

Nom :	Prénom :
--------------	-----------------

Exercice 1.

Considérons le modèle linéaire simple $Y_i = \mu + \beta X_i + \varepsilon_i, i = 1, \dots, n$ où ε_i vérifie l'hypothèse $\{\varepsilon_i, i = 1, \dots, n\} \stackrel{i.i.d.}{\sim} \mathcal{N}(0, \sigma^2)$.

On a lancé les codes suivants :

`X = c(10, 15, 20, 25, 30); Y = c(29, 44, 53, 60, 70); summary(lm(Y~X))`

Voici les résultats :

Residuals:

```
1    2    3    4    5
-2.6  2.6  1.8 -1.0 -0.8
```

Coefficients:

```
              Estimate Std. Error t value Pr(>|t|)
(Intercept) 12.0000     3.3226   3.612  0.0365 *
X            1.9600     0.1566  12.513  0.0011 **
Residual standard error: 2.477 on 3 degrees of freedom
Multiple R-squared:  0.9812, Adjusted R-squared:  0.9749
F-statistic: 156.6 on 1 and 3 DF,  p-value: 0.0011
```

Pouvez vous remplir le tableau suivant?

1. $\hat{\mu} =$	12
2. $\hat{\beta} =$	1,96
3. $\hat{\sigma}^2 =$	2,477 ²
4. $\text{Var}(\hat{\mu}) =$	3,3226 ²
5. $\text{Var}(\hat{\beta}) =$	0,1566 ²

Nous pouvons obtenir la valeur numérique 0.0011 en utilisant les autres résultats de la sortie en R. Écrire le code R qui renvoie 0.0011 en utilisant les fonctions `pt()` et `pf()`.

6. code R avec <code>pt()</code> :	<code>pt(12.513, 3, lower.tail=F) * 2</code>
7. code R avec <code>pf()</code> :	<code>pf(156.6, 1, 3, lower.tail=F)</code>

8. Est il surprenant que la somme des résidus vaut zéro, pourquoi ?

$$\bar{\hat{\varepsilon}} = \overline{Y - \hat{Y}} = \bar{Y} - \overline{(\hat{\mu} + \hat{\beta}X)} = \bar{Y} - (\hat{\mu} + \hat{\beta}\bar{X}) = \bar{Y} - \hat{\beta}\bar{X} - \hat{\mu} = \hat{\mu} - \hat{\mu} = 0$$

Oui.

Exercice 2.

On a lancé les codes suivants.

```
Y = c(10, 15, 20, 25, 30); X1 = c(29, 44, 53, 60, 70); X2 = c(29, 39, 49, 61, 66);  
summary(lm(Y~X1+X2))
```

Les sorties sont présentées dessous.

```
              Estimate Std. Error t value Pr(>|t|)  
(Intercept) -5.4937      1.6533  -3.323  0.0799 .  
X1           0.1949      0.1804   1.081  0.3928  
X2           0.3179      0.1848   1.721  0.2275  
Residual standard error: 0.9734 on 2 degrees of freedom  
Multiple R-squared:  0.9924, Adjusted R-squared:  0.9848  
F-statistic: 130.9 on 2 and 2 DF,  p-value: 0.00758
```

1. Observez vous des anomalies ? Pouvez vous les expliquer ?

Oui, "colinéarité": Parce que X_1 et X_2 sont fortement corrélées
anomalies: aucune variable est significative ($0,3928 > 0,05$, $0,2275 > 0,05$)
Le modèle est globalement significatif ($0,00758 < 0,05$)

On tape maintenant les codes suivants.

```
Y = Y-mean(Y); X1 = X1-mean(X1); X2 = X2-mean(X2); c = coefficients(lm(Y~X1+X2))
```

Pouvez vous prédire les valeurs des sorties des commandes suivantes?

2. c[1] ≈	0
3. c[2] ≈	0,1949
4. c[3] ≈	0,3179

Exercice 3.

