

## Formulaire de Statistique et Econométrie

### Chapitre I : Modes de convergence

**Convergence en loi** On dit que  $(X_n)$  converge en loi vers  $X$  ( $X_n \xrightarrow{L} X$ ) si la suite de fonctions  $(F_n)$  converge, point par point, vers  $F$  :

$$\forall x, \lim_{n \rightarrow +\infty} |F_n(X_n) - F(X)| = 0$$

**Convergence en probabilité** On dit que  $(X_n)$  converge en probabilité vers  $X$  ( $X_n \xrightarrow{P} X$  ou  $p \lim_{n \rightarrow +\infty} X_n = X$ ) si

$$\forall \varepsilon > 0, \lim_{n \rightarrow +\infty} Pr(|X_n - X| > \varepsilon) = 0$$

La convergence en probabilité est utilisée pour exprimer la loi faible des grands nombres.

**Convergence presque sûre** On dit que  $(X_n)$  converge presque sûrement vers  $X$  ( $X_n \xrightarrow{ps} X$ ) si et seulement si

$$\forall \varepsilon > 0, \lim_{n \rightarrow +\infty} Pr(|X_i - X| > \varepsilon \forall i \geq n) = 0$$

La convergence presque sûre se distingue de la convergence en probabilité par le fait qu'elle est plus générale ( $\forall i \geq n$ ). Intuitivement, elle implique qu'une fois que la série  $X_n$  s'approche de  $X$ , elle ne s'en écarte pas. On voit rapidement avec la définition (prenons  $i=n$ ) que la convergence presque sûre implique la convergence en probabilité.

$$X_n \xrightarrow{ps} X \Rightarrow X_n \xrightarrow{P} X$$

La convergence presque sûre est utilisée pour exprimer la loi forte des grands nombres.

**Convergence en moyenne quadratique** On dit que  $(X_n)$  converge en moyenne quadratique vers  $X$  ( $X_n \xrightarrow{L^2} X$ ) si

$$\lim_{n \rightarrow +\infty} E[|X_n - X|^2] \rightarrow 0$$

- Propriétés :**
1. Convergence presque sûre  $\Rightarrow$  Convergence en probabilité
  2. Convergence en Moyenne Quadratique  $\Rightarrow$  Convergence en probabilité
  3.  $X_n \rightarrow X$  en Loi  $\Rightarrow \varphi(X_n) \rightarrow \varphi(X)$  en loi pour toute fonction *continue*  $\varphi$
  4.  $E(X_n) \rightarrow c$  et  $V(X_n) \rightarrow 0 \Rightarrow X_n \rightarrow c$  en Moyenne Quadratique

**Estimateur convergent :**  $\text{plim } \varphi(\theta_n) = \theta$  (valeur vraie)

**Théorème de Slutsky :** Si  $f$  est une application réelle continue :  $X_n \rightarrow X$  (en probabilité) alors  $f(X_n) \rightarrow f(X)$  (en probabilité)

De même, si  $g$  est une application réelle continue :  $X_n \rightarrow X$  (en loi) alors  $g(X_n) \rightarrow g(X)$  (en loi)

**Inégalité de Jensen :**  $g[E(x)] \leq E[g(x)]$  pour  $g$  convexe

*Rappel : Inégalité de Chebyshev*

Soit  $X$  une variable aléatoire réelle, discrète ou continue de variance  $V(X)$ , alors

$$\forall \varepsilon > 0, P(|X - E(X)| > \varepsilon) \leq \frac{V(X)}{\varepsilon^2}$$

**Loi faible des grands nombres (Khinchine)** Soit  $(X_i)$  une suite de variables aléatoires réelles indépendantes et identiquement distribuées (iid) d'espérance finie,  $E(X_i) = m$  :

$$\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$$

Alors  $\bar{X}_n \xrightarrow{p} m$

**Théorème central limite** Soit une suite  $(X_n)_{n \in \mathbb{N}}$  de variables aléatoires indépendantes, de même loi, d'espérance  $m$  et de variance finie  $\sigma^2$ . Notons  $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$ . Alors

$$\sqrt{n} \left( \frac{\bar{X}_n - m}{\sigma} \right) \xrightarrow{L} \mathcal{N}(0, 1)$$

## Statistiques Appliquées FORMULAIRE chapitre 2 : Echantillonnage

F. GARDES / P. SEVESTRE

### 1. Echantillonnage sur une population de taille finie :

(a) *Moyenne empirique associée à un échantillon de taille n :*

$$\bar{X}_n = \frac{1}{n} \sum_{i=1}^n Z_i x_i \quad \text{avec } x_i = x(e_i) \text{ et } Z_i \text{ le nombre de fois où } e_i \text{ apparait dans l'échantillon.}$$

