

# Introduction à Pandas

*Par*

*OUHAB Abdelkrim*

# Introduction

- ❑ Pandas (qui signifie Python Data Analysis) est une bibliothèque conçue pour la manipulation et **l'analyse des données** .
- ❑ Elle s'intègre parfaitement avec d'autres bibliothèques Python telles que NumPy, Matplotlib et scikit-learn.

# À quoi sert Pandas ?

- ❑ Lecture et écriture de données à partir de différents formats de fichiers tels que CSV, Excel et les bases de données SQL.
- ❑ Nettoyage et préparation des données (gestion des valeurs manquantes, filtrage, suppression des doublons).
- ❑ Fusion, jointure des ensembles de données.
- ❑ Analyse des données.
- ❑ Visualisation des données.

## Pandas Basic Operations

Pandas simplifies data handling by enabling efficient preprocessing, cleaning, transformation, and visualization.



## Data Preprocessing

Handle missing values and clean raw data for analysis.  
Before (Table with Missing Values)

**Before** (Table with Missing Values)

| Name  | Age | Salary_Amount |
|-------|-----|---------------|
| Aryan | 25  | NaN           |
| Harsh | NaN | 5000          |
| Kunal | 30  | 7000          |

**After** (Missing Values Filled)

| Name  | Age | Salary |
|-------|-----|--------|
| Aryan | 25  | 0      |
| Harsh | 28  | 5000   |
| Kunal | 30  | 7000   |

**Operation Applied:**

Filled missing values with 0 /  
average using fillna()

## Data Cleaning

Remove duplicates and fix column inconsistencies.  
Before (Duplicate Rows & Bad Column Names):

**Before**

| Name  | Age | Salary_Amount |
|-------|-----|---------------|
| Aryan | 25  | 5000          |
| Harsh | 30  | 7000          |
| Aryan | 25  | 5000          |

**After**

| Name  | Age | Salary |
|-------|-----|--------|
| Aryan | 25  | 5000   |
| Harsh | 30  | 7000   |

**Operation Applied:** Removed duplicates using `drop_duplicates()`,  
renamed columns using `rename()`

## Data Transformation

Filter and sort data for better insights.

**Before** (unfiltered Data)

| Product    | Category    | Price |
|------------|-------------|-------|
| Laptop     | Electronics | 800   |
| Hoodie     | Clothing    | 20    |
| Smartphone | Electronics | 500   |
| Jeans      | Clothing    | 40    |

**After** (Filtered & Sorted Data)

| Product    | Category    | Price |
|------------|-------------|-------|
| Smartphone | Electronics | 500   |
| Laptop     | Electronics | 800   |

**Operation Applied:**

Filtered Electronics using `query()`,  
sorted by price using `sort_values()`


# Data Visualization

Represent data graphically for insights

**Before** (Raw Data Table)

| Category    | Price |
|-------------|-------|
| Electronics | 5000  |
| Clothing    | 2000  |
| Furniture   | 3000  |

**After** (Bar Chart Visual)



**Operation Applied:** Plotted sales data using matplotlib

# Installation Pandas

❑ Pour installer Pandas:

*pip install pandas.*

❑ Une fois Pandas installé sur le système, il faut importer la bibliothèque:

```
import pandas as pd
```

# Structures de données dans Pandas

- ❑ **Séries Pandas:** tableau unidimensionnel pouvant contenir des données de tout type (nombre, chaîne de caractères, objets Python, etc.)
- ❑ **DataFrame Pandas:** structure de données bidimensionnelle (lignes et colonnes)

Series

|   | apples |
|---|--------|
| 0 | 3      |
| 1 | 2      |
| 2 | 0      |
| 3 | 1      |

+

Series

|   | oranges |
|---|---------|
| 0 | 0       |
| 1 | 3       |
| 2 | 7       |
| 3 | 2       |

=

DataFrame

|   | apples | oranges |
|---|--------|---------|
| 0 | 3      | 0       |
| 1 | 2      | 3       |
| 2 | 0      | 7       |
| 3 | 1      | 2       |

# Création DataFrame

`pandas.DataFrame(data, index , colonnes , dtype , copy )`

- **data** : ndarray, series, listes, dictionnaires, autre DataFrame, etc.
- **index** : étiquettes de lignes, par défaut est `np.arange(n)` si aucun index n'est passé.
- **colonnes** : étiquettes de colonnes, par défaut est `np.arange(n)`.
- **dtype** : type de données de chaque colonne.
- **copy** : permet la copie des données.

