

LES FAMILLES D'IA FONCTIONNENT DÉPLOIEMENT



Sophie TARDIVEL

Dirigeante, ingénieure
data scientist

Tours, 5 juin 2026



Logiciels data & IA
R&D externalisée
Conseil en stratégie IT
Formations

**10 ans d'expérience
dans l'IA
+ 30 clients
+ 130 projets**





L'IA

Capacité qu'on donne par la technologie à une machine pour réaliser des tâches **intellectuelles complexes**.



La complexité adressée par les IA


La quantité et l'hétérogénéité des données à prendre en compte pour réaliser une tâche, dans un temps acceptable, sont trop grandes

Les données sont partielles mais il faut en déduire une généralité

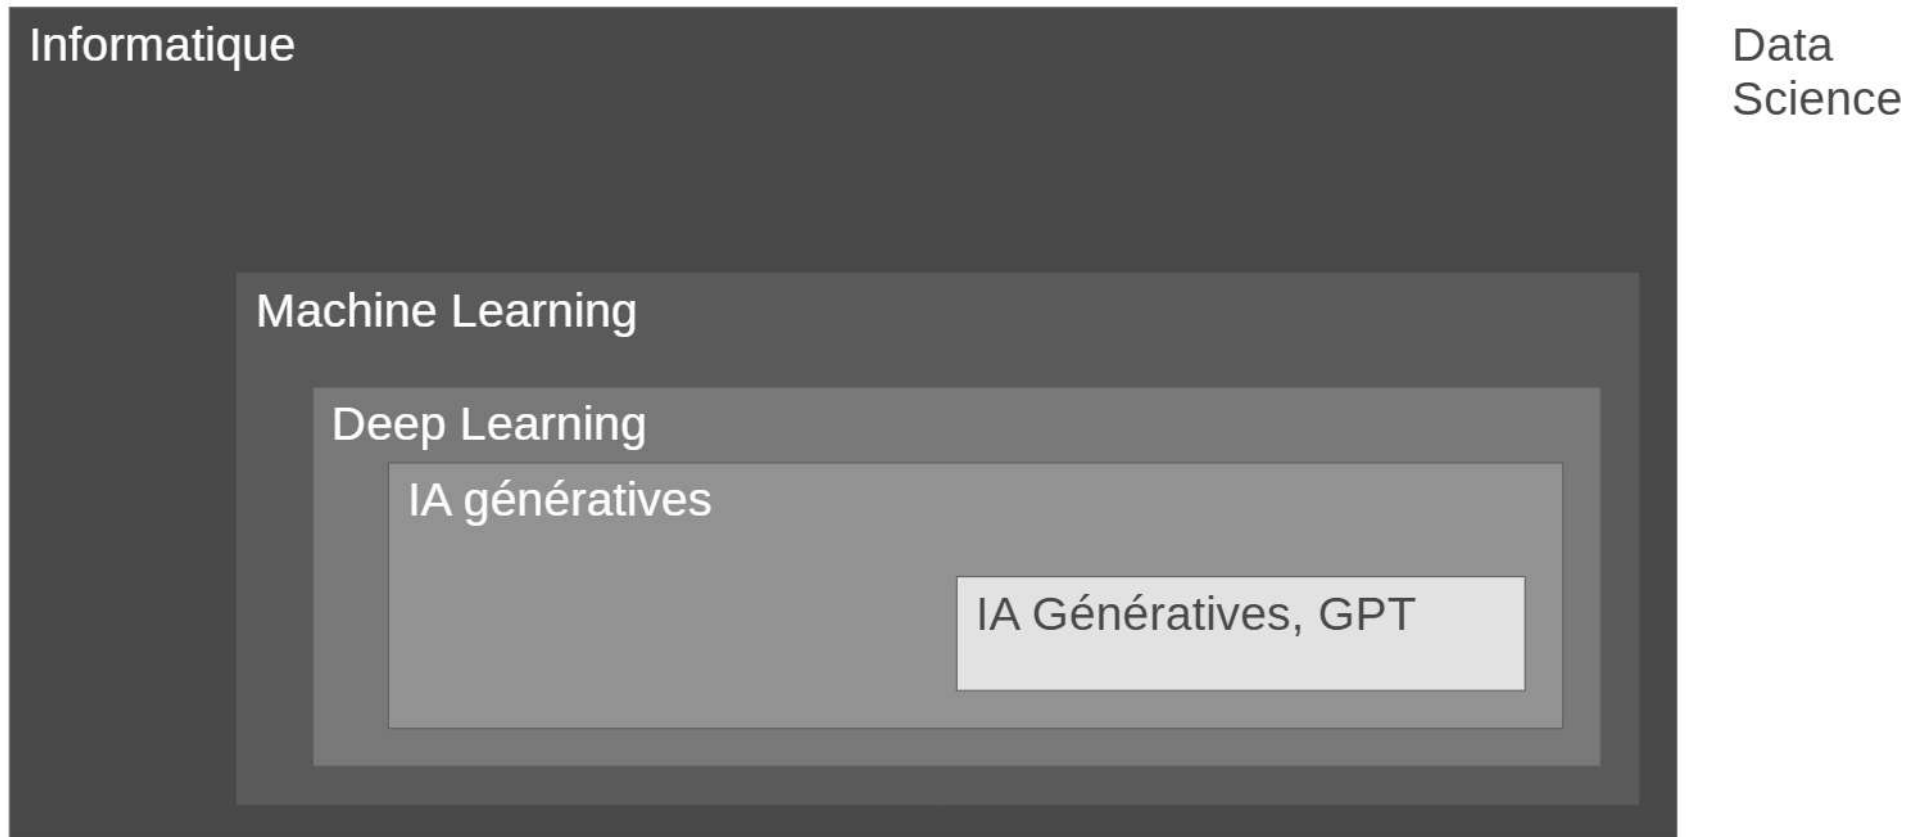
Tous les cas ne peuvent pas être décrits à l'avance

