
Statistique descriptive

Corrigé de l'examen blanc de décembre 2011

Question 1 (13 points)

Y = Variable d'intérêt = taux de réussite en bachelier dans les universités francophones

1^{ère} partie de la question :

N = 50.000 ; n = 200 ; nombre de succès (réussite) = 110

a. $f = \frac{n}{N} = \frac{200}{50000} = 0.004$

b. Dans le cadre de l'estimation d'une proportion : $ME = 2 \times \sqrt{(1-f) \frac{p(1-p)}{n}}$

- **Si** on n'a pas d'information *a priori* sur p, on prend le cas le plus défavorable ($p = 0.5 \rightarrow ME \text{ max}$). Ici, on sait qu'avec 200 étudiants sondés, $p = 0.55$ (110/200). Toutefois, cette proportion pourrait changer et se rapprocher encore de 0.5 avec plus ou moins d'individus sondés \rightarrow dans le doute, on prend $p = 0.5$ comme référence.

- **Si** $(1-f) \rightarrow 1$ alors, $ME \approx 2 \times \sqrt{\frac{p(1-p)}{n}}$; Ici, $(1-f) = 0.996 \approx 1$

- Dans ces **deux conditions**, il faut prendre $n \geq \frac{1}{x^2}$ (x étant la marge d'erreur maximale que le sondeur est prêt à accepter \rightarrow dans ce cas, $x = 3\% = 0.03$)

- $n \geq \frac{1}{0.03^2} = 1111.11 \rightarrow$ puisque chaque individu apporte plus de précision aux estimations, **ON ARRONDIT À L'UNITÉ SUPÉRIEURE** (1111,11 est un minimum pour avoir une $ME \leq$ à 3%, or 0.11 individu = « no sens » \rightarrow on en prend 1112)
Si on remplace la formule initiale avec ces données on a :

$$ME = 2 \times \sqrt{(1-0.004) \frac{0.5(1-0.5)}{1112}} = 0.02993 \approx 3\%$$

2^{ème} partie de la question :

H = 4	N_h	N_h/N	n_h	p_h
Bruxelles	$N_B = 15000$	$N_B/N = 0.3$	$n_B = 65$	$p_B = 0.4$
Louvain-la-Neuve	$N_{LN} = 12000$	$N_{LN}/N = 0.24$	$n_{LN} = 40$	$p_{LN} = 0.2$
Namur	$N_N = 9250$	$N_N/N = 0.185$	$n_N = 37$	$p_N = 0.3$
Liège	$N_L = 13750$	$N_L/N = 0.275$	$n_L = 58$	$p_L = 0.28$
	$N = 50000$		$n = 200$	

- a. Dans un sondage stratifié, la variable auxiliaire est la variable qui est utilisée pour délimiter les strates. Idéalement, cette variable doit être fortement liée à la variable d'intérêt (Y) puisque le sondage stratifié a de l'intérêt quand Y est fortement hétérogène au niveau de la population dans son ensemble. Aussi, en définissant des strates sur base des différentes catégories de la variable auxiliaire, l'espoir du sondeur est de réaliser un sondage aléatoire simple au sein de groupes plus homogènes et donc, en définitive, d'améliorer la précision de ses estimations.

b. $fh = \frac{nh}{Nh}$

$$fB = \frac{65}{15000} = 0.00433$$

$$fLN = \frac{40}{12000} = 0.00333$$

$$fN = \frac{37}{9250} = 0.004$$

$$fL = \frac{58}{13750} = 0.00422$$

Ils mesurent la probabilité pour un individu appartenant à la strate h d'être sélectionné dans l'échantillon n_h .

