

# Explicabilité de l'intelligence artificielle

Romain Giot



# **Préambule**

---

**Description de la  
présentation**

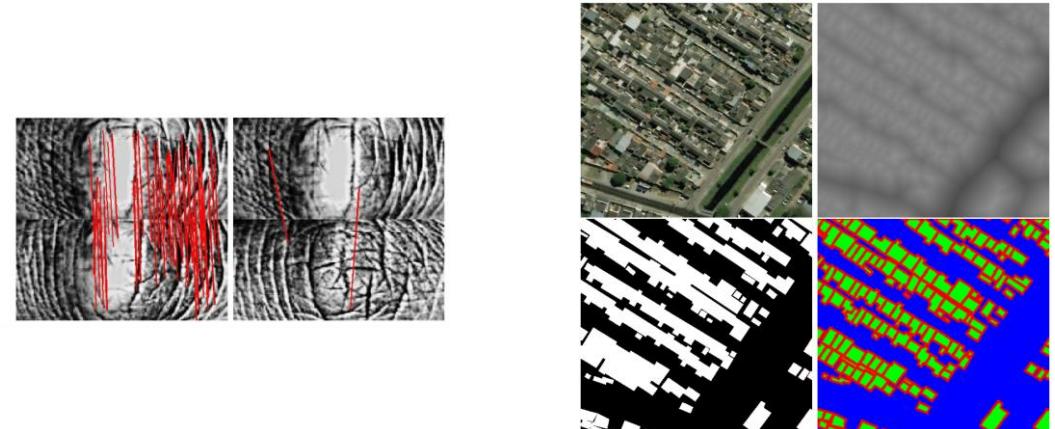
---

# Romain Giot – MCF en informatique

## IUT de Bordeaux / LaBRI

### Authentification biométrique

rides du doigt, dynamique de frappe, modèles adaptatifs, multi-biométrie



### Villes intelligentes

prédition d'usage des systèmes de vélos libre service, segmentation d'images satellites

### Analyse de documents et d'images

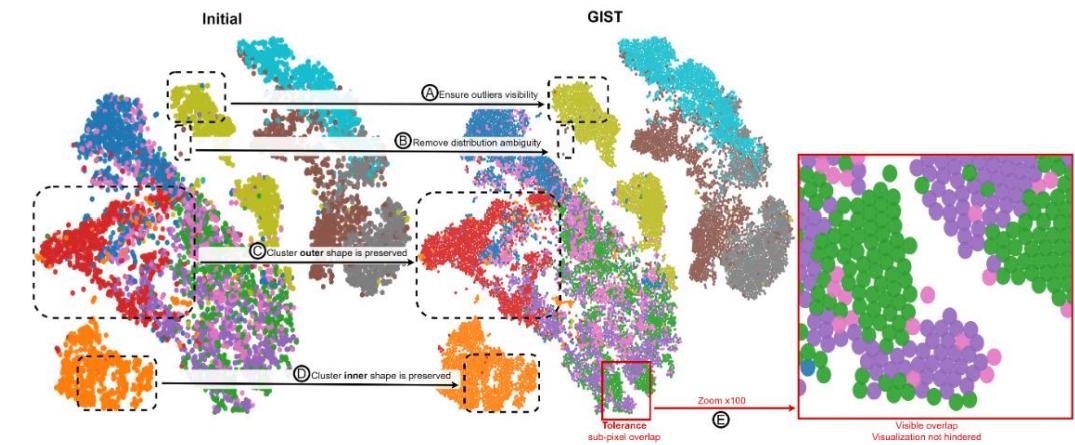
classification hiérarchique, fusion d'informations

### Intelligence artificielle pour la visualisation d'informations

dessin de graphes, suppression de chevauchements, analyse de représentations visuelles

### Visualisation d'informations pour l'intelligence artificielle

Explicabilité, détection d'erreurs dans les données



# Organisation de la présentation

---

1. Introduction à l'intelligence artificielle
2. Généralités sur l'apprentissage supervisé
3. Evaluation de l'apprentissage supervisé
4. Exemples de modèles de classification
5. Explicabilité intrinsèque
6. Explicabilité après-coup
7. Sélection de travaux liés à l'explicabilité

**Interrompez-moi quand vous voulez**

# Introduction à l'intelligence artificielle

---

**Survol de  
l'historique de  
l'intelligence  
artificielle**

---

# Définition d'Intelligence Artificielle

---

*La construction de programmes informatiques qui s'adonnent à des tâches qui sont, pour l'instant, accomplies de façon plus satisfaisante par des êtres humains car elles demandent des processus mentaux de haut niveau tels que : l'apprentissage perceptuel, l'organisation de la mémoire et le raisonnement critique.*

**Marvin Lee Misky**



<https://history.computer.org/pioneers/minsky.html>

# Dans les faits

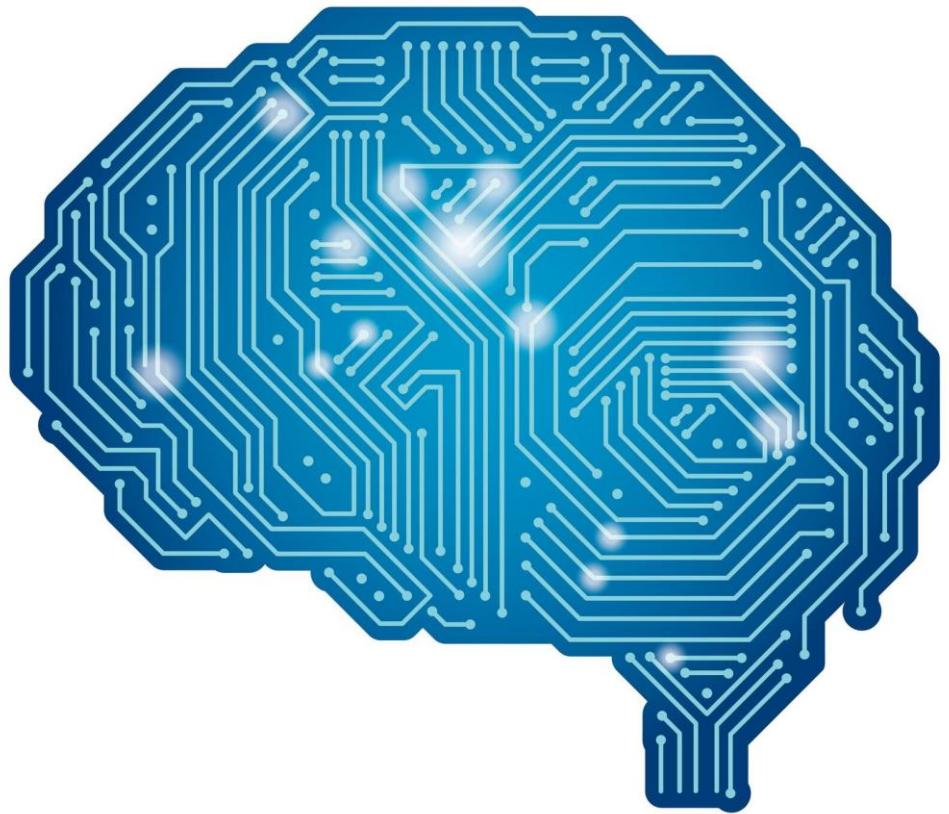
---

## Avant 2013

Systèmes symboliques, optimisation basée sur des heuristiques, algorithmes codés en dur

## Depuis 2013

Apprentissage profond



# 1666 - *Calculus ratiocinator* de Gottfried Wilhelm Leibniz

---

## Idée

une **méthode** qui permettrait de **démêler le vrai du faux** dans toute discussion dont les termes seraient exprimés dans une **langue philosophique universelle**

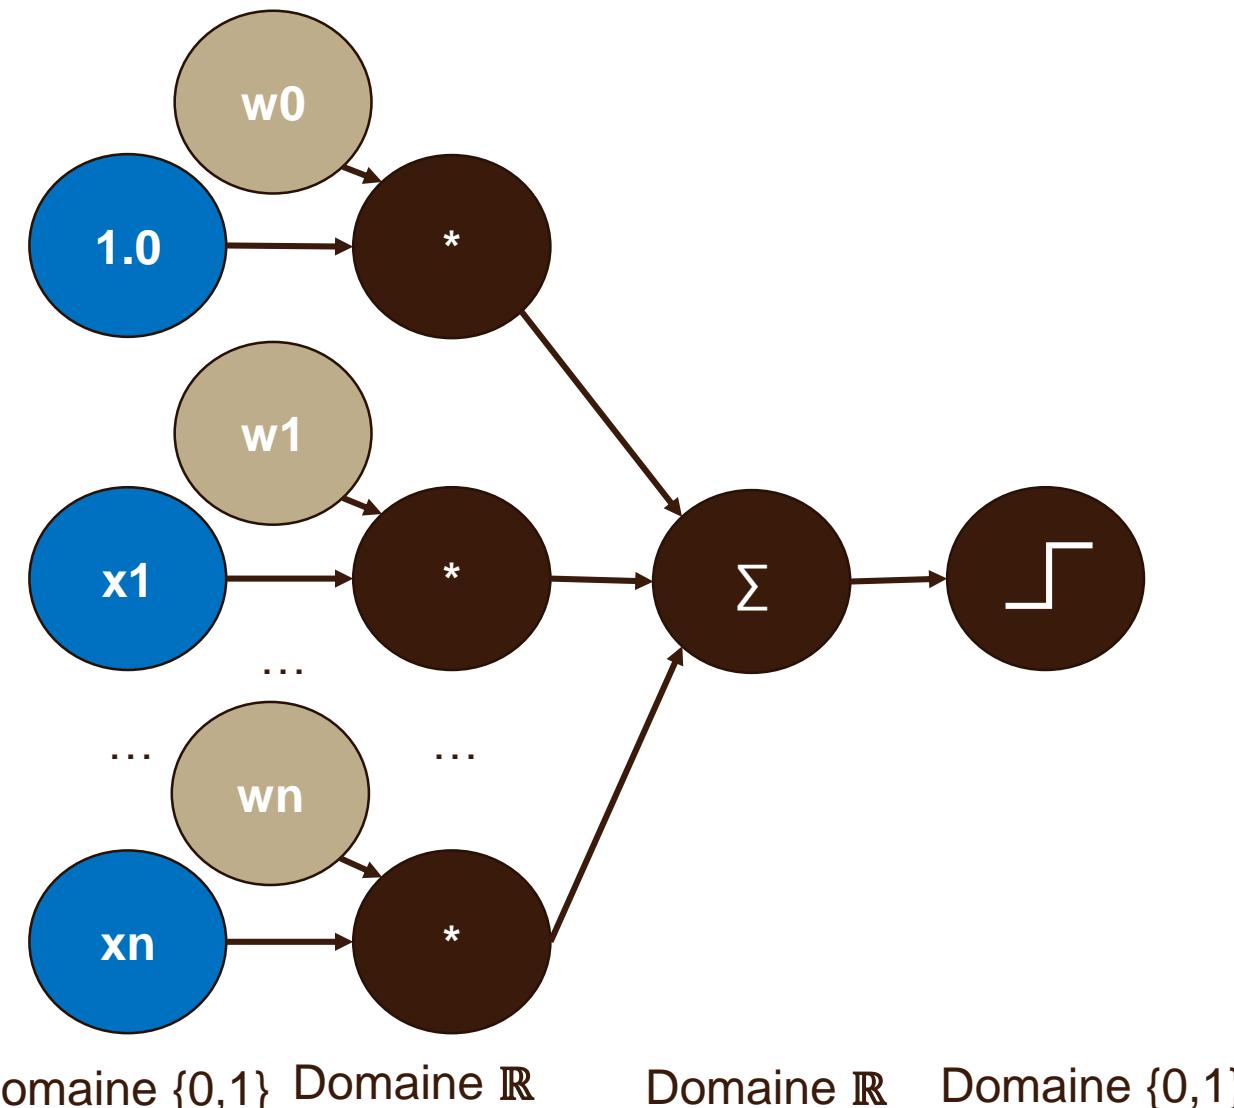
## Interprétation

- méthode : algorithme implémenté sur une machine
- démêler le vrai du faux : intelligence artificielle
- langue philosophique universelle : langage de programmation



# 1943 – Neurone formel de Warren McCulloch et Walter Pitts

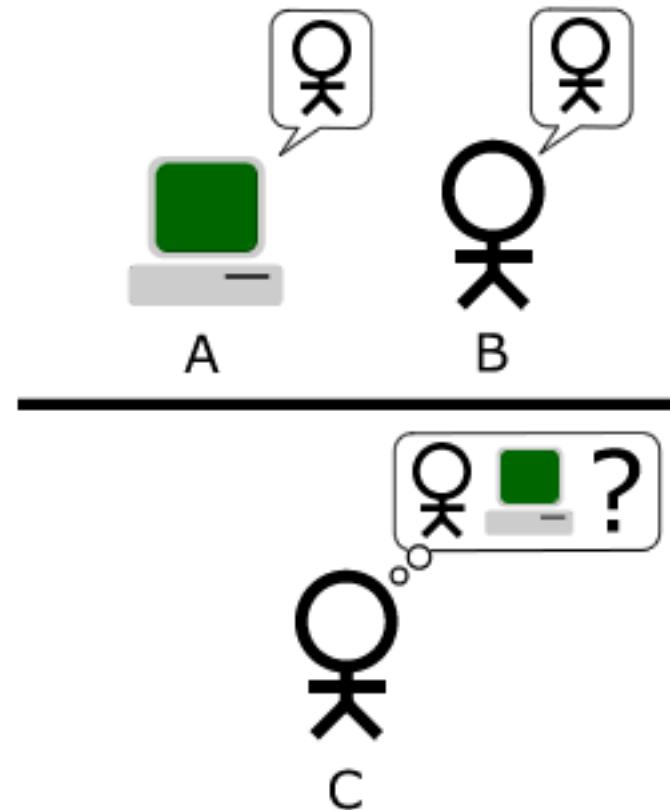
- Modélisation d'après des observations neurophysiologiques et anatomiques
- Somme pondérée binaire avec fonction d'activation à seuil



# 1950 – Test de Turing

---

- Proposition de test d'intelligence artificielle fondé sur la faculté d'une machine à imiter la conversation humaine.
- Prédiction : à l'an 2000, les machines avec 128 Mo de mémoire seront capables de tromper environ 30 % des juges humains durant un test de 5 minutes.
- Aucune machine n'a encore passé ce test



[https://fr.wikipedia.org/wiki/Test\\_de\\_Turing](https://fr.wikipedia.org/wiki/Test_de_Turing)

# 1955 – Logic theorist par Allen Newell, Herbert Simon et Cliff Shaw

- 1<sup>er</sup> raisonnement symbolique
- Capable de prouver 38 des 52 théorèmes des *Principia Mathematica* de Whitehead et Russell

\*54·43.  $\vdash \alpha, \beta \in 1. \supset : \alpha \cap \beta = \Lambda . \equiv . \alpha \cup \beta \in 2$

Dem.

$$\begin{aligned} \vdash *54·26. \supset \vdash \alpha = \iota'x. \beta = \iota'y. \supset : \alpha \cup \beta \in 2 . \equiv . x \neq y . \\ [\ast51·231] & \equiv . \iota'x \cap \iota'y = \Lambda . \\ [\ast13·12] & \equiv . \alpha \cap \beta = \Lambda \quad (1) \\ \vdash .(1). *11·11·35. \supset & \\ \vdash .(\exists x, y). \alpha = \iota'x. \beta = \iota'y. \supset : \alpha \cup \beta \in 2 . \equiv . \alpha \cap \beta = \Lambda & \quad (2) \\ \vdash .(2). *11·54 . *52·1. \supset \vdash . \text{Prop} & \end{aligned}$$

From this proposition it will follow, when arithmetical addition has been defined, that  $1 + 1 = 2$ .

## The Logic Theory Machine

In the language we have constructed, we have variables (atomic sentences):  $p, q, r, A, B, C, \dots$  and connectives:  $\neg$  (not),  $\vee$  (or),  $\rightarrow$  (implies). The connectives are used to combine the variables into expressions (molecular sentences). We have already considered one example of an expression:

$$1.7 \quad \neg p \rightarrow q \vee \neg p$$

The task set for LT will be to prove that certain expressions are theorems — that is, that they can be derived by application of specified rules of inference from a set of primitive sentences or axioms.

The two connectives,  $\neg$  and  $\vee$ , are taken as primitives. The third connective,  $\rightarrow$ , is defined in terms of the other two, thus:

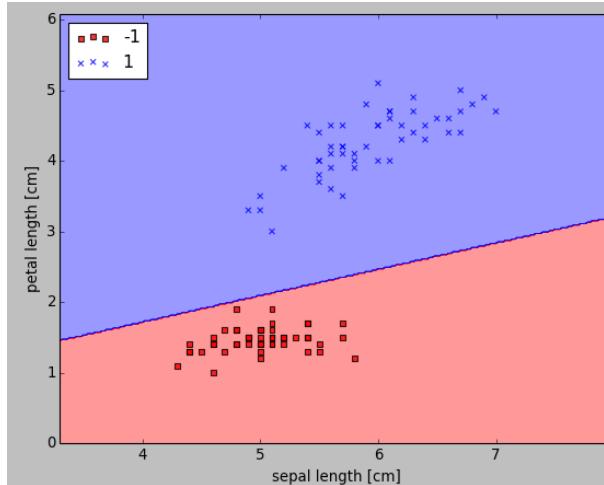
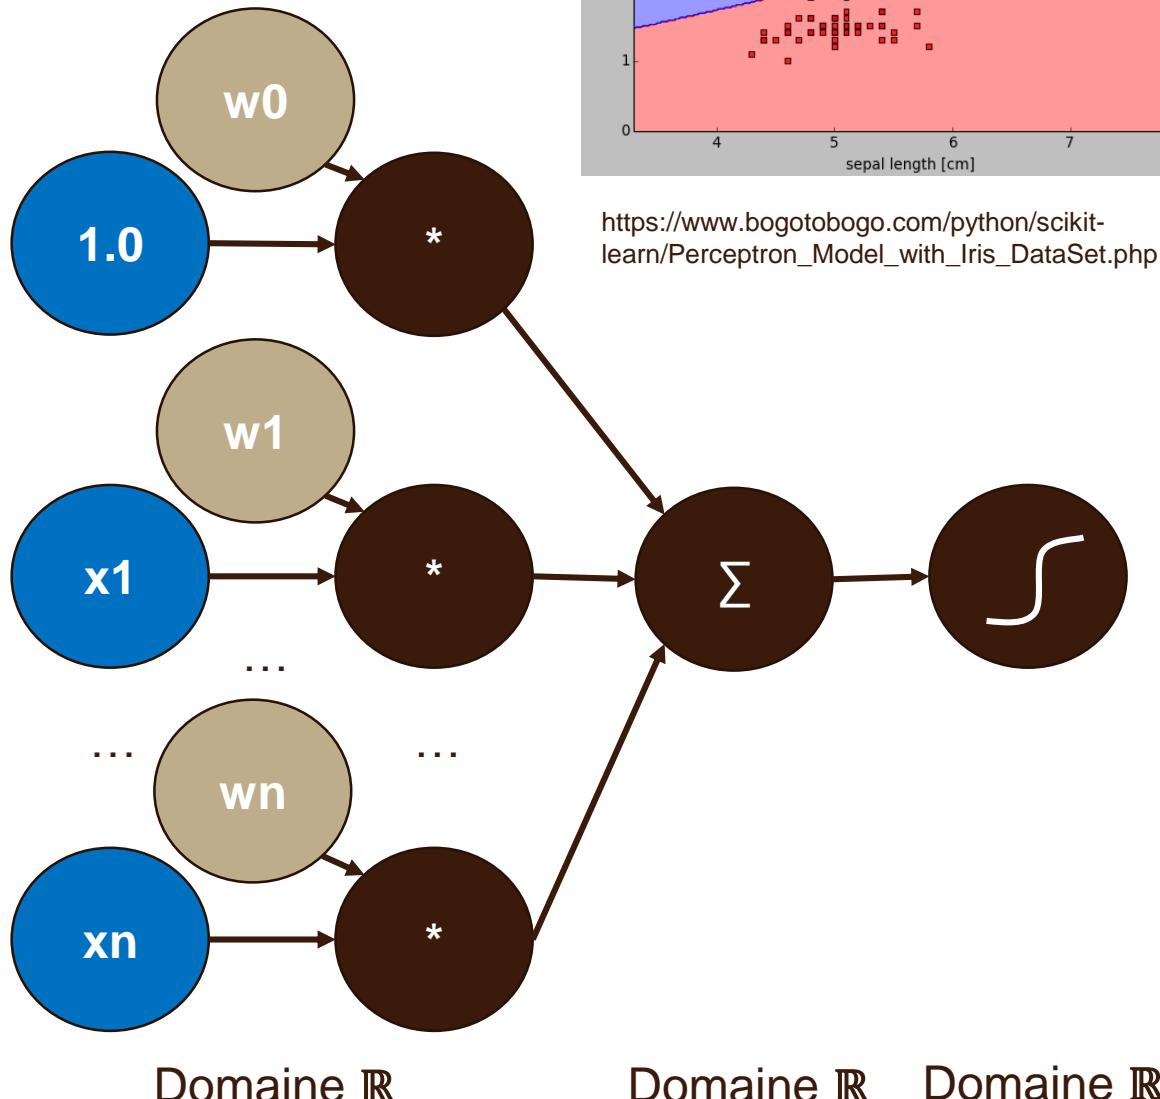
$$1.01 \quad p \rightarrow q \text{ "def" } \neg p \vee q$$

The five axioms that are postulated to be true are:

$$\begin{aligned} 1.2 & \quad p \vee p \rightarrow p \\ 1.3 & \quad p \rightarrow q \vee p \\ 1.4 & \quad p \vee q \rightarrow q \vee p \\ 1.5 & \quad p \vee q \vee r \rightarrow q \vee p \vee r \end{aligned}$$

# 1957 – Perceptron de Rosenblatt

- Classifieur linéaire à deux classes
- Elément fondamental du réseau de neurones moderne
- Différence au neurone de McCulloch et Pitts
  - Valeurs réelles plutôt que binaires
  - Accompagné d'une règle d'apprentissage



# 1959 – General Problem Solver de Herbert Simon, Cliff Shaw et Allen Newell

---

- solveur de problèmes universel : résout n'importe quel problème (simple) formalisé
- 1er programme séparant données et code

P-1584  
2-9-59  
-11-

## SUMMARY

This paper reports on a computer program, called GPS-I for General Problem Solving Program I. Construction and investigation of this program is part of a research effort by the authors to understand the information processes that underlie human intellectual, adaptive, and creative abilities. The approach is synthetic — to construct computer programs that can solve problems requiring intelligence and adaptation, and to discover which varieties of these programs can be matched to data on human problem solving.

GPS-I grew out of an earlier program, the Logic Theorist, which discovers proofs to theorems in the sentential calculus. GPS-I is an attempt to fit the recorded behavior of college students trying to discover proofs. The purpose of this paper is not to relate the program to human behavior, but to describe its main characteristics and to assess its capacities as a problem-solving mechanism. The paper will present enough theoretical discussion of problem-solving activity so that the program can be seen as an attempt to advance our basic knowledge of intellectual activity. The program will be assessed from this point of view, rather than whether it offers an economical solution to a significant class of problems.

The major features of the program that are worthy of discussion are:

# 1960 – Début du SAT (satisfaisabilité booléenne) par Davis et Putnam

---

1960 Algorithme pour prouver qu'un ensemble de clauses est satisfiable

$$\begin{aligned}(p \wedge q) \vee \neg p &\Rightarrow p = \text{faux} \\ (p \wedge \neg p) &\Rightarrow \text{pas de solution}\end{aligned}$$

1962 Algorithme pour résoudre le problème SAT

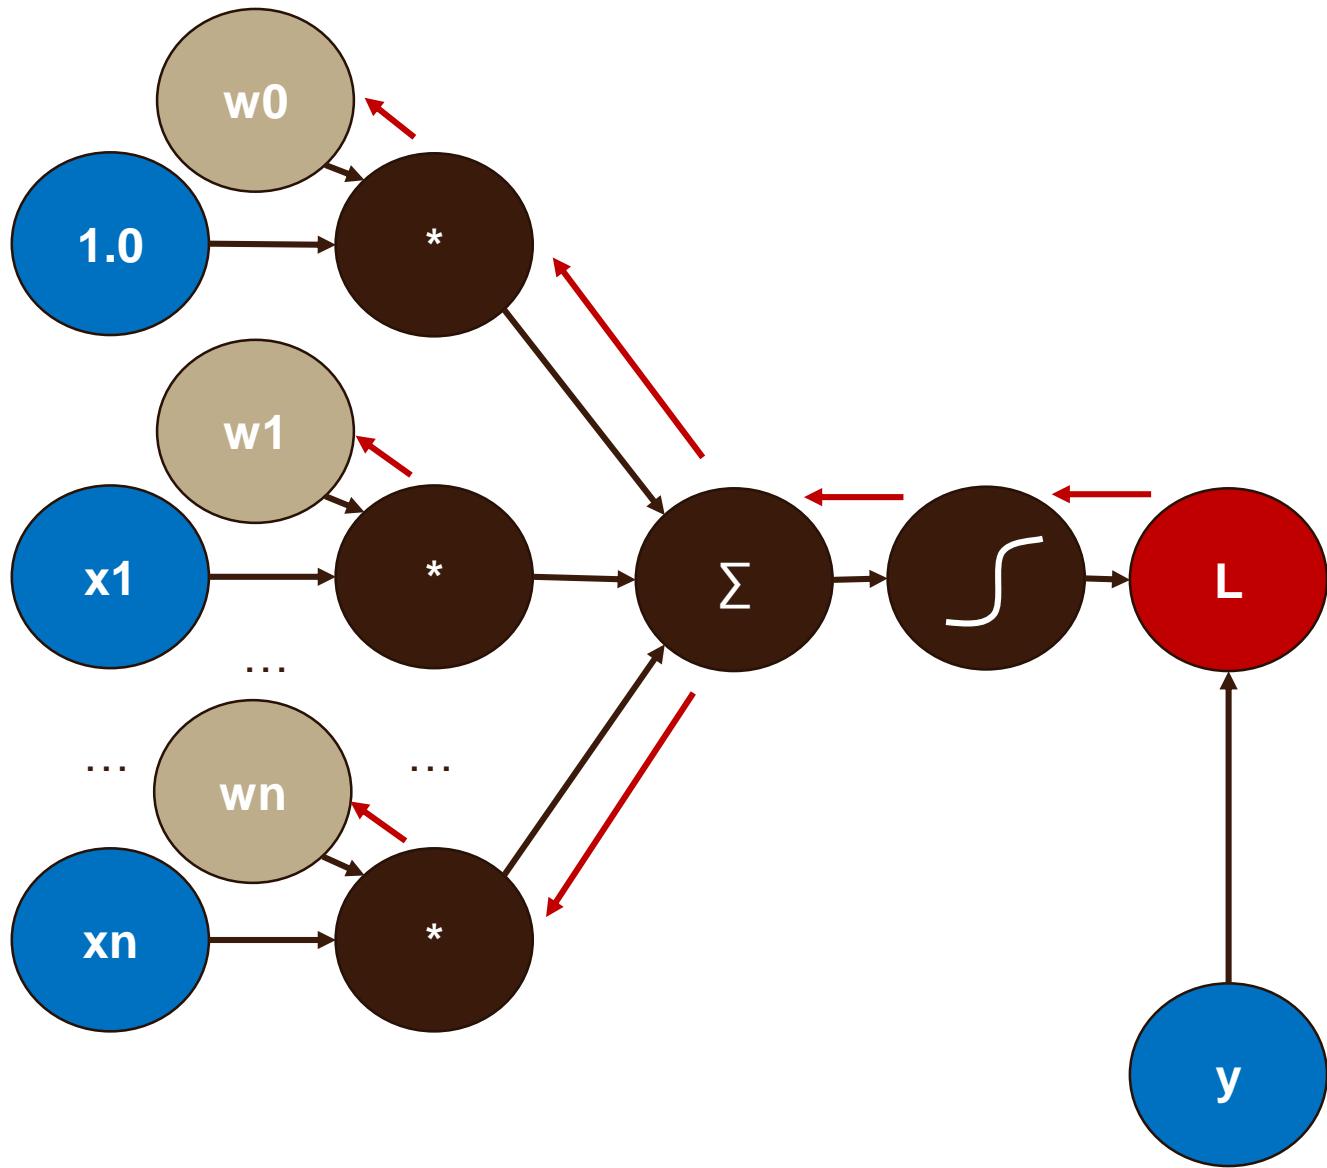
La base des solveurs modernes pour :

- Le diagnostic
- La planification
- La vérification de propriété de modèles

# 1980 – Rétropropagation du gradient

---

- Inventé plusieurs fois par différente personnes sur la même période
- Méthode actuelle d'apprentissage pour réseau de neurones
- Principe
  - Modification des poids de la sortie du graphe vers l'entrée en fonction d'une fonction de coût



# 1997 – Deep blue bat Kasparov

---

- Superordinateur de IBM (1.8m/1400kg)
- Bât le champion du monde Garry Kasparov
- Un bug a permis un coup très impressionnant qui a déstabilisé le champion



<http://www.intelligenceartificielle.org/details-deep+blue+super-ordinateur+d+ibm+-13.html>

# 2005 – Première conduite autonome sur route inconnue

---

- **2004 - Darpa Grand Challenge (230km désert)**
  - Aucune voiture ne termine
- **2005**
  - 5 véhicules sur 23 terminent

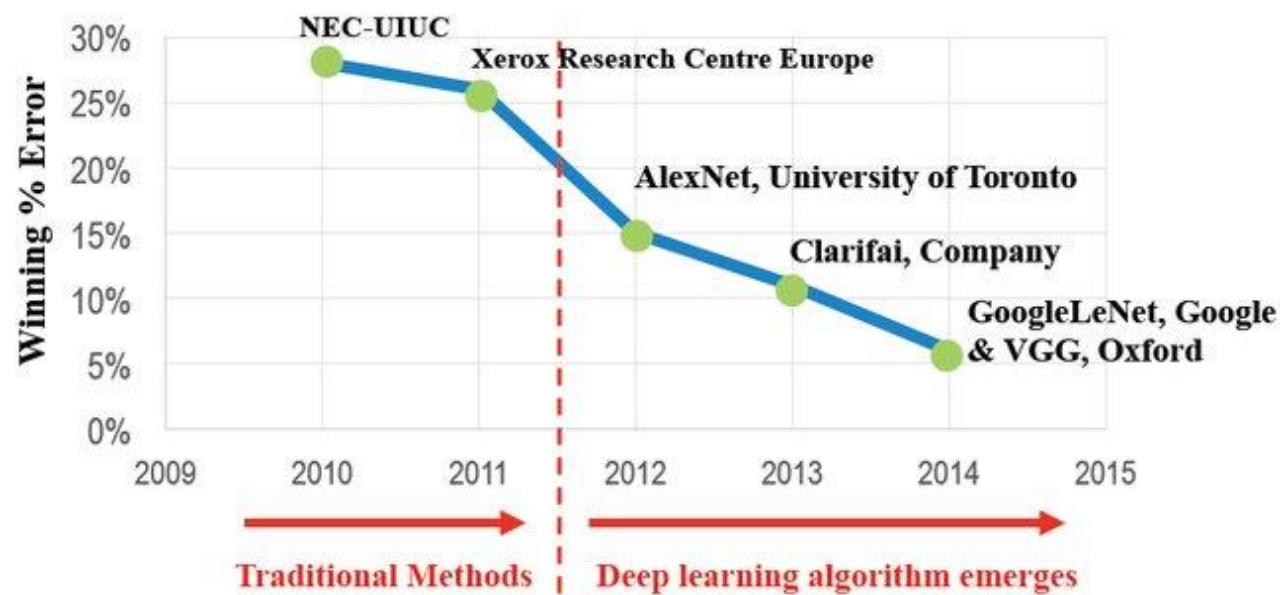


<https://www.herox.com/blog/159-the-drive-for-autonomous-vehicles-the-darpa-grand>

# 2012 – Apprentissage profond

---

- Réveil de techniques abandonnées 10 ans plus tôt
- AlexNet bat haut la main les concurrents utilisant des méthodes standards dans un concours de classification
- Depuis les performances ne font que s'améliorer

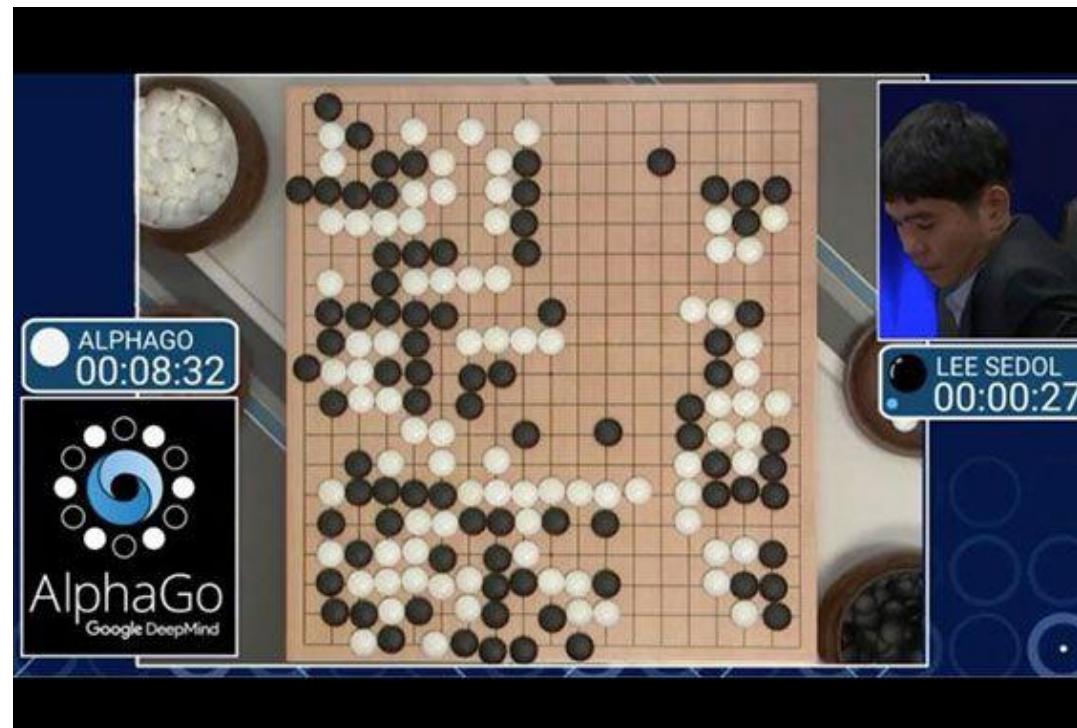


[https://www.researchgate.net/publication/329975404\\_FPGA-Based\\_Accelerators\\_of\\_Deep\\_Learning\\_Networks\\_for\\_Learning\\_and\\_Classification\\_A\\_Review](https://www.researchgate.net/publication/329975404_FPGA-Based_Accelerators_of_Deep_Learning_Networks_for_Learning_and_Classification_A_Review)

