

2022/2023

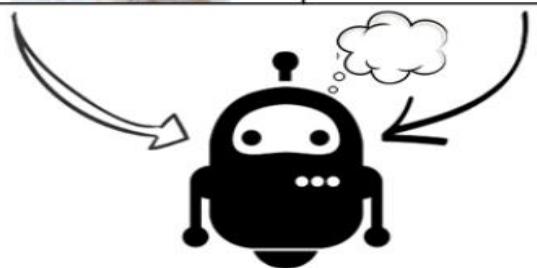
Réalisé par: Naïma Daghfous

# Apprentissage Supervisé

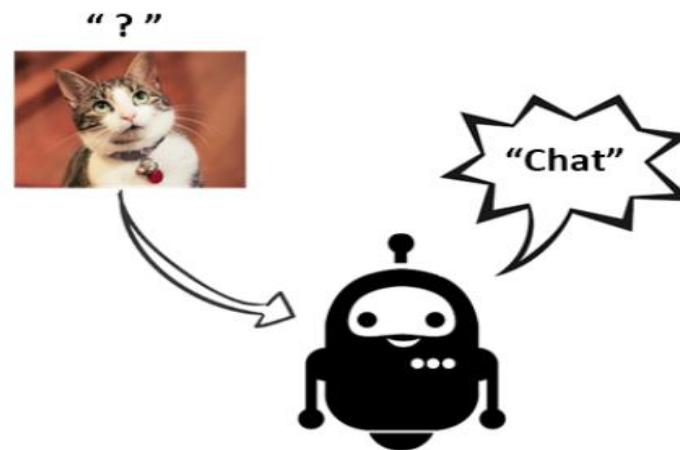
# Apprentissage Supervisé

- Apprentissage automatique = apprendre un modèle formel à partir de données observées

$x$	$\longrightarrow$	$y$
		“Chien”
		“Chien”
		“Chat”
		“Chien”



Apprentissage Supervisé



Utilisation finale

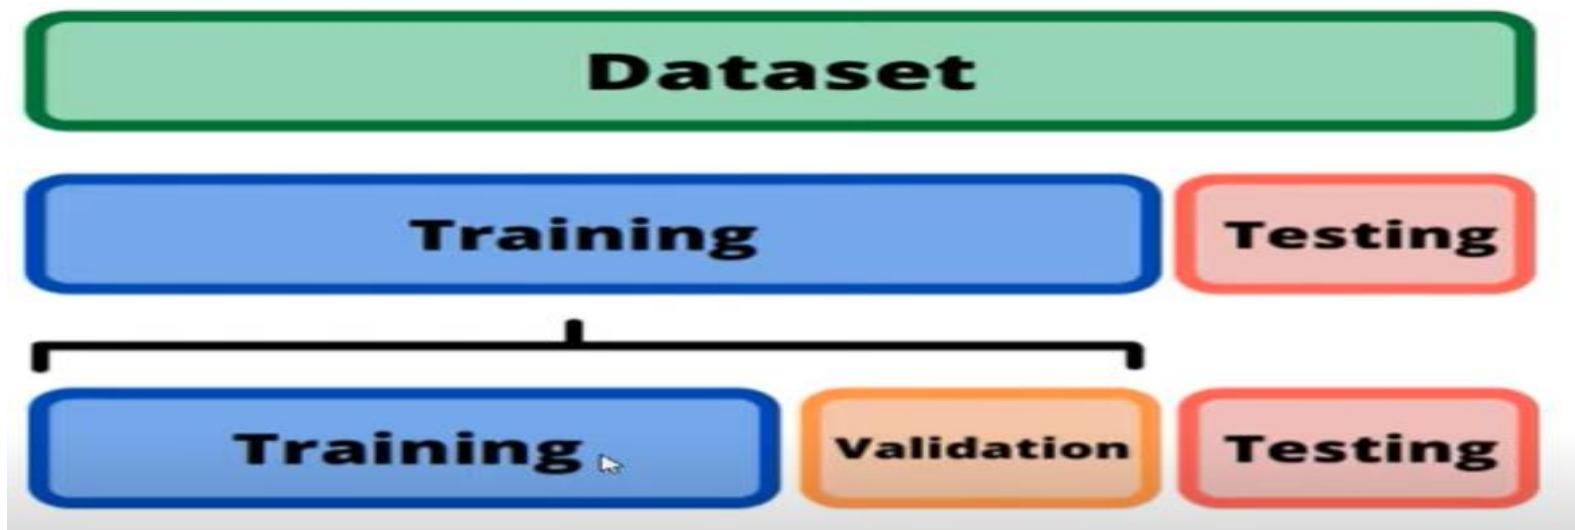
La machine apprend à partir de milliers d'exemples  $x, y$

