# TD - NSI Les k plus proches voisins

# Un exemple

---

**Objectifs**

- **Thème**
  Un exemple historique d'utilisation de l'algorithme des k plus proches voisins.
- **Prérequis Python**
  Bonne connaissance de Python, dictionnaires, listes, fichiers CSV.
  Il est conseillé d'avoir traité le TD sur les fichiers CSV et celui sur les dictionnaires.
- **Prérequis**
  Avoir étudié le principe et visionné la vidéo de cours sur l'algorithme plus proches voisins.

## 1 Le jeu de données Iris de Fisher

Nous allons ici appliquer l'algorithme des k plus proches voisins sur un exemple concret.
Ce **jeu de données Iris** connu aussi sous le nom de **Iris de Fisher** est un jeu de données présenté en 1936 par Ronald Fisher dans son papier "*The use of multiple measurements in taxonomic problems*". Le jeu de données comprend 50 échantillons de chacune des trois espèces d'iris (Iris setosa, Iris virginica et Iris versicolor). Quatre caractéristiques ont été mesurées à partir de chaque échantillon : la longueur et la largeur des sépales et des pétales, en centimètres.


**Iris Versicolor** **Iris Setosa** **Iris Virginica**

Sur la base de la combinaison de ces quatre variables, Fisher a élaboré un modèle d'analyse permettant de distinguer les espèces les unes des autres.

## 2 Un travail sur les données brutes

Il est possible de télécharger ces données au format csv : *iris_data_set.csv*

iris_data_set.csv saved

```
1  sepal_length,sepal_width,petal_length,petal_width,species
2  5.1,3.5,1.4,0.2,setosa
3  4.9,3.0,1.4,0.2,setosa
4  4.7,3.2,1.3,0.2,setosa
5  4.6,3.1,1.5,0.2,setosa
```

Ce jeu de données est composé de 150 entrées, pour chaque entrée nous avons :

— la longueur des sépales (en cm), première valeur : *sepal_length*;
— la largeur des sépales (en cm), deuxième valeur : *sepal_width*;

— la longueur des pétales (en cm), troisième valeur : *petal_length*;

— la largeur des pétales (en cm), quatrième valeur : *petal_width*;

— l'espèce d'iris : **Iris setosa**, **Iris virginica** ou **Iris versicolor** (label) , cinquième donnée : *species*.

## Exercice 1

En vous aidant du cours sur les fichiers CSV :

1. Importer ce fichier CSV nommé *iris_data_set.csv* sur votre éditeur Python (Spyder, , Jupyter, Edupython ...) : **lien du fichier**.
2. Dans un souci de simplification, nous allons travailler uniquement sur la taille des pétales, et donc supprimer les colonnes "*sepal_length*" et "*sepal_width*".

A partir du fichier initial, créer un fichier .CSV nommé *NouveauFichier.csv* ne conservant que les colonnes longueur pétale, largeur pétale et l'espèce.

3. Profitez-en pour renommer les titres en : *longueur_petale, largeur_petale, espece*.

Vous devrez obtenir un fichier *NouveauFichier.csv* de cette forme :

NouveauFichier.csv saved

```
1  longueur_petale,largeur_petale,espece
2  1.4,0.2,setosa
3  1.4,0.2,setosa
4  1.3,0.2,setosa
5  1.5,0.2,setosa
6  1.4,0.2,setosa
```

Aide : voici le fichier **NouveauFichier.csv** si vous êtes bloqués et le début du code.

```
# Dans l'éditeur Python import csv
def convert(dico):  # à compléter
    return {'longueur_petale':float(dico['...']),
    .... }

fichier = open ("iris_data_set.csv")
table = list (csv.DictReader( fichier, delimiter =","))
iris = [convert(ligne) for ligne in table]
fichier.close()

# Ecriture (export) d'un CSV avec Python

with open ("NouveauFichier.csv", "w") as sortie:
    objet = csv.DictWriter(sortie, ['longueur_petale', 'largeur_petale', 'espece'])

    # Pour écrire la ligne d'entêtes
    objet.writeheader()

    # on prend la table iris en argument
    objet.writerows(iris)
```

## 3 Représentation graphique

On cherche à obtenir une représentation graphique des données.