# Création DataFrame à partir d'une liste

```
import pandas as pd
liste = ['Omar', 'Ahmed', 'Fatiha']

df1 = pd.DataFrame(liste)
print("----- DF1 -----")
print(df1)

df2 = pd.DataFrame(liste, columns = ["nom"])
print("----- DF2 -----")
print(df2)
```

## Output

```
----- DF1 -----
0
0 Omar
1 Ahmed
2 Fatiha
----- DF2 -----
      nom
0 Omar
1 Ahmed
2 Fatiha
```

# Création DataFrame à partir d'une liste

```
import pandas as pd
liste = [['Omar', 25], ['Ahmed', 45], ['Fatima', 30]]
df = pd.DataFrame(liste, columns = ["nom", "age"])
print(df)
```

## Output

|   | nom    | age |
|---|--------|-----|
| 0 | Omar   | 25  |
| 1 | Ahmed  | 45  |
| 2 | Fatima | 30  |

# Création DataFrame à partir d'un dictionnaire

```
import pandas as pd
data = { 'nom': ['Omar', 'Ahmed', 'Fatiha'], 'age': [25, 45, 30] }
df = pd.DataFrame(data)
print(df)
```

## Output

|   | nom    | age |
|---|--------|-----|
| 0 | Omar   | 25  |
| 1 | Ahmed  | 45  |
| 2 | Fatiha | 30  |

# Création DataFrame à partir de tableaux NumPy

```
import pandas as pd
import numpy as np
data = np.array([[1, 2, 3], [4, 5, 6], [7, 8, 9]])
df = pd.DataFrame(data, columns= ['A', 'B', 'C'])
print(df)
```

## Output

|   | A | B | C |
|---|---|---|---|
| 0 | 1 | 2 | 3 |
| 1 | 4 | 5 | 6 |
| 2 | 7 | 8 | 9 |

# Lecture de fichiers CSV

```
pd.read_csv(filepath, sep=',', header='infer', index_col=None, usecols=None, engine=None, skiprows=None, nrows=None)
```

- **filepath**: Emplacement ou URL du fichier CSV
- **sep**: séparateur utilisé dans le fichier CSV, la valeur par défaut ','
- **header**: numéros de ligne servant de noms de colonnes par défaut 0
- **usecols**: les colonnes sélectionnées du fichier CSV
- **nrows**: Nombre de lignes à afficher
- **index\_col**: colonne utilisée comme index
- **skiprows**: les lignes à ignorer

# Lecture de fichiers CSV

```
import pandas as pd
df = pd.read_csv("d:/data/unemployment.csv")
df.head()
```

## Output

|   | country          | nemployment_rate |
|---|------------------|------------------|
| 0 | Marshall Islands | 36.0             |
| 1 | South Africa     | 33.6             |
| 2 | Kiribati         | 30.6             |
| 3 | Kosovo           | 30.5             |
| 4 | American Samoa   | 29.8             |

# Lecture de fichiers Excel

```
import pandas as pd
df = pd.read_excel("d:/data/unemployment.xlsx")
df.head()
```

## Output

|   | country          | nemployment_rate |
|---|------------------|------------------|
| 0 | Marshall Islands | 36.0             |
| 1 | South Africa     | 33.6             |
| 2 | Kiribati         | 30.6             |
| 3 | Kosovo           | 30.5             |
| 4 | American Samoa   | 29.8             |

# Enregistrer un Dataframe comme fichier CSV

```
import pandas as pd
liste = [['Omar', 25], ['Ahmed', 45], ['Fatiha', 30]]
df = pd.DataFrame(liste, columns = ["nom", "age"])
df.to_csv('d:/data/etudiant.csv', index=False)
```

# Affichage des données d'un dataframe

❑ La fonction head (tail) affiche par défaut les cinq premières (dernières) lignes d'un DataFrame, mais on peut également lui passer un nombre.

```
import pandas as pd
liste = [['Omar',25], ['Ahmed',45], ['Fatima',30], ['Ali',44]]
df = pd.DataFrame(liste, columns = ["nom","age"])
print(df.head(2))
print("-----")
print(df.tail(2))
```

## Output

|   | nom   | age |
|---|-------|-----|
| 0 | Omar  | 25  |
| 1 | Ahmed | 45  |

-----

|   | nom    | age |
|---|--------|-----|
| 2 | Fatima | 30  |
| 3 | Ali    | 44  |

# Concaténation de Dataframes

`pandas.concat(objs, axis=0, ...)`

- **Objs:** une liste ou un tuple d'objets pandas (DataFrames ou Series) à concaténer
- **Axis:** axe de concaténation : 0 pour les lignes (par défaut), 1 pour les colonnes

```
import pandas as pd
liste1 = [['Omar', 25], ['Ahmed', 45], ['Fatima', 30]]
df1 = pd.DataFrame(liste1, columns = ["nom", "age"])
liste2 = [['Ali', 55], ['Fatima', 35], ['Samir', 30]]
df2 = pd.DataFrame(liste2, columns = ["nom", "age"])
df = pd.concat([df1, df2])
```