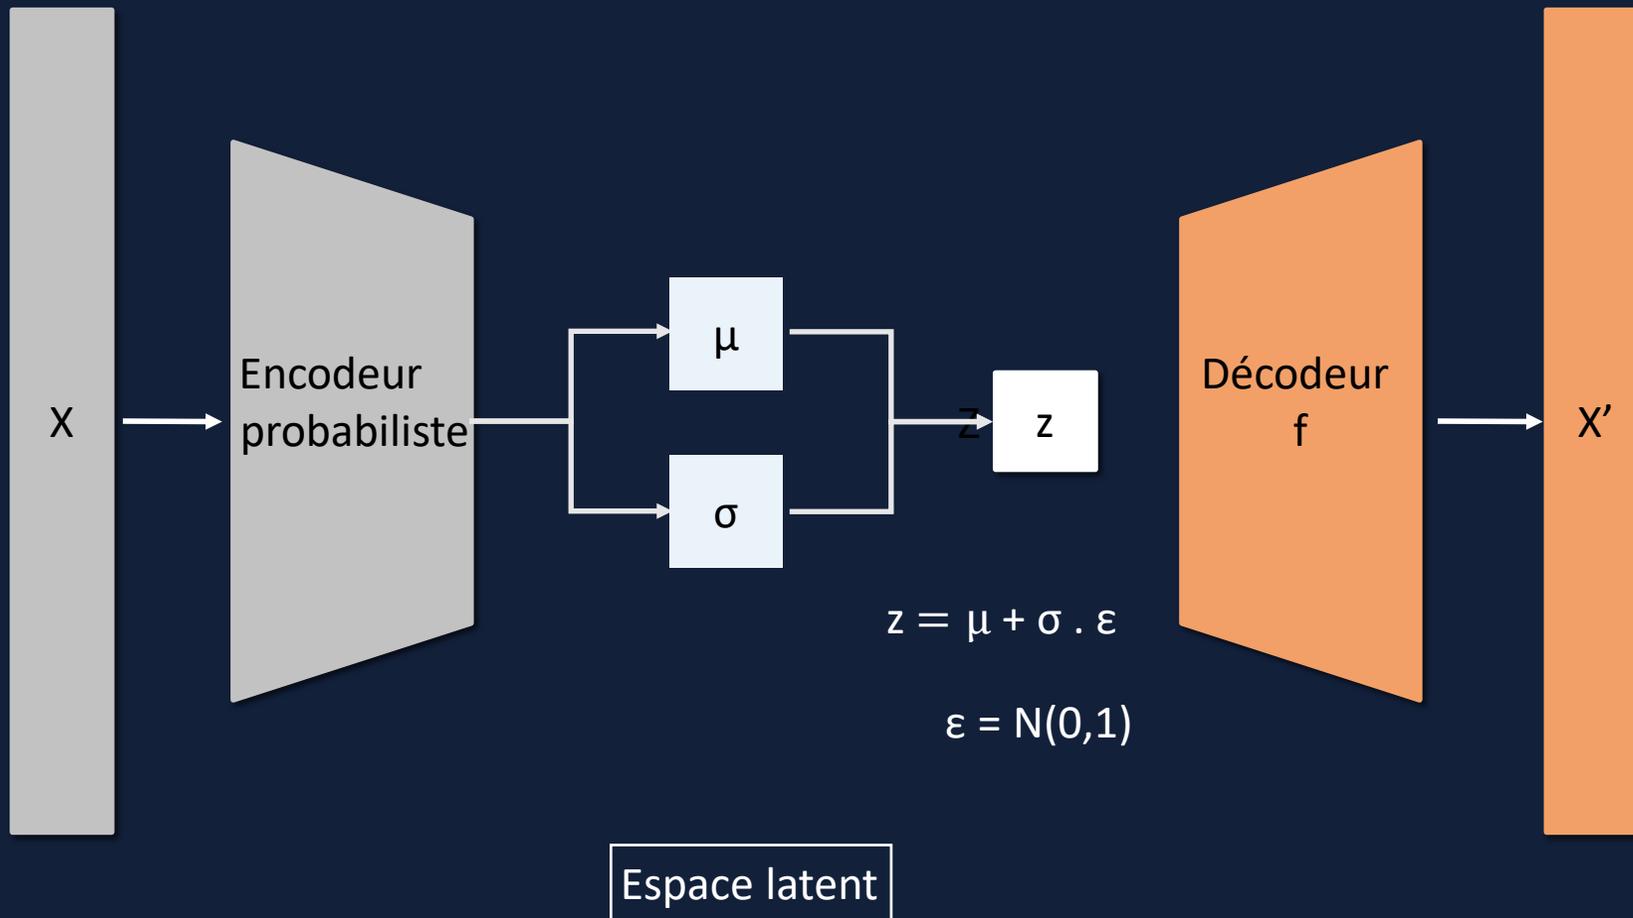
- **Encodeur** : réduit la taille de l'entrée dans un espace de (très) petite dimension dit **espace latent**
- **Décodeur** : reconstruit la donnée d'entrée à partir de l'espace latent
- La fonction de coût minimise la différence entre X et X'

Architecture non supervisée



Tout type de réseau : MLP, CNN, LSTM, transformer, ...

