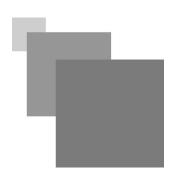
## TP 5 Visualisation Avancée et Webscraping

TP Data Science M11A

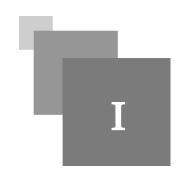
Ilyas Bambrik



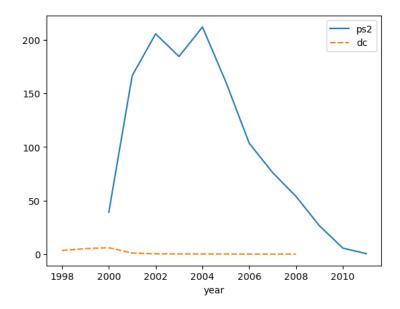
## Table des matières

I - Exercice : Visualisation et annotation	3
II - Exercice : Distributions	6
III - Exercice : WordCloud	7
IV - Exercice : Dashboards Interactives et Plotely	8
V - Exercice : Webscraping	11

## **Exercice: Visualisation et annotation**

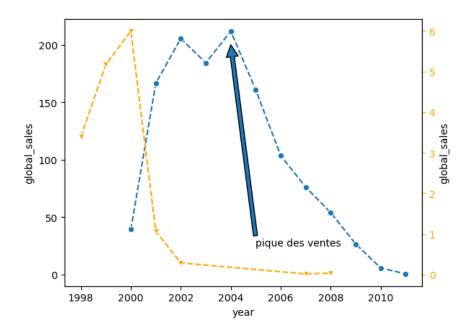


- Lisez le DataSet video\_games\_sales.csv.
- Tracez un graphe *lineplot* pour les ventes accumulés sur *DC* (*Dreamcast*) et graphe *lineplot* pour les vente accumulés sur *PS3* dans la même axe en fonction de l'année.



- Refaite le même travail en utilisant twinx pour séparer l'axe des y des deux graphe et adapter l'échelle.
- Pour les deux graphes, utilisez deux couleurs et marqueurs (paramètres marker et color) distinctes.
- Utilisez un style de ligne discontinu (argument *linestyle="--"*).

- Utiliser la fonction annotate de l'objet axe pour annoter la valeur maximale du graphe des ventes PS3.
Créez une flèche avec le paramètre arrowprops. Déplacez le texte de l'annotation en bas de la valeur annotée avec le paramètre xytext.



- Tracez un barplot qui affiche pour chaque année les ventes PC, PS3 et Xbox360 (utilisez le paramètre *hue*).

- Tracez un box-plot des ventes au Japon pour les jeux GB (GameBoy) et NES (Super Nintendo).

Exercice: Distributions

### **Exercice: Distributions**



### Question

- Lisez *players.csv* avec pandas.
- Tracez la distribution des valeurs de la colonne *height\_in\_cm* avec *histplot*. Utilisez l'argument *kde* pour afficher la fonction de densité estimée.
- Tracez un *barplort* de la colonne *highest\_market\_value\_in\_eur* cumulée en fonction de la colonne *sub\_position*. Élargissez la figure et faite une rotation 90° des étiquettes de l'axe des x afin que l'affichage soit claire.

Exercice: WordCloud

### **Exercice: WordCloud**



#### Question

- A partir du fichier *shakespare.txt*, créez un *wordcloud* simple. Les axes doivent être masqués de l'affichage avec un arrière plan blanc. Le *wordcloud* doit afficher seulement les 100 mots les plus importants du texte.
- Afficher le wordcloud à nouveau en ignorant les mots vides.
- Afficher le *wordcloud* à nouveau après avoir augmenté le nombre de termes affichés dans le *wordcloud* i 1000 et utilisez l'image *python-wordcloud.png* pour le masque et le schéma de coloriage.



# **Exercice : Dashboards Interactives et Plotely**



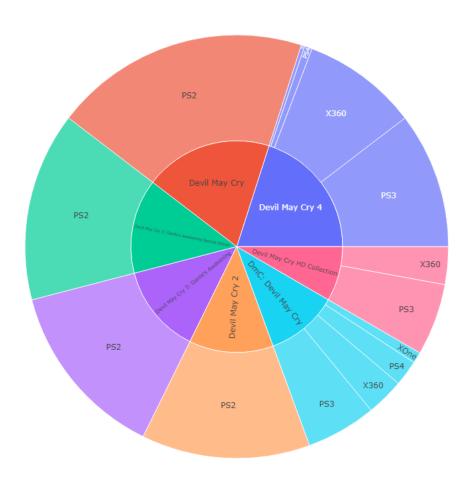
Lisez le DataSet video\_games\_sales.csv.

#### **Question 1**

Récupérez toutes les lignes où le nom du jeux contient la chaîne Devil May Cry.

### **Question 2**

A partir du résultat précédant, tracez un Sunburst plot divisant les ventes globales (*global\_sales*) par le nom du jeux et puis par plate-forme.

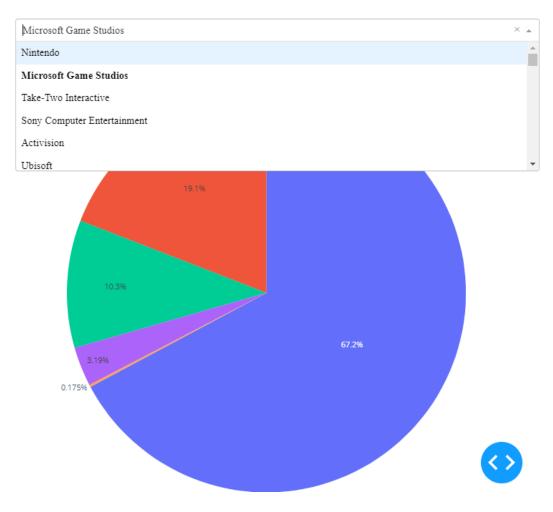


Créez une application Dash qui contient un *Dropdown* contenant touts les noms des maisons de publication ( *publisher*) présents dans *video\_games\_sales.csv*. Définissez l'identifiant de ce composant comme *game-selector*.



- Créer un composant dcc. Graph avec l'identifiant sales-shares.
- Définissez un callback dans votre application Dash qui filtre seulement les lignes associées publisher sélectionné game-selector.
- La fonction *callback* doit retourner un Pie plot représentant les proportions des ventes par plate-forme pour la maison de publication sélectionnée.
- Affich

### **Game Sales**

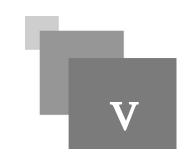


- Modifiez le code de l'application Dash afin d'afficher un deuxième graphique linéaire représentant l'évolution des ventes (global\_sales)au fils des années (year) pour la maison de publication sélectionné ( publisher). Vous devez utiliser le même composant identifié par sales-shares sans ajouter un autre dcc. Graph.
- Dans le premier Pie plot, la plus grande proportion (*platform*) doit être détachée du Pie plot par une distance de 0.1.



Exercice: Webscraping

### **Exercice: Webscraping**



#### Question

- Écrivez un programme avec le module *requests* pour récupérez la liste des université sous forme Json d'un pays donné. (par exemple http://universities.hipolabs.com/search?country=Algeria retourne la liste des université algériennes)
- Écrivez un programme avec les modules BeautifulSoup et requets afin de récupérer les prix et les noms des PC portables présents dans la page https://www.licbplus.com.dz/global-category/laptop-computers/3 /225?sort\_by=new