

Chapitre III

Comparaison

(1)

1) Test d'hypothèse

A partir des données d'un échantillon d'une population Ω on teste si celles-ci sont conformes à un modèle précis, à des paramètres connus, etc. On pourra aussi tester à partir de deux échantillons de deux populations distinctes, les caractéristiques de deux variables aléatoires, etc.

Cela se fait à travers une analyse qui permet de prendre une décision tout en ayant une estimation du risque d'erreur.

Le cadre est celui d'un problème de décision entre une hypothèse notée H_0 , hypothèse nulle, et une autre hypothèse dite H_1 .

Ici les hypothèses portent sur les paramètres d'une variable aléatoire.

• On testera par exemple l'hypothèse

$$H_0: \theta = \theta_0, \text{ où } \theta = \text{paramètre d'une v.a.}$$

Alors $H_1: \theta \neq \theta_0$: test bilatéral. (2)

Or encore $M_0: \theta > \theta_1$ et $M_1: \theta < \theta_1$
test unilatéral.

• la situation est alors la suivante :

réalité / décision	H_0 vraie	H_0 fausse
ne pas rejeter H_0	Vrai positif	Faux positif
rejeter H_0	Faux Négatif	Vrai Négatif

VP et VN sont de bonnes décisions.

FN : erreur de 1^{re} espèce.

FP : erreur de 2^{de} espèce.

FN: On note α la probabilité de rejeter à tort H_0 .
 α est appelé niveau du test (ou seuil)

FP: β = probabilité d'accepter H_0 à tort.

$1 - \beta$ = puissance du test.

Les tests d'hypothèse ne permettent pas d'accepter H_0
mais seulement de rejeter H_0 / ne pas rejeter H_0 .

Region critique W

Etant donné un échantillon, celui-ci donne lieu à des observations et à une valeur pour un certain paramètre θ . Si θ se trouve dans W , on rejette H_0 . Sinon on ne rejette pas H_0 .

W dépend de α

\bar{W} = complémentaire de W .

Demarche a suivre.

(4)

- ① On formule H_0 et H_1 avec le fait que ce qui est important est le rejet de H_0 .
- ② On fixe α . Probabilité de rejeter H_0 à tort.
- ③ On détermine la région critique W .
- ④ On regarde si la quantité issue des observations se trouve dans W .
Ou encore si Φ est dans W .
- ⑤ Conclusion: on rejette ou non H_0 .

rejeter H_0 : conclusion forte
ne pas rejeter H_0 : conclusion faible

2) Comparaison d'une moyenne d'un échantillon (5)
avec une moyenne donnée.

On dispose d'un échantillon de taille n sur une population Ω .
Soit la variable aléatoire X sur Ω de moyenne μ et
d'écart-type σ .

On souhaite tester μ vis à vis d'une valeur donnée μ_0 .

$H_0: \mu = \mu_0$
 $H_1: \mu \neq \mu_0$ } test bilatéral.

ici
 $\mu = \theta$

On suppose $X \sim \mathcal{N}(\mu, \sigma)$
avec σ connu.

1 cas

Par hypothèse $\mu = \mu_0$.

Soient X_1, \dots, X_n n v.a.i avec $X_i \sim \mathcal{N}(\mu_0, \sigma)$.

$\bar{X} = \frac{X_1 + \dots + X_n}{n}$ moyenne empirique.

Alors $\frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}} \sim \mathcal{N}(0, 1)$.

On fixe le seuil α .

(6)

→ $t_{\alpha/2}$ donné par $N(0,1)$: probabilités bilatérales.


La probabilité que $\left| \frac{\bar{x} - \mu_0}{\sigma/\sqrt{n}} \right| \geq t_{\alpha/2}$ vaut α .

Or encore:

\bar{x} est en dehors de $[\mu_0 - t_{\alpha/2} \sigma/\sqrt{n}; \mu_0 + t_{\alpha/2} \sigma/\sqrt{n}]$ avec une probabilité α .

Région critique W .

$$W = [\mu_0 - t_{\alpha/2} \sigma/\sqrt{n}; \mu_0 + t_{\alpha/2} \sigma/\sqrt{n}]$$



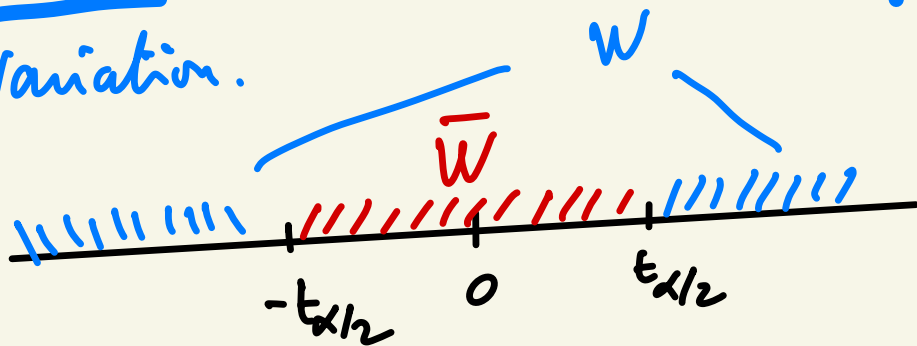
Sous μ_0 , \bar{x} est dans W avec une petite probabilité.

Si x est dans W : on rejette μ_0 . Risque d'erreur contrôlé par α .