# 2015 – Alpha GO

---

- Programme de DeepMind
- 1er programme à battre différents joueurs professionnels (2015/2016/2017)
- Surpassé par Alpha Zero en 2017
- <https://github.com/leela-zero/leela-zero>



<https://www.lesaffaires.com/techno/technologie-de-l-information/la-victoire-d-alphago-contre-le-champion-du-jeu-de-go-restera-dans-l-histoire/585999>

# L'intelligence artificielle dans la vie quotidienne

---

## Aujourd'hui

- Traduction automatique
- Planification de trajet
- Assistant personnel
- Upscaling jeux ou vidéos

## Demain

- Voiture intelligente
- Jeux Vidéos
- Œuvres artistiques
- Enseignement



# Généralités sur l'apprentissage supervisé

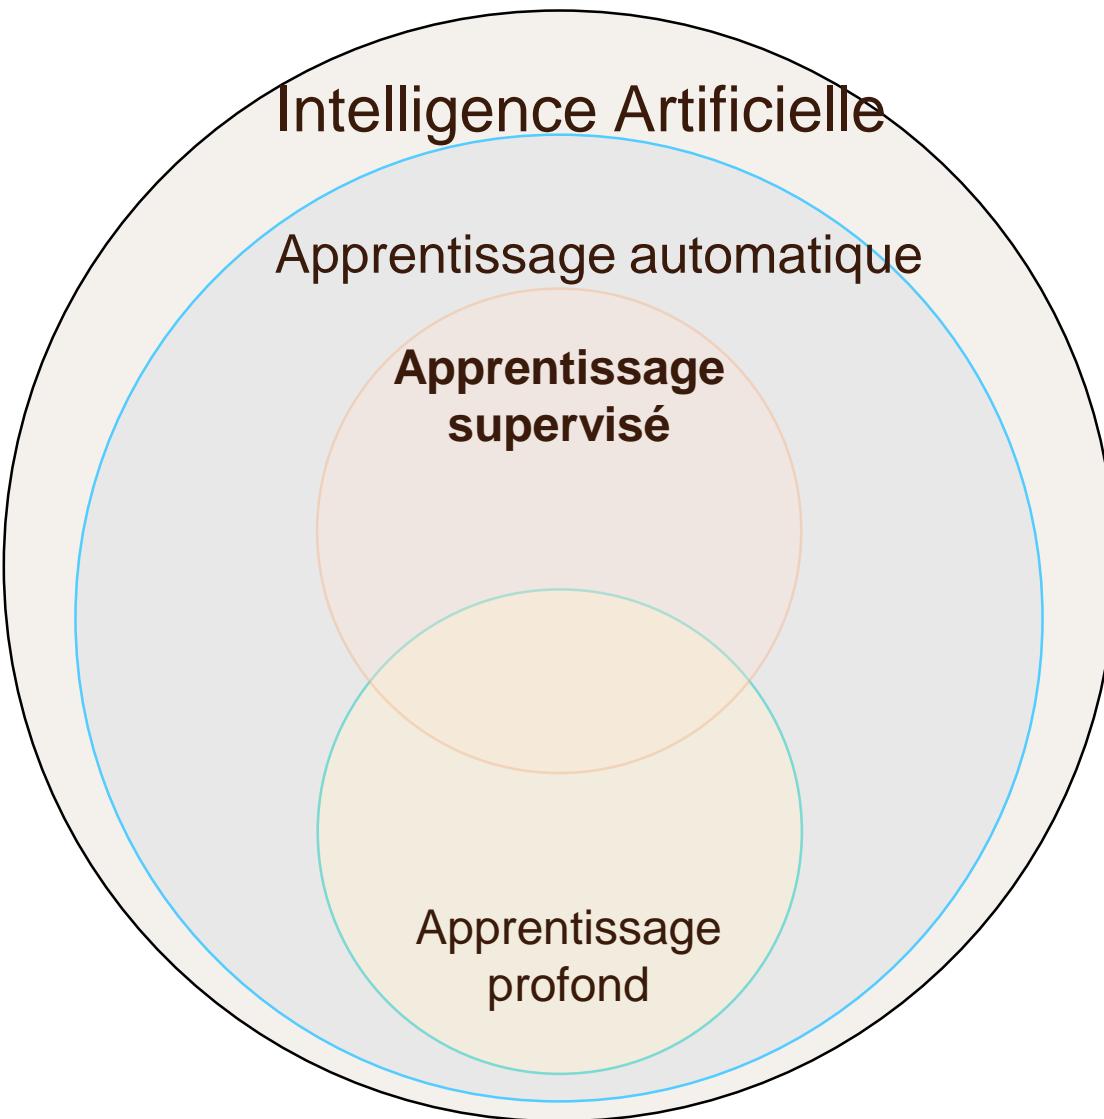
---

**On se focalise sur  
l'aspect  
apprentissage  
supervisé et on  
ignore les autres  
aspects de  
l'intelligence  
artificielle**

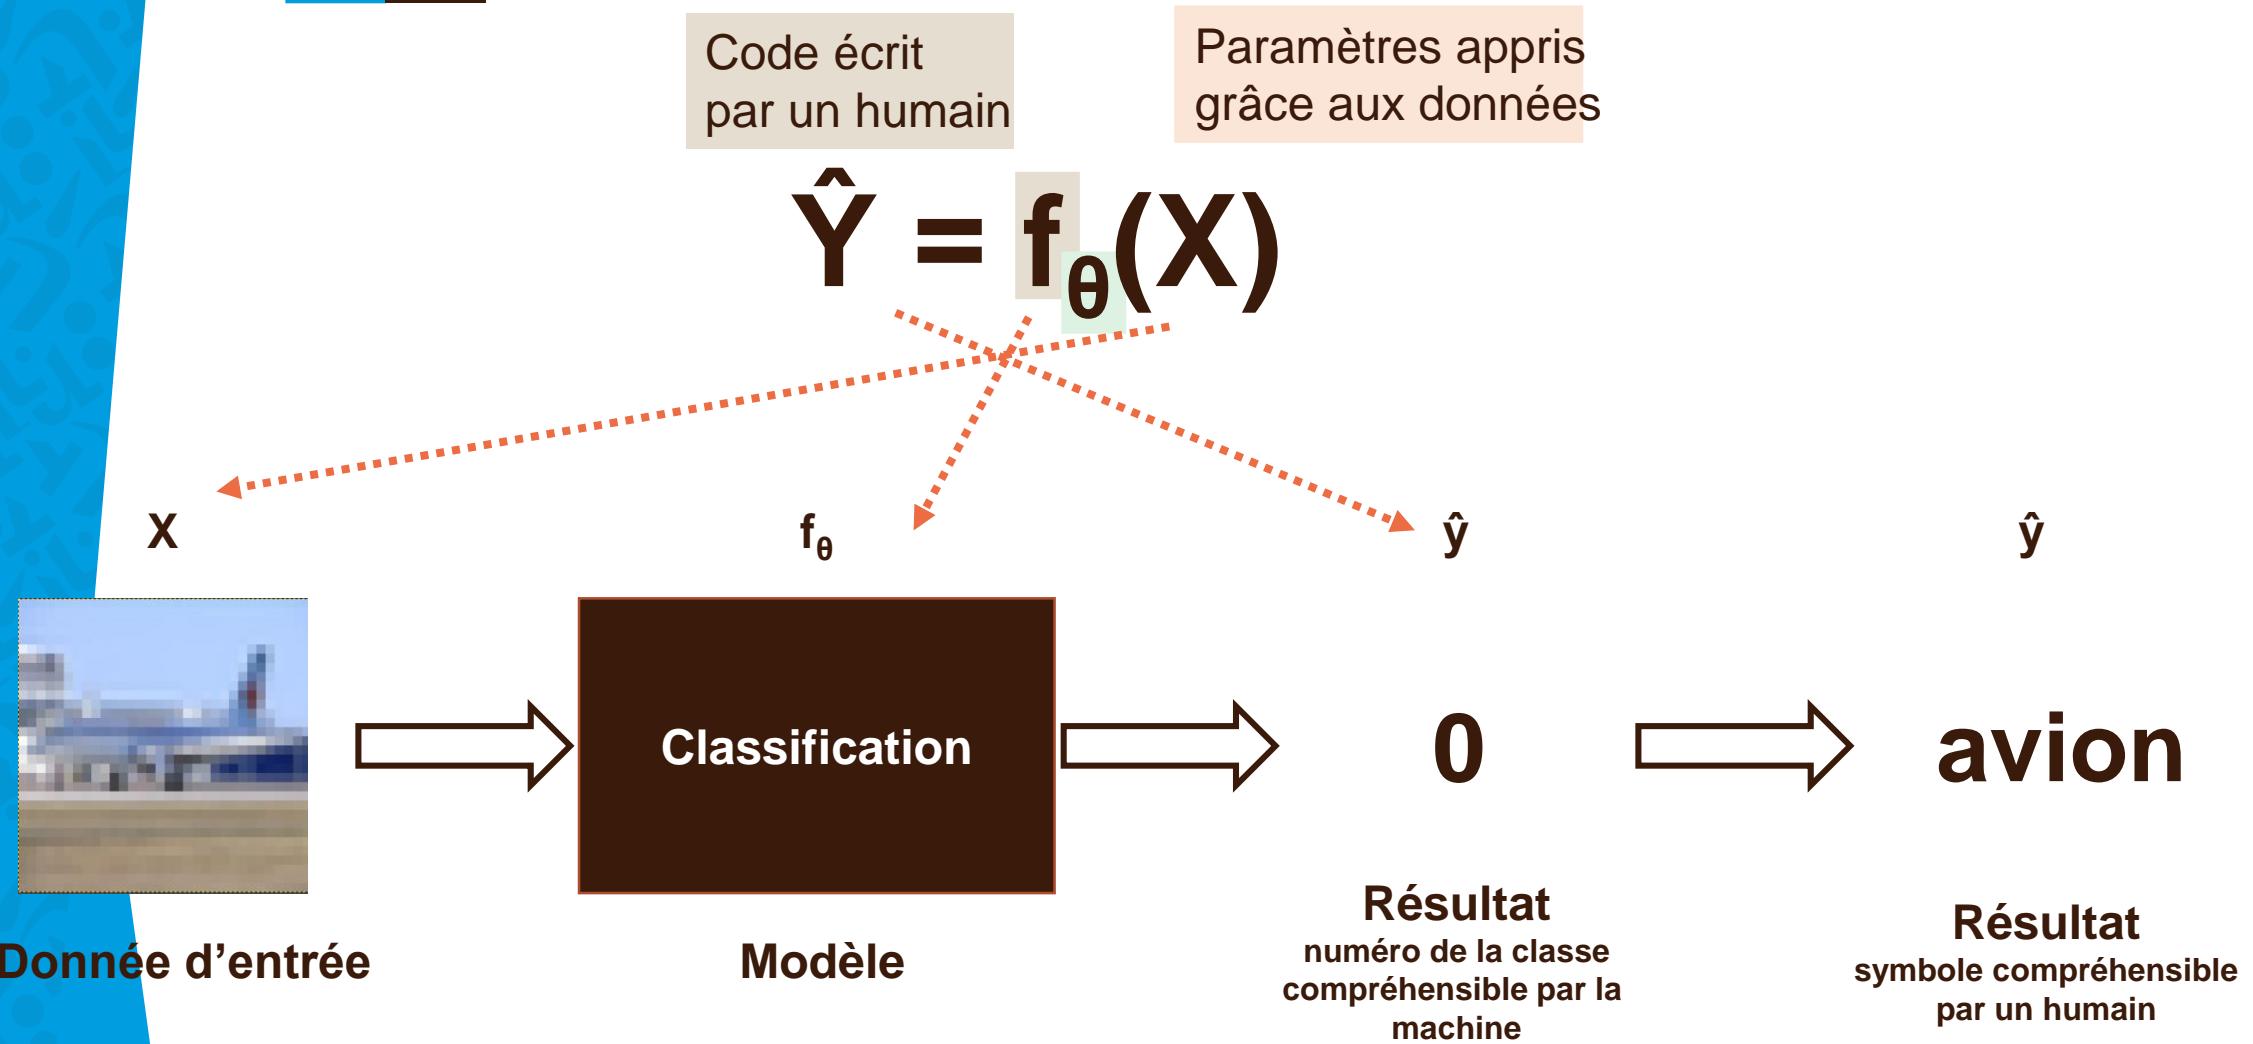
---

# Positionnement de l'apprentissage supervisé

---

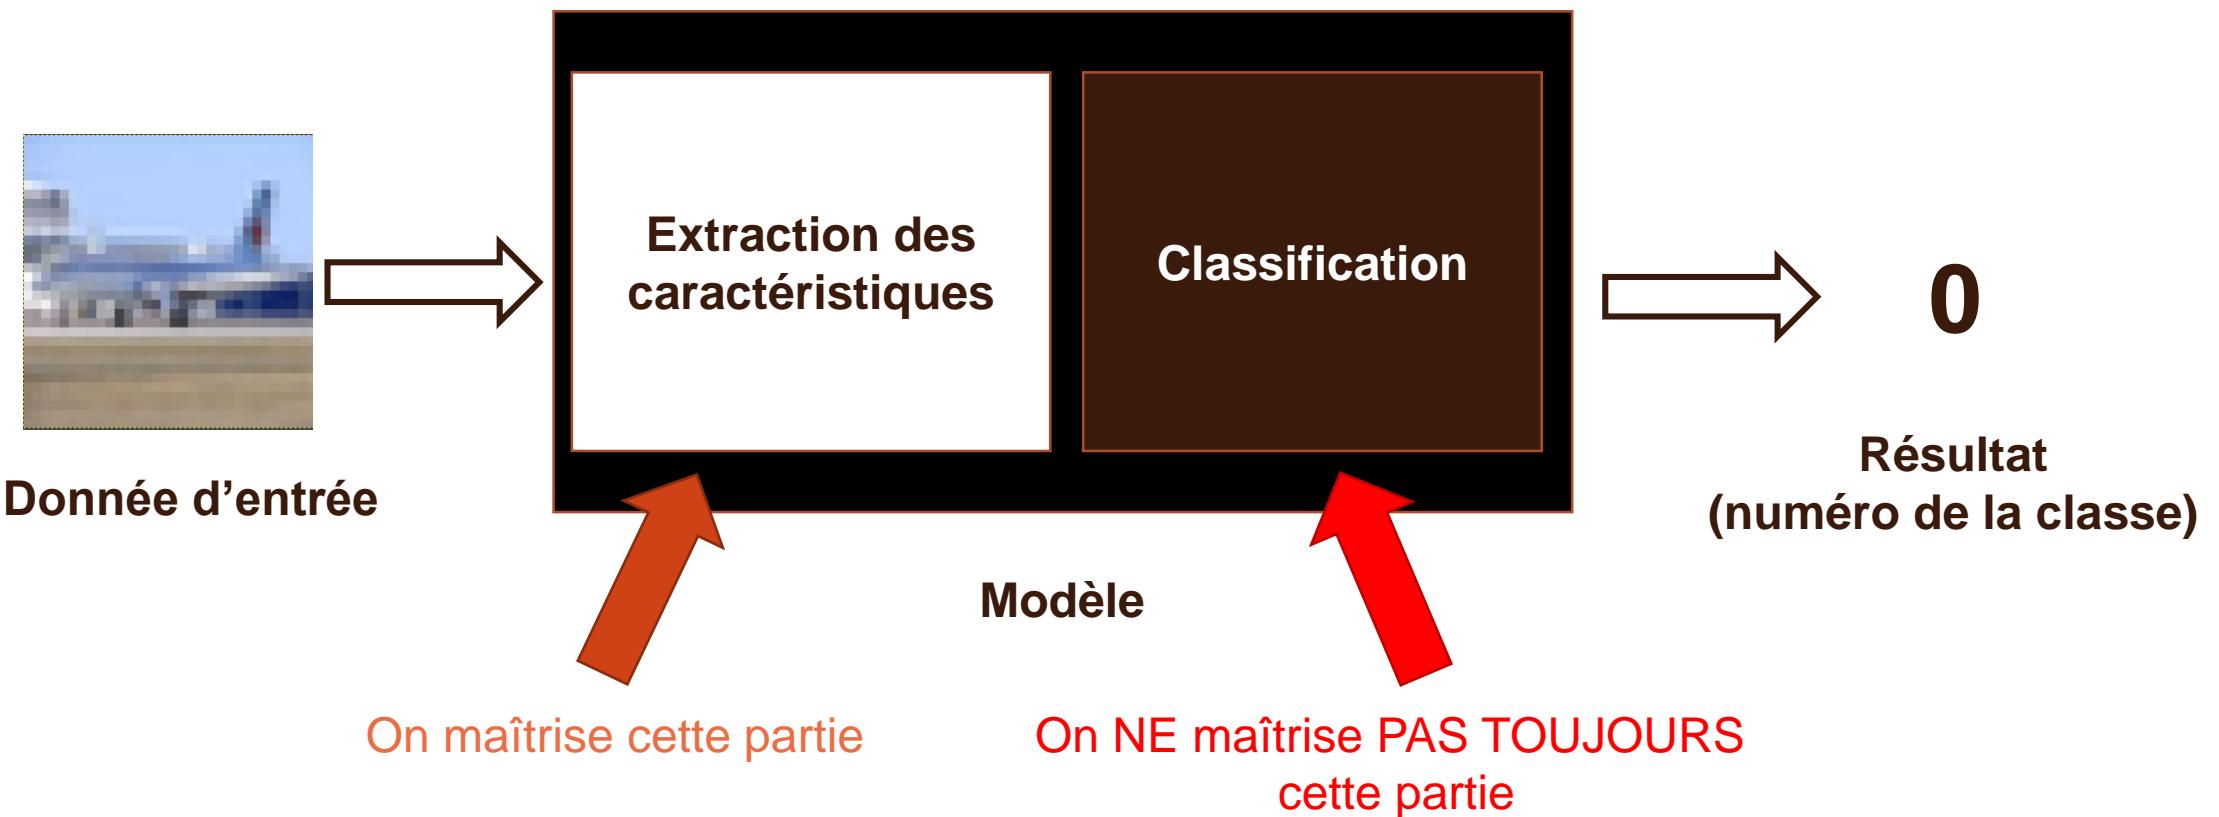


# Un modèle de classification prédit une classe



# Les données d'entrée doivent être transformées pour être exploitable par la machine

---

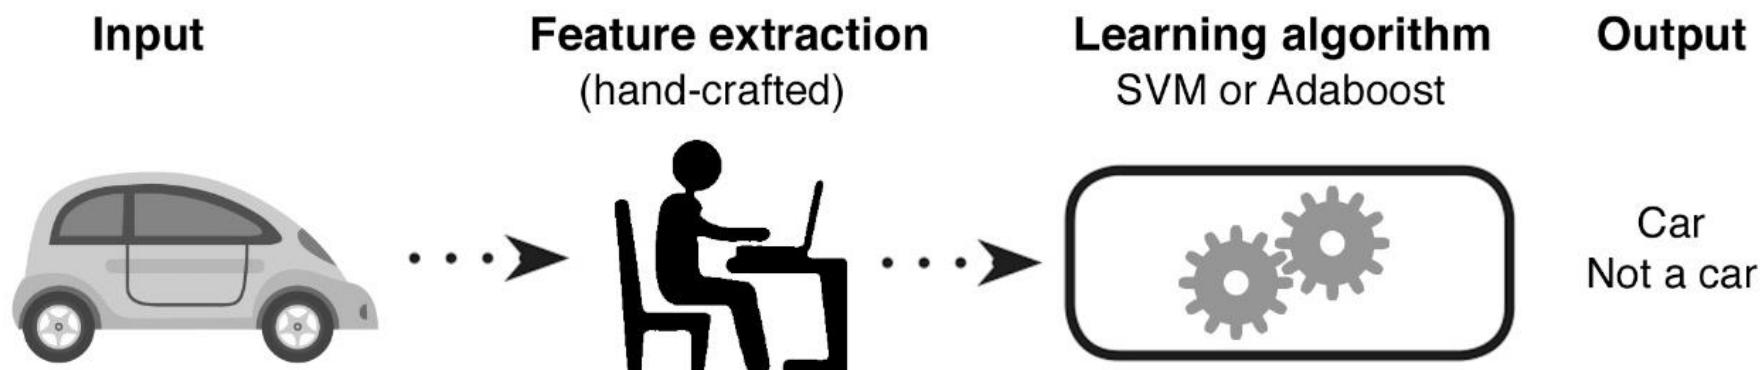


# Généralités sur l'extraction de caractéristiques

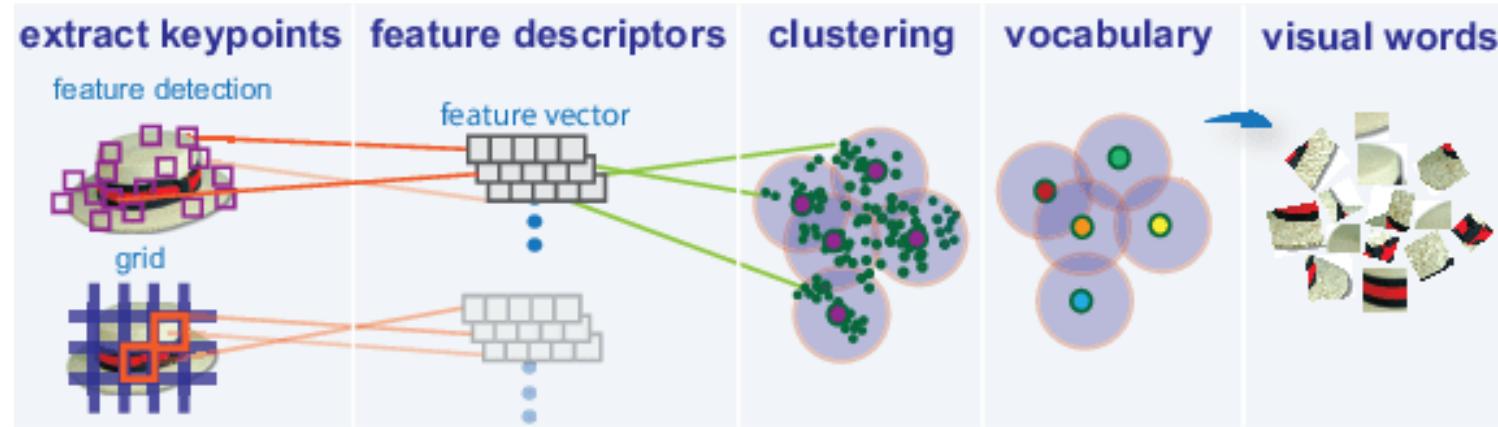
---

- Les données brutes ne peuvent pas être utilisées directement
- Il faut extraire des informations
- De nombreuses méthodes générales existent

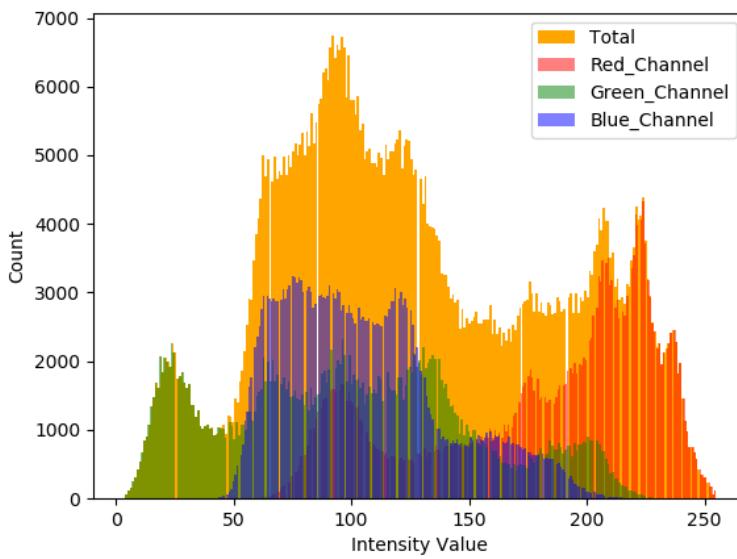
**Il est nécessaire d'être expert des données pour extraire des caractéristiques pertinentes**



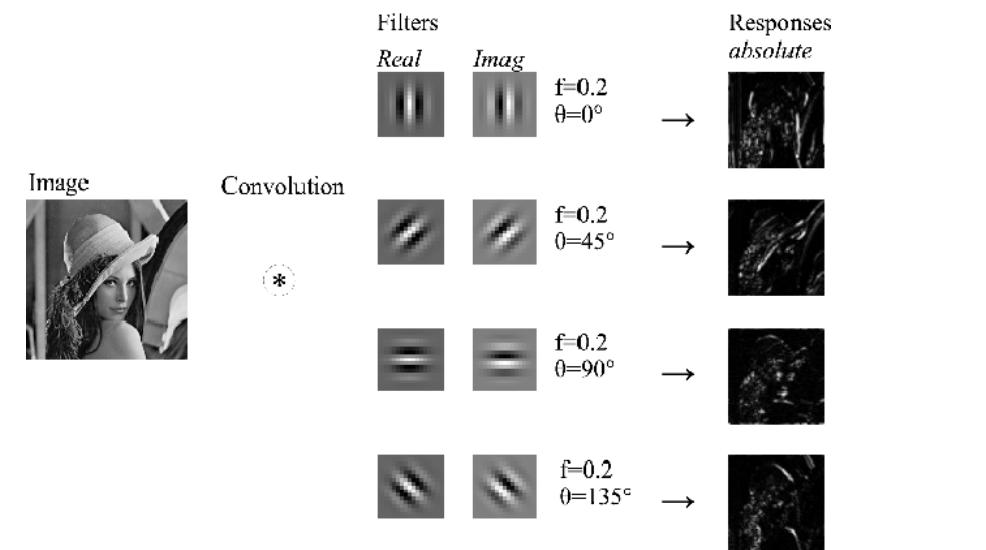
# Extraction de caractéristique - Image



<https://www.mathworks.com/help/vision/ug/image-classification-with-bag-of-visual-words.html>

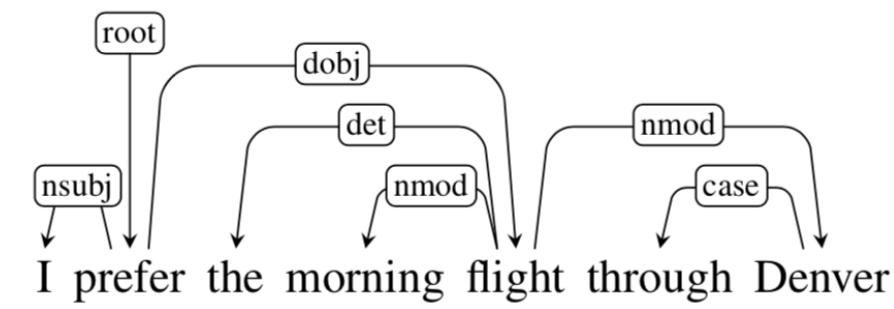
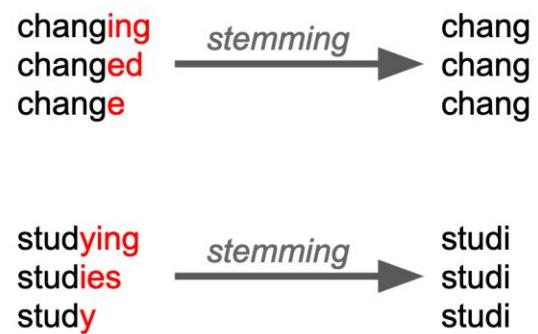
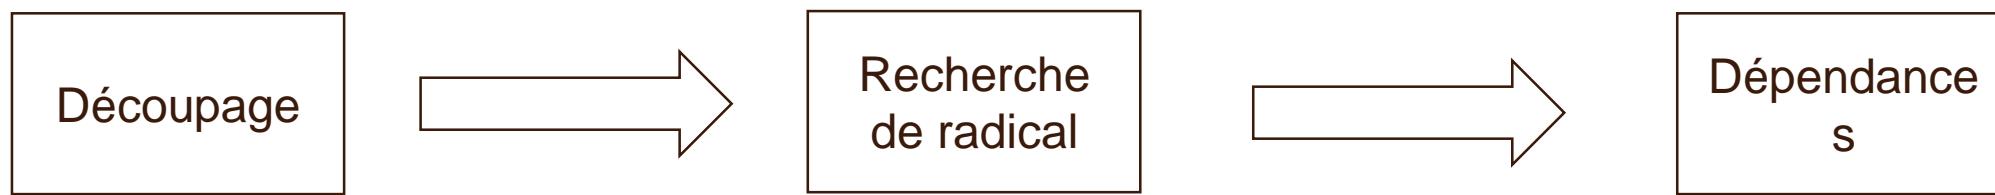


[https://miro.medium.com/v2/resize:fit:640/1\\*Vd5OY8LRaybkFj2NjBbpbA.png](https://miro.medium.com/v2/resize:fit:640/1*Vd5OY8LRaybkFj2NjBbpbA.png)



<https://www.semanticscholar.org/paper/Gabor-features-in-image-analysis-K%C3%A4m%C3%A4r%C3%A4inen/b0bc670f8ffb469eec5253cf9d634e90fd6eda88>

# Extraction de caractéristique - Texte



# Extraction de caractéristique – Données tabulaires

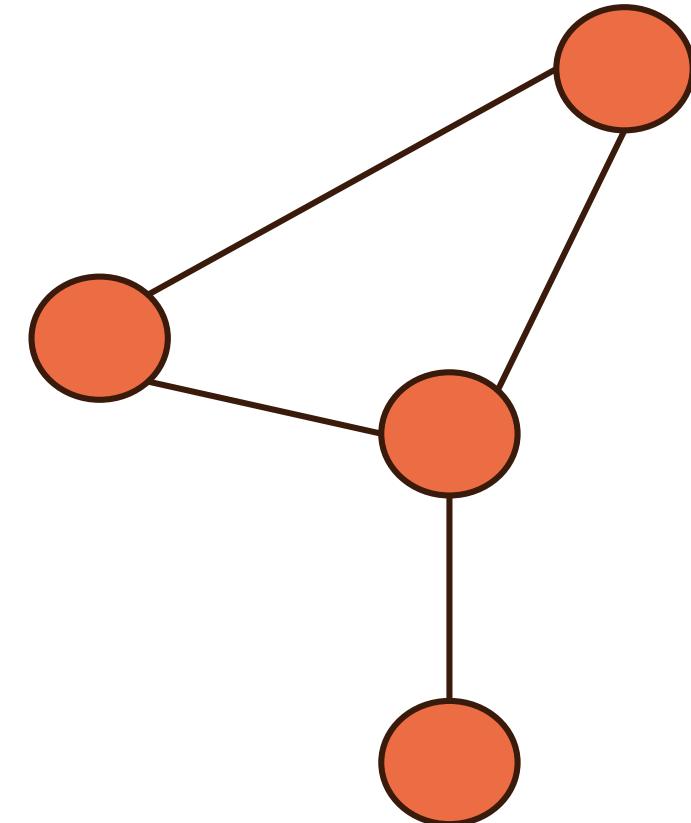
---

- Normalisation de dates
- Gestion de données manquantes
- Agrégations diverses
- ...

# Extraction de caractéristiques - Graphes

---

- Détection de communautés
- Calcul de chemins
- Calcul de plongement
- Métriques diverses
- Recherche de motifs
- ...



