


# Entraîner, évaluer et tester une Intelligence Artificielle fiable

Atelier technique

Sarah LEROY | Ingénieure développement et test de l'IA  
Clément FRANCOIS | Ingénieur d'études et test IA  
Avec le support de Anne-Laure WOZNIAK  
13/06/2023





## NOS FORMATIONS



## NOS LABELLISATIONS



## ■ Introduction

- Qu'est-ce que l'IA ?
- Etapes d'un projet de Machine Learning
- Différences entre le test logiciel et le test de l'IA

## ■ Evaluer un modèle IA

- Différences entre l'évaluation et le test
- Métriques d'évaluation

## ■ Live Coding : Données, entraînement et évaluation

- Préparation des données
- Entraînement d'un réseau de neurones
- Evaluation du modèle

## ■ Tester un modèle IA

- Importance & défis du test de l'IA

## ○ Propriétés des modèles de ML

- Qualité des données
- Ethique & équité
- Explicabilité
- Robustesse

## ■ Live Coding : Test

- Robustesse
- Explicabilité
- Ethique

- Qu'est-ce que l'IA ?
- Etapes d'un projet de Machine Learning
- Différences entre le test logiciel et le test de l'IA

# Introduction

« Possibilité pour une machine de **reproduire des comportements liés aux humains**, tels que le **raisonnement**, la **planification** et la **créativité**. »

*Parlement européen*

« Capacité d'un système technique à **acquérir, traiter et appliquer des connaissances et des compétences**. »

*ISO/IEC TR 29119-11:2020*



## **Narrow AI** **(ou IA étroite, IA faible)**

Système programmé pour effectuer une tâche spécifique, dans un contexte limité.

Système qui possède des **capacités cognitives générales, similaires à celles des humains.**

Quid de la **créativité** ?

- > Générateur d'images
- > Robot conversationnel

AW Is ChatGT creative ?

 ChatGPT is a language model that can generate text based on the input it is given. It can generate creative text, but it is not creative in the sense that it does not have its own ideas or original thoughts. It can only generate text based on the patterns and information it has been trained on.

Source : [2]



Alone astronaut on Mars, mysterious, colorful, hyper realistic




Pyramid shaped mountain above a still lake, covered with snow

Source : [3]


**Machine Learning (ML)** : apprentissage automatique

**Deep Learning (DL)** : apprentissage profond



## Apprentissage supervisé


Tâches réalisées : classification, régression



Source : [5]

## Apprentissage non-supervisé


Tâches réalisées : association, regroupement (clustering)




Source : [5]

## Apprentissage par renforcement

Tâches réalisées : interactions avec l'environnement, prise de décision



Source : [5]



Source : [6]

« **Processus** utilisant des techniques informatiques pour permettre aux systèmes **d'apprendre à partir de données ou d'expériences** »

ISO/IEC TR 29119-11

## LES 7 ÉTAPES DU MACHINE LEARNING



**Algorithme (d'apprentissage)** : programme qui produit un modèle ML à partir d'un ensemble de données d'apprentissage.

**Modèle** : sortie du processus d'apprentissage, objet informatique qui associe des données d'entrée à une sortie.

**Hyperparamètre** : paramètre utilisé pour contrôler l'apprentissage d'un modèle ML ou pour définir sa configuration, son architecture.

## LES 7 ÉTAPES DU MACHINE LEARNING



### Collecte et préparation des données

Activités d'acquisition des données, de prétraitement des données et d'ingénierie des caractéristiques.

Activités de **nettoyage**, de **transformation**, d'**augmentation** et d'échantillonnage des données.

Activité d'**identification des attributs** des données brutes les plus pertinents.

**Séparation des données** en trois sous-ensembles : données d'entraînement, données de validation et données de test.



## LES 7 ÉTAPES DU MACHINE LEARNING



### Entraînement


Processus d'**application de l'algorithme ML** à l'ensemble de données d'apprentissage pour créer un modèle ML.

### Evaluation

Processus de **comparaison des mesures de performance** aux critères requis et/ou à ceux d'autres modèles.