### Exercice 2

Voici le début du code permettant d'afficher les données du premier style d'Iris, complétez-le afin d'obtenir un graphique de ce type. Vous devez obtenir ce graphique :

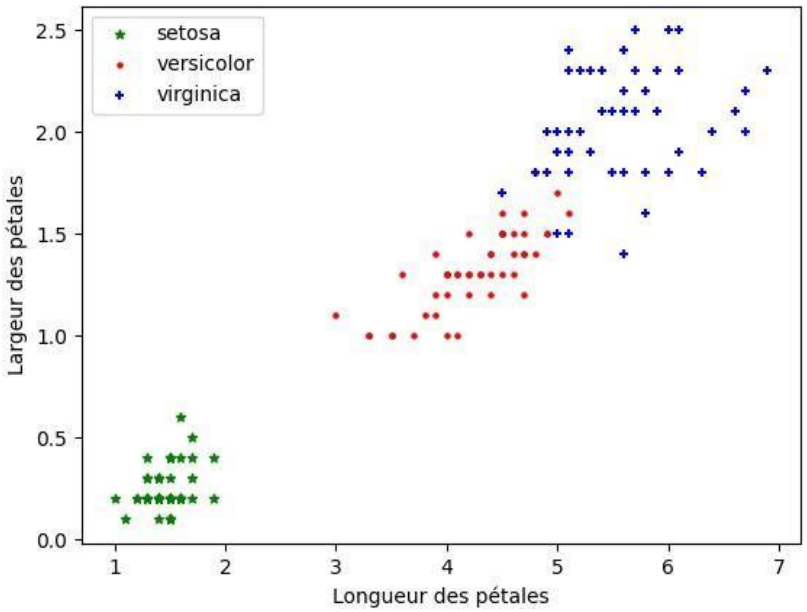

```
# Dans l'éditeur Python

import matplotlib.pyplot as plt

fichier = open("NouveauFichier.csv")
table = list (csv.DictReader (fichier, delimiter= ","))
X_iris_0 = [float  (ligne['longueur_petale']) for ligne in table if ligne ['espece'] == 'setosa']
Y_iris_0 = [float (ligne['largeur_petale']) for ligne in table if ligne['espece'] == 'setosa']
X_iris_1 =…
Y_iris_1 =…
X_iris_2 =...
Y_iris_2 =...
fichier.close()
plt.figure()

# Options de scatter : s = taille du point (20 par défaut),
# marker = symbole, on a        'o' : rond.        's' : carré (square). # '+'
: croix en forme de +.    'x' : croix en forme de x.        '*' : étoile.
plt.scatter(X_iris_0, Y_iris_0, color = 'g' , label = 'setosa', s = 20,  marker = '*'
plt.scatter(X_iris_1, Y_iris_1, color = 'r' , label = 'versicolor', s = 20, marker = '.')
plt.scatter(X_iris_2, Y_iris_2, color = 'b', label = 'virginica', s = 20, marker = '+')
plt.legend() # lable des axes
plt.xlabel('Longueur des pétales')
plt.ylabel('Largeur des pétales')  plt.show()
plt.savefig('plot.png')
```

---

## 4 Deux nouvelle Iris : des conjectures

On va introduire deux nouvelles données et on chercher à déterminer à quelle espèce elles appartiennent.

- Une Iris 1 telle que :
  - longueur du pétale = 2 cm ;
  - largeur du pétale = 0,5 cm .

- Une Iris 2 telle que :
  - longueur du pétale = 2,5 cm;
  - largeur du pétale = 0,75 cm .

## Exercice 3

Introduisez sur votre graphique ces deux nouvelles Iris et conjecturer l'espèce de chacune d'elle. On remarque que pour l'une des deux, c'est assez indécis. Vous devez obtenir ce graphique :

