

# Machine Learning (ML)

## Chap 1 : Les concepts de base

David TCHOUTA

Académie Française du Numérique  
[www.frenchtechacademie.fr](http://www.frenchtechacademie.fr)  
Tél/Whatsapp : +33 (0)7 49 62 72 49

June 23, 2022

*"Les gens qui réussissent font le premier pas, ils sont tournés vers l'action." Brian Tracy*

# Table de matières

- 1 Objectifs
- 2 Introduction
- 3 Machine Learning
- 4 Statistics
- 5 Manipulation
- 6 Scatter plot
- 7 Quiz



# Definition

## Definition

Le Machine Learning (ML) est la façon dont nous prenons les données et les transformons en information. Nous utilisons la puissance de calcul des ordinateurs pour analyser les données du passé et prédire les résultats des nouvelles données.

Le Machine Learning est de plus en plus répandu dans nos usages quotidiens. Par exemple, lorsque l'algorithme de Netflix recommande un film, il se base sur les films que les autres utilisateurs ont regardés (y compris nous-même) pour faire cette recommandation. De même que les prix pratiqués par Amazon se basent sur la manière dont les articles similaires ont été vendus par le passé. Il en va de même pour la surveillance des financements illicites.







# Contenu du cours 3

Nous verrons en detail les algorithmes suivants :

- 1 la régression logistique (**Logistic Regression**)
- 2 les arbres de décision (**decision Trees**)
- 3 les forêts aléatoires (**Random Forests**)
- 4 les réseaux de neurones (**Neural Networks**)



# Exercice d'application 1

Moyenne et médiane

Calculer la moyenne et la médiane de la distribution suivante :

0,1,1,2,6

# Les percentiles 1

la **médiane** correspond au **50e percentile (deuxième quartile)**, ce qui signifie que 50% des données sont inférieures à la médiane et 50% des données sont supérieures à la médiane. Elle nous renseigne sur l'endroit où se situe la valeur centrale. Nous nous intéressons également au **25e percentile (premier quartile)** et au **75e percentile (troisième quartile)**.

Le 25e percentile est la valeur qui se trouve à un quart des données. C'est la valeur pour laquelle 25% des données sont inférieures à cette valeur (et 75% des données sont supérieures à cette valeur)

# Les percentiles 2

De même, le 75e percentile correspond aux trois quarts des données. Il s'agit de la valeur pour laquelle 75% des données sont inférieures à cette valeur (et 25% des données sont supérieures à cette valeur).

Reprenons notre distribution de l'âge : 15, 16, 18, 19, 22, 24, 29, 30, 34

Nous avons 9 valeurs, donc 25% des données correspondraient à la 2e valeur environ. La 3e valeur est supérieure à 25% des données, donc le 25e percentile est 18.

De même, 75% des données correspondent à la 6e valeur environ. La 7e valeur est donc supérieur à 75% des données. Ainsi, le 75e percentile est de 29 (la 7e valeur des données).

# Les percentiles 3

## Attention !

S'il y a un nombre pair de données, pour trouver la médiane (ou le 50e percentile), vous prenez la moyenne des deux valeurs du milieu.

Académie

Numérique



# Écart-type & Variance 1

Pour avoir une compréhension plus poussée de la distribution, nous pouvons calculer **l'écart-type et la variance**, qui représentent **les mesures de dispersion des données**.

**Nous mesurons de combien un point se situe par rapport à la moyenne.**

Soit la distribution suivante : **15, 16, 18, 19, 22, 24, 29, 30, 34**  
Sa moyenne est de 23. Si nous calculons la distance de chaque point par rapport à la moyenne, ( $23-15 = 8$  pour la première valeur), on a le tableau suivant :

8, 7, 5, 4, 1, 1, 6, 7, 11

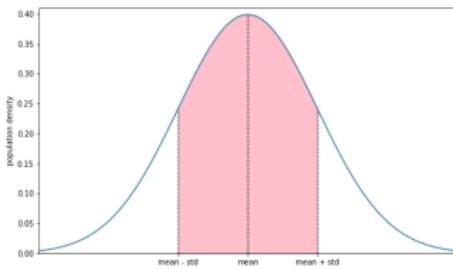
On élève ces valeurs au carré et on les additionne :

$$8^2 + 7^2 + 5^2 + 4^2 + 1^2 + 1^2 + 6^2 + 7^2 + 11^2 = 362$$



# Écart-type & Variance 3

Si nos données sont normalement distribuées comme dans le graphique ci-dessous, 68% de la population se situe dans la fourchette d'un écart-type de la moyenne. Dans le graphique, nous avons mis en évidence la zone située à l'intérieur d'un écart-type de la moyenne. Vous pouvez voir que la zone rose représente environ deux tiers (plus précisément 68%) de la surface totale sous la courbe. Si nous supposons que nos données sont normalement distribuées, nous pouvons dire que 68% des données se situent dans un écart-type de la moyenne.