– Echantillon tiré avec remise :  $[Z_i \text{ Binomiale}]$

$$E(\bar{X}_n) = m \text{ (moyenne vraie dans la population)}$$

$$V(\bar{X}_n) = \frac{\sigma^2}{n}$$

– Echantillon tiré sans remise : [lois marginales des  $Z_i \sim \mathcal{B}(\frac{n}{N})$ ]

$$\text{Proposition 1 : } E(\bar{X}_n) = m$$

$$\text{Proposition 2 : } V(\bar{X}_n) = \frac{N-n}{N-1} \frac{\sigma_x^2}{n}$$

Proposition 3 :  $V(\bar{X}_n) \downarrow$  quand  $n \uparrow$  (pour les deux types d'échantillons).

(b) *Variances empiriques associées à un échantillon de taille n :*  $S_n^2 = \frac{1}{n} \sum_{i=1}^n Z_i [x_i - \bar{X}_n]^2$

$$\text{Proposition 4 : } E(S_n^2) = \sigma_x^2 - V(\bar{X}_n)$$

$$\text{Proposition 5 : (tirage sans remise) } E(S_n^2) = \frac{n-1}{n} \sigma_x^2$$

$$\text{Proposition 6 : (tirage avec remise) } E(S_n^2) = \frac{N}{N-1} \frac{n-1}{n} \sigma_x^2$$

### 2. Echantillonnage d'un processus aléatoire (population infinie) : $X_i \sim \mathcal{L}$

(a) *Moyenne empirique :*  $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$

$$\text{Proposition 7 : } E(\bar{X}_n) = m$$

$$\text{Proposition 8 : } V(\bar{X}_n) = \frac{\sigma^2}{n}$$

(b) *Variance empirique :*  $S_n^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2$  et  $\bar{S}_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$

$$\text{Proposition 9 : } E(S_n^2) = \frac{n-1}{n} \sigma^2 \quad ; \quad E(\bar{S}_n^2) = \sigma^2$$

Proposition 10 :  $V(S_n^2)$  et  $V(\bar{S}_n^2)$  existent et  $\rightarrow 0$  quand  $n \rightarrow +\infty$

### 3. Echantillons issus d'une loi normale : $X_i \sim \mathcal{N}(m, \sigma^2)$

(a) *Propriétés des moyennes et variances empiriques :*

$$\text{Proposition 11 : Loi de la moyenne empirique : } \bar{X}_n \sim \mathcal{N}(m, \frac{\sigma^2}{n})$$

$$\text{Proposition 12 : Indépendance entre moyenne empirique et variance empirique : } \bar{X}_n \perp (X_i - \bar{X}_n)$$

$$\text{Proposition 13 : } \bar{X}_n \perp S_n^2$$

(b) *Le Théorème de Fisher :*

i. Les v.a.  $(n-1) \frac{S_n^2}{\sigma^2}$  et  $\frac{\bar{X}_n - m}{\sigma/\sqrt{n}}$  sont indépendantes

$$\text{ii. } (n-1) \frac{S_n^2}{\sigma^2} \sim \chi_{(n-1)}^2$$

$$\text{iii. } \frac{X_i - \bar{X}_n}{\sigma} \sim \mathcal{N}\left(0, \sqrt{\frac{n-1}{n}}\right)$$

$$\text{iv. } \text{cov}\left(\frac{X_j - \bar{X}_n}{\sigma}; \frac{X_k - \bar{X}_n}{\sigma}\right) = -\frac{1}{n} \neq 0$$

(c) *Conséquences :*

$$\text{i. } E(S_n^2) = \frac{n-1}{n} \sigma^2 \text{ (résultat général).}$$

$$\text{ii. } V(S_n^2) = \sigma^4 \frac{2(n-1)}{n^2}$$

$$\text{iii. } E(\bar{S}_n^2) = \sigma^2 \quad ; \quad V(\bar{S}_n^2) = 2 \frac{\sigma^4}{n-1}$$

$$\text{iv. } \frac{(\bar{X}_n - m)}{\bar{S}_n/\sqrt{n}} \sim \text{Student}(n-1)$$

## Formulaire de Statistique et Econométrie

### Chapitre III : Estimation ponctuelle

Estimateur : application  $T_n$  de l'échantillon de taille  $n$  sur  $\mathbb{R}^n$  (ou une partie de  $\mathbb{R}^n$ )

Estimateur sans biais (unbiased) :  $E(T_n) = \theta$

Estimateur *asymptotiquement* sans biais :  $E(T_n) \rightarrow \theta$  quand  $n \rightarrow \infty$

Estimateur convergent :  $\text{plim } T_n = \theta$  (valeur vraie)

Estimateur efficace : de variance minimale

*Théorème :*

1. Tout estimateur sans biais dont la variance tend vers 0 (quand  $n$  augmente) est convergent.
2. Tout estimateur *asymptotiquement* sans biais dont la variance tend vers 0 (quand  $n$  augmente) est convergent.