### Ajustement

Processus permettant de **déterminer les hyperparamètres optimaux** en fonction d'objectifs de performances.



Restreint


- > Le comportement du système n'est **pas programmé explicitement**
- > La logique du programme est **déterminée par les données d'entraînement**
- > Les processus d'entraînement sont **stochastiques**



- Différences entre l'évaluation et le test
- Métriques d'évaluation

Evaluer un modèle

## LES 7 ÉTAPES DU MACHINE LEARNING



Source : [8]

### Test ou évaluation ?

**L'évaluation du modèle** couvre l'ensemble des métriques et graphiques qui résument la performance sur un jeu de données de validation ou de test.

**Le test du modèle** implique des vérifications explicites du comportement attendu de la part du modèle.

Modèles de classification supervisés :

> Matrice de confusion

		Réel	
		Positif	Négatif
Prédit	Positif	VP	FP
	Négatif	FN	VN


> Accuracy

$$\frac{VP + VN}{VP + VN + FP + FN}$$

> Precision :  $\frac{VP}{VP + FP}$

> Rappel (Recall) :  $\frac{VP}{VP + FN}$

> Score F1 :  $2 * \frac{Precision * Rappel}{Précision + Rappel}$



How many selected items are relevant?

Precision =  $\frac{\text{true positives}}{\text{true positives} + \text{false positives}}$


How many relevant items are selected?

Recall =  $\frac{\text{true positives}}{\text{true positives} + \text{false negatives}}$


Source : [9]

Modèles de classification supervisés :

> Courbe precision recall




> Courbe ROC




$$TFP = \frac{FP}{FP + VN}$$

$$TVP = \frac{VP}{VP + FN} = \text{Rappel}$$

## Intersection over Union (IoU)




Source : [12]




IoU: 0.4034

IoU: 0.7330

IoU: 0.9264



Poor



Good



Excellent

Source : [12]

Cas d'usage : **Attribution de crédit** (classification binaire)



- Préparation des données
- Entraînement d'un réseau de neurones
- Evaluation du modèle

Source : [13]

Live coding :  
Données, entraînement et évaluation

- Importance & défis du test de l'IA
- Propriétés des modèles de ML
  - Ethique & équité
  - Explicabilité
  - Robustesse

Test de l'IA

## L'évaluation des performances n'est pas suffisante...

L'évaluation du modèle...

- > vérifie qu'il **généralise bien** (pas de surajustement ou de sous-ajustement),
- > assure que la **performance globale est satisfaisante** mais...
- > ne localise pas et ne caractérise pas les **erreurs**,
- > ne traque pas les **régressions comportementales**,
- > ne détecte pas les **biais**,
- > etc.



Source : [14]

**C'est un détecteur de neige...**

## Problématiques génériques au test

- > Manque de spécifications
- > Problème de l'oracle de test
- > Le rôle du testeur
- ➔ Des connaissances métiers sont souvent requises

## Problématiques spécifiques au ML


- > **Métriques d'adéquation des tests** (ex. métriques de couverture)
- > Tests de (non) régression
  - Le comportement change à chaque entraînement
- > **Problématiques spécifiques au domaine d'application** (ex. adversarial examples, fairness)



Source : [15]

## Problèmes des données

## Effets sur le modèle



## Principes éthiques

- > Respect de l'autonomie humaine
  - > Prévention de toute atteinte
  - > Equité
  - > Explicabilité
- Accorder une attention particulière aux situations concernant des groupes plus vulnérables
- Être conscient des avantages et risques liés aux systèmes IA

Source : [15]

Restreint

GRUPE D'EXPERTS  
INDEPENDANTS DE HAUT NIVEAU SUR  
L'INTELLIGENCE ARTIFICIELLE  
CONSTITUE PAR LA COMMISSION EUROPEENNE EN JUIN 2018



LIGNES DIRECTRICES EN  
MATIERE D'ETHIQUE  
POUR UNE IA DIGNE DE  
CONFIANCE

## Biais liés aux données, algorithmes, utilisateurs

- > De répercussion ;
- > De sélection ;
- > D'attribution de groupe ;
- > Implicite ;
- > D'automatisation/complaisance.

