

# Probabilités et observations économiques

C. Tuleau-Malot

Université de Nice - Sophia Antipolis

# Plan

## 1 Estimation par intervalle de confiance

Comparaison de la moyenne à une norme :  $\sigma^2$  inconnu

On a toujours  $Z_n = \sqrt{n} \frac{\bar{X}_n - \mu_0}{\sigma} \sim \mathcal{N}(0; 1)$ .

# Comparaison de la moyenne à une norme : $\sigma^2$ inconnu

On a toujours  $Z_n = \sqrt{n} \frac{\bar{X}_n - \mu_0}{\sigma} \sim \mathcal{N}(0; 1)$ .

Mais  $Z_n$  dépend d'un paramètre inconnu

# Comparaison de la moyenne à une norme : $\sigma^2$ inconnu

On a toujours  $Z_n = \sqrt{n} \frac{\bar{X}_n - \mu_0}{\sigma} \sim \mathcal{N}(0; 1)$ .

Mais  $Z_n$  dépend d'un paramètre inconnu :  $\sigma$

## Comparaison de la moyenne à une norme : $\sigma^2$ inconnu

On a toujours  $Z_n = \sqrt{n} \frac{\bar{X}_n - \mu_0}{\sigma} \sim \mathcal{N}(0; 1)$ .

Mais  $Z_n$  dépend d'un paramètre inconnu :  $\sigma$

Donc, on ne peut pas utiliser  $Z_n$  pour déterminer la zone de rejet

## Comparaison de la moyenne à une norme : $\sigma^2$ inconnu

On a toujours  $Z_n = \sqrt{n} \frac{\bar{X}_n - \mu_0}{\sigma} \sim \mathcal{N}(0; 1)$ .

Mais  $Z_n$  dépend d'un paramètre inconnu :  $\sigma$

Donc, on ne peut pas utiliser  $Z_n$  pour déterminer la zone de rejet

On utilise la même astuce que dans la construction d'un intervalle de confiance à variance inconnue

Comparaison de la moyenne à une norme :  $\sigma^2$  inconnu (2)

- on estime  $\sigma^2$  par  $\hat{\sigma}_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$

Comparaison de la moyenne à une norme :  $\sigma^2$  inconnu (2)

- on estime  $\sigma^2$  par  $\hat{\sigma}_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$
- si on a l'hypothèse de normalité sur  $X$ , alors on utilise le fait que  $T_n = \sqrt{n} \frac{\bar{X}_n - \mu_0}{\hat{\sigma}_n} \sim \mathcal{T}(n-1)$

Comparaison de la moyenne à une norme :  $\sigma^2$  inconnu (2)

- on estime  $\sigma^2$  par  $\hat{\sigma}_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$
- si on a l'hypothèse de normalité sur  $X$ , alors on utilise le fait que  $T_n = \sqrt{n} \frac{\bar{X}_n - \mu_0}{\hat{\sigma}_n} \sim \mathcal{T}(n-1)$
- sans hypothèse de normalité et avec  $n$  grand, alors on utilise le fait que  $T_n = \sqrt{n} \frac{\bar{X}_n - \mu_0}{\hat{\sigma}_n} \sim \mathcal{N}(0; 1)$

## Comparaison de la moyenne à une norme : test unilatéral

Qu'est ce qui change si on procède non pas à un test bilatéral mais à un test unilatéral?

# Comparaison de la moyenne à une norme : test unilatéral

Qu'est ce qui change si on procède non pas à un test bilatéral mais à un test unilatéral?

- test unilatéral supérieur ( $\mathcal{H}_0 : \mu \leq \mu_0$ )

La zone de rejet est de la forme  $z_n \in ]t, +\infty[$  avec  $t$  le fractile d'ordre  $1 - \alpha$  d'une loi  $\mathcal{N}(0; 1)$  ou d'une loi  $\mathcal{T}(n - 1)$  selon le cadre

## Comparaison de la moyenne à une norme : test unilatéral

Qu'est ce qui change si on procède non pas à un test bilatéral mais à un test unilatéral?

