

Première partie

Théorie d'estimation

0.1 Echantillonnage :

On s'intéresse à l'étude d'un caractère dans une population P à laquelle on n'a pas accès. Si on extrait plusieurs échantillons représentatif de taille n fixées, les différences observées entre les résultats obtenus sont dues à *des fluctuations d'échantillonnages*. A partir d'un échantillon, on n'a pas de certitudes mais estimations de paramètres.

L'échantillonnage est dit **non-exhaustif** si le tirage de n individus constituant l'échantillon a lieu avec remise.

Il est **exhaustif** si le tirage est réalisé sans remise. En fait, le plus souvent la taille de l'échantillon est faible par rapport à celle de la population, aussi on considérera dans la suite que tout échantillonnage est assimilable au cas non-exhaustif.

Si on étudie sur la population un caractère quantitatif, et si on considère plusieurs échantillon de taille n , on peut calculer la moyenne et la variance de chaque échantillon. On définit ainsi trois variables aléatoires.

\bar{X} **moyenne aléatoire de l'échantillon** qui prend pour valeurs les moyennes des échantillons de taille n .

S_e^2 **variance aléatoire de l'échantillon** qui prend pour valeurs les variances des échantillons de taille n .

Si la population est formée des individus ayant ou non un caractère A.

F **fréquence des échantillons** qui prend pour valeurs les fréquences de A des échantillons de taille n .

0.2 Estimation ponctuelle de la moyenne et la variance :

Soit X une variable aléatoire définie sur la population avec la moyenne μ et la variance σ^2 .

c'est μ et σ qu'il s'agit d'estimer

Théorème 1 $E(\bar{X}) = \mu$; $V(\bar{X}) = \frac{\sigma^2}{n}$; $E(S_e^2) = \frac{n-1}{n}\sigma^2$

0.2.1 Interprétation des résultats :

D'une manière générale, on dit qu'une variable aléatoire R est **estimateur sans biais** d'un paramètre r si $E(R) = r$

Dans le cas contraire on parle **d'estimateur biaisé**.

\bar{X} est estimateur sans biais de μ . Mais S_e^2 est un estimateur biaisé de σ^2 .

Par contre $S^2 = \frac{n}{n-1} S_e^2$ est un estimateur sans biais de σ^2 .

En pratique; on dispose d'un seul échantillon de taille n , alors la meilleure estimation ponctuelle :

La meilleure estimation ponctuelle de μ est la moyenne \bar{x} de l'échantillon.

la meilleure estimation ponctuelle de σ^2 est le nombre s^2 :

$$s^2 = \frac{n}{n-1} \times \text{variance de l'échantillon.}$$

0.3 Estimation ponctuelle d'un pourcentage :

la population est formée d'individus ayant ou non un caractère donné A . Soit p la probabilité pour qu'un individu pris au hasard dans la population présente le caractère A .

Théorème 2 $E(F) = p \quad V(F) = \frac{p(1-p)}{n}$

0.3.1 Utilisation :

F est un estimateur sans biais de p . Quand on dispose d'un seul échantillon de taille n , la meilleure estimation ponctuelle de p est donc la fréquence f observée sur l'échantillon.

0.4 Estimation d'une moyenne par un intervalle de confiance :

L'estimation ponctuelle n'est pas commode; c'est pour cette raison on cherche un intervalle I telle que : on ait de forte probabilité contenue μ

c-à-d $I =]a, b[\quad P(\mu \in I) = 1 - \alpha$; où α =risque

par exemple si $\alpha = 5\% \Rightarrow 1 - \alpha = 95\%$

On a 3 cas se présentent :