c. Uniquement au sein de la strate BXL → sondage aléatoire simple

- $p_B = 0.4$ (donné dans l'énoncé)
- IC (π) = $p \pm 2 \times \sqrt{V(p)}$ avec $V(p) = (1 - f) \frac{p(1-p)}{n}$
 - $V(p) = (1 - 0.00433) \times \frac{0.4 \times (1-0.4)}{65} = 0.003676$
 - IC (π) = $0.4 \pm 2 \times \sqrt{0.003676} = [0.28 ; 0.52]$

d. Toutes strates confondues → sondage stratifié

- IC (π) = $p_{st} \pm 2 \times \sqrt{\hat{V}(p_{st})}$
 - avec $p_{st} = \sum_{h=1}^H \frac{Nh}{N} ph$ et $\hat{V}(p_{st}) = \sum_{h=1}^H \left(\frac{Nh}{N}\right)^2 (1 - f) \frac{ph(1-ph)}{nh}$
 - $p_{st} = 0.4 \times 0.3 + 0.2 \times 0.24 + 0.3 \times 0.185 + 0.28 \times 0.275 = 0.3005$
 - $\hat{V}(p_{st}) = 0.3^2 \times (1 - 0.00433) \times (0.4 \times (1 - 0.4))/65 + 0.24^2 \times (1 - 0.00333) \times (0.2 \times (1 - 0.2))/40 + 0.185^2 \times (1 - 0.004) \times (0.3 \times (1 - 0.3))/37 + 0.275^2 \times (1 - 0.00422) \times (0.28 \times (1 - 0.28))/58 = 0.001016$
 - IC (π) = $0.3005 \pm 2 \times \sqrt{0.001016} = [0.237 ; 0.364]$, ce qui signifie que, en gardant 5% de chances de se tromper, le taux de réussite des étudiants de bachelier dans les universités francophones est situé entre 23.7% et 36.4%. **(TOUJOURS SE DEMANDER CE QUE SIGNIFIE UN RÉSULTAT CHIFFRÉ EN FRANÇAIS ET SAVOIR L'EXPRIMER - suppose la compréhension du concept et un retour à l'énoncé/question de départ).**

e. En allocation proportionnelle : $n_h = n \times \frac{Nh}{N}$

$$n_B = 200 \times 0.3 = 60$$

$$n_{LN} = 200 \times 0.24 = 48$$

$$n_N = 200 \times 0.185 = 37$$

$$n_L = 200 \times 0.275 = 55$$

f. $c_L = 20\text{€}$; $c_N = 35\text{€}$; $c_{LN} = 40\text{€}$; $c_B = 55\text{€}$

$C = 30000\text{€}$

- 1^{ère} étape : on calcule le nombre global d'individus qu'on va pouvoir sonder avec notre budget :

$$n = \frac{C}{\sum_{h=1}^H \frac{N h}{N} c_h} \rightarrow n = \frac{30000}{0.3 \times 0.55 + 0.24 \times 40 + 0.185 \times 35 + 0.275 \times 20} = 787.92$$

Étant donné qu'on ne peut pas dépasser C, **ON ARRONDIT** le nombre d'individus sondés **À L'UNITÉ INFÉRIEURE** $\rightarrow n = 787$

- 2^{ème} étape : on descend d'un niveau pour répartir ces n individus dans les strates de manière proportionnelle (en référence à la population) :

$$n_h = n \times \frac{N h}{N} \quad \rightarrow n_B = 787 \times 0.3 = 236.1$$

$$n_{LN} = 787 \times 0.24 = 188.88$$

$$n_N = 787 \times 0.185 = 145.6$$

$$n_L = 787 \times 0.275 = 216.4$$

Pour terminer, on arrondit de manière à avoir 787 individus au total :

$$n_B = 236 ; n_{LN} = 189 ; n_N = 146 ; n_L = 216$$

Question 2 (9 points)

Y = Variable d'intérêt = temps passé sur Facebook par jour

- Calcul des quartiles
- Distribution empirique chez les garçons :

Y	120	150	165	170	180	200	240	260
Fréq absolues	4	4	2	1	5	1	2	1
Fréq cumulées	4	8	10	11	16	17	19	20

(ATTENTION : ORDONNER LA SÉRIE AU PRÉALABLE + CALCULER LES FRÉQUENCES CUMULÉES)

