

Probabilités et observations économiques

C. Tuleau-Malot

Université de Nice - Sophia Antipolis

Plan

- 1 Estimation par intervalle de confiance

Exemples de test

Il existe différents tests :

- Tests d'hypothèse : on va comparer la moyenne sur la population à une valeur de référence
- Tests de comparaison : on va comparer la moyenne de deux populations
- Test d'adéquation : on va regarder si l'on peut considérer que notre variable suit une distribution pré-définie

Exemples de test

Il existe différents tests :

- Tests d'hypothèse : on va comparer la moyenne sur la population à une valeur de référence
- Tests de comparaison : on va comparer la moyenne de deux populations
- Test d'adéquation : on va regarder si l'on peut considérer que notre variable suit une distribution pré-définie
- Test d'indépendance : on va voir si deux variables aléatoires sont indépendantes ou non

Stratégie

Dans chacun des cas cités précédemment, on va :

- 1 Définir les hypothèses \mathcal{H}_0 et \mathcal{H}_a

Stratégie

Dans chacun des cas cités précédemment, on va :

- 1 Définir les hypothèses \mathcal{H}_0 et \mathcal{H}_a
- 2 on va calculer une statistique de test (une variable aléatoire) que l'on peut entièrement évaluer à partir d'observations et dont on connaît la loi sous l'hypothèse \mathcal{H}_0

Stratégie

Dans chacun des cas cités précédemment, on va :

- 1 Définir les hypothèses \mathcal{H}_0 et \mathcal{H}_a
- 2 on va calculer une statistique de test (une variable aléatoire) que l'on peut entièrement évaluer à partir d'observations et dont on connaît la loi sous l'hypothèse \mathcal{H}_0
- 3 si la statistique de test, calculée sur l'échantillon, prend une valeur trop improbable, alors on rejette \mathcal{H}_0

Stratégie (2)

- \mathcal{H}_0 et \mathcal{H}_a ne jouent pas le même rôle
- \mathcal{H}_0 : hypothèse à laquelle on souhaite accorder le bénéfice du doute
- on rejette \mathcal{H}_0 que si les observations penchent fortement en faveur de \mathcal{H}_a

Stratégie (2)

- \mathcal{H}_0 et \mathcal{H}_a ne jouent pas le même rôle
- \mathcal{H}_0 : hypothèse à laquelle on souhaite accorder le bénéfice du doute
- on rejette \mathcal{H}_0 que si les observations penchent fortement en faveur de \mathcal{H}_a

Stratégie (3)

Exemple :

Une entreprise cherche à introduire un nouveau produit A, et le fait tester à 150 acheteurs potentiels, en le comparant à un produit concurrent B. 80 disent préférer le produit A. La question qui se pose est : “peut-on conclure que plus de la moitié des consommateurs préfèrent le produit A” .

L'entreprise désirant montrer que son produit est meilleur, il faut prendre :

\mathcal{H}_0 : “moins de la moitié des consommateurs préfèrent le produit A”

\mathcal{H}_a est en général l'hypothèse que l'on veut démontrer.

Cadre

Dans un premier temps, nous nous limitons à des tests de comparaison de la moyenne d'une population ou d'une proportion dans une population, en faisant une comparaison à une valeur de référence.

Cadre

Dans un premier temps, nous nous limitons à des tests de comparaison de la moyenne d'une population ou d'une proportion dans une population, en faisant une comparaison à une valeur de référence.

Si on note μ la moyenne d'une population, il existe différents tests :

- $\mathcal{H}_0 : \mu \leq \mu_0$ et $\mathcal{H}_a : \mu > \mu_0$ (test unilatéral supérieur)
- $\mathcal{H}_0 : \mu \geq \mu_0$ et $\mathcal{H}_a : \mu < \mu_0$ (test unilatéral inférieur)
- $\mathcal{H}_0 : \mu = \mu_0$ et $\mathcal{H}_a : \mu \neq \mu_0$ (test bilatéral)

Cadre (2)

Deux décisions possibles :

- on ne rejette pas l'hypothèse \mathcal{H}_0
- on rejette l'hypothèse \mathcal{H}_0

Cadre (2)

Deux décisions possibles :

- on ne rejette pas l'hypothèse \mathcal{H}_0
- on rejette l'hypothèse \mathcal{H}_0