1^{er} cas : $P \curvearrowright N(\mu; \sigma)$ où $n \geq 30$

$$P \curvearrowright N(\mu; \sigma) \Rightarrow \bar{X} \curvearrowright N(\mu; \frac{\sigma}{\sqrt{n}})$$

$$\bar{X} \curvearrowright N(\mu; \frac{\sigma}{\sqrt{n}}); \text{ posons } z = \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \curvearrowright N(0, 1)$$

$$P(-z_\alpha < z < +z_\alpha) = 1 - \alpha \Rightarrow p(-z_\alpha < \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} < +z_\alpha) = 1 - \alpha$$

$$\Rightarrow P(-z_\alpha \frac{\sigma}{\sqrt{n}} < \bar{X} - \mu < +z_\alpha \frac{\sigma}{\sqrt{n}}) = 1 - \alpha$$

$$\Rightarrow P(\bar{X} - z_\alpha \frac{\sigma}{\sqrt{n}} < \mu < \bar{X} + z_\alpha \frac{\sigma}{\sqrt{n}}) = 1 - \alpha$$

$$\mu \in I =]\bar{x} - z_\alpha \frac{\sigma}{\sqrt{n}}; \bar{x} + z_\alpha \frac{\sigma}{\sqrt{n}}[$$

2^{ème} cas: $P \curvearrowright N(\mu; \sigma)$ où $n \geq 30$ et σ de la population est inconnue :

Si σ est inconnue, on l'estime par $s = \sqrt{\frac{n}{n-1}} s_e$

$$D'où : I =]\bar{x} - z_\alpha \frac{s_e}{\sqrt{n-1}}; \bar{x} + z_\alpha \frac{s_e}{\sqrt{n-1}}[$$

3^{ème} cas : P quelconque et $n < 30$ et σ inconnue

\bar{X} suit la loi de student à $n-1$ degrés de liberté $\bar{X} \curvearrowright St((n-1)d.d.l)$

$$D'où I =]\bar{x} - t_\alpha \frac{s_e}{\sqrt{n-1}}; \bar{x} + t_\alpha \frac{s_e}{\sqrt{n-1}}[$$

t_α est déterminé par la table de student.

Exemple :

Un dosage de sucre dans une solution effectuée sur 8 prélèvements provenant d'une même fabrication a donné les résultats suivants exprimés en g/l :

19,5 19,7 19,8 20,2 20,2 20,3 20,4 20,8

trouver I au risque 5%

On a le 3^{ème} cas : $n < 30$ et $\sigma = ?$

$$\bar{x} = \frac{\sum x_i}{n} = 20,11 \text{ g/l}; \quad V = s_e^2 = \frac{\sum x_i^2}{n} - \bar{x}^2 = 0,178 (\text{g/l})^2 \Rightarrow s_e = 0,422 \text{ g/l}$$

$n-1 = 8-1 = 7$ et $\alpha = 5\% = 0,05$ d'après la table de student $t_\alpha = 2,365$

$$\mu \in]20,11 - \frac{(2,365)(0,422)}{7}; 20,11 + \frac{(2,365)(0,422)}{7}[\Rightarrow \mu \in]19,75; 20,46[$$

0.5 Estimation d'un pourcentage par un intervalle de confiance :

Soit dans une population P ; une variable quantitative présentée dans la partition p (absente dans la partition $q = 1 - p$). Soit un échantillon de taille n sur lequel on dénombre np fois la présence du caractère A (nq fois son absence) avec : $n = np + nq$

1^{er} cas : si $n \geq 30$; $np \geq 5$ et $nq \geq 5 \implies F \curvearrowright N(p, \sqrt{\frac{pq}{n}})$

posons $z = \frac{F-p}{\sqrt{\frac{pq}{n}}} \curvearrowright N(0, 1)$

$$P(-z_\alpha < z < +z_\alpha) = 1 - \alpha \implies P(-z_\alpha < \frac{F-p}{\sqrt{\frac{pq}{n}}} < +z_\alpha) = 1 - \alpha \implies$$

$$P(-z_\alpha \sqrt{\frac{pq}{n}} < F - p < +z_\alpha \sqrt{\frac{pq}{n}}) = 1 - \alpha$$

$$\implies P(-z_\alpha \sqrt{\frac{pq}{n}} < F - p < +z_\alpha \sqrt{\frac{pq}{n}}) = 1 - \alpha$$

$$\implies P(F - z_\alpha \sqrt{\frac{pq}{n}} < p < F + z_\alpha \sqrt{\frac{pq}{n}}) = 1 - \alpha$$