On dispose d'un échantillon (Y_1, \dots, Y_n) de variables aléatoires réelles dans lequel Y_i est défini par la relation

$$Y_i = \frac{\mu}{p_i} + \varepsilon_i$$

où $(\varepsilon_1, \dots, \varepsilon_n)$ est une suite des variables aléatoires i.i.d. de loi $\mathcal{N}(0, \sigma^2)$ avec σ^2 inconnu et (p_1, \dots, p_n) sont des nombres réels non nuls supposés connus. On cherche à construire des estimateurs de μ et σ^2

1. On note $M = \frac{1}{n} \sum_{i=1}^n p_i Y_i$. Montrer que M est un estimateur sans biais de μ et calculer la variance de cet estimateur. Quelle est la loi de M ?

2. Rappelons que $P_{[v]}(u) = \frac{\langle u, v \rangle}{\|v\|^2} \cdot v$ et $P_{[v]^\perp}(u) = u - P_{[v]}(u)$. On note E le sous-espace vectoriel de \mathbb{R}^n engendré par le vecteur $e = (\frac{1}{p_1}, \dots, \frac{1}{p_n})^T$. Calculer $P_E(Y)$ et $P_{E^\perp}(Y)$.

3. On note ν le vecteur $(\frac{\mu}{p_1}, \dots, \frac{\mu}{p_n})^T$. Calculer $P_{E^\perp}(\nu)$.

4. Dédurre des questions précédentes et du théorème de Cochran la loi de $\|P_{E^\perp}(Y - \nu)\|^2$. Proposer un estimateur sans biais de σ^2 . Calculer la variance de cet estimateur. Comment s'écrit l'estimateur lorsque $p_1 = \dots = p_n = 1$?

5. Calculer les estimateurs de μ et σ^2 en utilisant la méthode des moindres carrés, c.a.d. $\hat{\mu} = (Z^T Z)^{-1} Z^T Y$ et $\hat{\sigma}^2 = SCR / (n - k)$. Comparer les espérances et variances de $\hat{\mu}$ et $\hat{\sigma}^2$ avec celles des estimateurs obtenus dans les questions 1 et 4.

Exo 3. (17/01)

$$1. \mathbb{E}M = \frac{1}{n} \sum p_i \mathbb{E}Y_i = \frac{1}{n} \sum p_i \cdot \frac{\mu}{p_i} = \mu \Rightarrow \text{sans biais}$$

$$\mathbb{V}M = \frac{1}{n^2} \sum p_i^2 \mathbb{V}Y_i = \frac{1}{n^2} \sum p_i^2 \cdot \sigma^2 = \frac{\sigma^2}{n^2} \sum p_i^2$$

La loi de M est $\mathcal{N}(\mu, \frac{\sigma^2}{n^2} \sum p_i^2)$

$$2. \langle Y, e \rangle = \sum \frac{Y_i}{p_i}, \quad \|e\|^2 = \sum \frac{1}{p_i^2}, \quad P_E(Y) = \frac{\langle Y, e \rangle}{\|e\|^2} \cdot e = \frac{\sum Y_i/p_i}{\sum 1/p_i^2} \left(\frac{1}{p_1}, \dots, \frac{1}{p_n} \right)^T$$

$$P_{E^\perp}(Y) = Y - P_E(Y) = (Y_1, \dots, Y_n)^T - \frac{\sum Y_i/p_i}{\sum 1/p_i^2} \left(\frac{1}{p_1}, \dots, \frac{1}{p_n} \right)^T$$

$$3. P_E(Y) = \frac{\sum \mu/p_i^2}{\sum 1/p_i^2} \left(\frac{1}{p_1}, \dots, \frac{1}{p_n} \right)^T = \mu \left(\frac{1}{p_1}, \dots, \frac{1}{p_n} \right)^T$$

$$P_{E^\perp}(Y) = Y - P_E(Y) = (0, \dots, 0)^T$$

4. Puisque $Y - \mathcal{Y} \sim \mathcal{N}(\vec{0}, \sigma^2 I)$, $\|P_{E^\perp}(Y - \mathcal{Y})\|^2 \sim \sigma^2 \chi^2(k)$
avec $k = \dim(E^\perp) = n-1$. Donc la loi de $\|P_{E^\perp}(Y - \mathcal{Y})\|^2$ est $\sigma^2 \cdot \chi^2(n-1)$.

