

# Chapitre 5 : apprentissage artificiel

## 1. Introduction

La reconnaissance d'image fait référence aux technologies qui identifient les lieux, les logos, les personnes, les objets, les bâtiments et plusieurs autres variables dans des images. Les utilisateurs partagent de grandes quantités de données par le biais d'applications, des réseaux sociaux et des sites Web. De plus, les téléphones mobiles équipés d'appareils photo permettent la création d'un nombre illimité d'images et de vidéos numériques. Le grand volume de données numériques est utilisé par les entreprises pour fournir des services meilleurs et plus intelligents aux personnes qui y accèdent.

La reconnaissance d'images fait partie de la vision par ordinateur et d'un processus pour identifier et détecter un objet ou un attribut dans une vidéo ou une image numérique (figure 1). La vision par ordinateur est un terme plus large qui inclut les méthodes de collecte, de traitement et d'analyse des données du monde réel. Les données sont hautement dimensionnelles et produisent des informations numériques ou symboliques sous forme de décisions (figure 2). Outre la reconnaissance d'images, la vision par ordinateur comprend également la détection d'événements, la reconnaissance d'objets, l'apprentissage, la reconstruction d'images et le suivi vidéo.

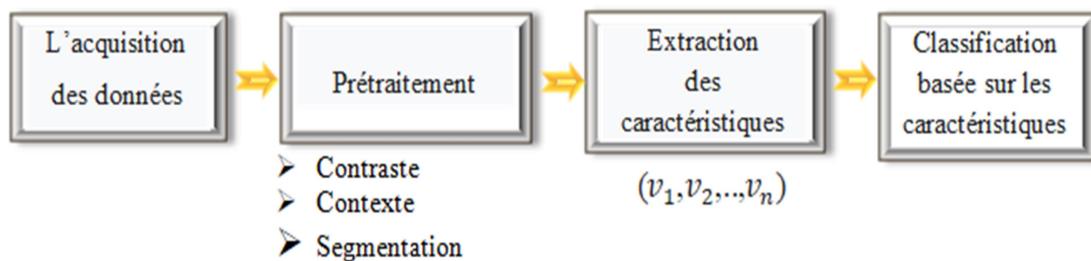


Figure 1 : Système de reconnaissance des images

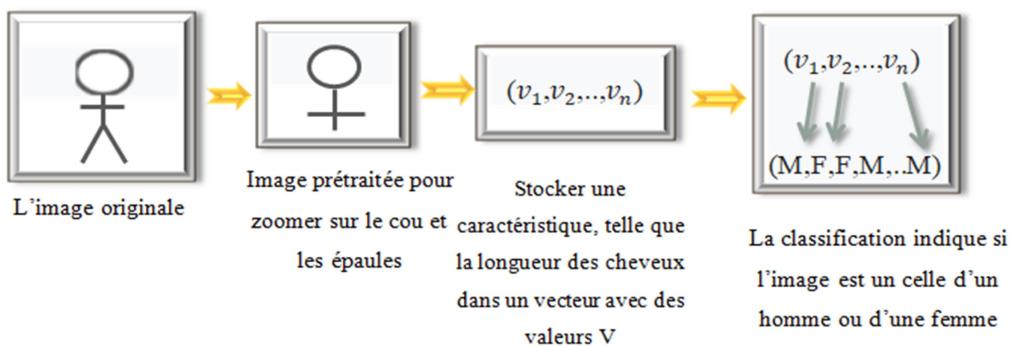


Figure 2: Exemple Homme vs Femme

## 2. L'apprentissage artificiel pour la classification automatique des images

### 2.1. Définition de la Classification

La classification, en général, se réfère au classement ou groupement d'éléments de données dans des ensembles similaires. Cette information est souvent utile dans l'étape d'analyse pour n'importe quel système de traitement du signal ou de données.

