

7. Estimation des paramètres

Dans une population trop grande pour être étudiée entièrement, on constitue un échantillon de n individus, sur lesquels on mesure la valeur d'un caractère quantitatif x . Soit X la variable aléatoire (théorique) définie par les valeurs du caractère x sur l'**ensemble** de la population; on dispose des *estimations ponctuelles* suivantes pour la moyenne, la variance et l'écart-type de X :

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i, \quad \text{Var}_x = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2, \quad s_x = \sqrt{\text{Var}_x}.$$

Noter que Var_x est égal à la *variance observée* multipliée par $\frac{n}{n-1}$, de façon à obtenir un estimateur *sans biais*, c'est-à-dire dont l'espérance (lorsqu'on considère un grand nombre d'échantillons) est égale à la variance théorique. La plupart des calculatrices à fonctions statistiques donnent à la fois l'écart-type *observé* (noté σ_n) et l'écart-type *débiaisé* s_x (noté σ_{n-1}).

Le principe de l'*estimation par intervalles* d'un paramètre t (moyenne, variance,...) est de choisir une *probabilité d'erreur* α et de déterminer un *intervalle de confiance* $]a, b[$ tel que

$$P(a < t < b) = 1 - \alpha.$$

Autrement dit, $P(t \notin]a, b[) = \alpha$. On appelle aussi α le *risque d'erreur* ou le *coefficient de risque* et $1 - \alpha$ le *seuil de confiance* ou le *coefficient de sécurité*. On choisit en général $\alpha = 1\%$ ou $\alpha = 5\%$.

En pratique, pour estimer la moyenne et la variance par intervalles de confiance, on distingue deux cas :

- pour les **grands** échantillons ($n \geq 30$), on lit u_α tel que $P(|\mathcal{N}| \geq u_\alpha) = \alpha$ (\mathcal{N} est la loi normale centrée réduite) dans la *table de l'écart réduit*; l'intervalle de confiance de la moyenne du caractère x au risque α est donné par :

$$\left] \bar{x} - u_\alpha \frac{s_x}{\sqrt{n}} ; \bar{x} + u_\alpha \frac{s_x}{\sqrt{n}} \right[.$$

En supposant de plus que X suit une **loi normale**, l'intervalle de confiance de la variance du caractère x au risque α est donné par :

$$\left] \frac{2(n-1)s_x^2}{(\sqrt{2n-3} + u_\alpha)^2} ; \frac{2(n-1)s_x^2}{(\sqrt{2n-3} - u_\alpha)^2} \right[.$$

- Pour les **petits** échantillons ($n \leq 30$), on a besoin de l'hypothèse que la variable aléatoire X suit une **loi normale**. On lit alors t_α tel que $P(|T| \geq t_\alpha) = \alpha$ (T est la loi de Student à $n - 1$ degrés de liberté) dans la *table de la loi de Student*; l'intervalle de confiance de la moyenne du caractère x au risque α est donné par :

$$\left] \bar{x} - t_\alpha \frac{s_x}{\sqrt{n}} ; \bar{x} + t_\alpha \frac{s_x}{\sqrt{n}} \right[.$$

Pour la variance, on lit a et b tels que $P(Y^2 \geq b) = \frac{\alpha}{2}$ et $P(Y^2 \geq a) = 1 - \frac{\alpha}{2}$, où Y^2 est la loi du χ^2 à $n - 1$ degrés de liberté, dans la *table de la loi du chi-deux*; l'intervalle de confiance de la variance du caractère x au risque α est donné par :

$$\left] \frac{(n-1)s_x^2}{b} ; \frac{(n-1)s_x^2}{a} \right[.$$

On rappelle qu'il est aussi possible d'estimer la *fréquence* d'apparition d'un caractère par intervalles de confiance.

Exercice 1

On a mesuré le poids en grammes du cerveau d'hommes et de femmes de 20 à 49 ans issus d'une région d'Europe. On a obtenu les résultats suivants.

Centre des classes	1170	1220	1270	1320	1370	1420	1470	total
Effectifs (hommes)	5	36	45	50	61	49	19	265

Centre des classes	1070	1120	1170	1220	1270	1320	1370	total
Effectifs (femmes)	12	22	45	54	52	20	10	215

Donner un intervalle de confiance au risque de 1% :

- pour la moyenne de la population des hommes ;
- pour la moyenne de la population des femmes.

Exercice 2

On a mesuré la masse en kg de raisin par souche sur 10 souches prises au hasard dans une vigne et on a obtenu :

2,4 ; 3,2 ; 3,6 ; 4,1 ; 4,3 ; 4,7 ; 5,4 ; 5,9 ; 6,5 ; 6,9 .

- Déterminer une estimation ponctuelle non biaisée de la moyenne et de la variance de la vigne dont ces souches sont extraites.
- Donner un intervalle de confiance de la moyenne au risque 5%, en supposant que la masse de raisin par souche suit une loi normale dans cette vigne.
- Sous la même hypothèse, donner un intervalle de confiance de la variance au risque 5%. En déduire un intervalle de confiance au même risque pour l'écart-type.

Exercice 3

Dans une parcelle de soja, on a mesuré la hauteur en cm de 100 plantes à l'âge de 6 semaines :

Hauteurs	36	37	38	39	40	41
Effectifs	6	11	26	32	14	11

Déterminer sous les hypothèses adéquates des intervalles de confiance au coefficient de sécurité 0,95 pour la moyenne et la variance de la hauteur des plantes de la parcelle.