exerciceTabac

October 31, 2024

1 Sujet 6 : Autour du Paradoxe de Simpson

1.1 Contexte :

En 1972-1974, à Whickham, une ville du nord-est de l'Angleterre, située à environ 6,5 kilomètres au sud-ouest de Newcastle upon Tyne, un sondage d'un sixième des électeurs a été effectué afin d'éclairer des travaux sur les maladies thyroïdiennes et cardiaques (Tunbridge et al. 1977). Une suite de cette étude a été menée vingt ans plus tard (Vanderpump et al. 1995). Certains des résultats avaient trait au tabagisme et cherchaient à savoir si les individus étaient toujours en vie lors de la seconde étude. Par simplicité, nous nous restreindrons aux femmes et parmi celles-ci aux 1314 qui ont été catégorisées comme "fumant actuellement" ou "n'ayant jamais fumé". Il y avait relativement peu de femmes dans le sondage initial ayant fumé et ayant arrêté depuis (162) et très peu pour lesquelles l'information n'était pas disponible (18). La survie à 20 ans a été déterminée pour l'ensemble des femmes du premier sondage.

1.2 L'étude de ce sujet se fera en 3 étapes :

1. Représenter dans un tableau le nombre total de femmes vivantes et décédées sur la période en fonction de leur habitude de tabagisme. Calculer dans chaque groupe (fumeuses / non fumeuses) le taux de mortalité (le rapport entre le nombre de femmes décédées dans un groupe et le nombre total de femmes dans ce groupe). Analyser ce résultat.
2. Reprendre la question 1 (effectifs et taux de mortalité) en rajoutant une nouvelle catégorie liée à la classe d'âge. On considérera les classes suivantes : 18-34 ans, 35-54 ans, 55-64 ans, plus de 65 ans. Analyser le résultat.
3. Etablir une régression logistique en introduisant un variable Death valant 1 ou 0 si la personne est morte ou pas au cours des 20 années entre le premier sondage et la suite de l'étude. Conclure.

1.3 Etape 1 : Calcul du taux de mortalité pour les fumeuses et les non fumeuses

Tout d'abord, il faut commencer par inclure les bibliothèques dont nous aurons besoin.

[1]:
```
import matplotlib.pyplot as plt
import pandas as pd
import statsmodels.api as sm
```

```
import numpy as np
```

Il faut ensuite charger et lire le fichier

[2]:
```
data_file = "Subject6_smoking.csv"
```

[3]:
```
raw_data = pd.read_csv(data_file)
raw_data
```

[3]:

	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
5	No	Alive	36.8
6	No	Alive	23.8
7	Yes	Dead	57.5
8	Yes	Alive	24.8
9	Yes	Alive	49.5
10	Yes	Alive	30.0
11	No	Dead	66.0
12	Yes	Alive	49.2
13	No	Alive	58.4
14	No	Dead	60.6
15	No	Alive	25.1
16	No	Alive	43.5
17	No	Alive	27.1
18	No	Alive	58.3
19	Yes	Alive	65.7
20	No	Dead	73.2
21	Yes	Alive	38.3
22	No	Alive	33.4
23	Yes	Dead	62.3
24	No	Alive	18.0
25	No	Alive	56.2
26	Yes	Alive	59.2
27	No	Alive	25.8
28	No	Dead	36.9
29	No	Alive	20.2
…	…	…	…
1284	Yes	Dead	36.0
1285	Yes	Alive	48.3
1286	No	Alive	63.1
1287	No	Alive	60.8
1288	Yes	Dead	39.3
1289	No	Alive	36.7

```
1290     No  Alive  63.8
1291     No   Dead  71.3
1292     No  Alive  57.7
1293     No  Alive  63.2
1294     No  Alive  46.6
1295    Yes   Dead  82.4
1296    Yes  Alive  38.3
1297    Yes  Alive  32.7
1298     No  Alive  39.7
1299    Yes   Dead  60.0
1300     No   Dead  71.0
1301     No  Alive  20.5
1302     No  Alive  44.4
1303    Yes  Alive  31.2
1304    Yes  Alive  47.8
1305    Yes  Alive  60.9
1306     No   Dead  61.4
1307    Yes  Alive  43.0
1308     No  Alive  42.1
1309    Yes  Alive  35.9
1310     No  Alive  22.3
1311    Yes   Dead  62.1
1312     No   Dead  88.6
1313     No  Alive  39.1

[1314 rows x 3 columns]
```

Création de 2 DataFrames à partir du contenu du fichier csv : *nonFumeuses* contient les données des personnes qui ne fument pas (qui ont “No” dans la colonne “Smoker”) et *fumeuses* contient les données des personnes qui fument (qui ont “Yes” dans la colonne “Smoker”)