La classification a deux significations distinctes. On peut recevoir une série d'observations avec l'objectif d'établir l'existence des classes ou des groupes dans les données. Ou peut savoir avec certitude qu'il y a tant de classes, et l'objectif consiste à instaurer une règle selon laquelle nous pouvons classer une nouvelle observation dans l'une des classes existantes. Le premier type est connu comme **l'apprentissage non supervisé** et le second comme **l'apprentissage supervisé**.

La classification d'image est en général similaire à la classification des données, mais elle peut être différente en fonction de l'application dans laquelle elle est utilisée.

La classification est souvent la dernière étape d'un processus de diagnostic général. Il s'agit généralement d'un tri d'objets dans une image ou plusieurs images dans des classes distinctes. Typiquement, l'image est segmentée ou traitée afin d'isoler les différents objets ou formes les uns des autres, et les différents objets ou images sont étiquetés.

Une étape d'extraction de caractéristiques (attributs) réduit les données en mesurant certaines propriétés ou caractéristiques des objets ou images étiquetés. Ces attributs sont ensuite transmis à un classifieur qui évalue ces caractéristiques et prend une décision relative à la classe de chaque objet ou image.

### 3. Les types de la classification

Les algorithmes de classifications peuvent être répertoriés de plusieurs manières, elle sont divisée en deux types (Figure 3).

#### 3.1. Classification non supervisée

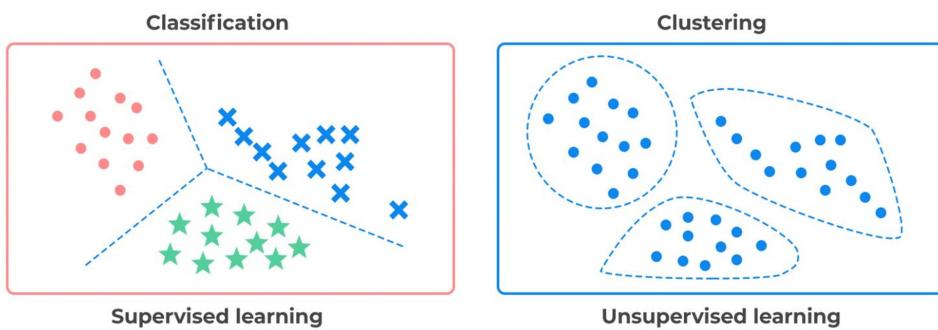
Cette méthode de classification est aussi appelée "classification automatique", (clustering en anglais) ou encore "regroupement". Aucune information a priori l'image n'est connue. On cherche alors à regrouper les différents exemples des images à traiter en fonction de la valeur de leurs descripteurs de manière à créer des classes homogènes

On suppose qu'on dispose d'un ensemble d'objets que l'on note par  $X = \{x_1, x_2, \dots, x_N\}$  caractérisé par un ensemble de descripteurs "D", l'objectif du regroupement est de trouver les groupes auxquels appartiennent chaque objet "x" qu'on note par  $C = \{c_1, c_2, \dots, c_N\}$ . Ce qui revient à déterminer une fonction notée "Ys" qui associe à chaque élément de X un ou plusieurs éléments de C.

Il faut pouvoir affecter une nouvelle observation à une classe. Les observations disponibles ne sont pas initialement identifiées comme appartenant à telle ou telle population. Parmi les méthodes non-supervisées les plus utilisées, citons deux types d'approches : les centres mobiles (k-means) et la classification hiérarchique.



## Supervised vs. Unsupervised Learning



**Figure 3 la classification supervisée vs la classification non supervisée**

### 3.2. Classification supervisée

Dans cette méthode de classification, on dispose déjà d'exemples dont la classe est connue et étiquetée. Une information sur les données à traiter est disponible et est utilisée pour entraîner le processus de classification, cela constitue la phase d'apprentissage du modèle (figure 3). Cette information appelée ensemble d'apprentissage est généralement constituée d'un ensemble d'individus {caractéristiques, classe associée}.