# Écart-type & Variance 4

Dans notre exemple, bien que les âges ne soient probablement pas exactement distribués normalement, nous supposons qu'ils le sont et disons qu'environ 68% de la population a un âge compris dans un écart-type de la moyenne. Comme la moyenne est de 23 et l'écart-type de 6,34, nous pouvons dire qu'environ 68% des âges de notre population se situent entre 16,66 ( $23 - 6,34$ ) et 29,34 ( $23 + 6,34$ ).

### Attention !

Même si les données ne présentent jamais une distribution normale parfaite, nous pouvons tout de même utiliser l'écart-type pour avoir une idée de la façon dont les données sont distribuées.

# Exercice d'application 3

mérique

## Écart-type & Variance

- 1) Qu'est-ce que la variance ?
- 2) Qu'est-ce que l'écart-type ?
- 3) Comment sont-ils calculés ?
- 4) Que traduit un écart-type élevé ou faible ?

ACC

# Numpy : Calcul Statistique 1

Nous allons utiliser les **fonctions de Numpy** pour le calcul des statistique tel que la **moyenne (mean)**, la **médiane (median)**, les **percentiles**, **std**, **var**.

Importons Numpy et initialisons la variable data pour avoir la liste des âges :

```

import numpy as np
data = [15, 16, 18, 19, 22, 24, 29, 30, 34]
print("mean:", np.mean(data))
print("median:", np.median(data))
print("50th percentile (median):", np.percentile(data, 50))
print("25th percentile:", np.percentile(data, 25))
print("75th percentile:", np.percentile(data, 75))
print("standard deviation:", np.std(data))
print("variance:", np.var(data))
  
```

# Exercice d'application 4

```
Calculez les percentiles  
import numpy as np  
  
print(np. .... (data, 70))
```


# Pandas : Lire et Manipuler les données 1

Pandas est un module Python qui nous aide à lire et à manipuler des données. Ce qu'il y a de bien avec Pandas, c'est que vous pouvez prendre des données et les afficher sous la forme d'un tableau lisible par l'homme, mais elles peuvent aussi être interprétées numériquement, ce qui vous permet d'effectuer de nombreux calculs.

Nous appelons le tableau de données un DataFrame.

# Exercice d'application 5

L'objet Pandas  
Comment appelle-t-on l'objet Pandas (Pandas data object) ?



# Pandas : Lire et Manipuler les données 2

Pour importer Pandas : `import pandas as pd`

Nous allons travailler avec la base de données des passagers du Titanic. Pour chaque passager, nous aurons des données sur eux et nous saurons s'ils ont survécu ou non à l'accident.

Nos données sont stockées dans un fichier CSV (comma-separated values). Le fichier titanic.csv se trouve à <https://gist.github.com/fyyying/4aa5b471860321d7b47fd881898162b7>.

# Pandas : Lire et Manipuler les données 3

La première ligne est l'en-tête, puis chaque ligne suivante est constituée des données d'un seul passager.

Chargons les données dans Pandas de manière à obtenir un Dataframe :

```
import pandas as pd  
data = pd.read_csv(titanic.csv)  
print(data.head())
```

```
In [7]: print(titanic.head())  
PassengerId  Survived  Pclass  ...  Fare Cabin Embarked  
0            1         0       3  ...  7.2500  NaN      S  
1            2         1       1  ... 71.2833  C85      C  
2            3         1       3  ...  7.9250  NaN      S  
3            4         1       1  ... 53.1000  C123     S  
4            5         0       3  ...  8.0500  NaN      S
```

# Exercice d'application 6

## Lire les données

Écrire un programme qui permet d'afficher les 5 premières lignes et les 5 premières colonnes (de Passengerd jusqu'à Sex) de la base titanic.