## Méthodes de résolution

- > Pre-processing :
  - Ajuster les distributions dans les données d'entraînement.
- > In-processing :
  - Prendre en compte le critère d'équité dans l'optimisation du modèle.
- > Post-processing :
  - Calibrer les prédictions après la phase d'entraînement.

Fairness Goal	Training Scheme	Sensitive Attribute	Method
Disparate impact	Regularization	Known	Prejudice index [45], Absolute correlation [12] Wasserstein fair [41], Pairwise comparisons [11] Fair regression [3], Fair decision trees [4]
	Constraint optimization	Known	Flexible mechanism [83], Tractable constraints [82], Convex-concave [73]
		Unknown	DRO [38], ARL [53], Proxy Fairness [37]
		Beyond	Paper matching [50]
Disparate treatment	Regularization	Known	Controlled direct effect [25], Fair decision trees [4], Convex fair regression [9]
	Constraint optimization	Known	Fairness Through Awareness [29], Logit pairing [35] Counterfactual fairness [52]
Hybrid methods	Constraint optimization	Known	subgroup fairness [46], rich subgroup fairness[46] Maxmin-Fair Ranking [34]

Goal	Training Techniques	Method
Impact-Driven	Adversarial Learning (Prediction-layer)	Adversarial Debiasing [84] Adversarial Recidivism Application [77]
	Adversarial Learning (Hidden-layer)	Censored Representation [30] Transferable Representations [58] Re-embeds word vector [75], Fair Word Embedding [31]
	Disentanglement (Hidden-layer)	Flexibly Fair [36] Disentangled Representations [56]
Treatment-Driven	Contrastive Learning	Contrastive Debiasing [19], Multi-CLRec [86] Conditional Contrastive [76], Fair Graph [51] Fairness-aware Data Augmentation [51]
Hybrid methods	Disentanglement	Flexibly Fair [36], Intersected Fair [63]
	Adversarial Learning	Fair Graph Embeddings [15]

Source : [16]

La facilité avec laquelle les utilisateurs peuvent déterminer pourquoi ou comment le système basé sur l'IA produit un résultat particulier.

## Objectifs


- > Justifier pour instaurer la confiance des différents acteurs
- > Contrôler pour respecter les normes et exigences, identifier les biais, risques, vulnérabilités
- > Améliorer la conception grâce à une meilleure compréhension

## Caractéristiques des méthodes

- > Modèle : spécifique, agnostique
- > Portée des explications : locale, globale
- > Types de données : images, texte ...
- > Technique : simplification, perturbation ...



Source : [17]




Restreint


“Ability of an AI system to **maintain its level of performance under any circumstances.**”

*ISO/IEC TR 24029-1:2021*

- > Englobe à la fois la **sécurité** et la **sûreté**.
  - Sécurité : “The degree to which a component or system protects its data and resources against unauthorized access or use and secures unobstructed access and use for its legitimate users.” (ISTQB)
  - Sûreté : “Safety is considered to be the expectancy that an AI-based system will not cause harm to people, property or the environment.” (ISTQB)
  
- > A nuancer : Les circonstances doivent être comprises dans le domaine opérationnel.



Source : [19]



Source : [19]

Attaque consistant à “**perturber subtilement les entrées valides** qui sont transmises au modèle formé pour l'amener à **fournir des prédictions incorrectes**”. (ISTQB)

## Caractéristiques d'une attaque

- > Attaque de disponibilité, d'intégrité ou contre la confidentialité et la vie privée
- > Attaque ciblée ou non ciblée
- > Attaque causale ou exploratoire
- > Attaque boîte blanche ou boîte noire

## Métriques d'évaluation et d'analyse

- > Taux de réussite
- > Accuracy du modèle attaqué
- > Distortion
- > Nombre d'itérations