Interprétation, Dans la famille des échantillons de taille n , la proportion de ceux pour lesquels \bar{x} est dans W est égale à α .

Or encore: il est "rare" que la moyenne \bar{x} d'un échantillon tombe dans W ... ainsi, lorsque cela arrive, on peut du principe qu'il y a une anomalie et donc que l'hypothèse de départ n'est pas bonne!
D'où le rejet de H_0 .

Variation.



On teste si $\frac{\bar{x} - \mu_0}{\sigma/\sqrt{n}}$ appartient à W :

→ Si oui: on rejette H_0 .

→ Si Non: on ne rejette pas H_0 .

On suppose $X \sim \mathcal{N}(\mu, \sigma)$
avec σ inconnu

(2 cas) 18

• $H_0: \mu = \mu_0$; $H_1: \mu \neq \mu_0$ au seuil α .

• X_1, \dots, X_n n v.a.i telles que $X \sim \mathcal{N}(\mu_0, \sigma)$

Soient $\bar{X} = \frac{X_1 + \dots + X_n}{n}$ et $S^2 = \frac{1}{n-1} \left[(X_1 - \bar{X})^2 + \dots + (X_n - \bar{X})^2 \right]$.

Alors $\frac{\bar{X} - \mu_0}{\frac{S}{\sqrt{n-1}}} \sim \text{St}(n-1)$. (on dans les chapitres précédents)

loi de Student à $n-1$ ddl

• le test porte sur la quantité $\frac{\bar{x} - \mu_0}{\hat{\sigma}/\sqrt{n}}$ où :

• $\bar{x} = \frac{x_1 + \dots + x_n}{n}$

• $\hat{\sigma} = \sqrt{\frac{1}{n-1} \left[(x_1 - \bar{x})^2 + \dots + (x_n - \bar{x})^2 \right]}$

• Région $\bar{W} = [-t_{\alpha/2}; t_{\alpha/2}]$

donnée par $\text{St}(n-1)$.

On rejette H_0 si $\frac{\bar{X} - \mu_0}{\hat{\sigma}/\sqrt{n}}$ n'est pas dans W

X quelconque, n grand

3^e cas

- $H_0: \mu = \mu_0 \rightarrow$ moyen de X . $H_1: \mu \neq \mu_0$
au sein α
- X_1, \dots, X_n n v.d.i avec $X_i \sim X$

On utilise le théorème central-limite.

$$\bar{X} = \frac{X_1 + \dots + X_n}{n}; \quad \bar{x} = \begin{array}{l} \text{réalisation de } \bar{X} \\ \text{= moyen issu de l'échantillon} \end{array}$$

Soit $\hat{\sigma} = \sqrt{\frac{1}{n-1} (x_1 - \bar{x})^2 + \dots + (x_n - \bar{x})^2}$ l'estimation ponctuelle de l'écart-type σ de X .

Alors $\frac{\bar{X} - \mu_0}{\hat{\sigma}/\sqrt{n}}$ proche de $\mathcal{N}(0, 1)$.
(n grand)

• $\bar{W} = [-t_{\alpha/2}; t_{\alpha/2}]$.

↑ donné par $\mathcal{N}(0,1)$

On rejette H_0 si $\frac{\bar{x} - \mu_0}{\hat{\sigma}/\sqrt{n}}$ n'est pas dans \bar{W} .

Si non, on ne rejette pas H_0 .

Tout ou une proportion
pour n grand.

$X \sim \mathcal{B}(p)$: loi de Bernoulli.

• $H_0: p = p_0$; $H_1: p \neq p_1$ au seuil α .

• Ici $\sigma^2 = p(1-p) = p_0(1-p_0)$ par hypothèse.

Par conséquent $\frac{\bar{X} - p_0}{\sqrt{\frac{p_0(1-p_0)}{n}}}$ proche de $\mathcal{N}(0,1)$

(théorème central limite)

- $\bar{W} = [-t_{\alpha/2}; t_{\alpha/2}]$

↳ donné par $\mathcal{N}(0, 1)$.


(11)

Si $\frac{\bar{x} - \mu_0}{\sqrt{\frac{p_0(1-p_0)}{n}}}$ ne tombe pas dans \bar{W} , on rejette H_0

test unilatéral pour une moyenne n grand.

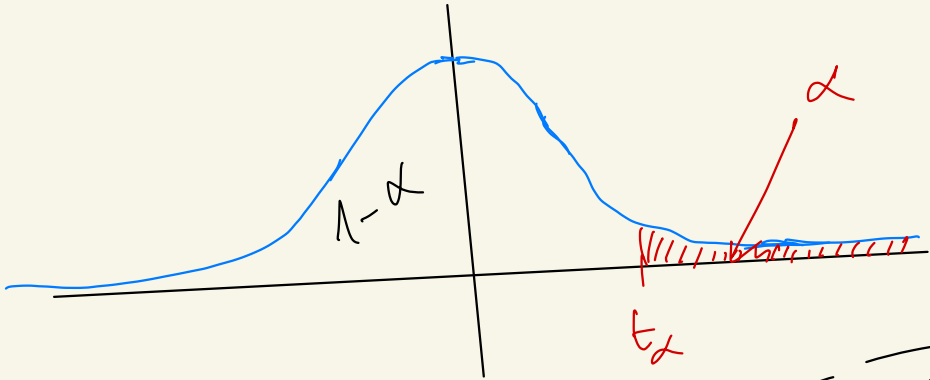
• $H_0: \mu \leq \mu_0$; $H_1: \mu > \mu_0$ au seul d.

