

Chapitre 3

Les intervalles de confiance

1) Introduction

- Comment détermine-t-on dans quelles limites se situe le nombre de globules rouges par litre de sang chez un individu en bonne santé ?
- Ce type d'évaluations est déduit de modèles probabilistes par les techniques statistiques d'estimation paramétrique.
- La notion importante est celle **d'intervalle de confiance**, qui permet d'évaluer la précision d'une **estimation ponctuelle**.

2) Intervalle de confiance d'une moyenne

Cas de variance σ^2 connue.

- On suppose que la variable X étudiée sur les individus d'une population **suit une loi normale $N(\mu, \sigma^2)$** .
- **Ou $n > 30$** si on n'a pas la normalité
- On peut en général considérer que la population est normale lorsque les données de l'échantillon aléatoire simple **de taille n** , de **moyenne \bar{x}** et **d'estimateur de variance**

$$s^2 = \frac{n}{n-1} S_{ech}^2$$

confirment qu'il n'y a pas des valeurs extrêmes et que l'histogramme a une forme qui n'est pas éloignée de celle d'une loi normale.

- L'objectif est d'estimer μ par un intervalle.
- $IC_\mu = [\bar{x}-E, \bar{x}+E]$ est **l'intervalle de confiance** de la moyenne μ au **niveau de confiance $1-\alpha$** (ou **au risque d'erreur α**) si

$$P(\mu \in IC_\mu) = 1 - \alpha.$$

- $E = t_{\frac{\alpha}{2}} * \frac{\sigma}{\sqrt{n}}$ la marge d'erreur sur la moyenne
- $t_{\frac{\alpha}{2}}$ la valeur critique de **$N(0,1)$** , c'est-à-dire

$$P\left(U > t_{\frac{\alpha}{2}}\right) = \frac{\alpha}{2} \quad \text{où } U \sim N(0,1).$$

*interpréter un intervalle de confiance

- Si on a par exemple $\alpha = 5\%$, on dit que nous avons confiance à 95% que l'intervalle IC_μ contienne la vraie valeur de μ .

- Cela signifie que si on sélectionnait de nombreux échantillons de même taille et qu'on construisait les intervalles de confiance correspondants, 95% d'entre eux contiendraient la vraie valeur.

Exemple 1 « Température du corps humain ».

Pour un échantillon des températures corporelles, on a $n=106$ et $\bar{x}=36.78^\circ\text{C}$.

Supposer que l'échantillon est un échantillon aléatoire simple et que σ est connue et vaut 0.34°C .

➤ Donner l'intervalle de confiance à 95% de la température corporelle.

Il faut d'abord vérifier les conditions requises pour estimer μ

On a la normalité de la population et $n>30$.

$n>30$ est suffisante même si on n'a pas la normalité.

$$E = t_{\frac{\alpha}{2}} * \frac{\sigma}{\sqrt{n}} = 1.96 \frac{0.34}{\sqrt{106}} = 0.06$$

$$IC_{\mu} = [36.72, 36.84]$$

Cas de variance σ^2 inconnue

Conditions requises pour estimer μ quand σ est inconnu

L'échantillon est aléatoire simple

Soit la population est normalement distribuée, soit $n>30$.

$$E = t_{\frac{\alpha}{2}; n-1} * \frac{s}{\sqrt{n}}$$

$t_{\frac{\alpha}{2}; n-1}$ la valeur critique de la loi de Student $t(n-1)$

Degré de liberté $\nu = n - 1$.

Exemple 2 Considérons l'exemple de la température corporelle mais avec l'écart type estimé $s=0.34$.

Les conditions requises pour l'estimation de μ sont satisfaites.

(n étant >30 , on n'a pas besoin de vérifier la normalité)

pour $\alpha=0.05$, $n-1=105$ on a $t_{\alpha/2, n-1}=1.984$

$$E = t_{\frac{\alpha}{2}} * \frac{s}{\sqrt{n}} = 1.984 \frac{0.34}{\sqrt{106}} = 0.06$$

$$IC_{\mu} = [36.72, 36.84]$$

Interprétation à partir des résultats de l'échantillon on peut être sûr à 95% que l'intervalle $[36.72; 36.84]$ contient effectivement la vraie valeur de la moyenne de la population.