## Fast Gradient Sign Method (FGSM)

$$\begin{array}{ccc} \begin{array}{c} \text{Image of a panda} \\ x \\ \text{"panda"} \\ 57.7\% \text{ confidence} \end{array} & + .007 \times & \begin{array}{c} \text{Noise pattern} \\ \text{sign}(\nabla_x J(\theta, x, y)) \\ \text{"nematode"} \\ 8.2\% \text{ confidence} \end{array} \\ & & = \\ & & \begin{array}{c} \text{Adversarial image} \\ x + \epsilon \text{sign}(\nabla_x J(\theta, x, y)) \\ \text{"gibbon"} \\ 99.3\% \text{ confidence} \end{array} \end{array}$$

Source : [20]

## Exemples : méthodes de test et de génération de cas de test

- > Vérification formelle
- > Test de mutation
- > Fuzzing
- > Approche « search-based »
- > Générateur basé sur un GAN
- > Générateur manuel
- > ...




Source : [21]

- Robustesse
- Explicabilité
- Ethique

Live coding : Test

## > Connaissances et bonnes pratiques

- Maîtriser le processus de développement d'un système IA
- Comprendre les spécificités du test de l'IA par rapport au test logiciel
- Connaître les principales faiblesses d'une IA
- Identifier les méthodes et outils de test pertinents
- Faire auditer son système IA (AI Act)



# Kereval

Laboratoire d'ingénierie du test logiciel

<https://www.kereval.com/>

[contact@kereval.com](mailto:contact@kereval.com)

[sarah.leroy@kereval.com](mailto:sarah.leroy@kereval.com)

[clement.francois@kereval.com](mailto:clement.francois@kereval.com)

- > [1] <https://www.europarl.europa.eu/news/fr/headlines/society/20200827STO85804/intelligence-artificielle-definition-et-utilisation>
- > [2] <https://openai.com/blog/chatgpt>
- > [3] <https://www.marktechpost.com/2022/11/14/how-do-dall%C2%B7e-2-stable-diffusion-and-midjourney-work/>
- > [4] <https://www.bercynumerique.finances.gouv.fr/quest-ce-que-lia>
- > [5] <https://blent.ai/blog/a/apprentissage-supervise-definition>
- > [6] <https://teahouse.fifty-five.com/en/machine-learning-reinforcement-learning/>
- > [7] [https://www.cftl.fr/wp-content/uploads/2022/08/ISTQB\\_CT-AI\\_Syllabus\\_v1.0-FR.pdf](https://www.cftl.fr/wp-content/uploads/2022/08/ISTQB_CT-AI_Syllabus_v1.0-FR.pdf)
- > [8] <https://bigwater.consulting/2019/04/08/software-development-life-cycle-sdlc/>
- > [9] <https://towardsdatascience.com/whats-the-deal-with-accuracy-precision-recall-and-f1-f5d8b4db1021>
- > [10] <https://analyticsindiamag.com/complete-guide-to-understanding-precision-and-recall-curves/>
- > [11] [https://en.wikipedia.org/wiki/Receiver\\_operating\\_characteristic](https://en.wikipedia.org/wiki/Receiver_operating_characteristic)
- > [12] <https://pyimagesearch.com/2016/11/07/intersection-over-union-iou-for-object-detection/>
- > [13] <https://www.fibe.in/blogs/fico-score-vs-credit-score-what-is-the-difference/>
- > [14] <https://medium.com/trusted-ai/explaining-ai-model-behaviour-with-ibm-watson-openscale-86515702c177>
- > [15] <https://digital-strategy.ec.europa.eu/en/library/ethics-guidelines-trustworthy-ai>
- > [16] <https://arxiv.org/abs/2111.03015>
- > [17] <https://ieeexplore.ieee.org/document/8466590>
- > [18] <https://dl.acm.org/doi/10.1145/3340482.3342741>
- > [19] <https://dl.acm.org/doi/abs/10.1145/3241979>
- > [20] <https://arxiv.org/abs/1412.6572>
- > [21] <https://github.com/eth-sri/eran>