**Inégalité de Cramer-Rao :** Il existe une borne inférieure pour l'ensemble des variances des estimateurs sans biais :  $V_{\theta}(T_n) \geq 1/I_n(\theta)$  avec  $I_n(\theta)$  la quantité d'information de Fisher :

$$I_n(\theta) = E_{\theta}(-\partial^2 \ln L / \partial \theta^2) = E_{\theta}(\partial \ln L / \partial \theta)^2$$

Estimation par le principe des *Moindres Carrés* :  $\text{Min } \sum_{i=1}^n (y_i - \theta)^2$

Estimation par le principe du *Maximum de Vraisemblance* :  $\text{Max}_{\theta} L(x_1, x_2, \dots, x_n; \theta) =$   
Probabilité d'observer le  $n$ -uplet  $(x_1, x_2, \dots, x_n)$ .

Estimation par la *Méthode des Moments* : résolution des équations : moment empirique de degré  $p = f_p(\theta)$

**Formulaire de Statistique et Econométrie**  
**Chapitre IV : Estimation par Intervalle de Confiance**

Estimation par Intervalle de Confiance d'une *moyenne*  $X_n$  :

1. *Grands échantillons* :  $X_n \sim N(\mu, \sigma/\sqrt{n})$  par le théorème Central Limite (pour  $n$  grand  $>30$ )
2. *Petits échantillons* : - Distribution normale des v.a  $x_i$ ,  $\sigma$  connue :  $X_n \sim N(\mu, \sigma/\sqrt{n})$   
 - Distribution normale des v.a  $x_i$ ,  $\sigma$  inconnue :  $\sqrt{n} (X_n - \mu)/S \sim$  Student à  $(n-1)$  degrés de liberté  $T(n-1)$ , avec  $S$  l'écart-type empirique corrigé.

Estimation d'une proportion :  $p_n \sim$  loi normale si  $np(1-p) \geq 15$  ; variance =  $p(1-p)/n$

v.a. pivotale : fonction du paramètre estimé dont on connaît la distribution statistique ;  
 exemple :  $(X_n - \mu) / \sigma/\sqrt{n} \sim N(0,1)$

*Théorème* : Si la distribution est unimodale et symétrique, les Intervalles de Confiance bilatéraux sont *de longueur minimale*.

IC pour les lois usuelles :

- (i) Moyenne d'une loi normale :  $X_n \pm u_{\alpha/2} s'_n/\sqrt{n}$
- (ii) Variance d'une loi normale :  $(n-1)s'_n/\sigma \sim \chi^2(n-1)$   
 soit  $(n-1)s'_n{}^2/u_{1-\alpha/2} \leq \sigma^2 \leq (n-1)s'_n{}^2/u_{\alpha/2}$
- (iii) Ecart-type d'une loi normale :  $s'_n \sqrt{(n-1)/u_{1-\alpha/2}} \leq \sigma \leq s'_n \sqrt{(n-1)/u_{\alpha/2}}$
- (iv) IC pour une Proportion :  $\sqrt{n}[(X_n - p)/(X_n(1-X_n))^{0.5}]$ , donc :  
 $IC = X_n \pm u_{\alpha/2} \{ X_n(1-X_n)/n \}^{0.5}$
- (v) IC pour un rapport de variances de lois normales  $(n-1) s'_n{}^2/\sigma^2 \sim (n-1) \Rightarrow$   
 $IC(\sigma_B^2/\sigma_A^2) = [u_{\alpha/2} s'_B{}^2/s'_A{}^2, u_{1-\alpha/2} s'_B{}^2/s'_A{}^2]$
- (vi) IC pour la différence des espérances de deux lois normales :  
 -  $\sigma_i$  connues :  $(X_{1n} - X_{2n}) - (\mu_1 - \mu_2) / \sqrt{(\sigma_1^2/n_1 + \sigma_2^2/n_2)} \sim N(0,1)$  (a)  
 -  $\sigma_i$  inconnues :  $s'_i{}^2$  tend en proba vers  $\sigma_i^2$ , donc IC (a) avec les variances empiriques corrigées  $s'_i{}^2$ .