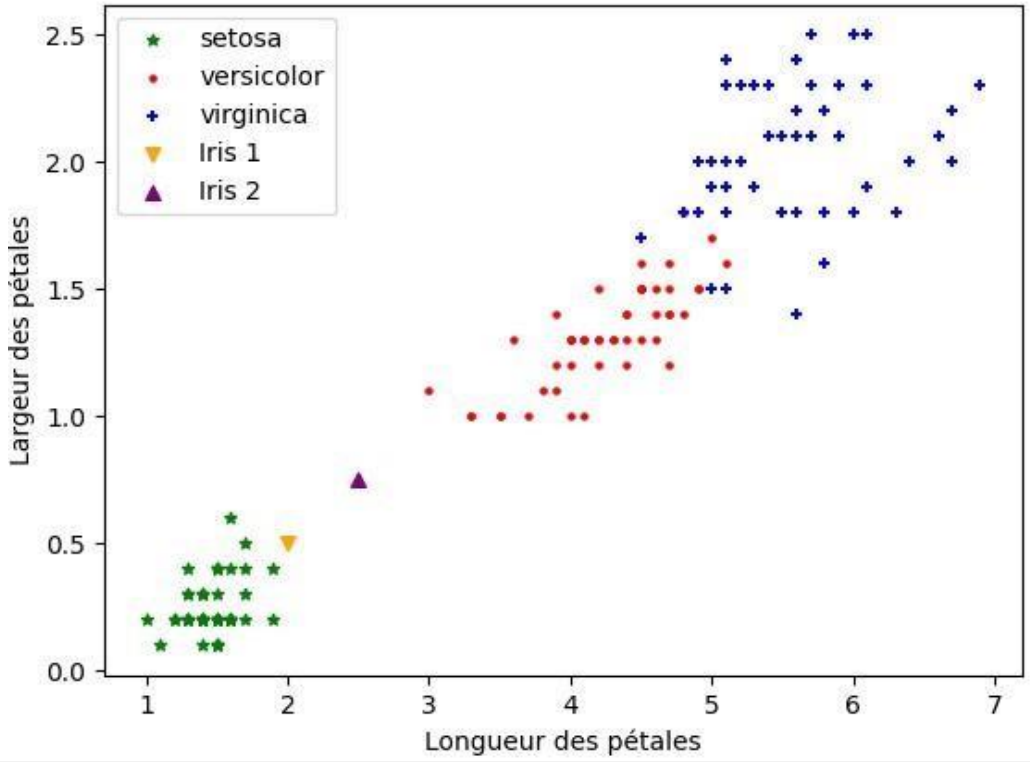


```
# Options de scatter : s = taille du point (20 par défaut),
# marker = symbole, on a  #
'o' : rond.
# 's' : carré (square).
# '+' : croix en forme de +.
# 'x' : croix en forme de x.
# '*' : étoile.
# 'D' : losange (diamond).
# 'd' : losange allongé.
# 'H' : hexagone ('h' est aussi un hexagone, mais tourné).
# 'p' : pentagone.
# '.' : point.
# '>' : triangle vers la droite ('<' pour vers la gauche).
# 'v' : triangle vers le bas ('^' pour vers la haut).
# '|' : trait vertical ('_' pour trait horizontal).
# '1' : croix à 3 branches vers le bas,'2' vers le haut, '3' gauche, # '4' droite).
```

# 5 L'algorithme des *k* plus proches voisins

## 5.1 Le cours

**Algorithme des *k* plus proches voisins**

Soit un ensemble E contenant *n* données labellisées.

1. On calcule les distances entre la nouvelle donnée *C* et chaque donnée appartenant à E à l'aide de la fonction distance *d*.

   On choisira la distance dite euclidienne définie par :

   $$d(A,B) = \sqrt{\left(x_B - x_A\right)^2 + \left(y_B - y_A\right)^2}$$

2. On retient les *k* éléments de E les plus proches de *C*, pour la distance choisie *d*.
3. On attribue à *C* la classe qui est la plus fréquente parmi les *k* données les plus proches.

## 5.2 Fonction knn

**Exercice 4**

On considère que la nouvelle donnée à étudier est B. Par exemple Iris1(2,0.5) ou Iris1(2.5,0.75).

1. Écrire la fonction distance euclidienne **d($x_A$, $y_A$, $x_B$, $y_B$)** et qui renvoie la distance entre les points

   $A\left(x_A ; y_A\right)$ et $B\left(x_B ; y_B\right)$.

2. On cherche à écrire une fonction **knn(liste_dico, k, longueur, largeur)** qui calcule la liste triée des tuples (distance, espece) et retient les *k* premiers.

(a) On part de la liste **iris** obtenue dans l'exercice 1.

Elle est constituée d'une liste de dictionnaires (voir ci-dessous).

(b) On boucle sur les éléments *X* de cette liste.

(c) On va créer une liste L composée des couples (distances, espece).

La distance est celle entre l'élément *X* et *B* (*longueur* ; *largeur*)).

(d) On trie cette liste de tuples par rapport au premier élément, c'est à dire la distance.
**aide** : sorted (*L* , *key = lambda x* : *x*[0])

(e) On renvoie les *k* premiers éléments. **aide** : *L*[0 : *k*]

Consultez sur la page suivante le début du code et les résultats attendus.

**Aide**

Quelques éléments pour trier des listes et des dictionnaires sur les pages 8 et 9.

```
# Pour trier une liste L de tuples par rapport à un élément,
# on utilise la fonction sorted et une clé
# trier/1er élément : sorted(L, key=lambda x: x[0])
# trier/2e élément : sorted(L, key=lambda x: x[1])
def
knn(liste_dico,k,longueur,largeur):
    '''Entrée : liste de dictionnaires (ici iris), le paramètre k et la longueur et largeur de
     l'iris à tester
     Sortie : une liste des k plus proches voisins'''
     L = [ ]
     xb = longueur
     yb = largeur for dico in liste_dico:
            ...
```

```
>>> iris
[{'longueur_petale': 1.4, 'largeur_petale': 0.2, 'espece': 'setosa'},
{'longueur_petale': 1.4, 'largeur_petale': 0.2, 'espece': 'setosa'},
{'longueur_petale': 1.3, 'largeur_petale': 0.2, 'espece': 'setosa'},
{ 'longueur_petale': 1.5, 'largeur_petale': 0.2, 'espece': 'setosa'},
{ 'longueur_petale': 1.4, 'largeur_petale': 0.2, 'espece': 'setosa'},
 ...

k = 10
longueur = 2.5
largeur = 0.75

>>> knn(iris,k,longueur,largeur)
[(0.6103277807866851, 'versicolor'), (0.6946221994724903, 'setosa'),
(0.8139410298049854, 'setosa'), (0.8381527307120104, 'versicolor'),
(0.8381527307120104, 'versicolor'), (0.8381527307120106, 'setosa'),
(0.873212459828649, 'setosa'), (0.9124143795447328, 'setosa'),
(0.9178779875342911, 'setosa'), (0.9656603957913982, 'setosa')]
```