• Région critique: W (à droite)



t_α est donné par la table de $\mathcal{N}(0,1)$:

(12)



x_i : échantillon

\bar{x} = moyenne de l'échantillon

$\hat{\Delta} = \sqrt{\frac{1}{n-1} \left((x_1 - \bar{x})^2 + \dots + (x_n - \bar{x})^2 \right)}$ proche de l'écart. type de x

Par le théorème central limite, on sait que

$\frac{\bar{X} - \mu}{\hat{\Delta}/\sqrt{n}}$ est proche de $\mathcal{N}(0,1)$. (ici n grand)

Supposons $\frac{\bar{x} - \mu_0}{\hat{\Delta}/\sqrt{n}} \geq t_\alpha$, alors comme $\mu_0 \geq \mu$ il vient:

$$\frac{\bar{x} - \mu}{\hat{\Delta}/\sqrt{n}} \geq t_\alpha.$$

Ainsi cela arrive avec une probabilité plus petite que α donc petite.


"On pense que ce n'est pas possible".

On rejette alors H_0 .



test unilatéral à gauche.

$H_0: \mu \geq \mu_0$; $H_1: \mu < \mu_0$



Example - Election entre deux candidats A et B. (1)

p = proportion pour A ; $q = 1 - p$ = proportion pour B.

Un sondage sur 800 personnes aboutit à $\bar{p} = 0,48$

$$\bar{q} = 0,52.$$

Seuil $\alpha = 5\% = 0,05$.

• Peut-on affirmer que $p < 0,5$?

$H_0: p \geq 0,5$; $H_1: p < 0,5$. Ici: $p_0 = 0,5$.

(à gauche)

$$\alpha = 0,05 \rightarrow t_{\alpha} = 1,64.$$

Région critique $W =]-\infty; -1,64]$.

le test porte sur: $\frac{\bar{p} - 0,5}{1/\sqrt{800}}$ avec $\Delta = \sqrt{0,48 \times 0,52}$.

15

-1,13

$\bar{p} = 0,48$
: (on ne rejette pas H_0)

• Que peut-on dire si le sondage porte sur $n = 2000$ avec $\bar{p} = 0,48$ et $\bar{q} = 0,52$?


ici le test porte sur $\frac{0,48 - 0,50}{\Delta/\sqrt{2000}} \approx -1,79$

On rejette $H_0: p < 0,5$ au risque d'erreur de 5%

3) Comparaison de deux moyennes.

On part de deux populations A et B et de deux échantillons extraits de ces populations. Soient X et Y deux v.a.i. sur chacune de ces populations.

On cherche à comparer μ_A et μ_B .



σ_A : écart. type de X

σ_B : écart. type de Y

n_A : taille de l'échantillon issu de A

n_B : _____ B

$$\bar{X} = \frac{X_{1A} + \dots + X_{n_A A}}{n_A} \quad \text{m}^e \quad X_{1A}, \dots, X_{n_A A} \quad n_A \text{ v.a.i.} \quad X_i \sim N_X.$$

$$\bar{Y} = \frac{Y_{1B} + \dots + Y_{n_B B}}{n_B} \quad \text{m}^e \quad Y_{1B}, \dots, Y_{n_B B} \quad n_B \text{ v.a.i.} \quad Y_i \sim N_Y.$$

On pose $\bar{Z} = \bar{X} - \bar{Y}$

\bar{X} et \bar{Y} sont indépendantes

Alors

$$\mu_{\bar{Z}} = \mu_{\bar{X}} - \mu_{\bar{Y}} = \mu_A - \mu_B$$

et

$$\text{Var}(\bar{Z}) = \text{Var}(\bar{X}) + \text{Var}(\bar{Y}) = \frac{\sigma_A^2}{n_A} + \frac{\sigma_B^2}{n_B}$$

26

$H_0: \mu_A = \mu_B$; $H_1: \mu_A \neq \mu_B$.

Sous H_0 , $\mu_{\bar{Z}} = 0$.

$X \sim \mathcal{N}(\mu_A, \sigma_A)$; $Y \sim \mathcal{N}(\mu_B, \sigma_B)$
avec σ_A et σ_B connus

$\bar{X} \sim \mathcal{N}(\mu_A, \sigma_A/\sqrt{n_A})$ et $\bar{Y} \sim \mathcal{N}(\mu_B, \sigma_B/\sqrt{n_B})$

Alors $\bar{Z} = \bar{X} - \bar{Y} \sim \mathcal{N}(\mu_A - \mu_B, \sqrt{\frac{\sigma_A^2}{n_A} + \frac{\sigma_B^2}{n_B}})$.

Sous H_0 , $\bar{Z} \sim \mathcal{N}\left(0, \sqrt{\frac{\sigma_A^2}{n_A} + \frac{\sigma_B^2}{n_B}}\right)$.

ou encore:

$$\frac{\bar{Z}}{\sqrt{\frac{\sigma_A^2}{n_A} + \frac{\sigma_B^2}{n_B}}} \sim \mathcal{N}(0, 1).$$

• le test porte sur $\frac{\bar{x} - \bar{y}}{\sqrt{\frac{\sigma_A^2}{n_A} + \frac{\sigma_B^2}{n_B}}} = \bar{e}$

\bar{x} = moyenne de l'échantillon de A

\bar{y} = moyenne de l'échantillon de B

• Région critique $\bar{W} = [-t_{\alpha/2}; t_{\alpha/2}]$

↳ par $\mathcal{N}(0, 1)$.