Alors l'intervalle de confiance de p est : $I =]f - z_\alpha \sqrt{\frac{pq}{n}}; f + z_\alpha \sqrt{\frac{pq}{n}}[$

et comme $\frac{f(1-f)}{n}$ est une estimation non biaisée de $\frac{p(1-p)}{n}$

$$\text{D'où } I =]f - z_\alpha \sqrt{\frac{f(1-f)}{n}}; f + z_\alpha \sqrt{\frac{f(1-f)}{n}}[$$

2^{ème} cas : Si $n < 30$; $np < 5$ où $nq < 5$

dans ce cas l'intervalle de confiance de la proportion p est :

$$I =]f - t_\alpha \sqrt{\frac{f(1-f)}{n}}; f + t_\alpha \sqrt{\frac{f(1-f)}{n}}[$$

le t_α lu dans la table de student à $(n - 1)$ degrés de liberté.

Remarque 3 lorsque le nombre de degré de liberté tend vers l'infini, la fonction de répartition de la loi de student tend vers celle de la loi normale centrée réduite (en pratique $n \geq 30$)

0.6 Estimation d'une variance par un intervalle de confiance :

Théorème 4 Si X suit une loi normale, la variable aléatoire $Y^2 = \frac{n-1}{\sigma^2} S^2$ suit la loi de χ^2 à $n - 1$ degrés de liberté.

0.6.1 Utilisation si $n \leq 31$:

Le coefficient de risque α étant choisi et le nombre de degrés de liberté étant connu, la table de χ^2 permet de déterminer a et b tels que :

$$P(a < Y^2 < b) = 1 - \alpha \quad \text{avec} \quad P(Y^2 \geq b) = \frac{\alpha}{2} \quad \text{et} \quad P(Y^2 \geq a) = 1 - \frac{\alpha}{2}$$

La seule valeur connue de S^2 est s^2 , on obtient comme intervalle de confiance de σ^2 au risque α : $]\frac{(n-1)}{b}s^2; \frac{(n-1)}{a}s^2[$

Remarque 5 On a $(n-1)s^2 = ns_e^2$ où s_e^2 est la variance de l'échantillon.

0.6.2 Utilisation si $n > 31$:

Le théorème cité est vrai quel que soit n . Mais les tables de χ^2 s'arrête au degrés de liberté 30. On ne peut pas les utiliser si $n > 31$.

Théorème 6 Si Y^2 est une variable aléatoire qui suit une loi de χ^2 de degrés de liberté ν et si $\nu > 30$, alors la variable aléatoire $U = \sqrt{Y^2} - \sqrt{2\nu - 1}$ suit sensiblement la loi normale centrée réduite.

Utilisation :

Ici on a $U = \sqrt{\frac{2(n-1)}{\sigma^2}S^2} - \sqrt{2n-3}$, Après avoir choisi α on détermine z_α et on déduit l'intervalle de confiance de σ^2 :

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

Deuxième partie

Introduction aux test statistiques

0.7 Test d'hypothèses :

On est souvent conduit à prendre une décision au sujet d'une population à partir des informations données sur un échantillon. Il s'agit de faire un choix entre plusieurs hypothèses.

On met en avant une hypothèse dite *hypothèse nulle* et notée (H_0). on souhaite vérifier si (H_0) est vraie alors que deux hypothèses sont possibles (H_0) et (H_1); où (H_1) est dite *hypothèse alternative*.

Pour effectuer notre choix entre (H_0) et (H_1); on effectue un test statistique lequel comporte les étapes suivantes :

- a) Définir (H_0) et (H_1).
- b) Choisir un certain paramètre sous l'hypothèse (H_0).
- c) Choisir un seuil α .
- d) Lire dans la table de la distribution du paramètre choisi en (b) la valeur correspondante à α .
- e) Définir une région critique.
- f) Calculer la valeur du paramètre choisi en (b)
- g) Adopter la règle suivante : si la valeur du paramètre calculer en (b) appartient à la région critique (H_1) si non on accepte (H_0).

On est alors conduit à choisir parmi deux décisions :

-Le résultat obtenu conduit à rejeter (H_0). Mais on court ainsi un risque de se tromper dit **erreur de première espèce** et noté α .