# Summary Statistics 1

Dans Pandas , la méthode **describe()** permet d'afficher les **statistiques descriptives**.

Pour forcer Python d'afficher un certain nombre de columns :

```
pd.options.display.max_columns = 4
print(data.describe())
```

```
In [76]: print(titanic.describe())
PassengerId  Survived  ...  Parch  Fare
count  891.000000  891.000000  ...  891.000000  891.000000
mean  446.000000  0.383838  ...  0.381594  32.204208
std  257.353842  0.486592  ...  0.806057  49.693429
min  1.000000  0.000000  ...  0.000000  0.000000
25%  223.500000  0.000000  ...  0.000000  7.910400
50%  446.000000  0.000000  ...  0.000000  14.454200
75%  668.500000  1.000000  ...  0.000000  31.000000
max  891.000000  1.000000  ...  6.000000  512.329200
```

NB : Seules les Statistiques de colonnes numériques sont affichées.

## Summary Statistics 2

Signification des indicateurs affichés :

**count** : C'est le nombre de lignes ayant une valeur. Dans notre cas, chaque passager a une valeur pour chaque colonne, donc la valeur est 891 (le nombre total de passagers).

**mean** : c'est la moyenne

**std** : c'est l'écart-type

**min** : c'est la plus petite valeur

**25%** : c'est le 25e percentile

**50%** : c'est le 50e percentile, ou encore la médiane

**75%** : c'est le 75e percentile

**max** : c'est la valeur la plus élevée

La méthode **describe()** permet d'avoir **quelques intuitions par rapport aux données (forme, dispersion, valeurs aberrantes, etc.)**.

# Exercice d'application 7

## Summary Statistics

Quelles sont les valeurs du maximum de Pclass et la médiane de age ?

# Selection d'une seule colonne (Serie)

Pour selectionner une **seule colonne**, on utilise les square brackets([ ]) et le nom de la colonne qu'on veut selectionner.

```
col = data['age']  
print(col)
```

Le **résultat** est ce qu'on appelle une **Pandas Series**. Une **Serie est comme un DataFrame, avec juste une seule colonne.**

# Exercice d'application 8

## Type

```
col = titanic['Survived']
```

Quel est le type de col ?

# Selection de plusieurs colonnes

Pour selectionner plusieurs colonnes, nous mettons le nom des colonnes dans une liste :  
['Survived', 'Age', 'Sex']. Puis nous insérons cette liste dans les brackets comme suit :

```
subset = data[['Survived', 'Age', 'Sex']]
print(subset.head())
```

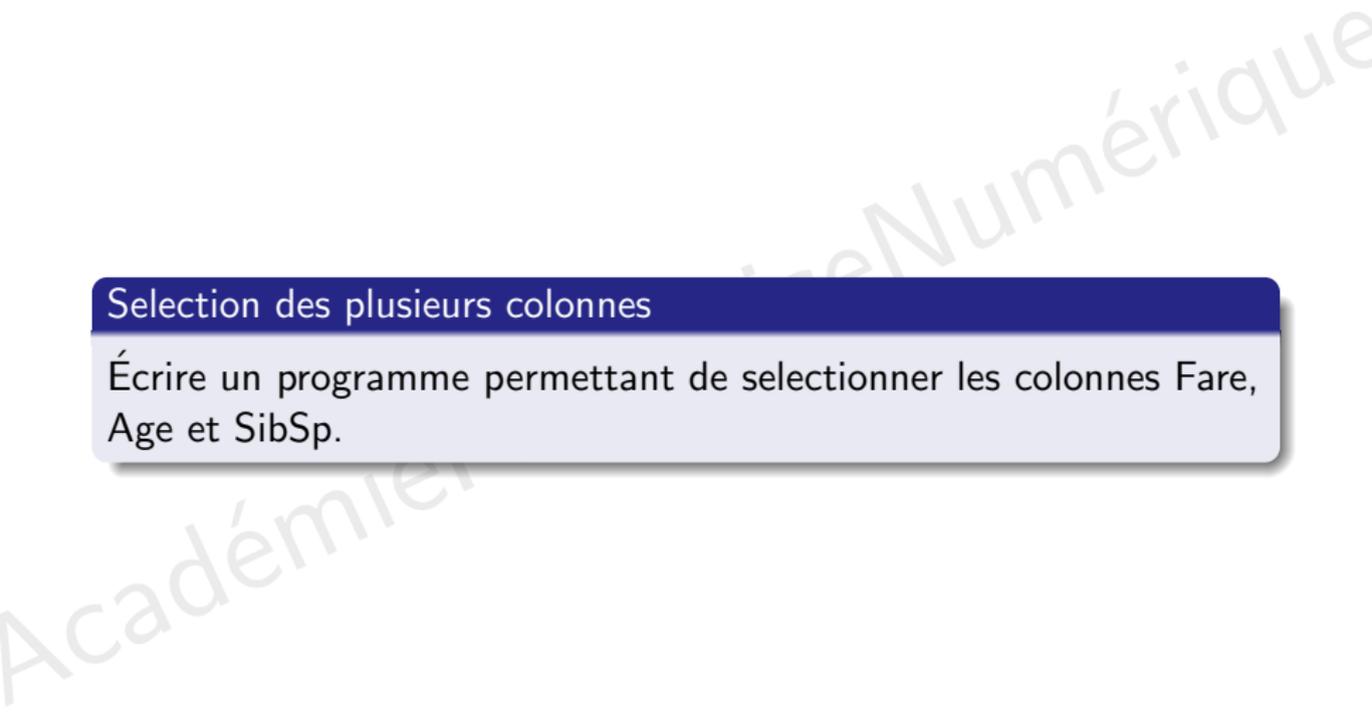
### Attention !