La relation entre les données observées et le résultat attendu n'est pas connue

Le bon résultat attendu échappe à une caractérisation précise et vérifiable



Place de l'IA dans les savoirs technologiques



Les familles d'IA

Machine Learning


Apprendre des données
Identifier des motifs = Modèle
Prédire des résultats

Deep Learning

Réseau Neuronal Profond
Grande quantité de données
Multi-modal

IA génératives

Génération et
Transformation
de données



Fonctionnement de (quelques) modèles IA

Le machine learning de base

Pour quels usages ?

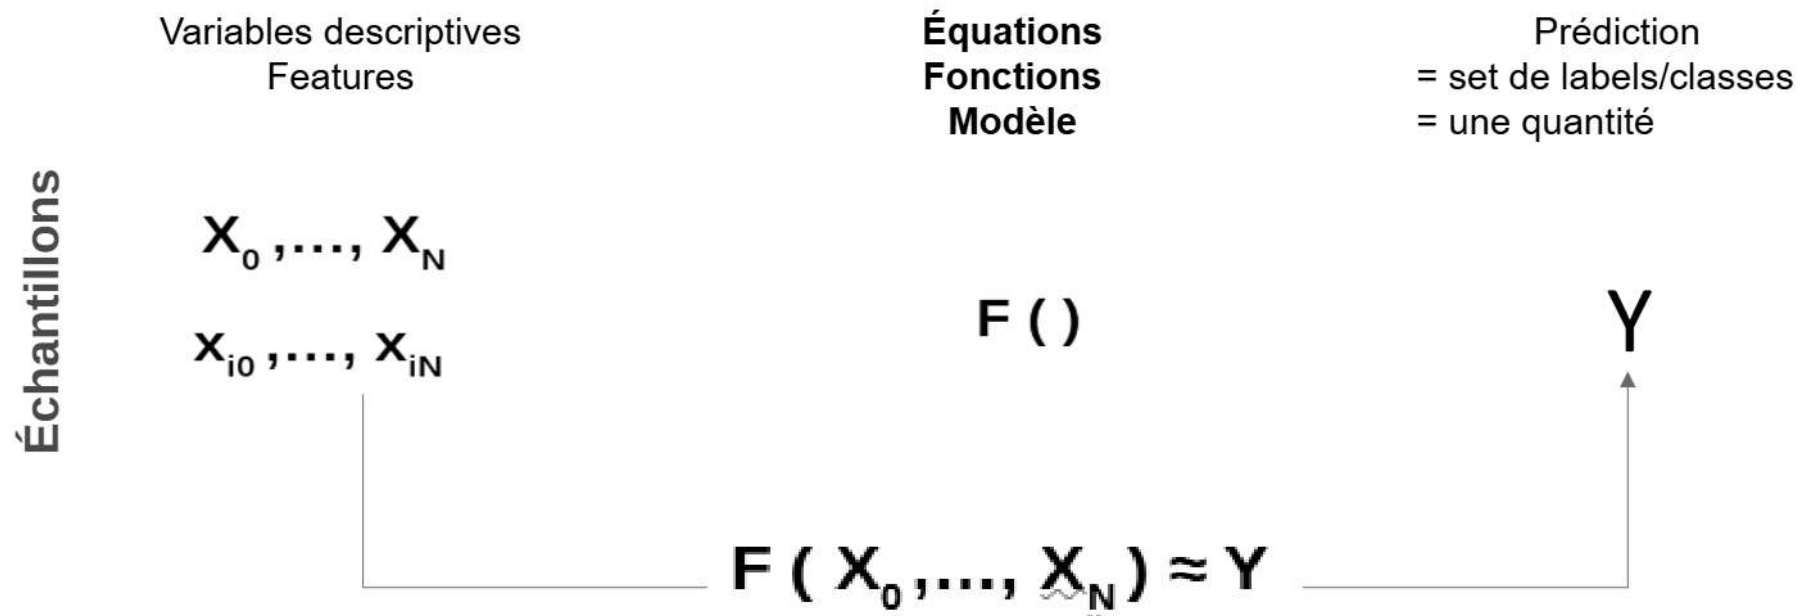
- Détection de dysfonctionnements
- Diagnostics (~ qualification)
- Pronostics (~ prédiction)
- Modélisation ~ Jumeau Numérique
- Prédiction de consommation

...



Le machine learning

Modèles = Représentations mathématiques d'objets, de phénomènes, de structures de données Y



Règle de base : nombre d'échantillons \gg nombre de variables N

Le machine learning de base

Exemple avec des données de chauffage

X_{i0}, \dots, X_{iN}

Y
avec 7 labels chaque saison

Input variables of the model.