## Formulaire de Statistique et Econométrie

### Chapitre VI : Tests d'hypothèses

*Erreur de première espèce* : Rejet de l'hypothèse nulle  $H_0$  alors qu'elle est vraie

*Erreur de seconde espèce* : Acceptation de l'hypothèse nulle  $H_0$  alors qu'elle est fautive ( $H_1$  est vraie)

*Seuil de signification* du test (seuil d'erreur du test):  $\alpha$  = probabilité maximale de commettre une erreur de première espèce (par exemple fixée à 5 ou 1%) =  $\text{Prob}(D_1|H_0)$

*Région* (dans l'espace des paramètres) *critique* : région de rejet de l'hypothèse nulle  $H_0$

*Région d'acceptation* : région d'acceptation de l'hypothèse nulle  $H_0$

*Test unilatéral* :  $H_0 : \mu \geq 3$       $H_1 : \mu < 3$

*Test bilatéral* :  $H_0 : \mu = 3$       $H_1 : \mu \neq 3$  (diviser le seuil  $\alpha$  entre les deux queues de distribution)

*Valeur pivotale* : Variable aléatoire dont on connaît la loi, ce qui permet de calculer les paramètres du test. Exemple :  $(X_n - \mu)/\sigma/\sqrt{n} \sim N(0,1)$

Tests de moyennes :  $X_n$  = moyenne empirique sur un échantillon de taille  $n$

\*  $\sigma$  connu: - Grands échantillons:  $X_n \sim N(\mu, \sigma/\sqrt{n})$  par le théorème Central Limite.

Règle de décision : rejet de  $H_0$  si la moyenne observée  $X_n$  n'appartient pas à l'intervalle  $[\mu - u_{1-\alpha/2} \sigma/\sqrt{n}, \mu + u_{1-\alpha/2} \sigma/\sqrt{n}]$  .où  $u_{1-\alpha/2}$  désigne le fractile d'ordre  $1 - \alpha/2$  de la loi  $N(0,1)$

- Petits échantillons ( $n < 30$ ) :  $(X_n - \mu)/\sigma/\sqrt{n} \sim T(n-1)$

- $\sigma$  inconnu: - Echantillon gaussien:  $(X_n - \mu)/s'/\sqrt{n}$  est une valeur pivotale suivant une loi de Student  $T(n-1)$  avec  $s'$  = écart-type empirique corrigé.  
- Grands échantillons ( $n > 30$ ) : TCL  $\Rightarrow (X_n - \mu)/s'/\sqrt{n} \rightarrow N(0,1)$  en loi.

Grands échantillons,  $\sigma$  inconnu: prendre l'écart-type empirique corrigé  $s' = (n/(n-1))s$

- Petits échantillons ( $n < 30$ ),  $\sigma$  inconnu:  $(X_n - \mu)/s'/\sqrt{n} \sim$  Student à  $(n-1)$  degrés de liberté.
- *Cas des proportions* : variance  $p(1-p)$

Tests de variances ou d'écart-type :

\* *Loi normale* : (théorème de Fisher)  $X_i$  iid  $\Rightarrow (n-1)s^2/\sigma^2 \sim \chi^2(n-1)$  donc  $(n-1)s^2/\sigma^2$  est une valeur pivotale pour  $\sigma$ .

Règle de décision : rejet de  $H_0$  si  $s^2$  n'appartient pas à l'intervalle  $[u_{\alpha/2}\sigma^2/(n-1), u_{1-\alpha/2}\sigma^2/(n-1)]$

Cas particulier des grands échantillons :  $[\sqrt{(n-1)}](s^2 - \sigma)/\sigma \rightarrow N(0,1)$  en loi donc  $[\sqrt{(n-1)}](s^2 - \sigma)/\sigma$  est une valeur pivotale asymptotique pour  $\sigma$ .

Tests de comparaison :

*Hypothèse* :  $X_i$  iid, de loi  $L_\mu$  dont deux observations de moyennes  $X_{i1}$  et  $X_{i2}$  sont faites dans 2 échantillons  $E1$  et  $E2$ .