- Médiane = Q₂ : n = 20 (pair) $\rightarrow (y_{\frac{n}{2}} + y_{\frac{n}{2}+1})/2$
On fait la moyenne de la 10^{ème} et de la 11^{ème} observation : $(y_{10} + y_{11})/2 = (165 + 170)/2 = 167.5$
- Q₁ = médiane des observations qui se situent en-dessous de Q₂ : n = 10 (pair)
On fait la moyenne de la 5^{ème} et de la 6^{ème} observation : $(y_5 + y_6)/2 = (150 + 150)/2 = 150$
- Q₃ = médiane des observations qui se situent au-dessus de Q₂ : n = 10 (pair)
On fait la moyenne de la 15^{ème} et de la 16^{ème} observation : $(y_{15} + y_{16})/2 = (180 + 180)/2 = 180$

- Distribution empirique chez les filles :

Y	30	45	60	75	90	120	150	200	240	300
Fréq absolues	3	1	3	1	3	4	1	1	2	1
Fréq cumulées	3	4	7	8	11	15	16	17	19	20

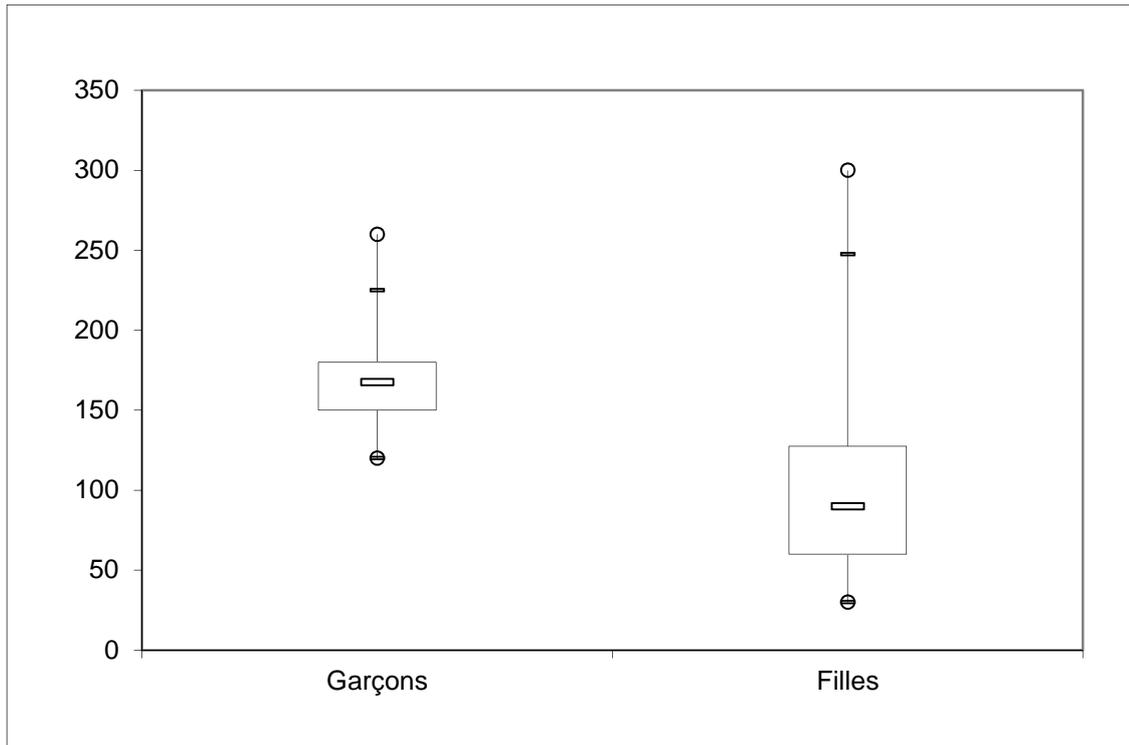
- Médiane = Q_2 : $n = 20$ (pair) $\rightarrow (y_{\frac{n}{2}} + y_{\frac{n}{2}+1})/2$
On fait la moyenne de la 10^{ème} et de la 11^{ème} observation : $(y_{10} + y_{11})/2 = (90 + 90)/2 = 90$
- Q_1 = médiane des observations qui se situent en-dessous de Q_2 : $n = 10$ (pair)
On fait la moyenne de la 5^{ème} et de la 6^{ème} observation : $(y_5 + y_6)/2 = (60 + 60)/2 = 60$
- Q_3 = médiane des observations qui se situent au-dessus de Q_2 : $n = 10$ (pair)
On fait la moyenne de la 15^{ème} et de la 16^{ème} observation : $(y_{15} + y_{16})/2 = (120 + 150)/2 = 135$
- Construction d'un graphique permettant de visualiser le lien entre les 2 variables :
 - ➔ Boîtes à moustaches du temps passé quotidiennement sur Facebook par sexe (**sur une même échelle** - axe vertical - pour pouvoir comparer les 2 distributions).
 - ➔ La boîte à moustaches utilise 5 valeurs qui résument des données :
 - la patte inférieure = la valeur minimum dans les données qui est supérieure à $Q_1 - 1,5 \times (Q_3 - Q_1)$
 - la valeur du 1^{er} quartile Q_1 (25% des effectifs - trait inférieur de la boîte),
 - la valeur du 2^{ème} quartile Q_2 (50% des effectifs - trait horizontal à l'intérieur de la boîte),
 - la valeur du 3^{ème} quartile Q_3 (75% des effectifs - trait supérieur de la boîte),
 - la patte supérieure = la valeur maximum dans les données qui est inférieure à $Q_3 + 1,5 \times (Q_3 - Q_1)$.