Variational Auto Encodeur (VAE)



Combinaison de deux fonctions de coût

- Binary cross-entropy : mesure la différence entre l'entrée et la sortie
- Divergence de Kullback-Leibler : mesure la divergence entre 2 distributions

AE/VAE : applications

Encodeur/Décodeur

- Détection d'anomalies

Entraînement sur des données « normales » pour reconstruire les entrées « typiques ». Lorsqu'on présente des données avec anomalies, l'erreur de reconstruction augmente.

- Débruitage

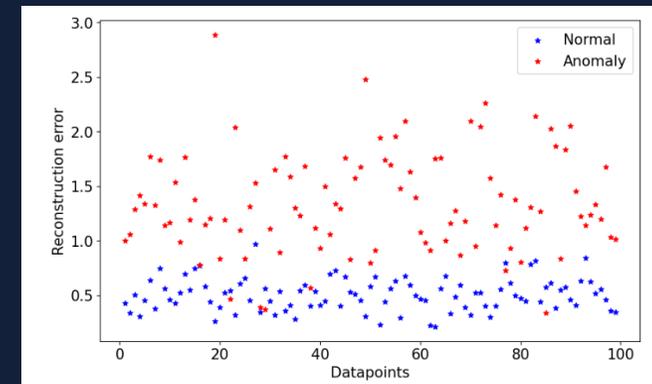
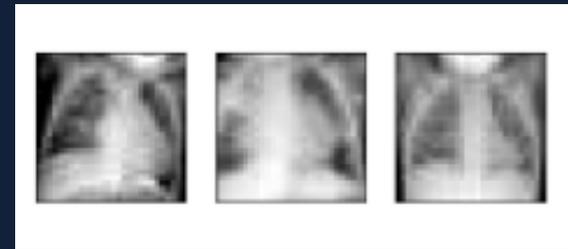
Encodeur

- Réduction de dimensionnalité
- Compression d'image

Décodeur (VAE)

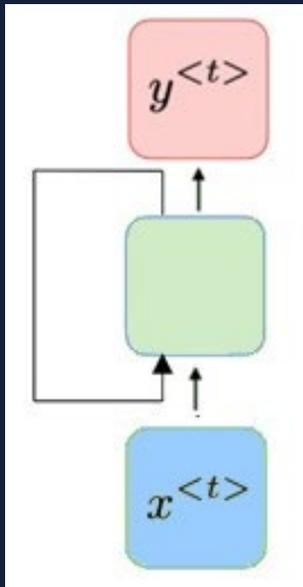
- Génération de données

Détection d'anomalies
RX thoracique

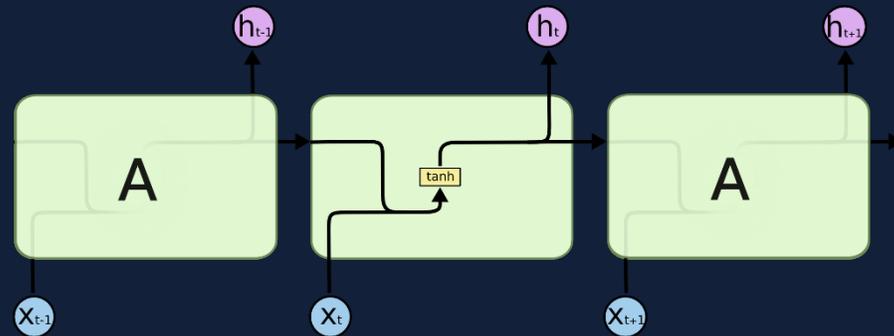
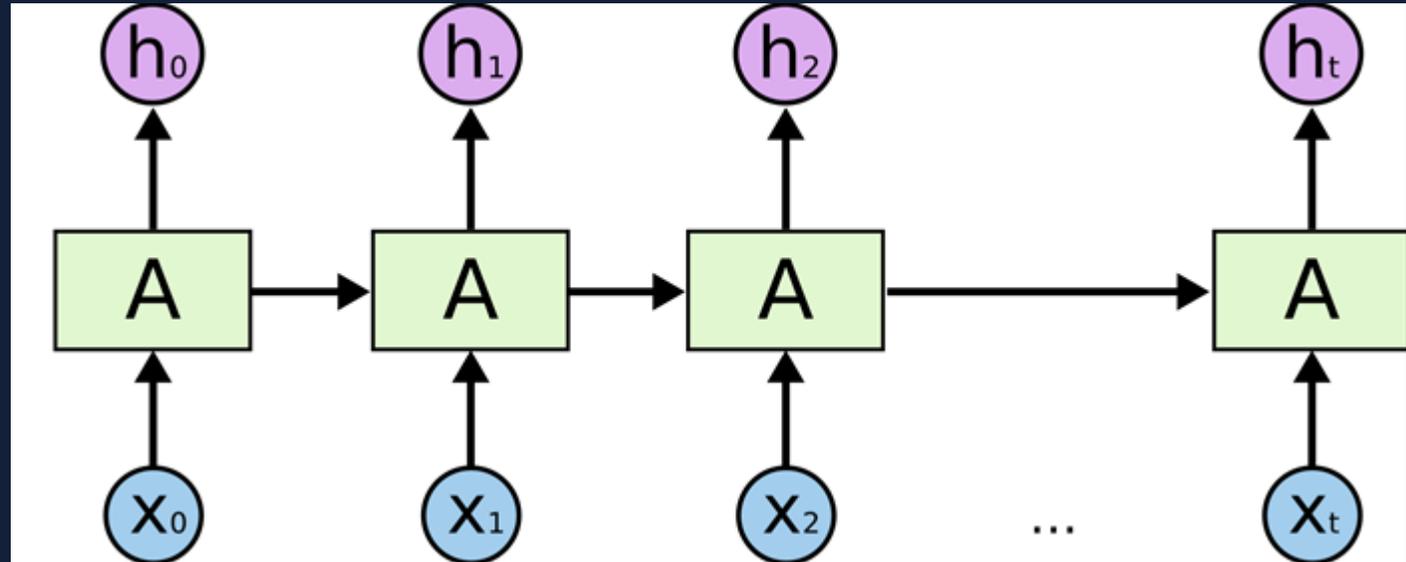