α est la probabilité de se tromper quand on rejete (H_0)

-Le résultat obtenu conduit à accepter (H_0). Mais il y a là encore un risque d'erreur. Il est dit **erreur de deuxième espèce** et noté β .

β est la probabilité de se tromper quand on accepte (H_0).

0.7.1 Test de conformité :

Il s'agit de comparer un échantillon à une loi théorique. L'hypothèse (H_0) consiste à supposer que les différences observées ne sont pas significative et

sont dues aux fluctuations d'échantillonnage.

0.7.2 Test d'homogénéité :

Il s'agit de comparer deux échantillons. L'hypothèse (H_0) est qu'ils proviennent d'une même population.

0.7.3 Comparaison d'une moyenne observée à une moyenne théorique :

Soit \bar{x} la moyenne observée d'une variable quantitative dans un échantillon E . Soit d'autre part P_0 une population de moyenne μ_0 .

On désire savoir : **Si l'échantillon E provient de P_0 ou s'il est extrait d'une autre population P de moyenne $\mu \neq \mu_0$**

On désire savoir si la différence $\bar{x} - \mu_0$ entre les deux moyennes est significative (en l'est pas extrait de P_0) où bien la différence n'est pas significative (extrait de P_0).

Test bilatéral :

On teste (H_0) l'hypothèse nulle contre (H_1) l'hypothèse alternative.

(H_0) l'hypothèse nulle : $\mu = \mu_0$

(H_1) l'hypothèse alternative : $\mu \neq \mu_0$

On calcule $z = \frac{\bar{x} - \mu_0}{\frac{\sigma}{\sqrt{n}}}$

En choisissant un seuil significatif α est on est amené à prendre la décision suivante :

$z \in] -z_\alpha, +z_\alpha[$ on accepte (H_0)

$z \notin] -z_\alpha, +z_\alpha[$ on rejette (H_0).

Test unilatéral :

On teste (H_0) l'hypothèse nulle contre l'hypothèse (H_1) :

(H_0) l'hypothèse nulle : $\mu = \mu_0$

(H_1) l'hypothèse : $\mu > \mu_0$ où $\mu < \mu_0$

On calcule $z = \frac{\bar{x} - \mu_0}{\frac{\sigma}{\sqrt{n}}}$

Pour le cas unilatéral à droite :

$z \in] - \infty, +z_\alpha]$ on accepte (H_0)

$z \in] +z_\alpha, +\infty[$ on rejette (H_0).

Pour le cas unilatéral à gauche :

$z \in [-z_\alpha, +\infty[$ on accepte (H_0)

$z \in] - \infty, -z_\alpha[$ on rejette (H_0).

Soit la population P_0 de moyenne μ_0 et d'écart type σ ; on extrait un échantillon E de taille n . la moyenne d'échantillon est \bar{x} . On a 4 cas :

1^{er} cas : $n \geq 30$ et σ connue

$$\bar{x} \curvearrowright N(\mu_0; \frac{\sigma}{\sqrt{n}}) \Rightarrow z_\alpha = \frac{\bar{x} - \mu_0}{\frac{\sigma}{\sqrt{n}}} \curvearrowright N(0, 1)$$

Supposon que $\alpha = 5\% \Rightarrow z_\alpha = 1,96$

Si $z_\alpha \in] - 1,96, +1,96[$ on accepte l'hypothèse (H_0) (E extrait de la population P_0)

Si $z_\alpha \in] - \infty, -1,96[$ ou $z_\alpha \in] +1,96, +\infty[$ (la région critique) On accepte (H_1) (E extrait de P et non P_0)

2^{ème} cas : $n \geq 30$ et σ inconnue

σ de la population est inconnue on l'estime par $s = \sqrt{\frac{n}{n-1}}s_e$; s_e l'écart type de l'échantillon E .

$$z_\alpha = \frac{\bar{x} - \mu_0}{\frac{s}{\sqrt{n}}} \curvearrowright N(0, 1)$$

3^{ème} cas : $N < 30$ et σ inconnue

$$t_l = \frac{\bar{x} - \mu_0}{\frac{s}{\sqrt{N}}} \curvearrowright St((n - 1)d.d.l)$$

4^{ème} cas : la population est normale et σ connue

c'est le 1^{er} cas.