# Extraction de caractéristique – Données structurées

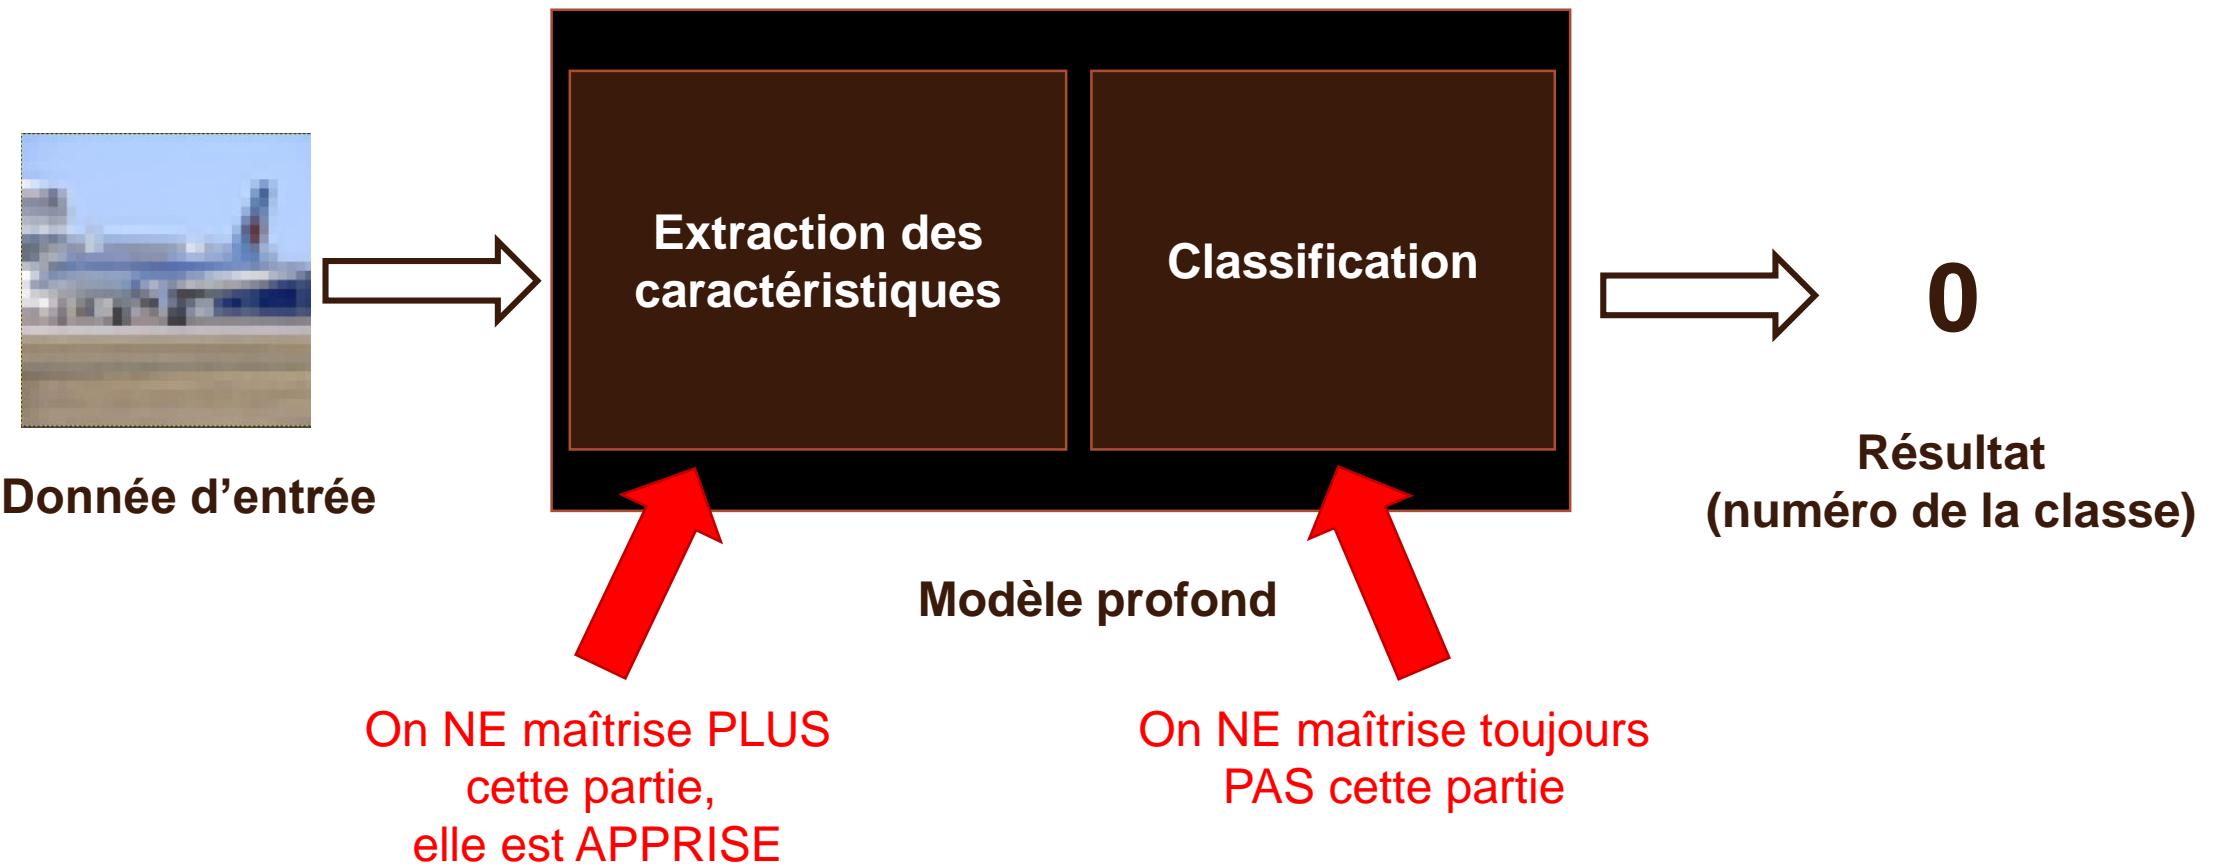
---

- Opérations spécifiques aux données

# Avec l'apprentissage profond, l'extraction devient automatique et non maîtrisée

---

Il n'est plus nécessaire d'être expert des données pour extraire des caractéristiques pertinentes



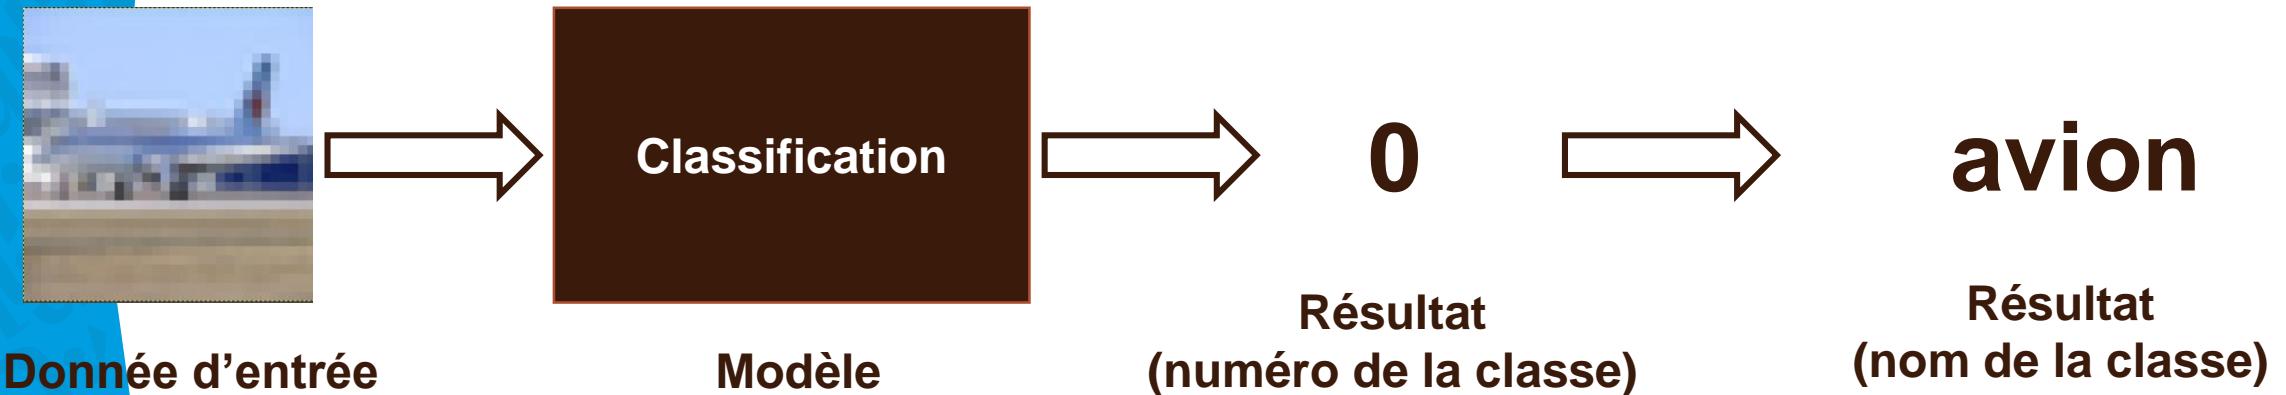
# Evaluation des modèles d'apprentissage supervisé

---

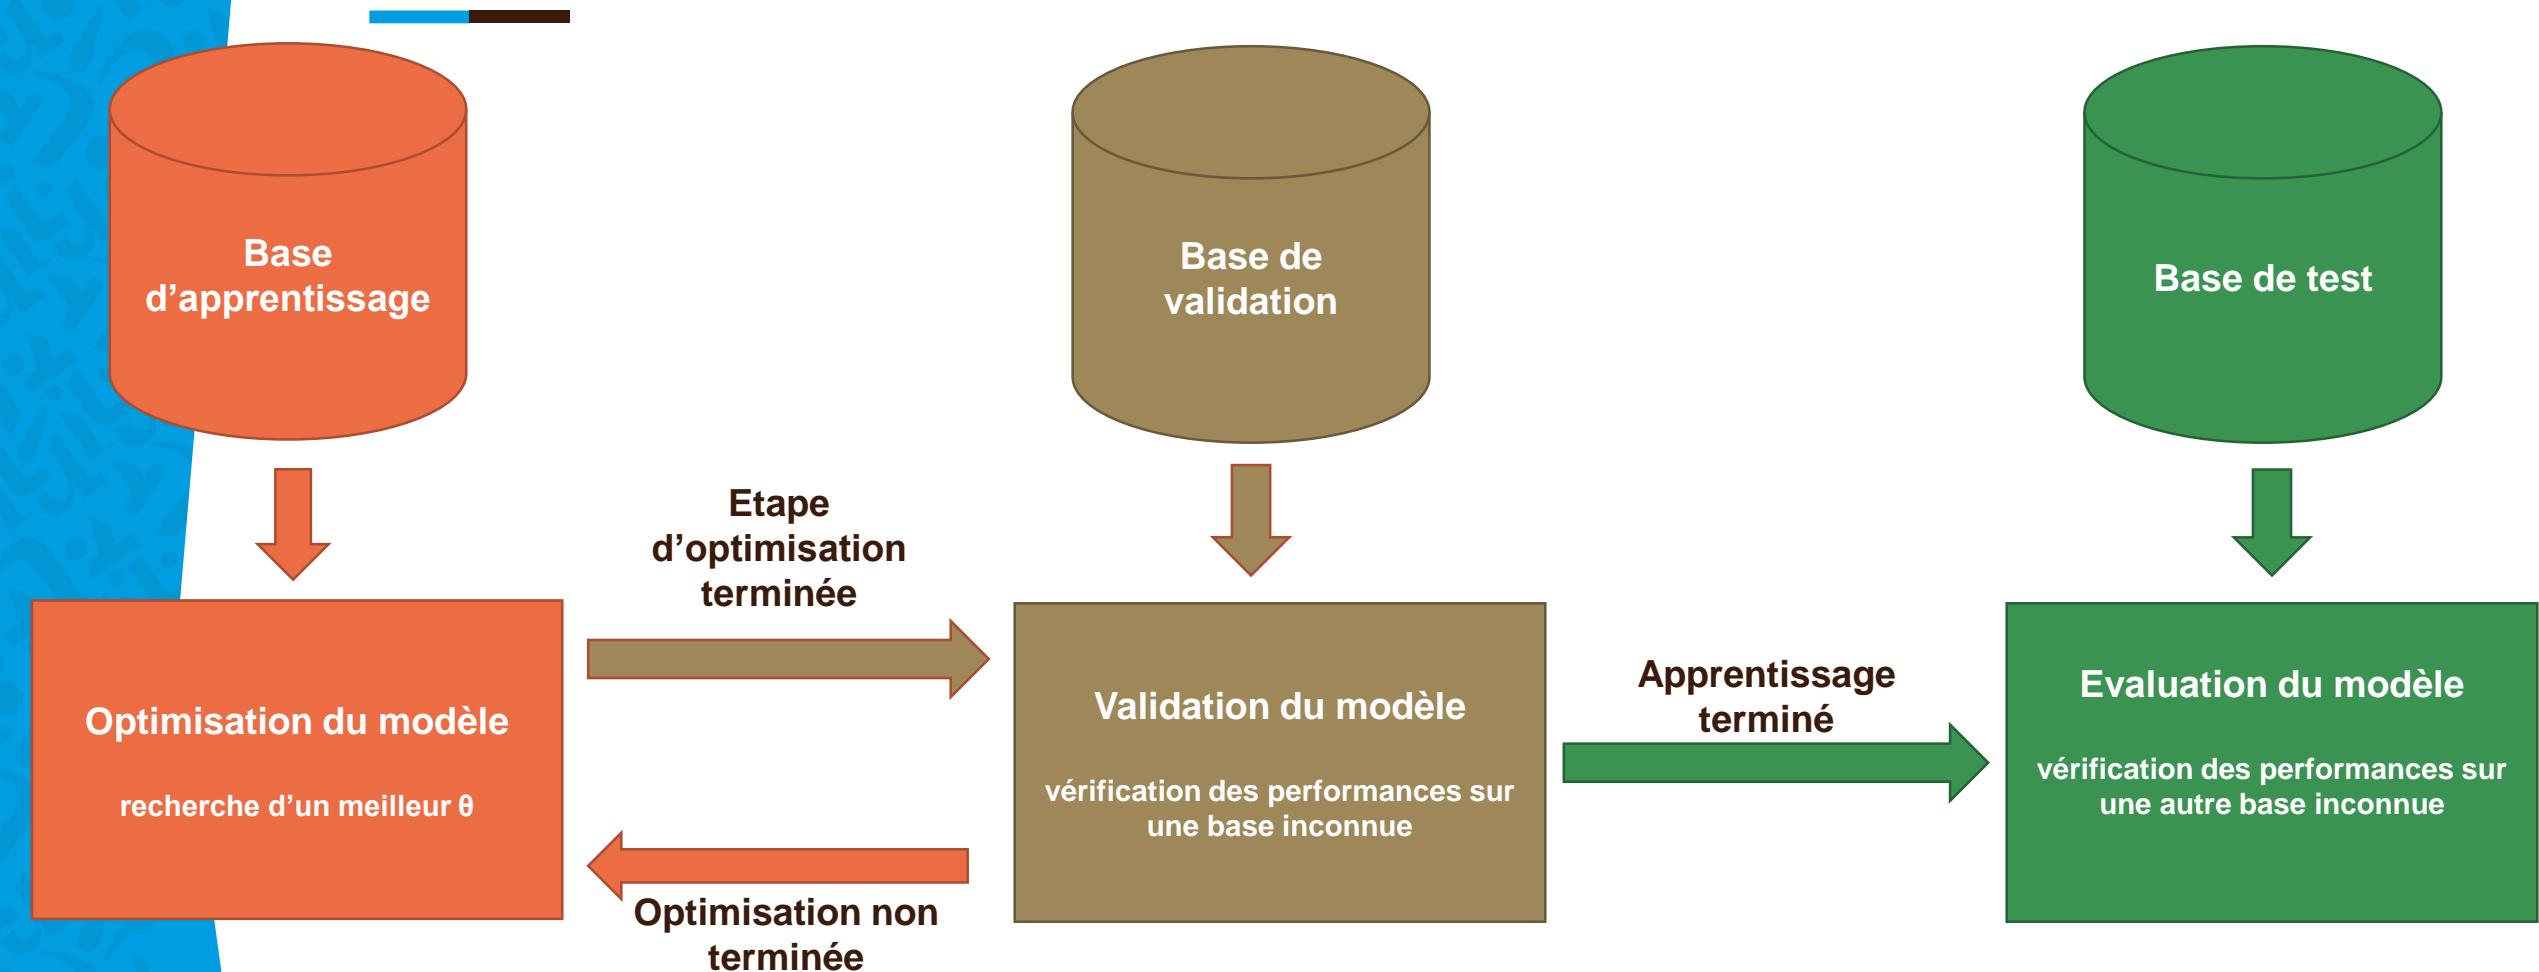
**Il est nécessaire  
d'évaluer les  
modèles pour  
connaitre leurs  
performances**

---

# Pour rappel, voici comment fonctionne un classifieur

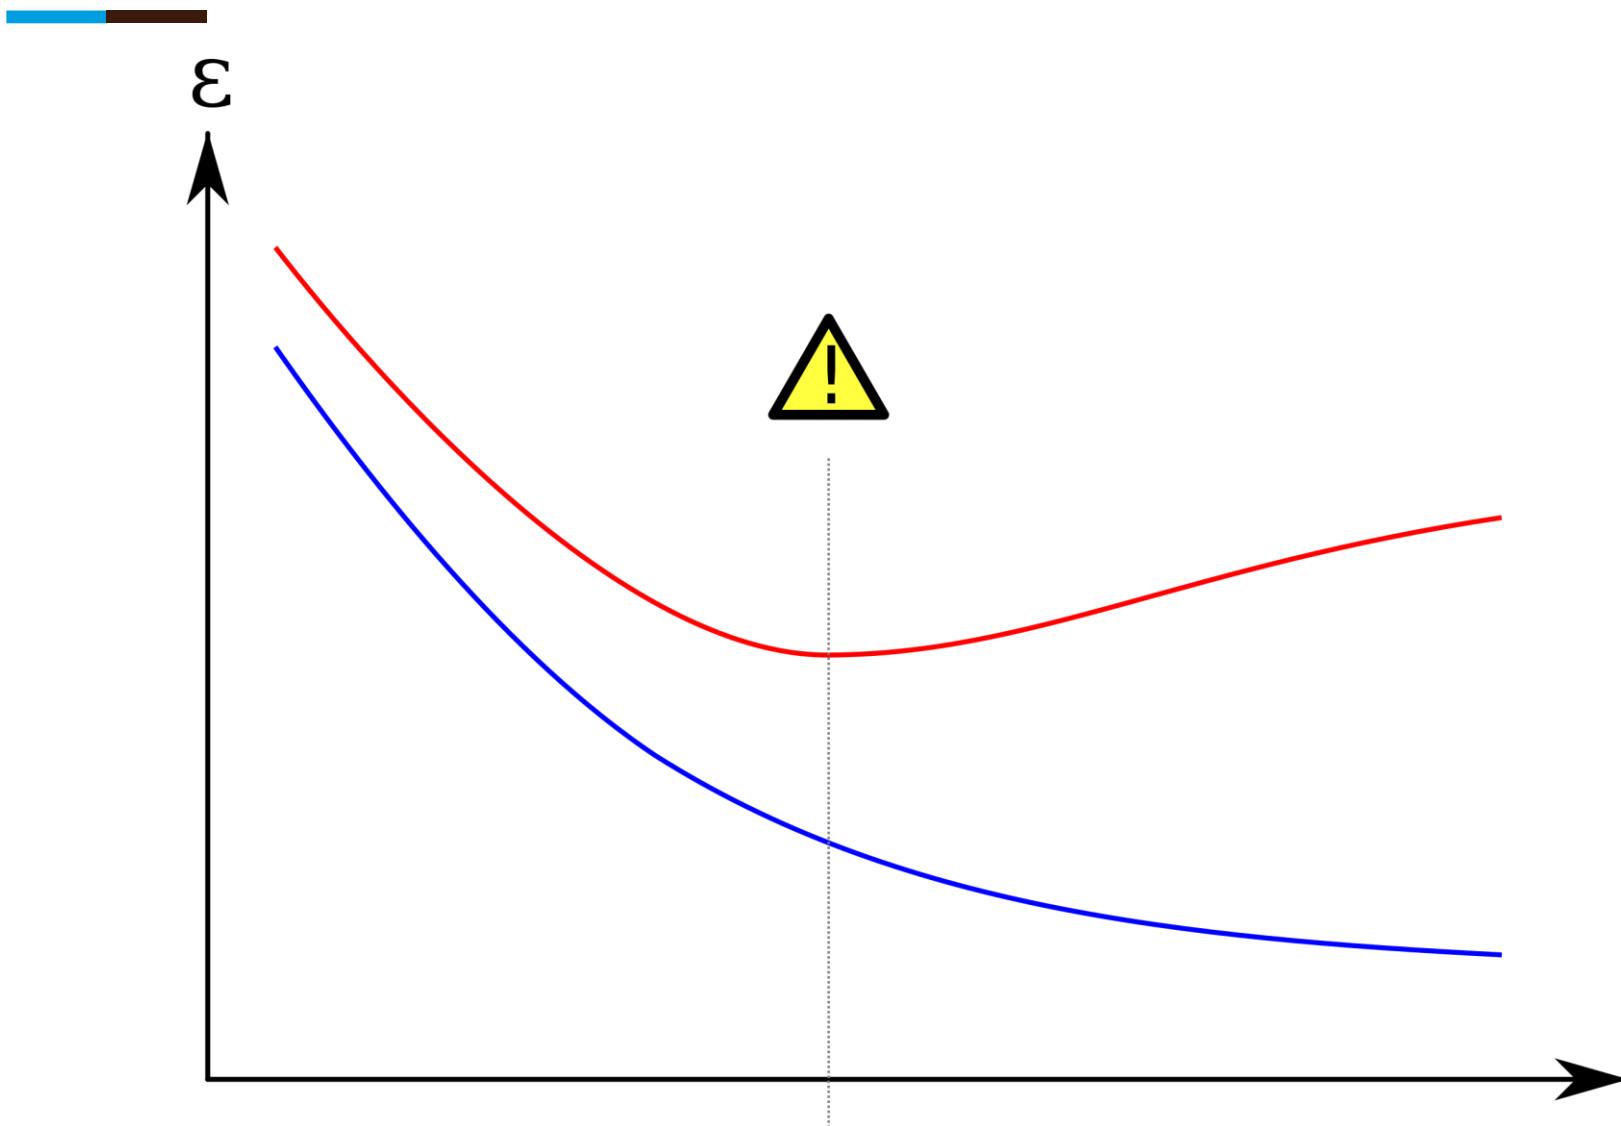


# Aparté : apprentissage d'un modèle

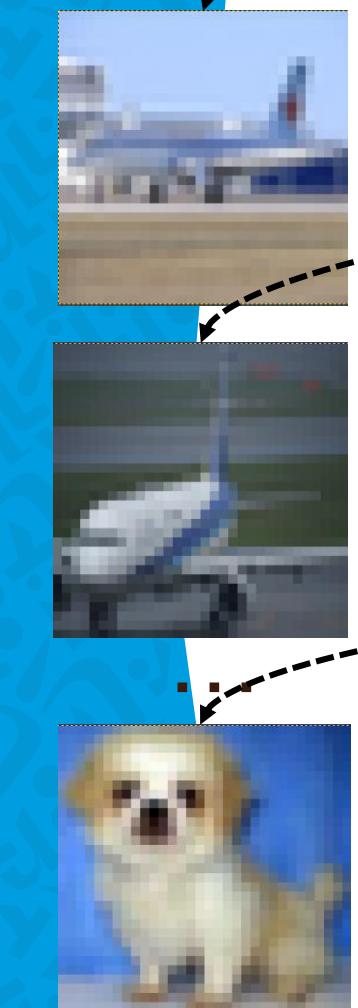


Les techniques dépendent  
bien entendu du type de  
modèle

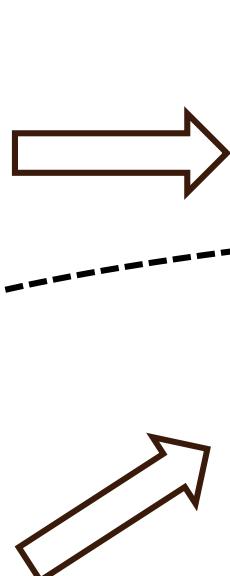
# Pourquoi autant de bases ?



# Evaluation d'un modèle de classification

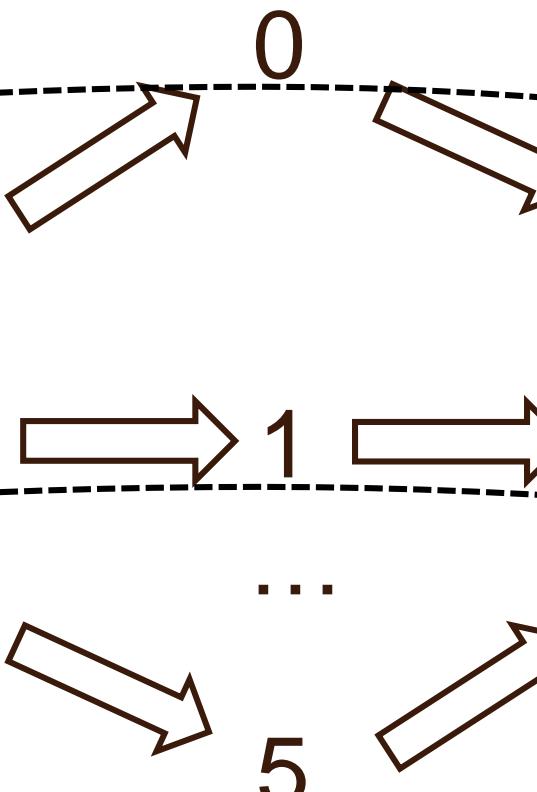


Base d'évaluation  
étiquetée



Classification

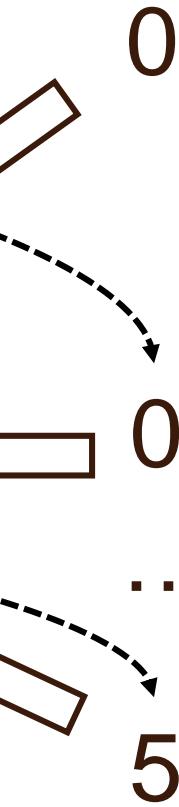
Modèle



Résultats

Evaluation

Rapport  
d'évaluation



Vérité  
terrain

# La matrice de confusion : un ensemble de compteurs pour calculer différentes métriques

---

```
[[ 828,    13,    12,    11,    18,      0,      2,      4,    85,    27],  
 [ 10,   910,     0,      5,      1,      1,      0,      1,    11,    61],  
 [ 47,      1,  708,    64,    88,    14,    63,      4,      8,      3],  
 [  3,      4,    16,  768,    33,    93,    50,    19,      4,    10],  
 [ 10,      0,    39,    43,  788,    12,    57,    43,      6,    21],  
 [  2,      0,    10,  137,    29,  777,      8,    33,      0,      4],  
 [  7,      2,    10,    54,    29,      7,  888,      1,      1,      1],  
 [ 24,      2,    14,    39,    76,    17,      4,  818,      2,      4],  
 [ 27,    14,      0,      7,      3,      0,      3,      0,  9333,    14],  
 [ 19,    64,      1,      7,      2,      1,      1,      0,    18,  887]])
```

# La matrice de confusion : un ensemble de compteurs pour calculer différentes métriques



Prédiction

	avion	voiture	oiseau	chat	cerf	chien	grenouille	cheval	bateau	camion
avion	828	13	12	11	18	0	2	4	85	27
voiture	10	910	0	5	1	1	0	1	11	61
oiseau	47	1	708	64	88	14	63	4	8	3
chat	3	4	16	768	33	93	50	19	4	10
cerf	10	0	39	43	788	12	57	43	6	2
chien	2	0	10	137	29	777	8	33	0	4
grenouille	7	2	10	54	29	7	888	1	1	1
cheval	24	2	14	39	76	17	4	818	2	4
bateau	27	14	0	7	3	0	3	0	9333	14
camion	19	64	1	7	2	1	1	0	18	887

# Chaque ligne représente les exemples appartenant à une classe précise

---

Prédiction

Vérité terrain	avion	voiture	oiseau	chat	cerf	chien	grenouille	cheval	bateau	camion	total
avion	828	13	12	11	18	0	2	4	85	27	1000
voiture	10	910	0	5	1	1	0	1	11	61	1000
oiseau	47	1	708	64	88	14	63	4	8	3	1000
chat	3	4	16	768	33	93	50	19	4	10	1000
cerf	10	0	39	43	788	12	57	43	6	2	1000
chien	2	0	10	137	29	777	8	33	0	4	1000
grenouille	7	2	10	54	29	7	888	1	1	1	1000
cheval	24	2	14	39	76	17	4	818	2	4	1000
bateau	27	13	0	7	3	0	3	0	933	14	1000
camion	19	64	1	7	2	1	1	0	18	887	1000

# Chaque colonne représente les exemples classé dans une classe précise



Prédiction

	avion	voiture	oiseau	chat	cerf	chien	grenouille	cheval	bateau	camion	total
avion	828	13	12	11	18	0	2	4	85	27	1000
voiture	10	910	0	5	1	1	0	1	11	61	1000
oiseau	47	1	708	64	88	14	63	4	8	3	1000
chat	3	4	16	768	33	93	50	19	4	10	1000
cerf	10	0	39	43	788	12	57	43	6	2	1000
chien	2	0	10	137	29	777	8	33	0	4	1000
grenouille	7	2	10	54	29	7	888	1	1	1	1000
cheval	24	2	14	39	76	17	4	818	2	4	1000
bateau	27	13	0	7	3	0	3	0	933	14	1000
camion	19	64	1	7	2	1	1	0	18	887	1000
total	977	1009	810	1135	1067	922	1076	923	1068	1013	10000

# Les cellules de la diagonale représentent le nombre d'exemples bien classés



Prédiction

	avion	voiture	oiseau	chat	cerf	chien	grenouille	cheval	bateau	camion	total
avion	828	13	12	11	18	0	2	4	85	27	1000
voiture	10	910	0	5	1	1	0	1	11	61	1000
oiseau	47	1	708	64	88	14	63	4	8	3	1000
chat	3	4	16	768	33	93	50	19	4	10	1000
cerf	10	0	39	43	788	12	57	43	6	2	1000
chien	2	0	10	137	29	777	8	33	0	4	1000
grenouille	7	2	10	54	29	7	888	1	1	1	1000
cheval	24	2	14	39	76	17	4	818	2	4	1000
bateau	27	13	0	7	3	0	3	0	933	14	1000
camion	19	64	1	7	2	1	1	0	18	887	1000
total	977	1009	810	1135	1067	922	1076	923	1068	1013	10000

# Les autres représentent les erreurs de classification



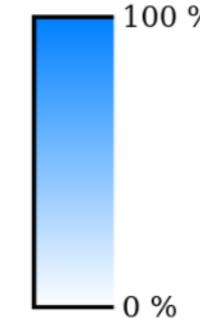
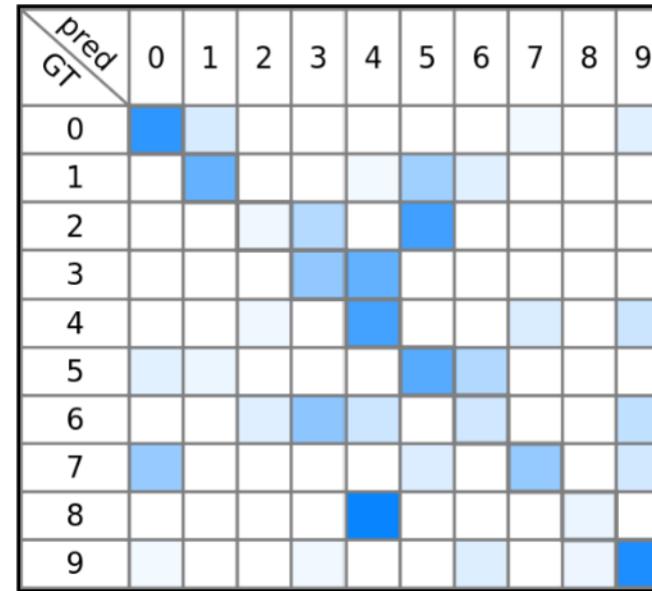
Prédiction

	avion	voiture	oiseau	chat	cerf	chien	grenouille	cheval	bateau	camion	total
avion	828	13	12	11	18	0	2	4	85	27	1000
voiture	10	910	0	5	1	1	0	1	11	61	1000
oiseau	47	1	708	64	88	14	63	4	8	3	1000
chat	3	4	16	768	33	93	50	19	4	10	1000
cerf	10	0	39	43	788	12	57	43	6	2	1000
chien	2	0	10	137	29	777	8	33	0	4	1000
grenouille	7	2	10	54	29	7	888	1	1	1	1000
cheval	24	2	14	39	76	17	4	818	2	4	1000
bateau	27	13	0	7	3	0	3	0	933	14	1000
camion	19	64	1	7	2	1	1	0	18	887	1000
total	977	1009	810	1135	1067	922	1076	923	1068	1013	10000

# La matrice de confusion du système parfait est donc diagonale

# Mais nous regardons rarement la matrice de confusion sous forme textuelle

---



# Taux de reconnaissance

---



$$\frac{\sum_i \text{Vrais positifs de } i}{\text{Nb d'exemples}}$$

Prédiction

	avion	voiture	oiseau	chat	cerf	chien	grenouille	cheval	bateau	camion	total
avion	828	13	12	11	18	0	2	4	85	27	1000
voiture	10	910	0	5	1	1	0	1	11	61	1000
oiseau	47	1	708	64	88	14	63	4	8	3	1000
chat	3	4	16	768	33	93	50	19	4	10	1000
cerf	10	0	39	43	788	12	57	43	6	2	1000
chien	2	0	10	137	29	777	8	33	0	4	1000
grenouille	7	2	10	54	29	7	888	1	1	1	1000
cheval	24	2	14	39	76	17	4	818	2	4	1000
bateau	27	13	0	7	3	0	3	0	933	14	1000
camion	19	64	1	7	2	1	1	0	18	887	1000
total	977	1009	810	1135	1067	922	1076	923	1068	1013	10000

# Précision

$$\text{Précision}(i) = \frac{\text{Vrais positifs de } i}{\text{Vrais positifs de } i + \text{Faux positifs de } i}$$

Prédiction

	avion	voiture	oiseau	chat	cerf	chien	grenouille	cheval	bateau	camion	total
avion	828	13	12	11	18	0	2	4	85	27	1000
voiture	10	910	0	5	1	1	0	1	11	61	1000
oiseau	47	1	708	64	88	14	63	4	8	3	1000
chat	3	4	16	768	33	93	50	19	4	10	1000
cerf	10	0	39	43	788	12	57	43	6	2	1000
chien	2	0	10	137	29	777	8	33	0	4	1000
grenouille	7	2	10	54	29	7	888	1	1	1	1000
cheval	24	2	14	39	76	17	4	818	2	4	1000
bateau	27	13	0	7	3	0	3	0	933	14	1000
camion	19	64	1	7	2	1	1	0	18	887	1000
total	977	1009	810	1135	1067	922	1076	923	1068	1013	10000

