
Premiers pas pour l'utilisation de l'IA scientifique


 **Corentin Allaire**
David Rousseau
Françoise Bouvet

Pourquoi utiliser du Deep Learning ?


[Nature 560, 41–48 \(2018\)](#)

- Outil informatique/statistique nous permettant de maximiser l'usage de nos données scientifiques

➡ Au LHC, IA ~ **50% de data en plus** pour nos analyses



[CaloChallenge 2022](#)



- Optimisation de notre consommation en ressource de calcul

➡ CaloChallenge 2022 : simulation de calorimètre. **~10 000 fois moins coûteux** que Geant4

Intensifier son problème

- Pas de magie !
- Les réseaux de neurones: résolvent le **problème** sur lequel ils sont optimisés et uniquement dans le **contexte** où ils sont entraînés
- Objectifs ?
 - **Classifier** des objets ?
 - **Reconstruire** des quantités physiques ?
 - **Générer** de nouveaux objets ? (simulation)
- Pourquoi veut-on utiliser de l'IA ?
 - Algorithme actuel trop peu performant ?
 - Algorithme actuel trop lent ? Utilisation de ressources hétérogènes ?
 - Question insoluble numériquement ?

Intensifier son problème

- Comment déterminer si notre nouvel algorithme est bon ?
- Bien séparer les notions de **fonction de coût / loss** de la notion de **métrique** de performance

Loss :

- Sert à l'optimisation du réseau
- Tend vers 0 quand le réseau fonctionne mieux
- Doit être différentiable

Métrique :

- Sert à l'évaluation des performances du réseau
- Peut être aussi complexe que nécessaire :
 - Efficacité de reconstruction
 - Vitesse de calcul
 - Faux-positif, faux-négatif, AUC...

	Fonction d'activation (dernière couche)	Fonction de coût
Régression (quantitatif)	Linéaire	Mean squared error $c(y, \hat{y}) = \frac{1}{2} \sum_{i=1}^N (\hat{y}_i - y_i)^2$
Classification à 2 classes (régression logistique)	Sigmoïde	Cross-entropy $ce(y, \hat{y}) = ((y == 1) ? -\log(\hat{y}) : -\log(1 - \hat{y}))$
Classification multi-classes	Soft-max (probabilité)	Cross-entropy (categorical_crossentropy)

Comprendre ses données

- Pour apprendre les réseaux ont besoin de **données représentatives étiquetées**
- Quelle quantité est disponible ? Quelle est la qualité de l'étiquetage ?
- Est-il possible de **simuler des données réalistes** ?
Si oui, l'entraînement est beaucoup plus facile.
- Le type de donnée influe grandement sur le type d'algorithme:
 - Image → Réseau de convolution
 - Données tabulaire → Perceptron multi-couche (MLP)
 - Séquence → LSTM (réseau récurrent)
 - Données non ordonnées / Graph → GNN, Transformer

Quel Hardware pour l'IA ?

- Deux types de **hardware** à considérer : entraînement / inférence

Entraînement :

- Ordinateur portable pour petit algorithme (BDT, petit réseau de neurones)
- *Data center* local sur GPU:
 - [Ruche](#) (Paris-Saclay)
 - [Jean Zay](#) (IDRIS)
 - Centre de calcul des expériences (Grille...)

Inférence :

- Dépend énormément de l'objectif : analyse, acquisition...
- CPU même si entraîné sur GPU
- Peuvent être déployés « *online* » dans les expériences sur FPGA
- Taille de réseau à adapter au support d'inférence

Bibliothèque d'IA : Ne pas réinventer la roue

- Pour le machine learning en Python : [scikit-learn](#)
- Tout les outils nécessaires pour le ML (pas/peu de DL)
- Bibliothèque spécifique dans les autres langages (penser à regarder si elles sont **maintenues**)



 PyTorch



- Pour le Deep Learning : [Pytorch](#) et [Tensorflow](#)
- Utilisation simplifiée de l'un ou l'autre : [Keras](#)
- Les « **briques** » de la plupart des réseaux sont disponibles

Example : réseau de neurones avec Keras

```
from keras.models import Sequential
from keras.layers import Input, Dense, Normalization


layer_norm = Normalization()
layer_norm.adapt(x_train)

model = Sequential()
model.add(Input(np.shape(x_train)[1:], ))
model.add(layer_norm)
model.add(Dense(128, activation='relu'))
model.add(Dense(128, activation='relu'))
model.add(Dense(1, activation='sigmoid'))

model.compile(optimizer='sgd',
              loss='binary_crossentropy',
              metrics=['accuracy', 'AUC'])

model.summary()
```

Transfert learning et modèle de fondation




- Certains réseaux doivent apprendre 2 choses :
- **Extraire** des *features* de l'entrée
- **Calculer** une quantité avec ces *features*
- Typiquement : Images
- Réutilisation de réseaux déjà entraînés sur des images

- **Modèle de fondation** : même idée pour domaines spécifiques
- Entraînement sur des données du détecteur ATLAS utilisé pour différentes analyses/reconstructions d'objets

Bonne pratique d'entraînement

- Bien séparer ses données **d'entraînement**, de **validation** et de **test**.
- Attention aux corrélations !



- **Normalisation**

1. $X = \{x^m\}, m \in \{1, M\}, x^m \in R^N$

2. $\mu_i = \frac{1}{M} \sum_{m=1}^M x_i^m$


3. $\sigma_i^2 = \frac{1}{M} \sum_{m=1}^M (x_i^m - \mu_i)^2$

4. $x_i^m \leftarrow \frac{x_i^m - \mu_i}{\sigma_i}$

blue $\rightarrow \begin{pmatrix} 1 \\ 0 \\ 0 \end{pmatrix}$; green $\rightarrow \begin{pmatrix} 0 \\ 1 \\ 0 \end{pmatrix}$; red $\rightarrow \begin{pmatrix} 0 \\ 0 \\ 1 \end{pmatrix}$

- Bien préparer ses données:
- Normalisation
- Encodage des classes

- Suivre l'évolution de sa **courbe d'entraînement**
- Outil utile : **Tensorboard**



Déploiement de son réseau

- Une fois le réseau entraîné, les poids peuvent être **sauvegardés** sous forme de fichier (souvent de très petite taille)
- Ces fichiers vont vous permettre de réutiliser le modèle sur vos futurs données
- Deux déploiements possible :
 - Dans un **script Python**, en utilisant la bibliothèque d'entraînement: le réseau est chargé et utilisé
 - Dans un autre langage : utilisation d'un **moteur d'inférence**
- [onnxruntime](#) : Inférence d'un modèle déjà entraîné depuis la plupart des langages de programmation
- Nécessite juste d'écrire une l'interface et de fournir les fichiers de poids