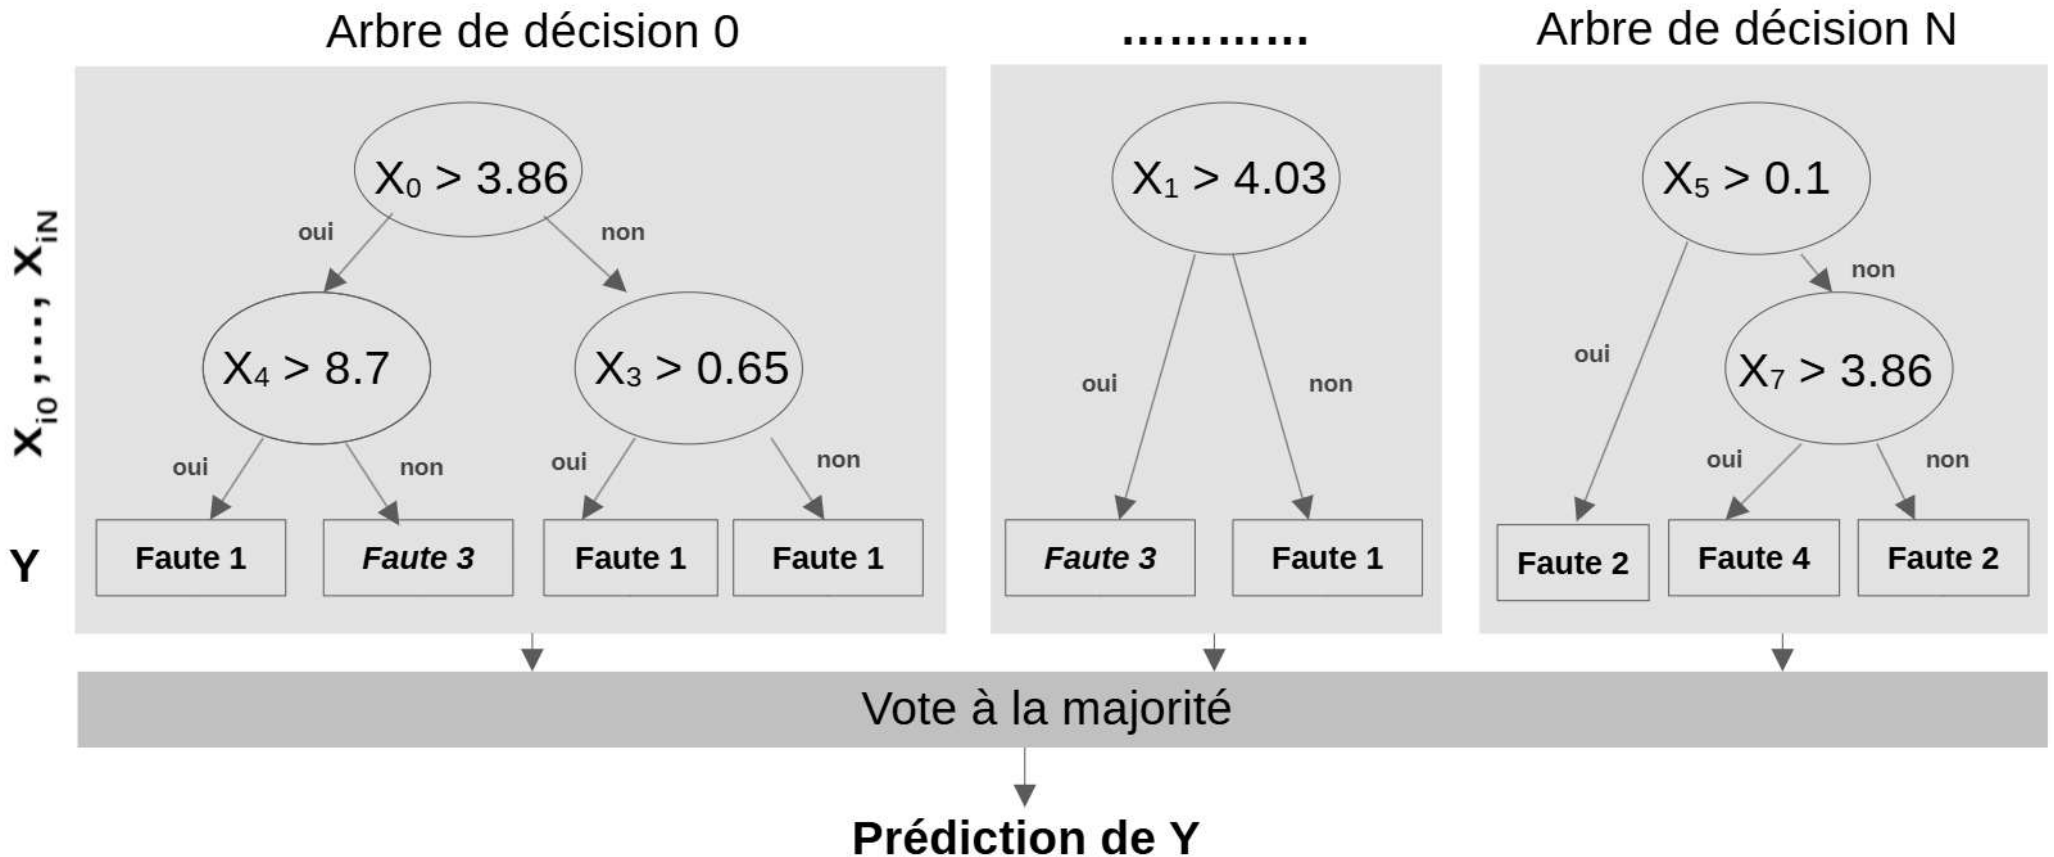
No.	Input variables
1	Heating coil energy consumption (W)
2	Cooling coil energy consumption (W)
3	Supply fan energy consumption (W)
4	Return fan energy consumption (W)
5	Supply fan speed (%)
6	Return fan speed (%)
7	Supply air duct static pressure (psi)
8	Supply air flow rate (CFM)
9	Return air flow rate (CFM)
10	Outdoor air flow rate (CFM)
11	Exhaust air damper control signal (%)
12	Recirculated air damper control signal (%)
13	Outside air damper control signal (%)