# Rappel



$$\text{Rappel}(i) = \frac{\text{Vrais positifs de } i}{\text{Vrais positifs de } i + \text{Faux négatifs de } i}$$

## Prédiction

	avion	voiture	oiseau	chat	cerf	chien	grenouille	cheval	bateau	camion	total
avion	828	13	12	11	18	0	2	4	85	27	1000
voiture	10	910	0	5	1	1	0	1	11	61	1000
oiseau	47	1	708	64	88	14	63	4	8	3	1000
chat	3	4	16	768	33	93	50	19	4	10	1000
cerf	10	0	39	43	788	12	57	43	6	2	1000
chien	2	0	10	137	29	777	8	33	0	4	1000
grenouille	7	2	10	54	29	7	888	1	1	1	1000
cheval	24	2	14	39	76	17	4	818	2	4	1000
bateau	27	13	0	7	3	0	3	0	933	14	1000
camion	19	64	1	7	2	1	1	0	18	887	1000
total	977	1009	810	1135	1067	922	1076	923	1068	1013	10000

# Spécificité



$$\text{Spécificité}(i) = \frac{\text{Vrais négatifs de } i}{\text{Vrais négatifs de } i + \text{Faux positifs de } i}$$

## Prédiction

	avion	voiture	oiseau	chat	cerf	chien	grenouille	cheval	bateau	camion	total
avion	828	13	12	11	18	0	2	4	85	27	1000
voiture	10	910	0	5	1	1	0	1	11	61	1000
oiseau	47	1	708	64	88	14	63	4	8	3	1000
chat	3	4	16	768	33	93	50	19	4	10	1000
cerf	10	0	39	43	788	12	57	43	6	2	1000
chien	2	0	10	137	29	777	8	33	0	4	1000
grenouille	7	2	10	54	29	7	888	1	1	1	1000
cheval	24	2	14	39	76	17	4	818	2	4	1000
bateau	27	13	0	7	3	0	3	0	933	14	1000
camion	19	64	1	7	2	1	1	0	18	887	1000
total	977	1009	810	1135	1067	922	1076	923	1068	1013	10000

# Généralités sur l'évaluation

---

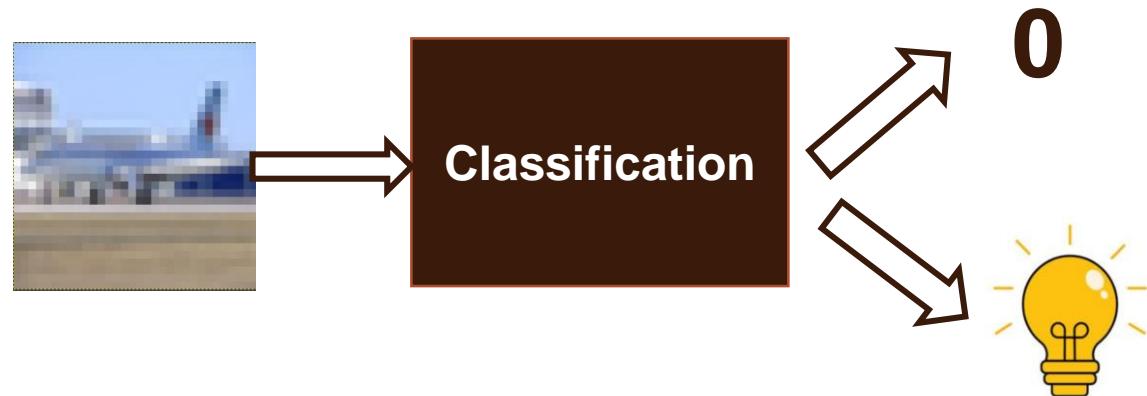
- **Prérequis**
  - Modèle
  - Base de test de qualité
- **Obtient**
  - Métriques à interpréter et comparer
  - Une idée des performances
  - Possibilité de comparer des modèles relativement les uns aux autres
- **Il manque**
  - Raisons qui expliquent les réussites et les erreurs

# Comment expliquer les décisions du classifieur ?

---

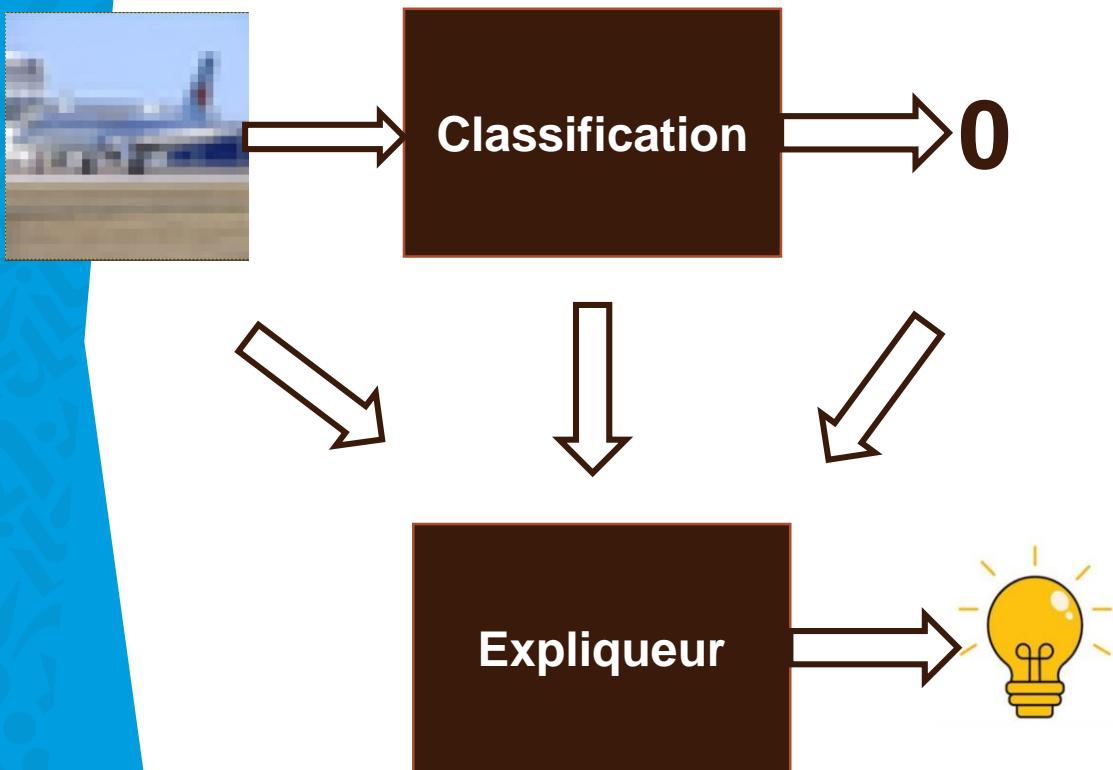
## Méthodes intrinsèques

- Par construction, les modèles expliquent la décision
- En général il s'agit de modèles simples sur des données simples



# Comment expliquer les décisions du classifieur ?

---



## Méthodes après-coup

- On se sert de différentes informations pour supposer ce que le modèle a fait
- On ne sait pas toujours évaluer la qualité de l'explication

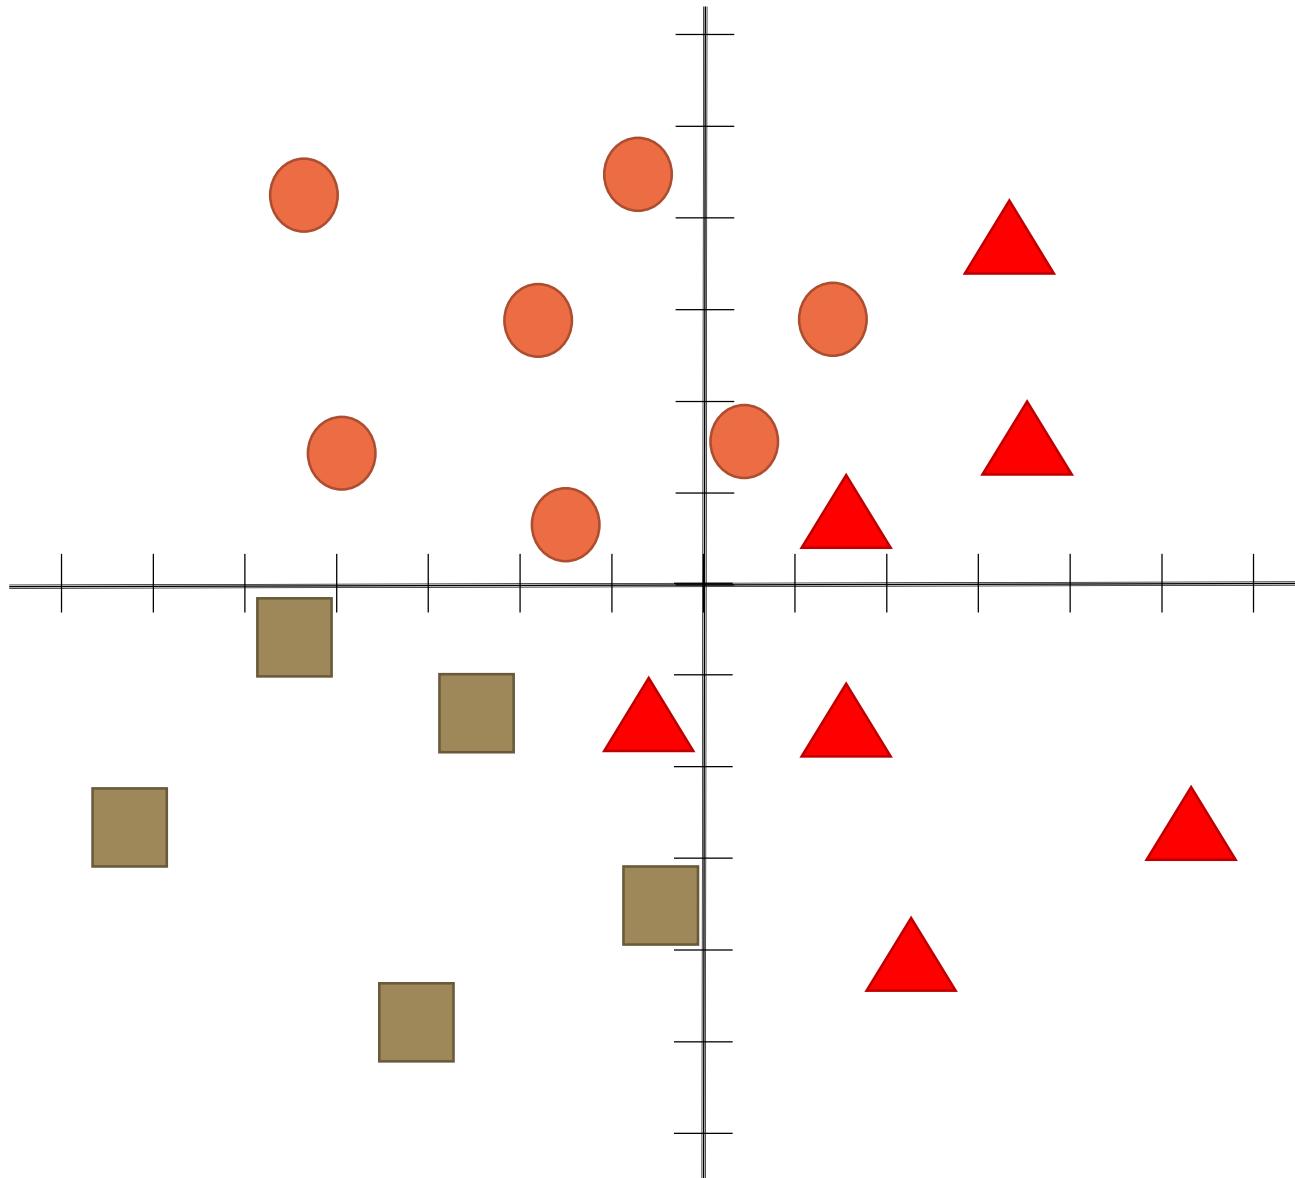
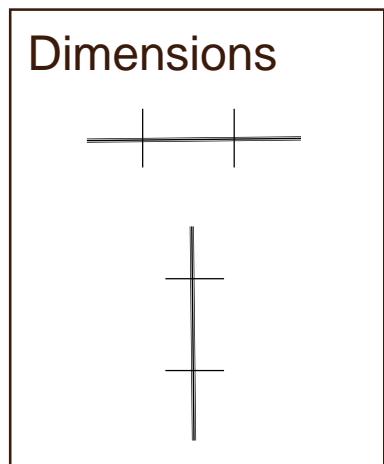
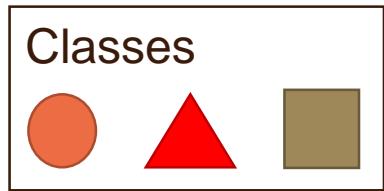
# **modèles simples de classification supervisée**

---

**Description de  
quelques modèles  
avant de présenter  
les explications  
intrinsèques et  
après-coup**

---

# Classification de données en 2 dimensions



# K plus proches voisins : apprentissage

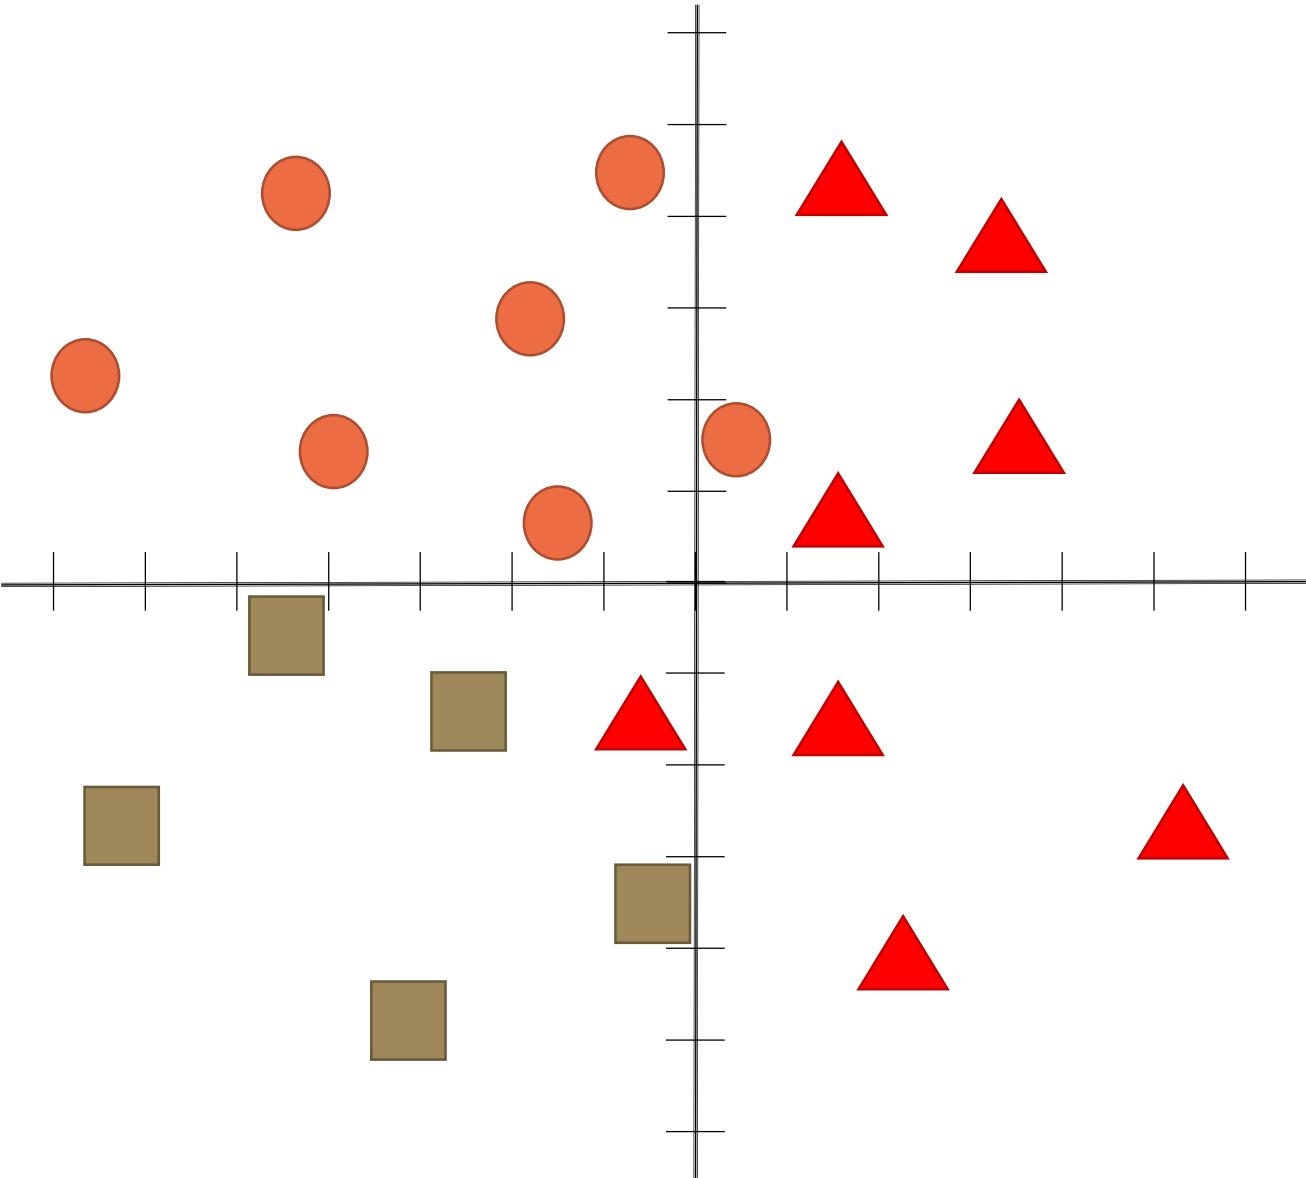
---

**Paramètres** : ensemble des données étiquetées

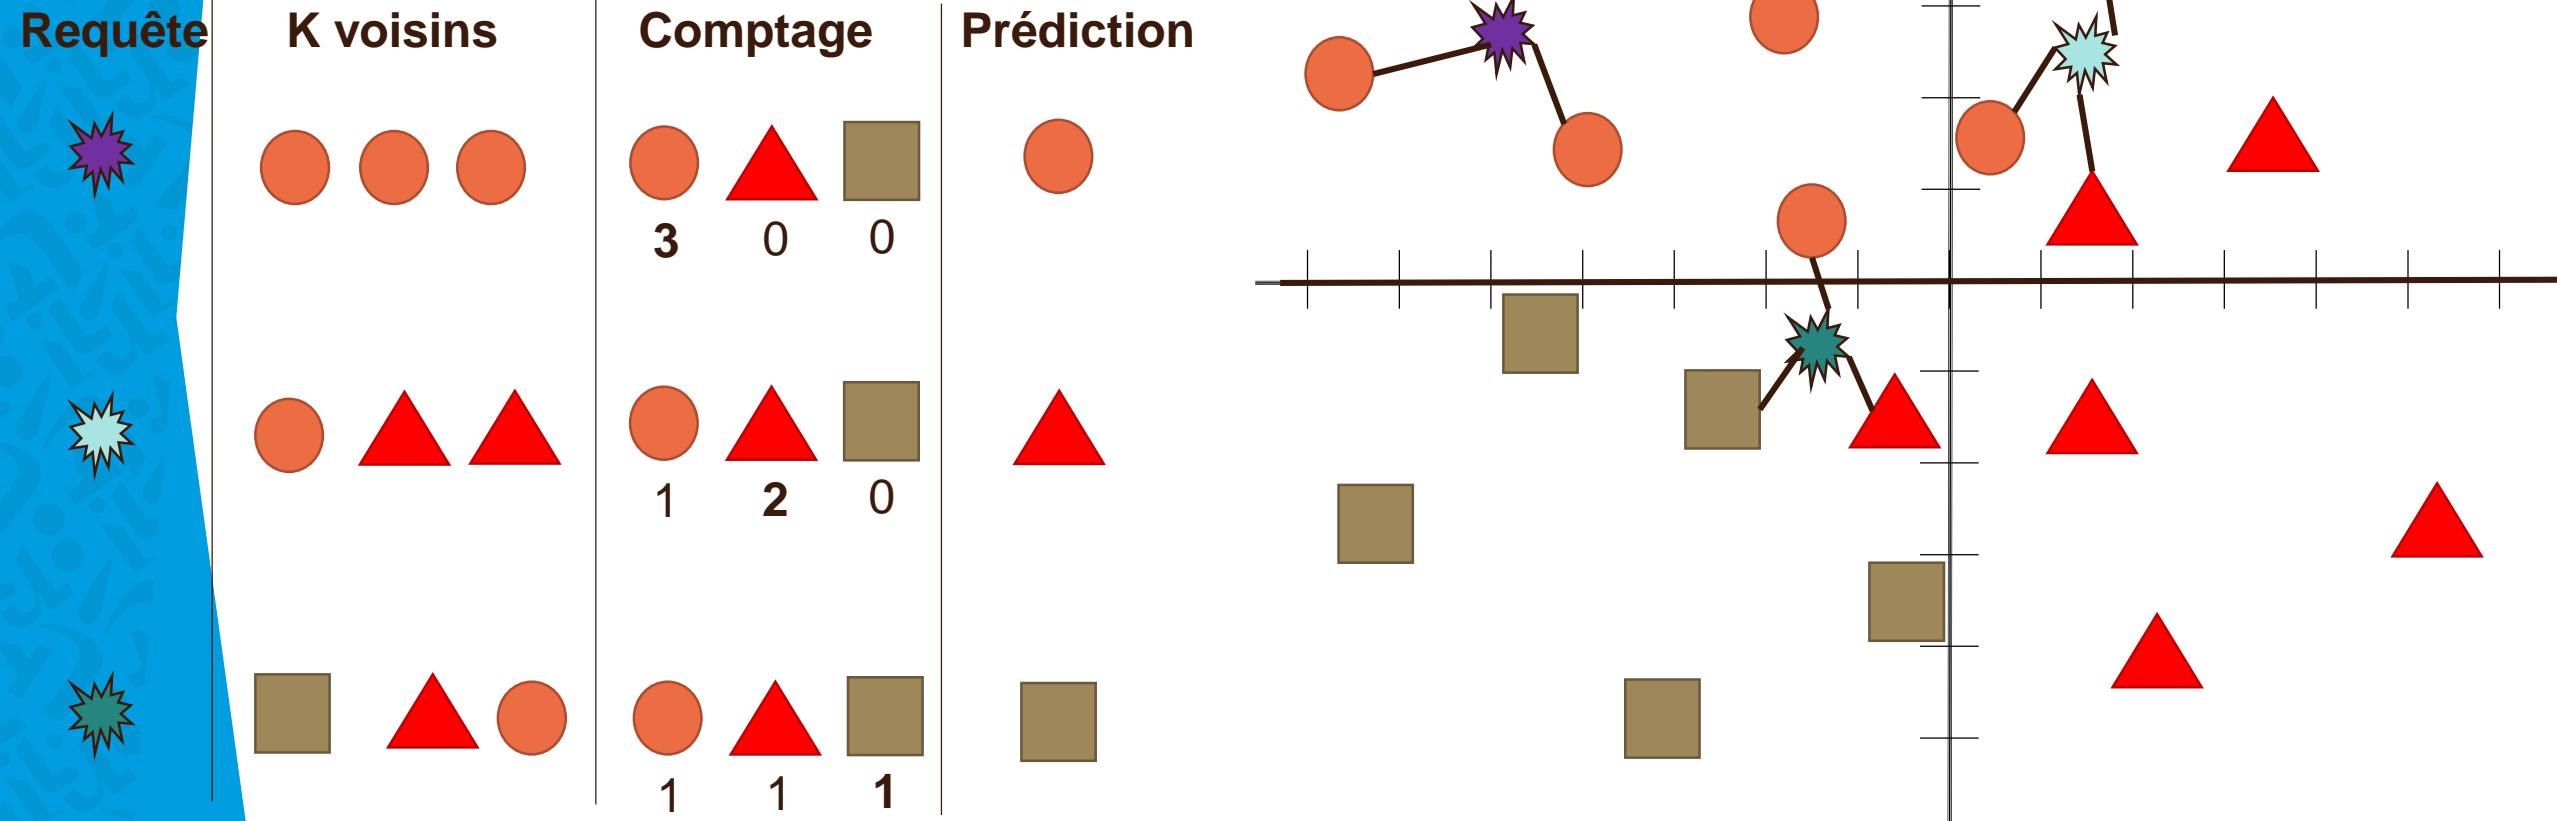
**Hyperparamètres** : K

F : code qui recherche les exemples les plus proches

**Optimiseur** : aucun



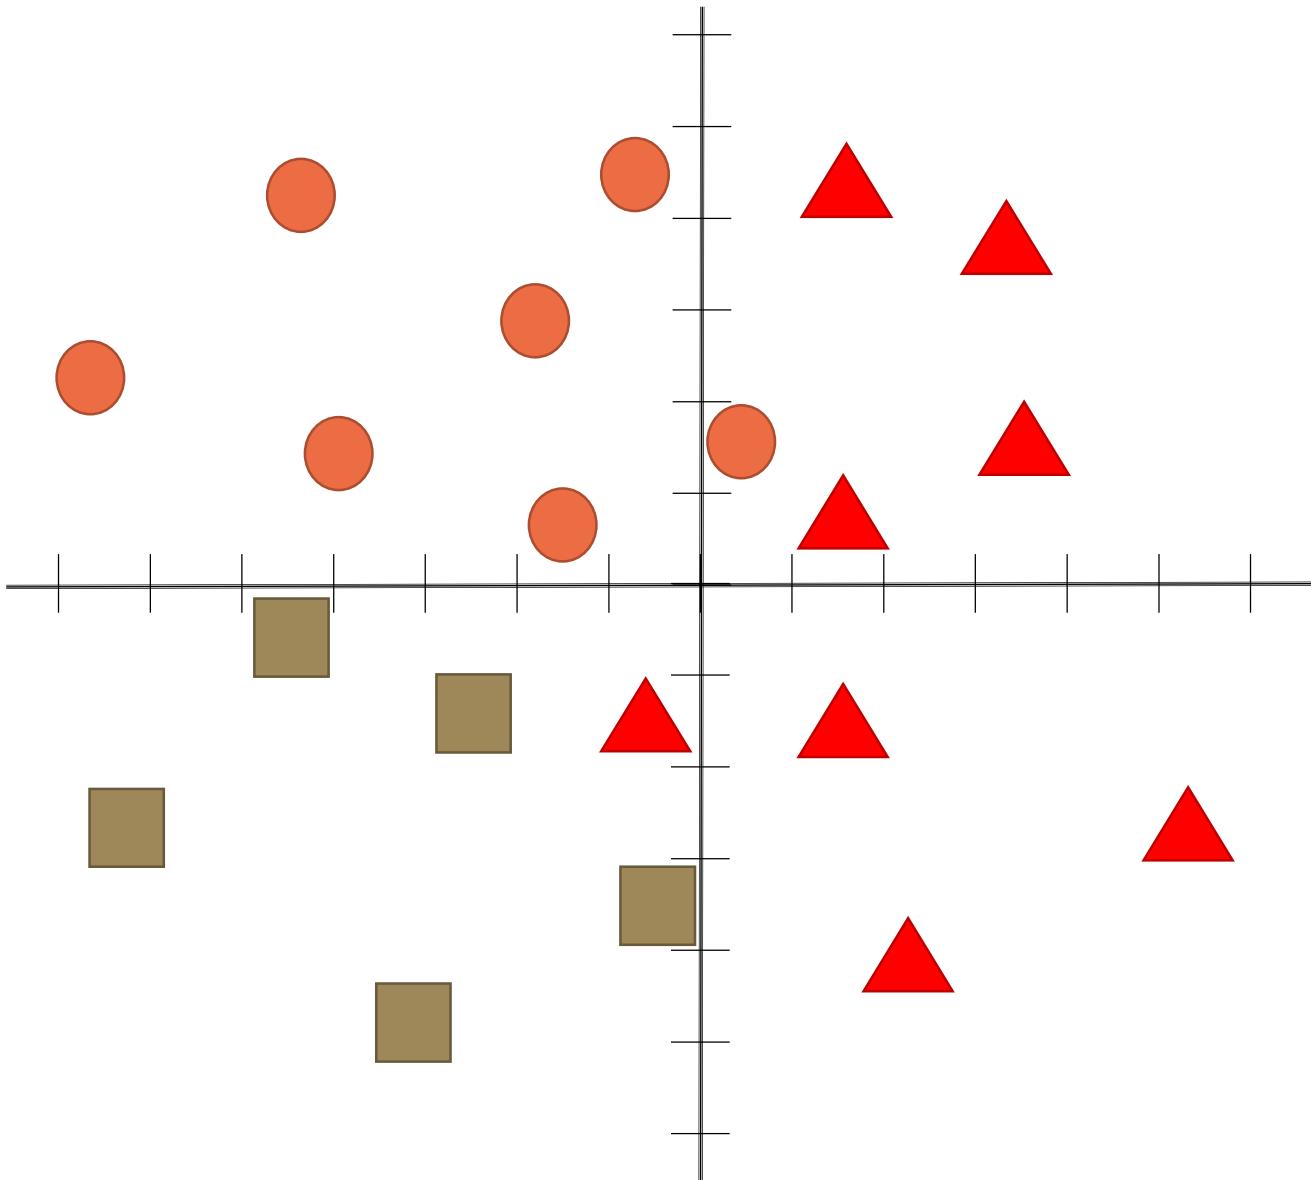
# K plus proches voisins : inférence



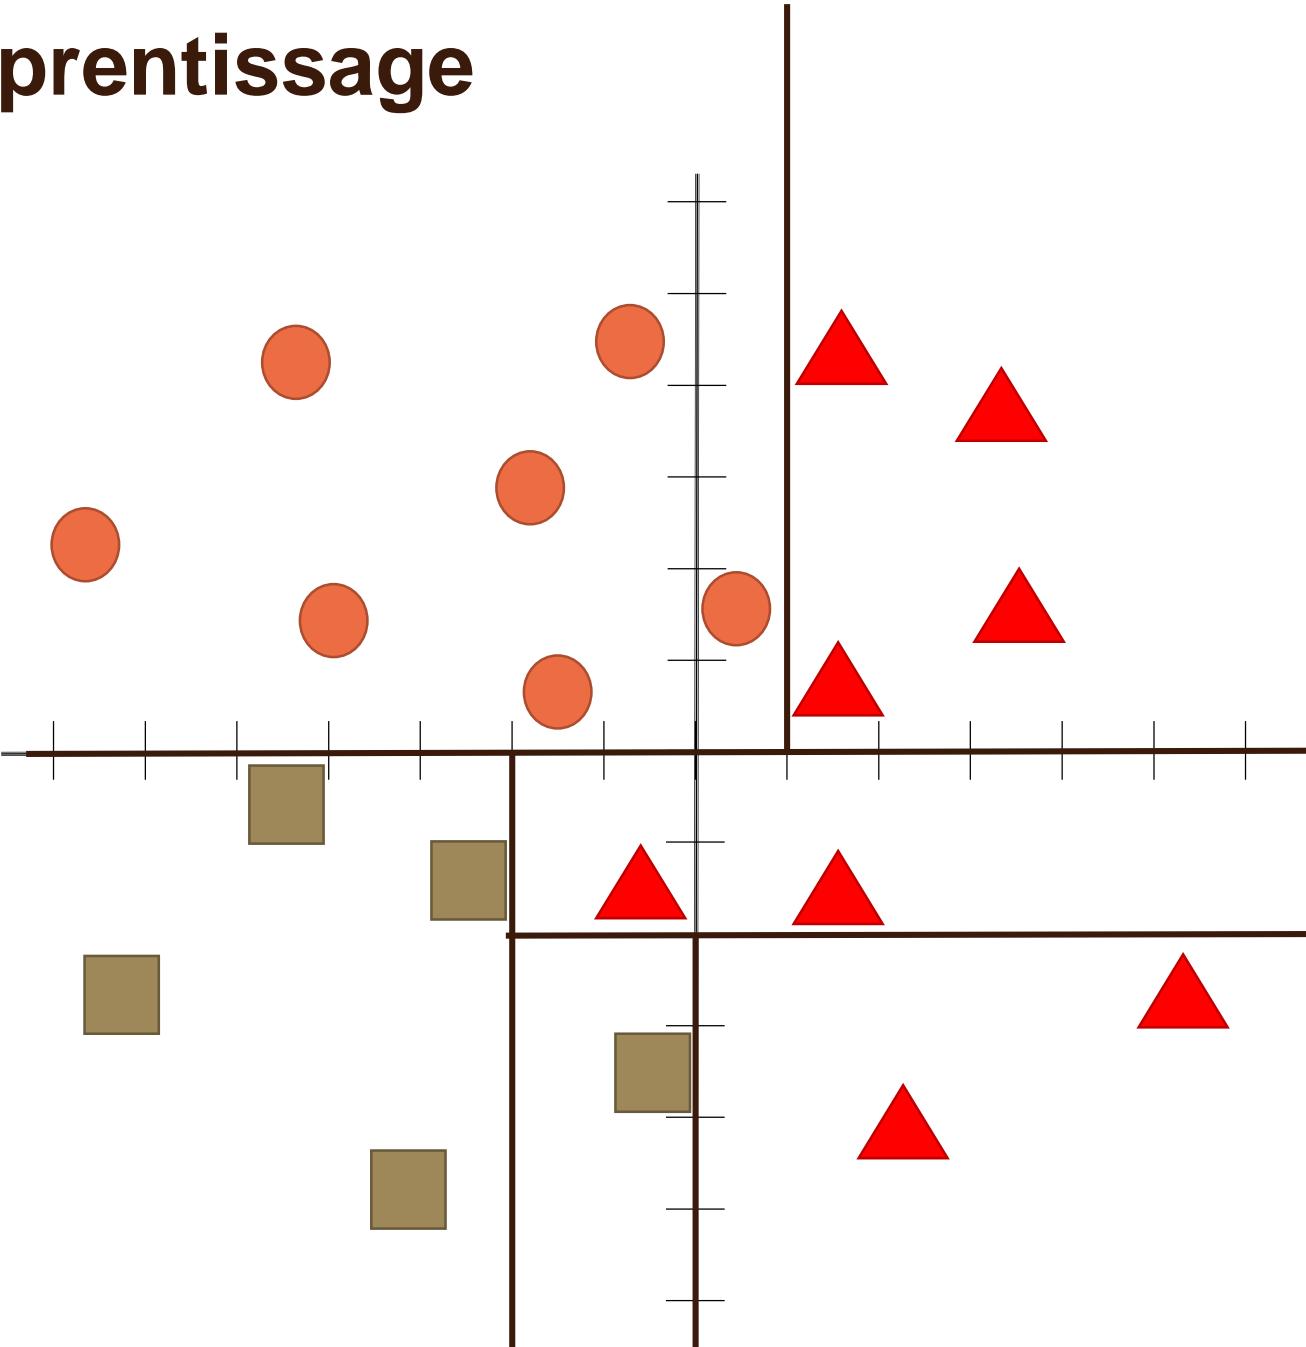
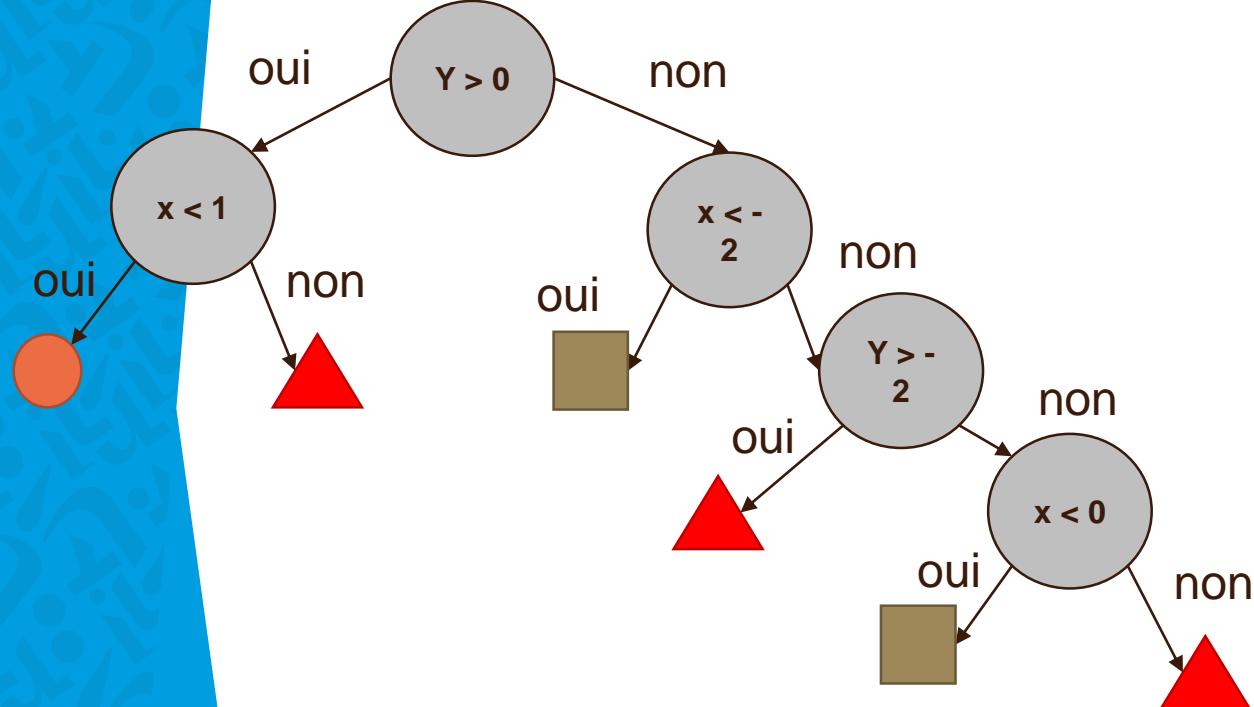
# Arbre de décision : apprentissage