Detecting Rare Diseases: Autoencoders for Detecting Anomalies in Medical Imaging ;S. Reve, University of Twente, 2024

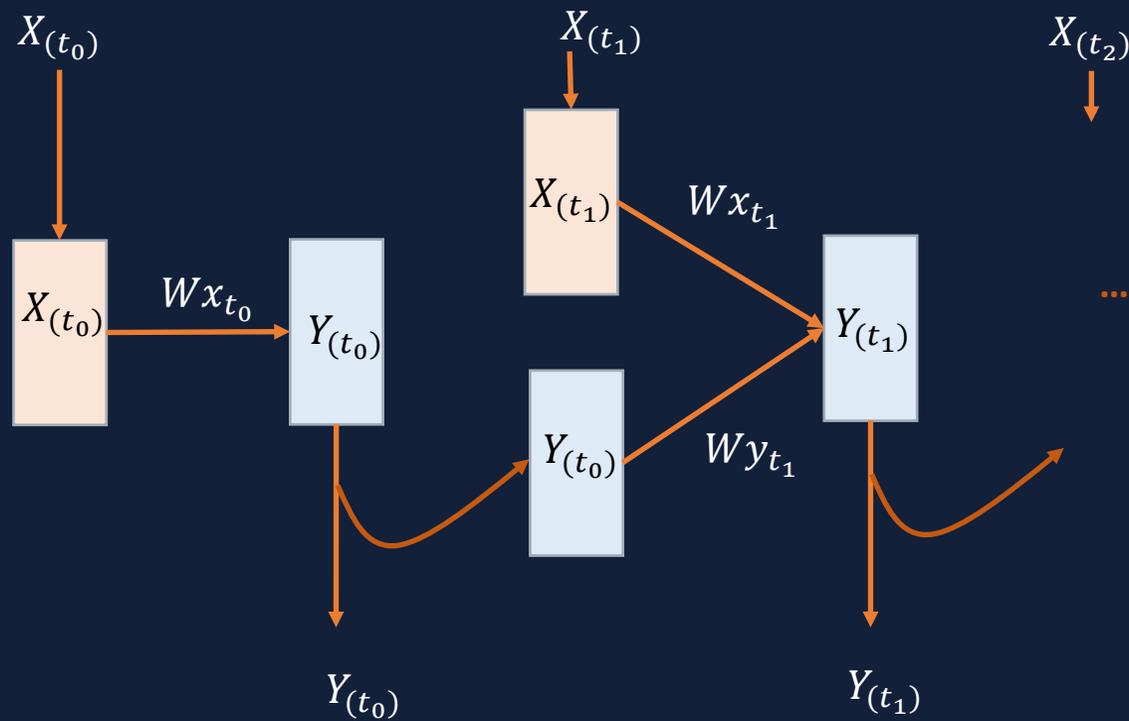
Recurrent Neural Network (RNN)