Lorsqu'on veut selectionner **une seule colonne**, on utilise les **single square brackets [ ]**. Lorsqu'on veut **recupérer plusieurs colonnes**, on utilise les **double square brackets [[ ]]**.

# Exercice d'application 9

## Selection des plusieurs colonnes

Écrire un programme permettant de selectionner les colonnes Fare, Age et SibSp.



# Création d'une colonne

Nous allons créer une nouvelle colonne **genre** de type boolean (True pour les male et False pour les female : `data['Sex']=='male')` en se basant sur la colonne Sex : `data['genre'] = data['Sex'] == 'male'`

```
In [103]: print(titanic.head())
PassengerId  Survived  ... Embarked  genre
0            1         0  ...         S     True
1            2         1  ...         C    False
2            3         1  ...         S    False
3            4         1  ...         S    False
4            5         0  ...         S     True
```

## Attention !

Souvent, nos données ne sont pas dans le format idéal. Heureusement, Pandas nous permet de créer facilement de nouvelles colonnes basées sur nos données afin de les formater de manière appropriée.

# Exercice d'application 10

## Création d'une nouvelle colonne

Écrire un programme pour créer la colonne "First Class", qui est True si le passager est dans la Pclasse 1 et False sinon.

Académie

Numérique

# Numpy

Numpy est un module de Python qui permet de manipuler les listes (table data = numpy array) et les tableaux.

**Bien qu'on peut faire certaines opérations sous Pandas, Il est préférable d'utiliser Numpy pour les calculs sur les tableaux. Pandas a en fait été construit en utilisant Numpy comme base.**

# Conversion de Pandas à Numpy

**L'attribut `values` permet de convertir une Pandas Serie en numpy array :**

```
data['Fare'].values  
array([ 7.25 , 71.2833, 7.925, 53.1, 8.05, 8.4583, ...
```

Le résultat est un tableau à une dimension. Vous pouvez le constater puisqu'il n'y a qu'un seul jeu de parenthèses et qu'il ne s'étend que sur la page (et non vers le bas).

# Exercice d'application 11

## Conversion d'une Serie en Numpy array

Écrivez le code pour obtenir un Numpy array des valeurs de la colonne 'Age' à partir du DataFrame titanic.



# Conversion d'un Pandas DataFrame en Numpy array

Si nous avons un **Pandas DataFrame** (au lieu d'une Pandas Serie comme précédemment), nous pouvons toujours utiliser l'**attribut values**, mais **il renvoie un numpy array à 2 dimensions** :

```
data[['Pclass', 'Fare', 'Age']].values
```

```
array([[ 3.      ,  7.25   , 22.     ],
       [ 1.      , 71.2833 , 38.     ],
       [ 3.      ,  7.925  , 26.     ],
       ...,
       [ 3.      , 23.45   ,   nan   ],
       [ 1.      , 30.     , 26.     ],
       [ 3.      ,  7.75   , 32.     ]])
```

C'est un **numpy array** à **deux dimensions**, car il y a **deux square brackets**.