[4]:
```
#trier = raw_data.sort_values(by = ["Smoker"])
masq = raw_data["Smoker"] == "Yes"
fumeuses = raw_data.loc[masq]
nonFumeuses = raw_data.loc[raw_data["Smoker"]=="No"]
```

[5]:
```
#Affichage
fumeuses
```

[5]:
```
     Smoker Status   Age
0       Yes  Alive  21.0
1       Yes  Alive  19.3
4       Yes  Alive  81.4
7       Yes   Dead  57.5
8       Yes  Alive  24.8
9       Yes  Alive  49.5
10      Yes  Alive  30.0
```

```
12      Yes  Alive  49.2
19      Yes  Alive  65.7
21      Yes  Alive  38.3
23      Yes   Dead  62.3
26      Yes  Alive  59.2
30      Yes  Alive  34.6
31      Yes  Alive  51.9
32      Yes  Alive  49.9
35      Yes  Alive  46.7
36      Yes  Alive  44.4
37      Yes  Alive  29.5
38      Yes   Dead  33.0
39      Yes  Alive  35.6
40      Yes  Alive  39.1
42      Yes  Alive  35.7
46      Yes   Dead  44.3
48      Yes  Alive  37.5
49      Yes  Alive  22.1
53      Yes  Alive  39.0
56      Yes  Alive  40.1
60      Yes  Alive  58.1
61      Yes  Alive  37.3
63      Yes   Dead  36.3
…     …    …     …
1240    Yes  Alive  29.7
1243    Yes  Alive  40.1
1251    Yes  Alive  27.8
1252    Yes  Alive  52.4
1253    Yes  Alive  27.8
1254    Yes  Alive  41.0
1259    Yes  Alive  40.8
1260    Yes  Alive  20.4
1263    Yes  Alive  20.9
1264    Yes  Alive  45.5
1269    Yes  Alive  38.8
1270    Yes  Alive  55.5
1271    Yes  Alive  24.9
1273    Yes  Alive  55.7
1276    Yes  Alive  58.5
1278    Yes  Alive  43.7
1282    Yes  Alive  51.2
1284    Yes   Dead  36.0
1285    Yes  Alive  48.3
1288    Yes   Dead  39.3
1295    Yes   Dead  82.4
1296    Yes  Alive  38.3
1297    Yes  Alive  32.7
```

```
1299    Yes   Dead  60.0
1303    Yes  Alive  31.2
1304    Yes  Alive  47.8
1305    Yes  Alive  60.9
1307    Yes  Alive  43.0
1309    Yes  Alive  35.9
1311    Yes   Dead  62.1

[582 rows x 3 columns]
```

[6]:
```
#Affichage
nonFumeuses
```

[6]:
```
     Smoker Status   Age
2        No   Dead  57.5
3        No  Alive  47.1
5        No  Alive  36.8
6        No  Alive  23.8
11       No   Dead  66.0
13       No  Alive  58.4
14       No   Dead  60.6
15       No  Alive  25.1
16       No  Alive  43.5
17       No  Alive  27.1
18       No  Alive  58.3
20       No   Dead  73.2
22       No  Alive  33.4
24       No  Alive  18.0
25       No  Alive  56.2
27       No  Alive  25.8
28       No   Dead  36.9
29       No  Alive  20.2
33       No  Alive  19.4
34       No  Alive  56.9
41       No   Dead  69.7
43       No   Dead  75.8
44       No  Alive  25.3
45       No   Dead  83.0
47       No  Alive  18.5
50       No  Alive  82.8
51       No  Alive  45.0
52       No   Dead  73.3
54       No  Alive  28.4
55       No   Dead  73.7
…      …     …   …
1262     No  Alive  41.2
1265     No  Alive  26.7
```

```
1266     No  Alive  41.8
1267     No  Alive  33.7
1268     No  Alive  56.5
1272     No  Alive  33.0
1274     No  Alive  25.7
1275     No  Alive  19.5
1277     No  Alive  23.4
1279     No  Alive  34.4
1280     No   Dead  83.9
1281     No  Alive  34.9
1283     No   Dead  86.3
1286     No  Alive  63.1
1287     No  Alive  60.8
1289     No  Alive  36.7
1290     No  Alive  63.8
1291     No   Dead  71.3
1292     No  Alive  57.7
1293     No  Alive  63.2
1294     No  Alive  46.6
1298     No  Alive  39.7
1300     No   Dead  71.0
1301     No  Alive  20.5
1302     No  Alive  44.4
1306     No   Dead  61.4
1308     No  Alive  42.1
1310     No  Alive  22.3
1312     No   Dead  88.6
1313     No  Alive  39.1

[732 rows x 3 columns]
```

Calcul du nombre **total** de fumeuses (*nbTotalF*) et de non fumeuses (*nbTotalNF*)

