

Principe et Applications du Machine Learning

 **Corentin Allaire**

Remerciement à **David Rousseau** et **Françoise Bouvet** pour une partie des figures

Une question de nomenclature



SVN: Support Vector Machine

CNN: Convolution NN

RNN: Recurrent NN

À quoi s'attendre


Machine Learning :

- Concepts fondamentaux de « L'IA »
- Les différentes techniques de Machine Learning :
 - Supervisé
 - Non-supervisé
- Application à la recherche du boson de Higgs

Deep Learning :

- Brève histoire du réseau de neurones
- Les différentes techniques de Deep Learning :
 - Perceptron multi-couche
 - Le réseau de convolution
 - Réseaux à base de graphe
- Application à la reconstruction d'objet en physique des hautes énergies

Une question de nomenclature



SVN: Support Vector Machine


CNN: Convolution NN

RNN: Recurrent NN

Maintenant

Le Machine Learning, qu'est ce que c'est ?

Machine Learning : Extraire de l'information de (grandes quantités de) **données** à l'aide d'un modèle



Différents types d'apprentissage possibles

Apprentissage supervisé :

- On dispose de donnée **étiquetées**
- On souhaite effectuer une **prédiction** sur de nouvelle donnée inconnues

Exemples :

- Classification ←
- Régression
- Classement
- Génération de texte, d'image



Chats



Chiens



?


Différents types d'apprentissage possibles

Apprentissage non supervisé :


- On dispose de données **non-étiquetées**
- On souhaite obtenir de **nouvelles informations** sur ces données

Exemples :


- Clustering
- Réduction de dimension ←
- Détection d'anomalie
- Génération de texte, d'image



t-SNE



Différents types d'apprentissage possibles




La première étape avant d'utiliser le ML est toujours **d'identifier** le type de problème auquel on est confronté pour déterminer quel type **d'algorithme** utiliser


La gestion des données

Le **succès** d'un algorithme de ML repose sur la bonne utilisation de ses données **d'entraînement** et de **test**

Entraînement supervisé : Ne jamais tester un modèle avec les données d'apprentissage



Overfitting : Le modèle apprend **par cœur** les données d'entraînement, mais ne sait pas généraliser



L'évaluation du modèle

Un critère d'évaluation est indispensable pour répondre à la question : **quel est le meilleur modèle ?**

Le critère dépendra du problème :


- **Régression** : Erreur aux moindres carrés
$$\text{MSE}(y, \hat{y}) = \frac{1}{N_{\text{samples}}} \sum_{i=0}^{N_{\text{samples}}-1} (y_i - \hat{y}_i)^2$$
- **Classification** : Précision, Sensibilité, Spécificité, Aire sous la courbe...

Réalité	Prédiction	
	FAUX	VRAI
	FAUX	VRAI
	VN	FP
	FN	VP

$$\text{Precision} = \frac{VP}{VP + FP}$$

$$\text{Sensibilité} = \frac{VP}{VP + FN}$$

$$\text{Spécificité} = \frac{VN}{VN + FP}$$




Quelque exemples : Supervisé

Classification : Arbre de décision

- Outil central de la physique des particules depuis les années 90
- Classifie des objets décrits par N **variables** x_i

Construction de l'arbre :

- **Coupures** successives sur les variables pour maximiser la « pureté » des nœuds suivants
- Répète l'opération jusqu'à atteindre une pureté (ou un nombre de nœuds) cible




Avantages :

- Simple à **interpréter**
- Demande peu de données
- Désavantages :
 - Risque d'overfit
 - Création de l'arbre instable

Quelque exemples : Supervisé


Classification : Arbre de décision



Quelque exemples : Supervisé

Classification : Arbre de décision


Decision tree, depth=1



Quelque exemples : Supervisé

Classification : Arbre de décision


Decision tree, depth=2



Quelque exemples : Supervisé

Classification : Arbre de décision


Decision tree, depth=3



Quelque exemples : Supervisé

Classification : Arbre de décision


Decision tree, depth=4



Quelque exemples : Supervisé

Classification : Arbre de décision


Decision tree, depth=5



Quelque exemples : Supervisé

Classification : Arbre de décision


Decision tree, depth=6



Quelque exemples : Supervisé

Classification : Arbre de décision


Decision tree, depth=8



Quelque exemples : Supervisé

Classification : Arbre de décision


Decision tree, depth=9



Quelque exemples : Supervisé

Classification : **BDT** (boosted decision tree)




- Individuellement, les arbres peuvent **overfit** et sont très **instables**
- Utilise une **série d'arbres** pour optimiser la précision du système
- Solution idéale pour les problèmes à moins de 100 variables