=



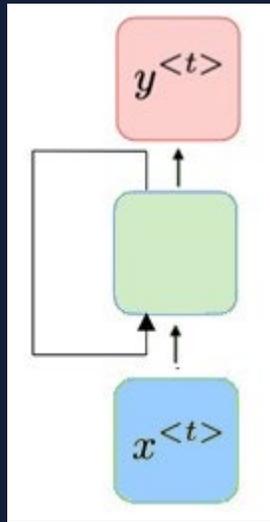
RNN : fonctionnement



X : vecteur (n)
 Y : vecteur (p)
 Wx : tenseur ($n * p$)
 Wy : tenseur ($p * p$)

$$Y_{(t)} = f(Wx_t^T X_t - Wy_t^T Y_{t-1})$$

RNN : variantes

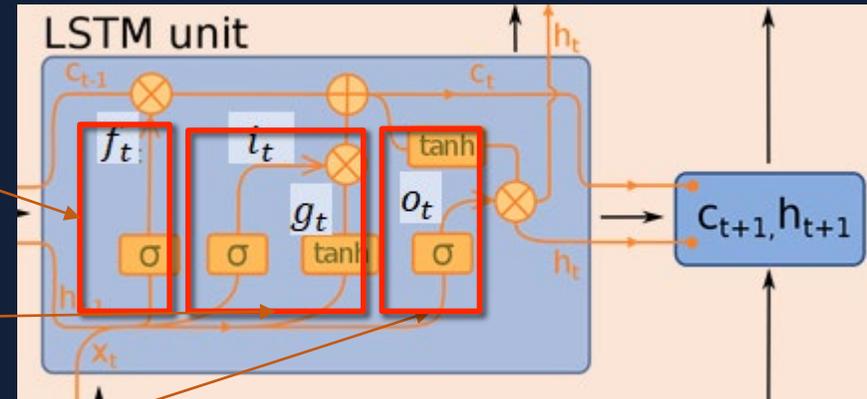


LSTM : Long Short Term Memory

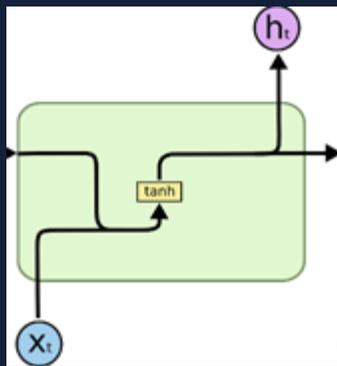
Forget Gate : supprime l'information inutile

Input gate : transmet seulement l'information utile

Output gate : extrait l'information utile



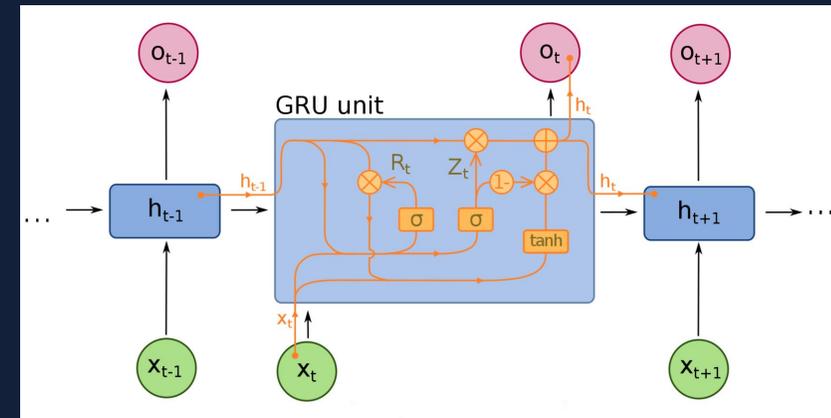
La mémoire d'état est remplacée par 2 mémoires : court terme et long terme.



RNN unit

GRU : Gated Recurrent Unit

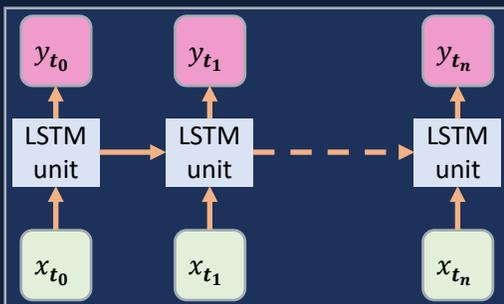
Même approche sans output gate



RNN : applications

Données séquentielles

Many-to-many



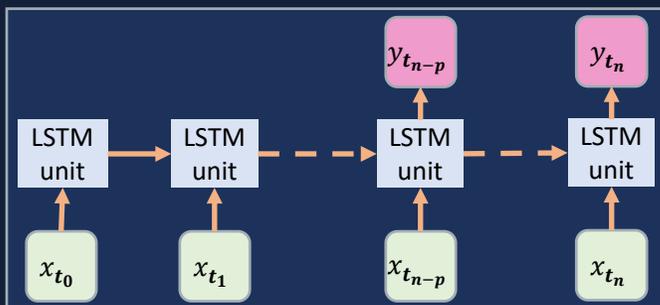
Génération de langage naturel

- Traduction : représentation des structures grammaticales de la langue
- Reconnaissance vocale (discours \rightarrow texte)

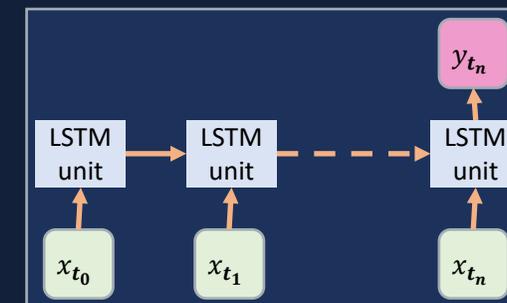
Prévisions sur des séries temporelles

- Processus physiques
- Météorologie
- Audio
- Vidéo (robotique)
- Evolution des prix
- Demande d'électricité
- Trajectoire (piéton, navire, ...)
- Hydrologie, océanographie ...