Ici, le calcul des trois quartiles a déjà été réalisé. Il reste à calculer les « pattes » :

- Chez les garçons :
 - Patte inférieure : valeur minimum des données (min) = 120 \rightarrow comparer cette valeur avec $Q_1 - 1,5 \times EIQ$: $150 - 1,5 \times (180 - 150) = 105$. $Min > Q_1 - 1,5 \times EIQ \rightarrow$ patte inférieure = 120.
 - Patte supérieure : valeur maximum des données (max) = 260 \rightarrow comparer cette valeur avec $Q_3 + 1,5 \times EIQ$: $180 + 1,5 \times 30 = 225$. $Max > Q_3 + 1,5 \times EIQ \rightarrow$ patte supérieure = 225.

- Chez les filles :

- Patte inférieure : valeur minimum des données (min) = 30 → comparer cette valeur avec $Q1 - 1,5 \times \text{EIQ}$: $60 - 1,5 \times (135 - 60) = -52,5$. $\text{Min} > Q1 - 1,5 \times \text{EIQ}$ → patte inférieure = 30.
- Patte supérieure : valeur maximum des données (max) = 300 → comparer cette valeur avec $Q3 + 1,5 \times \text{EIQ}$: $135 + 1,5 \times 75 = 247,5$. $\text{Max} > Q3 + 1,5 \times \text{EIQ}$ → patte supérieure = 247,5.



c. Chez les garçons :

- $\bar{y} = \frac{1}{n} \sum_{k=1}^K n_k y_k = \frac{1}{20} (4 \times 120 + 4 \times 150 + 2 \times 165 + 1 \times 170 + 5 \times 180 + 1 \times 200 + 2 \times 240 + 1 \times 260) = 171$
- $\hat{\sigma}^2 = \frac{1}{n} (\sum_{k=1}^K n_k y_k^2) - \bar{y}^2 = \frac{1}{20} (4 \times 120^2 + 4 \times 150^2 + 2 \times 165^2 + 1 \times 170^2 + 5 \times 180^2 + 1 \times 200^2 + 2 \times 240^2 + 1 \times 260^2) - 171^2 = 1546,5$
- $s^2 = \frac{n}{n-1} \hat{\sigma}^2 = \frac{20}{19} \times 1546,5 = 1627,89$

Chez les filles :

- $\bar{y} = \frac{1}{n} \sum_{k=1}^K n_k y_k = \frac{1}{20} (3 \times 30 + 1 \times 45 + 3 \times 60 + 1 \times 75 + 3 \times 90 + 4 \times 120 + 1 \times 150 + 1 \times 200 + 2 \times 240 + 1 \times 300) = 113,5$

- $\hat{\sigma}^2 = \frac{1}{n} (\sum_{k=1}^K n_k y_k^2) - \bar{y}^2 = \frac{1}{20} (3 \times 30^2 + 1 \times 45^2 + 3 \times 60^2 + 1 \times 75^2 + 3 \times 90^2 + 4 \times 120^2 + 1 \times 150^2 + 1 \times 200^2 + 2 \times 240^2 + 1 \times 300^2) - 113.5^2 = 5655.25$
- $s^2 = \frac{n}{n-1} \hat{\sigma}^2 = \frac{20}{19} \times 5655.25 = 5952.89$

d. Type des variables :

- Sexe : variable qualitative nominale car « fille » et « garçon » indiquent la catégorie à laquelle l'individu appartient sans que l'on puisse quantifier la distance entre les deux catégories ni leur donner un ordre.
- Temps passé sur Facebook : variable quantitative continue car elle prend une valeur numérique et peut en principe prendre une infinité de valeurs possibles entre deux bornes et est généralement exprimée à l'aide d'une unité de mesure (ici : minutes).

Statut des variables :

- Sexe : variable explicative
- Temps passé sur Facebook : variable réponse

Justification : le sexe est susceptible d'influencer, d'introduire une différence dans le temps passé quotidiennement sur FB et non pas l'inverse (le sexe est un « donné » qui ne peut pas être influencé). Dans ce cas, le sens de la relation est très clair.

Question 3 (4 points)

Association entre 2 variables catégorielles (chapitre 1 slides 44 à 64)

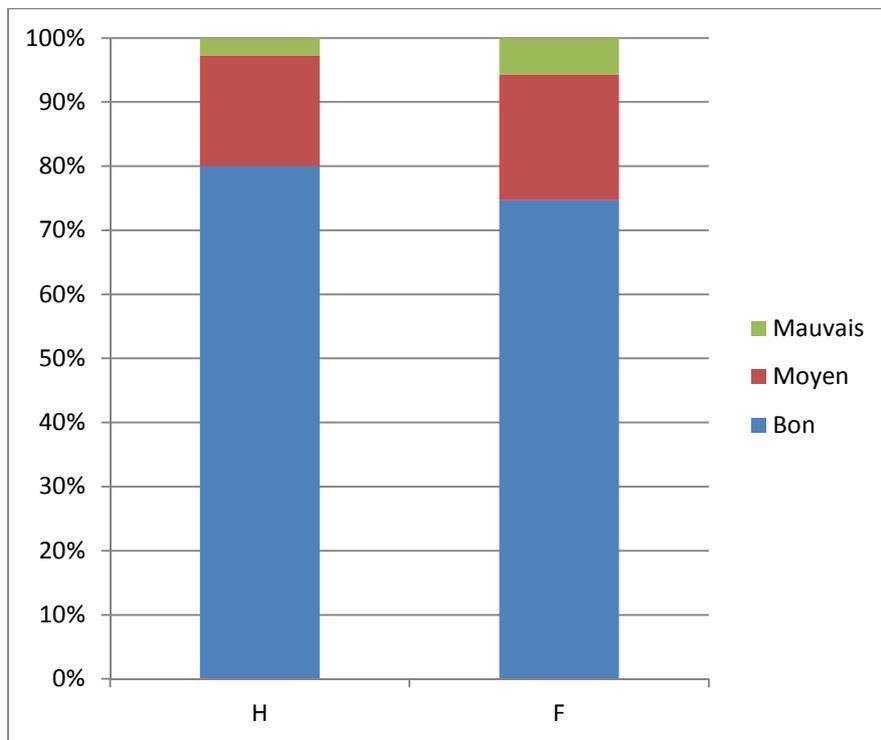
- 1^{ère} étape : distinguer la variable explicative et la variable réponse → Genre = variable explicative ; état de santé autoévalué = variable réponse (pour les mêmes raisons que celles évoquées *supra*).
- 2^{ème} étape : construire la table de contingence en plaçant la variable explicative en lignes et la variable réponse en colonnes.