Si \bar{e} ne tombe pas dans \bar{W} , on rejette H_0 au seuil α

2. cas

X et Y quelconques
 n_A et n_B grands

• on estime ponctuellement σ_A et σ_B par:

$$\hat{\sigma}_A = \sqrt{\frac{1}{n_A - 1} \left((x_1 - \bar{x})^2 + \dots + (x_{n_A} - \bar{x})^2 \right)}$$

(x_i = échantillon de A)

$$\hat{\sigma}_B = \sqrt{\frac{1}{n_B - 1} \left((y_1 - \bar{y})^2 + \dots + (y_{n_B} - \bar{y})^2 \right)}$$

(y_i = échantillon de B)

• Par le théorème central limite.

et \bar{X} proche de $\mathcal{N}(\mu_A, \hat{\sigma}_A / \sqrt{n_A})$
 \bar{Y} proche de $\mathcal{N}(\mu_B, \hat{\sigma}_B / \sqrt{n_B})$

Comme pour le cas précédent, on en déduit que $\bar{Z} = \bar{X} - \bar{Y}$ est proche de:

$$d\left(0, \sqrt{\frac{\hat{\Delta}_A^2}{n_A} + \frac{\hat{\Delta}_B^2}{n_B}}\right)$$

• Région critique: $\bar{W} = [-t_{\alpha/2}; t_{\alpha/2}]$

↑ de $d(0, 1)$

Si $\bar{C} = \frac{\bar{x} - \bar{y}}{\sqrt{\frac{\hat{\Delta}_A^2}{n_A} + \frac{\hat{\Delta}_B^2}{n_B}}}$ ne tombe pas dans \bar{W} ,
on rejette H_0
au sein α

lorsque σ_A et σ_B sont inconnus, que n_A ou n_B
est petit mais que X et Y suivent des lois
normales, il est possible d'effectuer un test.
Cela va faire intervenir la loi de Student.

3^e cas

$X \sim \mathcal{N}(\mu_A, \sigma)$
 $Y \sim \mathcal{N}(\mu_B, \sigma)$
 avec σ inconnu.

$\sigma_A = \sigma_B$

• $H_0: \mu_A = \mu_B; H_1: \mu_A \neq \mu_B$.

• Sous $H_0, \bar{Z} = \bar{X} - \bar{Y} \sim \mathcal{N}(0, \sigma \sqrt{\frac{1}{m_A} + \frac{1}{m_B}})$

$$\frac{\bar{Z}}{\sigma \sqrt{\frac{1}{m_A} + \frac{1}{m_B}}} \sim \mathcal{N}(0, 1).$$

problème: "simplifier" σ

• Soit

$$S_A^2 = (X_1 - \bar{X})^2 + \dots + (X_{m_A} - \bar{X})^2$$

$$S_B^2 = (Y_1 - \bar{Y})^2 + \dots + (Y_{m_B} - \bar{Y})^2.$$

"Variances empiriques".

$$\text{Alors } \frac{S_A^2}{\sigma^2} \sim \chi^2(m_A - 1) \text{ et } \frac{S_B^2}{\sigma^2} \sim \chi^2(m_B - 1). \quad (2)$$

$$\text{Snt } T = S_A^2 + S_B^2.$$

$$\text{Alors } \frac{T}{\sigma^2} \sim \chi^2(m_A + m_B - 2).$$

Ainsi

Student

$$\frac{\bar{Z}}{\sqrt{\frac{1}{m_A} + \frac{1}{m_B}}}$$

$$\times \sqrt{m_A + m_B - 2}$$

$$\sim St(m_A + m_B - 2)$$

$$\sqrt{S_A^2 + S_B^2}$$

• Région critique: $\bar{w} = [-t_{\alpha/2}; t_{\alpha/2}]$

$$St(m_A + m_B - 2)$$

Si

$$\bar{e} = \frac{\bar{x} - \bar{y}}{\sqrt{\frac{1}{n_A} + \frac{1}{n_B}} \sqrt{\frac{(n_A-1)\hat{\Delta}_A^2 + (n_B-1)\hat{\Delta}_B^2}{n_A+n_B-2}}}$$

ne tombe pas dans \bar{w} , on rejette H_0 .

n_A

$$\hat{\Delta}_A^2 = \frac{1}{n_A-1} \left((x_1 - \bar{x})^2 + \dots + (x_{n_A} - \bar{x})^2 \right)$$

$$\hat{\Delta}_B^2 = \frac{1}{n_B-1} \left((y_1 - \bar{y})^2 + \dots + (y_{n_B} - \bar{y})^2 \right)$$

4i 600

22

$X \sim \mathcal{N}(\mu_A, \sigma_A)$
 $Y \sim \mathcal{N}(\mu_B, \sigma_B)$
 σ_A et σ_B inconnus

• $H_0: \mu_A = \mu_B$; $H_1: \mu_A \neq \mu_B$.

• On effectue un test sur la quantité :

$$\bar{e} = \frac{\bar{x} - \bar{y}}{\sqrt{\frac{\hat{\Delta}_A^2}{n_A} + \frac{\hat{\Delta}_B^2}{n_B}}}$$

$$\hat{\Delta}_A^2 = \frac{1}{n_A - 1} \left((x_1 - \bar{x})^2 + \dots + (x_{n_A} - \bar{x})^2 \right)$$

$$\hat{\Delta}_B^2 = \frac{1}{n_B - 1} \left((y_1 - \bar{y})^2 + \dots + (y_{n_B} - \bar{y})^2 \right)$$

• Regime critique. $W = [-t_{cr}; t_{cr}]$

(24)

\uparrow
St(N)

où N est l'entier le plus proche de

$$\left(\frac{\hat{\Delta}_A^2}{m_A} + \frac{\hat{\Delta}_B^2}{m_B} \right)^2$$

$$\frac{\left(\frac{\hat{\Delta}_A^2}{m_A} \right)^2}{m_A - 1} + \frac{\left(\frac{\hat{\Delta}_B^2}{m_B} \right)^2}{m_B - 1}$$

4) Comparaison de deux moyennes : populations (15) appariées

- Soient X et Y deux variables aléatoires sur une population Ω .
- On observe n couples d'échantillons $(x_1, y_1), \dots, (x_n, y_n)$
où $x_i = X(\omega_i)$ et $y_i = Y(\omega'_i)$.

Ici $\omega_1, \dots, \omega_n$ ont des individus de Ω .
 $\omega'_1, \dots, \omega'_n$

Éventuellement $\boxed{\omega_i = \omega'_i}$.

- Mathématiquement c'est considéré n couples de v.a. : $(X_1, Y_1), \dots, (X_n, Y_n)$ où :
 - les X_i sont des v.a.i et $X_i \sim X$
 - les Y_i sont des v.a.i et $Y_i \sim Y$
 - X_i et Y_i peuvent ne pas être indépendantes

Exemples.

- Evaluer sur un même individu la taille et le poids
Ici $w_i = w'_i$
- Par un couple marié, évaluer la taille des deux individus.
(H-F)

Ici $w_i \neq w'_i$

X : taille de H.

Y : taille de F.

- Evaluer la consommation d'essence d'une voiture :
à la sortie ; après 10 ans.

Ici $w_i = w'_i$

- On pose :
- μ_X et μ_Y les moyennes de X et de Y
 - $Z_i = X_i - Y_i$. Alors $\mu_{Z_i} = \mu_X - \mu_Y$.
 - $\bar{X} = \frac{X_1 + \dots + X_n}{n}$ et $\bar{Y} = \frac{Y_1 + \dots + Y_n}{n}$
 - $\bar{Z} = \frac{(X_1 - Y_1) + \dots + (X_n - Y_n)}{n} = \bar{X} - \bar{Y}$.

Les variables aléatoires Z_1, \dots, Z_n sont indépendantes.

• Mais attention on ne connaît pas a priori la variance (ou l'écart. type) de Z_i .

En effet:

$$\text{var}(Z_i) = \text{var}(X_i - Y_i) = \text{var}(X_i) + \text{var}(Y_i) + 2\text{cov}(X_i, Y_i)$$

Covariance. peut être non nulle car X et Y non indépendantes.

Notons $\sigma =$ écart. type de $X - Y$.

$$\sigma = \sigma_{X-Y} = \sigma_Z$$

Ici on pose $Z = X - Y$

X et Y quelconques
n grand

1 cas

On utilise la théorème central limite.

- On commence par estimer σ .

(28)

$$\hat{S}^2 = \frac{1}{n-1} \left((z_1 - \bar{z})^2 + \dots + (z_n - \bar{z})^2 \right) : \text{bon estimateur de } \sigma_z^2 = \sigma.$$

$$\begin{aligned} \hat{\Delta}^2 &= \frac{1}{n-1} \left((x_1 - \bar{x} - (y_1 - \bar{y}))^2 + \dots + (x_n - \bar{x} - (y_n - \bar{y}))^2 \right) \\ &= \frac{1}{n-1} \left((x_1 - \bar{x} - (y_1 - \bar{y}))^2 + \dots + (x_n - \bar{x} - (y_n - \bar{y}))^2 \right) \end{aligned}$$

Ainsi $\hat{\Delta}^2$ est une bonne estimation de σ^2 .

- Par le théorème central limite,

$$\bar{z} \text{ proche de } \mathcal{N}(\mu_x - \mu_y, \sigma/\sqrt{n})$$

- Hypothèse $H_0: \mu_x = \mu_y$ (test bilatéral)
 $H_1: \mu_x \neq \mu_y$

Sous H_0 , \bar{Z} proche de $N(0, \hat{\Delta}/\sqrt{n})$

ou encore $\frac{\bar{Z}}{\hat{\Delta}/\sqrt{n}}$ proche de $N(0, 1)$.

• Region critique

$$\bar{W} = [-t_{\alpha/2}; t_{\alpha/2}]$$

donné par $N(0, 1)$.