# Apprentissage Supervisé

- L'apprentissage supervisé fonctionne en 4 étapes :
  - ♣ Importer un **Dataset** qui contient nos exemples
  - ♣ Développer un **Modèle** aux paramètres aléatoires
  - ♣ Développer une **Fonction Coût** qui mesure les erreurs entre le modèle et le Dataset
  - ♣ Développer un Algorithme d'apprentissage pour trouver les paramètres du modèle qui **minimisent la Fonction Coût**

# Dataset

- ♣ **Collecte des données** et leur labellisation.
- ♣ **Nettoyage des données** (Valeurs manquantes, redondance, variables inutiles...).
- ♣ **Prétraitement des données** (Identification des variables explicatives et de la sortie cible, séparation en données d'entraînement et données de validation, normalisation des données...)



# Exemple de Dataset

- ♣ Les colonnes sont variables d'entrée, attributs ou caractéristiques.
- ♣ les variables résultats ou les cibles. (target )
- ♣ Une ligne du tableau est appelée un exemple d'entraînement ou instance. *Exemple de Dataset sur des appartements*

The diagram shows a table representing a dataset. The columns are labeled 'Target  $y$ ' and 'Features' ( $x_1$ ,  $x_2$ ,  $x_3$ ). The rows represent examples. A blue double-headed arrow on the left indicates the number of examples  $m$ . A yellow double-headed arrow at the bottom indicates the number of features  $n$ . A green arrow points to the second row, which is highlighted in green, with the label  $x_3^{(2)}$  next to it. The table data is as follows:

Target $y$	Features		
	$x_1$	$x_2$	$x_3$
Prix	Surface	Qualité	Adresse postale
313,000	90	3	95000
720,000	110	5	93000
250,000	40	4	44500
290,000	60	3	67000
190,000	50	3	59300
...	...	...	...

Par convention:  
 $m$ : nombre d'exemples  
 $n$ : nombre de features

Par convention, on note:  
 $x_{feature}^{(exemple)}$

$x_3^{(2)}$

# Représentation du Dataset

Dataset  $(x, y)$

$y$	$x_1$	$x_2$	$x_3$	...	$x_n$
$y^{(1)}$	$x_1^{(1)}$	$x_2^{(1)}$	$x_3^{(1)}$	...	$x_n^{(1)}$
$y^{(2)}$	$x_1^{(2)}$	$x_2^{(2)}$	$x_3^{(2)}$	...	$x_n^{(2)}$
$y^{(3)}$	$x_1^{(3)}$	$x_2^{(3)}$	$x_3^{(3)}$	...	$x_n^{(3)}$
...	...	...	...	...	...
$y^{(m)}$	$x_1^{(m)}$	$x_2^{(m)}$	$x_3^{(m)}$	...	$x_n^{(m)}$

vecteur target  $y \in \mathbb{R}^{m \times 1}$

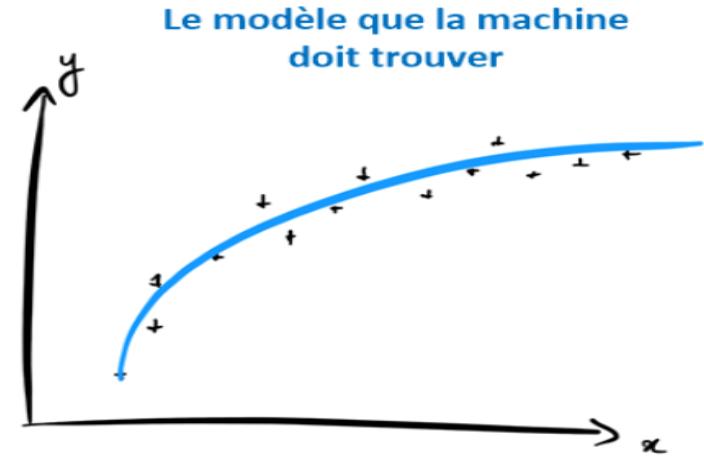
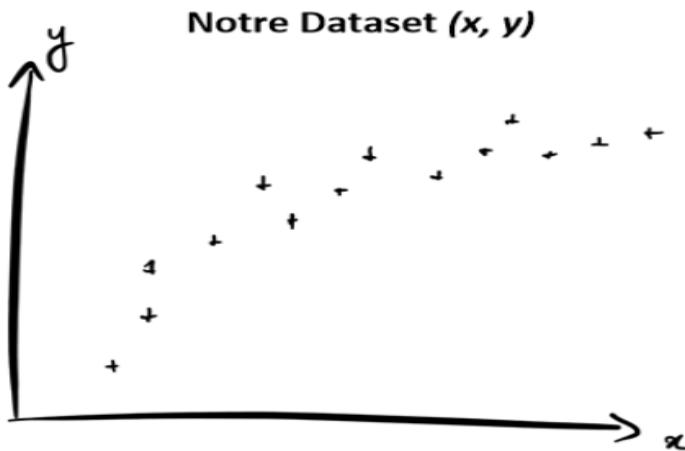
matrice features  $X \in \mathbb{R}^{m \times n}$