- test unilatéral supérieur ( $\mathcal{H}_0 : \mu \leq \mu_0$ )

La zone de rejet est de la forme  $z_n \in ]t, +\infty[$  avec  $t$  le fractile d'ordre  $1 - \alpha$  d'une loi  $\mathcal{N}(0; 1)$  ou d'une loi  $\mathcal{T}(n - 1)$  selon le cadre

- test unilatéral inférieur ( $\mathcal{H}_0 : \mu \geq \mu_0$ )

La zone de rejet est de la forme  $z_n \in ] - \infty, -t[$  avec  $t$  le fractile d'ordre  $1 - \alpha$  d'une loi  $\mathcal{N}(0; 1)$  ou d'une loi  $\mathcal{T}(n - 1)$  selon le cadre

## Test pour une proportion

Exemple : On sait qu'en 2008, la proportion de fumeurs dans une population donnée était de 38%. Une enquête menée sur 235 personnes donnent 79 fumeurs. Peut-on affirmer que la proportion de fumeurs a diminué?

# Test pour une proportion

Exemple : On sait qu'en 2008, la proportion de fumeurs dans une population donnée était de 38%. Une enquête menée sur 235 personnes donnent 79 fumeurs. Peut-on affirmer que la proportion de fumeurs a diminué?

Méthodologie :

- on se fixe  $\alpha = 0.05$

## Test pour une proportion

Exemple : On sait qu'en 2008, la proportion de fumeurs dans une population donnée était de 38%. Une enquête menée sur 235 personnes donnent 79 fumeurs. Peut-on affirmer que la proportion de fumeurs a diminué?

### Méthodologie :

- on se fixe  $\alpha = 0.05$
- on choisit les hypothèses :

$$\mathcal{H}_0 : p \geq p_0 = 0.38$$

$$\mathcal{H}_a : p < p_0 = 0.38$$

## Test pour une proportion

Exemple : On sait qu'en 2008, la proportion de fumeurs dans une population donnée était de 38%. Une enquête menée sur 235 personnes donnent 79 fumeurs. Peut-on affirmer que la proportion de fumeurs a diminué?

Méthodologie :

- on se fixe  $\alpha = 0.05$
- on choisit les hypothèses :

$$\mathcal{H}_0 : p \geq p_0 = 0.38$$

$$\mathcal{H}_a : p < p_0 = 0.38$$

- il faut créer une statistique de test à savoir une variable aléatoire dont on connaît la loi

## Test pour une proportion (2)

idée : faire comme on a fait pour la construction de l'intervalle de confiance

$$\Rightarrow \text{utiliser } \hat{p}_n = \frac{1}{n} \sum_{i=1}^n X_i$$

## Test pour une proportion (2)

idée : faire comme on a fait pour la construction de l'intervalle de confiance

$$\Rightarrow \text{utiliser } \hat{p}_n = \frac{1}{n} \sum_{i=1}^n X_i$$

$\Rightarrow$  on sait que cette variable suit approximativement une loi normale d'espérance  $p$  et de variance  $p(1 - p)/n$

$\Rightarrow$  sous  $\mathcal{H}_0$  avec égalité,  $\hat{p}_n$  suit approximativement une loi normale d'espérance  $p_0$  et de variance  $p_0(1 - p_0)/n$

## Test pour une proportion (2)

idée : faire comme on a fait pour la construction de l'intervalle de confiance

⇒ utiliser  $\hat{p}_n = \frac{1}{n} \sum_{i=1}^n X_i$

⇒ on sait que cette variable suit approximativement une loi normale d'espérance  $p$  et de variance  $p(1-p)/n$

⇒ sous  $\mathcal{H}_0$  avec égalité,  $\hat{p}_n$  suit approximativement une loi normale d'espérance  $p_0$  et de variance  $p_0(1-p_0)/n$

calcul de la p-valeur :

## Test pour une proportion (2)

idée : faire comme on a fait pour la construction de l'intervalle de confiance

⇒ utiliser  $\hat{p}_n = \frac{1}{n} \sum_{i=1}^n X_i$

⇒ on sait que cette variable suit approximativement une loi normale d'espérance  $p$  et de variance  $p(1 - p)/n$

⇒ sous  $\mathcal{H}_0$  avec égalité,  $\hat{p}_n$  suit approximativement une loi normale d'espérance  $p_0$  et de variance  $p_0(1 - p_0)/n$

calcul de la p-valeur :

ici  $\hat{p}_n = 79/235$

## Test pour une proportion (2)

idée : faire comme on a fait pour la construction de l'intervalle de confiance

⇒ utiliser  $\hat{p}_n = \frac{1}{n} \sum_{i=1}^n X_i$

⇒ on sait que cette variable suit approximativement une loi normale d'espérance  $p$  et de variance  $p(1-p)/n$

⇒ sous  $\mathcal{H}_0$  avec égalité,  $\hat{p}_n$  suit approximativement une loi normale d'espérance  $p_0$  et de variance  $p_0(1-p_0)/n$

calcul de la p-valeur :

ici  $\hat{p}_n = 79/235$

on calcule  $z_n = \sqrt{n} \frac{\hat{p}_n - p_0}{\sqrt{p_0(1-p_0)}} = \sqrt{235} \frac{79/235 - 0.38}{\sqrt{0.38(1-0.38)}} \approx -1.38$

## Test pour une proportion (2)

idée : faire comme on a fait pour la construction de l'intervalle de confiance

$$\Rightarrow \text{utiliser } \hat{p}_n = \frac{1}{n} \sum_{i=1}^n X_i$$

$\Rightarrow$  on sait que cette variable suit approximativement une loi normale d'espérance  $p$  et de variance  $p(1-p)/n$

$\Rightarrow$  sous  $\mathcal{H}_0$  avec égalité,  $\hat{p}_n$  suit approximativement une loi normale d'espérance  $p_0$  et de variance  $p_0(1-p_0)/n$

calcul de la p-valeur :

$$\text{ici } \hat{p}_n = 79/235$$

$$\text{on calcule } z_n = \sqrt{n} \frac{\hat{p}_n - p_0}{\sqrt{p_0(1-p_0)}} = \sqrt{235} \frac{79/235 - 0.38}{\sqrt{0.38(1-0.38)}} \approx -1.38$$

On calcule  $P(\mathcal{N}(0;1) < z_n)$ ; on trouve  $1-0.9162=0.0838$

## Test pour une proportion (2)

idée : faire comme on a fait pour la construction de l'intervalle de confiance

$$\Rightarrow \text{utiliser } \hat{p}_n = \frac{1}{n} \sum_{i=1}^n X_i$$

$\Rightarrow$  on sait que cette variable suit approximativement une loi normale d'espérance  $p$  et de variance  $p(1-p)/n$

$\Rightarrow$  sous  $\mathcal{H}_0$  avec égalité,  $\hat{p}_n$  suit approximativement une loi normale d'espérance  $p_0$  et de variance  $p_0(1-p_0)/n$

calcul de la p-valeur :

$$\text{ici } \hat{p}_n = 79/235$$

$$\text{on calcule } z_n = \sqrt{n} \frac{\hat{p}_n - p_0}{\sqrt{p_0(1-p_0)}} = \sqrt{235} \frac{79/235 - 0.38}{\sqrt{0.38(1-0.38)}} \approx -1.38$$

On calcule  $P(\mathcal{N}(0;1) < z_n)$ ; on trouve  $1-0.9162=0.0838$

puisque  $0.05 < 0.0838$ , dans le cas présent on ne rejette pas  $\mathcal{H}_0$

## Résumé :

- Test sur la moyenne de la population à variance connue

$$\Rightarrow Z = \frac{\bar{X}_n - \mu_0}{\sigma/\sqrt{n}} \text{ (cadre loi normale ou } n > 30)$$

- test bilatéral : zone de rejet  $] -\infty; -z_{1-\alpha/2}[ \cup ] z_{1-\alpha/2}; +\infty[$
- test unilatéral supérieur : zone de rejet  $] z_{1-\alpha}; +\infty[$
- test unilatéral inférieur : zone de rejet  $] -\infty; -z_{1-\alpha}[$

## Résumé :

- Test sur la moyenne de la population à variance inconnue

$$\Rightarrow T = \frac{\bar{X}_n - \mu_0}{\hat{\sigma}_n / \sqrt{n}}$$

- on sait que loi normale :  $\Rightarrow T \sim T(n-1)$ 
  - test bilatéral : zone de rejet  $] -\infty; -t_{1-\alpha/2}[ \cup ] t_{1-\alpha/2}; +\infty[$
  - test unilatéral supérieur : zone de rejet  $] t_{1-\alpha}; +\infty[$
  - test unilatéral inférieur : zone de rejet  $] -\infty; -t_{1-\alpha}[$
- on ne connaît pas la loi : il faut obligatoirement  $n$  grand et alors on dit que  $T$  suit approximativement une loi normale centrée réduite
  - test bilatéral : zone de rejet  $] -\infty; -z_{1-\alpha/2}[ \cup ] z_{1-\alpha/2}; +\infty[$
  - test unilatéral supérieur : zone de rejet  $] z_{1-\alpha}; +\infty[$
  - test unilatéral inférieur : zone de rejet  $] -\infty; -z_{1-\alpha}[$

## Résumé :

- Test sur une proportion :  $Z = \frac{\bar{p}_n - \varphi_0}{\sqrt{p_0 \cdot (1 - p_0) / \sqrt{n}}}$

approximativement une loi normale centrée réduite

- test bilatéral : zone de rejet  $] -\infty; -z_{1-\alpha/2}[ \cup ] z_{1-\alpha/2}; +\infty[$
- test unilatéral supérieur : zone de rejet  $] z_{1-\alpha}; +\infty[$
- test unilatéral inférieur : zone de rejet  $] -\infty; -z_{1-\alpha}[$

## Comparaison de deux populations

Exemple : On considère deux centres commerciaux et on veut comparer la dépense moyenne des clients dans chacun des centres.

## Comparaison de deux populations

Exemple : On considère deux centres commerciaux et on veut comparer la dépense moyenne des clients dans chacun des centres.

Méthodologie :

- Population 1 avec une moyenne  $m_1$  et une variance  $\sigma_1^2$   
Echantillon 1 :  $(X_1, \dots, X_n)$  et on considère  $X_n = \frac{X_1 + \dots + X_n}{n}$
- Population 2 avec une moyenne  $m_2$  et une variance  $\sigma_2^2$   
Echantillon 2 :  $(Y_1, \dots, Y_l)$  et on considère  $Y_l = \frac{Y_1 + \dots + Y_l}{l}$

## Comparaison de deux populations

Exemple : On considère deux centres commerciaux et on veut comparer la dépense moyenne des clients dans chacun des centres.

Méthodologie :

- Population 1 avec une moyenne  $m_1$  et une variance  $\sigma_1^2$   
Echantillon 1 :  $(X_1, \dots, X_n)$  et on considère  $\bar{X}_n = \frac{X_1 + \dots + X_n}{n}$
- Population 2 avec une moyenne  $m_2$  et une variance  $\sigma_2^2$   
Echantillon 2 :  $(Y_1, \dots, Y_l)$  et on considère  $\bar{Y}_l = \frac{Y_1 + \dots + Y_l}{l}$

Cadre : 2 possibilités

- on suppose que les deux échantillons sont de loi normale et on connaît les variances
- on ne connaît pas les variances et  $l$  et  $n$  grands

## Comparaison de deux populations (2)

Dans les deux cadres, on a :

- $\bar{X}_n$  suit approximativement  $\mathcal{N}(m_1, \sigma_1^2/n)$
- $\bar{Y}_l$  suit approximativement  $\mathcal{N}(m_2, \sigma_2^2/l)$

## Comparaison de deux populations (2)

Dans les deux cadres, on a :

- $\bar{X}_n$  suit approximativement  $\mathcal{N}(m_1, \sigma_1^2/n)$
- $\bar{Y}_l$  suit approximativement  $\mathcal{N}(m_2, \sigma_2^2/l)$

Or nous on veut regarder comment est  $m_1 - m_2$ !

## Comparaison de deux populations (2)

Dans les deux cadres, on a :

- $\bar{X}_n$  suit approximativement  $\mathcal{N}(m_1, \sigma_1^2/n)$
- $\bar{Y}_l$  suit approximativement  $\mathcal{N}(m_2, \sigma_2^2/l)$

Or nous on veut regarder comment est  $m_1 - m_2$ !

$\Rightarrow$  on considère  $\bar{X}_n - \bar{Y}_l$

## Comparaison de deux populations (2)

Dans les deux cadres, on a :

- $\bar{X}_n$  suit approximativement  $\mathcal{N}(m_1, \sigma_1^2/n)$
- $\bar{Y}_l$  suit approximativement  $\mathcal{N}(m_2, \sigma_2^2/l)$

Or nous on veut regarder comment est  $m_1 - m_2$ !