- σ est connu

Si $X \sim N(0,1)$ ou $n > 30$, E est calculé avec $t_{\alpha/2}$ (de la table de la loi normale).

- σ de la population n'est pas connu. Si $n > 30$ ou la population suit une loi normale, E est calculé avec $t_{\alpha/2, n-1}$ (de la loi de Student)
- $n < 30$ et la population ne suit pas une loi normale, E ne devrait pas être calculé par les méthodes paramétriques

3) intervalle de confiance d'une proportion

*Notations pour les proportions

p = proportion de succès dans toute la population.

$\hat{p} = \frac{x}{n}$ = proportion de x succès dans un échantillon de taille n .

$\hat{q} = 1 - \hat{p}$ = proportion d'échecs dans un échantillon de taille n .

*Conditions requises pour l'estimation de p

* l'échantillon est aléatoire simple

* $np \geq 5$ et $nq \geq 5$

*Intervalle de confiance pour p de la population

$IC_p = [\hat{p} - E, \hat{p} + E]$

$$E = t_{\frac{\alpha}{2}} * \sqrt{\frac{\hat{p}\hat{q}}{n}}$$

$t_{\frac{\alpha}{2}}$ est la valeur critique de $N(0,1)$

Exemple Gregor Mendel a mené ses fameuses expériences génétiques avec des pois, un des échantillons des croisements a été obtenu en croisant **des pois à gousses vertes** et **des pois à gousses jaunes**. Cette lignée comportait **580 pois**. Parmi ces pois, **428 avait des gousses vertes** et **152 gousses jaunes**.

A partir de sa théorie des gènes, Mendel s'attendait à ce que **25%** des pois aient **des gousses jaunes**. Le pourcentage **de gousses jaunes est de 26.2%**.

- Trouver la marge d'erreur qui correspond à un intervalle de confiance à 95%
- Trouver l'intervalle de confiance à 95% de p de la population
- A partir de ces résultats, que pouvons-nous conclure sur la théorie de Mendel qui déclare que le pourcentage de pois à gousse jaune devrait être de 25%?

Solution

On a: $n\hat{p} = 152 \geq 5$, $n\hat{q} = 428 \geq 5$

$$a. E=1.96 \sqrt{\frac{0.262*0.738}{580}} = 0.036$$

b. $IC_p=[0.226, 0.298]$ cet intervalle est décrit comme suit :

Le pourcentage de pois à gousse jaune est estimé à 26.2% avec une marge d'erreur de plus ou moins 3.6%.

A partir de ces résultats nous sommes sûr à 95% que les limites 22.6% et 29.8% contiennent le vrai pourcentage de pois à gousses jaunes.

Le vrai pourcentage peut être vraisemblablement n'importe quelle valeur entre ces deux limites. Comme cet intervalle contient la valeur 25%, la valeur de Mendel ne peut pas être considéré comme fausse.

4) Intervalle de confiance d'une variance

*conditions requises pour estimer σ^2

L'échantillon est aléatoire simple

La population doit avoir une distribution normale (même si $n>30$).

*Intervalle de confiance de σ^2

$$IC_{\sigma^2} = \left[\frac{(n-1)s^2}{\chi^2_D}, \frac{(n-1)s^2}{\chi^2_G} \right]$$

- s^2 estimateur de la variance de la population
- χ^2_G est la valeur qui se localise à la ligne (le degré de liberté) de la colonne gauche et la colonne $1- \alpha/2$ au niveau des en-têtes.
- χ^2_D est la valeur qui se localise à la ligne (le degré de liberté) de la colonne gauche et la colonne $\alpha/2$ au niveau des en-têtes.

Exemple : « Températures corporelles »

On liste 106 températures corporelles prises par des chercheurs. Supposer que c'est un échantillon simple et utiliser les caractéristiques suivantes pour construire un **intervalle de confiance à 95%** de l'écart type pour les températures corporelles de l'ensemble de la population.