$$y = \begin{pmatrix} y^{(1)} \\ y^{(2)} \\ \dots \\ y^{(m)} \end{pmatrix}$$

$$X = \begin{pmatrix} x_1^{(1)} & \dots & x_n^{(1)} \\ \vdots & \ddots & \vdots \\ x_1^{(m)} & \dots & x_n^{(m)} \end{pmatrix}$$

# Le Modèle et ses paramètres

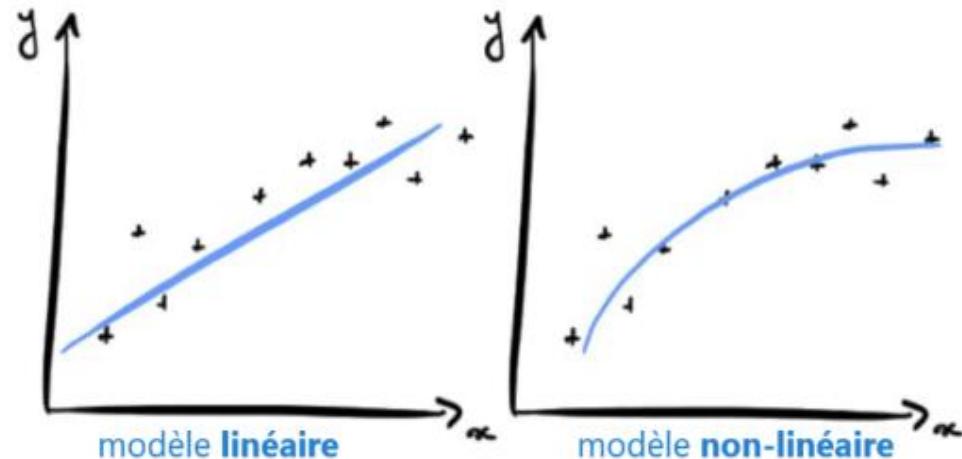
- Un modèle est une **représentation** simplifiée de la réalité, que l'on peut utiliser pour **prédir** ce qui se passerait dans certaines conditions. Ça peut être un dessin, une équation physique, une fonction mathématique, une courbe... bref, n'importe quelle représentation.
- Si par exemple le Dataset nous donne le nuage de point suivant, alors la machine devra trouver le modèle qui rentre le mieux dans ce nuage de point.



# Le Modèle et ses paramètres

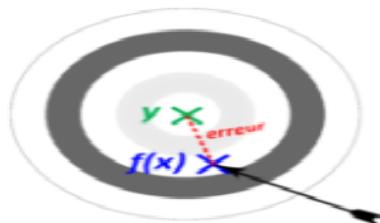
- Cependant, ce n'est pas à la machine de faire tout le travail ! c'est à nous de choisir le type de modèle (c'est-à-dire la fonction mathématique) et c'est à la machine de trouver les **coefficients** donnant les meilleurs résultats.
- Ces coefficients sont les **paramètres** du modèle.
- Par exemple, on peut choisir de développer :
  - ♣ un modèle **linéaire**  $f(x) = ax + b$
  - ♣ un modèle **non-linéaire**  $f(x) = ax^2 + bx + c$

et on laisse la machine trouver la valeur des paramètres  $(a, b)$  ou  $(a, b, c)$  qui donnent les meilleurs résultats.