[7]:
```
nbTotalF = len(fumeuses.axes[0])
nbTotalNF = len(nonFumeuses.axes[0])
print("Le nombre total de fumeuses est de :", nbTotalF)
print("Le nombre total de non fumeuses est de :", nbTotalNF)
```

```
Le nombre total de fumeuses est de : 582
Le nombre total de non fumeuses est de : 732
```

Calcul du nombre de **fumeuses décédées** (*nbDecedeesF*)

[8]:
```
nbDecedeesF = len(fumeuses.loc[fumeuses["Status"]=="Dead"])
nbDecedeesF
```

[8]: 139

Calcul du nombre de **non fumeuses décédées** (*nbDecedeesNF*)

[9]:
```
nbDecedeesNF = len(nonFumeuses.loc[nonFumeuses["Status"]=="Dead"])
nbDecedeesNF
```

[9]:
```
230
```

Calcul du **taux de mortalité** des fumeuses (*tauxMortF*) et des non fumeuses (*tauxMortNF*)

[10]:
```
tauxMortF = nbDecedeesF/nbTotalF*100
tauxMortNF = nbDecedeesNF/nbTotalNF*100
print("Sur la période donnée, il y a pour les fumeuses un taux de mortalité de :
 ↪ ", tauxMortF, "%")
print("et il y a pour les non fumeuses un taux de mortalité de : ", tauxMortNF,␣
 ↪"%")
```

```
Sur la période donnée, il y a pour les fumeuses un taux de mortalité de :
23.883161512027492 %
et il y a pour les non fumeuses un taux de mortalité de :  31.420765027322407 %
```

Création d'une nouvelle DataFrame pandas (*dt*) qui contient les taux de mortalité selon le statut (fumeuse ou non) en vue de la construction d'un graphique utilisant ces données.

[11]:
```
d = {"tauxMortalite" : [tauxMortF, tauxMortNF], "Statut" : ["Fumeuses",␣
 ↪"nonFumeuses"]}
dt = pd.DataFrame(data = d)
dt
```

[11]:

	Statut	tauxMortalite
0	Fumeuses	23.883162
1	nonFumeuses	31.420765

Création d'un diagramme en barre pour illustrer les calculs précédents.

[12]:
```
%matplotlib inline
plt.figure(figsize=(8, 5))
plt.bar(dt["Statut"], dt["tauxMortalite"], color=['salmon', 'skyblue'])

plt.title("Taux de mortalité par statut de tabagisme")
plt.xlabel("Statut")
plt.ylabel("Taux de mortalité (%)")

plt.show()
```