- a. D'après la représentation graphique (histogramme) de l'échantillon, **Il n'y a pas de valeurs extrêmes** et les **données semblent suivre une loi normale**.

$$\bar{x} = 36.78^\circ\text{C}, s = 0.34^\circ\text{C}, n = 106$$

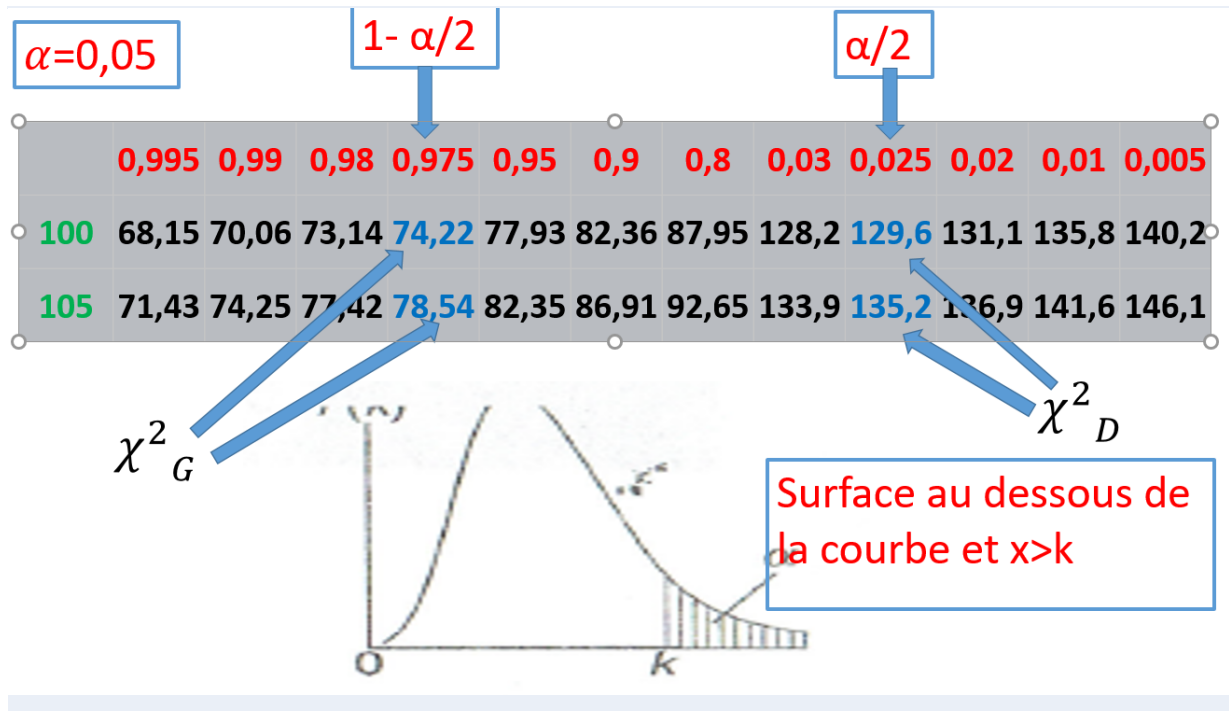
Solution

1. La condition de normalité est satisfaite.

$n=106$, le $ddl=106-1=105$. Si ce ddl n'est pas dans la table, nous prendrons la valeur la plus proche. Par exemple $ddl=100$.

Pour un niveau de confiance 95%, on se réfère aux valeurs 0.975 et 0.025 comme en-têtes de colonnes, On a pour $ddl=105$: $\chi^2_G = 78,54$, $\chi^2_D = 135,2$

Pour $ddl=100$: $\chi^2_G = 74.22$, $\chi^2_D = 129.561$



$$IC_{\sigma^2} = \left[\frac{(n-1)s^2}{\chi^2_D}, \frac{(n-1)s^2}{\chi^2_G} \right]$$

$$IC_{\sigma^2} = \left[\frac{(106-1) * (0.34)^2}{135.2}, \frac{(106-1) * (0.34)^2}{78.54} \right]$$

$$IC_{\sigma^2} = [0.0898, 0.155]$$

Si on prend la racine carré $IC_{\sigma} = [0.3, 0.39]$