Season	Label	Fault description
Summer	Fault 1	OA Damper Leak (45% Open)
	Fault 2	OA Damper Leak (55% Open)
	Fault 3	EA Damper Stuck (Fully Open)
	Fault 4	Cooling Coil Valve Stuck (Fully Closed)
	Fault 5	Cooling Coil Valve Control unstable
	Fault 6	Return Fan at fixed speed
	Fault 7	AHU Duct Leaking (after SF)
Winter	Fault 1	EA Damper Stuck (Fully Open)
	Fault 2	EA Damper Stuck (Fully Closed)
	Fault 3	Heating Coil Reduced Capacity (Stage 1)
	Fault 4	Heating Coil Reduced Capacity (Stage 2)
	Fault 5	Heating Coil Reduced Capacity (Stage 3)
	Fault 6	OA Damper Leak (52% Open)
	Fault 7	OA Damper Leak (62% Open)

Y est connu dans les données historiques = modèle supervisé

Le machine learning de base – modèle supervisé

Avec un ensemble d'arbres de décision



Le machine learning de base – modèle supervisé

Avec des ensembles

Random Forest

XGBoost

- ▶ Nombre de variables < qqes milliers
- ▶ Stable
- ▶ Rapide en apprentissage
- ▶ Très rapide en prédiction



1.11. Ensembles: Gradient boosting, random forests, bagging, voting, stacking

Ensemble methods combine the predictions of several base estimators built with a given learning algorithm in order to improve generalizability / robustness over a single estimator.

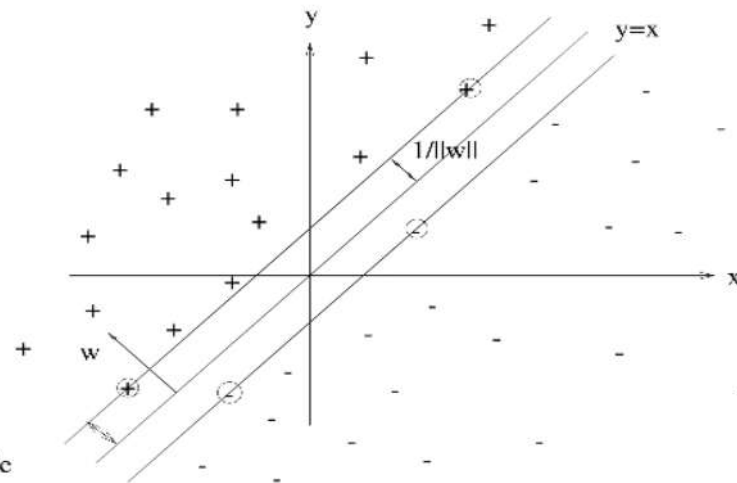

Two very famous examples of ensemble methods are [gradient-boosted trees](#) and [random forests](#).

More generally, ensemble models can be applied to any base learner beyond trees, in averaging methods such as [Bagging methods](#), [model stacking](#), or [Voting](#), or in boosting, as [AdaBoost](#).


Le machine learning de base – modèle supervisé Avec le Support Vector Machine (SVM)

Trouver les lignes (**les vecteurs support**) qui maximisent la marge de séparation entre les échantillons de classe distinctes.


Pour les séparations non linéaires, appliquer une transformation, un **kernel trick**, pour chercher la ligne dans un espace de dimension plus grand



Marge maximale




Le machine learning de base – modèle supervisé Avec le Support Vector Machine (SVM)



Solution : Ajouter une dimension (= passer en 2D) grâce à une projection

$$\varphi : x \mapsto \left(\frac{x-150}{10}, \left(\frac{x-150}{10} \right)^2 \right)$$



Problème transformé :
Classer avec x

↓
Classer avec $\varphi(x)$

$$K(x, x') = \varphi(x)^\top \cdot \varphi(x')$$

Le machine learning de base

Modèles non supervisés

Situation courante :

Des échantillons de variables X mais pas de label Y associé

Modèles de clustering

1. Constituer des groupes d'échantillons (un label = un groupe)
 - 1.1 Choisir un nombre de groupes
 - 1.2 Calculer des distances entre les échantillons
2. Un nouvel échantillon ira dans le groupe le plus proche

2. Unsupervised learning

2.1. Gaussian mixture models

[2.1.1. Gaussian Mixture](#)

[2.1.2. Variational Bayesian Gaussian Mixture](#)

2.2. Manifold learning

[2.2.1. Introduction](#)

[2.2.2. Isomap](#)

[2.2.3. Locally Linear Embedding](#)

[2.2.4. Modified Locally Linear Embedding](#)

[2.2.5. Hessian Eigenmaps](#)

[2.2.6. Spectral Embedding](#)

[2.2.7. Local Tangent Space Alignment](#)

[2.2.8. Multi-dimensional Scaling \(MDS\)](#)

[2.2.9. t-distributed Stochastic Neighbor Embedding \(t-SNE\)](#)

[2.2.10. Tips on practical use](#)

2.3. Clustering

[2.3.1. Overview of clustering methods](#)

[2.3.2. K-means](#)

[2.3.3. Affinity Propagation](#)

[2.3.4. Mean Shift](#)

[2.3.5. Spectral clustering](#)

[2.3.6. Hierarchical clustering](#)

[2.3.7. DBSCAN](#)

[2.3.8. HDBSCAN](#)

[2.3.9. OPTICS](#)

[2.3.10. BIRCH](#)

[2.3.11. Clustering performance evaluation](#)

2.4. Biclustering

[2.4.1. Spectral Co-Clustering](#)

[2.4.2. Spectral Biclustering](#)

[2.4.3. Biclustering evaluation](#)

2.5. Decomposing signals in components (matrix factorization problems)

[2.5.1. Principal component analysis \(PCA\)](#)

[2.5.2. Kernel Principal Component Analysis \(KPCA\)](#)

[2.5.3. Truncated singular value decomposition and latent semantic analysis](#)

[2.5.4. Dictionary Learning](#)

[2.5.5. Factor Analysis](#)

[2.5.6. Independent component analysis \(ICA\)](#)

[2.5.7. Non-negative matrix factorization \(NMF or NNMF\)](#)

[2.5.8. Latent Dirichlet Allocation \(LDA\)](#)

2.6. Covariance estimation

[2.6.1. Empirical covariance](#)

[2.6.2. Shrink Covariance](#)

[2.6.3. Sparse inverse covariance](#)

[2.6.4. Robust Covariance Estimation](#)

2.7. Novelty and Outlier Detection

[2.7.1. Overview of outlier detection methods](#)

[2.7.2. Novelty Detection](#)

[2.7.3. Outlier Detection](#)

[2.7.4. Novelty detection with Local Outlier Factor](#)

2.8. Density Estimation

[2.8.1. Density Estimation: Histograms](#)

[2.8.2. Kernel Density Estimation](#)

2.9. Neural network models (unsupervised)

[2.9.1. Restricted Boltzmann machines](#)

Le machine learning de base

Modèles non supervisés

Ex. : K-means

- ▶ **Nombre de variables < 50**
- ▶ **Choisir une distance**
(Euclidienne, Manhattan, Chebychev...)
- ▶ **Stable**
- ▶ **Long en calcul si bcp de variables**
- ▶ **Rapide en prédiction**




Diagramme de Voronoï

Le deep learning de base

Pour quels usages ?

- Classement d'images
- Détection de défaut sur image
- Création d'images synthétiques
- Prédiction météorologique
- Analyse vibratoire

....


*Attention !
Besoin de plus d'échantillons que
Machine Learning*



Le deep learning

Réseaux Neuronaux profonds

- ▶ Pour un très grand nombre de variables
- ▶ Stable si suffisamment d'échantillons
- ▶ Long en apprentissage
- ▶ Rapide en prédiction



Réduire
le nombre de variables
sans perdre les caractères
influençant le résultat Y