---

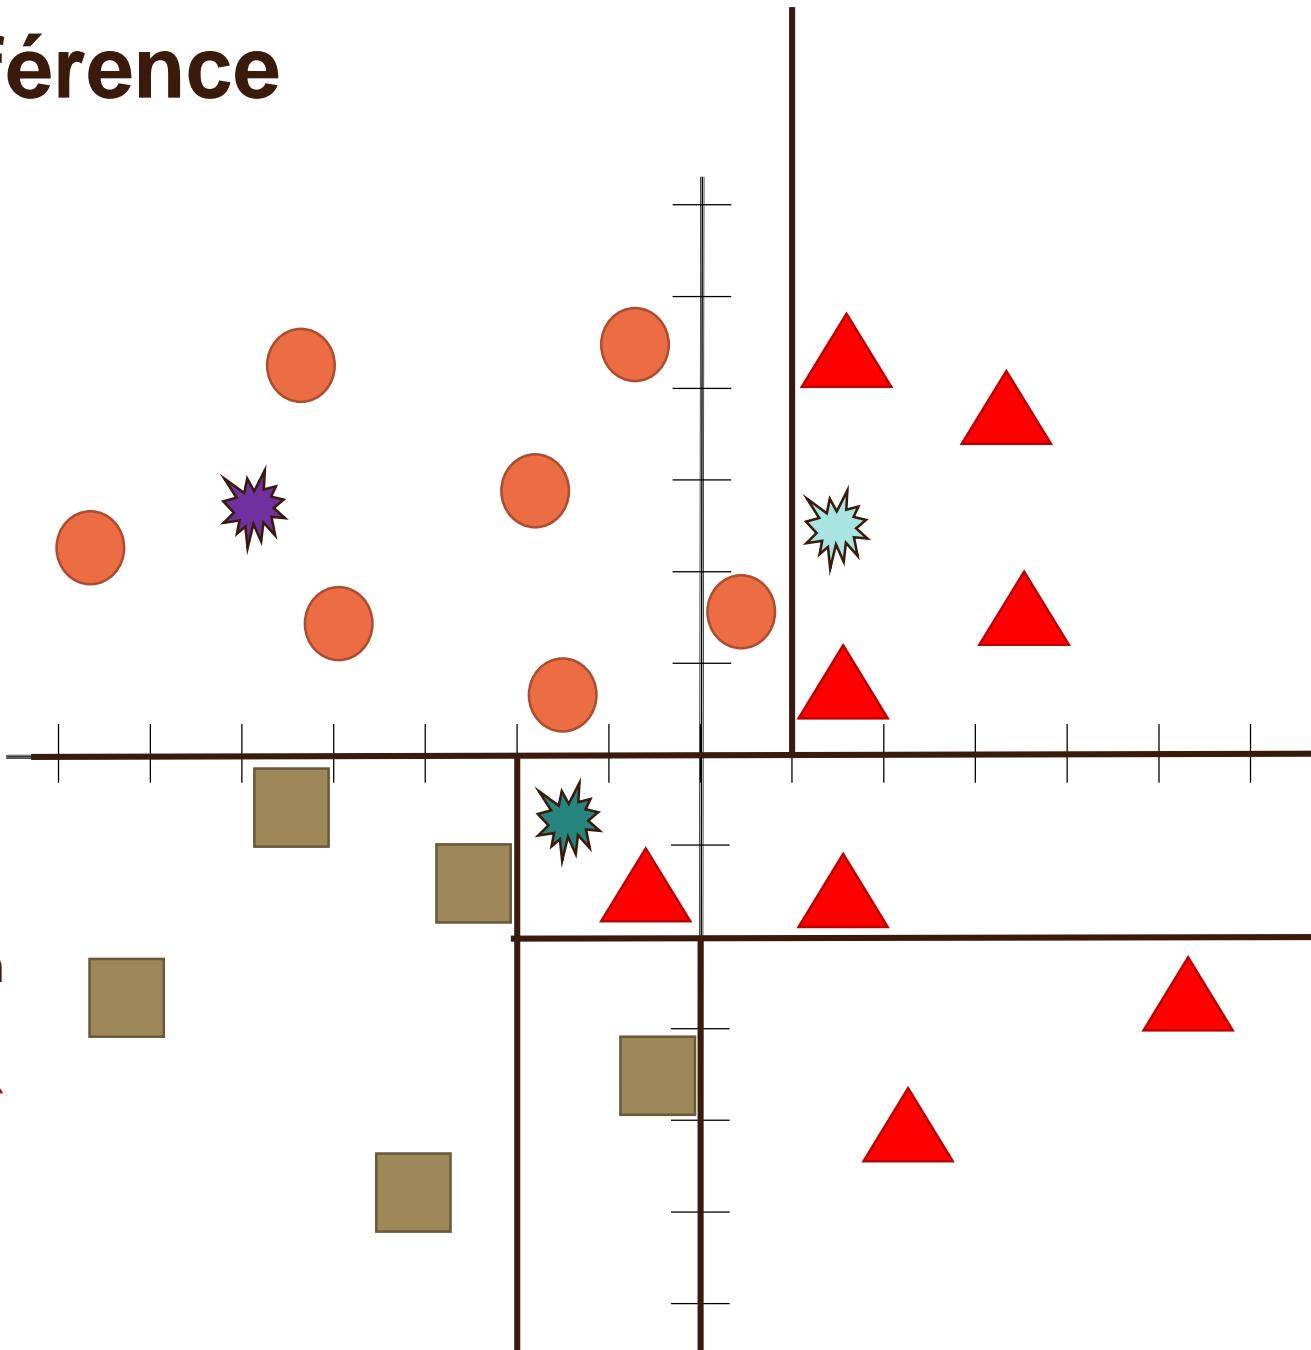
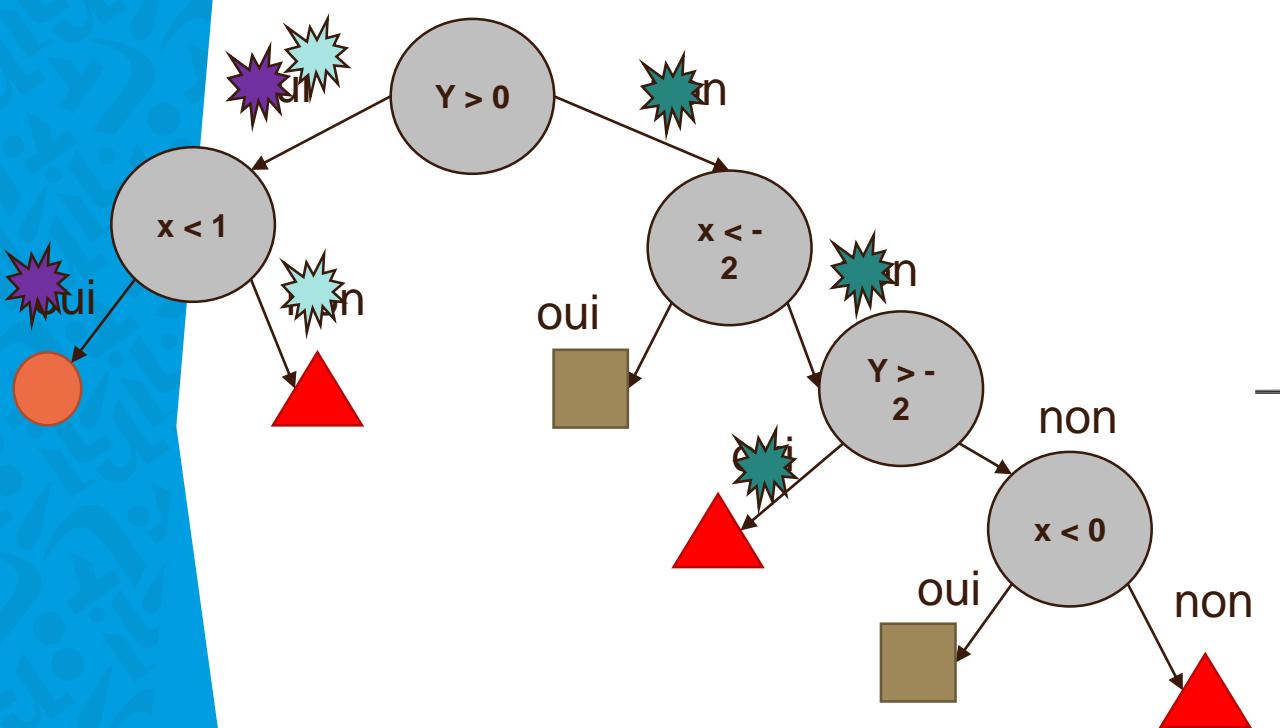
**Paramètres** : définition de l'arbre  
**F**: code qui exécute un arbre  
**Hyperparamètres** : configuration de l'optimiseur  
**Optimiseur**: algorithme de construction de l'arbre



# Arbre de décision : apprentissage

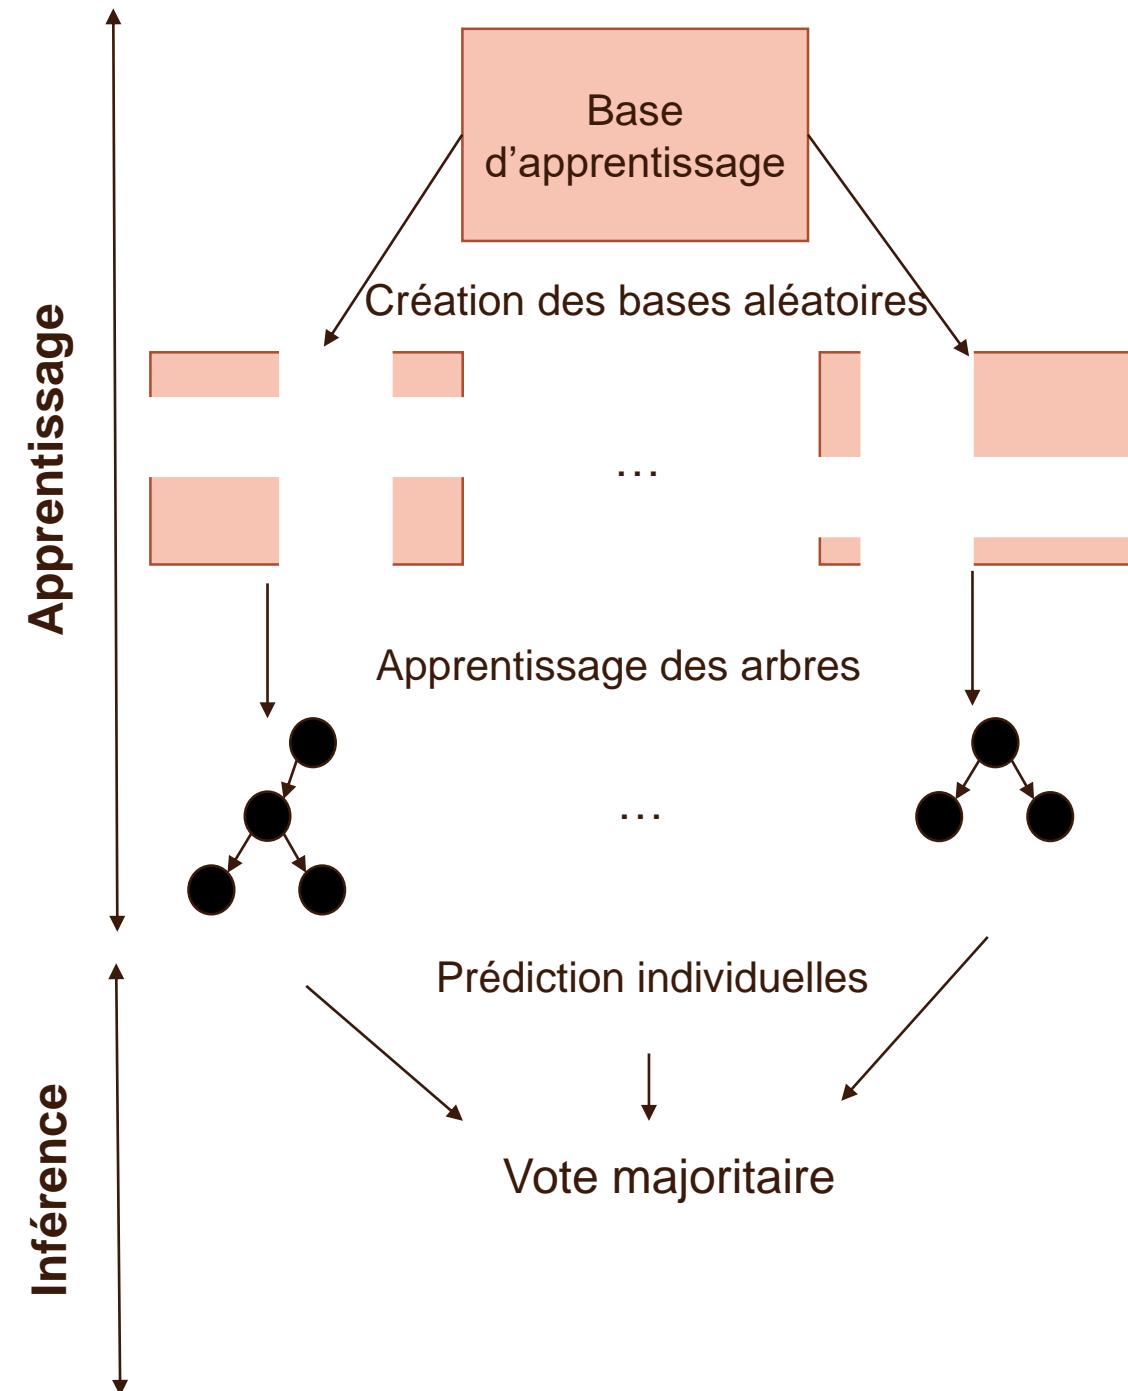


# Arbre de décision : inférence



# Forêt aléatoire

- Ensemble d'arbres
- Chaque arbre
  - Est appris avec un sous ensemble des exemples
  - Est appris avec un sous ensemble des caractéristiques
  - A des performances médiocres
- La forêt
  - Agrège les résultats de ses arbres
  - A de très bonnes performances



# Régression logistique

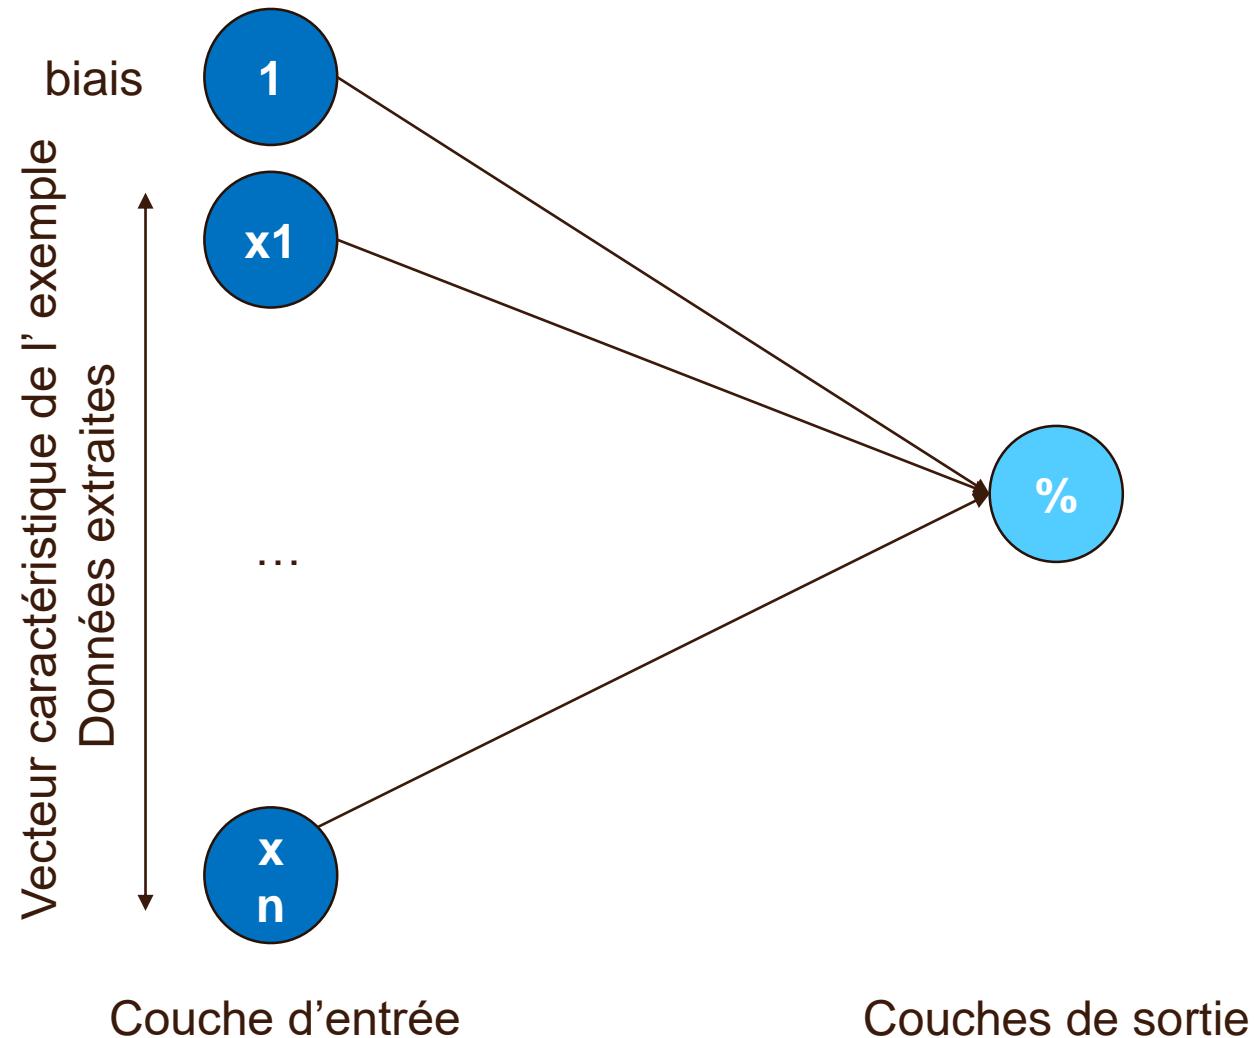
---

**Paramètres** : ensemble des poids

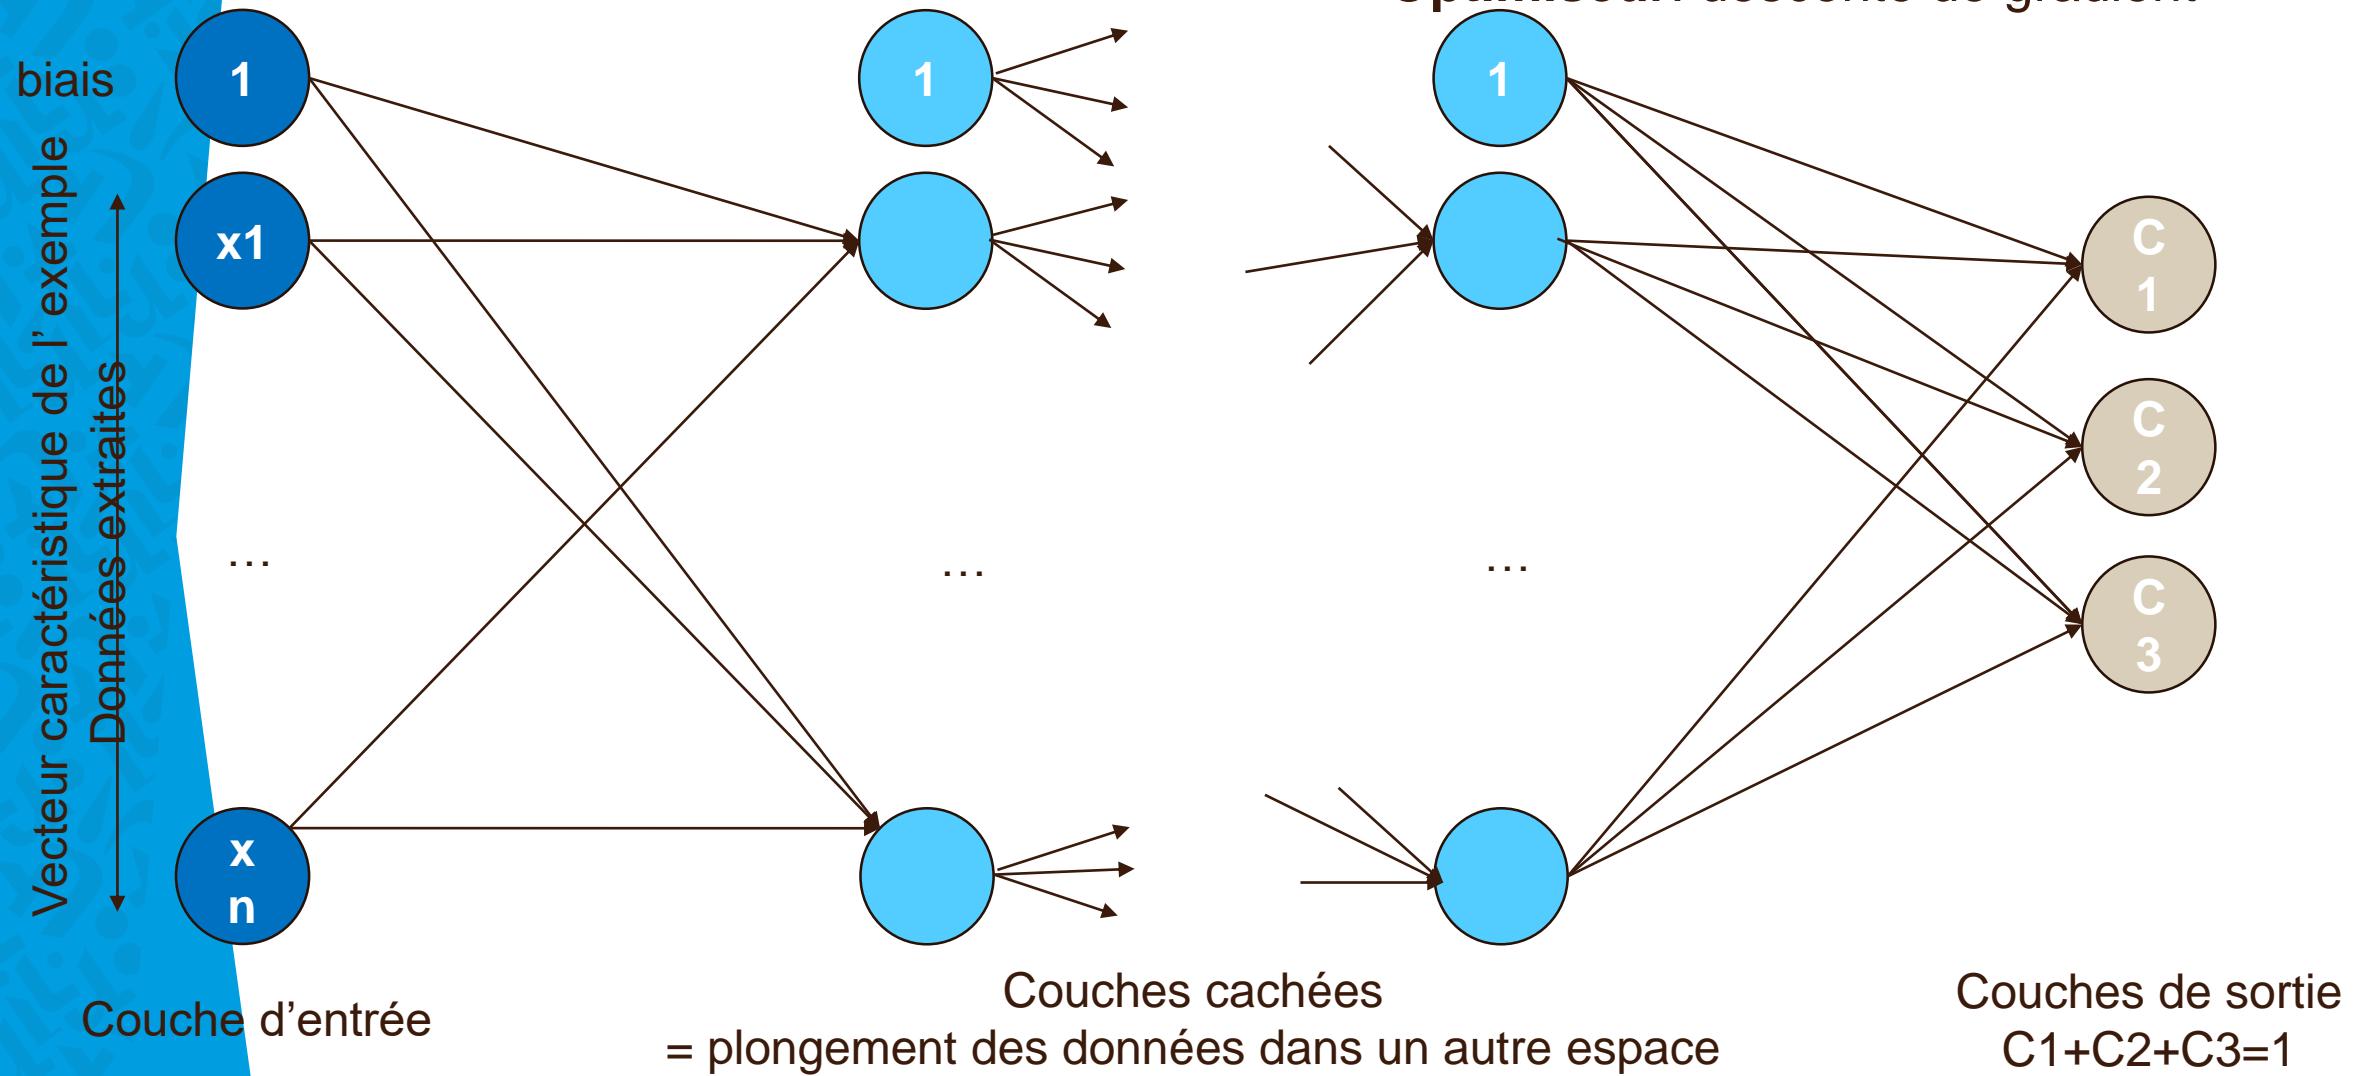
**Hyperparamètres** : fonction de régularisation

**F**: code qui exécute la somme pondérée et l'activation

**Optimiseur**: descente de gradient, méthode de newton, optimiseurs hadock



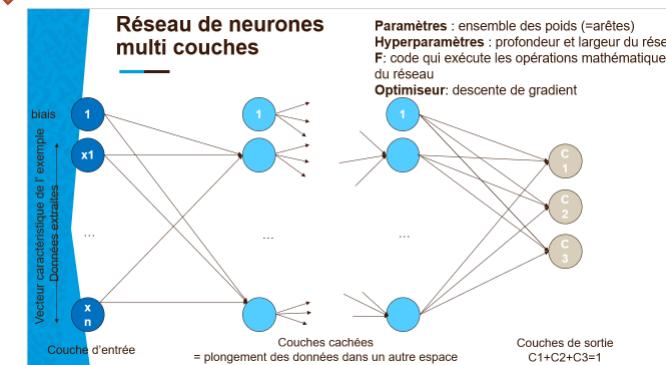
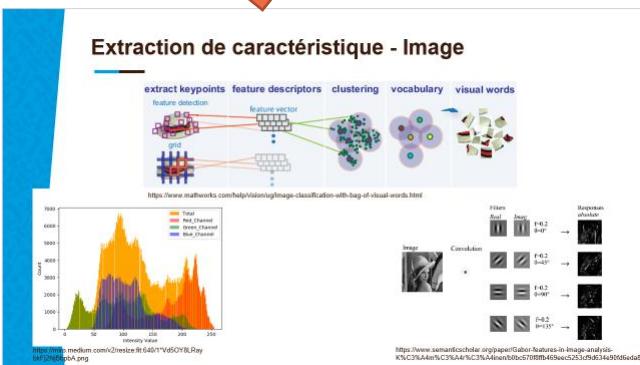
# Réseau de neurones multi couches



# Réseau de neurones profond



Un réseau fait  
l'extraction  
De nombreuses  
astuces sont  
utilisées pour diminuer  
le nombre de poids