Many-to-many (encodeur/decodeur)

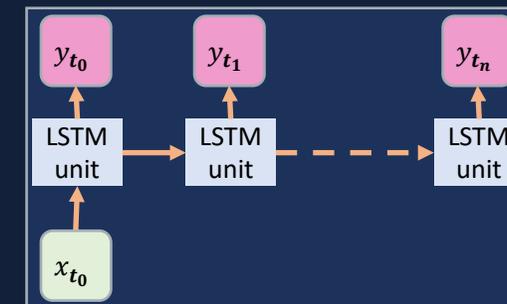


Many-to-one



Ex : analyse de sentiments

One-to-many



Ex : sous-titrage / annotation d'images

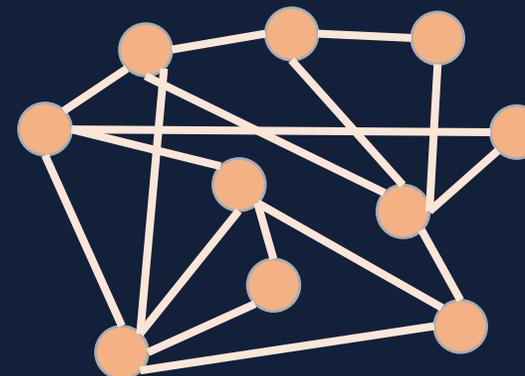
Graph Neural Network (GNN)

Pour les données qui peuvent être représentées sous forme de graphe

- Peut résoudre des problèmes complexes
- **MPNN** : Message Passing Neural Network
 - basé sur la propagation des messages pour mettre à jour chaque état de nœud
 - sortie : état final du nœud

Applications

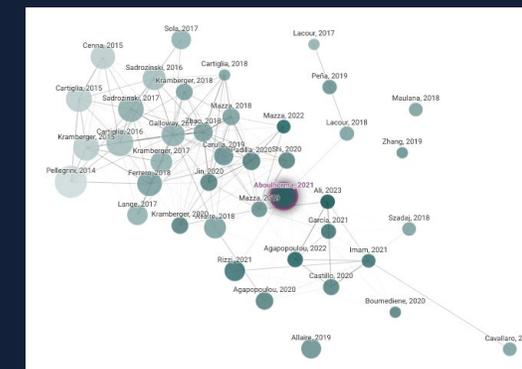
- Classification des nœuds : étiquette de prédiction pour chaque nœud (semi-supervisé)
Ex : citations, vidéo youtube, relations d'amis (FB)
- Prédiction de lien : prédire la relation entre les nœuds
Ex : prédire l'intérêt de l'utilisateur pour les nouveaux produits
- Classification de graphes
Ex : classification de structures moléculaires