Transformation
Convolution
Encodage
Filtrage

Mémoriser si besoin
les variables 'passées' qui
influent le résultat Y

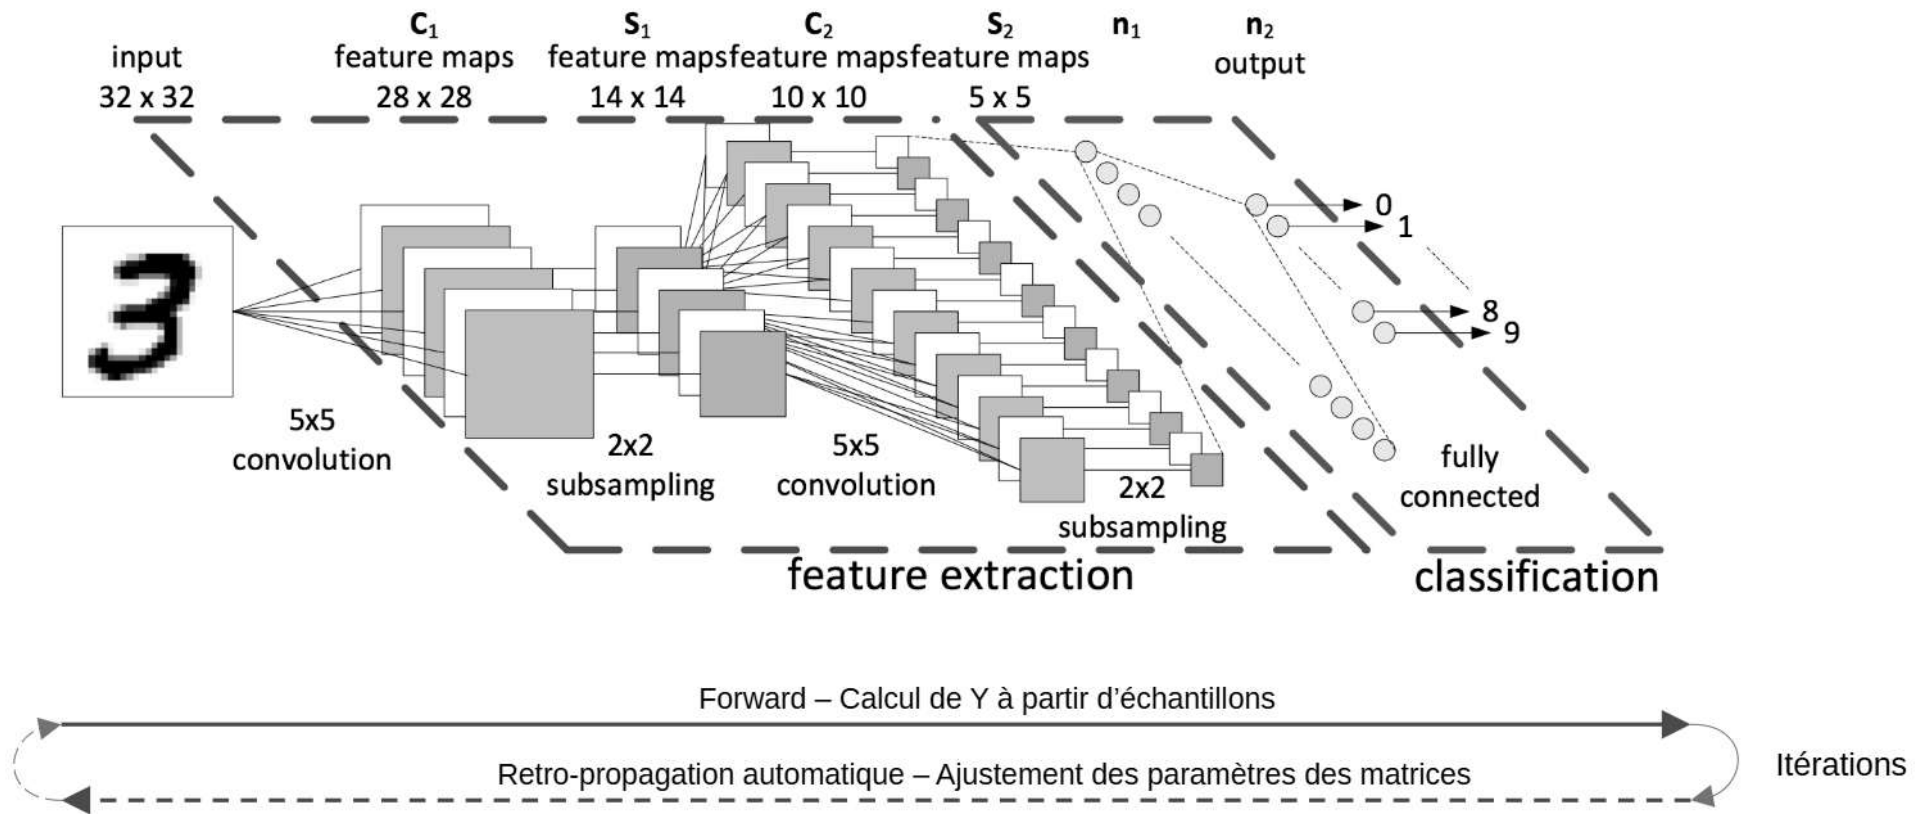
Mémoire
persistante
Portes d'oubli
Positionnement

Classer ou quantifier Y
par combinaison de
variables

Equivalent au XGB,
RD, dans une
architecture NN

Le Deep learning

Les réseaux neuronaux convolutifs (CNN)



Le Deep learning

Les IA intégrées dans les caméras industrielles

1. Présentation de peu d'échantillons bons et mauvais



Bon

Bon


Mauvais

Bon

Mauvais

2. Adaptation des paramètres d'une IA pré-entraînée


Transfer Learning
Fine Tuning



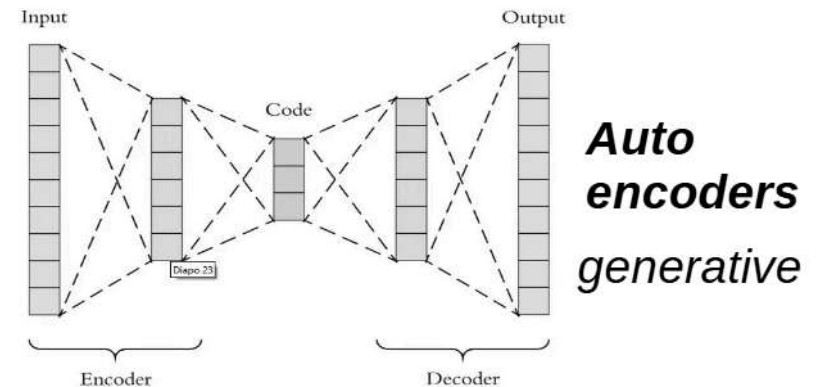
Le Deep learning

Les IA intégrées dans les caméras industrielles

Situation : On ne dispose que de bons échantillons



Apprentissage d'un modèle des bons échantillons
=> Une erreur tolérée



credit: Matthew Stewart, source: <https://towardsdatascience.com/generating-images-with-autoencoders-77fd3a8dd368>