$H_0 : \mu_1 = \mu_2$      $H_1 : \mu_1 \neq \mu_2$     ou  $H_0 : \mu_1 \leq \mu_2$      $H_1 : \mu_1 > \mu_2$

- *Moyennes de variables suivant des lois normales* :  $X_{i1} \sim N(\mu_1, \sigma_1)$  et  $X_{i2} \sim N(\mu_2, \sigma_2)$   
 $\sigma_i$  connues :  $[X_{1n} - X_{2n} - (\mu_1 - \mu_2)] / \sqrt{(\sigma_1^2/n_1 + \sigma_2^2/n_2)} \sim N(0,1)$  est une valeur pivotable de loi  $N(0,1)$   
 $\sigma_1 = \sigma_2$  inconnues :  $[X_{1n} - X_{2n} - (\mu_1 - \mu_2)] / s' \sqrt{(1/n_1 + 1/n_2)} \sim T(n_1 + n_2 - 2)$   
 $\sigma_1 \neq \sigma_2$  inconnues :  $[X_{1n} - X_{2n} - (\mu_1 - \mu_2)] / \sqrt{(s_1'^2/n_1 + s_2'^2/n_2)}$  asymptotiquement pivotale pour  $(\mu_1 - \mu_2)$ , tend en loi (si  $n > 30$ ) vers  $N(0,1)$ .
- *Lois quelconques* :  
*Hypothèse* :  $\sigma_1$  et  $\sigma_2$  connues, grands échantillons ( $n_i > 10$ )  
 $(X_{1n} - X_{2n}) \sim N(\mu_1 - \mu_2, (\sigma_1^2/n_1 + \sigma_2^2/n_2)^{0.5})$  asymptotiquement  
*Hypothèse* :  $\sigma_1$  et  $\sigma_2$  inconnues, grands échantillons ( $n_i > 50$ )  
 $[(X_{1n} - X_{2n}) - (\mu_1 - \mu_2)] / (s_1'^2/n_1 + s_2'^2/n_2)^{0.5} \sim N(0,1)$

Test d'indépendance du  $\chi^2$  : Caractères X et Y, soit qualitatifs, soit quantitatifs soit respectivement à r et s modalités ;  $n_{ij} = \text{Card}\{X=i, Y=j\}$  ;  $n = \sum_{ij} n_{ij}$  ;  $p_{ij} = n_{ij}/n$  ;  $p_i =$  probabilité marginale  $= \sum_j n_{ij}/n$ .

*Hypothèse d'indépendance* :  $H_0 : p_{ij} = p_i \cdot p_j$   
 $H_1 : p_{ij} \neq p_i \cdot p_j$

*Statistique* :  $D_n = \sum_i \sum_j [(n_{ij} - n_i \cdot n_j / n)^2 / n_i \cdot n_j / n]$   
 $D_n \sim \chi^2[(r-1)(s-1)]$  sous  $H_0$

Tests sur les paramètres d'un modèle linéaire estimés par les MCO :  $y_t = \alpha + X_t \beta + \varepsilon_t$

*Hypothèse* :  $\varepsilon \sim N(0, \sigma_\varepsilon)$

- *Test sur un paramètre estimé  $\beta^{\wedge}$  d'écart-type estimé s* :  
Non rejet de  $H_0 : \beta = b$  contre  $H_1 : \beta \neq b \Leftrightarrow (\beta^{\wedge} - b) / s < u$  pour une valeur u correspondant sur une loi de Student au seuil de confiance (5 ou 1% : par exemple  $u = 1,697$  pour un nombre de degrés de liberté = taille de l'échantillon - nombre de paramètres estimés = 30 et un seuil de 5%).
- *Test sur un vecteur de paramètres estimés  $\beta^{\wedge}$  de matrice de variances-covariances*  
 $\sum : k =$  taille du vecteur  $\beta^{\wedge}$  ;  $\text{SCR}(M_c) =$  somme des carrés des résidus du modèle estimé M.  
Test de Fisher comparant un modèle contraint  $M^c$  (à  $(n-p-k)$  degrés de liberté) par l'hypothèse  $H_0$  au modèle non contraint  $M^{nc}$  (estimation libre) à  $(n-p)$  degrés de liberté :  
 $\{[\text{SCR}(M_c) - \text{SCR}(M_{nc})] / k\} / \{\text{SCR}(M_{nc}) / (n-p)\} \sim F(k, n-p)$ .

Règle de décision : Rejet de  $H_0$  si  $\{[\text{SCR}(M_c) - \text{SCR}(M_{nc})] / k\} / \{\text{SCR}(M_{nc}) / (n-p)\} >$  limite de  $F(k, n-p)$  pour un seuil de confiance donné (par exemple  $F(3, 60) = 2,76$  pour un seuil de 5%).