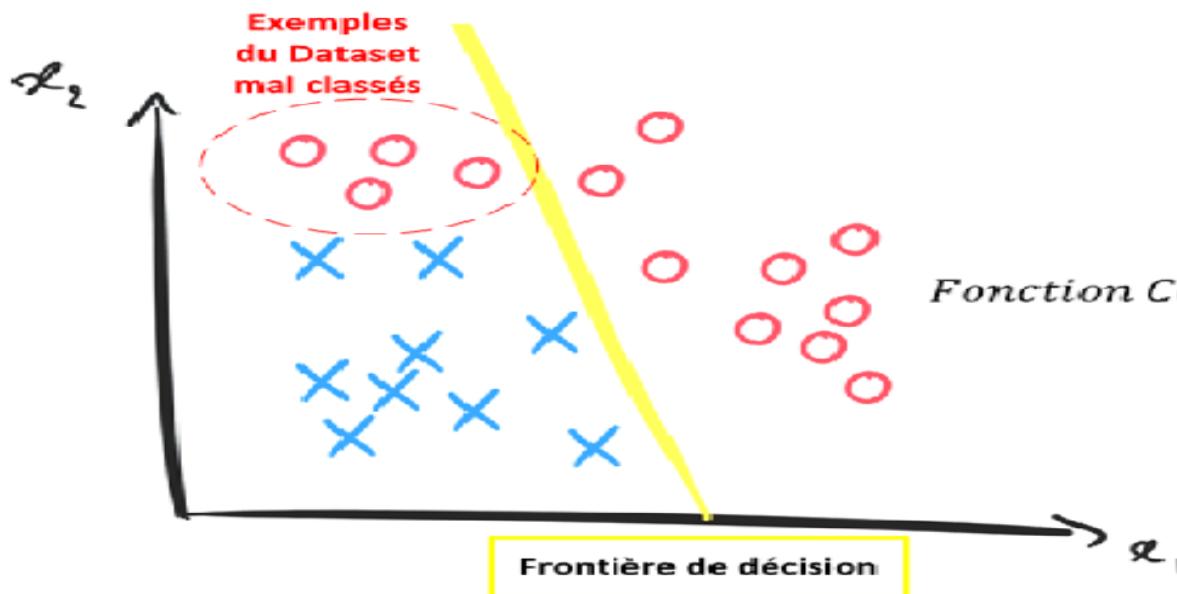
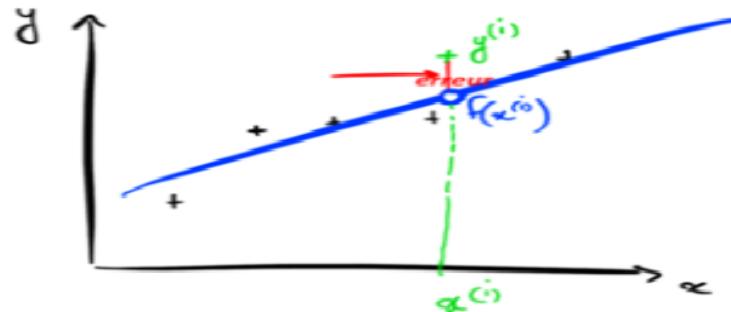


# La fonction cout

- Pour que la machine trouve le meilleur modèle, il faut qu'elle puisse **mesurer la performance** d'un modèle donné



Distance entre flèche et cible  
Équivalent à  
Erreur entre modèle et Dataset



$$\begin{aligned} \text{Fonction Coût} &= \frac{\# \text{ Erreurs}}{\# \text{ Exemples}} \\ &= \frac{4}{22} \end{aligned}$$