Cet ensemble est alors appris par un algorithme de classification supervisée classique parmi lesquels, on cite : les k-plus proches voisins (k-NN), les réseaux de neurones, les machines à support de vecteurs (SVM), etc.

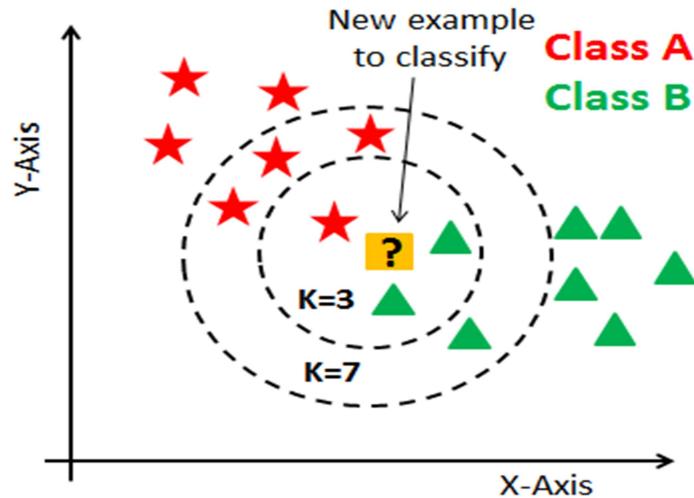
## 4. Méthodes de classification

Les méthodes utilisées pour la classification sont nombreuses, citons: Les arbres de décision, Réseaux de neurones, la méthode des Machines à vecteurs supports (SVM), k plus proches voisins , K-NN.... Voyons quelques méthodes de classification supervisée :

### 4.2. Méthode des k plus proches voisins (k-ppv)

Le principe général de la méthode des k-ppv consiste à rechercher parmi l'ensemble d'apprentissage  $T$ , contenant l'ensemble des individus et leurs classes d'affectation, un nombre  $k$  d'individus parmi les plus proches possibles de l'individu à classer. Puis, l'individu est affecté à la classe majoritaire parmi ces  $k$  individus trouvés. Le nombre  $k$  est fixé a priori par l'utilisateur

Si  $k = 1$ , alors l'individu est affecté à la classe du plus proche voisin de l'ensemble  $T$ . Une variante de la règle de la majorité consiste à prévoir un seuil  $s$  au-dessus duquel une décision de rejet est prise. Ainsi, on peut rencontrer des cas où l'individu n'est affecté à aucune classe.



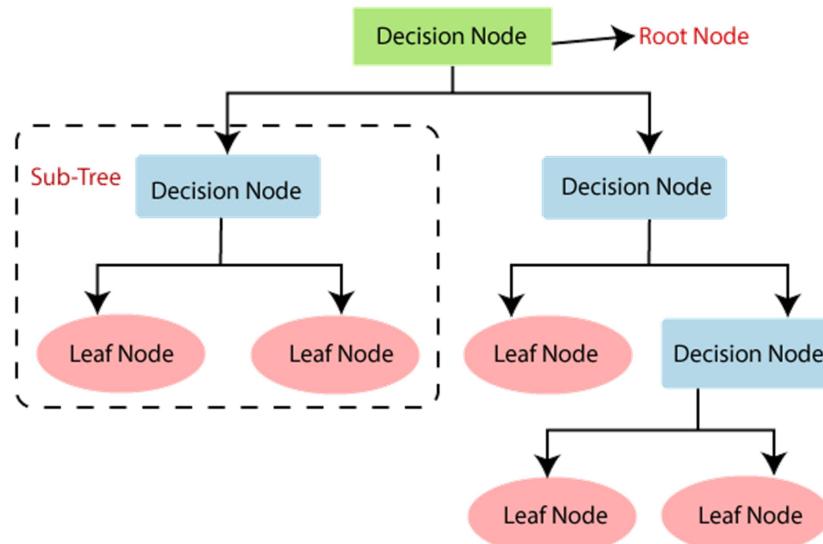
**Figure 4** Méthode de KNN.