0.7.4 Comparaison d'une fréquence observée à une fréquence théorique :

Dans une population P on étudie un caractère statistique à deux modalités A et \bar{A} . Soit p le pourcentage d'apparition de A dans la population, et f est la fréquence d'apparition de A dans un échantillon de taille n . notons F la variable aléatoire qui prend la valeur f sur chaque échantillon de taille n .

Est ce que la différence entre f et p est explicable par les aléatoires dus à l'échantillonnage ?

Test bilatéral :

On test (H_0) l'hypothèse nulle contre l'hypothèse alternative (H_1) :

(H_0) l'hypothèse nulle : $p = p_0$

(H_1) l'hypothèse alternative : $p \neq p_0$

$$\text{On calcule } z = \frac{f-p}{\sqrt{\frac{p_0(1-p_0)}{n}}}$$

En choisissant un seuil significative α est on est amené à prendre la décision suivante :

$z \in] - z_\alpha, +z_\alpha[$ on accepte (H_0)

$z \notin] - z_\alpha, +z_\alpha[$ on rejette (H_0).

Test unilatéral :

On test (H_0) l'hypothèse nulle contre l'hypothèse (H_1)

(H_0) l'hypothèse nulle : $p = p_0$

(H_1) l'hypothèse : $p > p_0$ où $p < p_0$

, On calcule $z = \frac{f-p_0}{\sqrt{\frac{p_0(1-p_0)}{n}}}$

Pour le cas unilatéral à droite :

$z \in] - \infty, +z_\alpha]$ on accepte (H_0)

$z \in] +z_\alpha, +\infty[$ on rejette (H_0).

Pour le cas unilatéral à gauche :

$z \in [-z_\alpha, +\infty[$ on accepte (H_0)

$z \in]-\infty, -z_\alpha[$ on rejette (H_0).

On a deux cas à distinguer :

1^{er} cas : si $n \geq 30; np \geq 5$ et $nq \geq 5 \implies F \curvearrowright N(p, \sqrt{\frac{pq}{n}})$

posons $z = \frac{F-p}{\sqrt{\frac{pq}{n}}} \curvearrowright N(0, 1) \implies z = \frac{f-p_0}{\sqrt{\frac{p_0(1-p_0)}{n}}}$

2^{ème} cas : Si $n < 30; np < 5$ où $nq < 5$

le t_α lu dans la table de Student à $(n-1)$ degrés de liberté.

0.7.5 Comparaison d'une variance expérimentale et d'une variance théorique :

Soit X une variable aléatoire suit la loi normale $N(\mu, \sigma)$; on extrait un échantillon de taille n , \bar{x} est la moyenne de l'échantillon et $s^2 = \frac{n}{n-1} s_e^2$

s_e^2 est la variance de l'échantillon.

Alors $Y^2 = \frac{n-1}{\sigma^2} S^2$ suit la loi khi-deux à $(n-1)$ degrés de liberté.

Test bilatérale :

On test (H_0) l'hypothèse nulle contre (H_1) l'hypothèse alternative.

(H_0) l'hypothèse nulle : $\sigma^2 = \sigma_0^2$

(H_1) l'hypothèse alternative : $\sigma^2 \neq \sigma_0^2$

On calcule $y^2 = \frac{n-1}{\sigma^2} s^2$

Le risque α étant fixé et le nombre de degrés de liberté étant connu, la table de χ^2 permet de déterminer a et b tels que :

$P(a < Y^2 < b) = 1 - \alpha$ avec $p(Y^2 \geq b) = \frac{\alpha}{2}$ et $P(Y^2 \geq a) = 1 - \frac{\alpha}{2}$

Si $y^2 \in]a, b[$ alors on accepte (H_0).

Si $y^2 \notin]a, b[$ alors on rejette (H_0).

Test unilatérale :

On test (H_0) l'hypothèse nulle contre l'hypothèse (H_1) :

(H_0) l'hypothèse nulle : $\sigma^2 = \sigma_0^2$

(H_1) l'hypothèse : $\sigma^2 > \sigma_0^2$

On détermine b tel que $P(Y^2 \geq b) = \alpha$, on décide que :

Si $y^2 < b$, alors on accepte (H_0).

Si $y^2 \geq b$, alors on rejette (H_0).

Test unilatérale :

On test (H_0) l'hypothèse nulle contre l'hypothèse (H_1).

(H_0) l'hypothèse nulle : $\sigma^2 = \sigma_0^2$

(H_1) l'hypothèse : $\sigma^2 < \sigma_0^2$

On détermine a tel que $P(Y^2 \geq a) = 1 - \alpha$, on décide que :

Si $y^2 > a$, alors on accepte (H_0).

Si $y^2 \leq a$, alors on rejette (H_0) avec une probabilité α de se tromper.

0.7.6 Test d'homogénéité :

Il s'agit de comparer deux échantillons. L'hypothèse (H_0) est qu'ils proviennent d'une même population.

0.7.7 Comparaison de deux moyennes :

Dans deux populations P_1 et P_2 ; on étudie une variable aléatoire X .

On note :

μ_1 et σ_1 la moyenne et l'écart-type de X dans P_1 .

μ_2 et σ_2 la moyenne et l'écart-type de X dans P_2 .

De P_1 on extrait un échantillon E_1 de taille n_1 ; pour lequel on calcule sa moyenne \bar{x}_1 et s_1 estimation de σ_1 .

De P_2 on extrait un échantillon E_2 de taille n_2 ; pour lequel on calcule sa moyenne \bar{x}_2 et s_2 estimation de σ_2 .

les échantillons E_1 et E_2 sont supposés indépendantes. le problème est de savoir si les différence entre les moyennes expérimentales \bar{x}_1 et \bar{x}_2 est significative, ou contraire explicable par les fluctuations d'échantillonnage.

1) Cas de grand échantillons indépendants :

On suppose que $n_1 > 30$ et $n_2 > 30$

Théorème 7 *Quelle que soit la loi suivie par X , la v.a $Z = \frac{\bar{X}_1 - \bar{X}_2}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}}$ suit la loi normale centrée réduite.*

On calcule $z = \frac{\bar{x}_1 - \bar{x}_2}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}}$

0.7.8 Test bilatéral :

(H_0) $\mu_1 = \mu_2$ c'est à dire $P_1 = P_2$ sont homogènes.

(H_1) $\mu_1 \neq \mu_2$

α étant fixé, on lit z_α tel que : $P(|Z| \geq z_\alpha) = \alpha$

Si $z \in] - z_\alpha, z_\alpha[$; on accepte (H_0)

Si $z \notin] - z_\alpha, z_\alpha[$; on rejette (H_0).

0.7.9 Test unilatérale :

(H_0) : $\mu_1 = \mu_2$ conte (H_1) $\mu_1 > \mu_2$

On détermine z_α tel que $P(Z < z_\alpha) = 1 - \alpha$ et on décide que :

Si $z < z_\alpha$, alors on accepte (H_0).

Si $z \geq z_\alpha$, alors on rejette (H_0).

(H_0) : $\mu_1 = \mu_2$ conte (H_1) $\mu_1 < \mu_2$

On détermine z'_α tel que $P(Z \geq z'_\alpha) = 1 - \alpha$ et on décide que :

Si $z > z'_\alpha$, alors on accepte (H_0).

Si $z \leq z_\alpha$, alors on rejette (H_0) .

2) Cas de petits échantillons extraits de populations gaussiennes :

On suppose $n_1 < 30$ et $n_2 < 30$ et $\sigma = \sigma_1 = \sigma_2$

Théorème 8 Si X suit une loi normale dans P_1 et P_2 et si $\sigma = \sigma_1 = \sigma_2$; Alors la variable aléatoire $T = \frac{\bar{X}_1 - \bar{X}_2}{\sigma \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}}$ suit la loi de student à $(n_1 + n_2 - 2)$ degrés de liberté.