La classification est faite  
grâce à un MLP.  
La plupart des poids sont  
ici

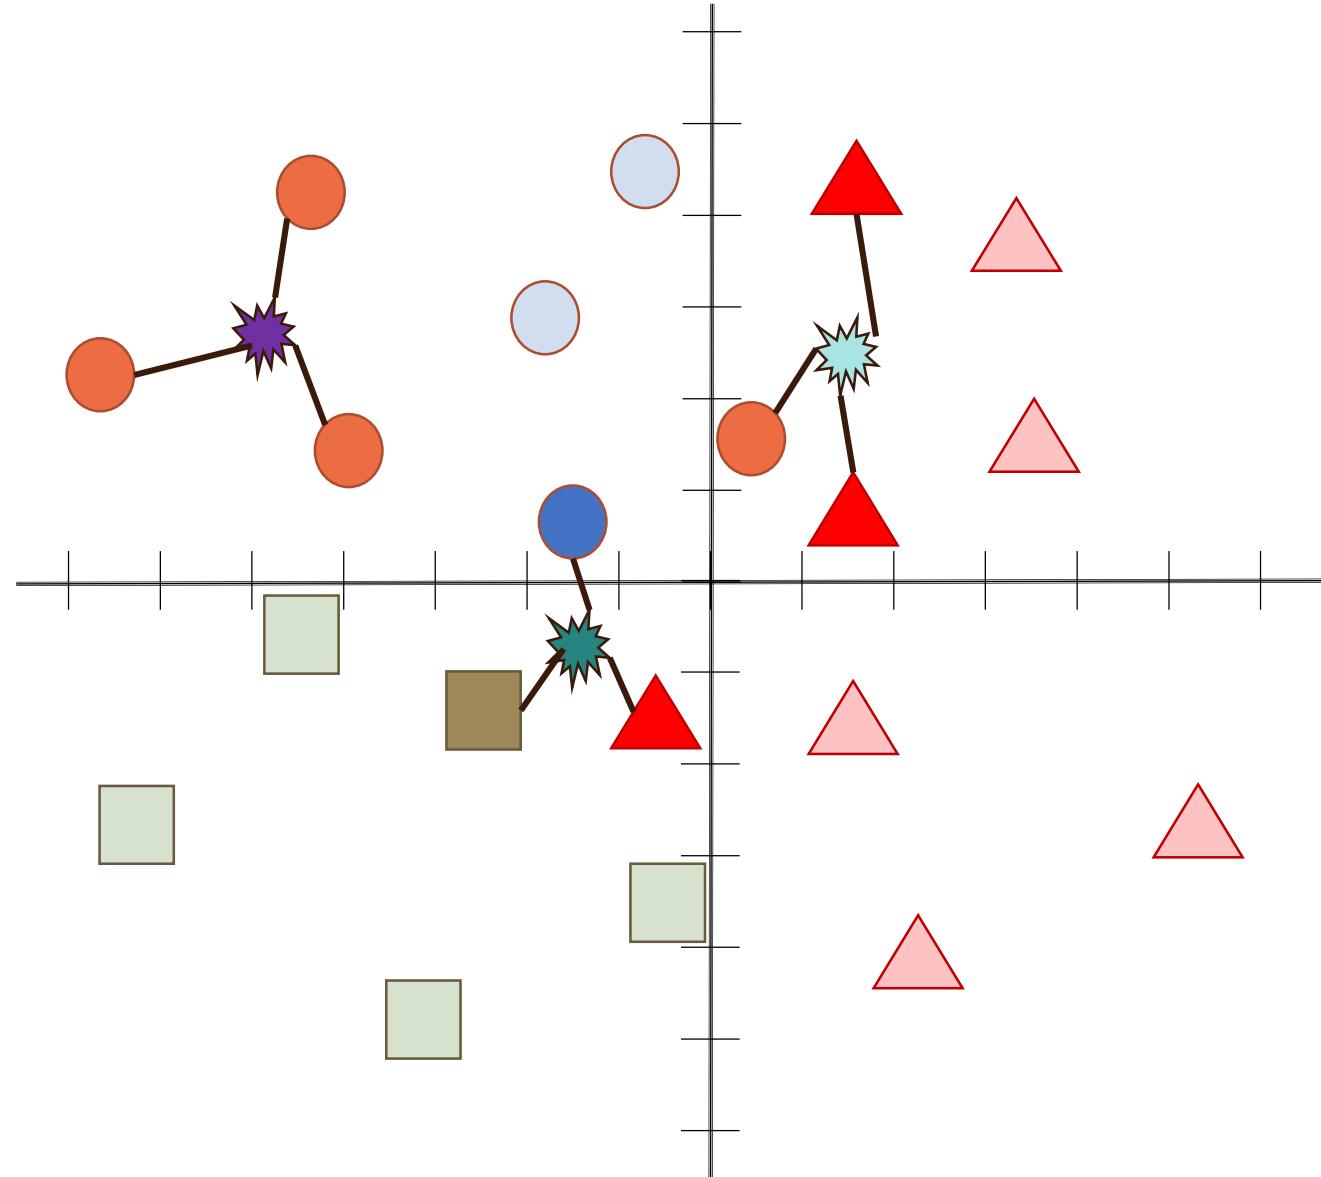
# **Explications intrinsèques**

---

**Les modèles proposent directement des explications**

---

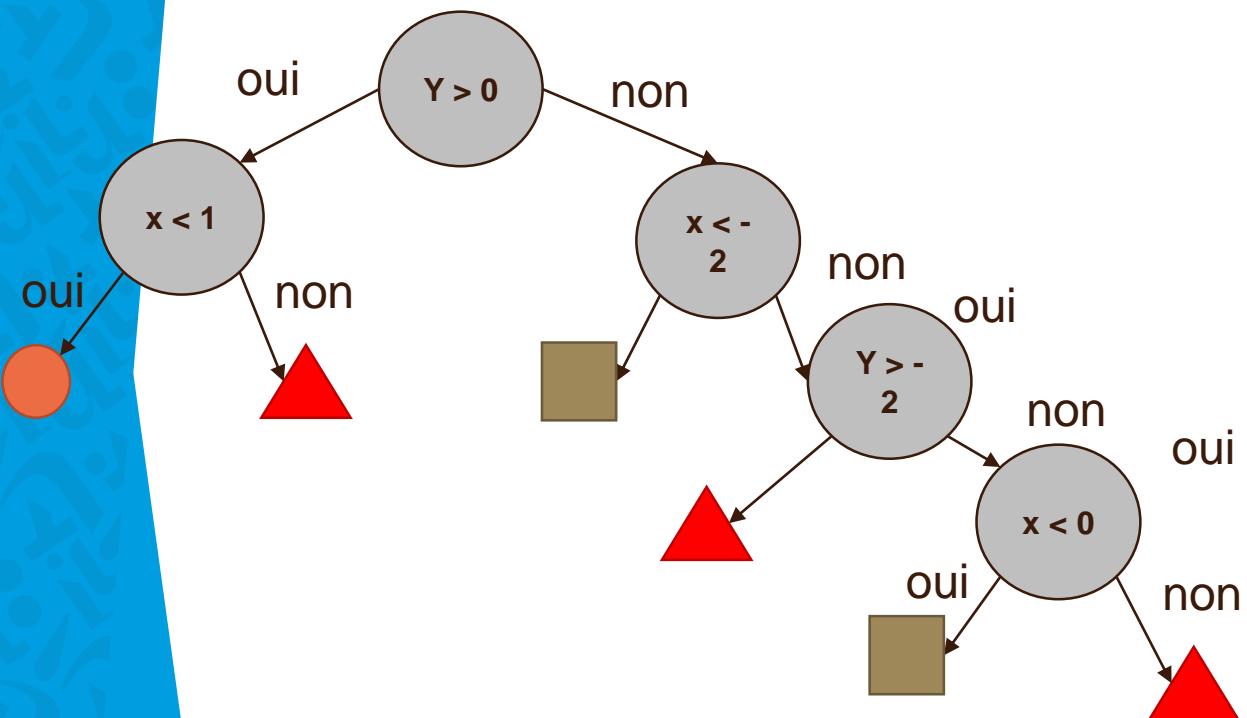
# K plus proches voisins : représentation des plus proches voisins



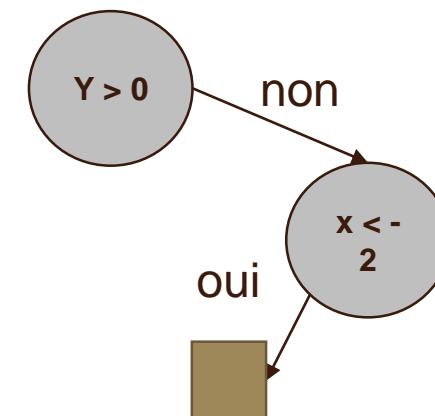
# Arbre de décision : représentation de l'arbre ou du chemin emprunté par une donnée

---

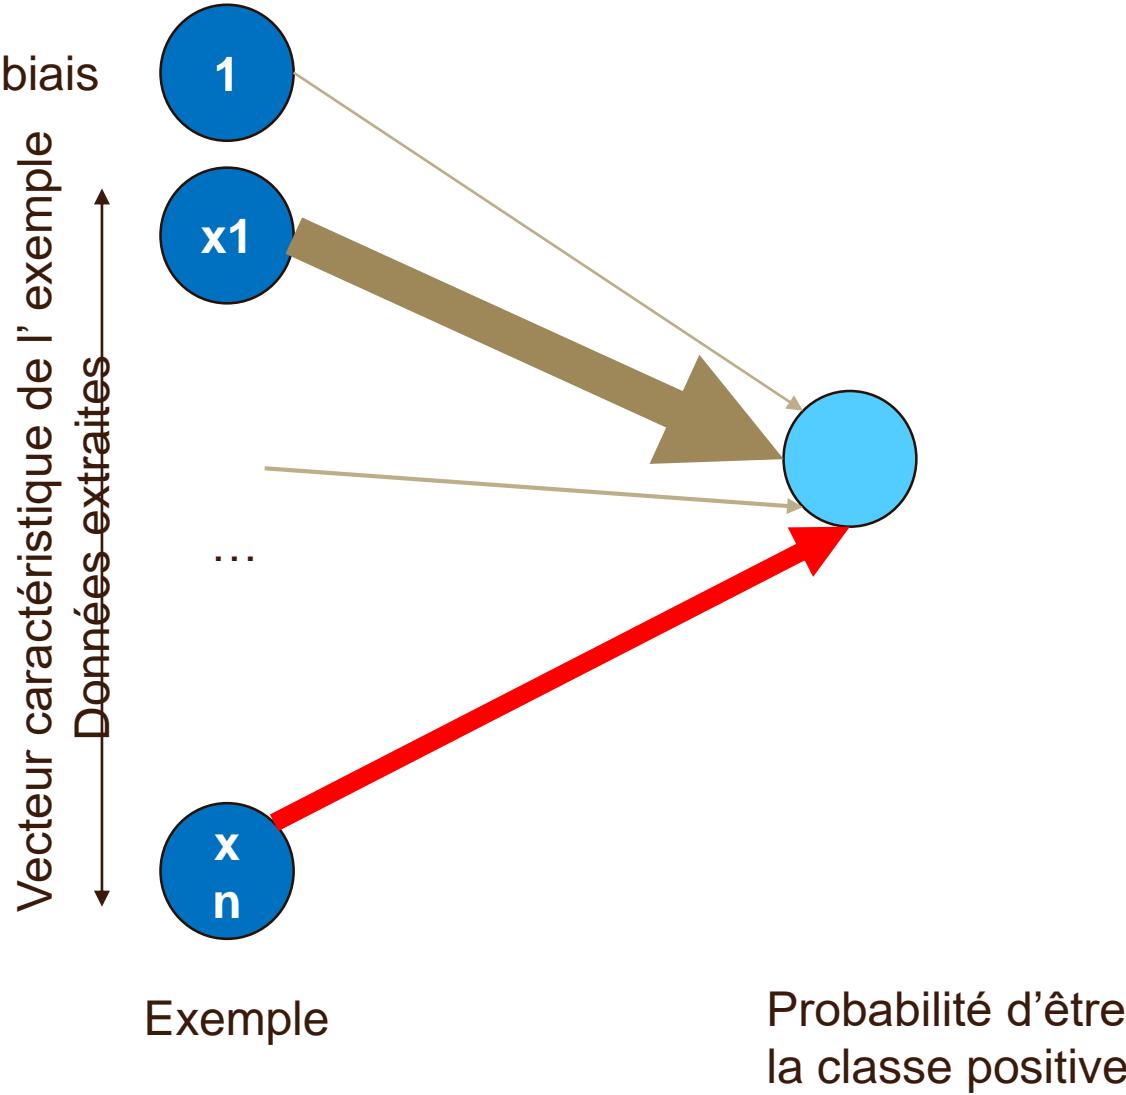
Explication globale



Explication locale



# Régression logistique : importance des (valeur absolue des) poids



# Limites des explications intrinsèques

---

- **Limité à des modèles simples**
  - Donc pas forcément les plus performants
- **Ne passe pas l'échelle**
  - Comment visualiser les plus proches voisins lorsqu'on ne connaît pas la sémantique des caractéristiques et que la donnée n'est pas une image ?
  - Comment comprendre un arbre de décision trop grand ?
  - Comment lister les poids lorsqu'il y en a trop ?
  - ...

# L'analyse visuelle et interactive est une solution : illustration avec la régression logistique



Figure 1: The interface of the prototype where the limb reduction defect is analyzed. (A1) The univariate analysis view. (A2) The descriptive statistics information panel. (B) The variable grouping view. (C) The model evaluation and comparison view.

# L'analyse visuelle et interactive est une solution : illustration avec les arbres de décision

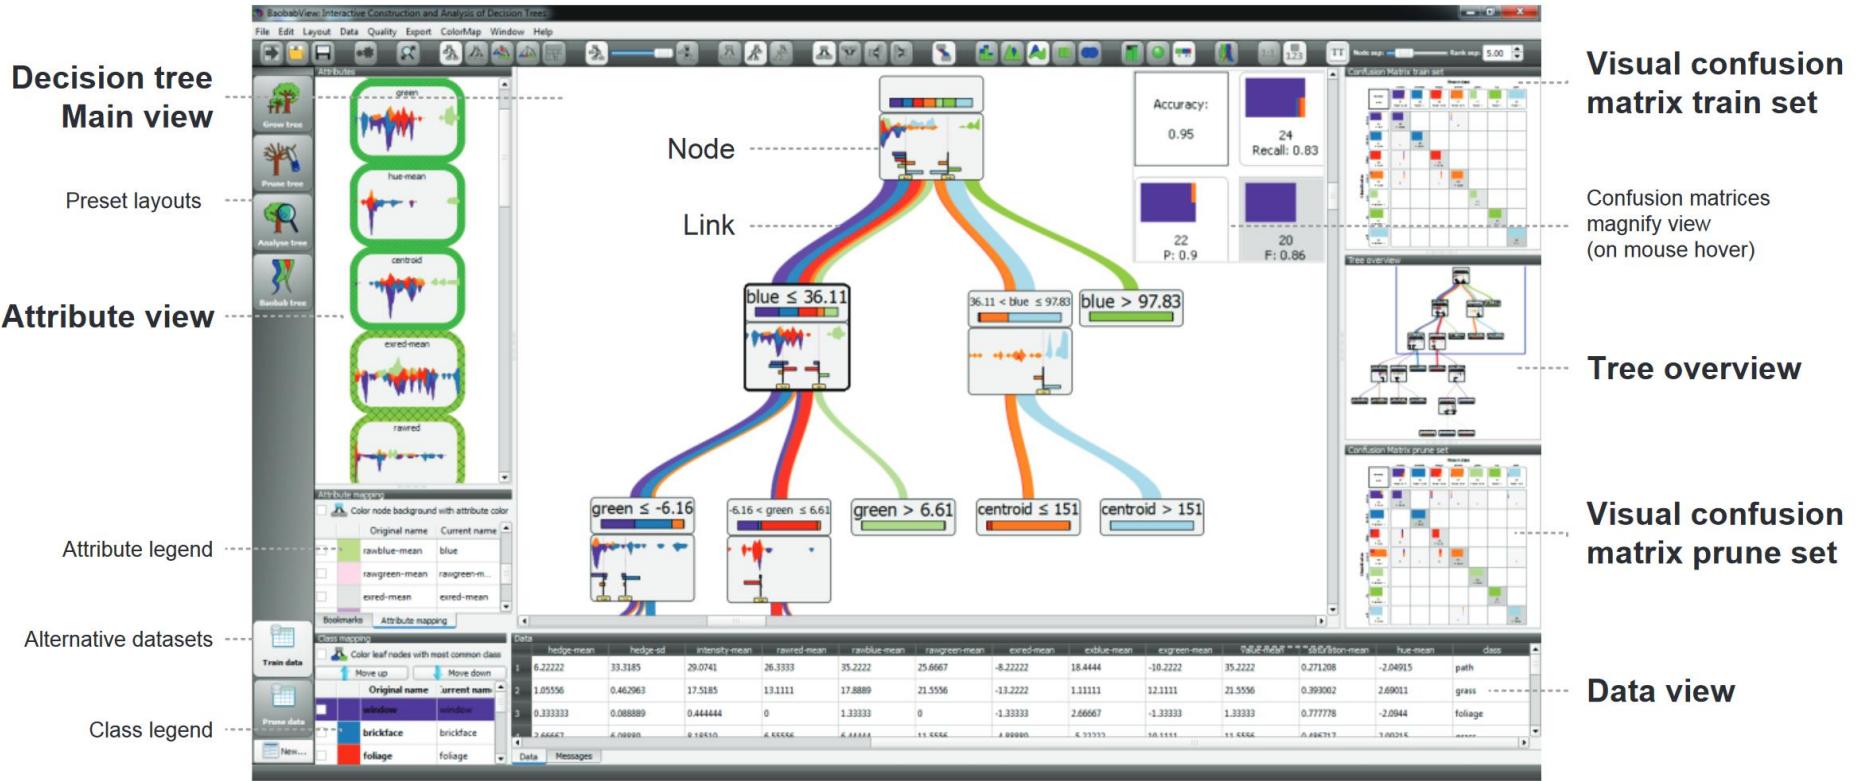


Figure 3: Interface of the interactive decision tree construction software with according proposed decision tree visualization; Based on adapted node-link diagram. Nodes contain important decision tree components. Links are visualized as a stream of items.

# L'analyse visuelle et interactive est une solution : illustration avec les forêts alétoires

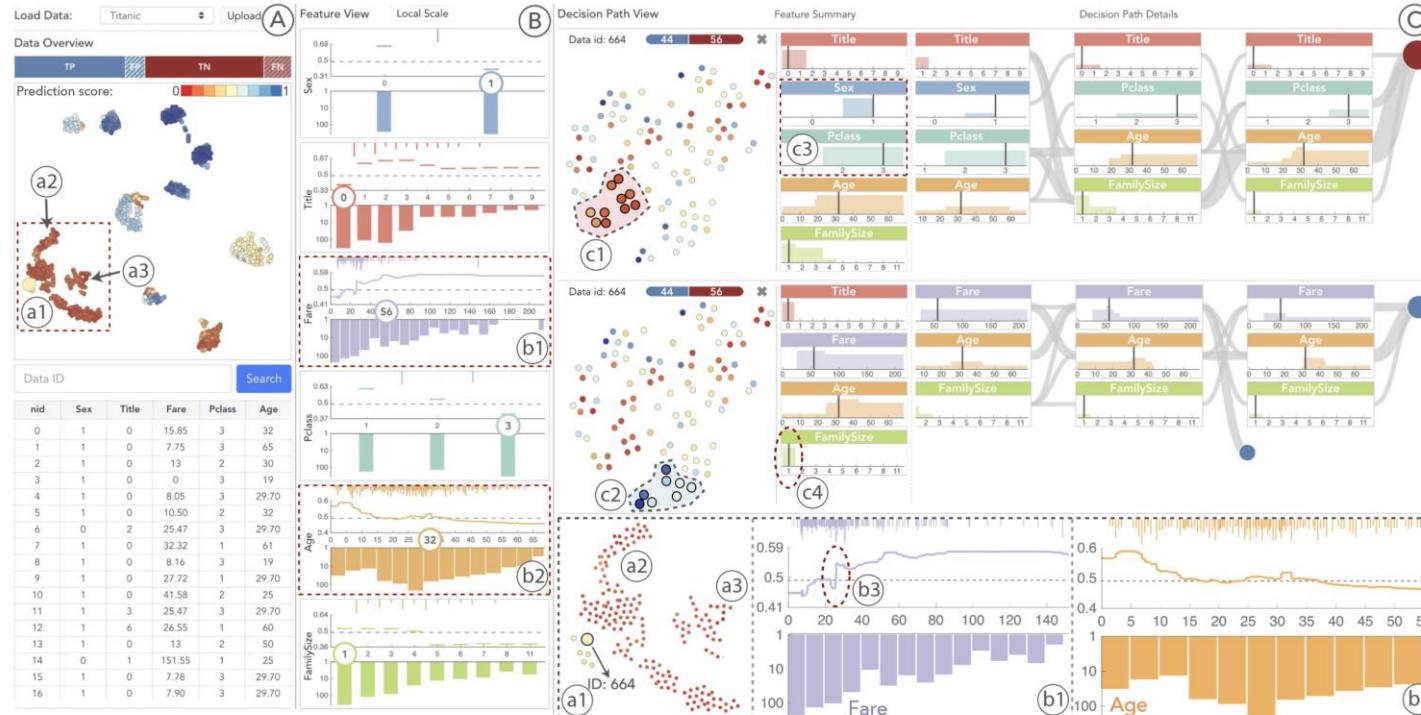


Figure 1. Using iForest to interpret random forests with Titanic dataset: (A) a Data Overview displaying an overview of how random forests classify data; (B) a Feature View depicting the relationships between features and predictions from various perspectives; (C) a Decision Path View revealing the underlying working mechanisms by enabling users to audit and compare different decision paths. iForest allows users to interpret random forests from various perspectives. For example, users can compare the negative decision paths (c1) against the positive ones (c2) to examine the most significant reasons for generating different results.

# Discussion sur les explications intrinsèques

---

- Certaines familles de modèles sont auto-explicables
  - Globalement sur l'ensemble des données
  - Localement pour un exemple particulier
- Cependant, elles passent rarement l'échelle
- L'analyse visuelle et interactive peut aider à mieux apprécier le modèle
  - Il est nécessaire de définir les tâches exactes à résoudre
  - La courbe d'apprentissage de tels outils est souvent longue

# Explications après-coup

---

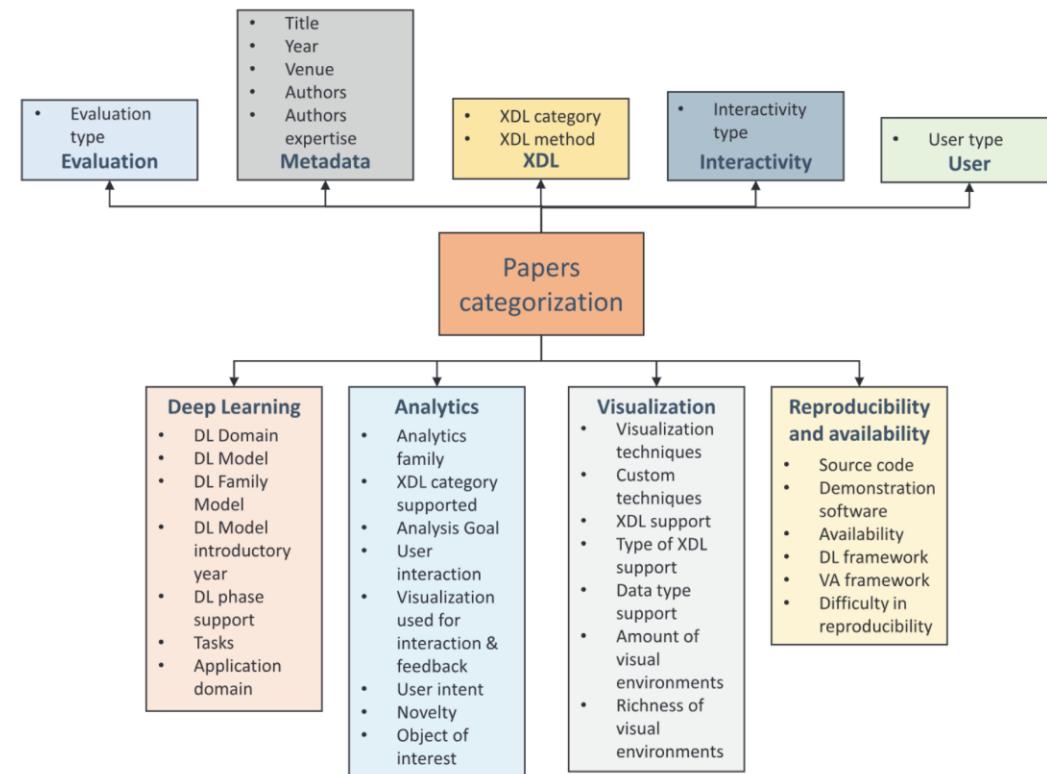
Des post-traitements cherchent à comprendre le modèle. On se focalise sur l'apprentissage profond dans cette partie

---

# Etat de l'art de l'analyse visuelle et interactive pour l'explicabilité de l'apprentissage profond

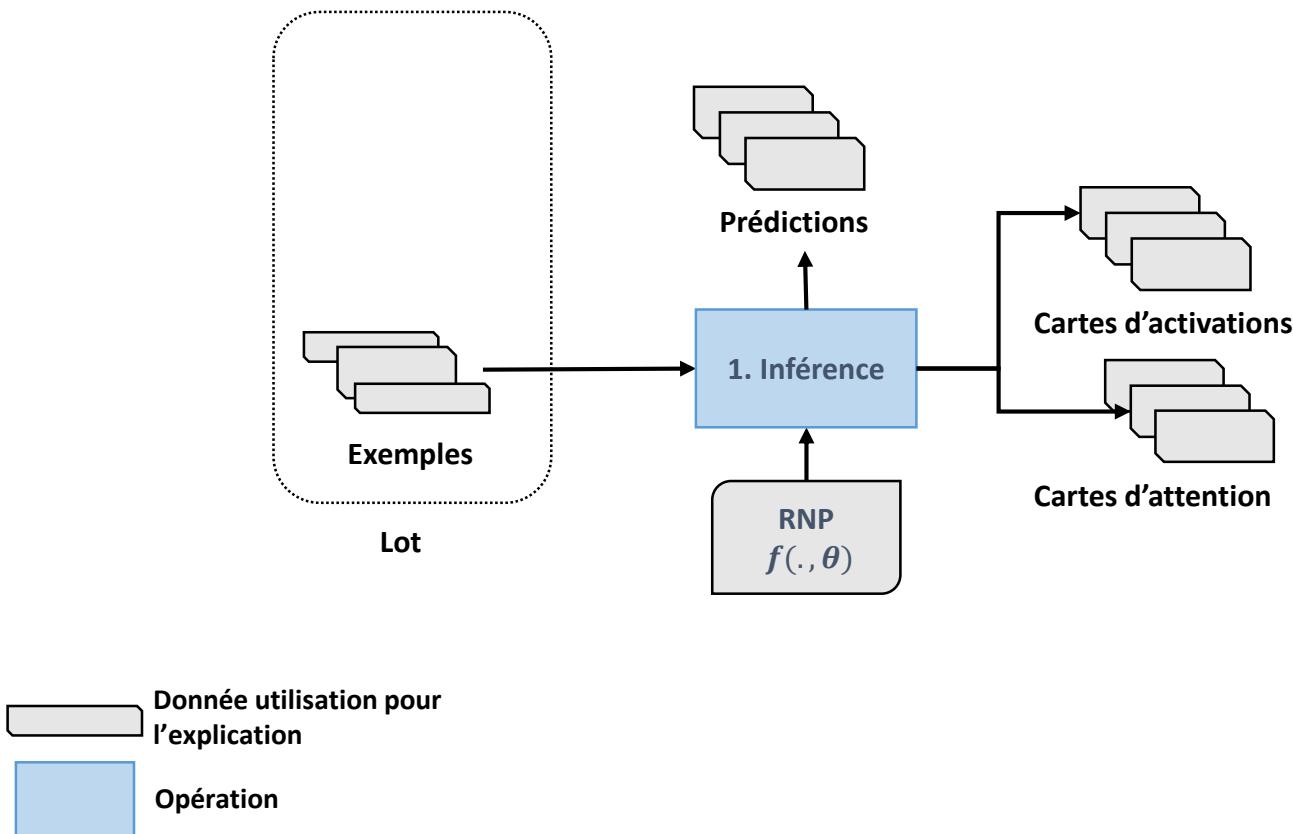
---

- Analyse de la littérature
- Collection de 196 articles
- Conservation de 67 d'entre eux
- Analyse suivant 38 caractéristiques

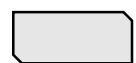
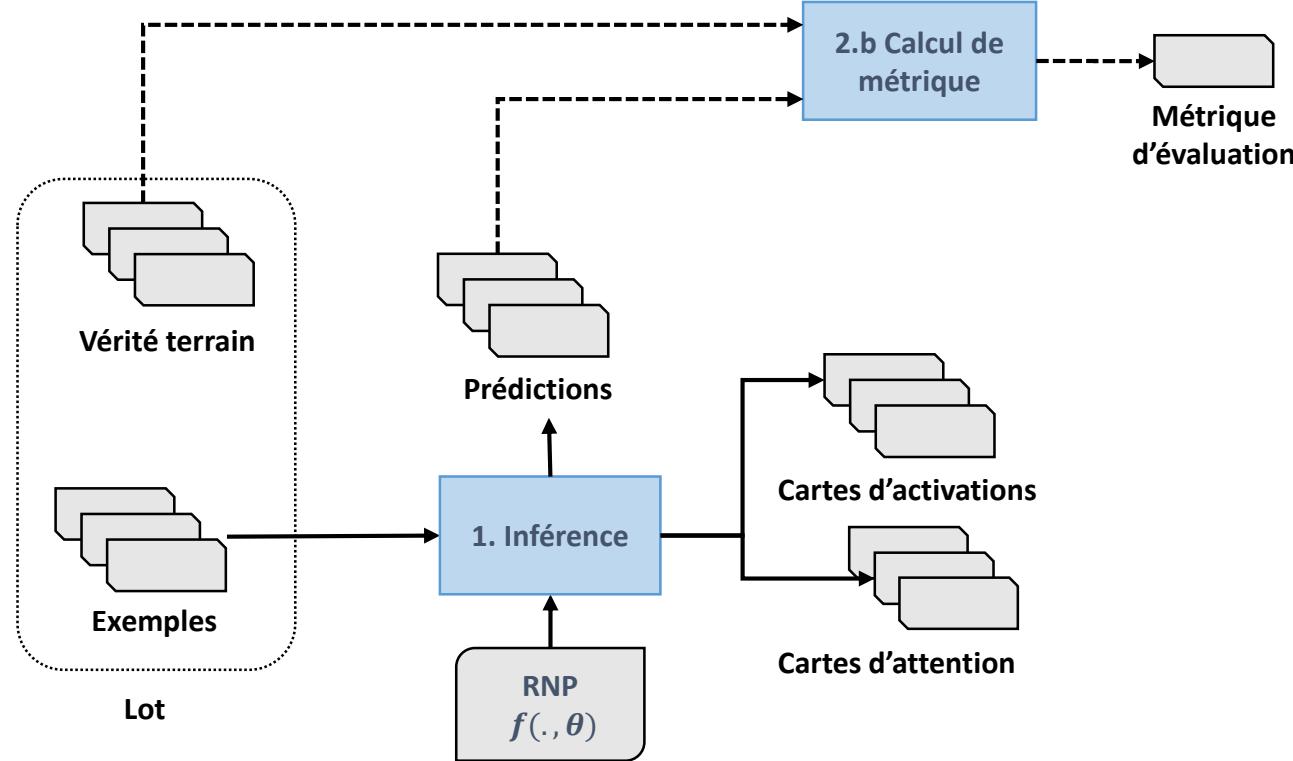