$$\|P_{E^\perp}(Y - \mathcal{Y})\|^2 = \|P_{E^\perp}Y - P_{E^\perp}\mathcal{Y}\|^2 \stackrel{P_{E^\perp}(\mathcal{Y}) = \vec{0}}{=} \|P_{E^\perp}Y\|^2$$

$$\mathbb{E} \|P_{E^\perp}Y\|^2 = \mathbb{E} \|P_{E^\perp}(Y - \mathcal{Y})\|^2 = \mathbb{E} (\sigma^2 \chi^2(n-1)) = \sigma^2(n-1)$$

$\frac{\|P_{E^\perp}Y\|^2}{n-1}$ est un estimateur sans biais de σ^2 .

$$\text{Notons } \hat{\sigma}^2 = \frac{\|P_{E^\perp}Y\|^2}{n-1}, \quad \mathbb{V}\hat{\sigma}^2 = \frac{1}{(n-1)^2} \mathbb{V}(\sigma^2 \chi^2(n-1)) = \frac{2\sigma^4}{n-1}$$

Lorsque $p_1 = \dots = p_n = 1$, on a

$$\hat{\sigma}^2 = \frac{\left((Y_1 - \frac{\sum Y_i}{n})^2 + \dots + (Y_n - \frac{\sum Y_i}{n})^2 \right)}{n-1} = \frac{\|Y - \bar{Y}\|^2}{n-1}$$

5. Le modèle $Y_i = \frac{\mu}{P_i} + \varepsilon_i$ peut s'écrire en forme matricielle

$$Y = Z\mu + \varepsilon \quad \text{avec } Z = \left(\frac{1}{P_1}, \dots, \frac{1}{P_n}\right)^T.$$

$$\text{On a } Z^T Z = Z \frac{1}{P_i^2}, \quad Z^T Y = \sum \frac{Y_i}{P_i}, \quad (Z^T Z)^{-1} Z^T Y = \frac{\sum Y_i / P_i}{\sum 1/P_i^2} = \hat{\mu}.$$

$$\text{On a } \text{SCR} = \|Y - \hat{Y}\|^2 = \|Y - Z\hat{\mu}\|^2 = \left\| Y - \left(\frac{1}{P_1}, \dots, \frac{1}{P_n}\right)^T \cdot \frac{\sum Y_i / P_i}{\sum 1/P_i^2} \right\|^2 = \|P_{E^\perp}(Y)\|^2.$$

Donc $\hat{\sigma}^2$ et $\tilde{\sigma}^2$ sont identiques.

$$E\hat{\mu} = \mu, \quad V\hat{\mu} = \frac{\sigma^2}{\sum 1/P_i^2}$$

$$\text{Si } P_1 = \dots = P_n = P, \text{ alors } VM = V\hat{\mu} = \frac{\sigma^2 \cdot P^2}{n}.$$

$$\text{Sinon } \frac{VM}{V\hat{\mu}} = \frac{\sum P_i^2 \cdot \sum 1/P_i^2}{n^2} = \frac{n + \sum_{i \neq j} P_i^2 / P_j^2}{n^2} > 1, \text{ si } \sum_{i \neq j} P_i^2 / P_j^2 > A_n^2.$$

