

## Exercice 1: variables quantitatives

On souhaite étudier les caractéristiques des individus tués par la police aux États-Unis. La base de données 'KilledbyUSPolice' contient des informations sur la personnes tuée (sexe, âge, race ethnique, revenus personnel, revenu de son ménage...) ainsi que des statistiques relatives à la zone géographique où l'individu tué (revenus médians des individus dans le county...).

- 1) Importer le fichier 'KilledbyUSPolice.xlsx' sur SAS ([PROC IMPORT](#)).
- 2) Combien y-a-t-il de variables et d'observations dans le fichier ? ([PROC CONTENTS](#) ou [PROC SUMMARY](#))
- 3) Quelles sont les variables numériques ? ([PROC CONTENTS](#))
- 4) On s'intéresse aux variables 'age', 'p\_income' (revenus de la personne tuée) et 'h\_income' (revenu médian du ménage de la personne tuée). On s'aperçoit que ces variables censées être numériques ont été importées en variables textes par SAS.
  - 4.1) Remplacer les valeurs manquantes symbolisées par 'NA' par '.' (Sans les guillemets pour signaler qu'il s'agit de données manquantes de variables numériques) (étape [DATA](#) + [SET](#) + Condition).
  - 4.2) Convertir ces variables en variables numériques dans une nouvelle colonne ('age\_num', 'p\_income\_num' et 'h\_income\_num') ([DATA](#) + [INPUT](#) + [FORMAT](#)).
  - 4.3) Calculez la moyenne, l'écart type, maximum, minimum de ces variables ('age\_num', 'p\_income\_num' et 'h\_income\_num') et exportez les résultats obtenus dans une sortie appelée 'stat1' ([PROC MEANS](#) + [OUTPUT OUT](#)).
- 5) On s'intéresse aux variables 'h\_income\_num' et 'county\_income' (revenu médian des ménages dans la zone géographique où la personne a été tuée). Construisez le graphique boxplot de ces deux variables ([PROC SGPLOT](#) + option [VBOX](#)).
- 6) Créez le graphique nuage de points avec en abscisse la variable 'age\_num' et en ordonnée 'p\_income\_num'. Spécifiez un titre pour le graphique. Que constatez-vous ([PROC SGPLOT](#) + option [SCATTER](#) + option [TITLE](#)) ?
- 7) Calculez la corrélation entre la variable 'age\_num' et 'p\_income\_num'. Quel est le coefficient de corrélation obtenu ? Que pouvez-vous en déduire ([PROC CORR](#)) ?
- 8) Étude des variables transformées :
  - 8.1) Transformez les variables 'age\_num' et 'p\_income\_num' en rang que vous nommerez 'RankAge' et 'RankIncome' ([PROC RANK](#)).
  - 8.2) Croisez les variables 'RankAge' et 'RankIncome' dans un graphique nuage de point. Que constatez-vous ? ([PROC SGPLOT](#) + option [SCATTER](#)).
  - 8.3) Calculez le coefficient de corrélation entre ces deux variables transformées. Que constatez-vous ? ([PROC CORR](#))
- 9) Calculez les coefficients des moindres carrés entre les variables 'age\_num' et 'p\_income\_num'. Quelle est la valeur du coefficient ? ([PROC REG](#))
- 10) Tracez la droite de régression entre la variable 'age\_num' et 'p\_income\_num' ([PROC SGPLOT](#) + option [REG](#)).

## Exercice 2: variables qualitative et quantitative

Nous allons travailler sur les variables `'age_num'` et `'raceethnicity'`.

1) Comme vu à l'exercice précédent, certaines observations de `'age_num'` ont été changées en `'.'`. A l'aide de la `PROC STDIZE` remplacer ces valeurs par la moyenne de la variable `'age_num'`.

2) Observez la distribution de fréquence des modalités de la variables `'raceethnicity'` (`PROC FREQ`). Quelle remarque peut-on faire lorsque l'on compare les fréquences de chaque modalité entre elles?

3) Pour plus de lisibilité et parce que le nombre d'observation des modalités `'Native American'`, `'Asian/Pacific Islander'` et `'Unknown'` est faible, nous allons en créer une nouvelle, `'Other'`. Utiliser l'étape `DATA` pour faire les changements et sauvegardez les dans une nouvelle colonne `'raceethnicity_recode'`

4) Décrivez la variable `'age_num'` en fonction des modalités de la variable `'raceethnicity_recode'`. Pour ce faire vous pouvez utiliser la `PROC MEANS` et devez tracer dans le même graphique des boîtes à moustache (`PROC BOXPLOT`) montrant les statistiques de `'age_num'` par modalités de `'raceethnicity_recode'`.

Remarque: utilisez la `PROC SORT` afin de trier les valeurs de `'raceethnicity_recode'` avant d'utiliser la `PROC BOXPLOT`.

5) Quelles informations pouvez-vous extraire de ces boîtes à moustaches?

6) On réalise maintenant une ANOVA sur les mêmes variables que précédemment en utilisant la `PROC GLM`.

7) Que pouvez-vous dire sur l'homogénéité des variances? Sur quoi vous renseigne la p-value de l'analyse?

### Exercice 3: variables qualitatives

1) Nous souhaitons maintenant regrouper les individus par classe d'âge. Pour cela, nous allons créer une nouvelle variable 'age\_recode' issu de la discrétisation de la variable 'age\_num' en 4 modalités qui sont les suivantes:

$$\begin{aligned} < 21 &== \textit{mineur} \\ 21 - 30 &== \textit{jeune adulte} \\ 31 - 50 &== \textit{adulte} \\ > 51 &== \textit{senior} \end{aligned}$$

Représentez graphiquement le nombre d'individus dans les catégories ([PROC FREQ](#)).

2) Faites un tableau croisé des variables 'age\_recode' et 'armed' puis effectuez un test de khi2 entre ces dernières. ([PROC FREQ](#))

3) On souhaite étudier les liens entre les variables 'armed' et 'raceethnicity\_recode'. Commencez par afficher la fréquence des modalités par variable. Puis croisez les deux variables dans un tableau, afficher le nombre de modalités ainsi que les profils lignes (utilisez la [PROC TABULATE](#) et [ROWPCTN](#))

4) Proposez une représentation graphique ([PROC FREQ](#) à l'aide de l'option [MOSAICPLOT](#))

5) Effectuez un test de khi2 entre les variables 'armed' et 'raceethnicity\_recode', que constatez-vous ?