

```
In [20]: # Sujet 6 : Autour du Paradoxe de Simpson
# Parcours : Jupyter Notebook
# -----
```

```
In [22]: # Importations
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import seaborn as sns
import statsmodels.api as sm
import statsmodels.formula.api as smf

# Chargement des données
file_path = 'Subject6_smoking.csv'
df = pd.read_csv(file_path)

# Aperçu des données
df.head()
```

```
Out[22]:
```

	Smoker	Status	Age
0	Yes	Alive	21.0
1	Yes	Alive	19.3
2	No	Dead	57.5
3	No	Alive	47.1
4	Yes	Alive	81.4

```
In [24]: # -----
# Question 1 : Tableau vivantes/décédées selon le tabagisme
# -----
```

```
In [26]: # Tableau de contingence
contingency_table = pd.crosstab(df['Smoker'], df['Status'])

# Taux de mortalité
mortality_rates = contingency_table.apply(lambda row: row['Dead'] / (row['Alive'] + row['Dead']),
                                          axis=1)

# Affichage
print("Tableau de contingence:\n", contingency_table)
print("\nTaux de mortalité:\n", mortality_rates)

# Graphique
mortality_rates.plot(kind='bar', color=['skyblue', 'salmon'])
plt.ylabel('Taux de mortalité')
plt.title('Taux de mortalité selon le statut tabagique')
plt.show()
```


Tableau de contingence:

Status	Alive	Dead
Smoker		
No	502	230
Yes	443	139

Taux de mortalité:

Smoker	
No	0.314208
Yes	0.238832

dtype: float64



```
In [28]: # -----
# Question 2 : En introduisant les classes d'âge
# -----
```

```
In [30]: # Création de la colonne 'AgeGroup'
age_bins = [18, 34, 54, 64, 120]
age_labels = ['18-34', '35-54', '55-64', '65+']
df['AgeGroup'] = pd.cut(df['Age'], bins=age_bins, labels=age_labels)

# Nouveau tableau
contingency_table_age = pd.crosstab([df['Smoker'], df['AgeGroup']], df['Status'])

# Taux de mortalité par groupe
mortality_rates_age = contingency_table_age.apply(lambda row: row['Dead'] / (row['Alive'] + row['Dead']), axis=1)

# Affichage
print("Tableau de contingence par âge:\n", contingency_table_age)
print("\nTaux de mortalité par groupe:\n", mortality_rates_age)

# Graphique
mortality_rates_age.unstack(0).plot(kind='bar', figsize=(10,6))
plt.ylabel('Taux de mortalité')
plt.title('Taux de mortalité selon le statut tabagique et l\'âge')
plt.legend(title='Smoker')
plt.show()
```


Tableau de contingence par âge:

Status	Alive	Dead
Smoker AgeGroup		
No	18-34	212
	35-54	180
	55-64	81
	65+	28
Yes	18-34	172
	35-54	196
	55-64	64
	65+	7

Taux de mortalité par groupe:

Smoker	AgeGroup	
No	18-34	0.027523
	35-54	0.095477
	55-64	0.330579
	65+	0.854922
Yes	18-34	0.028249
	35-54	0.172996
	55-64	0.443478
	65+	0.857143

dtype: float64



```
In [36]: # -----
# Question 3 : Régression Logistique Status ~ Age
# -----
```

```
In [38]: # Création variable Death_bin (0=Alive, 1=Dead)
df['Death_bin'] = df['Status'].apply(lambda x: 1 if x == 'Dead' else 0)

# Définir les bons labels présents dans les données
smoker_values = df['Smoker'].unique()
smoker_label = smoker_values[0]
non_smoker_label = smoker_values[1]

# Régression pour les fumeuses
model_smoker = smf.logit('Death_bin ~ Age', data=df[df['Smoker'] == smoker_label]).fit()
```

```

# Régression pour Les non-fumeuses
model_non_smoker = smf.logit('Death_bin ~ Age', data=df[df['Smoker'] == non_smoker_label]).fit

# Affichage résumés
print(model_non_smoker.summary())
print(model_smoker.summary())

# Prédiction
ages = np.linspace(df['Age'].min(), df['Age'].max(), 100)

# Prédiction pour chaque groupe
pred_non_smoker = model_non_smoker.predict(pd.DataFrame({'Age': ages}))
pred_smoker = model_smoker.predict(pd.DataFrame({'Age': ages}))

# Graphique
plt.figure(figsize=(10,6))
plt.plot(ages, pred_non_smoker, label=f'{non_smoker_label}', color='blue')
plt.plot(ages, pred_smoker, label=f'{smoker_label}', color='red')
plt.fill_between(ages, pred_non_smoker - 0.05, pred_non_smoker + 0.05, color='blue', alpha=0.2)
plt.fill_between(ages, pred_smoker - 0.05, pred_smoker + 0.05, color='red', alpha=0.2)
plt.xlabel('Age')
plt.ylabel('Probabilité de décès')
plt.title('Probabilité de décès selon l'âge et le tabagisme')
plt.legend()
plt.show()

```


Optimization terminated successfully.
Current function value: 0.412727
Iterations 7

Optimization terminated successfully.
Current function value: 0.354560
Iterations 7

Logit Regression Results						
Dep. Variable:	Death_bin	No. Observations:	732			
Model:	Logit	Df Residuals:	730			
Method:	MLE	Df Model:	1			
Date:	Sat, 26 Apr 2025	Pseudo R-squ.:	0.4304			
Time:	18:54:29	Log-Likelihood:	-259.54			
converged:	True	LL-Null:	-455.62			
Covariance Type:	nonrobust	LLR p-value:	2.808e-87			
	coef	std err	z	P> z	[0.025	0.975]
Intercept	-6.7955	0.479	-14.174	0.000	-7.735	-5.856
Age	0.1073	0.008	13.742	0.000	0.092	0.123

Logit Regression Results						
Dep. Variable:	Death_bin	No. Observations:	582			
Model:	Logit	Df Residuals:	580			
Method:	MLE	Df Model:	1			
Date:	Sat, 26 Apr 2025	Pseudo R-squ.:	0.2492			
Time:	18:54:29	Log-Likelihood:	-240.21			
converged:	True	LL-Null:	-319.94			
Covariance Type:	nonrobust	LLR p-value:	1.477e-36			
	coef	std err	z	P> z	[0.025	0.975]
Intercept	-5.5081	0.466	-11.814	0.000	-6.422	-4.594
Age	0.0890	0.009	10.203	0.000	0.072	0.106

Probabilité de décès selon l'âge et le tabagisme



```
In [ ]: # -----
# Remarques :
# Le paradoxe de Simpson apparaît ici car l'âge moyen diffère selon le groupe de fumeuses et r
# Les fumeuses étaient souvent plus jeunes que les non-fumeuses.
# Ainsi, à âge égal, les fumeuses peuvent avoir une mortalité plus forte,
# mais globalement (sans correction sur l'âge) elles semblent avoir une mortalité plus faible.
# -----

# Fin du notebook
```

In []: