



PASS/LAS

Correction

UE5 – ED Tut' rentrée 1

23 / 24 / 25 Août 2021

Fait par les bbs D1 de l'UE gangstat

Relu par ces mêmes babies

QCM 1 : AB

- A. VRAI. La population est un ensemble très grand, parfois même innombrable donc les **études exhaustives y sont impossibles**.
- B. VRAI.
- C. FAUX. Elles **ne sont pas mesurables** car ce sont des **variables QUALITATIVES**. En revanche, elles peuvent être ordonnées et classées.
- D. FAUX. Le **mode** est une **mesure de la tendance centrale** qui ne peut se déterminer **QUE** pour les **variables quantitatives**. De plus, les variables qualitatives ne se mesurent pas.
- E. FAUX. Le groupe sanguin est **une variable qualitative pure**. En effet, on ne peut ni classer ni ordonner les groupes sanguins comme on pourrait le faire pour l'intensité d'une douleur par exemple.

QCM 2 : AE

En considérant X comme la variable "nombre de vertèbres" et x_i la valeur de X mesurée pour chaque girafon. Ici, on a :

- $N = 12$ girafons
- Valeurs prises par X : 2, 2, 2, 2, 2, 3, 7, 12, 12, 13, 13, 14


- A. VRAI. La **moyenne** est égale à la somme des valeurs prises par X multipliées par leur effectifs respectifs (n_i) divisée par l'effectif total (N) soit :

$$\bar{X} = \frac{\sum(x_i \times n_i)}{N} = \frac{2 \times 5 + 3 \times 1 + 7 \times 1 + 12 \times 2 + 13 \times 2 + 14 \times 1}{12} = \frac{10 + 3 + 7 + 24 + 26 + 14}{12} = \frac{84}{12} = 7 \text{ vertèbres.}$$

- B. FAUX. La **médiane** est la **valeur de X qui divise l'échantillon en 2 parties égales**, c'est-à-dire autant de girafons qui ont un nombre de vertèbres au-dessus de cette médiane (50%) que de girafons qui ont un nombre de vertèbres en-dessous (50%).

⚠ Ici nous sommes devant une série paire. La médiane se situe donc entre la $n^{\text{ième}}$ et $(n + 1)^{\text{ième}}$ avec $n = \frac{N}{2}$.

Donc :



$$\text{Médiane} = \frac{n^{\text{ième}} + (n+1)^{\text{ième}}}{2} = \frac{3 + 7}{2} = 5 \text{ vertèbres.}$$

- C. FAUX. Le **mode** est la **valeur de X la plus souvent rencontrée** dans l'échantillon. Ici, le mode vaut **2 vertèbres** car cette valeur de X est répétée le plus de fois (5 fois). Tandis que la **différence entre les valeurs extrêmes de l'échantillon** correspond à l'**étendue** et vaut **12**.
- D. FAUX. La **mesure de la dispersion** est permise par la variance, l'écart-type et l'**étendue**. Alors que la moyenne, le mode et la médiane permettent de **mesurer la tendance centrale**.

E. VRAI. L'**écart-type** $\sigma(X)$ est égale à la racine carré de la variance $s^2(X)$. Donc : $\sigma(X) = \sqrt{s^2(X)}$

$$\begin{aligned}\sqrt{s^2(X)} &= \sqrt{\frac{\sum n_i (x_i - \bar{X})^2}{N}} = \sqrt{\frac{5 \times (2-7)^2 + 1 \times (3-7)^2 + 1 \times (7-7)^2 + 2 \times (12-7)^2 + 2 \times (13-7)^2 + 1 \times (14-7)^2}{12}} \\ &= \sqrt{\frac{5 \times (-5)^2 + (-4)^2 + 2 \times (5)^2 + 2 \times (6)^2 + (7)^2}{12}} = \sqrt{\frac{5 \times 25 + 16 + 2 \times 25 + 2 \times 36 + 49}{12}} \\ &= \sqrt{\frac{312}{12}} = \sqrt{26} \approx \sqrt{25} = \mathbf{5 \text{ vertèbres}}\end{aligned}$$

QCM 3 : ABD

A. VRAI. Le **mode** est la valeur la plus souvent rencontrée, ici le mode est donc bien égal à **7**.

Pour la suite de l'exercice on va effectuer la méthode du changement de variable grâce au tableau suivant :
Nous utilisons cette méthode car elle facilite les calculs.