Remarque 9 : Comme on ne connaît pas σ_1 et σ_2 ; il faut d'abord tester l'égalité des deux variances. Si l'hypothèse $\sigma_1 = \sigma_2$ est retenue, cette valeur commune σ est alors estimée par : $\hat{\sigma} = \sqrt{\frac{(n_1-1)s_1^2 + (n_2-1)s_2^2}{n_1 + n_2 - 2}}$

On calcul $t = \frac{\bar{x}_1 - \bar{x}_2}{\hat{\sigma} \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}}$

0.7.10 Test bilatéral :

α étant fixé, on lit t_α tel que : $P(|T| \geq t_\alpha) = \alpha$

Si $t \in] -t_\alpha, t_\alpha[$; on accepte (H_0)

Si $t \notin] -t_\alpha, t_\alpha[$; on rejette (H_0) .

0.7.11 Test unilatéral :

$(H_0) : \mu_1 = \mu_2$ contre $(H_1) \mu_1 > \mu_2$

On détermine t_α tel que $P(T < t_\alpha) = 1 - \alpha$ et on décide que :

Si $t < t_\alpha$, alors on accepte (H_0) .

Si $t \geq t_\alpha$, alors on rejette (H_0) .

$(H_0) : \mu_1 = \mu_2$ contre $(H_1) \mu_1 < \mu_2$

On détermine t_α tel que $P(T \geq t_\alpha) = 1 - \alpha$ et on décide que :

Si $t > t_\alpha$, alors on accepte (H_0) .

Si $t \leq t_\alpha$, alors on rejette (H_0) .

3) Cas des échantillons appariés :

Deux échantillons E_1 et E_2 sont dits **appariés** lorsque chaque observation $x_{1,i}$ de E_1 est associée à une valeur $x_{2,i}$ de E_2 (appariés=associés par paires). C'est par exemple le cas lorsque E_1 et E_2 proviennent d'un même groupe de malades avant et après traitement. Deux échantillons appariés ont donc la même taille $n = n_1 = n_2$.

3.1) Cas des grands échantillons appariés :

On suppose que $n = n_1 = n_2 > 30$, et que les échantillons E_1 et E_2 sont appariés.

On considère la variable aléatoire $D = X_1 - X_2$, dont un échantillon est (D_1, D_2, \dots, D_n) avec $D_i = X_{1,i} - X_{2,i}$ la moyenne et la variance d'échantillon sont :

$$\bar{D} = \frac{\sum D_i}{n} \quad \text{et} \quad S_d^2 = \frac{n}{n-1} S_{d,e}^2 \quad \text{avec} \quad S_{d,e}^2 = \frac{\sum D_i^2}{n} - (\bar{D})^2$$

Désignons par $\mu = \mu_1 - \mu_2$ la moyenne de D .

Puisque $n > 30$, $U = \frac{\bar{D} - \mu}{\frac{S_d}{\sqrt{n}}}$ suit la loi normale $N(0, 1)$.

Test bilatéral :

L'hypothèse (H_0) : $\mu_1 = \mu_2$ contre (H_1) $\mu_1 \neq \mu_2$

Ce test est équivalent au test bilatéral de (H_0) : $\mu = 0$ contre (H_1) : $\mu \neq 0$

Test unilatéral :

L'hypothèse (H_0) : $\mu_1 = \mu_2$ contre (H_1) $\mu_1 > \mu_2$

Ce test est équivalent au test bilatéral de (H_0) : $\mu = 0$ contre (H_1) : $\mu > 0$

3.2) Cas des petits échantillons appariés extraits de populations gaussiennes :

On suppose que $n = n_1 = n_2 \leq 30$, et que les échantillons E_1 et E_2 sont appariés. et que X_1 et X_2 suivent les lois normales $N(\mu_1, \sigma_1)$ et $N(\mu_2, \sigma_2)$

Dans ce cas $T = \frac{\bar{D} - \mu}{\frac{S_d}{\sqrt{n}}}$ suit la loi de Student à $(n - 1)$ degrés de liberté.

0.7.12 Comparaison de deux fréquences :

Dans deux populations P_1 et P_2 on étudie un caractère statistique à deux modalités A et \bar{A} . Les pourcentages d'apparition de A dans les populations P_1 et P_2 sont p_1 et p_2 . De P_1 et P_2 on extrait deux échantillons E_1 et E_2 de taille n_1 et n_2 dans lesquels les fréquences d'apparition de A sont respectivement f_1 et f_2 .