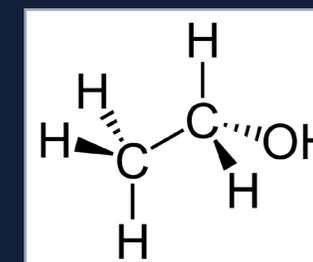
Graphe : nœuds et liens



Réseau social



Papiers scientifiques

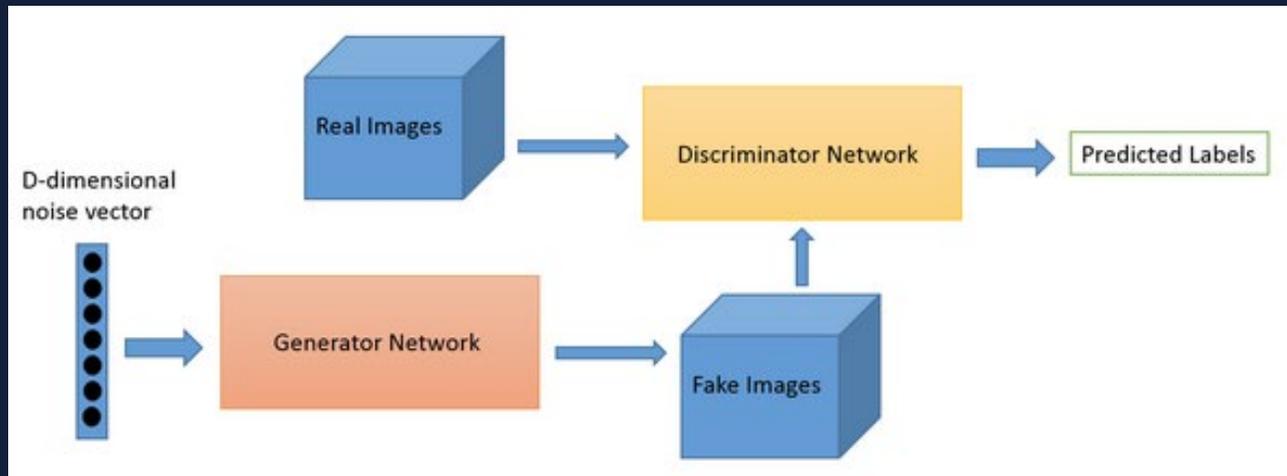


Molécules

Generative Adversarial Network (GAN)

Génération de données à partir de bruit

- Utilise 2 réseaux:
 - Générateur : crée des données à partir de bruit
 - Discriminateur : essaye de distinguer les données générées des vraies données