### 5.3 Fonction décision

**Exercice 5**

Il reste maintenant à attribuer à *B* (*longueur* ; *largeur*) la classe qui est la **plus fréquente** parmi les *k* éléments les plus proches.

1. On cherche à écrire une fonction **decision(liste_dico,k,longueur,largeur)** qui renvoie la classe attribuée à l'élément *B* (*longueur* ; *largeur*).

2. Tester votre fonction avec différentes valeurs de k et proposer une classe pour Iris1(2 ; 0,5) et pour Iris2(2,5 ; 0,75).

Justifier votre choix.

```
def decision (liste_dico, k, longueur, largeur):
        '''Entrée : liste de dictionnaires (ici iris), le paramètre k et la longueur et largeur de
       l'iris à tester
         Sortie : l'espèce attribuée'''
        L = knn(liste_dico, k, longueur, largeur)
         ...
```

```
K = 10
Longueur = 2.5
largeur = 0.75

>>> knn(iris, k, longueur, largeur)
[(0.6103277807866851, 'versicolor'), (0.6946221994724903, 'setosa'),
(0.8139410298049854, 'setosa'), (0.8381527307120104, 'versicolor'),
(0.8381527307120104, 'versicolor'), (0.8381527307120106, 'setosa'),
(0.873212459828649, 'setosa'), (0.9124143795447328, 'setosa'),
(0.9178779875342911, 'setosa'), (0.9656603957913982, 'setosa')]
```

```
K = 10
Longueur = 2.5
largeur = 0.75

>>> decision(iris,k,longueur,largeur)
'setosa'
```

**Aide**

Quelques éléments pour trier des listes et des dictionnaires sur l es pages 8 et 9.

## 6 Quelques éléments utiles

### 6.1 Pour trier une liste L de tuples par rapport à un élément

On utilise la fonction **sorted** et une clé. Cette fonction renvoie une liste triée.

— trier par rapport au 1er élément : **sorted(L, key = lambda x : x[0])**

```
>>> liste_tuples = [(2.5, 'Marc'),(12, 'Bernard'),(100, 'Carole')]
>>> L0 = sorted(liste_tuples, key = lambda t: t[0])

[(2.5, 'Marc'), (12, 'Bernard'), (100, 'Carole')]
```

— trier par rapport au 2e élément : **sorted(L, key = lambda x : x[1])**

```
>>> liste_tuples = [(2.5,'Marc'),(12,'Bernard'),(100,'Carole')]
>>> L1 = sorted(liste_tuples, key = lambda t: t[1])

[(12, 'Bernard'), (100, 'Carole'), (2.5, 'Marc')]
```

### 6.2 Pour trier un dictionnaire dico par rapport aux clés ou aux valeurs

Pour trier un objet dict, il suffit d'utiliser la fonction sorted et une clé de tri.
Cette fonction retourne une liste contenant les valeurs triées.
Dans le cas d'un objet dictionnaire, les données (clés + valeurs) sont converties en tuple.

— trier par rapport aux clés : **sorted(dico.items(), key = lambda x : x[0])**

```
>>> dico = {'Pierre':50, 'Anatole':150, 'Zaina':75}
>>> L0 = sorted(dico.items(), key = lambda t: t[0])

[('Anatole', 150), ('Pierre', 50), ('Zaina', 75)]
```

— trier par rapport aux valeurs : **sorted(sorted(dico.items(), key=lambda x : x[1])**

```
>>> dico = {'Pierre':50,'Anatole':150,'Zaina':75}
>>> L1 = sorted(dico.items(), key=lambda t: t[1])

[('Pierre', 50), ('Zaina', 75), ('Anatole', 150)]
```

## 7 Représentation Graphique

**Exercice 6**

Représenter sur votre graphique, un cercle centré sur l'iris à tester, contenant les *k* plus proche voisins.

" **Fin du TD #**