Exo3 (14/02)

$$1. E(M) = \frac{1}{n} \sum \frac{\mu P_i}{P_i} = \mu \Rightarrow \text{sans biais}, \quad VM = \frac{\sigma^2}{n^2} \sum \frac{1}{P_i^2}, \quad M \sim N\left(\mu, \frac{\sigma^2}{n^2} \sum \frac{1}{P_i^2}\right)$$

$$2. P_E(X) = \frac{\sum P_i X_i}{\sum P_i^2} (P_1, \dots, P_n)^T, \quad P_{E^\perp}(X) = (X_1, \dots, X_n)^T - \frac{\sum P_i X_i}{\sum P_i^2} (P_1, \dots, P_n)^T.$$

$$3. P_{E^\perp}(Y) = \vec{0}.$$

$$4. \|P_{E^\perp}(X - Y)\|^2 \sim \sigma^2 \chi^2(n-1)$$

$$\tilde{\sigma}^2 = \frac{\|P_{E^\perp} X\|^2}{n-1} \text{ est un estimateur sans biais de } \sigma^2.$$

$$V\tilde{\sigma}^2 = \frac{2\sigma^4}{n-1}, \quad \text{Lorsque } P_1 = \dots = P_n = P, \text{ on a } \tilde{\sigma}^2 = \frac{\|X - \bar{X}\|^2}{n-1}.$$

$$5. \hat{\mu} = \frac{\sum P_i X_i}{\sum P_i^2}, \quad \hat{\sigma}^2 = \tilde{\sigma}^2$$

$$E\hat{\mu} = \mu, \quad V\hat{\mu} = \frac{\sigma^2}{\sum P_i^2}$$

$$\text{Si } P_1 = \dots = P_n = P, \text{ alors } VM = V\hat{\mu} = \frac{\sigma^2}{nP^2}$$

$$\text{Sinon } \frac{VM}{V\hat{\mu}} > 1 \text{ si } \sum_{i \neq j} P_i^2 / P_j^2 > A_n^2$$

Nom :	Prénom :
--------------	-----------------

Exercice 1.

Considérons le modèle gaussien

$$Y_{ij} = \mu_i + \varepsilon_{ij} \text{ avec } i = 1, 2, 3 \text{ et } j = 1, \dots, 6,$$

où $\mathbb{E}(\varepsilon_{ij}) = 0$, $V(\varepsilon_{ij}) = \sigma^2$, $V(i, j)$ et les ε_{ij} sont indépendants.

On a lancé les codes suivants :

```
Y = c(23.4, 24.4, 24.6, 24.9, 25.0, 26.2, 22.5, 22.9, 23.7, 24.0, 24.4, 18.9,
      21.1, 21.2, 22.1, 22.5, 23.5, 24.5)
```

```
I = c(rep(1,6), rep(2,6), rep(3,6)); I = as.factor(I)
summary(lm(Y~I)); anova(lm(Y~I))
```

Voici les résultats :

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	24.7500	0.6060	40.838	<2e-16 ***
I2	-2.0167	0.8571	-2.353	0.0327 *
I3	-2.2667	0.8571	-2.645	0.0184 *

Response: Y

	Df	Sum Sq	Mean Sq	F value	Pr(>F)
I	2	18.534	9.2672	4.2052	0.03549 *
Residuals	15	33.057	2.2038		

1. Que signifient elles les sorties numériques 24.75, -2.0167, < 2e - 16 et 0.0184 ?

1) 24.75

$$\hat{\mu}_1$$

2) -2.0167

$$\hat{\mu}_2 - \hat{\mu}_1$$

3) < 2e - 16

P-value pour tester entre $H_0: \mu_1 = 0$ et $H_1: \mu_1 \neq 0$

4) 0.0184

P-value pour tester entre $H_0: \mu_2 = \mu_1$ et $H_1: \mu_2 \neq \mu_1$

2. Que signifient elles les valeurs numériques 18.53, 33.057 et 0.03549 ?

1) 18.53

$$SCE = \sum_{i=1}^3 \sum_{j=1}^6 (Y_{ij} - \bar{Y}_{i.})^2 : \text{inter groupe}$$

2) 33.057

$$SCR = \sum_{i=1}^3 \sum_{j=1}^6 (Y_{ij} - \bar{Y}_{i.})^2 : \text{intra groupe}$$

3) 0.03549

P-value pour tester entre $H_0: \mu_1 = \mu_2 = \mu_3$ et $H_1: \text{au moins } \exists \mu_i \text{ t.q. } \mu_i \neq \mu_j, i \neq j$