#### 4.2 Les arbres de décision

Les arbres de décision représentent une méthode très efficace d'apprentissage supervisé. Il s'agit de partitionner un ensemble de données en des groupes les plus homogènes possible du point de vue de la variable à prédire.

On prend en entrée un ensemble de données classées, et on fournit en sortie un arbre qui ressemble beaucoup à un diagramme d'orientation où chaque nœud final (feuille) représente une décision (une classe) et chaque nœud non final (interne) représente un test. Chaque feuille représente la décision d'appartenance à une classe des données vérifiant tous les tests du chemin menant de la racine à cette feuille.

Les arbres de décisions sont très répandus, à cause de la simplicité de lecture de leurs résultats et leur traitement naturels des cas multi-classe.



**Figure 5** : Structure générale d'un arbre de décision

## 5. Evaluation de la classification

L'estimation des performances nécessite des exemples. Il est évident que ces exemples ne doivent pas être les mêmes que ceux sur lesquels l'apprentissage est effectué, sinon les performances estimées vont être sûrement trop optimistes puisque le classifieur a déjà appris ces exemples au cours de sa construction. Nous avons donc besoin de certains exemples utilisés pour l'apprentissage et d'autre pour le test.

L'ensemble des exemples utilisés pour l'apprentissage est nommé base d'apprentissage. L'ensemble des exemples utilisés pour tester le classifieur est nommé base de test. Si le nombre d'exemples disponible est limité, on utilise souvent une partie de la base disponible comme base d'apprentissage et le reste comme base de test .

### 5.1. Matrice de confusion

La matrice de confusion est un tableau de contingence confrontant les classes obtenues (colonnes) et les classes désirées (lignes) pour l'échantillon. Sur la diagonale principale on trouve donc les valeurs bien classées, hors diagonale les éléments mal classés

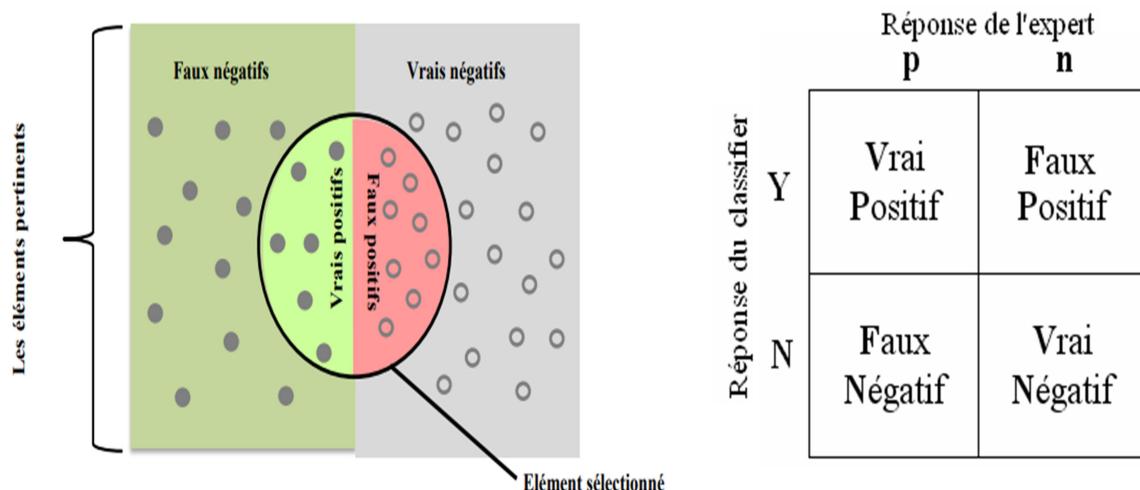


Figure 6 : Matrice de confusion de deux classes

- ✓ **La précision** représente le rapport entre le nombre des éléments pertinents retrouvés (vrais positifs), et le nombre des éléments sélectionnés (vrais positifs+ faux positifs) comme il est représenté sur la figure II.12 à gauche, en d'autre terme c'est la capacité du classifieur d'affecter le modèle à sa vraie classe (par exemple : le chiffre 3 appartient à la classe 3).
- ✓ **Le rappel** est défini par le rapport entre le nombre de vrais éléments reconnus (affectés à leurs vraie classe), et le nombre des éléments existant dans la base de données(les éléments pertinents c.à.d. les