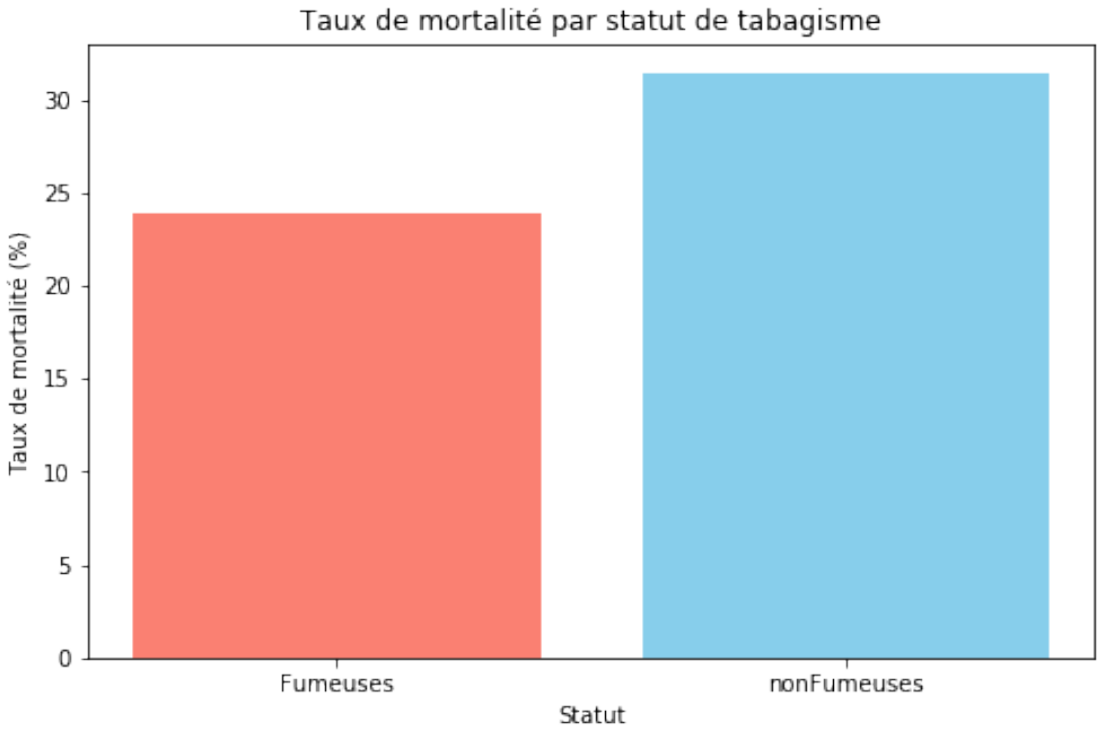

On obtient des résultats assez surprenants dans le sens où, étant donné que l'on nous a souvent répété que fumer est mauvais pour la santé, nous nous attendions à retrouver ce fait dans cette étude. Or, nous pouvons observer que le résultat des calculs effectués nous montre l'inverse de ce à quoi nous nous attendions : le groupe de femmes qui ne fumaient pas a un taux de mortalité supérieur à celui composé de femmes qui fumaient.

1.4 Etape 2 : Calcul du taux de mortalité pour les fumeuses et les non fumeuses selon des classes d'âge

Première tentative pour calculer le nombre total de fumeuses et de non fumeuses ayant entre 18 et 34 ans

[13]:
```
nb18_34F = len(fumeuses.loc[fumeuses["Age"]<34]) - len(fumeuses.
 ↪loc[fumeuses["Age"]<18])
nb18_34NF = len(nonFumeuses.loc[nonFumeuses["Age"]<34]) - len(nonFumeuses.
 ↪loc[nonFumeuses["Age"]<18])
print(nb18_34F, nb18_34NF)
```

```
179 219
```

Calcul avec une autre méthode du nombre de fumeuses entre 18 et 34 ans et calcul du nombre de fumeuses de appartenant à cet intervalle d'âge qui sont mortes.

[14]:
```
test = fumeuses.loc[fumeuses["Age"]<34]
t2 = test.loc[test["Age"]>=18]
print(len(t2))
nbDecedees18_34F = len(t2.loc[t2["Status"]=="Dead"])
print(nbDecedees18_34F, "fumeuses ayant entre 18 et 34 ans lors du premier␣
 ↪sondage sont décédées durant la période avant la suite de l'étude")
```

```
179
5 fumeuses ayant entre 18 et 34 ans lors du premier sondage sont décédées durant
la période avant la suite de l'étude
```

Calcul du taux de mortalité pour les fumeuses entre 18 et 34 ans.

[15]:
```
tauxMort18_34F = nbDecedees18_34F/nb18_34F*100
tauxMort18_34F
```

[15]:
```
2.793296089385475
```

Une fois les calculs trouvés et testés sur le premier intervalle d'âge [18, 34[, il vaut mieux créer une fonction qui calcule le taux de mortalité pour un intervalle et une DataFrame donnés.

[16]:
```
def calculTMparClAge(borneInf, borneSup, data): # la borne supérieure de␣
 ↪l'intervalle n'est pas comprise :
    t1 = data.loc[data["Age"]<borneSup]          # [borneInf, borneSup[
    t2 = t1.loc[t1["Age"]>=borneInf]
    nb = len(t2)
    #print(nb)
    nbMort = len(t2.loc[t2["Status"]=="Dead"])
    #print(nbMort)
    tauxM = nbMort/nb*100
    return tauxM
```

Application de la fonction sur tous les intervalles d'âge

[17]:
```
tauxMort18_34Fv2 = calculTMparClAge(18, 34, fumeuses)
print("Le taux de mortalité des fumeuses pour la classe d'âge 18-34 est de :", ␣
 ↪tauxMort18_34Fv2, "%")

tauxMort18_34NF = calculTMparClAge(18, 34, nonFumeuses)
print("Le taux de mortalité des non fumeuses pour la classe d'âge 18-34 est de :
 ↪", tauxMort18_34NF)
```

```
Le taux de mortalité des fumeuses pour la classe d'âge 18-34 est de :
2.793296089385475 %
Le taux de mortalité des non fumeuses pour la classe d'âge 18-34 est de :
2.73972602739726
```

[18]:
```
tauxMort34_54F = calculTMparClAge(34, 54, fumeuses)
print("Le taux de mortalité des fumeuses pour la classe d'âge 34-54 est de :", ␣
 ↪tauxMort34_54F, "%")

tauxMort34_54NF =  calculTMparClAge(34, 54, nonFumeuses)
print("Le taux de mortalité des non fumeuses pour la classe d'âge 34-54 est de :
 ↪",  tauxMort34_54NF, "%")
```

```
Le taux de mortalité des fumeuses pour la classe d'âge 34-54 est de :
17.154811715481173 %
Le taux de mortalité des non fumeuses pour la classe d'âge 34-54 est de :
9.547738693467336 %
```

[19]:
```
tauxMort54_64F = calculTMparClAge(54, 64, fumeuses)
print("Le taux de mortalité des fumeuses pour la classe d'âge 54-64 est de :",␣
 ↪tauxMort54_64F, "%")

tauxMort54_64NF =  calculTMparClAge(54, 64, nonFumeuses)
print("Le taux de mortalité des non fumeuses pour la classe d'âge 54-64 est de :
 ↪", tauxMort54_64NF, "%")
```

```
Le taux de mortalité des fumeuses pour la classe d'âge 54-64 est de :
44.34782608695652 %
Le taux de mortalité des non fumeuses pour la classe d'âge 54-64 est de :
32.773109243697476 %
```

[20]:
```
tauxMort64_150F = calculTMparClAge(64, 150, fumeuses)
print("Le taux de mortalité des fumeuses de la classe d'âge 64-150 est de :",␣
 ↪tauxMort64_150F)

tauxMort64_150NF = calculTMparClAge(64, 150, nonFumeuses)
print("Le taux de mortalité des fumeuses de la classe d'âge 64-150 est de :",␣
 ↪tauxMort64_150NF)
```

```
Le taux de mortalité des fumeuses de la classe d'âge 64-150 est de :
85.71428571428571
Le taux de mortalité des fumeuses de la classe d'âge 64-150 est de :
85.12820512820512
```

Création d'une nouvelle DataFrame *d2* contenant les classes d'âge suivies de *F* pour fumeuses ou de *NF* pour non fumeuses ainsi que les différents taux de mortalité.

[21]:
```
d2 = {"classeAge" : ["18-34F", "18-34NF", "34-54F", "34-54NF", "54-64F",␣
 ↪"54-64NF", "64+F", "64+NF"],
      "tauxMortalite" : [tauxMort18_34Fv2, tauxMort18_34NF, tauxMort34_54F,␣
 ↪tauxMort34_54NF, tauxMort54_64F, tauxMort54_64NF, tauxMort64_150F,␣
 ↪tauxMort64_150NF]}
dt2 = pd.DataFrame(data = d2)
```

Création du diagramme en barre illustrant les taux de mortalité calculés précédemment selon les classes d'âge.

[22]:
```
%matplotlib inline
plt.figure(figsize=(8, 5))
plt.bar(dt2["classeAge"], dt2["tauxMortalite"], color=['salmon', 'skyblue'])

plt.title("Taux de mortalité par classe d'âge")
plt.xlabel("Classe d'âge (F -> fumeuses et NF -> non fumeuses)")
plt.ylabel("Taux de mortalité (%)")

plt.show()
```