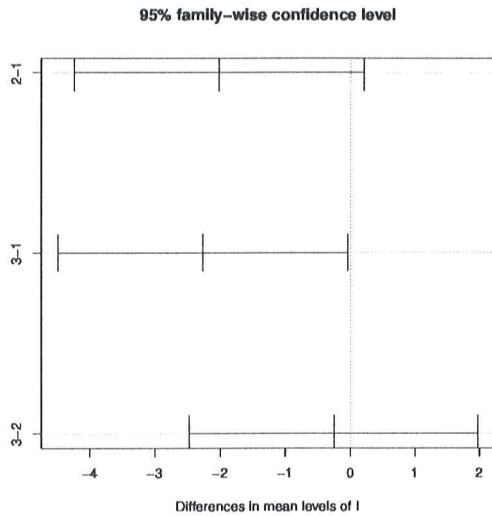
3. Pouvez vous prédire la valeur de la commande $\text{sum}((Y-\text{mean}(Y))^2)$?

$$18,534 + 33,057 = 51,591$$

4. Nous pouvons obtenir la valeur numérique 0.03549 en utilisant la fonction $\text{pf}()$ et les autres résultats de la sortie en R. Écrire le code R qui renvoie 0.03549 en utilisant $\text{pf}()$.

$$1 - \text{pf}\left(\frac{18,534/2}{33,057/15}, 2, 15\right)$$

5. On a tapé la commande $\text{plot}(\text{TUKEYHSD}(\text{aov}(Y\sim I)))$. La sortie est présentée ci dessous. Pouvez vous commenter ce graphique ? Est il cohérent avec les sorties numériques ?



μ_1 et μ_3 sont significativement différents. μ_1 et μ_2 ne sont pas, μ_2 et μ_3 ne sont pas. Il est cohérent avec les sorties numériques : $0,0184 < 0,05 \Rightarrow \mu_1 \neq \mu_3$

Exercice 2.

On considère un échantillon (X_1, \dots, X_n) de variables aléatoires réelles indépendantes dans lequel X_i suit une loi $\mathcal{N}(\mu p_i, \sigma^2)$ avec μ et σ^2 des paramètres inconnus et (p_1, \dots, p_n) des nombres réels non nuls supposés connus. On cherche à construire des estimateurs de μ et σ^2

1. On note $M = \frac{1}{n} \sum_{i=1}^n \frac{X_i}{p_i}$. Montrer que M est un estimateur sans biais de μ et calculer la variance de cet estimateur. Quelle est la loi de M ?
2. Rappelons que $P_{[v]}(u) = \frac{\langle u, v \rangle}{\|v\|^2} \cdot v$ et $P_{[v]^\perp}(u) = u - P_{[v]}(u)$. On note E le sous-espace vectoriel de \mathbb{R}^n engendré par le vecteur $e = (p_1, \dots, p_n)^T$. Calculer $P_E(Y)$ et $P_{E^\perp}(Y)$.
3. On note ν le vecteur $(\mu p_1, \dots, \mu p_n)^T$. Calculer $P_{E^\perp}(\nu)$.
4. Dédire des questions précédentes et du théorème de Cochran la loi de $\|P_{E^\perp}(Y - \nu)\|^2$. Proposer un estimateur sans biais de σ^2 . Calculer la variance de cet estimateur. Comment s'écrit l'estimateur lorsque $p_1 = \dots = p_n = p$?
5. Calculer les estimateurs de μ et σ^2 en utilisant la méthode des moindres carrés, c.a.d. $\hat{\mu} = (Z^T Z)^{-1} Z^T Y$ et $\hat{\sigma}^2 = \text{SCR}/(n - k)$ pour le modèle $X_i = \mu p_i + \varepsilon_i$. Comparer les espérances et variances de $\hat{\mu}$ et $\hat{\sigma}^2$ avec celles des estimateurs obtenus dans les questions 1 et 4.