Cela revient à définir une région de rejet, on savoir un sous-espace de \mathbb{R}^n où l'on décide \mathcal{H}_a Pb : quand on prend une décision, on

peut se tromper. Deux sources d'erreur :

- on rejette \mathcal{H}_0 alors que \mathcal{H}_0 est vrai : erreur de première espèce
- on ne rejette pas \mathcal{H}_0 alors que \mathcal{H}_a est vrai : erreur de deuxième espèce

Cadre (3)

Exemple :

- erreur de première espèce : conclure que plus de la moitié des consommateurs préfèrent le produit A alors que ce n'est pas vrai
- erreur de deuxième espèce : conclure que moins de la moitié des consommateurs préfèrent le produit A alors que ce n'est pas vrai

définition seuil

La probabilité de faire une erreur de première espèce est appelée seuil de signification du test

ce seuil est généralement noté α

ce seuil est généralement fixé arbitrairement au début du test

on ne contrôle pas la probabilité de la seconde erreur!

Comparaison de la moyenne à une norme

Deux cadres :

- σ^2 connu
- σ^2 inconnu

Comparaison de la moyenne à une norme : σ^2 connu

Test bilatéral :

- $\mathcal{H}_0 : \mu = \mu_0$
- $\mathcal{H}_a : \mu \neq \mu_0$

Exemple :

Une chaîne de production remplit des barils de lessive de 5kg. On pèse précisément 36 barils pour savoir si la chaîne est bien réglée, à savoir si la moyenne de remplissage est bien $\mu = 5kg$.

Pour réaliser le test, on suppose que la variable aléatoire X qui n'est autre que le remplissage du baril en kg, suit une loi $\mathcal{N}(\mu; \sigma = 0.05)$. D'après l'énoncé, on a $n = 36$.

Comparaison de la moyenne à une norme : σ^2 connu (2)

Principe :

- On ne connaît pas μ mais on peut l'estimer

Comparaison de la moyenne à une norme : σ^2 connu (2)

Principe :

- On ne connaît pas μ mais on peut l'estimer
- estimateur : \bar{X}_n

Comparaison de la moyenne à une norme : σ^2 connu (2)

Principe :

- On ne connaît pas μ mais on peut l'estimer
- estimateur : \bar{X}_n
- estimation : on calcule \bar{x}_n à partir des 36 observations et si \bar{x}_n est trop éloigné de μ_0 on rejette \mathcal{H}_0

Comparaison de la moyenne à une norme : σ^2 connu (2)

Principe :

- On ne connaît pas μ mais on peut l'estimer
- estimateur : \bar{X}_n
- estimation : on calcule \bar{x}_n à partir des 36 observations et si \bar{x}_n est trop éloigné de μ_0 on rejette \mathcal{H}_0
- que veut dire trop loin?

Comparaison de la moyenne à une norme : σ^2 connu (2)

- Si l'on suppose \mathcal{H}_0 , \bar{X}_n est une loi $\mathcal{N}(\mu_0; \sigma = 0.05/\sqrt{n})$

Comparaison de la moyenne à une norme : σ^2 connu (2)

- Si l'on suppose \mathcal{H}_0 , \bar{X}_n est une loi $\mathcal{N}(\mu_0; \sigma = 0.05/\sqrt{n})$
- si la valeur calculée \bar{x}_n est trop improbable au vu de la distribution de \bar{X}_n , on rejette \mathcal{H}_0

Comparaison de la moyenne à une norme : σ^2 connu (2)

- Si l'on suppose \mathcal{H}_0 , \bar{X}_n est une loi $\mathcal{N}(\mu_0; \sigma = 0.05/\sqrt{n})$
- si la valeur calculée \bar{x}_n est trop improbable au vu de la distribution de \bar{X}_n , on rejette \mathcal{H}_0
- sous \mathcal{H}_0 , $\bar{X}_n \sim \mathcal{N}(\mu_0; \sigma = 0.05/\sqrt{n})$ soit
$$Z_n = \sqrt{n} \frac{\bar{X}_n - \mu_0}{\sigma} \sim \mathcal{N}(0; 1)$$

Comparaison de la moyenne à une norme : σ^2 connu (2)