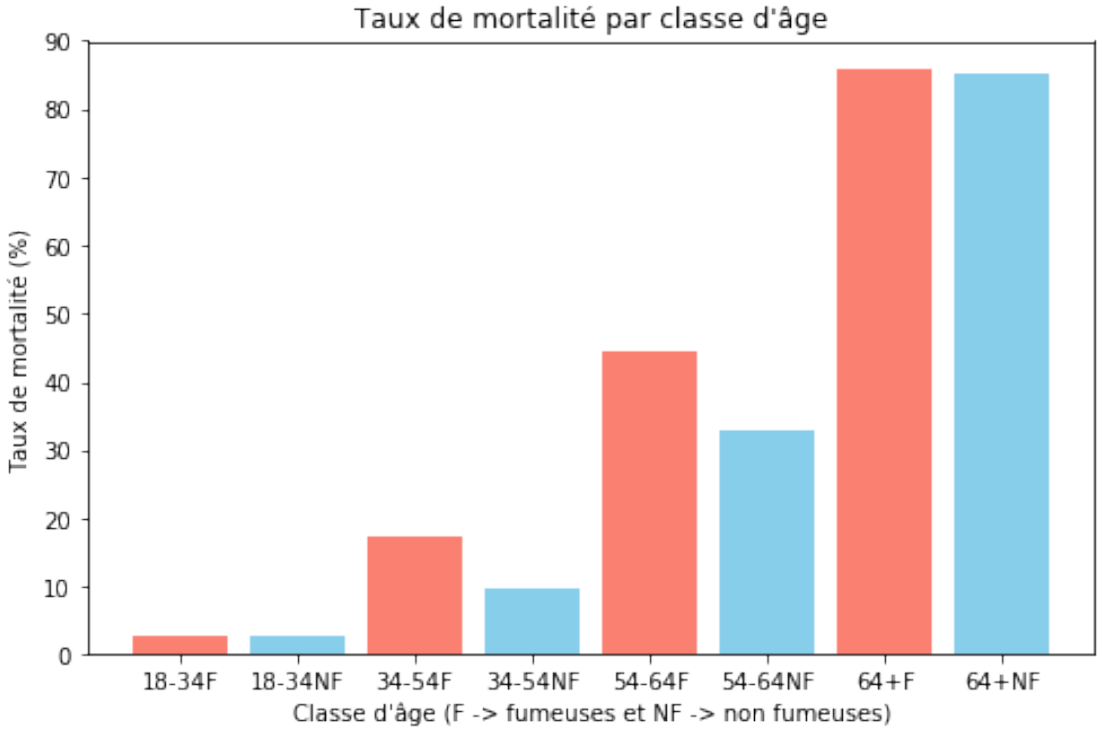

En faisant des classes d'âge, nous obtenons pour les classes centrales comme 34-54 et 54-64 un résultat totalement opposé à celui de l'étape précédente. Il y a, pour ces 2 classes, significativement plus de morts dans le groupe des fumeuses que dans le groupe de non fumeuses durant la période de temps entre le premier sondage et la suite de l'étude. Ce qui se rapproche plus de ce que nous aurions pu supposer avec seulement nos connaissances. Nous pouvons donc avancer que l'âge des femmes est une variable non négligeable dans cette étude puisqu'en le prenant en compte, nous obtenons des résultats différents. Ce qui entrerait en accord avec la description du paradoxe de simpson.

1.5 Etape 3 : Régression logistique

Ajout d'une colonne Death contenant 1 si la personne est morte pendant la période entre le premier sondage et la suite de l'étude et 0 sinon pour toutes les lignes de la DataFrame.

[23]:
```
raw_data["Death"] = raw_data["Status"].apply(lambda x: 1 if x == "Dead" else 0)␣
↪#Usage d'apply pour appliquer la fonction
raw_data                                                                    ␣
↪#anonyme lambda sur chaque ligne de la DataFrame
```

[23]:

	Smoker	Status	Age	Death
0	Yes	Alive	21.0	0
1	Yes	Alive	19.3	0
2	No	Dead	57.5	1
3	No	Alive	47.1	0
4	Yes	Alive	81.4	0
5	No	Alive	36.8	0
6	No	Alive	23.8	0
7	Yes	Dead	57.5	1
8	Yes	Alive	24.8	0
9	Yes	Alive	49.5	0
10	Yes	Alive	30.0	0
11	No	Dead	66.0	1
12	Yes	Alive	49.2	0
13	No	Alive	58.4	0
14	No	Dead	60.6	1
15	No	Alive	25.1	0
16	No	Alive	43.5	0
17	No	Alive	27.1	0
18	No	Alive	58.3	0
19	Yes	Alive	65.7	0
20	No	Dead	73.2	1
21	Yes	Alive	38.3	0
22	No	Alive	33.4	0
23	Yes	Dead	62.3	1
24	No	Alive	18.0	0
25	No	Alive	56.2	0
26	Yes	Alive	59.2	0
27	No	Alive	25.8	0
28	No	Dead	36.9	1
29	No	Alive	20.2	0
…	…	…	…	…
1284	Yes	Dead	36.0	1
1285	Yes	Alive	48.3	0
1286	No	Alive	63.1	0
1287	No	Alive	60.8	0
1288	Yes	Dead	39.3	1

```
1289     No  Alive  36.7      0
1290     No  Alive  63.8      0
1291     No   Dead  71.3      1
1292     No  Alive  57.7      0
1293     No  Alive  63.2      0
1294     No  Alive  46.6      0
1295    Yes   Dead  82.4      1
1296    Yes  Alive  38.3      0
1297    Yes  Alive  32.7      0
1298     No  Alive  39.7      0
1299    Yes   Dead  60.0      1
1300     No   Dead  71.0      1
1301     No  Alive  20.5      0
1302     No  Alive  44.4      0
1303    Yes  Alive  31.2      0
1304    Yes  Alive  47.8      0
1305    Yes  Alive  60.9      0
1306     No   Dead  61.4      1
1307    Yes  Alive  43.0      0
1308     No  Alive  42.1      0
1309    Yes  Alive  35.9      0
1310     No  Alive  22.3      0
1311    Yes   Dead  62.1      1
1312     No   Dead  88.6      1
1313     No  Alive  39.1      0

[1314 rows x 4 columns]
```

Création de nouvelles DataFrames contenant les mêmes valeurs que *fumeuses* et *nonFumeuses* ainsi que la colonne Death ajoutée juste au-dessus.