Statistique $\bar{c} = \frac{\bar{x} - \bar{y}}{\hat{\Delta}/\sqrt{n}}$

avec $\hat{\Delta} = \sqrt{\frac{1}{n-1} \left((x_1 - \bar{x} - (\bar{y} - \bar{y}))^2 + \dots + (x_n - \bar{x} - (\bar{y} - \bar{y}))^2 \right)}$

Si \bar{c} tombe dans \bar{W} , on ne rejette pas H_0
Si \bar{c} ne tombe pas dans \bar{W} , on rejette H_0 .

$$X \sim \mathcal{N}(\mu_x, \sigma_x)$$

$$Y \sim \mathcal{N}(\mu_y, \sigma_y)$$

n petit

$$\hat{Z} \text{ cas}$$

- X_1, \dots, X_n n v.a.i. $X_i \sim X$
 Y_1, \dots, Y_n n v.a.i. $Y_i \sim Y$

$$Z_i = X_i - Y_i.$$

$$\bar{X} = \frac{X_1 + \dots + X_n}{n}; \quad \bar{Y} = \frac{Y_1 + \dots + Y_n}{n}; \quad \bar{Z} = \frac{Z_1 + \dots + Z_n}{n}$$

- Alors $Z_i \sim \mathcal{N}(\mu_x - \mu_y, \sigma)$
 où $\sigma = \sigma_z = \sigma_{x-y}$.

Ainsi $\bar{Z} \sim \mathcal{N}(\mu_x - \mu_y, \sigma/\sqrt{n})$.

(on rappelle que l'on ne connaît pas a priori σ).
 il faut "éliminer" σ .

• Soit $S^2 = (z_1 - \bar{z})^2 + \dots + (z_n - \bar{z})^2$.

(31)

Alors

$$\frac{\bar{z} - (\mu_x - \mu_y)}{\sigma/\sqrt{n}} \sim \mathcal{N}(0, 1)$$

et

$$\frac{S^2}{\sigma^2} \sim \chi^2(n-1)$$

Par conséquent:

$$\frac{\bar{z} - (\mu_x - \mu_y)}{\sqrt{\frac{S^2}{n(n-1)}}} \sim \text{St}(n-1)$$

loi de Student
à $n-1$ ddl.

- $H_0: \mu_x = \mu_y$; $H_1: \mu_x \neq \mu_y$
(test bilatéral)

Sous H_0 , $\frac{\bar{Z}}{\sqrt{\frac{S^2}{n(n-1)}}} \sim St(n-1)$.

- Région critique $\leftarrow St(n-1)$
 $\bar{W} = [-t_{\alpha/2}; t_{\alpha/2}]$

Soit $\bar{C} = \frac{\bar{x} - \bar{y}}{\hat{\sigma} / \sqrt{n}}$

$$\hat{\sigma} = \sqrt{\frac{1}{n-1} \left((z_1 - \bar{z})^2 + \dots + (z_n - \bar{z})^2 \right)}$$


Si \bar{C} ne tombe pas dans \bar{W} , on rejette H_0 .
Si \bar{C} tombe dans \bar{W} , on ne rejette pas H_0 .

test unilatéral

33

$\hat{\mu}$ test à droite

- $H_0: \mu_X \leq \mu_Y$; $H_1: \mu_X > \mu_Y$. (au sein α)
- $W =]t_\alpha; +\infty[$; $\bar{W} =]-\infty; t_\alpha[$.



Ici t_α est donné par $N(0,1)$ si n est grand,
ou par $St(n-1)$ si n est petit.

- la probabilité que $\frac{\bar{Z} - (\mu_X - \mu_Y)}{\hat{\Delta}/\sqrt{n}}$ tombe dans W vaut α .
- or sous H_0 , $\mu_X - \mu_Y \leq 0$, et donc

$$\frac{\bar{z}}{\hat{\delta}/\sqrt{n}} \leq \frac{\bar{z} - (\mu_x - \mu_y)}{\hat{\delta}/\sqrt{n}}.$$


(24)

Ainsi: " $\frac{\bar{z}}{\hat{\delta}/\sqrt{n}} \geq t_\alpha$ " arrive avec une probabilité plus petite que α .

$$\text{Soit } \bar{c} = \frac{\bar{z}}{\hat{\delta}/\sqrt{n}} = \frac{\bar{x} - \bar{y}}{\hat{\delta}/\sqrt{n}}.$$

Si \bar{c} tombe dans W , on rejette H_0 .

Si \bar{c} tombe dans \bar{W} , on ne rejette pas H_0 .




z_α tout à gauche.

• $H_0: \mu_x \geq \mu_y$; $H_1: \mu_x < \mu_y$.

(à droite de z_α)

• Région critique (auil α)

(35)



- $$\bar{c} = \frac{\bar{x} - \bar{y}}{\hat{\sigma} / \sqrt{n}}$$

Si \bar{c} tombe dans W , on rejette H_0 .

Si \bar{c} tombe dans \bar{W} , on ne rejette pas H_0 .

EXEMPLE

- Une étude porte sur les salaires M/F à travers 50 couples.

Soit X la v.a. qui indique le salaire de l'homme ⁽²⁶⁾
 Soit Y _____ la femme.

• $(x_1, y_1) = (2752, 2253) \rightsquigarrow z_1 = x_1 - y_1 = 499$

$(x_2, y_2) = (2893, 1790) \rightsquigarrow z_2 = 1103$

$(x_3, y_3) = (1064, 1212) \rightsquigarrow z_3 = -148$

⋮

$(x_{50}, y_{50}) = (1808, 1287) \rightsquigarrow z_{50} = 521$

X	Y	Z
$\bar{x} = 1941$	$\bar{y} = 1644$	$\bar{z} = 297$
$\sigma_x = 1146$	$\sigma_y = 925$	$\sigma_z = 515$

↑
 écart-typs de l'échantillon de taille 50.

1. t-test

On compare les moyennes μ_x et μ_y .

(37)

• $H_0: \mu_x = \mu_y ; \mu_x \neq \mu_y$

• $\alpha = 5\%$; $t_{\alpha/2} = 1,96$ (lim sup de $U(0,1)$)
 $n \geq 30$.