N_i	X_i	$Y_i = X_i - \text{mode}$	Y_i^2	$Y_i N_i$	$Y_i^2 N_i$
1	10	$10-7 = 3$	$3^2 = 9$	$3 \times 1 = 3$	$9 \times 1 = 9$
2	9	$9-7 = 2$	$2^2 = 4$	$2 \times 2 = 4$	$4 \times 2 = 8$
3	7	$7-7 = 0$	$0^2 = 0$	$0 \times 3 = 0$	$0 \times 3 = 0$
1	4	$4-7 = -3$	$(-3)^2 = 9$	$-3 \times 1 = -3$	$9 \times 1 = 9$
2	2	$2-7 = -5$	$(-5)^2 = 25$	$-5 \times 2 = -10$	$25 \times 2 = 50$
1	0	$0-7 = -7$	$(-7)^2 = 49$	$-7 \times 1 = -7$	$49 \times 1 = 49$
N = 10				T1 = -13	T2 = 125

B. VRAI. La moyenne de Y_i : $m(Y_i) = \frac{T1}{N} = \frac{-13}{10} = \mathbf{-1,3}$

⚠ **Attention à ne pas oublier de repasser ensuite à X_i en ajoutant le mode** ⚠

La **moyenne** de X_i : $m(X_i) = m(Y_i) + \text{mode} = -1,3 + 7 = \mathbf{5,7}$

Il est également possible de calculer la moyenne sans passer par le tableau. Pour cela, nous utilisons la formule suivante :

$$m(X_i) = \frac{\sum (x_i \times n_i)}{N} = \frac{1 \times 10 + 2 \times 9 + 3 \times 7 + 1 \times 4 + 2 \times 2 + 1 \times 0}{10} = \frac{10 + 18 + 21 + 4 + 4 + 0}{10} = 5,7$$

C. FAUX. $Var(Y_i) = \frac{T2 - \frac{T1^2}{N}}{N} = \frac{125 - \frac{(-13)^2}{10}}{10} = \frac{125 - 16,9}{10} = \frac{108,1}{10} = \mathbf{10,81}$

Dans le cas d'un changement de variable de la forme $Y_i = X_i - \text{mode}$, la **variance de Y est la même que celle de X**. Donc $Var(X_i) = \mathbf{10,81 \text{ gaufres}^2}$

D. VRAI. cf. correction item C.

E. FAUX. L'**écart type** est égal à la racine carré de la variance donc $\sigma(X_i) = \sqrt{\sigma^2(X_i)} = \sqrt{10,81} \approx \sqrt{10} = \mathbf{3,16}$
L'écart type est de **3,16 gaufres**.

→ Remarque : Ici, pas besoin de connaître la valeur de $\sqrt{10}$, on sait que l'écart-type correspond à la racine de la variance, ils ne peuvent donc pas avoir la même valeur.

QCM 4 : AC

- A. VRAI. Ici, on souhaite déterminer le **paramètre dans la population** à partir de celui d'un échantillon. On réalise ainsi un **intervalle de confiance**.
- B. FAUX. L'**intervalle de pari** détermine le **paramètre dans l'échantillon** à partir de celui de la Population.
- C. VRAI. Nous sommes ici dans un **intervalle de confiance** avec une **variable qualitative** (proportion de personnes qui disent "chocolatine" = fréquence). Ainsi, les conditions à vérifier sont **NP et NQ ≥ 5**.
 → Seulement, on ne connaît pas encore ni P ni Q, on doit donc vérifier les conditions **À POSTÉRIORI**.

À la fin on trouve : $P \in [0,12 ; 0,28]$ (cf. correction QCM 5) et on sait que $N = 100$ et que $Q = 1 - P$

- ❖ Pour $P = 0,12$
 - $NP = 100 \times 0,12 = 12$
 - $NQ = 100 \times 0,88 = 88$
- ❖ Pour $P = 0,28$
 - $NP = 100 \times 0,28 = 28$
 - $NQ = 100 \times 0,72 = 72$

NP et NQ ≥ 5 sur tout l'intervalle. Les conditions sont respectées.

- D. FAUX. cf. correction item C.
- E. FAUX. Nous sommes ici dans un **intervalle de confiance** avec une **variable qualitative** (proportion de personnes qui disent "chocolatine" = fréquence). Ainsi, le paramètre calculé appartient à l'intervalle :

$$f \pm U_{\alpha} \times \sqrt{\frac{f \times (1-f)}{N}}$$

QCM 5 : CE

Dans tous les QCMs de "calculs" en UE5, il faut apprendre à résumer par étapes :

- 1) Trouver la bonne variable et son type
 → Ici, variable qualitative : "proportion de gens qui disent chocolatine"
- 2) Comprendre ce que l'on cherche à partir de ce que l'on a
 → On cherche la fréquence dans la population, en connaissant la fréquence d'un échantillon ⇒ **intervalle de confiance** (A et D faux d'office)
- 3) Vérifier les conditions d'applications → NP et NQ ≥ 5 (⚠ Recherchées **À POSTÉRIORI** ⚠)
- 4) Trouver le U_{α} correspondant au α → $\alpha = 0,05 \Rightarrow U_{\alpha} = 1,96 (\approx 2)$

5) Faire le calcul de l'intervalle :

$$P \in \left[f \pm U_{\alpha} \times \sqrt{\frac{(1-f)}{N}} \right] = \left[0,2 \pm 1,96 \times \sqrt{\frac{0,2 \times (1-0,2)}{100}} \right]$$

$$P \in \left[0,2 \pm 2 \times \sqrt{\frac{(0,2 \times 0,8)}{100}} \right]$$

$$P \in \left[0,2 \pm 2 \times \sqrt{\frac{0,16}{100}} \right]$$

$$P \in [0,2 \pm 2 \times 0,04] = [0,12 ; 0,28]$$

Ainsi, la proportion dans la population de gens qui disent chocolatine est d'environ **20 % ± 8%**.

- A. FAUX. (On cherche à encadrer le paramètre "P" et non "m")
- B. FAUX. cf. correction ci-dessus.
- C. VRAI. cf. correction ci-dessus.

- D. FAUX. ⚠ On ne pourra jamais avoir comme résultat une seule valeur, on établit toujours un **intervalle**.
 E. VRAI. En effet, plus le **risque α est grand**, plus l'**intervalle** qui contient la variable **est petit**.

Si on raisonne avec la formule : $P \in \left[f \pm U_{\alpha} \times \sqrt{\frac{(1-f)}{N}} \right]$. Quand α **augmente**, U_{α} **diminue** et l'**intervalle devient plus précis**.

QCM 6 : BE

- A. FAUX. On connaît ici la valeur de la **fréquence dans la population P** et on réalise **des échantillons dont on cherche la valeur de la fréquence** pour chacun : c'est le principe de la **fluctuation d'échantillonnage dans le cadre d'un intervalle de Pari**. En d'autres termes, c'est le paramètre de l'échantillon qu'on cherche à encadrer dans l'intervalle et non celui de la population.

*Moyen mnémo : Pour un intervalle de **Pari**, on **Part** de la **Population**.*

- B. VRAI. Nous connaissons les différents paramètres nous permettant d'appliquer la formule suivante pour réaliser notre intervalle de pari :

$$f \in \left[P \pm U_{\alpha} \times \sqrt{\frac{PQ}{N}} \right]$$

⚠ Avant de commencer nos calculs, nous devons **impérativement** vérifier que les **conditions** sont bien respectées : **NP ≥ 5 et NQ ≥ 5**.

On a donc :

- NP = 64 × 0,2 = 12,8
- NQ = 64 × 0,8 = 51,2 > 5

Nous pouvons ainsi passer au calcul.

$$f \in \left[P \pm U_{\alpha} \times \sqrt{\frac{PQ}{N}} \right] \text{ Avec } U_{\alpha} \approx 2 \text{ pour un risque de 5\%}$$

$$f \in \left[0,2 \pm 2 \times \sqrt{\frac{0,2 \times 0,8}{64}} \right]$$

$$f \in \left[0,2 \pm 2 \times \sqrt{\frac{0,16}{64}} \right]$$

$$f \in \left[0,2 \pm 2 \times \frac{\sqrt{0,16}}{\sqrt{64}} \right]$$

$$f \in \left[0,2 \pm 2 \times \frac{0,4}{8} \right]$$

$$f \in \left[0,2 \pm \frac{0,8}{8} \right]$$

$$f \in [0,2 \pm 0,1]$$

$$f \in [10\% ; 30\%]$$

- C. FAUX. Le risque α n'étant pas le même, l'intervalle est forcément différent : **plus le risque α de se tromper est faible, plus l'intervalle sera grand et peu précis**.
 D. FAUX. Comme pour l'item B, nous avons tous les paramètres pour appliquer la formule, il ne nous reste plus qu'à **vérifier les conditions** : NP ≥ 5 et NQ ≥ 5.
 On a donc NP = 16 × 0,2 = **3,2 < 5**. **Les conditions ne sont pas respectées, l'intervalle proposé est rejeté** : il faut un plus grand échantillon pour une meilleure représentativité.
 E. VRAI. En effet, on peut remarquer mathématiquement que l'échantillon N se trouve au dénominateur de la formule : **plus N croît, plus l'écart se réduit et l'intervalle devient précis**.

QCM 7 : BD

- A. FAUX. Cette étude s'intéresse à une **variable quantitative** : le nombre de lapins adoptés.
 B. VRAI. Ici, on part de la **Population** pour encadrer le paramètre dans un échantillon : il s'agit donc d'un **intervalle de Pari**.


- C. FAUX. **ATTENTION** : il faut utiliser l'**écart type** et non la variance. L'écart type est la **racine carrée de la variance** $\Rightarrow \sigma = \sqrt{Var} = \sqrt{9} = 3$.
- D. VRAI. On réalise ici une fluctuation d'échantillonnage. On cherche à encadrer la moyenne m de l'échantillon dans un intervalle de pari.
- On utilise la formule : $m \in \left[\mu \pm U_{\alpha} \frac{\sigma}{\sqrt{N}} \right] = \left[3 \pm 2 \frac{3}{\sqrt{36}} \right]$ (pour $\alpha = 5\% \rightarrow U_{\alpha} \approx 2$)
- $$m \in \left[3 \pm \frac{2 \times 3}{6} \right]$$
- $$m \in [3 \pm 1]$$
- $$m \in [2 ; 4]$$
- E. FAUX. Les **conditions ne sont pas respectées** car la moitié du groupe est égale à **18**.
 \rightarrow **N doit être ≥ 30** pour effectuer un intervalle de pari sur une variable quantitative.

QCM 8 : B

- A. FAUX. C'est l'inverse, H_0 serait plutôt "Il n'y a **pas** de différence significative entre l'échantillon et la population".
- B. VRAI. Autre formulation possible.
- C. FAUX. Pour des variables qui sont **quantitatives**, comme c'est le cas ici (car nous pouvons mesurer la variable qui sont « les dépenses »), la condition d'utilisation du test de la loi Normale est **$N \geq 30$** .
- D. FAUX. Pour des variables qui sont **qualitatives**, la condition d'utilisation du test de la loi Normale est **NP et $NQ \geq 5$** .
- E. FAUX. Plus la région critique est grande, plus notre paramètre a de chance de se trouver dans cette région critique donc plus on a de chance de rejeter H_0 (et moins on a de chance d'accepter H_0).

QCM 9 : ACD

- A. VRAI. Pour $\alpha = 0,05$, $U_{\alpha} = 1,96$ (à connaître par <3). Pour le seuil $\alpha = 0,05$, la région critique est la région hachurée :



- B. FAUX. En présence d'une **variable quantitative**, on calcule le paramètre U avec la formule suivante :

$$U = \frac{m - \mu}{\frac{\sigma}{\sqrt{N}}} \rightarrow (\text{! aux détails})$$

- C. VRAI. Comme les conditions sont respectées (cf. QCM 8), nous pouvons calculer le paramètre :

$$U = \frac{m - \mu}{\frac{\sigma}{\sqrt{N}}} = \frac{50 - 25}{\frac{10}{\sqrt{36}}} = \frac{25}{\frac{10}{6}} = \frac{25}{\frac{5}{3}} = \frac{25 \times 3}{5} = \frac{5 \times 5 \times 3}{5} = 5 \times 3 = \mathbf{15}$$

- D. VRAI. **$U \in RC$** , on **rejette H_0** au risque **α de 1^{ère} espèce** : l'échantillon n'est pas représentatif de la population, il existe une différence significative entre m et μ .
- E. FAUX. cf. correction item D.

QCM 10 : AC

- A. VRAI. **Remarque** : L'hypothèse H_1 serait l'inverse « Il y a une différence significative entre les deux fréquences ».
- B. FAUX. Les conditions à vérifier pour le test basé sur la loi Normale avec des **variables qualitatives** sont **NP ≥ 5 et $NQ \geq 5$** .

Les conditions sont donc vérifiées puisqu'on a :

- NP = $70 \times 0,1 = 7$
- NQ = $70 \times 0,9 = 63$

C. VRAI. Le paramètre U pour le test de la loi normale avec des valeurs qualitatives se calcule avec la formule

s suivante :
$$U = \frac{f - P}{\sqrt{\frac{PQ}{N}}}$$

On a donc :
$$U = \frac{0,15 - 0,1}{\sqrt{\frac{0,1 \times 0,9}{70}}} = \frac{0,05}{\sqrt{\frac{0,09}{70}}} \approx \frac{0,05}{0,03} \approx \frac{5}{3} \approx 1,67$$

D. FAUX. Pour un risque $\alpha \leq 5\%$, on a $U_{\alpha} = 1,96$ (voir TER). Ici, $U \approx 1,67$ et **n'appartient donc pas à la RC** : on **accepte H_0** au **risque β de seconde espèce**.

E. FAUX. Peu importe le résultat de notre test, on ne peut **jamais établir de causalité** dans les conclusions d'un test statistique de la loi Normale. On ne peut parler **QUE** de **lien statistique**.