# Exercice d'application 12

## Conversion d'un Pandas DataFrame en Numpy array

Quelle est la dimension du numpy array renvoyé par l'instruction suivante : `titanic[['Sex', 'Survived', 'Age']].values` ?

Académie

Numérique

# L'attribut shape

Nous utilisons **l'attribut shape** pour déterminer la **taille de notre numpy array**. La **taille** nous indique le **nombre de lignes et de colonnes de nos données**.

```
arr = data[['Pclass', 'Fare', 'Age']].values  
print(arr.shape) ==> (891, 3)
```

Ce résultat signifie que nous avons 891 lignes et 3 colonnes.

Vous pouvez également utiliser **l'attribut shape** sur un **Pandas DataFrame** (titanic.shape).

# Exercice d'application 13

```
Taille d'un Numpy array  
Quel est l'output des instructions suivantes ?  
  
arr = df[['Survived', 'Pclass']].values  
  
print(arr.shape)
```

# Selection des valeurs dans un Numpy Array

```
Soit le numpy array suivant :  
arr = df[['Pclass', 'Fare', 'Age']].values  
print(arr[0, 1])
```

Ce sera **la 2ème colonne de la 1ère ligne** (rappelez-vous que nous commençons à compter à 0). Ce sera donc le tarif du 1er passager, soit 7,25.

Nous pouvons également sélectionner **une seule ligne**, par exemple, la ligne entière du premier passager :

```
print(arr[0])
```

Pour sélectionner **une seule colonne** (la colonne Age par exemple) :

```
print(arr[:,2]) ==> array([ 3. , 7.25, 22. ])
```

# Exercice d'application 14

**Selection**

Soit le tabealeau suivant :

```
arr = data[['Pclass', 'Fare', 'Age']].values
```

Écrire un programme permettant d'afficher/selectionner les frais de tous les passagers.

# Selection des données en fonction critère

Créons un sous-ensemble de données des passagers ayant moins de 18 ans (mineurs) :

```
mask = arr[:, 2] < 18  
print(arr[mask])
```

Une autre façon d'obtenir le même résultat :

```
print(arr[arr[:, 2] < 18])
```

**Attention !**

Un masque (mask) est un tableau booléen (True/False) qui nous indique les valeurs du tableau qui nous intéressent.

# Exercice d'application 15

Académie Française

## Selection

Soit le tableau suivant :

```
arr = data[['Pclass', 'Fare', 'Age']].values
```

Complétez le programme suivant de manière à afficher/sélectionner uniquement les passagers de la première classe (Pclass=1):

```
arr[ ..... == 1 ]
```

# Somme des valeurs boolean

```
arr = df[['Pclass', 'Fare', 'Age']].values  
mask = arr[:, 2] < 18
```

Rappelez-vous que les **valeurs vraies** sont interprétées comme **1** et que les **valeurs fausses** sont interprétées comme **0**. Nous pouvons donc simplement additionner le tableau et cela équivaut à compter le nombre de valeurs vraies.

```
print(mask.sum())
```

Une autre façon d'obtenir le même résultat :

```
print((arr[:, 2] < 18).sum())
```

### Attention !

Sommer un tableau de valeurs booléennes donne le nombre de valeurs vraies.

# Exercice d'application 16

## Sommer un tableau de boolean

Soit le tableau suivant :

```
arr = data[['Pclass', 'Fare', 'Age']].values
```

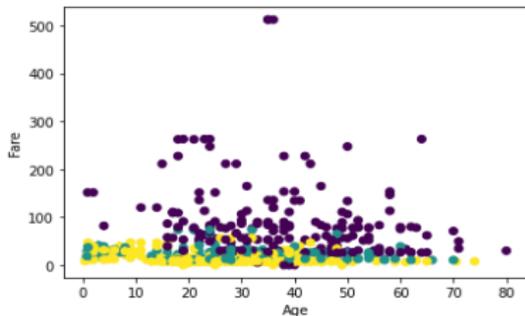
Laquelle des propositions suivantes est correcte pour compter le nombre de passagers dans la classe 1 ?