En production, dès qu'un mauvais échantillon apparaît



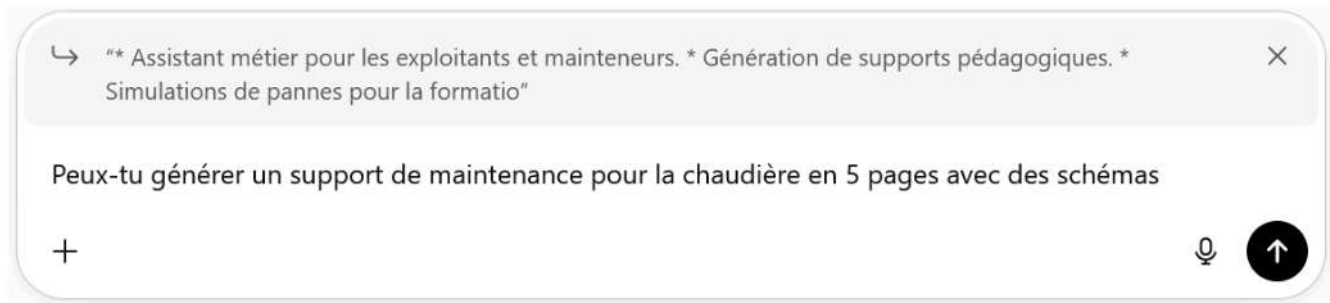
Application du modèle Erreur supérieure à la tolérée + seuil :
« mauvais »

Les IA génératives

Pour quels usages ?

- Assistance à la rédaction des cahiers des charges techniques.
- Interrogation en langage naturel des documents (réglementaires, Cahier des Charges, BIM ...)
- Détection automatique des conflits entre réseaux CVC, structure et électricité.
- Comparaison de plusieurs propositions de fournisseurs
- Génération de diagnostics probables lors d'une panne appris sur des historiques de maintenance
- Création de procédures d'intervention personnalisées.
- Création de supports de formation

....

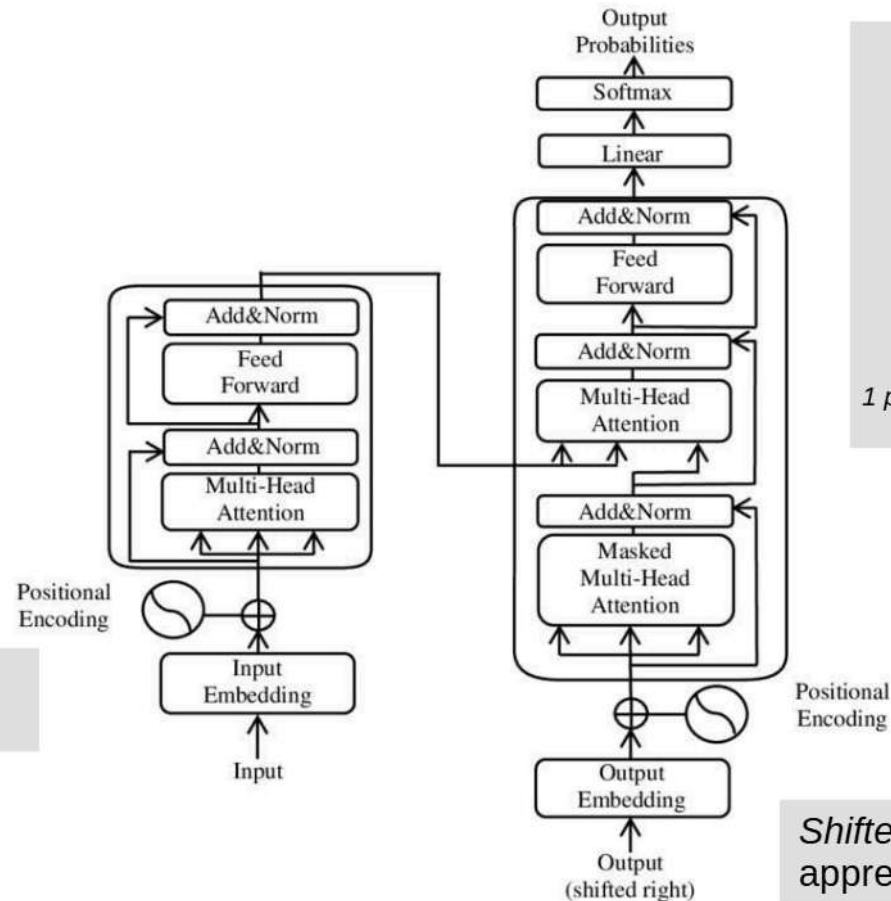


Le Deep learning Transformers et IA pré-entraînées – les GPT

Capter plusieurs relations
(Multi-Head)
entre les mots de la requête

- Grammaire
- Causalité
- Domaine de vocabulaire
- Proximité temporelle

Encoder en **tokens** en tenant compte de la position des mots.



On obtient les Matrices de
Large Language Model (LLM) par entraînement sur des milliards de textes, d'images expliqués en texte, de transcription de son.

1 page de livre ≈ quelques centaines de tokens

Shifted right pour lui faire apprendre le mot suivant.


Le déploiement des IA

Des IA de Machine, puis Deep learning aux IA génératives

Besoin de puissance et de stockage toujours plus grands

sur capteur

IA DL sur GPU (Nvidia ...)
IA ML sur petit capteur



Chipset

sur smartphone

IA ML, DL intégrés à l'OS
ou dans votre apps



Smartphone

sur laptop / PC


IA ML, DL, petite IA Gen intégré en local
sur des laptops et des PC 'gaming'.
Script avec API vers IA Gen dans cloud



Laptop

dans le cloud

du fournisseur, en cloud privé,
en cloud edge dans votre bâtiment,
IA génératives via navigateur WEB



Écran

Cloud

La tarification en cloud est par abonnement pour l'accès web + par millions de tokens sur les API (pour les scripts)
Il existe des open-sources de LLM pour se construire son propre système IA.