• $\bar{w} = [-1,96 ; 1,96]$.

• Ici la statistique est la quantité:

$$\bar{c} = \frac{\bar{x} - \bar{y}}{\sqrt{\frac{\hat{\sigma}_x^2}{m} + \frac{\hat{\sigma}_y^2}{n}}} \approx 1,42$$

où $\hat{\sigma}_x \approx \sigma_x$

$\hat{\sigma}_y \approx \sigma_y$

On observe que \bar{c} est dans \bar{w} :

on ne rejette pas H_0 .

2nd test

test bilatéral sur des échantillons
appariés

- $H_0: \mu_x = \mu_y$; $H_1: \mu_x \neq \mu_y$.
- Niveau critique au sein α : $t_{\alpha/2} = 1,96$.
- Ici $\sigma_z \approx 515$.

La statistique est la suivante:

$$\bar{c} = \frac{\bar{z}}{\sigma_z / \sqrt{n}} = \frac{297}{515 / \sqrt{50}} \approx 4,07 \dots$$

On observe que \bar{c} ne tombe pas dans $\bar{w} = [-1,96; 1,96]$.

on rejette H_0 ; on accepte $H_1: \mu_x \neq \mu_y$.

- Prenons $\alpha = 0,002\% = 0,00002$.

$$t_{\alpha} = 4,08 \rightarrow \mathcal{N}(0,1).$$

Ici $\bar{c} = 4,07$ tombe dans $\bar{w} = [-t_{\alpha}; t_{\alpha}]$;
on se rejette pas $H_0: \mu_x \leq \mu_y$.

5) Comparaison de deux variances

Pour le fait de comparaison de deux moyennes on a vu l'importance de l'hypothèse $\sigma_A = \sigma_B$ (pour de petits effectifs) quand X et Y suivent des lois normales.

Ici on propose un protocole pour tester l'hypothèse
 $H_0: \sigma_A = \sigma_B$; $H_1: \sigma_A \neq \sigma_B$.

a) La loi de Fisher - Snedecor


(41)

- Soient deux entiers $m, n \geq 1$.

On pose

$$f(x) = \begin{cases} 0 & \text{si } x \leq 0, \\ \frac{\Gamma\left(\frac{n+m}{2}\right)}{\Gamma\left(\frac{n}{2}\right)\Gamma\left(\frac{m}{2}\right)} \left(\frac{n}{m}\right)^{n/2} \frac{x^{n/2-1}}{\left(1 + \frac{n}{m}x\right)^{\frac{n+m}{2}}} & \end{cases}$$

- La fonction f est une fonction à densité!



- On note par $F(m, n)$ la loi associée : c'est la loi de Fisher - Snedecor.

- On a $\mu_F = m/n-3$ (pour $m \geq 4$) ;
 $\sigma_F = \sqrt{\frac{2m^2(n+m-2)}{n(m-2)^2(m-4)}}$ (pour $m \geq 5$).

Resultats clefs.

① Si $X \sim F(m, n)$ alors $\frac{1}{X} \sim F(n, m)$.


② Si $X_1 \sim \chi^2(m)$ et $X_2 \sim \chi^2(n)$ alors
 $\frac{X_1/m}{X_2/n} \sim F(m, n)$.

b) Quantiles

• Pour une loi X on note par $Q_X(\alpha)$ le nombre tel que

$$P(X \leq Q_X(\alpha)) = \alpha.$$

le nombre $Q_X(\alpha)$ est le **dine-quantile**.



• Amoi

$$\begin{aligned}
 P(X > Q_x(1-\alpha)) &= 1 - P(X \leq Q_x(1-\alpha)) \\
 &= 1 - (1-\alpha) = \alpha
 \end{aligned}$$