[24]:
```
nonFumeusesv2 = raw_data.loc[raw_data["Smoker"]=="No"]
fumeusesv2 = raw_data.loc[raw_data["Smoker"]=="Yes"]
```

Régression logistique sur le groupe des fumeuses

[25]:
```
# Modèle pour les fumeuses
X_fumeuses = sm.add_constant(fumeusesv2['Age'])  # Ajout de l'intercept
y_fumeuses = fumeusesv2['Death']
model_fumeuses = sm.Logit(y_fumeuses, X_fumeuses).fit()

# Affichage du résumé des résultats
print("Fumeuses:\n", model_fumeuses.summary())
```

```
Optimization terminated successfully.
         Current function value: 0.412727
         Iterations 7
Fumeuses:
```

```
                           Logit Regression Results
==============================================================================
Dep. Variable:                  Death   No. Observations:                  582
Model:                          Logit   Df Residuals:                      580
Method:                           MLE   Df Model:                            1
Date:                Thu, 31 Oct 2024   Pseudo R-squ.:                 0.2492
Time:                        23:20:10   Log-Likelihood:                -240.21
converged:                       True   LL-Null:                       -319.94
                                        LLR p-value:                 1.477e-36
==============================================================================
                 coef    std err          z      P>|z|      [0.025      0.975]
------------------------------------------------------------------------------
const         -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
==============================================================================
```

Analyse des résultats obtenus avec la régression logistique pour les fumeuses :

La p-value (P>|z|) de l'âge est inférieure à 0.005, ce qui signifie que l'âge a un effet significatif sur la probabilité du décès chez les fumeuses. Son coefficient est de 0.0890 et son intervalle de confiance est [0.072, 0.106]. Le coefficient étant positif, cela signifie que la probabilité de décès augmente en fonction de l'âge. Le pseudo R-carré établit la qualité du modèle. Dans le cas de la régression logistique pour les fumeuses, il est de 0.2492, ce qui n'est pas très élevé et signifie donc que le modèle actuel n'est pas d'une très grande qualité. Cependant, cela confirme toujours que l'âge a un certain effet sur la probabilité de décès. La constante représente la probabilité de base de décès pour les fumeuses lorsqu'on ne prend pas en compte l'âge. Elle est ici de -5.5081.

Régression logistique pour le groupe des non fumeuses

[26]:
```
# Modèle pour les non-fumeuses
X_non_fumeuses = sm.add_constant(nonFumeusesv2['Age'])  # Ajout de l'intercept
y_non_fumeuses = nonFumeusesv2['Death']
model_non_fumeuses = sm.Logit(y_non_fumeuses, X_non_fumeuses).fit()

# Affichage du résumé des résultats
print("Non-fumeuses:\n", model_non_fumeuses.summary())
```

```
Optimization terminated successfully.
         Current function value: 0.354560
         Iterations 7
Non-fumeuses:
                           Logit Regression Results
==============================================================================
Dep. Variable:                  Death   No. Observations:                  732
Model:                          Logit   Df Residuals:                      730
Method:                           MLE   Df Model:                            1
Date:                Thu, 31 Oct 2024   Pseudo R-squ.:                 0.4304
Time:                        23:20:10   Log-Likelihood:                -259.54
converged:                       True   LL-Null:                       -455.62
```

```
                                        LLR p-value:                 2.808e-87
==============================================================================
                 coef    std err          z      P>|z|      [0.025      0.975]
------------------------------------------------------------------------------
const         -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
==============================================================================
```

Analyse des résultats obtenus avec la régression logistique pour les non fumeuses :

La p-value (P>|z|) de l'âge est inférieure à 0.005, ce qui signifie que l'âge a un effet significatif sur la probabilité du décès chez les non fumeuses. Son coefficient est de 0.1073 et son intervalle de confiance est [0.092, 0.123]. Le coefficient étant positif, cela signifie que la probabilité de décès augmente en fonction de l'âge. Dans le cas de la régression logistique pour les non fumeuses, le pseudo R-carré est de 0.4304, ce qui est assez élevé et signifie donc que le modèle actuel est d'assez bonne qualité. La constante est ici de -6.7955.

Comparaison des résultats obtenus pour les 2 régressions logistiques réalisées précédemment :

Le coefficient de l'âge de la régression logistique pour les non fumeuses est plus élevé que celui de la régression logistique pour les fumeuses, ce qui signifie que l'âge a un effet un peu plus fort sur la probabilité de décès des non fumeuses.
Si l'on ne prend pas en compte l'âge et que l'on regarde les chances de décès de base, c'est-à-dire que l'on regarde les constantes, on observe que celle des non fumeuses est inférieure à celle des fumeuses, ce qui veut dire que la chance de base de décès pour les non fumeuses est plus petite que celle des fumeuses.
Ces résultats suggèrent que l'âge a un effet plus important sur la mortalité des non fumeuses que des fumeuses. Ce qui pourrait nous faire penser que le tabagisme semble diminuer les effets de l'âge, mais cela peut être dû à un biais dans les donnée ou à un autre facteur qui n'a pas été pris en compte dans cette étude et qui influence plus le groupe des fumeuses que celui des non fumeuses.

Création d'une série de valeurs d'âge régulièrement espacées allant de la plus petite à la plus grande avec 100 points intermédiaires.