Notons F_1 et F_2 les variables aléatoires qui prennent les valeurs f_1 et f_2 sur chaque échantillon.

Test bilatérale :

$$(H_0) p_1 = p_2 = p$$

$$(H_1) p_1 \neq p_2$$

Théorème 10 *Supposons que : $n_1 \geq 30$ et $n_2 \geq 30$; $n_1 f_1 \geq 5$ et $n_1(1 - f_1) \geq 5$; $n_2 f_2 \geq 5$ et $n_2(1 - f_2) \geq 5$; Alors la v.a $Z = \frac{F_1 - F_2}{\sqrt{\frac{p(1-p)}{n_1} + \frac{p(1-p)}{n_2}}}$ suit la loi normale centrée réduite.*

Estimation de p : on l'estime p par $\hat{p} = \frac{n_1 f_1 + n_2 f_2}{n_1 + n_2}$

$$\text{On calcule } z = \frac{f_1 - f_2}{\sqrt{\hat{p}(1-\hat{p})\left(\frac{1}{n_1} + \frac{1}{n_2}\right)}}$$

Puis on choisit α le risque, on lit dans la table z_α tel que : $P(|Z| \geq z_\alpha) = \alpha$

Si $z \in] - z_\alpha, z_\alpha[$; on accepte (H_0)

Si $z \notin] - z_\alpha, z_\alpha[$; on rejette (H_0) .

Test unilatérale :

On a $(H_0) p_1 = p_2$ contre $(H_1) p_1 > p_2$

Dans ce cas on a toujours $z > 0$

On détermine alors z_α tels que : $P(Z \geq z_\alpha) = \alpha$

Si $z < z_\alpha$; on accepte (H_0)

Si $z \geq z_\alpha$; on rejette (H_0)

0.7.13 Comparaison de deux variances :

Dans deux populations P_1 et P_2 ; on étudie une variable aléatoire X .

On note :

μ_1 et σ_1 la moyenne et l'écart-type de X dans P_1 .

μ_2 et σ_2 la moyenne et l'écart-type de X dans P_2 .

De P_1 on extrait un échantillon E_1 de taille n_1 ; pour lequel on calcule sa moyenne \bar{x}_1 et s_1 estimation de σ_1 .

De P_2 on extrait un échantillon E_2 de taille n_2 ; pour lequel on calcule sa moyenne \bar{x}_2 et s_2 estimation de σ_2 .

les échantillons E_1 et E_2 sont supposés indépendantes. le problème est de savoir si les différence entre les moyennes expérimentales s_1^2 et s_2^2 est significative, ou au contraire explicable par les fluctuations d'échantillonnage.

On teste (\mathbf{H}_0): $\sigma_1^2 = \sigma_2^2$ contre (\mathbf{H}_1) : $\sigma_1^2 \neq \sigma_2^2$

Théorème 11 *Si les deux population sont gaussiennes, la variable aléatoire $F = \frac{S_1^2}{S_2^2}$ suit la loi de Snédécour à $(n_1 - 1, n_2 - 1)$ degrés de liberté.*

On calcule $f = \frac{s_1^2}{s_2^2}$; Si nécessaire, on permute les échantillons de sorte que $f \geq 1$. le risque α étant fixé; on détermine f_α tel que :

$$P(F \geq f_\alpha) = \frac{\alpha}{2} \text{ (on utilise la table de Snédécour) et on décide que :}$$

Si $f < f_\alpha$ alors on accepte (\mathbf{H}_0).

Si $f \geq f_\alpha$ on rejette (\mathbf{H}_0).

Lois de Snédécour :

Une loi de Snédécour est une loi de probabilité continue dont la densité est nulle pour $x < 0$ et dépend de deux paramètres appelés degrés de liberté.

Le risque α étant fixé, la table de Snédécour permettent de déterminer f_α et f'_α tel que : $P(f'_\alpha < F < f_\alpha) = 1 - \alpha$

$$\text{avec } P(F \leq f'_\alpha) = \frac{\alpha}{2} \quad \text{et } P(F \geq f_\alpha) = \frac{\alpha}{2}.$$