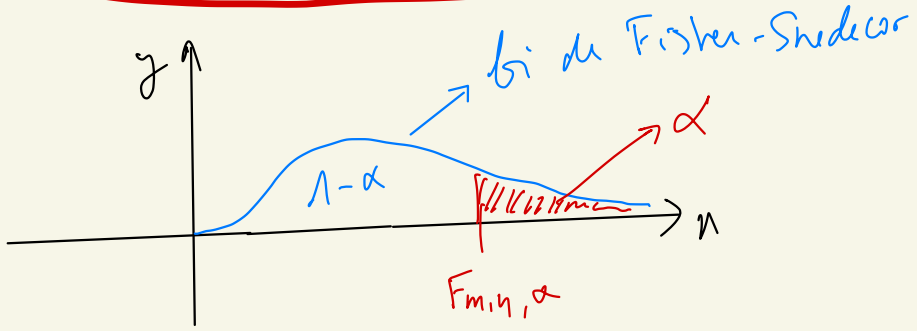
• Résultat

$$Q_x(1-\alpha) = \frac{1}{Q_{1/x}(\alpha)} \quad (\text{facile})$$

• On pose

$$F_{m,n,\alpha} = Q_{F_{m,n}}(1-\alpha)$$

→ bi de Fisher-Snedecor



• Ainsi

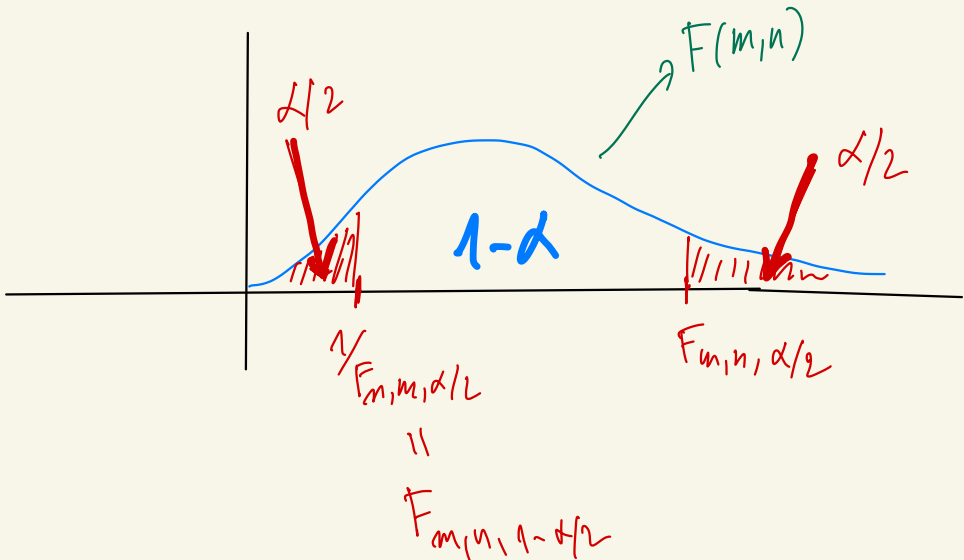
(54)

$$F_{m,n,\alpha} = P_{F_{m,n}}(1-\alpha) = \frac{1}{P_{F_{n,m}}(\alpha)} = \frac{1}{F_{n,m,1-\alpha}}$$

$$F_{m,n,\alpha} = \frac{1}{F_{n,m,1-\alpha}}$$

• Pour α petit, la quantité $F_{m,n,\alpha}$ est plus grande que 1.

Ainsi $F_{m,n,1-\alpha}$ est plus petite que 1.



- Soit la zone critique

(45)

$$\bar{W} = \left[\frac{1}{F_{m, n, \alpha/2}} ; F_{m, n, \alpha/2} \right]$$

Soit le nombre C . Supposons $C > 1$.

Alors C tombe dans \bar{W} si et seulement si

$$C \leq F_{m, n, \alpha/2}.$$

c) test d'égalité sur l'écart-type.

- Soient X et Y deux v.a. normales sur A et B .
On note par σ_A l'écart-type de X ,
 σ_B ————— Y .
- Soient X_1, \dots, X_{n_A} n_A v.a.i. avec $X_i \sim X$.
 Y_1, \dots, Y_{n_B} n_B v.a.i. avec $Y_i \sim Y$.
- Ici n_A et n_B sont petits.

On veut tester l'hypothèse H_0 suivante :

$$H_0: \sigma_A = \sigma_B \quad ; \quad H_1: \sigma_A \neq \sigma_B.$$

$$X \sim \mathcal{N}(\mu_A, \sigma_A) \quad ; \quad Y \sim \mathcal{N}(\mu_B, \sigma_B)$$

$$S_A^2 = (X_1 - \bar{X})^2 + \dots + (X_{m_A} - \bar{X})^2$$

$$S_B^2 = (Y_1 - \bar{Y})^2 + \dots + (Y_{m_B} - \bar{Y})^2$$

On a vu ;

$$\frac{S_A^2}{\sigma_A^2} \sim \chi^2(m_A - 1)$$

$$\frac{S_B^2}{\sigma_B^2} \sim \chi^2(m_B - 1)$$

loi du chi-doux.

- Sous H_0 , $\sigma_A = \sigma_B$, et ainsi:

(CA)

$$\frac{S_A^2/n_A-1}{S_B^2/n_B-1} \sim F(n_A-1, n_B-1).$$

(Sous H_0 , σ_A et σ_B se simplifient).

- Région critique au sein α .

$$\bar{W} = \left[\underset{F}{1} ; F_{n_A-1, n_B-1, \alpha/2} \right]$$

- La statistique \bar{C} est la quantité:

$$\bar{C} = \frac{\hat{\Delta}_A^2}{\hat{\Delta}_B^2}$$

$$\hat{\Delta}_A^2 = \frac{1}{n_A-1} \left((x_1 - \bar{x})^2 + \dots + (x_{\frac{n_A}{2}} - \bar{x})^2 \right)$$

$$\hat{\Delta}_B^2 = \frac{1}{n_B-1} \left((y_1 - \bar{y})^2 + \dots + (y_{\frac{n_B}{2}} - \bar{y})^2 \right)$$

- Supposons $\bar{c} \geq 1$ (ou encore $\hat{\Delta}_A^2 \geq \hat{\Delta}_B^2$).

Alors \bar{c} tombe dans \bar{W} si et seulement si

$$\bar{c} \leq F_{n_A-1, n_B-1, \alpha/2}.$$

Si $\bar{c} < 1$, \bar{c} tombe dans \bar{W} si et seulement si

$$\frac{1}{\bar{c}} \geq F_{n_B-1, n_A-1, \alpha/2}.$$

- Conclusion.

Si \bar{c} ne tombe pas dans \bar{W} , on rejette H_0 .

Si \bar{c} tombe dans \bar{W} , on ne rejette pas H_0 .

Exemple $\alpha = 10\% = 0,1$

$$\alpha/2 = 0,05$$

$$F_{3,5, \alpha/2} = 5,409.$$