Outil de développement d'IA de Machine learning


<https://scikit-learn.org>
BSD license

 **TensorFlow**
<https://www.tensorflow.org>
Google
Licence Apache


 **PyTorch**
<https://pytorch.org>
Facebook/Meta
Licence Berkeley Distribution

 **K**
<https://keras.io>
François Chollet
Licence MIT

Python
 **Python Software Foundation**
Licence BSD + **Librairies**

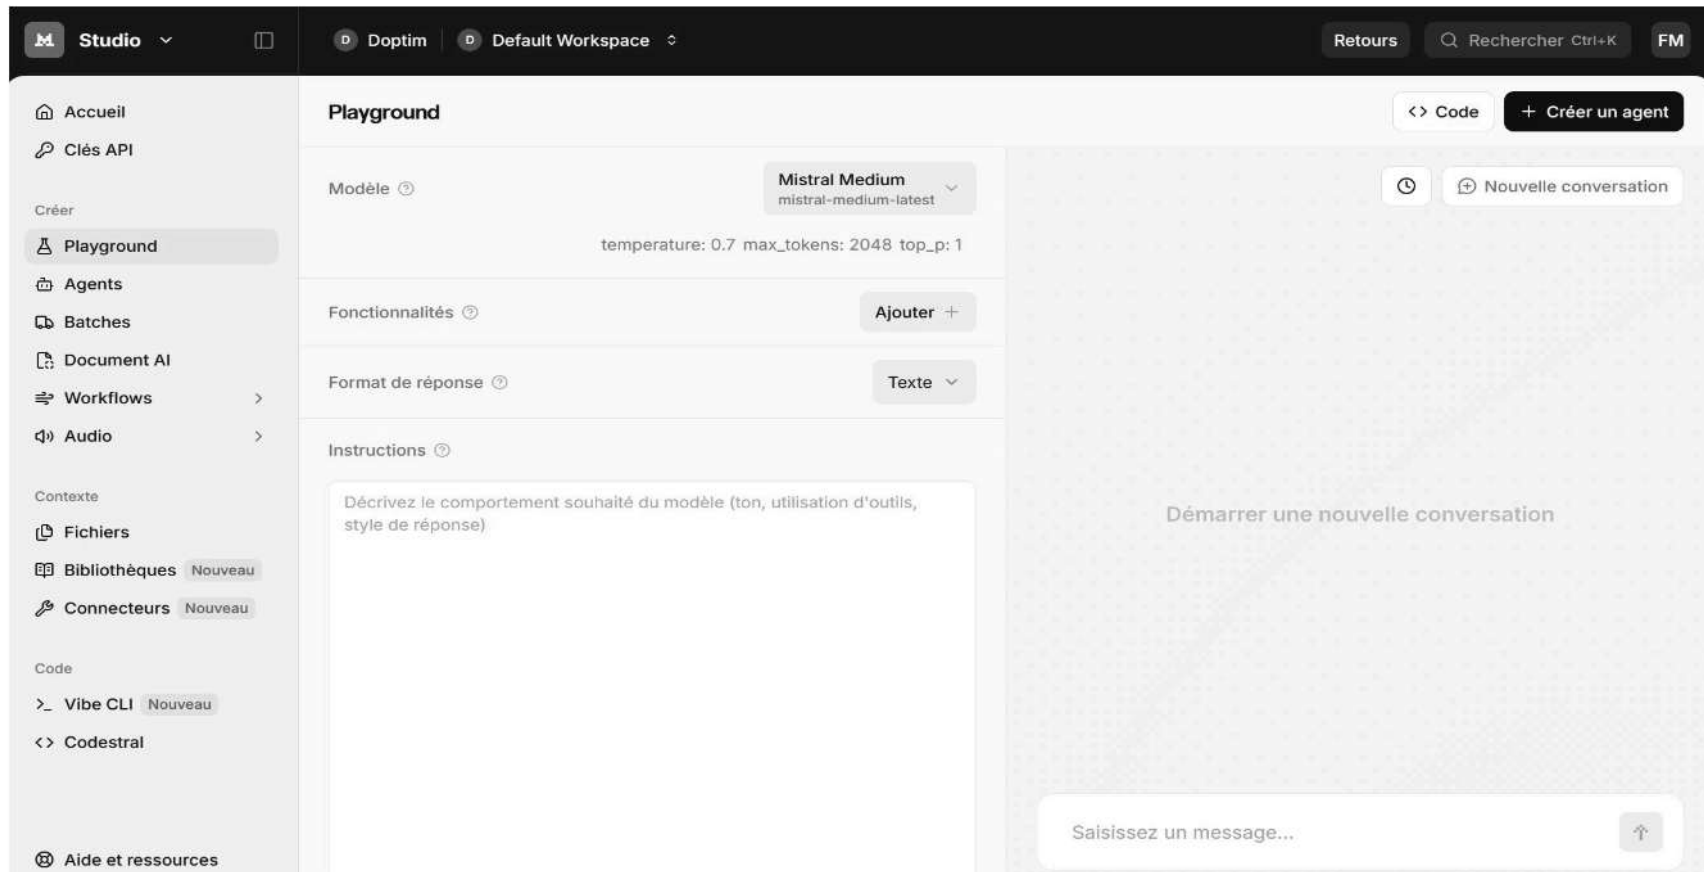
 **Format Notebook**
<https://ipython.org>
Licence BSD

Darts  Timeseries

 **Hugging Face**
LLM + benchmarks



Les outils en ligne de création d'agent d'IA générative



Doptim

Data Optimizers

Merci de votre attention
A vos questions ...