	État de santé autoévalué			
Genre	Bon	Moyen	Mauvais	TOTAL
Hommes	699	151	24	874
Femmes	675	177	52	904
TOTAL	1374	328	76	1778

- 3^{ème} étape : calcul des pourcentages (fréquences relatives de la variable réponse pour chaque modalité de la variable explicative)

Genre	État de santé autoévalué			TOTAL
	Bon	Moyen	Mauvais	
H	$(699/874) \times 100 = 80\%$	$(151/874) \times 100 = 17.3\%$	$(24/874) \times 100 = 2.7\%$	100%
F	$(675/904) \times 100 = 74.7\%$	$(177/904) \times 100 = 19.6\%$	$(52/904) \times 100 = 5.7\%$	100%

- 4^{ème} étape : représentation graphique
 - En abscisse : les différentes catégories de la variable explicative avec rappel des effectifs pour chacune.
 - En ordonnée : les fréquences relatives cumulées (de 0 à 100%) pour les différentes catégories de la variable réponse.



Question 4 (4 points)

$X =$ Vitesse des véhicules (en km/h) ; $X \sim N(\mu = 112; \sigma^2 = 4.9^2)$; $Z = \frac{X - \mu}{\sigma} \sim N(0,1)$

$$\begin{aligned}
 \text{a. } P(X > 120) &= P\left(Z > \frac{120 - 112}{4.9}\right) \\
 &= P(Z > 1.63) \\
 &= 1 - P(Z \leq 1.63) \rightarrow \text{Dans la table } P(Z \leq 1.63) = 0.9484 \\
 &= 1 - 0.9484 = 0.0516
 \end{aligned}$$

→ 5,16% des véhicules dont la vitesse est mesurée par un radar automatique ne respectent pas la limitation des 120km/h.

b. Il faut ajouter/soustraire une certaine valeur (v) à la moyenne μ pour trouver les bornes ($-t$; t) de l'intervalle au sein duquel on trouve 70% des données :

$$P(\mu - v \leq X \leq \mu + v) = 0.7 \Leftrightarrow P\left(\frac{(\mu - v) - \mu}{\sigma} \leq Z \leq \frac{(\mu + v) - \mu}{\sigma}\right) = 0.7$$

$$\Leftrightarrow P\left(\frac{-v}{\sigma} \leq Z \leq \frac{v}{\sigma}\right) = 0.7$$

$$\Leftrightarrow P\left(Z \leq \frac{v}{4.9}\right) - P\left(Z \leq \frac{-v}{4.9}\right) = 0.7$$

$$\Leftrightarrow P\left(Z \leq \frac{v}{4.9}\right) - \left(1 - P\left(Z \leq \frac{v}{4.9}\right)\right) = 0.7$$

$$\Leftrightarrow 2P\left(Z \leq \frac{v}{4.9}\right) - 1 = 0.7$$

$$\Leftrightarrow P\left(Z \leq \frac{v}{4.9}\right) = \frac{0.7+1}{2} = 0.85 \rightarrow \text{Dans la table } P\left(Z \leq \frac{v}{4.9}\right) = 0.85 \Leftrightarrow \frac{v}{4.9} \approx 1.04$$

$$\rightarrow v = 1.04 \times 4.9 \approx 5.1$$

→ 70% des vitesses (centrées sur la moyenne) mesurées par le radar sont comprises entre : $[\mu - 5.1 ; \mu + 5.1] = [106.9 ; 117.1]$ km/h.