#	System Name	Reference	Venue	Year	Category	Application Domain	DL Model	Users	Interactivity	Phase	Evaluation	Code											
					FA	LF	EE	CE	MB	A	T	E	P	I	M	TR	TE	Q-USr	F-USr	F-CSr	CSt	USc	
01	DG-Viz	[LYY*20]	JMIR	2020	Medical	RNN													✓	✓	✓	✓	✓
02	RetainVis	[JKCK*19]	TVCG	2018	Medical	RNN													✓	✓	✓	✓	✓
03	V-Awake	[CWGvW*19]	CGF	2019	Medical	RNN													✓	✓	✓	✓	✓
04	ViSFE	[WWM20]	ArXiv	2020	Domain agnostic	RNN													✓	✓	✓	✓	✓
05	VisRPDesigner	[HZ*21]	CGF	2021	Domain agnostic	XDL													✓	✓	✓	✓	✓
06	DeepVid	[WGG*19]	TVCG	2019	Domain agnostic	Transformers	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
07	DeepVID	[WGG*19]	TVCG	2019	Domain agnostic	Other	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
08	GLANCE	[vdBvC*20]	IVIS	2020	Medical	CNN												✓	✓	✓	✓	✓	
09	IVDAS	[HSL*21]	IVIS	2021	Bioinformatics	CNN												✓	✓	✓	✓	✓	
10	GANViz	[WGT*18]	TVCG	2018	Domain agnostic	Generative	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
11	explAlner	[SSSE19]	TVCG	2019	Domain agnostic	Variable	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
12	AttributionHeatmaps	[WONNM18]	IEEE Big Data	2018	Domain agnostic	RNN												✓	✓	✓	✓	✓	
13	NNVA	[HLW*19]	TVCG	2020	Bioinformatics	Variable												✓	✓	✓	✓	✓	
14	NJM-Vis	[JCM20]	IUI	2020	Domain agnostic	Variable												✓	✓	✓	✓	✓	
15	BERTViz	[Vig19]	ACL-SD	2019	Domain agnostic	Transformers	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
16	-	[DWSZ20]	PacificVIS	2020	Domain agnostic	RNN												✓	✓	✓	✓	✓	
17	Dodrio	[WTC21]	ACL-SD	2021	Domain agnostic	Transformers	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
18	Attention Flows	[DWB21]	TVCG	2020	Domain agnostic	Transformers	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
19	-	[CHS20]	Vis.Inform.	2020	Linguistics	CNN												✓	✓	✓	✓	✓	
20	-	[HCC*20]	Distill	2020	Game agent	DRL	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
21	TSViz	[SMM*19]	IEEE Access	2019	Domain agnostic	CNN	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
22	-	[CGR*17]	VLAD	2017	Domain agnostic	RNN												✓	✓	✓	✓	✓	
23	AttViz	[SSE*21]	EACL	2021	Domain agnostic	Transformers	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
24	-	[MFH*21]	TVCG	2020	Domain agnostic	CNN											✓	✓	✓	✓	✓		
25	DeepEyes	[PHG*18]	TVCG	2017	Domain agnostic	CNN	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
26	ProtoViewer	[ZDXR20]	VIS	2020	Domain agnostic	CNN	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
27	Deep View	[ZXZ*17]	ICML-Viz	2017	Domain agnostic	CNN	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
28	CNNComparator	[ZHP*17]	VLAD	2017	Domain agnostic	CNN	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
29	DeepVis	[YCN*15]	ICML	2015	Domain agnostic	CNN	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
30	ShapeShop	[HHC17]	CHI	2017	Domain agnostic	Variable												✓	✓	✓	✓	✓	
31	Bluff	[DPW*20]	VIS	2020	Domain agnostic	CNN	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
32	NeuroCartography	[PDD*22]	TVCG	2021	Domain agnostic	CNN	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
33	Summit	[HPRC20]	TVCG	2019	Domain agnostic	CNN	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
34	TopoAct	[RCFW21]	CGF	2021	Domain agnostic	Variable												✓	✓	✓	✓	✓	
35	CNNVis	[LSL*17]	TVCG	2016	Domain agnostic	CNN	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
36	RNNVis	[MCZ*17]	VIS	2017	Domain agnostic	RNN	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
37	DeepCompare	[MMD*19]	CG&A	2019	Domain agnostic	Variable												✓	✓	✓	✓	✓	
38	What-If Tool	[WPB*19]	TVCG	2019	Domain agnostic	Variable												✓	✓	✓	✓	✓	
39	DECE	[CMQ21]	TVCG	2020	Domain agnostic	Variable												✓	✓	✓	✓	✓	
40	-	[BDME20]	VizSe	2020	Cybersecurity	Variable	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
41	GNNLens	[JWW*22]	TVCG	2020	Domain agnostic	GNN	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
42	ActiVis	[KAKC18]	TVCG	2017	Domain agnostic	Variable												✓	✓	✓	✓	✓	
43	DRILIVE	[WZY*22]	TVCG	2021	Game agent	DRL	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
44	SCANViz	[WZY*20]	PacificVIS	2020	Game agent	Generative	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
45	-	[SW17]	VLAD	2017	Domain agnostic	CNN	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
46	SANVis	[PCN*19]	VIS	2019	Domain agnostic	Transformers	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
47	Seq2Seq-Vis	[SGB*19]	TVCG	2018	Domain agnostic	Other												✓	✓	✓	✓	✓	
48	exBERT	[HSG20]	ACL-SD	2020	Domain agnostic	Transformers	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
49	ProtoSteer	[MXC*20]	TVCG	2019	Domain agnostic	Other												✓	✓	✓	✓	✓	
50	PolicyExplainer	[MSHB22]	PacificVIS	2022	Domain agnostic	DRL	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
51	Recat	[WSP*21]	ACM-HCI	2021	Domain agnostic	RNN	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
52	MultiRNNExplorer	[SWJ*20]	PacificVIS	2020	Game agent	DRL	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
53	DQNVis	[WGSY19]	TVCG	2018	Game agent	DRL	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
54	DLRViz	[JWV20]	CGF	2020	Game agent	DRL	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
55	-	[ZZM16]	ICML	2016	Domain agnostic	Environment	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
56	VATUN	[PYN*21]	EuroVis	2021	Domain agnostic	CNN	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
57	M2Lens	[WHJ*22]	TVCG	2021	Linguistics	Variable												✓	✓	✓	✓	✓	
58	Blocks	[BYJ*18]	TVCG	2017	Domain agnostic	CNN	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
59	AEvis	[LLS*18]	TVCG	2020	Domain agnostic	CNN	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
60	TNNVis	[NHP*18]	PacificVIS	2018	Domain agnostic	CNN	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
61	CNN2DT	[JLL*19]	IVIS	2020	Domain agnostic	CNN	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
62	DynamicsExplorer	[HLV*20]	PacificVIS	2020	Robotics	DRL	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
63	LSTMVis	[JSFR18]	TVCG	2017	Domain agnostic	RNN	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
64	USEVis	[JTH*21]	Vis.Inform.	2021	Domain agnostic	Transformers	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
65	Melody	[CBN*20]	ArXiv	2020	Domain agnostic	RNN	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
66	HyperSteer	[WM20]	ArXiv	2020	Domain agnostic	RNN	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	
67	NLIZE	[LLL*19]	TVCG	2018	Linguistics	Other	•	•	•	•	•	•	•	•	•	•	•	✓	✓	✓	✓	✓	

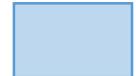
# Ensemble des données accessibles pour expliquer : à l'inférence sans vérité terrain



# Ensemble des données accessibles pour expliquer : à l'inférence avec vérité terrain

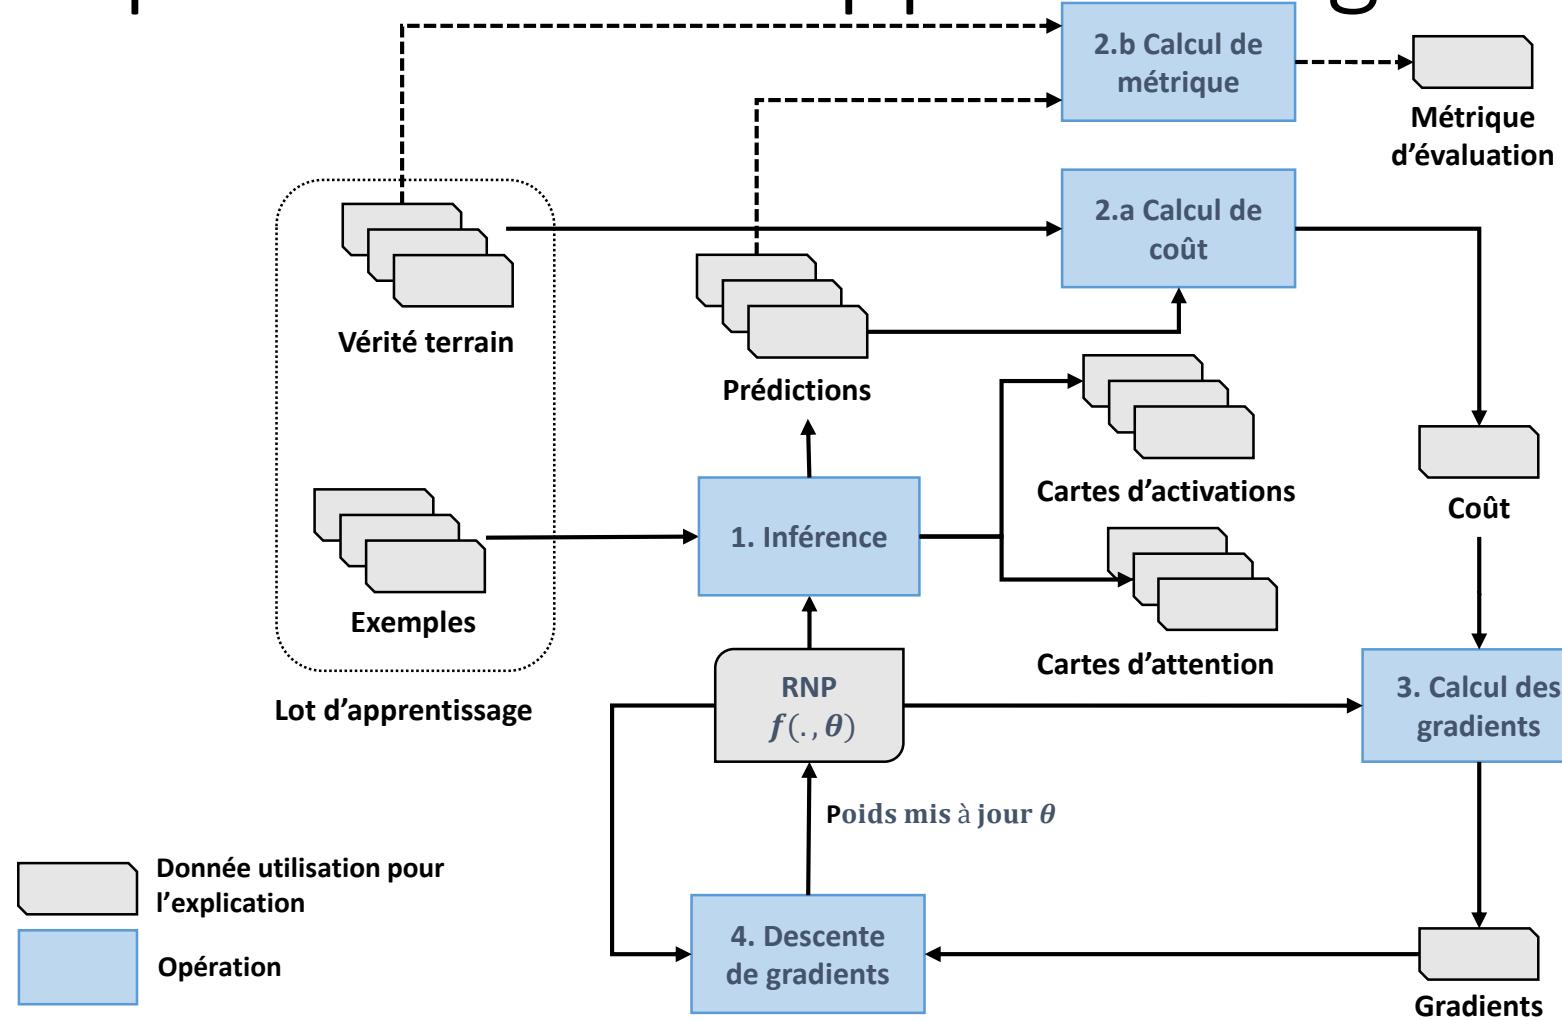


Donnée utilisée pour  
l'explication

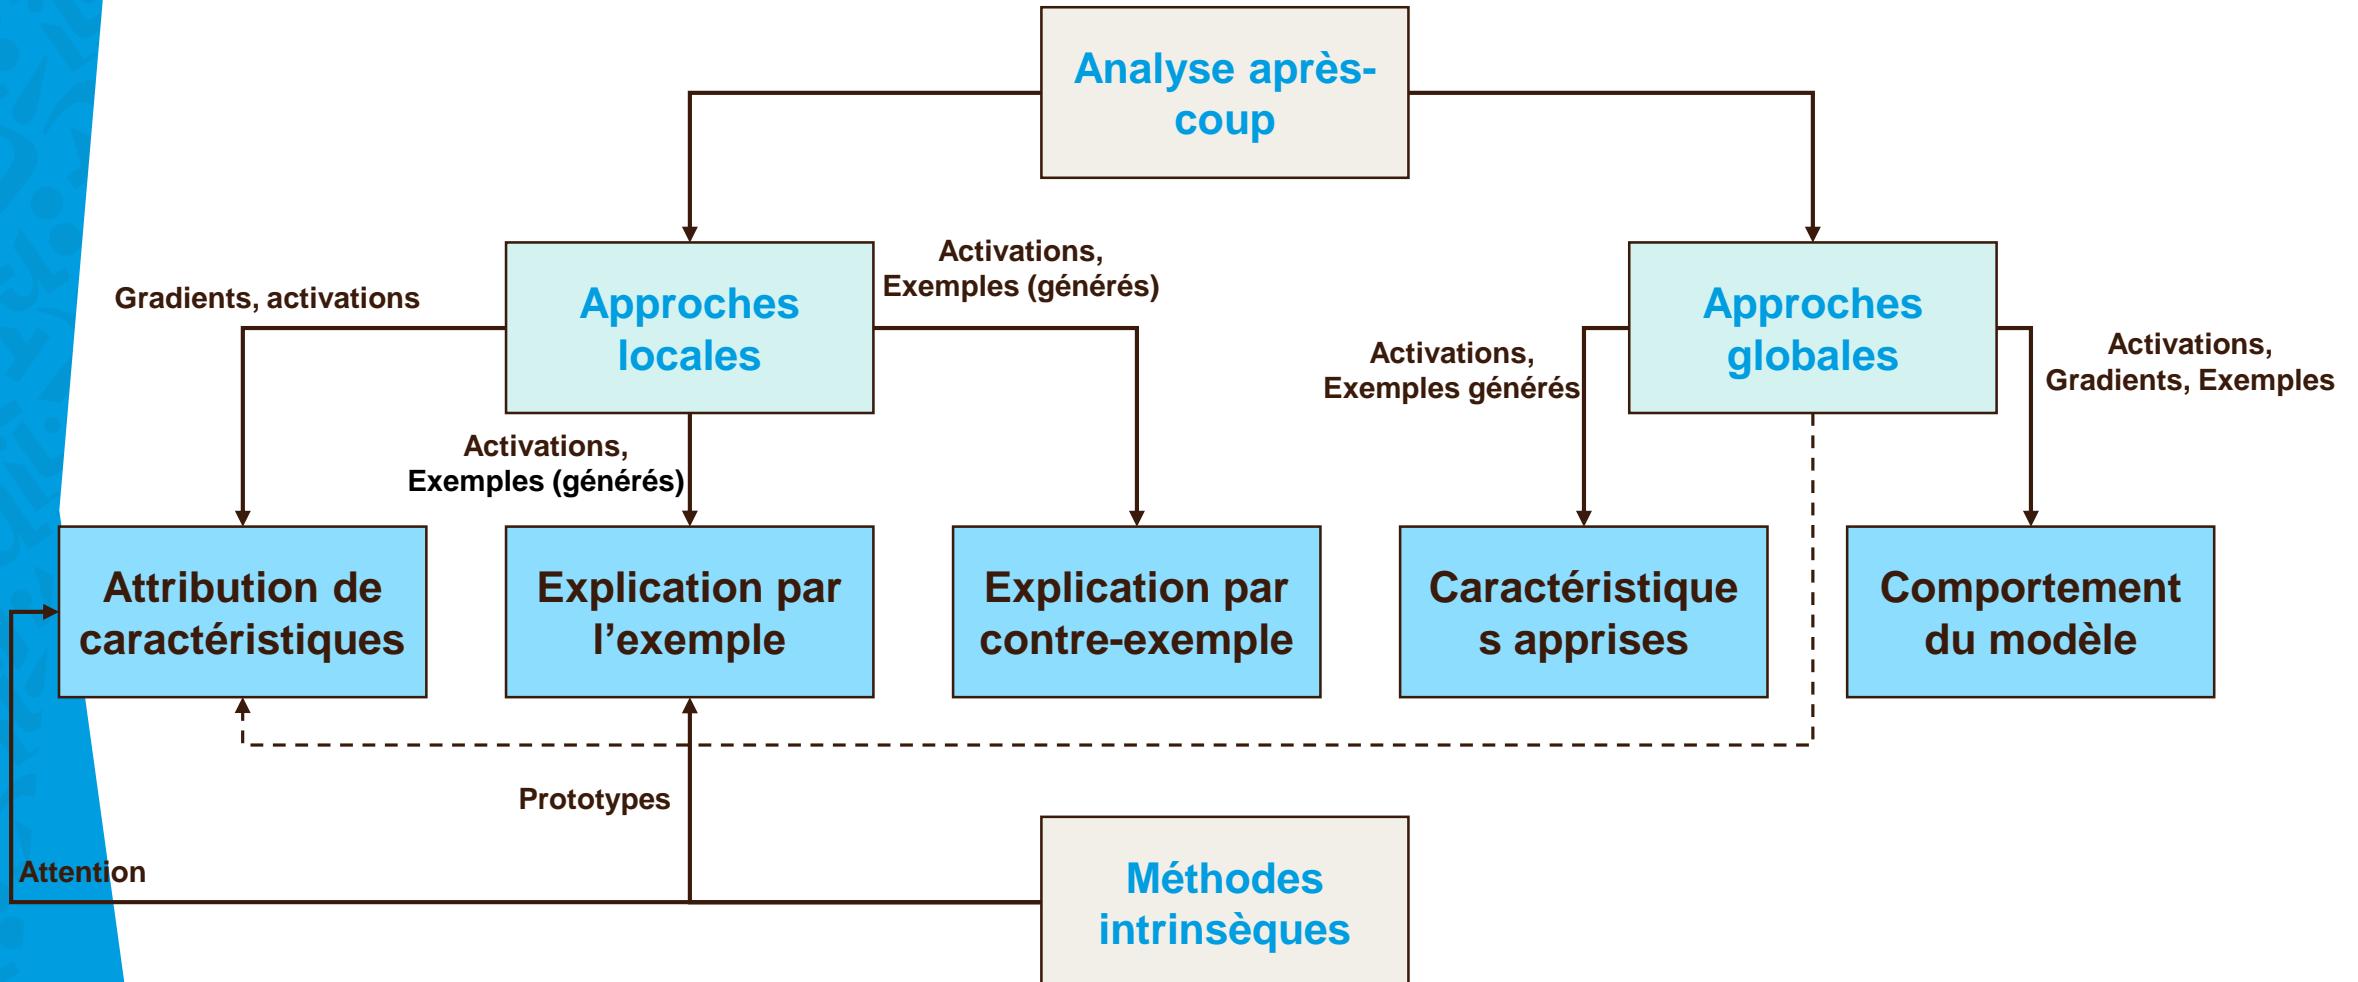


Opération

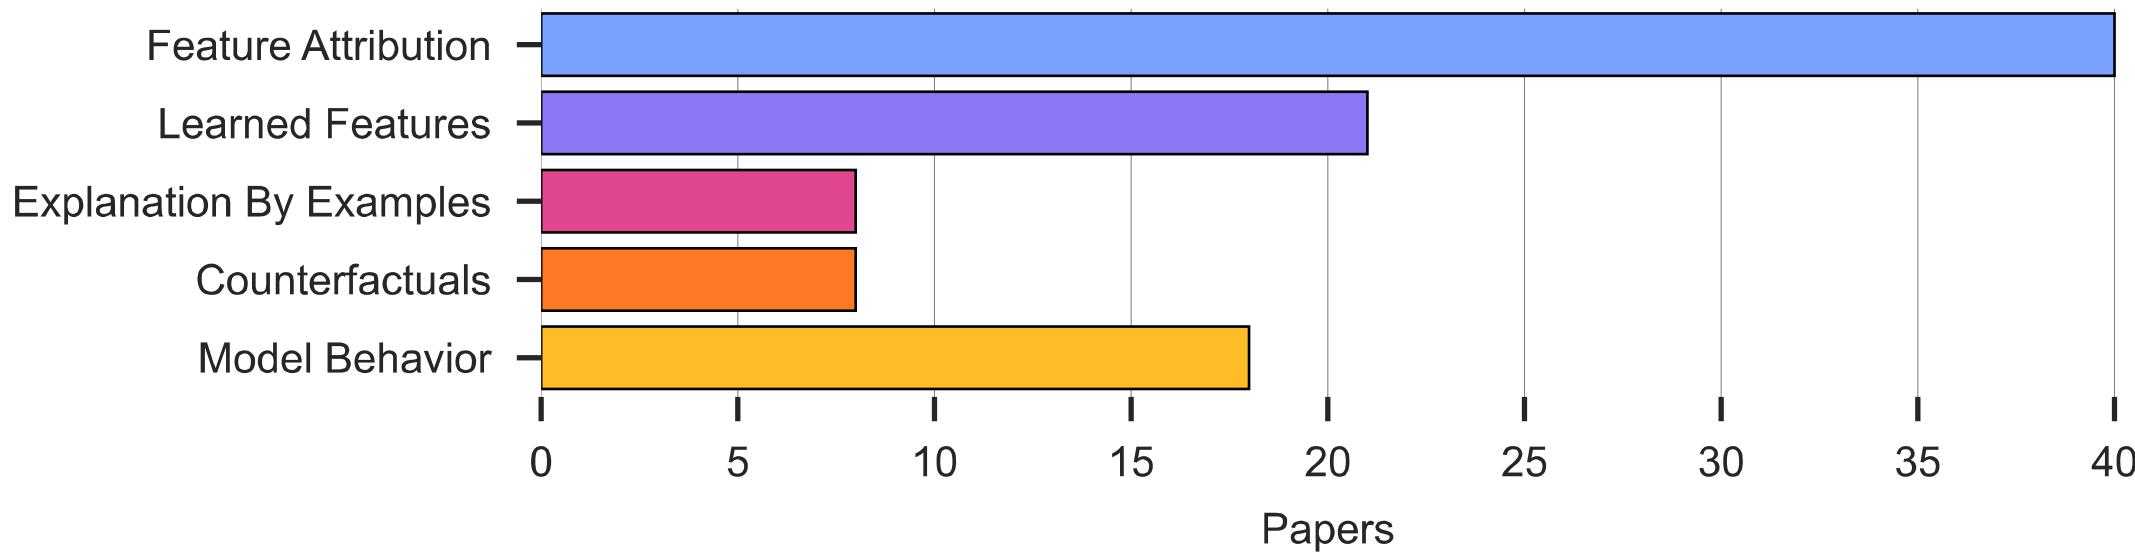
# Ensemble des données accessibles pour expliquer : lors de l'apprentissage



# Taxonomie des méthodes d'explication



# Nette sur-représentation des outils utilisant l'attribution de caractéristiques

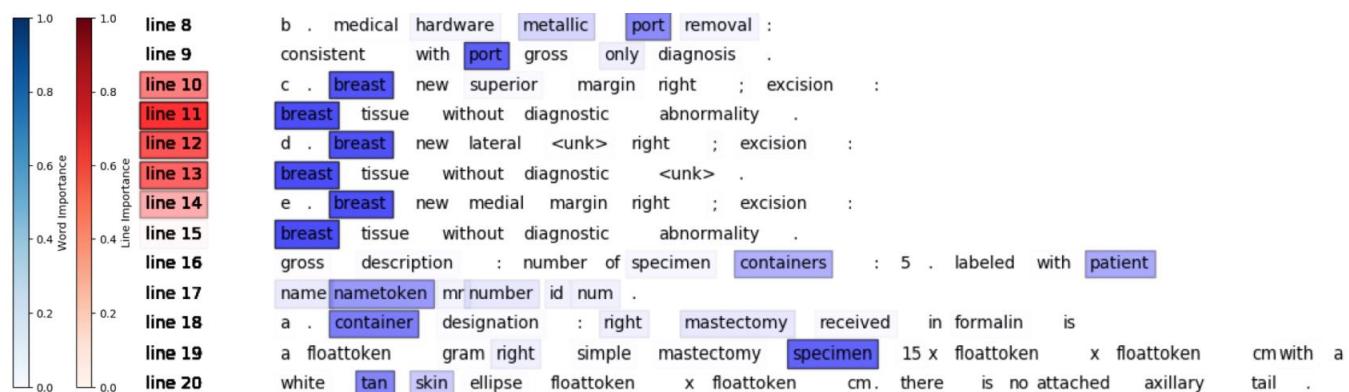


# Attribution de caractéristiques

- Sur quelles données d'entrée le modèle se focalise ?
  - Attribution de score sur chaque donnée d'entrée
- Catégorie la plus étudiée dans la littérature
- Supporte différents types de données
- Utilise différents types de représentations



Selvaraju, Ramprasaath R., et al. "Grad-cam: Visual explanations from deep networks via gradient-based localization." *Proceedings of the IEEE international conference on computer vision*. 2017.

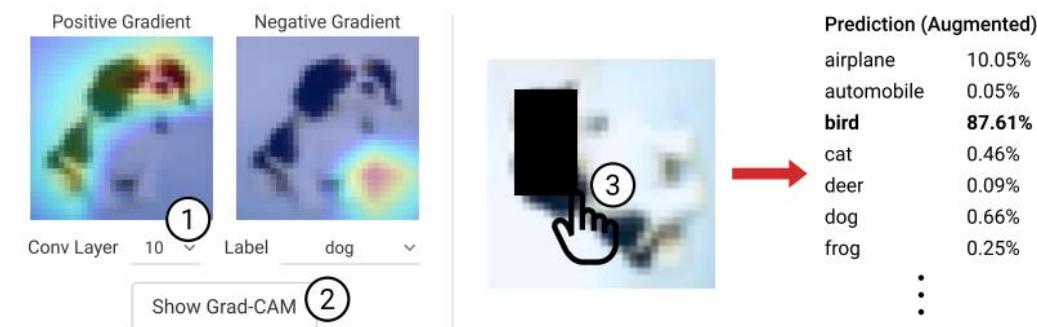


Chae J., Gao S., Ramanathan A., Steed C. A., Tourassi G.: Visualization for Classification in Deep Neural Networks. Tech. Rep., Oak Ridge National Laboratory (ORNL), Oak Ridge, TN, United States, Oct. 2017

# Attribution de caractéristiques : plusieurs tâches sont réalisables

---

- Vérification de la robustesse du modèle
- Analyse des erreurs
- Exploration de données
- Contrôle de l'amélioration du modèle
- Analyse « quoi si ? »
- Détection de biais
- ...

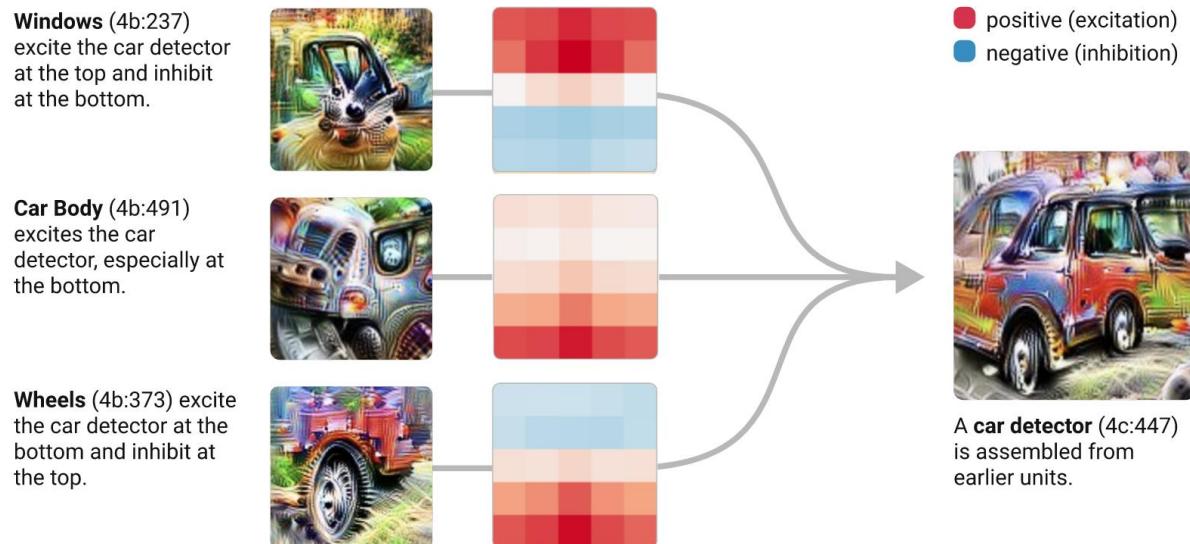


Park, Cheonbok, et al. "Vatun: Visual analytics for testing and understanding convolutional neural networks." *Eurographics Conference on Visualization (EuroVis)-Short Papers*. 2021.

# Caractéristiques apprises

---

- **Qu'est-ce que les données ont appris durant l'apprentissage ?**
  - Génère les caractéristiques qui excitent fortement un neurone
- **Principaux défis**
  - Gérer les milliers de neurones et couches
- **Solutions**
  - Abstractions et partitionnement
  - Encodage spécifiques aux données

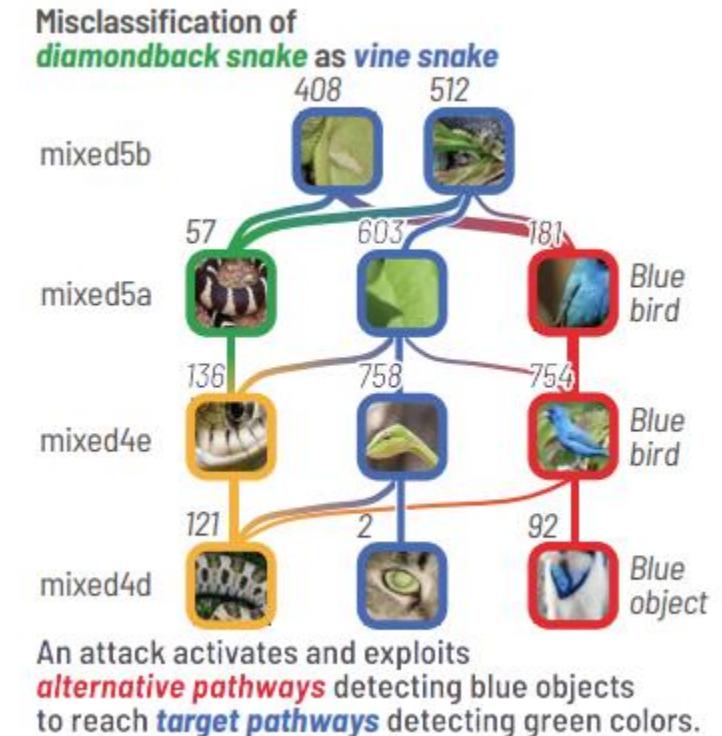


Olah, et al., "Zoom In: An Introduction to Circuits", Distill, 2020.

# Caractéristiques apprises : plusieurs tâches sont possibles

---

- Diagnostiquer les erreurs lors de l'apprentissage
- Vérifier la connaissance apprise
- Comparer les modèles
- Explorer le rôles des neurones et couches
- Comprendre les attaques adversariales
- ...



Das N., Park H., Wang Z. J., Hohman F., Firstman R., Rogers E., Chau D. H. P.: Bluff: Interactively deciphering adversarial attacks on deep neural networks. In Proceedings of the 2020 IEEE Visualization Conference (VIS)

# Explication par exemples

---



- **Quels exemples sont considérés similaires par le modèle ?**
  - Caractéristiques, activations, représentation, sortie, ...
- **Buts**
  - Compréhension de la représentation de la donnée par le réseau
  - Prédictions



Similaire à



# Explication par exemples : plusieurs tâches sont réalisables

---

- Identification d'erreurs
- Correction des hyperparamètres de l'apprentissage
- Amélioration de l'architecture
- Comparaison de prédictions
- Analyse « quoi si ? »

Class: Yellow\_throated\_Vireo  
Prediction: Blue\_winged\_Warbler

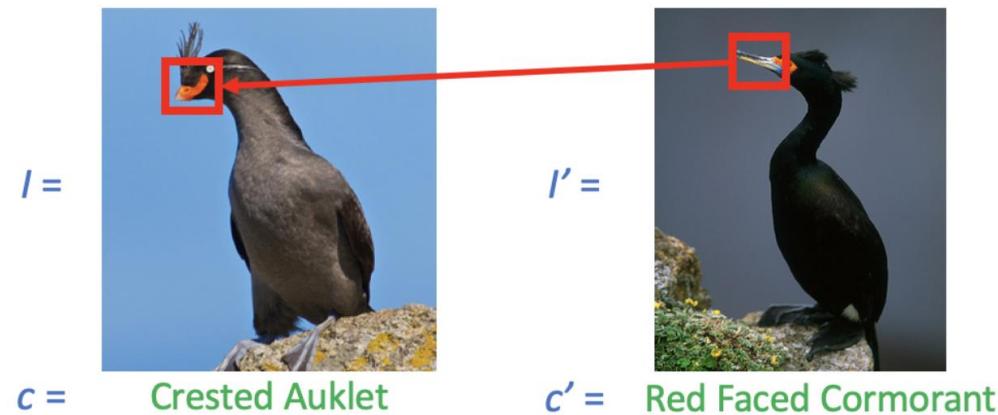


Chan G. Y.-Y., Bertini E., Nonato L. G., Barr B., Silva C. T.: Melody: Generating and visualizing machine learning model summary to understand data and classifiers together. arXiv preprint arXiv:2007.10614 (July 2020).

# Explication par contre-exemple

---

- Que faut-il changer pour obtenir une prédiction différente ?
  - Proposition d'un exemple légèrement différent générant une autre prédiction
  - Ou proposition d'un changement à effectuer

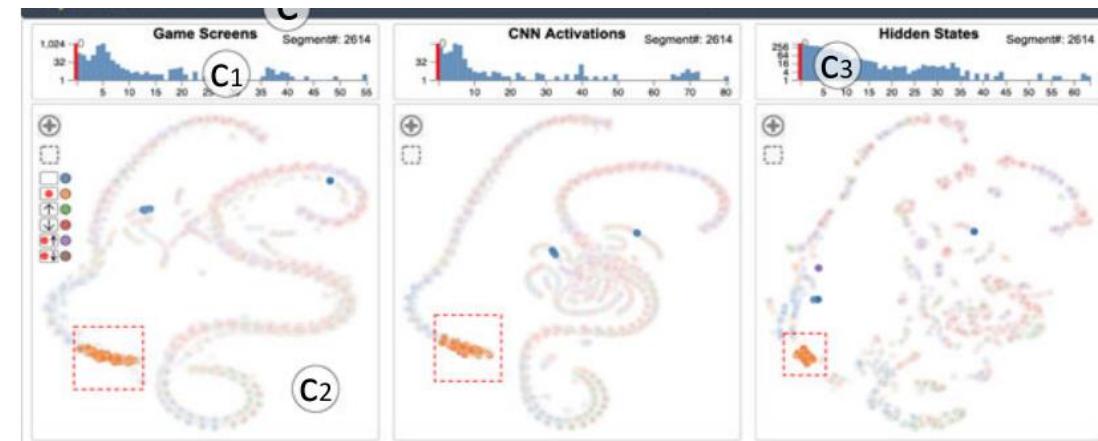


Goyal, Yash, et al. "Counterfactual visual explanations." *International Conference on Machine Learning*. PMLR, 2019.