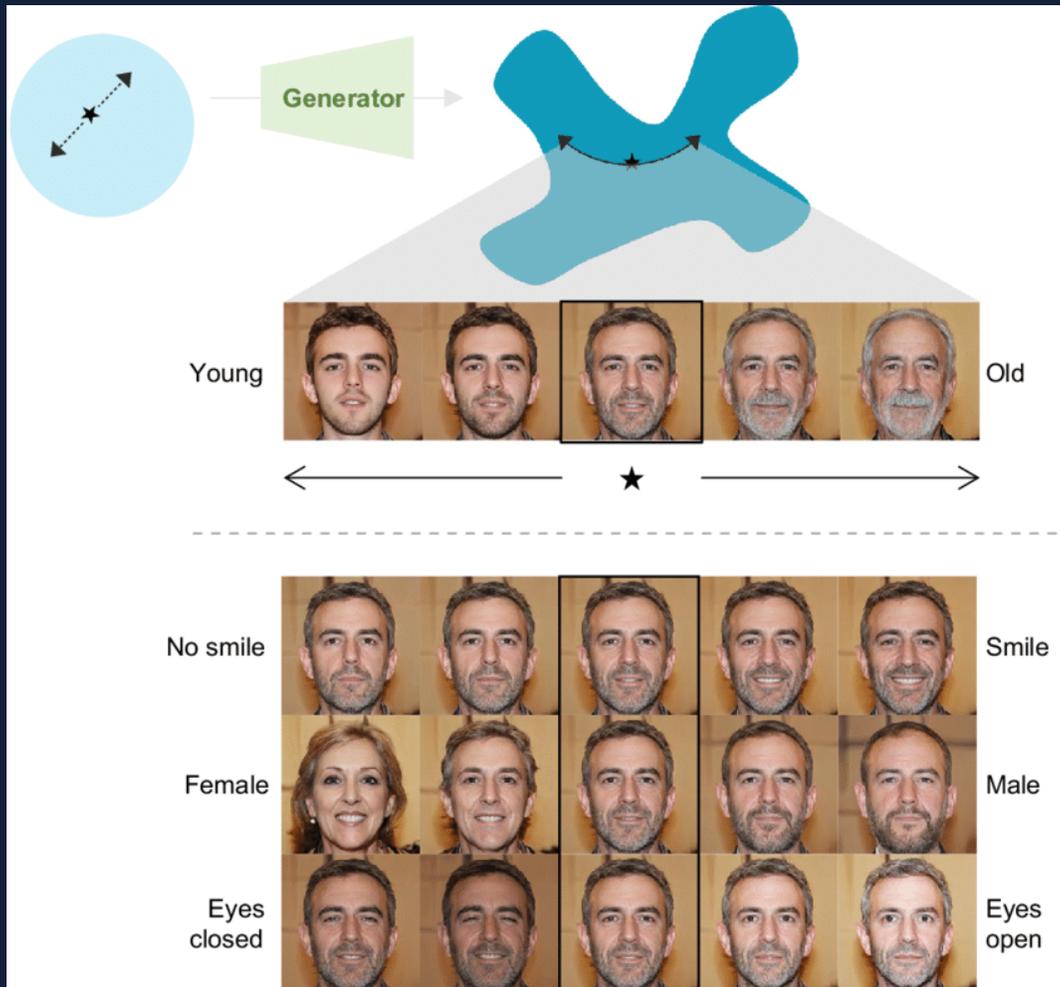


Principe des GAN - Credit: O'Reilly

Génère des données de haute qualité
Difficile à entraîner

GAN : applications

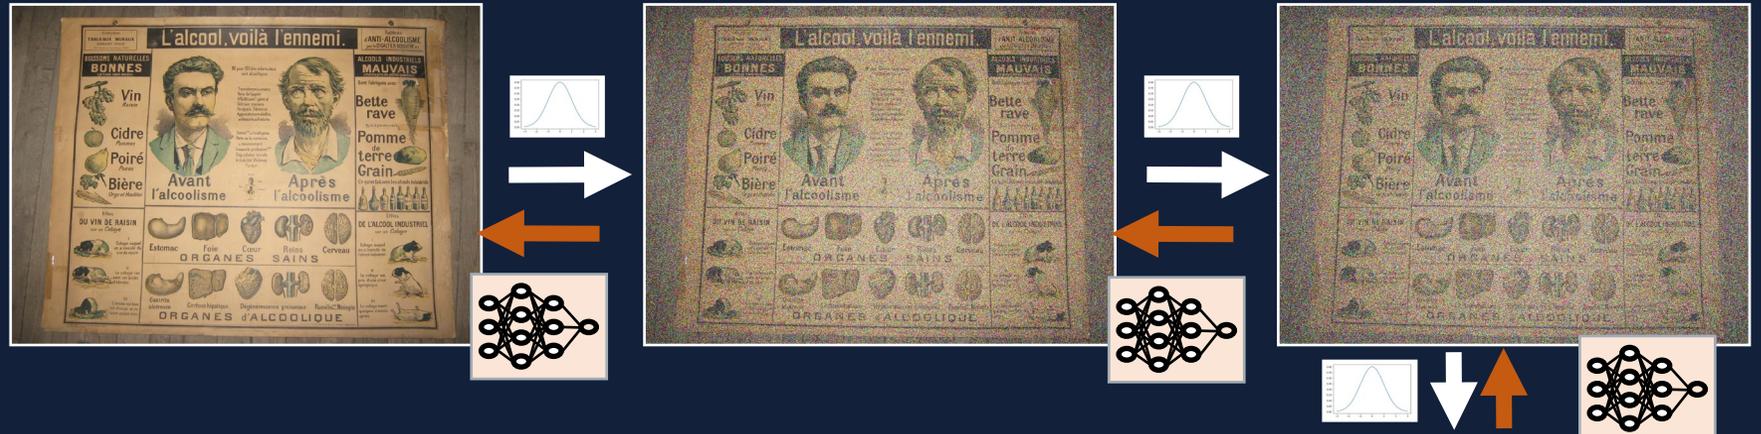
Utilisation : Simulation, génération d'image, image vers image, ...



GAN2.0 (Nvidia, 2018)

Modèle de diffusion

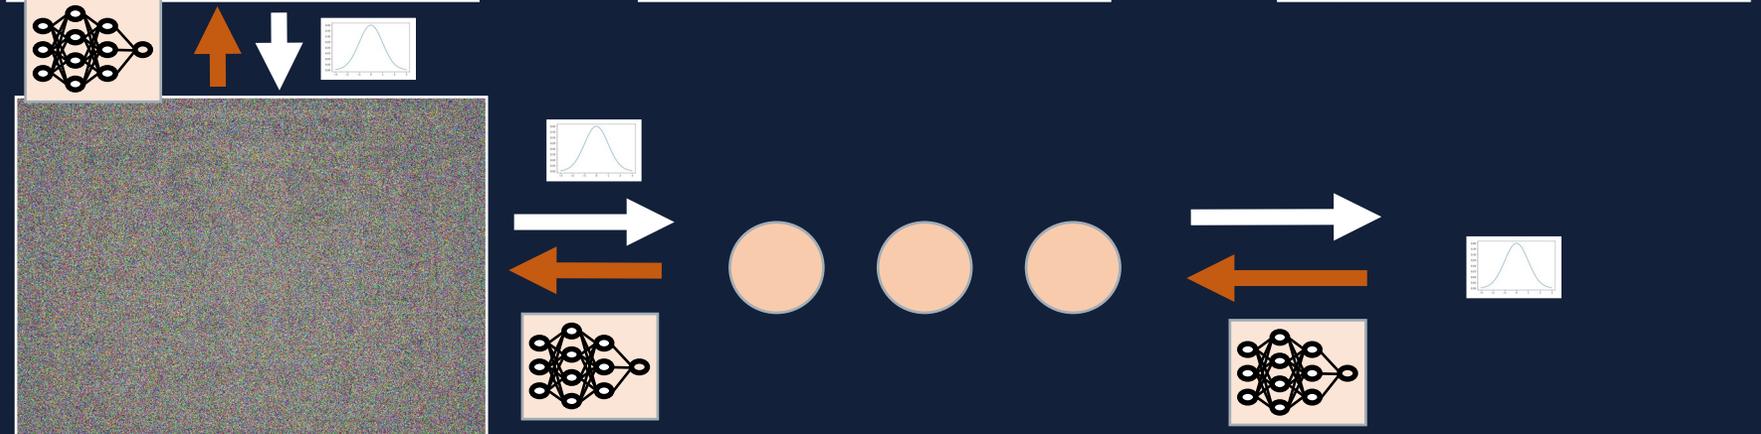
Forward process : ajout successif de bruit gaussien



Reverse process : à chaque étape, le réseau apprend à retirer le bruit



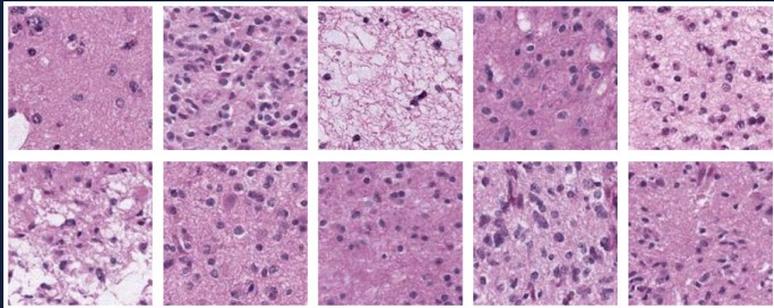
Génération d'images : on démarre avec du bruit ; on peut rajouter des contraintes.



Modèle de diffusion : applications

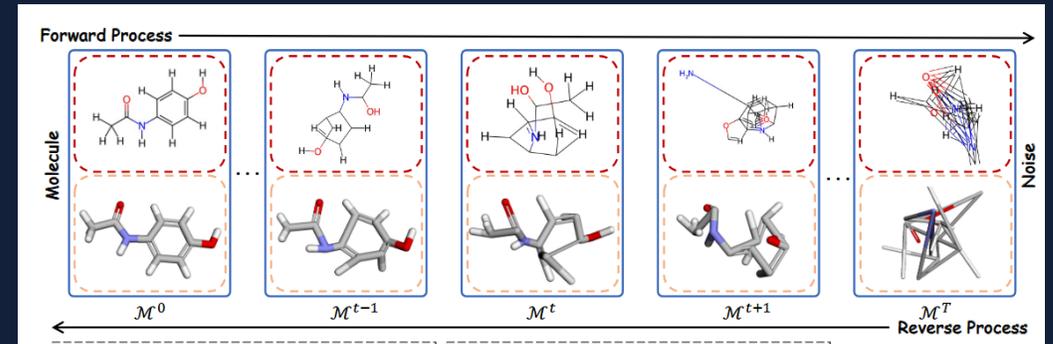
Génération 1D, 2D

Génération d'images histologiques

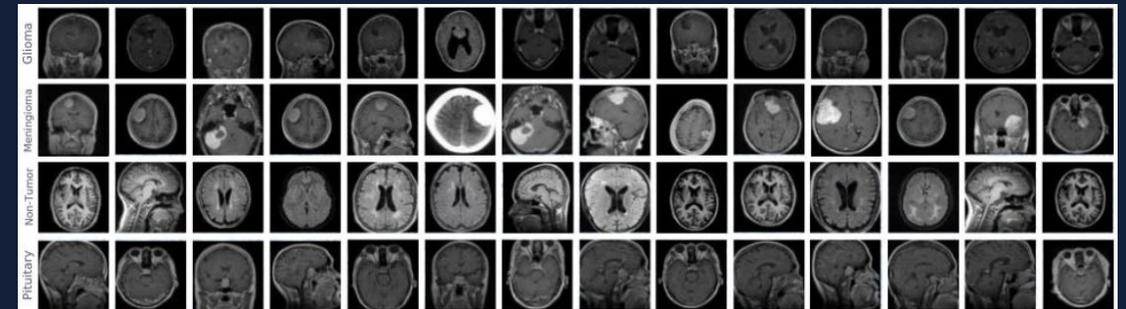


A morphology focused diffusion probabilistic model for synthesis of histopathology images ; PA Moghadam et al. ; Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision, 2023

Génération de molécules



Diffusion Models for Molecules: A Survey of Methods and Tasks ; L. Wang et al. ; 2025 ; arXiv 2502.09511v1



Diffusion-based approaches in medical images generation and analysis ; A. Nafi et al. ; 2024 ; arXiv2412.16860v1

Conclusion : quelques questions liées à l'IA

✓ **Interprétabilité**

Compréhension des décisions prises par les modèles de DL, cruciale pour les applications critiques, par exemple médicales, certains processus en recherche

✓ **Reproductibilité**

Obtention des mêmes résultats par d'autres chercheurs en utilisant les mêmes données et méthodes

✓ **Questions de société**

Quelle influence sur l'humain ? Rapport de l'humain à l'IA et aux robots ? L'empathie artificielle ? (Affaire Blake Lemoine, chatbot)

✓ **Questions éthiques**

Utilisation responsable des technologies, prévention des biais, protection de la confidentialité des données, transparence dans les applications critiques, IA et robotique, usage militaire, sécurité, vie privée...

✓ **Questions de gouvernance**

Encadrement par les pouvoirs publics, EU AI Act (03/24)

✓ **Questions de droit d'auteur**

Données utilisées pour l'entraînement ?

✓ **Questions de responsabilité**

✓ **Sobriété énergétique**