

## M1 MEEF 2016-2017

### Séquence 4

#### Feuille 4. La statistique.

**Exercice 1.** On considère  $n$  points du plans  $((x_i, y_i))_{i \in \{1, \dots, n\}}$ . Pour  $(a, b)$  deux réels quelconques, on approche ce nuage de point par une droite d'équation  $y = ax + b$ . On définit la fonction  $f$  de  $\mathbb{R}^2$  dans  $\mathbb{R}$  par, pour tout  $(a, b) \in \mathbb{R}^2$ ,

$$f(a, b) := \frac{1}{n} \sum_{i=1}^n \left[ (y_i - (ax_i + b))^2 \right].$$

Considérons  $M$  la variable aléatoire à valeurs dans  $\mathbb{R}^2$  qui charge uniformément les points  $(x_i, y_i)$

$$M \sim \frac{1}{n} \sum_{i=1}^n \delta_{(x_i, y_i)}.$$

On définit alors  $X$  comme étant l'abscisse de  $M$  et  $Y$  comme étant l'ordonnée de  $M$ . On a alors  $(X, Y) = M$  et dans cette construction on a pour tout  $i \neq j$ ,  $\mathbb{P}(X = x_i, Y = y_j) = 0$ . De plus,

$$X \sim \frac{1}{n} \sum_{i=1}^n \delta_{x_i} \quad \text{et} \quad Y \sim \frac{1}{n} \sum_{i=1}^n \delta_{y_i}.$$

1. Que représente  $nf(a, b)$  ?
2. Ecrire  $f(a, b)$  en fonction de  $\mathbb{E}(X)$ ,  $\mathbb{E}(Y)$ ,  $\mathbb{E}(X^2)$ ,  $\mathbb{E}(Y^2)$  et  $\mathbb{E}(XY)$ .
3. Justifier que  $f$  est différentiable, calculer ses dérivées partielles, exprimer sa différentielle ainsi que son gradient.
4. Trouver tous les points critiques de  $f$ .
5. La fonction  $f$  admet-elle un maximum global ? Justifier.
6. Montrer que l'on peut écrire  $f$  de la façon suivante :

$$f(a, b) = (b + a\mathbb{E}(X) - \mathbb{E}(Y))^2 + \text{Var}(X) \left( a - \frac{\text{Cov}(X, Y)}{\text{Var}(X)} \right)^2 + \text{Var}(Y) - \frac{\text{Cov}(X, Y)^2}{\text{Var}(X)}.$$

7. En déduire la nature du point critique de la question 4 que l'on notera  $(a_0, b_0)$ . Cet extremum est-il global ? A quoi correspond graphiquement la droite  $y = a_0x + b_0$  ?
8. Calculer  $f(a_0, b_0)$  et exprimer cette quantité en fonction du coefficient de corrélation  $r$  et de  $\text{Var}(Y)$ . En déduire pourquoi on demande que  $r$  soit proche de 1 en valeur absolue pour une bonne approximation.

**Exercice 2.** Le tableau suivant représente la distribution de la taille des coquilles d'individus adultes dans l'espèce *capea nemoralis* (escargots des bois). Deux régions ont été étudiées, A : région de Montluçon, B : région d'Egletons.

Intervalle (en mm)	[16 ; 17[	[17 ; 18[	[18 ; 19[	[19 ; 20[	[20 ; 21[	[21 ; 22[	[22 ; 23[
Nombre d'individus de A	0	100	200	950	210	200	45
Nombre d'individus de B	20	40	110	280	80	60	66

Intervalle (en mm)	[23 ; 24[	[24 ; 25[	[25 ; 26[	[26 ; 27[	[27 ; 28[	[28 ; 29[
Nombre d'individus de A	8	0	1	0	1	0
Nombre d'individus de B	1	0	0	0	0	0

- Pour chacune des régions, déterminer le mode, les fréquences, les fréquences cumulées, la moyenne, la classe médiane, les classes quartiles et l'écart-type.
- Déterminer la droite d'équation  $y = ax + b$  passant par  $(19, 0, 17)$  et  $(20, 0, 73)$  et en déduire une valeur interpolée de la médiane pour la distribution A.

**Exercice 3.** Dans une ferme industrielle, le service vétérinaire veut modifier le régime alimentaire des vaches, dans le but d'augmenter la production laitière. Pour cela, on a choisi au hasard 15 vaches que l'on a nourries pendant un mois avec l'aliment habituel et l'on a relevé pour chaque vache  $X$  la production quotidienne moyenne de lait exprimée en kg. Puis, on a nourri ces mêmes vaches pendant un mois avec le nouvel aliment et on a relevé de même  $Y$  la production quotidienne moyenne de chaque vache.

N° de la vache	1	2	3	4	5	6	7	8	9	10	11
X en kg/jour	27,6	23,4	25,2	28,2	28,8	25,8	27	27	29,4	28,2	30
Y en kg/jour	28,8	25,6	26,4	28	31,2	27,2	28,8	28	29,6	29,2	28,4

N° de la vache	12	13	14	15
X en kg/jour	28,2	32,4	29,4	30
Y en kg/jour	29,6	31,2	32	29,2

On note  $x_i$  la production de la vache  $i$  avec l'aliment habituel et  $y_i$  avec l'aliment nouveau. On note également  $N = 15$ ,  $X$  une variable aléatoire de loi  $\frac{1}{N} \sum_{i=1}^N \delta_{x_i}$  et  $Y$  de loi  $\frac{1}{N} \sum_{i=1}^N \delta_{y_i}$ .

- Calculer  $\mathbb{P}(X = x_1)$  et  $\mathbb{P}(Y = y_1)$ . Quel est le terme statistique pour désigner  $\mathbb{P}(X = 27,6)$  ?
- On pose  $U = \frac{X-28,2}{0,6}$ ,  $u_i = \frac{x_i-28,2}{0,6}$ ,  $V = \frac{Y-28,8}{0,8}$  et  $v_i = \frac{y_i-28,8}{0,8}$ . On sait que

$$\sum_{i=1}^{15} u_i = -4; \quad \sum_{i=1}^{15} u_i^2 = 190; \quad \sum_{i=1}^{15} v_i = 1,5; \quad \sum_{i=1}^{15} v_i^2 = 67,75; \quad \sum_{i=1}^{15} u_i v_i = 91.$$

Exprimer ces sommes en termes probabilistes de  $U$  et de  $V$ .

- Écrire  $X$  et  $Y$  en fonction de  $U$  et  $V$  et en déduire  $\mathbb{E}(X)$ ,  $\mathbb{E}(Y)$ ,  $\text{Var}(X)$ ,  $\text{Var}(Y)$ ,  $\text{Cov}(X, Y)$ .
- Calculer la valeur moyenne et l'écart type des  $(x_i)_{1 \leq i \leq 15}$  et des  $(y_i)_{1 \leq i \leq 15}$ .
- Calculer le coefficient de corrélation  $r$  entre  $(x_i)_{1 \leq i \leq 15}$  et  $(y_i)_{1 \leq i \leq 15}$ , que peut-on en conclure ?

**Exercice 4.** On réalise une enquête auprès de 1000 ménages. On s'intéresse à la liaison entre  $X$  : « le nombre d'enfants à charge du ménage » et  $Y$  : « les dépenses annuelles de fournitures scolaires » (données en dizaine d'euros).

	Y=[0 ; 4[	Y=[4 ; 10[	Y=[10 ; 20[	Y=[20 ; 40[
X=1	322	12	2	0
X=2	14	230	116	36
X=3	0	0	20	248

- Calculer le coefficient de corrélation linéaire  $r$ , que peut-on en déduire ?
- Calculer l'équation de la droite de régression de  $Y$  en  $X$  :  $y = ax + b$ .

**Exercice 5.** Une filature livre des pelotes de laine dont les poids  $X_1, X_2, \dots$  sont supposés i.i.d. de moyenne  $m$  et d'écart-type  $\sigma$ .

1. Quel est la moyenne de  $S_n$ ? Son écart-type? Quel théorème permet de justifier que lorsque  $n$  est grand,  $S_n = X_1 + \dots + X_n$  renormalisé suit une loi normale?
2. On suppose que  $S_n$  suit une loi normale et on suppose également connaître  $\sigma = 4,5g$ . On prélève 9 pelotes dans une livraison dont le poids total vaut  $507,6g$ . Calculer un intervalle de confiance à 95%. Tester la valeur  $m = 60g$  pour cet intervalle.  
*On précise que, pour la loi normale centrée réduite, le quantile d'ordre  $0,975$  vaut  $q = 1,96$ .*
3. On considère un nouveau type de pelote. On note  $x_i$  le poids de la pelote  $i$ . Montrer que

$$\hat{m} := \frac{1}{n} \sum_{i=1}^n x_i \quad \text{et} \quad \hat{\sigma}^2 := \frac{1}{n-1} \sum_{i=1}^n (x_i - \hat{m})^2,$$

sont des estimateurs sans biais de  $m$ , respectivement  $\sigma^2$ .

4. On suppose toujours que  $S_n$  suit une loi normale. On a mesuré  $\hat{m} = 102g$  et  $\hat{\sigma}^2 = 7,5g$ . En approchant  $\sigma$  par  $\hat{\sigma}$ , construire un intervalle de confiance autour de  $\hat{m}$  à 95%.

**Exercice 6.** On s'intéresse à la durée de vie de tubes fluorescents fabriqués par une usine. Un organisme indépendant souhaite vérifier que la durée de vie moyenne dépasse  $\theta_0 = 1600$  heures. Pour cela il mesure la durée de vie moyenne sur un échantillon de taille  $n = 100$  et trouve une valeur de 1575 heures avec un écart-type de 120 heures. On pose  $X_1, \dots, X_n$  la durée de vie de  $n$  tubes fluorescents, de moyenne  $\theta$  et de variance  $\sigma^2$ .

1. Quelles hypothèses sur  $(X_i)_{i \geq 1}$  sont nécessaires pour assurer, pour  $S_n = X_1 + \dots + X_n$ , la convergence en loi suivante :

$$\frac{S_n - n\theta}{\sigma\sqrt{n}} \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} \mathcal{N}(0, 1).$$

On supposera dans la suite l'approximation suivante  $N := \frac{S_n - n\theta}{\sigma\sqrt{n}} \sim \mathcal{N}(0, 1)$ .

2. A l'aide de la fonction caractéristique de la gaussienne de moyenne  $\mu$  et de variance  $\delta^2$  donnée par

$$\varphi_{\mu, \delta^2}(t) = e^{it\mu} e^{-\frac{t^2\delta^2}{2}},$$

retrouver la loi de  $\frac{S_n}{n}$ .

3. Quelle est l'hypothèse nulle  $H_0$  adaptée pour l'organisme indépendant s'il désire être sûr que la moyenne dépasse  $\theta_0$ ?
4. Compléter la construction de la zone de rejet de l'hypothèse nulle, pour  $x_\alpha > 0$  un réel qui sera choisi ultérieurement :

$$\mathcal{R} := \left\{ \frac{S_n}{n} \dots \theta_0 + x_\alpha \right\}.$$

5. On définit l'erreur de première espèce au niveau  $\alpha$  par

$$\sup_{\theta \in H_0} \mathbb{P}_\theta(\mathcal{R}) = \alpha.$$

ou sous  $\mathbb{P}_\theta$ , les  $X_i$  sont de moyenne  $\theta$ . En raisonnant qualitativement, pour quelle valeur de  $\theta$ , la borne supérieure est-elle atteinte ?

6. On approche brutalement  $\sigma$  par l'écart-type empirique valant 120 heures. On donne que le quantile d'ordre  $1 - \alpha = 0,95$  vaut  $q_\alpha = 1,65$ . En déduire la valeur minimale de  $x_\alpha$  pour  $\alpha = 0,05$ .
7. On définit également l'erreur de seconde espèce par

$$\sup_{\theta \in \bar{H}_1} \mathbb{P}_\theta(\mathcal{R}^c).$$

Traduire en français la signification de cette erreur. Pour quelle valeur de  $\theta$  cette borne supérieure est-elle atteinte ? Afin de minimiser cette seconde erreur, vaut-il mieux avoir  $x_\alpha$  plutôt grand ou petit ? En déduire une valeur de  $x_\alpha$  adaptée.

8. A l'aide de la valeur mesurée pour la durée de vie moyenne, conclure si l'organisme rejette ou non l'hypothèse nulle avec une certitude de 95%.
9. Quelle est la conclusion si l'on exige une précision d'ordre 99% sachant que le quantile d'ordre 0,99 vaut  $q_\alpha = 2,33$  ?
10. Faire le même travail mais du point de vue de l'usine, la conclusion est-elle la même pour le test à 95% ? à 99% ?