

Consignes

- Jeu de données : data_exploration.csv.

```
In [2]: #Importation des bibliothèques nécessaires.
import pandas as pd
import seaborn as sns
import matplotlib.pyplot as plt
import numpy as np

# Data Description (very Quick). Rename the DataFrame variable (df) if needed.
df = pd.read_csv('./data_exploration.csv', sep=';')

print(f'\n ** Noms et Types des attributs **: \n{df.dtypes}\n\n-----\n')
print(f'\n ** Aperçu des données **: \n{df.head(5)}')
```

```
** Noms et Types des attributs **:
Username      object
Subscribers   float64
Views         int64
Country       object
dtype: object

-----

** Aperçu des données **:
   Username  Subscribers      Views Country
0   Colors TV         77.6  76490031656     IN
1  shripaashant        53.9   3237975581     IN
2    Alan Walker        46.2  14996804659     NO
3 SonyMusicIndiaVEVO    53.2  33399550869     US
4  LUCCAS NETO - LICCAS TOON  50.1   29698114509    BR
```

Question 1

- Nous souhaitons utiliser un nuage de points (scatterplot) pour vérifier si le nombre de vues des chaînes YouTube est proportionnel à celui des abonnés.

- Figure à réaliser (voir exemple 1):

Figure 2D (nuage de points) avec :

- en abscisses les Youtubers classés du plus suivi au moins suivi (attribut Subscribers)
- et en ordonnées les nombres de vues des Youtubers

<https://seaborn.pydata.org/generated/seaborn.scatterplot.html>

- Exemple 1

title

Réponse 1


```
In [3]: # Trier par nombre d'abonnés (du plus au moins suivi)
df_sorted = df.sort_values(by="Subscribers", ascending=False).reset_index(drop=True)

df_sorted["Rank"] = df_sorted.index + 1
```

```
In [16]: # Scatter plot
plt.figure(figsize=(10, 6))
plt.scatter(df_sorted["Rank"], df_sorted["Views"], alpha=0.7)

# Mise en forme
plt.xlabel("Classement des YouTubers par nombre d'abonnés")
plt.ylabel("Nombre de vues")
plt.title("Relation entre nombre d'abonnés et nombre de vues")

plt.grid(True, linestyle="--", alpha=0.5)
plt.tight_layout()
plt.show()
```



Question 2

- Nous souhaitons utiliser la visualisation en boîtes à moustaches (boxplots) pour examiner la distribution des vues sur YouTube en fonction de pays spécifiques, afin de réaliser une comparaison.

- Figure à réaliser (voir exemple 2):

Figure 2D (boxplots) avec :

- en abscisses les deux classes de Youtubers (1st Class et 2nd Class), groupées par pays (Canada, États-Unis, Japon et autres pays),
- et en ordonnées le nombre de vues des Youtubers,
- sachant qu'un Youtuber appartient à la 1st Class si le nombre de vues est strictement supérieur à 60Milliards, sinon il est classé dans la 2nd Class."

<https://seaborn.pydata.org/generated/seaborn.boxplot.html#>

- Exemple 2

title

Réponse 2

```
In [17]: df["Famous_Youtuber"] = np.where(df['Views'].astype(int) > 60000000000, 1, 2)


conditions = [
    (df['Country'] == 'US'),
    (df['Country'] == 'JP'),
    (df['Country'] == 'CA')
]
choices = ['United States', 'Japan', 'Canada']

# Create the new 'result' column using np.select()
df['Country2'] = np.select(conditions, choices, default='Other Countries')
df.head()
```

	Username	Subscribers	Views	Country	Famous_Youtuber	Country2	Country3
0	Colors TV	77.6	76490031656	IN	1	Other Countries	India
1	shripaashant	53.9	3237975581	IN	2	Other Countries	India
2	Alan Walker	46.2	14996804659	NO	2	Other Countries	Other Countries
3	SonyMusicIndiaVEVO	53.2	33399550869	US	2	United States	United States
4	LUCCAS NETO - LICCAS TOON	50.1	29698114509	BR	2	Other Countries	Other Countries

```
In [18]: sns.boxplot(data=df, x='Country2', y='Views', hue="Famous_Youtuber", fill=True, gap=.1)
```


Out[18]: <Axes: xlabel='Country2', ylabel='Views'>



```
In [19]: conditions = [
    (df['Country'] == 'US'),
    (df['Country'] == 'JP'),
    (df['Country'] == 'IN')
]
choices = ['United States', 'Japan', 'India']

df['Country3'] = np.select(conditions, choices, default='Other Countries')
sns.violinplot(data=df, x='Country3', y='Subscribers', hue="Famous_Youtuber")
```

Out[19]: <Axes: xlabel='Country3', ylabel='Subscribers'>



In [] :

In [] :