[27]:
```
age_range = np.linspace(raw_data['Age'].min(), raw_data['Age'].max(), 100)
```

Création des prédictions pour les fumeuses *pred_fumeuses* et les non fumeuses *pred_non_fumeuses*

[28]:
```
pred_fumeuses = model_fumeuses.predict(sm.add_constant(age_range))

pred_non_fumeuses = model_non_fumeuses.predict(sm.add_constant(age_range))
```

Création du graphique de probabilité de décès en fonction de l'âge

[29]:
```
plt.figure(figsize=(10, 6))
plt.plot(age_range, pred_fumeuses, label="Fumeuses", color="salmon")
plt.plot(age_range, pred_non_fumeuses, label="Non Fumeuses", color="skyblue")

# Ajout d'intervalles de confiance pour chaque groupe
plt.fill_between(age_range, pred_fumeuses - 1.96 * np.std(pred_fumeuses),␣
 ↪pred_fumeuses + 1.96 * np.std(pred_fumeuses), color="salmon", alpha=0.2)
```

```
plt.fill_between(age_range, pred_non_fumeuses - 1.96 * np.
 ↪std(pred_non_fumeuses), pred_non_fumeuses + 1.96 * np.
 ↪std(pred_non_fumeuses), color="skyblue", alpha=0.2)

# Mise en forme du graphique
plt.xlabel("Âge")
plt.ylabel("Probabilité de décès")
plt.title("Probabilité de décès en fonction de l'âge et du statut (fumeuses ou␣
 ↪non fumeuses)")
plt.legend()
plt.show()
```

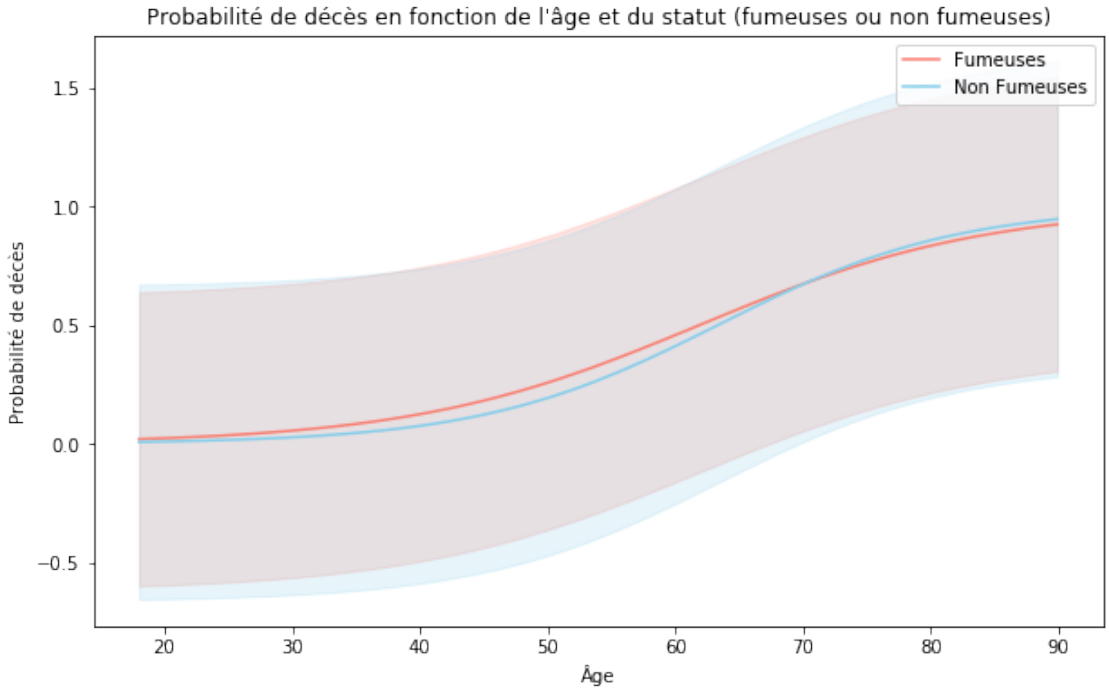

Sur ce graphique, on peut observer que les probabilités de décès pour les fumeuses et les non fumeuses entre 18 et 34 ans et entre 64 et 90 ans sont presques égales, ce qui correspond aux résultats des calculs et au diagramme en barre réalisés à l'étape 2. Entre 34 et 64 ans, la probabilité de décès des fumeuses est supérieure à celle des non fumeuses, ce qui correspond également aux résultats obtenus à l'étape 2.
D'après ce graphique, la probabilité de décès des fumeuses serait plus élevée que celle des non fumeuses pour un âge allant de 18 à 70 ans puis la tendance s'inverserait.
Cela signifierait que le tabagisme augmente les chances de décès des femmes le pratiquant jusqu'à un certain âge.

[ ]: