

Problème 1 [7+7+4+7+7 points]

Les données en annexe portent sur un échantillon aléatoire simple de **34** hôpitaux d'une population de **700** hôpitaux. Pour chaque hôpital de l'échantillon, on note les valeurs des variables suivantes:

- lits: le nombre de lits dans l'hôpital
- chambres: le nombre de chambres
- univ: précise si l'hôpital est un hôpital universitaire ou non

1-a) Déterminer un intervalle de confiance à 95 % pour le *nombre moyen de lits par hôpital*

$$n = 34, N = 700, \bar{y} = \frac{14433}{34} = 424,50. \hat{\sigma}_{\bar{y}} = \sqrt{1 - \frac{34}{700}} \frac{\sqrt{159951}}{\sqrt{34}} = 66,9025.$$

Intervalle de confiance : $424,5 - 2(66,9025) \leq \mu_y \leq 424,5 + 2(66,9025)$

$290,695 \leq \mu_y \leq 558,3050$

Nombre moyen de lits par hôpital : 424,50 ; Écart-type de l'estimateur : 66,9025

Intervalle de confiance : 290,605 ≤ μ_y ≤ 558,3050

1-b) Déterminer un intervalle de confiance à 95 % pour le *nombre moyen de lits par chambre*.

$$\hat{R} = \frac{\bar{y}}{\bar{x}} = \frac{14433}{3971} = 3,6346$$

$$\hat{\sigma}_{\hat{R}} = \frac{\sqrt{1 - n/N}}{\bar{x}\sqrt{n}} \sqrt{s_y^2 + \hat{R}^2 s_x^2 - 2\hat{R}s_{xy}} = \frac{\sqrt{1 - 34/700}}{(3971/34)\sqrt{34}} \sqrt{159951 + \hat{R}^2(15713) - 2\hat{R}(49968)} = 0,0953$$

Intervalle de confiance : $3,6346 - 2(0,0953) \leq R \leq 3,6346 + 2(0,0953)$

Nombre moyen de lits par chambre : 3,6346 ; écart-type de l'estimateur 0,0953

Intervalle de confiance : 3,444 ≤ R ≤ 3,825

1-c) Sachant qu'il y a en tout **86 200** chambres dans les hôpitaux de la population, estimer *par le quotient* le nombre total de lits (*estimation ponctuelle seulement*).

$$T_{y_q} = \frac{\bar{y}}{\bar{x}} \tau_x = \frac{14433}{3971} 86200 = 313303$$

Nombre total de lits : 313 303

1-d) Déterminer un intervalle de confiance pour *le nombre total de lits dans les hôpitaux non universitaires ayant moins de 10 chambres.*

Nous définissons la variable y' dont les valeurs sont toutes nulles sauf les quatre qui correspondent à des hôpitaux non universitaires ayant moins de 10 chambres. Ces valeurs non nulles sont 31 ; 40 ; 35; et 63.

$$\text{On a donc } \bar{y}' = \frac{31+40+35+63}{34} = \frac{169}{34}.$$

$$\hat{T}_d = N\bar{y}' = 700 \frac{169}{34} = 3479;$$

$$s'^2 = \frac{(31-169/34)^2 + (40-169/34)^2 + (35-169/34)^2 + (63-169/34)^2 + (0-169/34)^2 \times 30}{34-1}$$

$$= \frac{6914,9706}{33} = 209,5446.$$

$$\hat{\sigma}_{\hat{T}_d} = N \sqrt{1 - \frac{n}{N}} \frac{s'}{\sqrt{n}} = 700 \sqrt{1 - \frac{34}{700}} \frac{\sqrt{209,5446}}{\sqrt{34}} = 1695$$

Intervalle de confiance : $3479-2(1695) \leq \tau_d \leq 3479+2(1695)$

$$89 \leq \tau_d \leq 6869$$

Estimation ponctuelle : 3479

Intervalle de confiance : 89 ≤ τ_d ≤ 6869

1-e) Vous avez l'intention de refaire ce sondage afin d'estimer (par la moyenne) *le nombre moyen de lits par hôpital.* Vous voulez que votre marge d'erreur relative soit de **10 %**. Estimer *la taille de l'échantillon* (aléatoire simple) que vous devrez tirer.

$$n_o = \frac{(2S)^2}{(0,1\mu)^2}. \text{ Utilisant les données de l'échantillon, on obtient}$$

$$n_o = \frac{4(159951)}{[(0,1)(14433/34)]^2} = 355,051672$$

$$n = \frac{355,051672}{1 + \frac{355,051672}{700}} = 235,5677$$

n : 236

Problème 3 [5+2+5 points]

Une compagnie qui fait souvent des sondages d’opinion s’interroge sur l’utilité d’envoyer des cadeaux pour encourager les gens à répondre. On décide d’envoyer des questionnaires à **300** personnes : **100** personnes ne reçoivent aucun cadeau; à **100** autres, on promet un abonnement de six mois à un magazine; et à **100** autres enfin on promet un portefeuille en cuir de crocodile. On note alors le nombre de répondants dans chaque groupe. Voici les résultats

<i>A répondu</i>	<i>Cadeau promis</i>			<i>Total</i>
	<i>Aucun</i>	<i>Abonnement de 6 mois</i>	<i>Portefeuille en cuir de crocodile</i>	
<i>Oui</i>	30	40	50	120
<i>Non</i>	70	60	50	180
<i>Total</i>	100	100	100	300

3-a) Énoncer l’hypothèse nulle dans le langage du contexte

Il est inutile d’envoyer des cadeaux ; ou
 La probabilité de réponse est la même, quelle que soit la promesse; ou
 Le fait de répondre ou pas est indépendant de l’offre faite.

3-b) Déterminer les effectifs théoriques :

<i>A répondu</i>	<i>Cadeau promis</i>			<i>Total</i>
	<i>Aucun</i>	<i>Abonnement de 6 mois</i>	<i>Portefeuille en cuir de crocodile</i>	
<i>Oui</i>	40	40	40	120
<i>Non</i>	60	60	60	180
	100	100	100	300

3-c) Compléter le test et exprimer votre conclusion dans le langage du contexte

$$\chi^2 = \frac{(30 - 40)^2}{40} + \frac{(40 - 40)^2}{40} + \frac{(50 - 40)^2}{40} + \frac{(70 - 60)^2}{60} + \frac{(60 - 60)^2}{60} + \frac{(50 - 60)^2}{60}$$

$$= \frac{100}{40} + 0 + \frac{100}{40} + \frac{100}{60} + 0 + \frac{100}{60} = 8,33$$

Cette valeur étant supérieure 5,9915, on rejette l’hypothèse H_0 et on conclut que la promesse faite (ou l’absence de promesse) influence la volonté de répondre.

Problème 4 [10 points]

Afin de déterminer si dans un sondage téléphonique on peut faire augmenter le taux de réponse en prenant un ton doux, un enquêteur fait 120 appels sur un ton doux et 120 autres sur un ton ferme. Il compte ensuite le nombre de personnes qui acceptent de répondre dans chaque groupe. Enfin, il effectue un test du khi-deux.

4-a) Vrai ou faux? Si la valeur calculée de khi-deux est 15 ...

(i)	on conclut que les différences entre les deux taux de réponse sont entièrement dus au hasard	vrai: <input type="checkbox"/> faux: <input checked="" type="checkbox"/>
(ii)	on peut conclure avec 95% de confiance que le ton n'a pas d'effet sur le taux de réponse	vrai: <input type="checkbox"/> faux: <input checked="" type="checkbox"/>
(iii)	on conclut que la différence entre les deux groupes est trop importante pour être attribuée au hasard	vrai: <input checked="" type="checkbox"/> faux: <input type="checkbox"/>
(iv)	il y a 5 % de chance que l'hypothèse soit fausse	vrai: <input type="checkbox"/> faux: <input checked="" type="checkbox"/>
(v)	on peut affirmer avec 95 % de confiance que le ton affecte la probabilité de réponse	vrai: <input checked="" type="checkbox"/> faux: <input type="checkbox"/>

4-b) Vrai ou faux? Si la valeur calculée de khi-deux est 1,4 ...

(i)	on peut conclure avec 95% de confiance que le ton n'a pas d'effet sur le taux de réponse	vrai: <input type="checkbox"/> faux: <input checked="" type="checkbox"/>
(ii)	on conclut que la différence entre les deux groupes est trop importante pour être attribuée au hasard	vrai: <input type="checkbox"/> faux: <input checked="" type="checkbox"/>
(iii)	il y a 5 % de chance que l'hypothèse soit fausse	vrai: <input type="checkbox"/> faux: <input checked="" type="checkbox"/>
(iv)	on ne peut pas conclure que le ton a un effet sur le taux de réponse	vrai: <input checked="" type="checkbox"/> faux: <input type="checkbox"/>
(v)	on peut affirmer avec 5 % de confiance que le ton a un effet	vrai: <input type="checkbox"/> faux: <input checked="" type="checkbox"/>

Problème 5 [10 points]

On tire un échantillon aléatoire simple de n familles dans un quartier habité par N familles. On observe pour chaque famille la valeur des variables suivantes:

- Nombre d'adultes dans la famille
- Nombre de personnes dans la famille
- Revenu annuel de la famille

et on note aussi si la famille est *monoparentale ou pas*.

Dans chacune des situations suivantes, dire précisément quel paramètre il s'agit d'estimer. Faire votre choix parmi les suivants (le numéro 0 ci-dessous illustre le type de réponse attendu):

- A. La moyenne μ_y d'une variable Y . Identifier Y .
- B. Le total τ_y d'une variable Y . Identifier Y
- C. La moyenne μ_d d'un domaine. Identifier la variable et le domaine.
- D. Le total τ_d d'une variable Y dans un domaine \mathcal{D} . Identifier Y et \mathcal{D} .
- E. La proportion p d'unités appartenant à une certaine classe. Identifier la classe.
- F. Le nombre N_c d'unités appartenant à une certaine classe. Identifier la classe.
- G. Le quotient de deux moyennes $R = \frac{\mu_y}{\mu_x}$. Identifier Y et X .

	Réponse (A, B, ..., ou F)
0. Le nombre moyen de personnes par famille <i>Il s'agit d'une moyenne μ_y où Y est le nombre de personnes dans la famille</i>	A
1. Le nombre moyen d'adultes par famille <i>μ_y, où Y est le nombre d'adultes dans la famille</i>	A
2. La proportion de familles monoparentales <i>p, la proportion de familles dans la classe des familles monoparentales</i>	E
3. La proportion d'adultes dans le quartier <i>$R = \bar{y} / \bar{x}$ où Y est le nombre d'adultes et X le nombre de personnes dans la famille</i>	G
4. Le nombre de personnes dans le quartier <i>τ_y, où Y est le nombre de personnes dans la familles</i>	B
5. Le nombre de personnes dans le quartier appartenant à des familles monoparentales <i>τ_d où Y, le nombre de personnes dans la famille et \mathcal{D} est le domaine des familles monoparentales</i>	D
6. Le nombre moyen d'adultes dans les familles monoparentales <i>μ_d où Y est le nombre d'adultes dans la famille et \mathcal{D} est le domaine des familles monoparentales</i>	C
7. Le nombre de familles monoparentales dans le quartier <i>N_c le nombre de familles dans la classe des familles monoparentales</i>	F
8. Le revenu annuel par personne <i>$R = \bar{y} / \bar{x}$, $Y =$ revenu annuel de la famille, $X =$ nombre de familles</i>	G
9. Le revenu annuel par famille <i>μ_y, où Y est le revenu annuel de la familles</i>	A
10. Le revenu total des familles monoparentales <i>τ_d où Y est le revenu de la famille et \mathcal{D} est le domaine des familles monoparentales</i>	D

Problème 6 [8 points]

Pour chacune des descriptions suivantes, dire de quel mode d'échantillonnage il s'agit. Choisir une réponse parmi les suivantes:

- A:** aléatoire simple **B:** stratifié **C:** systématique
D: par grappes avec probabilités de sélection égales **E:** par grappes avec probabilités de sélection inégales.

	Réponse (A, B, C, D ou E)
1) Population: l'ensemble des ménages d'une petite ville. On divise la ville en 5 secteurs, puis on tire au hasard 15 maisons dans chaque secteur.	B
2) Population: l'ensemble des ménages d'une petite ville. On divise la ville en 35 secteurs; puis on tire 5 secteurs au hasard. L'échantillon comprend tous les ménages des 5 secteurs choisis.	D
3) Population: les 150 succursales d'une banque. L'échantillon est formé en tirant au hasard 25 succursales dans le centre-ville; et 32 succursales en banlieue.	B
4) Population: l'ensemble des auteurs des livres d'une bibliothèque municipale. On tire au hasard 100 <i>titres</i> dans la liste de tous les titres. L'échantillon est l'ensemble des auteurs des titres choisis.	E
5) Population: l'ensemble de toutes les factures envoyées par une compagnie à ses clients le mois dernier. On tire au hasard 50 factures. Pour chaque facture tirée, on ajoute à l'échantillon toutes les factures envoyées au même client.	E
6) Population: l'ensemble des étudiants de l'UQAM. On tire au hasard trois programmes, et on inclut dans l'échantillon tous les étudiants inscrits dans ces trois programmes	D
7) Population: l'ensemble des étudiants de l'UQAM. On dresse une liste de tous les étudiants, puis on tire successivement et sans remise 300 étudiants.	A
8) Population: l'ensemble des clients à qui on a envoyé une facture le mois dernier. On tire au hasard 200 factures. Les clients à qui ces factures ont été envoyées constituent l'échantillon.	E

Problème 7 [10 points]

Répondre par *vrai* (V) ou *faux* (F)

	Réponse (V ou F)
1) L'estimateur par le quotient peut être beaucoup plus efficace que l'estimateur par la moyenne si la corrélation entre la variable d'intérêt (Y) et la variable auxiliaire (X) est forte	V
2) L'estimateur par la différence peut être beaucoup plus efficace que l'estimateur par la moyenne si la corrélation entre la variable d'intérêt (Y) et la variable auxiliaire (X) est forte	V
3) Pour estimer une moyenne, un échantillon de 50 familles ayant en tout 250 personnes est généralement plus précis qu'un échantillon de 250 personnes tirées au hasard dans la population.	F
4) Un estimateur <i>sans biais</i> est d'autant meilleur que son écart-type est grand	F
5) L'estimateur de la moyenne par le quotient n'est pas sans biais	V
6) L'estimateur de la moyenne par la différence est sans biais	V
7) Un estimateur est dit sans biais s'il est égal au paramètre	F
8) Dans l'échantillonnage systématique, l'estimateur de la moyenne n'a pas de variance	F
9) L'estimateur par le quotient est <i>toujours</i> plus efficace que l'estimateur par la moyenne	F
10) Un échantillon tiré par grappes contient nécessairement des éléments de chaque grappe	F

Annexe

Nombre de lits et nombre de chambres dans un échantillon de 34 hôpitaux
Taille de la population : 700 hôpitaux

Lits (y)	Chambres (x)	Univ	Lits (y)	Chambres (x)	Univ	Lits (y)	Chambres (x)	Univ
823	245	OUI	216	44	NON	121	27	NON
1343	395	OUI	170	31	NON	280	60	NON
908	274	OUI	252	53	NON	188	39	NON
648	202	OUI	38	11	NON	35	6	NON
1043	321	OUI	170	30	NON	134	23	NON
1325	407	OUI	179	38	NON	63	9	NON
1123	327	OUI	31	9	NON	280	57	NON
690	205	OUI	40	9	NON	75	18	NON
519	163	OUI	295	61	NON	142	25	NON
1118	328	OUI	336	70	NON	293	59	NON
522	152	OUI	166	37	NON	152	31	NON
715	205	OUI						

Données pour l'ensemble de l'échantillon (n=34)

	Lits (y)	Chambres (x)
Sommes	$\sum y_i = 14\ 433$	$\sum x_i = 3\ 971$
Variances corrigées	$s_y^2 = 159\ 951$	$s_x^2 = 15\ 713$
Covariance s_{xy}	$s_{xy} = 49\ 968$	

Données pour les 12 hôpitaux universitaires

	Lits (y)	Chambres (x)
Sommes	$\sum y_i = 10\ 777$	$\sum x_i = 3\ 224$
Variances corrigées	$s_y^2 = 84\ 582$	$s_x^2 = 7\ 516$
Covariance s_{xy}	$s_{xy} = 25\ 123$	

Données pour les 22 hôpitaux non universitaires

	Lits (y)	Chambres (x)
Sommes	$\sum y_i = 3\ 656$	$\sum x_i = 747$
Variances corrigées	$s_y^2 = 8\ 981$	$s_x^2 = 385$
Covariance s_{xy}	$s_{xy} = 1\ 844$	

Formulaire MAT2080 Examen final

Résumé des paramètres, leur estimateur, l'écart-type de l'estimateur, et l'estimateur de l'écart-type de l'estimateur.