# Comportement du modèle

---

- Comment le modèle se comporte dans un scénario donné ?
- But
  - Explorer le rôle des différentes couches
  - Visualiser la logique du traitement du réseau
  - Extraire des règles de décision
  - Repose majoritairement sur des outils d'analyse visuelle interactive



# Autres aspects importants

---

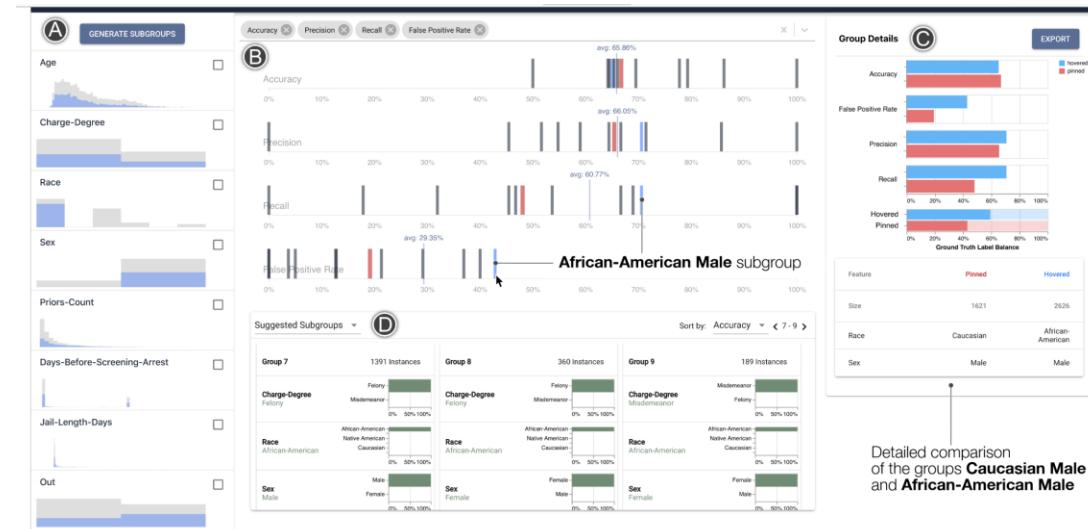
**Le modèle n'est pas  
la seule partie  
importante à  
analyser**

---

# Les données sont plus importantes que les modèles

---

- Les performances des modèles dépendent principalement des données d'apprentissage
- Ces données peuvent souffrir de différents biais
  - Il est important de les connaître
  - Rarement pris en compte
- Ces données peuvent être sujet à oubli
  - Il est important de pouvoir les retirer de la connaissance du modèle
  - Thème de recherche émergeant

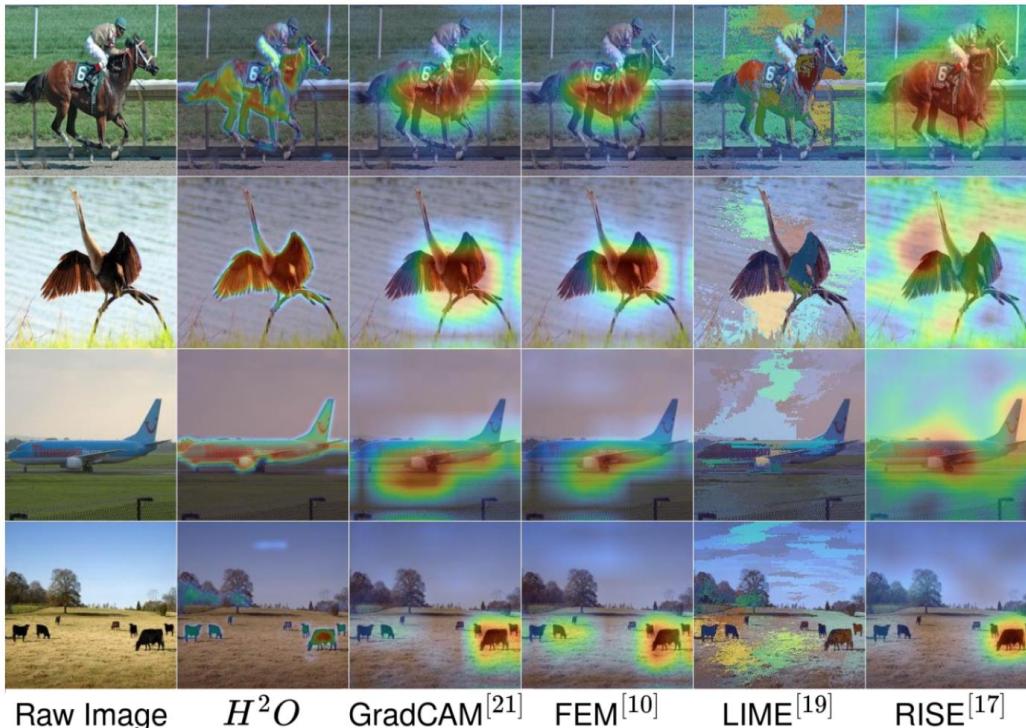


Cabrera, Ángel Alexander, et al. "FairVis: Visual analytics for discovering intersectional bias in machine learning." 2019 IEEE Conference on Visual Analytics Science and Technology (VAST). IEEE, 2019.

# Il est nécessaire d'augmenter la confiance aux modèles et leurs explications

---

Quelle est la vérité terrain d'une explication ?



Comment empêcher la contrefaçon d'explications ?



# Il est nécessaire que le grand public comprenne les limites des systèmes

---

## Les masses de données

- Collecte des données
- Propriété intellectuelle

## Fiabilité des systèmes

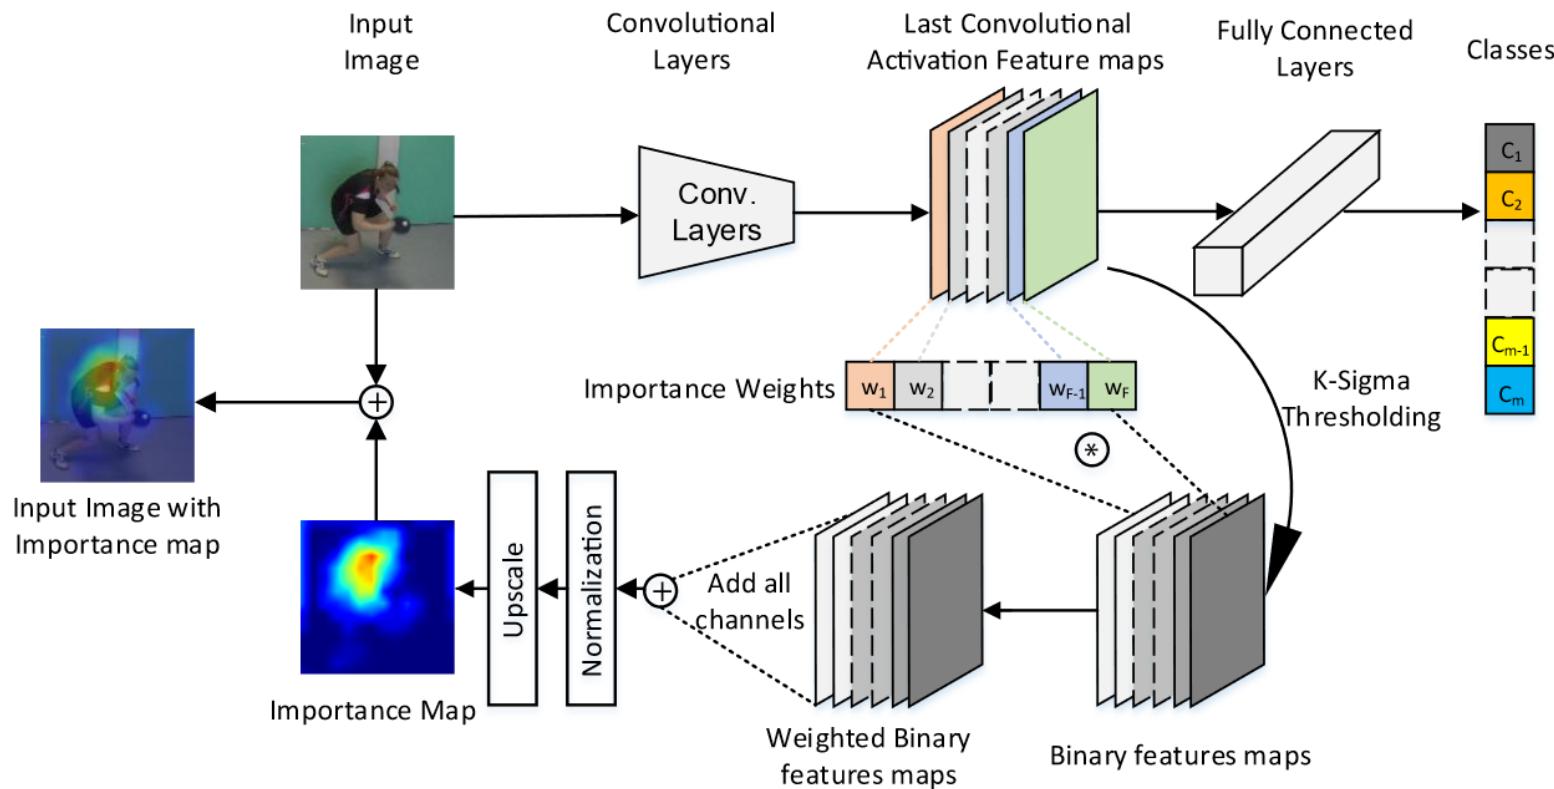
- Ils peuvent ce tromper
- Ils peuvent mieux fonctionner dans certains contextes que d'autres
- On ne sait pas toujours les expliquer

# Sélection de travaux sur l'explicabilité

---

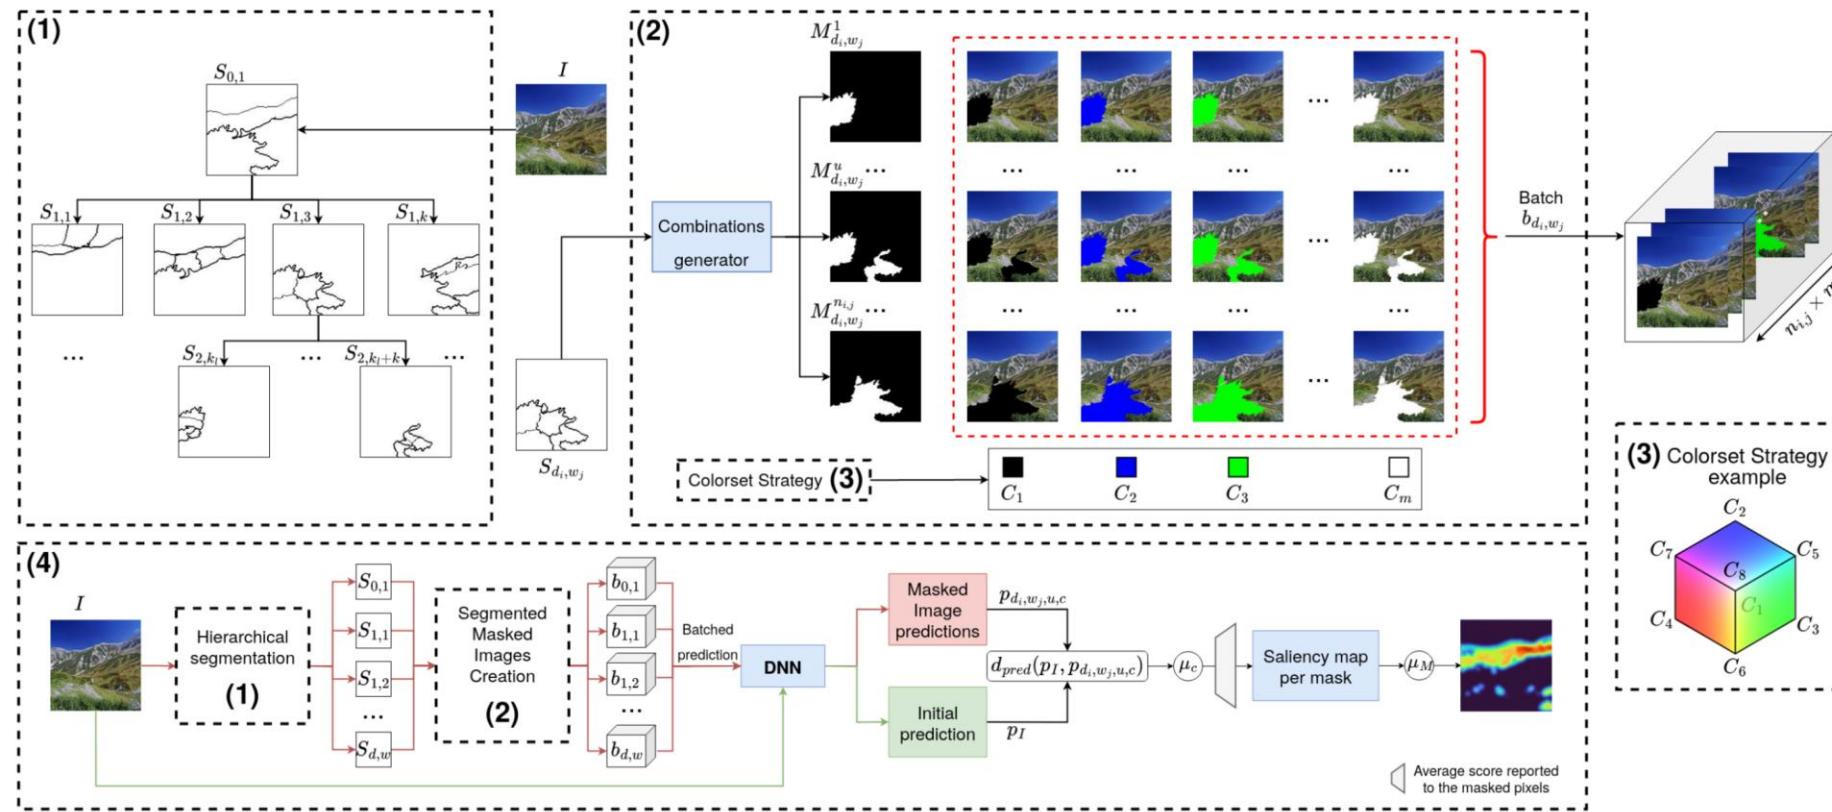


# Features Explanation Method



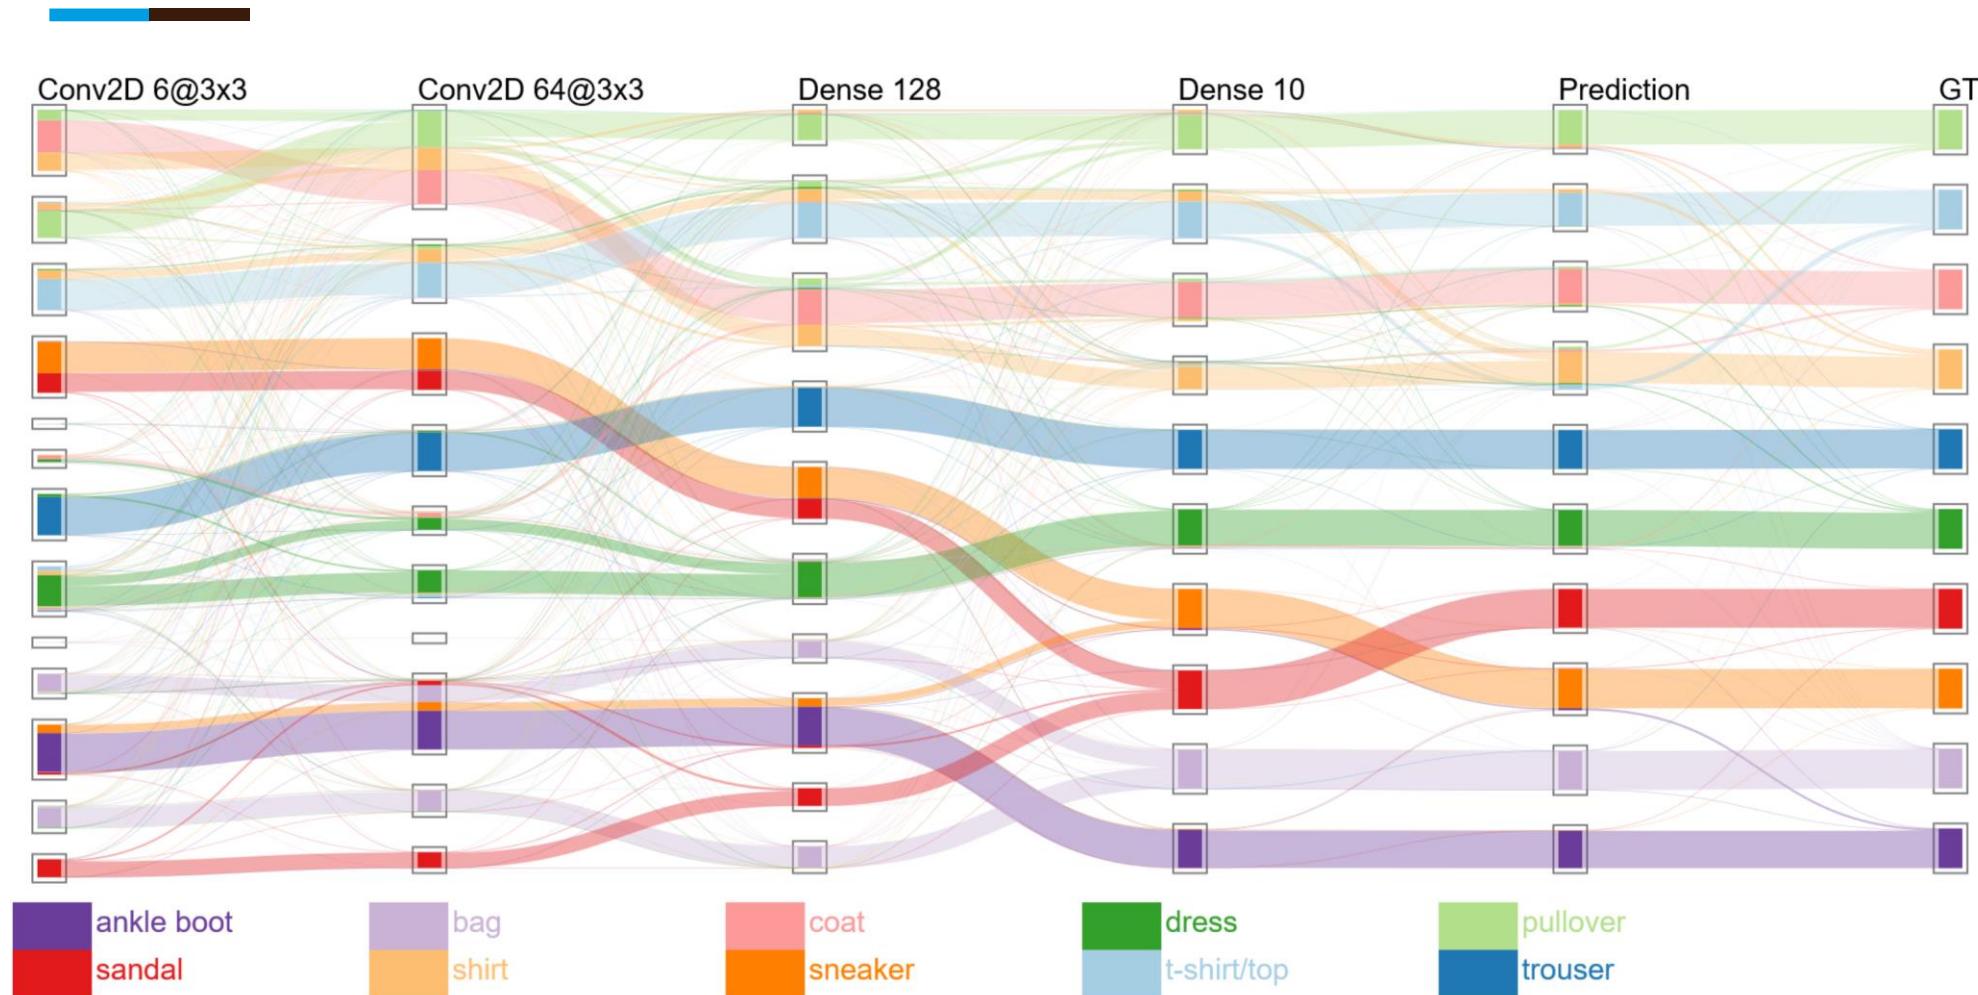
- **Attribution de caractéristiques**
- **Explication locale**
- **Indépendant de la classe**
- **Boîte blanche**
  - Activations dans les réseaux de neurones

# H<sup>2</sup>O: Heatmap by Hierarchical Occlusion

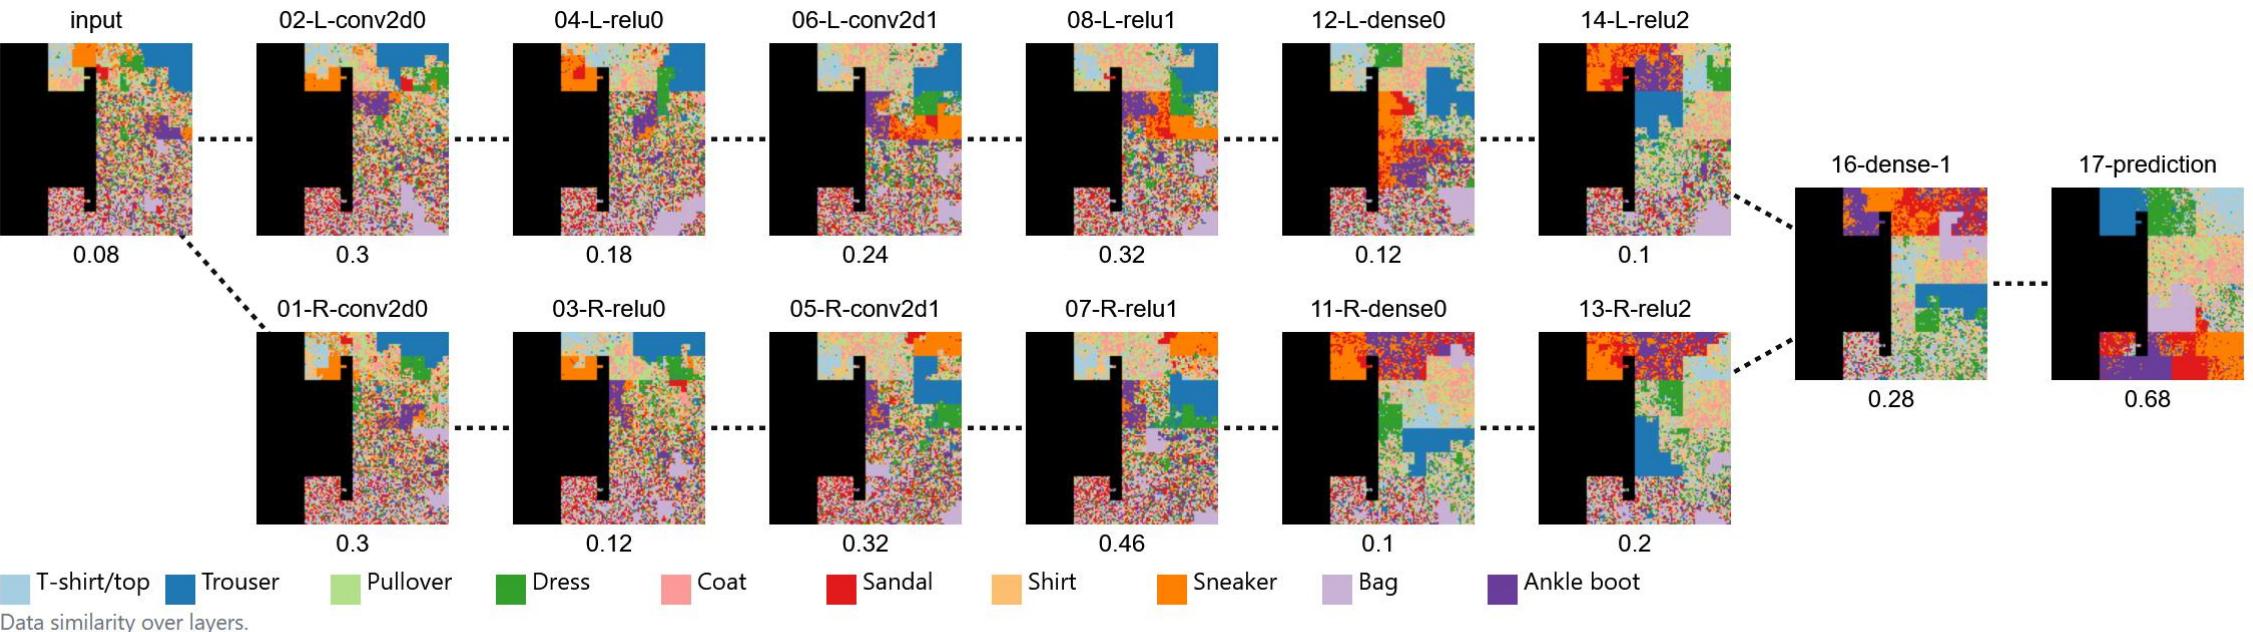


- Attribution de caractéristiques
- Explication locale
- Indépendant de la classe
- Boîte noire

# Deep Dive into Deep Neural Networks with Flows



# Samples Classification Analysis Across DNN Layers with Fractal Curves



Analyse du comportement du modèle

# Zoo Graph: a New Visualisation for Biometric System Evaluation

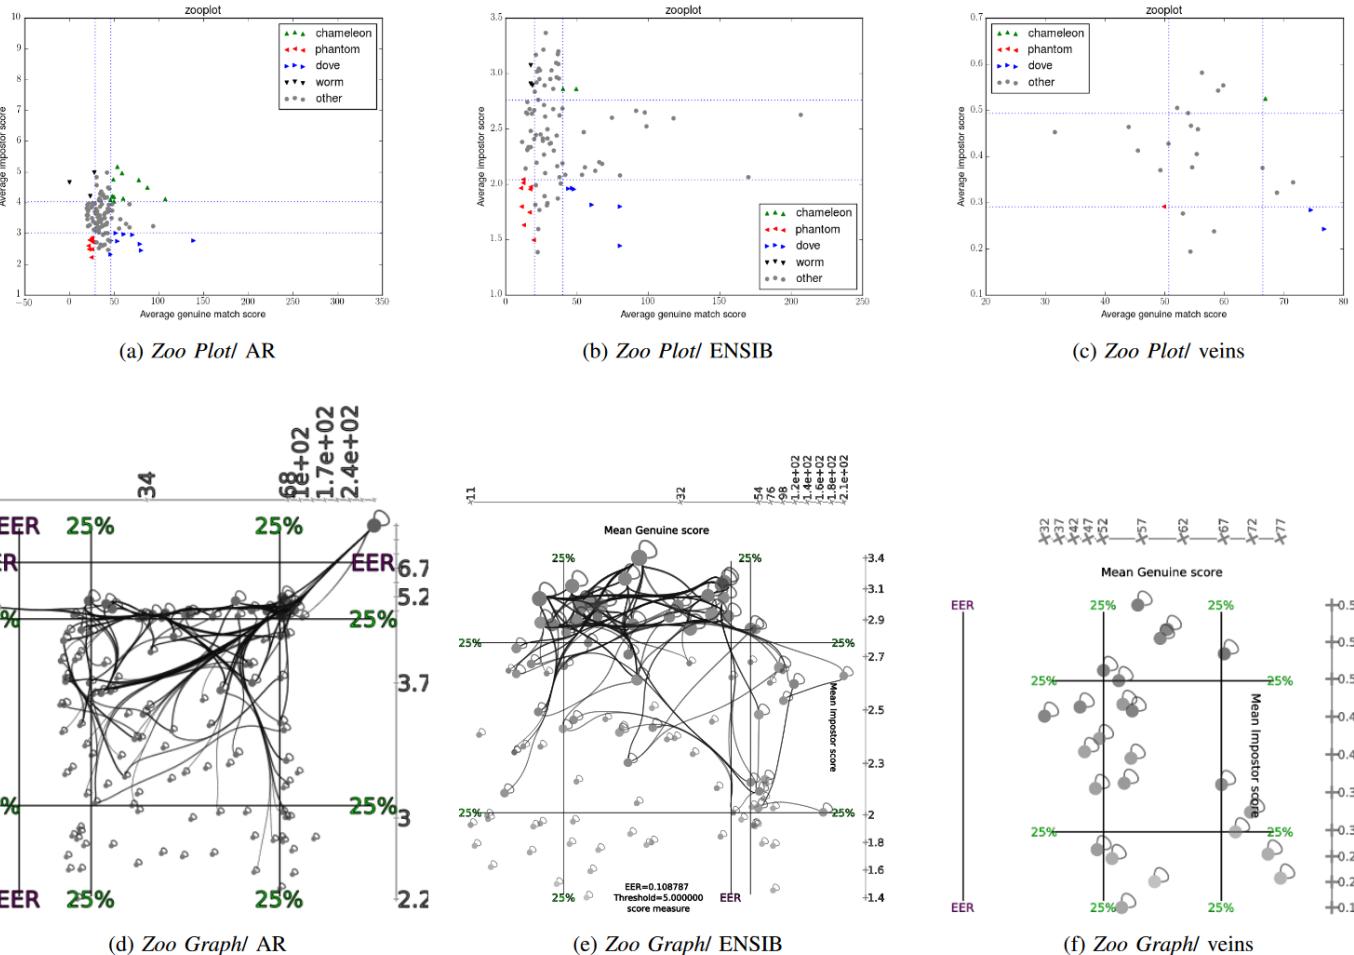
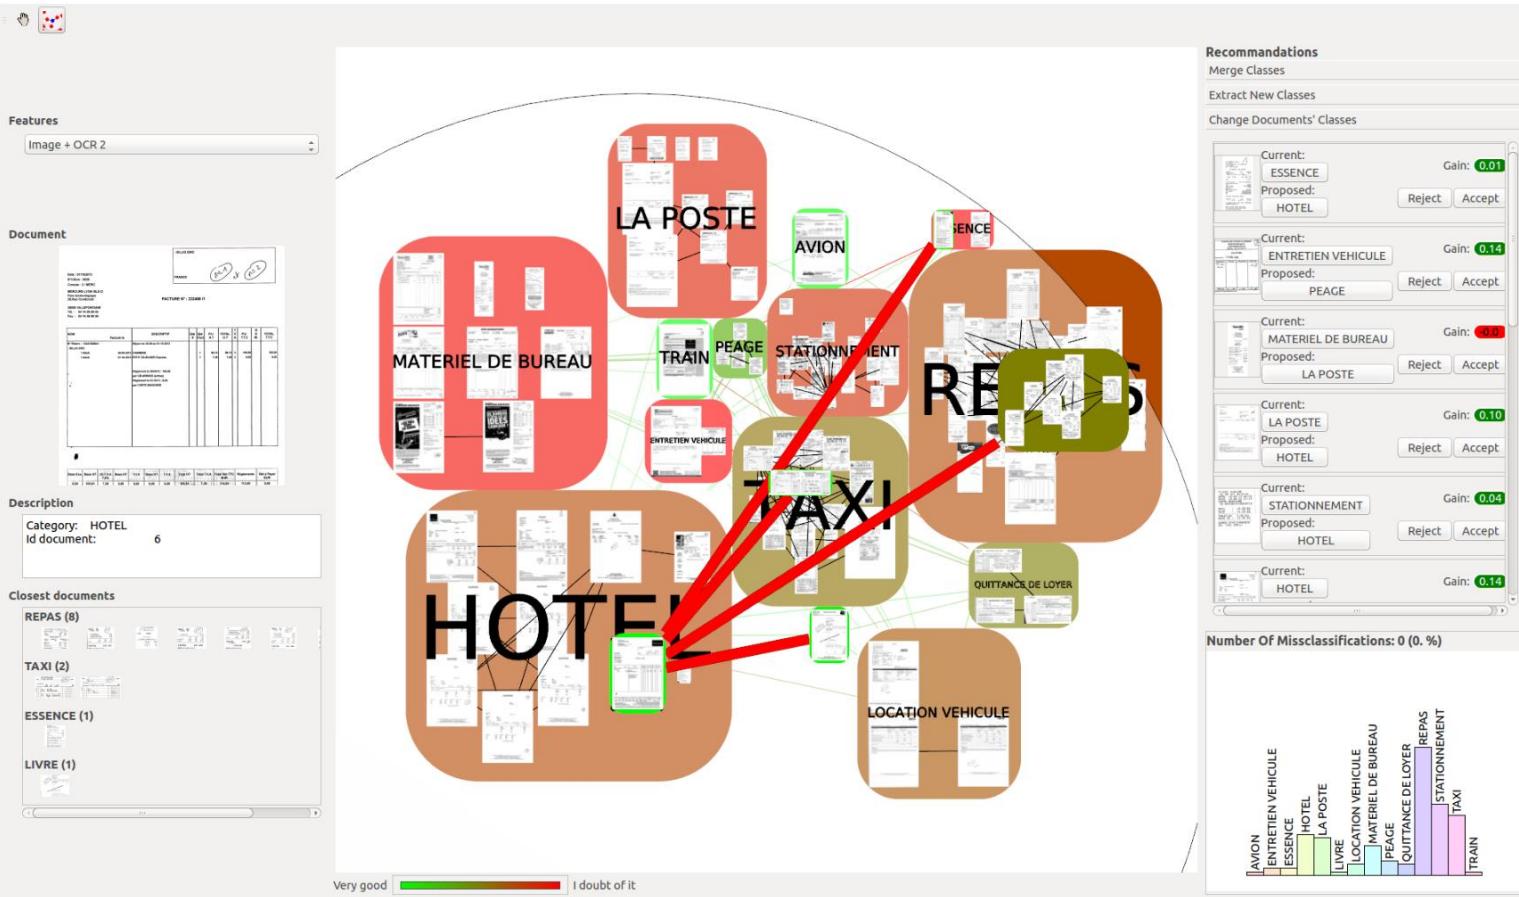


Figure 2. Illustration of the difference between the baseline method (Zoo Plot) and the proposal (Zoo Graph) for 3 biometric databases.

# Visual Graph Analysis for Quality Assessment of Manually Labelled Documents Image Database



# Conclusion rapide

---



# Conclusion

---

- **Les modèles d'apprentissage font des erreurs**
- **Nous sommes capables de les évaluer, mais pas forcément comprendre leurs erreurs**
- **Les méthodes actuelles d'explicabilité ont des limites**
  - Elles imposent toujours à l'utilisateur d'inférer l'information pertinente
  - Il faut ajouter de la sémantique aux explications
  - Elles traitent majoritairement de méthodes à base d'images

# Perspectives de recherche

---

- Inclusion de sémantique dans les explications
- Hybrider les approches intrinsèques et après-coup
- Simplifier les systèmes d'explication pour les rendre grand public
- Et les sciences sociales ?