Autre option : entraîner un grand nombre d'arbres et effectuer un **vote**



Application à la recherche du Higgs

- Observation du boson de Higgs : Comparaisons de la **distribution** (histogramme) d'une variable d'intérêt observé au LHC (**signal**) avec sa valeur attendue en absence de Higgs (**bruit de fond**)
- La présence d'un **excès** dénote l'existence d'une nouvelle particule



Choix de la variable d'intérêt

- Option évidente : **masse résonante** de production du **Higgs**
- « Facile » à reconstruire à partir de la cinématique des particules produite
- Nous donne une information sur les **propriétés** de la particule reconstruite



- Autre option : score de classification **BDT** des événements
- Le BDT essaie de séparer Higgs / non Higgs
- Idéale pour les **signatures complexes**
- Tire parti de plus de paramètres de l'événement

Quelques exemples : non supervisé

Reduction de dimension: **t-SNE**

(t-distributed stochastic neighbour embedding)



Extension des algorithmes de SNE :

- Dans **P** : calcule la probabilité que i et j soient choisis comme **voisin** (choix de voisin basé sur une distribution gaussienne) $p_{j|i} = \frac{\exp(-\|x_i - x_j\|^2 / 2\sigma_i^2)}{\sum_{k \neq i} \exp(-\|x_i - x_k\|^2 / 2\sigma_i^2)}$,

Quelques exemples : non supervisé

Reduction de dimension: **t-SNE**

(t-distributed stochastic neighbour embedding)



Extension des algorithmes de SNE :

- Dans **P** : calcule la probabilité que i et j soient choisis comme **voisin** (choix de voisin basé sur une distribution gaussienne)
- Même chose dans **Q**

$$q_{ij} = \frac{(1 + \|y_i - y_j\|^2)^{-1}}{\sum_{k \neq l} (1 + \|y_k - y_l\|^2)^{-1}}$$

Quelques exemples : non supervisé

Reduction de dimension: **t-SNE**

(t-distributed stochastic neighbour embedding)



Extension des algorithmes de SNE :

- Dans **P** : calcule la probabilité que i et j soit choisis comme **voisin** (choix de voisin basé sur une distribution gaussienne)
- Même chose dans **Q**
- Si Q est une bonne représentation de P , alors $\frac{p_{j|i}}{q_{j|i}}$ tends vers 1
- On trouve les positions dans Q par **descente de gradient**

$$C = \sum_i KL(P_i || Q_i) = \sum_i \sum_j p_{j|i} \log \frac{p_{j|i}}{q_{j|i}}$$

Quelques exemples : non supervisé

Exemple avec des chiffres





Image 8*8 = 64D




t-SNE


2D plot

t-SNE pour l'explicabilité des réseaux de neurones

- Les **réseaux de neurones** (cf demain) sont aussi utilisés pour la classification des **particules**
- Beaucoup plus complexe (projection en dimension > 100)
- L'utilisation d'algorithme de **t-SNE** nous permet de « **visualiser** » partiellement le fonctionnement de notre algorithme
- Visualisation de l'**encodage** de jet de particules en fonction de leurs sources




Pourquoi utiliser du ML ?



- Principalement des **BDT** à **~10 variables**
- En moyenne, l'utilisation de BTD nous permet d'atteindre des **sensibilités** à l'existence du Higgs **~50%** plus élevés
- Maximisation de notre usage du LHC

Une question de nomenclature




SVN: Support Vector Machine

CNN: Convolution NN

RNN: Recurrent NN


Maintenant

Une brève histoire du Deep Learning




Le neurone formel

Idée : Crée une construction mathématique qui « simule » les **neurones biologiques**







1943 : McCulloch & Pitts





- Retourne uniquement des entrée **booléennes** (0,1)
- Assemblage de neurone : **Turing complets**

Le neurone formel : généralisation




- Nombre d'entrées arbitraire
- Addition d'une constante par neurone : w_0
- **Fonction d'activation** appliquée au résultat du neurone : différents intervalles de valeur possible

Le neurone formel : approximateur universel




- Toute fonction mathématique réelle peut être **approximée** comme une **somme de fonction Relu** translaté
- Les réseaux de neurones peuvent naturellement remplir ce rôle

Le neurone formel : approximateur universel




- Toute fonction mathématique réelle peut être **approximée** comme une **somme de fonction Relu** translaté
- Les réseaux de neurones peuvent naturellement remplir ce rôle

Le neurone formel : approximateur universel




- Toute fonction mathématique réelle peut être **approximée** comme une **somme de fonction Relu** translaté
- Les réseaux de neurones peuvent naturellement remplir ce rôle