Paramètre	Estimateur	Écart-type de l'estimateur	Estimateur de l'écart-type de l'estimateur
Moyenne μ	\bar{y}	$\sigma_{\bar{y}} = \sqrt{1-f} \frac{S}{\sqrt{n}}$	$\hat{\sigma}_{\bar{y}} = \sqrt{1-f} \frac{s}{\sqrt{n}}$
Proportion p	$\hat{p} = \frac{X}{n}$	$\sigma_{\hat{p}} = \sqrt{\frac{N-n}{N-1}} \sqrt{\frac{p(1-p)}{n}}$	$\hat{\sigma}_{\hat{p}} = \sqrt{1-f} \sqrt{\frac{\hat{p}(1-\hat{p})}{n-1}}$
Un quotient R $= \frac{\mu_y}{\mu_x}$	$\hat{R} = \frac{\bar{y}}{\bar{x}}$	$\sigma_{\hat{R}} \approx \frac{\sqrt{1-f}}{\mu_x} \frac{\sqrt{S_y^2 + R^2 S_x^2 - 2RS_{xy}}}{\sqrt{n}}$	$\hat{\sigma}_{\hat{R}} = \frac{\sqrt{1-f}}{\bar{x}} \frac{\sqrt{s_y^2 + \hat{R}^2 s_x^2 - 2\hat{R}s_{xy}}}{\sqrt{n}}$
Moyenne μ Estimation par la différence	$\hat{\mu}_{yd} = \mu_x + (\bar{y} - \bar{x})$	$\sigma_{\hat{\mu}_{yd}} = \sqrt{1-f} \frac{\sqrt{S_y^2 + S_x^2 - 2S_{xy}}}{\sqrt{n}}$	$\hat{\sigma}_{\hat{\mu}_{yd}} = \sqrt{1-f} \frac{\sqrt{s_y^2 + s_x^2 - 2s_{xy}}}{\sqrt{n}}$
Moyenne μ Estimation par le quotient	$\hat{\mu}_{yq} = \mu_x \hat{R}$	$\sqrt{1-f} \frac{\sqrt{S_y^2 + R^2 S_x^2 - 2RS_{xy}}}{\sqrt{n}}$	$\sqrt{1-f} \frac{\sqrt{s_y^2 + \hat{R}^2 s_x^2 - 2\hat{R}s_{xy}}}{\sqrt{n}}$
Moyenne μ_d d'un domaine \mathcal{D}	\bar{y}_d : Moyenne du domaine dans l'échantillon		$\sqrt{1-\frac{n_d}{N}} \frac{s_d}{\sqrt{n_d}}$ ou $\sqrt{1-\frac{n}{N}} \frac{s_d}{\sqrt{n_d}}$ selon que N_d est connu ou pas
Total $\tau_d = N_d \mu_d$ d'un domaine (N_d connu)	$T_d = N_d \bar{y}_d$		$N_d \sqrt{1-\frac{n_d}{N}} \frac{s_d}{\sqrt{n_d}}$
Total $\tau_d = N_d \mu_d$ d'un domaine (N_d inconnu)	$\hat{T}_d = \hat{N}_d \bar{y}_d = N \bar{y}'$ où $\hat{N}_d = \frac{n_d}{n} N$		$N \sqrt{1-f} \frac{s'}{\sqrt{n}}$

$$f = \frac{n}{N}$$

Taille d'échantillon

Estimation de la moyenne La taille d'échantillon nécessaire pour que la marge d'erreur absolue

soit égale à E est $n = \frac{n_o}{1 + \frac{n_o}{N}}$ où $n_o = \left(\frac{2S}{E}\right)^2$.

La taille d'échantillon nécessaire pour que la marge d'erreur relative soit égale à R est $n = \frac{n_o}{1 + \frac{n_o}{N}}$

où $n_o = \left(\frac{2S}{R\mu}\right)^2$.

Estimation d'une proportion p Pour estimer une proportion p de telle sorte que la marge d'erreur absolue soit égale à E , la taille approximative de l'échantillon qu'il faut tirer est donnée par n

$$= \frac{n_o}{1 + \frac{n_o}{N}} \text{ où } n_o = \frac{4p(1-p)}{E^2}.$$

Pour estimer une proportion p de telle sorte que la marge d'erreur *relative* soit égale à R , la taille

approximative de l'échantillon qu'il faut tirer est donnée par $n = \frac{n_o}{1 + \frac{n_o}{N}}$ où $n_o = \frac{4(1-p)}{R^2 p}$.

Échantillonnage par strates

L'estimateur de la moyenne dans un échantillon stratifié est $\bar{y}_{st} = \sum_{h=1}^L W_h \bar{y}_h$; son écart type est

$$\sigma_{\bar{y}_{st}} = \sqrt{\sum_{h=1}^L W_h^2 \sigma_{\bar{y}_h}^2} \text{ où } \sigma_{\bar{y}_h}^2 = (1-f_h) \frac{S_h^2}{n_h} \text{ et } f_h = n_h/N_h.$$

L'allocation optimale pour l'estimation d'une moyenne dans un échantillon stratifié est donnée par

n_h proportionnels aux $W_h S_h$

Test du khi-deux

$\chi^2 = \sum \frac{(O_i - T_i)^2}{T_i},$
--

Points critiques ($\alpha = 5 \%$) d'une loi khi-deux

v	χ_v^2	v	χ_v^2	v	χ_v^2	v	χ_v^2
1	3,8415	6	12,5916	11	19,6751	16	26,2962
2	5,9915	7	14,0671	12	21,026	17	27,5871
3	7,8147	8	15,5073	13	22,362	18	28,8693
4	9,4877	9	16,919	14	23,6848	19	30,1435
5	11,0705	10	18,307	15	24,9958	20	31,4104