- 1 (arr[0] == 1).sum()
- 2 (arr[:, 0] == 1).sum
- 3 (arr[:, 0] == 1).sum()
- 4 (arr[0] == 1).sum



# Scatter plot 2

```
import matplotlib.pyplot as plt
plt.scatter(titanic['Age'],
            titanic['Fare'], c=titanic['Pclass'])
plt.xlabel('Age')
plt.ylabel('Fare')
plt.show()
```



Les points violets sont de première classe, les points verts de deuxième classe et les points jaunes de troisième classe.

# Exercice d'application 17

Numérique

## Construire un cross-plot

Écrivez un programme pour créer un cross-plot avec Pclass sur l'axe des y et Fare sur l'axe des x. Attribuez un code de couleur selon qu'ils ont survécu ou non. Ajoutez les étiquettes "Fare" et "Pclass" sur les axes x et y respectivement.

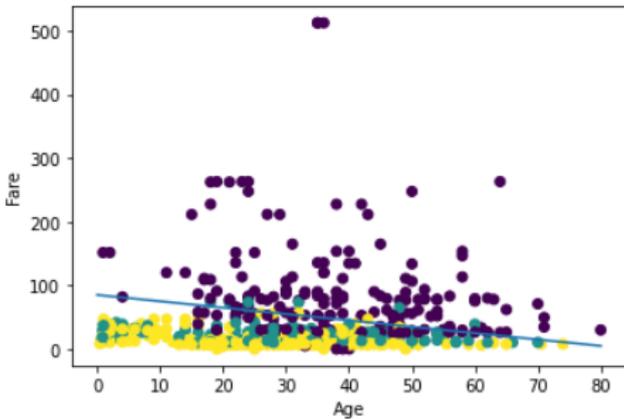
Académie

# Tracé d'une droite 1

La fonction `plot()` permet de tracer **une droite à partir de ces coordonnées**. L'exemple suivant trace une ligne qui sépare approximativement la première classe de la deuxième et de la troisième classe. À vue d'oeil, nous placerons la droite de (0, 85) à (80, 5). Notre syntaxe ci-dessous comporte une liste de valeurs x et une liste de valeurs y :

```
plt.scatter(titanic['Age'], titanic['Fare'], c=titanic['Pclass'])  
plt.xlabel('Age')  
plt.ylabel('Fare')  
plt.plot([0, 80], [85, 5])  
plt.show()
```

# Tracé d'une droite 2



Vous pouvez voir que les points jaunes (3ème classe) et verts (2ème classe) sont principalement en dessous de la ligne et que les points violets (1ère classe) sont principalement au-dessus. Nous avons fait cela manuellement, mais dans le prochain module, nous apprendrons à le faire de manière algorithmique.

# Exercice d'application 18

**Construire une droite**  
Reprendre le graphique précédent en traçant cette fois-ci une droite qui va de (0, 15) à (100, 15).

# Quiz 1

1) Quel module permet de manipuler et lire les données avec un main data object de DataFrame ?

- ① Matplotlib
- ② Pandas
- ③ Numpy

2) Quel module permet de réaliser des calculs et des analyses numériques avec un main data object d' array ?

- ① Matplotlib
- ② Pandas
- ③ Numpy

# Quiz 2

3) Quelle est la médiane et la moyenne de la Serie suivante ?

5,10, 15, 20, 25

- 1 mean = 20 / median = 10
- 2 mean = 15 / median = 10
- 3 mean = 15 / median = 15

4) Quelle est la mesure de la dispersion des données ?

- 1 Mean
- 2 Median
- 3 Standard deviation
- 4 Variance

# Quiz 3

## 5) Chargez et affichez les données

Soit un fichier csv appelé `eleves.csv` avec trois colonnes : `nom`, `prenom` et `age`.

Écrire un programme qui permet de charger le fichier csv comme un Pandas DataFrame et afficher uniquement la Serie appelée `'nom'`.

## 6) Quelle est l'instruction qui permet de récupérer les colonnes `age` et `prenom` comme un Numpy array ?

- ① `data['prenom', 'age']`
- ② `data['prenom', 'age'].values`
- ③ `data[['prenom', 'age']]`
- ④ `data[['prenom', 'age']].values`

# Quiz 4

## 7) Construction d'un cross-plot

Soit un fichier csv appelé `eleves.csv` avec trois colonnes : `nom`, `taille` et `age`.

Complétez le programme suivant permettant de construire un cross-plot avec la taille sur l'axe des abscisses et l'age sur l'axe des ordonnées :

```
import matplotlib as plt  
..... ( data['taille'], data['age'])
```