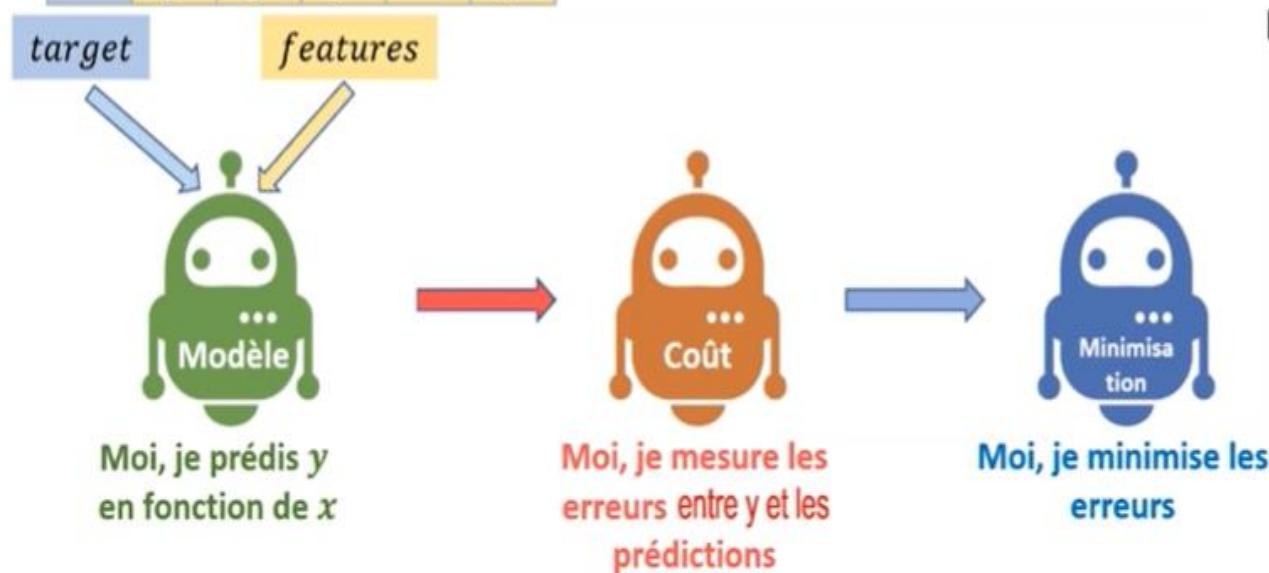
# L'Algorithme d'apprentissage

- La machine cherche les **paramètres** de modèle qui **minimisent** la **Fonction Coût**. C'est ça qu'on appelle l'apprentissage. Cette phrase est **très importante**. C'est l'essentiel de ce qu'il faut comprendre en Machine Learning.
- Pour trouver les paramètres qui minimisent la fonction Coût, il existe un plusieurs stratégies.
- Une stratégie, **très populaire** en Machine Learning, est de considérer la Fonction Coût comme une fonction **convexe**, c'est-à-dire une fonction qui n'a qu'un seul minimum, et de chercher ce minimum avec un algorithme de minimisation appelé **Gradient Descent**.

# Schéma de l'Apprentissage Supervisé

*Dataset  $(x, y)$*

$y$	$x_1$	$x_2$	$x_3$	...	$x_n$
$y^{(1)}$	$x_1^{(1)}$	$x_2^{(1)}$	$x_3^{(1)}$	...	$x_n^{(1)}$
$y^{(2)}$	$x_1^{(2)}$	$x_2^{(2)}$	$x_3^{(2)}$	...	$x_n^{(2)}$
$y^{(3)}$	$x_1^{(3)}$	$x_2^{(3)}$	$x_3^{(3)}$	...	$x_n^{(3)}$
...	...	...	...	...	...
$y^{(m)}$	$x_1^{(m)}$	$x_2^{(m)}$	$x_3^{(m)}$	...	$x_n^{(m)}$



## 1. Dataset

$y$  : Target

$x$  : features

## 2. Modèle

paramètres

## 3. Fonction Coût

## 4. Algorithme de minimisation

# Régression & Classification

## L'apprentissage supervisé

Je **sais** ce que je cherche à prédire et j'ai déjà des données **en guise d'exemple** à fournir à ma machine

SUPERVISE

### La régression

Je cherche à prédire une **valeur numérique**, un chiffre, un nombre ?

*Exemples : ventes, marge, stock, température, pression, taille, poids, quantité...*

### La classification

Je cherche à prédire une **catégorie**, une dimension, une classe ?

*Exemples : oui / non, vrai / faux, homme / femme, segments, espèces d'animaux...*

# Avantages & Inconvénients

- Quels sont les avantages de l'apprentissage supervisé?  
Plusieurs problématiques peuvent être traitées à l'aide de l'apprentissage supervisé.

**Entraînement facile et efficace** des différents modèles grâce à des données déjà étiquetées.

Les labels permettent de valider le modèle en le testant sur des données étiquetées et en **comparant les résultats prédictifs et les sorties réelles**.

- Pourquoi l'apprentissage supervisé est de moins en moins populaire?

**Difficultés pour étiqueter les données**, surtout quand elles sont en grande quantité.

Problème de **sur-apprentissage** si le modèle rencontre des données anormales (problème très fréquent si le jeu de données d'entraînement est de petite taille).