- Si l'on suppose \mathcal{H}_0 , \bar{X}_n est une loi $\mathcal{N}(\mu_0; \sigma = 0.05/\sqrt{n})$
- si la valeur calculée \bar{x}_n est trop improbable au vu de la distribution de \bar{X}_n , on rejette \mathcal{H}_0
- sous \mathcal{H}_0 , $\bar{X}_n \sim \mathcal{N}(\mu_0; \sigma = 0.05/\sqrt{n})$ soit

$$Z_n = \sqrt{n} \frac{\bar{X}_n - \mu_0}{\sigma} \sim \mathcal{N}(0; 1)$$
- Z_n statistique de test et z_n statistique de test observée (plus $|z_n|$ loin de 0 et plus on préfère \mathcal{H}_a)

Comparaison de la moyenne à une norme : σ^2 connu (2)

Méthode 1 :

- On réfléchit à la région de rejet :

Comparaison de la moyenne à une norme : σ^2 connu (2)

Méthode 1 :

- On réfléchit à la région de rejet : $z_n \in] - \infty; -t[U]t; +\infty[$

Comparaison de la moyenne à une norme : σ^2 connu (2)

Méthode 1 :

- On réfléchit à la région de rejet : $z_n \in] - \infty; -t[\cup]t; +\infty[$
- Il faut trouver t de sorte de contrôler l'erreur de première espèce

Comparaison de la moyenne à une norme : σ^2 connu (2)

Méthode 1 :

- On réfléchit à la région de rejet : $z_n \in] - \infty; -t[U]t; +\infty[$
- Il faut trouver t de sorte de contrôler l'erreur de première espèce
- t est le fractile d'ordre $1 - \alpha/2$ d'une loi normale

Comparaison de la moyenne à une norme : σ^2 connu (2)

Méthode 1 :

- On réfléchit à la région de rejet : $Z_n \in] - \infty; -t[U]t; +\infty[$
- Il faut trouver t de sorte de contrôler l'erreur de première espèce
- t est le fractile d'ordre $1 - \alpha/2$ d'une loi normale

Exemple :

Si $\alpha = 0.05$, alors $t = 1.96$ et ainsi si $z_n = 2.4$ on rejette \mathcal{H}_0 .

Comparaison de la moyenne à une norme : σ^2 connu (2)

Et si on n'avait pas émis l'hypothèse de loi normale sur notre variable d'intérêt X , est ce que cela aurait changé quelque chose?

Comparaison de la moyenne à une norme : σ^2 connu (2)

Et si on n'avait pas émis l'hypothèse de loi normale sur notre variable d'intérêt X , est ce que cela aurait changé quelque chose?

NON

Comparaison de la moyenne à une norme : σ^2 connu (2)

Et si on n'avait pas émis l'hypothèse de loi normale sur notre variable d'intérêt X , est ce que cela aurait changé quelque chose?

NON

En effet, grâce au théorème central limit, on aurait que \bar{X}_n suit approximativement une loi $\mathcal{N}(\mu_0; \sigma = 0.05/\sqrt{n})$

Comparaison de la moyenne à une norme : σ^2 connu (2)

Méthode 2 :

- On calcule z_n

Comparaison de la moyenne à une norme : σ^2 connu (2)

Méthode 2 :

- On calcule z_n
- on calcule $P(|Z_n| \geq z_n)$: cette quantité est appelée la p-valeur

Comparaison de la moyenne à une norme : σ^2 connu (2)

Méthode 2 :

- On calcule z_n
- on calcule $P(|Z_n| \geq z_n)$: cette quantité est appelée la p-valeur
- si p-valeur $< \alpha$: on décide \mathcal{H}_a , sinon on ne rejette pas \mathcal{H}_0

Comparaison de la moyenne à une norme : σ^2 connu (2)

Méthode 2 :

- On calcule z_n
- on calcule $P(|Z_n| \geq z_n)$: cette quantité est appelée la p-valeur
- si p-valeur $< \alpha$) : on décide \mathcal{H}_a , sinon on ne rejette pas \mathcal{H}_0

Exemple : Pour $z_n = 2.4$, on lit p-valeur = 0.0164. Puisque p - valeur $< \alpha$ on rejette \mathcal{H}_0

Comparaison de la moyenne à une norme : σ^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 : σ^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 : σ^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 : σ

Comparaison de la moyenne à une norme : σ^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 : σ

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

Comparaison de la moyenne à une norme : σ^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 : σ

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 : σ^2 inconnu (2)

- on estime σ^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 : σ^2 inconnu (2)

- on estime σ^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 : σ^2 inconnu (2)

- on estime σ^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