

5. On s'intéresse à la répartition des salaires sur ces données agrégées.

5.1 (0.5). Tracer la courbe de Lorenz. On rappelle que cette courbe est obtenue à partir des points

$$\left(F_i, \frac{\sum_{j \leq i} n_j c_j}{\sum_{j=1}^3 n_j c_j} \right), \quad i \in \llbracket 1, 3 \rrbracket,$$

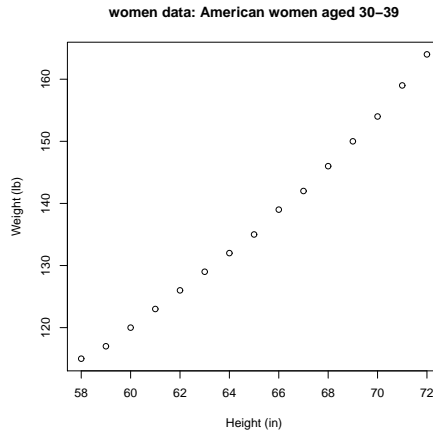
où F_i est la fréquence cumulée, n_i l'effectif et c_i le centre de la classe $i \in \llbracket 1, 3 \rrbracket$.

5.2 (1). Calculer l'indice de Gini.

5.3 (0.5). Commenter.

Exercice 3 (Relation poids-taille, 10 pts)

On étudie la relation poids (**weight** en anglais, en inches) - taille (**height**, en livres) pour un échantillon de 15 Américaines âgées de 30 à 39 ans. On obtient le graphique suivant :



1 (0.5 pt). Que vous inspire ce graphique ?

2 (1.5). Sous **R**, la table s'appelle **women**. On donne :

```
mean(women$height)=65
mean(women$weight)=136.7333
mean(women$height^2)=4243.667
mean(women$weight^2)=18920.2
mean(women$height*women$weight)=8952.067
```

Calculer la moyenne et la variance des variables **taille** et **poids**, ainsi que la covariance des variables **taille** et **poids**.

3 (1.5). On obtient sous **R** :

```
var(women$height)= 20
var(women$weight)=240.2095
cov(women$height,women$weight)=69
```

D'où viennent les différences ? Ré-obtenir ces valeurs à partir des calculs de la question 2.

4 (1.5). A partir des résultats des questions précédentes, calculer les estimateurs MCO de la régression suivante :

$$\text{poids} = a \times \text{taille} + b + \varepsilon$$

5 (1). On donne le résultat suivant, obtenu sous **R** :

```
> reg<-lm(women$weight ~ women$height)
> summary(reg)
```

```
Call:
lm(formula = women$weight ~ women$height)
```

```
Residuals:
    Min       1Q   Median       3Q      Max
-1.7333 -1.1333 -0.3833  0.7417  3.1167
```

```
Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept)  -87.51667     5.93694  -14.74 1.71e-09 ***
women$height   3.45000     0.09114   37.85 1.09e-14 ***
---

```

```
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```


```
Residual standard error: 1.525 on 13 degrees of freedom
Multiple R-Squared:  0.991,    Adjusted R-squared:  0.9903
F-statistic: 1433 on 1 and 13 DF,  p-value: 1.091e-14
```

Que pensez-vous de la qualité de la régression (donnez 3 éléments pour justifier votre réponse).

6 (1). Quelles sont les hypothèses pour pouvoir lire les tests de Student et de Fisher donnés à la question précédente? Pour vérifier cela, on tape sous **R** le code suivant :

```
eps<-reg$residuals
qqnorm(eps)
qqline(eps)
```

ce qui nous fournit la figure ci-contre :



Qu'en pensez-vous ?

7 (1). Nous supposons les résidus gaussiens. Quelle est la loi de \hat{a} conditionnellement aux variables explicatives? (on pourra noter x_i et y_i la taille et le poids respectivement de l'individu i)

8 (0.5). Quelle sont les hypothèses nulle et alternative du test de Student calculé sur la ligne `women$height 3.45000 0.09114 37.85 1.09e-14 ***` dans la question 5?

9 (1.5). A partir de la question 7, établir l'expression littérale de la statistique du test de Student de la question 8.