Le neurone formel : approximateur universel




- Toute fonction mathématique réelle peut être **approximée** comme une **somme de fonction Relu** translaté
- Les réseaux de neurones peuvent naturellement remplir ce rôle

Le neurone formel : approximateur universel




- Toute fonction mathématique réelle peut être **approximée** comme une **somme de fonction Relu** translaté
- Les réseaux de neurones peuvent naturellement remplir ce rôle

Le neurone formel : approximateur universel




- Toute fonction mathématique réelle peut être **approximée** comme une **somme de fonction Relu** translaté
- Les réseaux de neurones peuvent naturellement remplir ce rôle

Le neurone formel : approximateur universel




- Toute fonction mathématique réelle peut être **approximée** comme une **somme de fonction Relu** translaté
- Les réseaux de neurones peuvent naturellement remplir ce rôle

Le neurone formel : approximateur universel




- Toute fonction mathématique réelle peut être **approximée** comme une **somme de fonction Relu** translaté
- Les réseaux de neurones peuvent naturellement remplir ce rôle

Le neurone formel : approximateur universel




- Toute fonction mathématique réelle peut être **approximée** comme une **somme de fonction ReLU** translaté
- Les réseaux de neurones peuvent naturellement remplir ce rôle

Le neurone formel : approximateur universel




- Toute fonction mathématique réelle peut être **approximée** comme une **somme de fonction Relu** translaté
- Les réseaux de neurones peuvent naturellement remplir ce rôle

Le neurone formel : approximateur universel




- Toute fonction mathématique réelle peut être **approximée** comme une **somme de fonction Relu** translaté
- Les réseaux de neurones peuvent naturellement remplir ce rôle

Le neurone formel : approximateur universel




- Toute fonction mathématique réelle peut être **approximée** comme une **somme de fonction Relu** translaté
- Les réseaux de neurones peuvent naturellement remplir ce rôle

Le neurone formel : approximateur universel




- Toute fonction mathématique réelle peut être **approximée** comme une **somme de fonction Relu** translaté
- Les réseaux de neurones peuvent naturellement remplir ce rôle

Le neurone formel : approximateur universel




- Toute fonction mathématique réelle peut être **approximée** comme une **somme de fonction Relu** translaté
- Les réseaux de neurones peuvent naturellement remplir ce rôle

Perceptron multicouche (MLP)




- Neurones assemblés ensemble pour **approximer** une fonction inconnue
- Taille des couches cachées et profondeur (nombre de couches) au choix du développeur


Perceptron multicouche : exemple



- Example Chat/Chien
- x_i : pixel de mon image
- y_1 : 0 ➡ pas chat; 1 ➡ chat
- y_2 : 0 ➡ pas chien; 1 ➡ chien




(0.85, 0.1)
Clairement Chat




(0.35, 0.78)
Plutôt chien

Perceptron multicouche : mathématiquement



Perceptron multicouche : Example




En notation matriciel :

$$\begin{pmatrix} 3 & 3 & 5 \\ 9 & 4 & 1 \end{pmatrix} \begin{pmatrix} 1 \\ 2 \\ -2 \end{pmatrix} = \begin{pmatrix} -1 \\ 3 \end{pmatrix}$$

$$f \begin{pmatrix} -1 \\ 3 \end{pmatrix} = \begin{pmatrix} 0.73 \\ 0.95 \end{pmatrix}$$

$$(1 \quad 2 \quad -1) \begin{pmatrix} 1 \\ 0.73 \\ 0.95 \end{pmatrix} = 1.51$$

Rétropropagation du gradient



- Nombre de **paramètres** : $(n + 1) \times p + (p + 1) \times q + (q + 1) \times 2$
- Si $n = p = q = 10 \Rightarrow 242$ paramètre à optimiser
- Comment effectuer cette **optimisation** de manière efficace ?

Rétropropagation du gradient


Fonction de coût pour évaluer les performances de notre algorithme (**adapté** à l'objectif) :

$$Loss(y, \hat{y}) = \frac{1}{2} \sum_{i=0}^N (\hat{y}_i - y_i)^2$$

Algorithme de **rétropropagation** :

- Calcule $\frac{\partial Loss(y, \hat{y})}{\partial w_{ji}}$
- Mise à jour des poids : $w_{ji} \leftarrow w_{ji} - \alpha \frac{\partial Loss(y, \hat{y})}{\partial w_{ji}}$


avec α le **taux d'apprentissage**
(peut évoluer au cours du temps)



Rétropropagation du gradient

Dernière (P) couche :

$$\frac{\partial Loss}{\partial w_{12}^{[2]}} = \frac{\partial Loss}{\partial s_1^3} \frac{\partial s_1^3}{\partial w_{12}^{[2]}}$$




Rétropropagation du gradient

Dernière (P) couche :

$$\frac{\partial Loss}{\partial w_{12}^{[2]}} = \frac{\partial Loss}{\partial s_1^3} \frac{\partial s_1^3}{\partial w_{12}^{[2]}}$$

$\delta_1 = (\hat{y}_1 - y_1)$
 $x_2^{[2]}$

$$w_{12}^{[2]} = w_{12}^{[2]} - \alpha \delta_1 x_2^{[2]}$$




Rétropropagation du gradient

Dernière (P) couche :

$$\frac{\partial Loss}{\partial w_{12}^{[2]}} = \frac{\partial Loss}{\partial s_1^3} \frac{\partial s_1^3}{\partial w_{12}^{[2]}}$$

$\delta_1 = (\hat{y}_1 - y_1)$
 $x_2^{[2]}$

$$w_{12}^{[2]} = w_{12}^{[2]} - \alpha \delta_1 x_2^{[2]}$$



Couche P-1 :

$$\frac{\partial Loss}{\partial w_{21}^{[1]}} = \frac{\partial Loss}{\partial s_2^{[2]}} \frac{\partial s_2^{[2]}}{\partial w_{21}^{[1]}}$$

$\delta_2 = (\hat{y}_2 - y_2)$
 $x_1^{[1]}$

$$\frac{\partial Loss}{\partial s_2^{[2]}} = \sum_k \delta_k \frac{\partial \delta_k}{\partial s_2^{[2]}}$$


Rétropropagation du gradient

Dernière (P) couche :

$$\frac{\partial Loss}{\partial w_{12}^{[2]}} = \frac{\partial Loss}{\partial s_1^3} \frac{\partial s_1^3}{\partial w_{12}^{[2]}}$$

$\delta_1 = (\hat{y}_1 - y_1)$
 $x_2^{[2]}$

$$w_{12}^{[2]} = w_{12}^{[2]} - \alpha \delta_1 x_2^{[2]}$$



$$Loss(y, \hat{y}) = \frac{1}{2} \sum_k (\hat{y}_i - y_i)^2$$

Au moins dérivable par morceaux

Couche P-1 :

$$\frac{\partial Loss}{\partial w_{21}^{[1]}} = \frac{\partial Loss}{\partial s_2^{[2]}} \frac{\partial s_2^{[2]}}{\partial w_{21}^{[1]}}$$

$$\frac{\partial Loss}{\partial s_2^{[2]}} = \sum_k \delta_k \frac{\partial \delta_k}{\partial s_2^{[2]}}$$

$x_1^{[1]}$

$$\frac{\partial \delta_k}{\partial s_2^{[2]}} = w_{k2}^{[2]} f'(s_2^{[2]}) \quad \frac{\partial Loss}{\partial s_2^{[2]}} = f'(s_2^{[2]}) \sum_k \delta_k w_{k2}^{[2]}$$

$$\frac{\partial Loss}{\partial w_{21}^{[1]}} = x_1^{[1]} f'(s_2^{[2]}) \sum_k \delta_k w_{k2}^{[2]}$$

Rétropropagation du gradient

Si vous vous ennuyez cet été essayez de calculer P-2 !

$$(g \circ f)' = (g' \circ f) \times f'$$

Plus **généralement**, on peut ensuite montrer que :

$$\frac{\partial Loss}{\partial w_{ji}^{[p-1]}} = x_i^{[p-1]} f'(s_j^{[p]}) \sum_k \frac{\partial Loss}{\partial s_k^{[p]}} w_{kj}^{[p]}$$

 **Précédent Gradient !**

Grâce à cette formule on peut facilement calculer **de proche en proche** la dérivée de chaque poids pour mettre à jour le réseau sans difficulté !


Les réseaux de convolution (CNN)

MLP : Peu adapté aux images

- Le nombre paramètre augmente très vite avec la taille de l'entrée
- Pas **d'invariance** par translation/rotation


Utilisation de filtre de convolution :

- Boucle sur tous les pixels et calcule une nouvelle valeur basée sur les voisins
- Les **poids** du filtre sont **optimisés** à l'entraînement
- La taille du filtre est au choix du développeur
- Essaie de capturer les **traits caractéristiques** de l'image
- Peut remplacer les MLP dans un grand nombre de réseaux



Les réseaux de convolution



Illustration de l'effet des filtres :



AlexNet, 2012

ImageNet Visual Recognition Challenge :

- $\sim 10^6$ images et ~ 1000 catégories
- 2 avancées majeures :
 - AlexNet (2012)
 - GoogleNet (2014)




Classification des événements dans l'expérience Nova


Nova :

- Détecteur de neutrinos
- Basé à **Fermilab** (US)
- Étudie l'oscillation des **neutrinos**
- Mesure la désintégration de neutrino dans son détecteur


3D schematic of NOvA particle detector



View from the top






View from the side



Classification des événements dans l'expérience Nova

Utilisation de CNN pour la **classification** des événements :


- Inspiré par GoogleNet
- Difficulté : 2 images par input
- Utilisé dans des papiers avec des résultats de physique : [1703.03328](#) et [1706.04592](#)



A Convolutional Neural Network Neutrino Event Classifier

Les Réseaux Antagonistes Génératifs (GAN)


- Technique **générative** : crée des données/images à partir de bruit
- Utilise deux réseaux de neurones :
 - **Générateur** : génère des données à partir de bruit
 - **Discriminateur** : sépare le bruit des données cibles



Les Réseaux Antagonistes Génératifs (GAN)

Même fonction de coût pour le discriminateur et le générateur :


- Le discriminateur essaie de **séparer** les vraies entrées des entrées simulées
- Le générateur essaie de **tromper** le discriminateur



Les Réseaux Antagonistes Génératifs (GAN)




Simulation des événements dans ATLAS/CMS



Simulateurs :




- Combine une connaissance précise de la physique pour prendre en compte l'interaction particules/matière (**Geant4**)
- Simulation **extrêmement précise** de nos détecteurs

- Demande beaucoup de **ressources** :
 - Humaine (optimisation de la simulation, étalonnage...)
 - CPU (50% de nos ressources de calcul vont dans la simulation)



Simulation de calorimètre à l'aide de GAN

- **Calorimètre** : détecte l'énergie des particules
- **Cascades** de particules à l'intérieur
- Simulation du dépôt d'énergie de ces cascades avec un **GAN**
- Résultat réaliste obtenu **100x** plus rapidement



[Deep generative models for fast shower simulation in ATLAS](#)

Conclusion


- Deep learning = Machine learning avec des réseaux de neurones
- Capable d'apprendre très efficacement de nos données
- Très grande variété d'algorithmes de machine learning ➡ adapter nos algorithmes à nos problèmes
- De plus en plus omniprésente en physique pour les tâches de reconstruction d'objets, de simulation...

Pour aller plus loin


Graph Neural Network

Objectif : adapter la **structure** de notre réseau à la structure de nos données.

Grand nombre de structures représentable par des **graphes**



Molécule



Publication scientifique



Email communication




Relation sociale


Graph Neural Network

Objectif : adapter la **structure** de notre réseau à la structure de nos données.

Grand nombre
de structures
représentable
par des **graphes**



Molécule



Publication scientifique




Email communication



Relation sociale

Graph Neural Network




Graphe : 3 type d'info : **Noeuds**, **arêtes** et **globale**



Graph Neural Network


Graphe : 3 type d'info : **Noeuds**, **arêtes** et **globale**

Application d'un NN à ces variables :




Graph Neural Network : Message Passing

Transfert d'information
entre les éléments du
graph avec une **fonction
d'agrégation** :



Différentes méthodes de transfert
d'information sont possibles




Graph Neural Network : Classification

Utilisation d'un dernier NN pour la classification des Noeuds, des arêtes ou du graph




Exemples (*publications*) :

- Noeuds : Quelle catégorie de noeuds ?
(*laboratoires*)
- Arêtes : Quel lien entre noeuds ?
(*relations professionnelles*)
- Graph : Quel type de graph/structure ?
(*stratégie de publication*)



Trajectographie des particules chargées



- Particules chargées : **dépôt d'énergie** dans le détecteur (coups)
- **Trajectographie** : connecter ensemble ces coups pour reconstruire une trajectoire



- Très complexe : beaucoup de **combinatoire** (~ 100 000 coups par collision)
- Algorithme très complexe : **Filtres de Kalman**
- Très fort coût CPU

GNN4ITk : Trajectographie avec un GNN

- Appliqué au futur **trajectographe** d'ATLAS (ITk)
- **Coups = Noeuds**
- Connexion entre coups = arrêtes
- **Classification** d'arête : bonnes arêtes ➡ trajectoire d'une particule
- Performance compatible avec les algorithmes classique



[Physics Performance of the ATLAS GNN4ITk Track Reconstruction Chain](#)