éléments de la classe), par exemple pour la classe de chiffre 3, c'est le nombre des caractères classifiés comme étant 3 et qui sont des 3 par rapport au nombre total des éléments de la classe 3.



**Figure 7: Précision et rappel**

- ✓ **Précision de la classification :** est la proportion d'exemples correctement classés.
- ✓ **La sensibilité** est le nombre d'exemples positifs détectés parmi tous les exemples positifs, par exemple la proportion de chiffre 3 correctement classifiés comme chiffre 3. C'est la même chose que le rappel

$$\frac{\text{Nombre des vrais positifs}}{\text{Nombre des vrais positifs} + \text{Nombre des faux négatifs}}$$

- ✓ **La spécificité** est la proportion d'exemples négatifs détectés parmi tous les exemples négatifs.

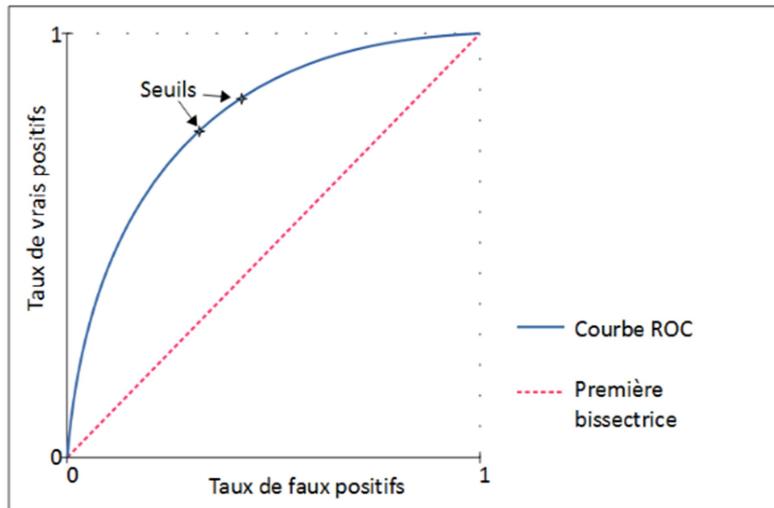
$$\frac{\text{Nombre des vrais négatifs}}{\text{Nombre des vrais négatifs} + \text{Nombre des faux positifs}}$$

- ✓ **F-mesure** est une moyenne harmonique pondérée de précision et de rappel.  $2 * \frac{\text{précision} * \text{rappel}}{\text{rappel} + \text{précision}}$ .

### II.6.2. La caractéristique de performance (ROC)

La caractéristique de performance (ROC), plus fréquemment désignée sous le terme (courbe ROC) (de l'anglais Receiver Operating Characteristic, pour caractéristique de fonctionnement du récepteur) dite aussi caractéristique de performance d'un test ou courbe sensibilité/spécificité, est une mesure de la performance d'un classificateur binaire, c'est-à-dire d'un système qui a pour objectif de catégoriser des éléments en deux groupes distincts sur la base d'une ou plusieurs des caractéristiques de chacun de ces éléments.

Graphiquement, on représente souvent la mesure ROC sous la forme d'une courbe qui donne le taux de vrais positifs (fraction des positifs qui sont effectivement détectés) en fonction du taux de faux positifs (fraction des négatifs qui sont incorrectement détectés)



**Figure 8 : Courbe ROC**