$\Rightarrow$  on considère  $\bar{X}_n - \bar{Y}_l$

$$\bar{X}_n - \bar{Y}_l \sim \mathcal{N}(m_1 - m_2; \sigma_1^2/n + \sigma_2^2/l)$$

## Comparaison de deux populations (2)

Dans les deux cadres, on a :

- $\bar{X}_n$  suit approximativement  $\mathcal{N}(m_1, \sigma_1^2/n)$
- $\bar{Y}_l$  suit approximativement  $\mathcal{N}(m_2, \sigma_2^2/l)$

Or nous on veut regarder comment est  $m_1 - m_2$ !

$\Rightarrow$  on considère  $\bar{X}_n - \bar{Y}_l$

$$\bar{X}_n - \bar{Y}_l \sim \mathcal{N}(m_1 - m_2; \sigma_1^2/n + \sigma_2^2/l)$$

- si  $\sigma_1^2$  et  $\sigma_2^2$  connus : il suffit de connaître  $m_1 - m_2$  pour connaître précisément la loi
- si  $\sigma_1^2$  et  $\sigma_2^2$  inconnus : on les remplace par  $\hat{\sigma}_1^2$  et  $\hat{\sigma}_2^2$  puis il suffit de connaître  $m_1 - m_2$  pour connaître précisément la loi

## Comparaison de deux populations (3)

Test :

$$\mathcal{H}_0 : m_1 = m_2$$

$$\mathcal{H}_a : m_1 \neq m_2$$

## Comparaison de deux populations (3)

Test :

$$\mathcal{H}_0 : m_1 = m_2$$

$$\mathcal{H}_a : m_1 \neq m_2$$

Exemple :  $n = 120$ ,  $l = 150$ ,  $\bar{x}_n = 82$ ,  $\bar{y}_l = 78$ ,  $\hat{\sigma}_1 = 11$ ,  $\hat{\sigma}_2 = 9$  et  $\alpha = 0.1$

## Comparaison de deux populations (3)

Test :

$$\mathcal{H}_0 : m_1 = m_2$$

$$\mathcal{H}_a : m_1 \neq m_2$$

Exemple :  $n = 120$ ,  $l = 150$ ,  $\bar{x}_n = 82$ ,  $\bar{y}_l = 78$ ,  $\hat{\sigma}_1 = 11$ ,  $\hat{\sigma}_2 = 9$  et  $\alpha = 0.1$

- on calcule :  $Z = \frac{\bar{X}_n - \bar{Y}_l}{\sqrt{\hat{\sigma}_1^2/n + \hat{\sigma}_2^2/l}}$

## Comparaison de deux populations (3)

Test :

$$\mathcal{H}_0 : m_1 = m_2$$

$$\mathcal{H}_a : m_1 \neq m_2$$

Exemple :  $n = 120$ ,  $l = 150$ ,  $\bar{x}_n = 82$ ,  $\bar{y}_l = 78$ ,  $\hat{\sigma}_1 = 11$ ,  $\hat{\sigma}_2 = 9$  et  $\alpha = 0.1$

- on calcule :  $Z = \frac{\bar{X}_n - \bar{Y}_l}{\sqrt{\hat{\sigma}_1^2/n + \hat{\sigma}_2^2/l}}$
- $z \simeq 3.21$  et on regarde la p-valeur associée qui est  $P(|\mathcal{N}(0; 1)| > z)$
- on lit 0.0013 et donc on décide de

## Comparaison de deux populations (3)

Test :

$$\mathcal{H}_0 : m_1 = m_2$$

$$\mathcal{H}_a : m_1 \neq m_2$$

Exemple :  $n = 120$ ,  $l = 150$ ,  $\bar{x}_n = 82$ ,  $\bar{y}_l = 78$ ,  $\hat{\sigma}_1 = 11$ ,  $\hat{\sigma}_2 = 9$  et  $\alpha = 0.1$

- on calcule :  $Z = \frac{\bar{X}_n - \bar{Y}_l}{\sqrt{\hat{\sigma}_1^2/n + \hat{\sigma}_2^2/l}}$
- $z \simeq 3.21$  et on regarde la p-valeur associée qui est  $P(|\mathcal{N}(0; 1)| > z)$
- on lit 0.0013 et donc on décide de rejeter  $\mathcal{H}_0$