

# Chap 1: ESTIMATION

## I Introduction:

L'estimation consiste à donner des valeurs approchées à 1 ou plusieurs paramètres (souvent noté  $\theta \in \mathbb{R}$  ou  $\mathbb{R}^n$ ) à partir d'observations notées généralement  $x_1, \dots, x_n$  issues d'une même "population"

Le modèle statistique retenu par la plupart des statisticiens consiste à supposer que  $x_1, \dots, x_n$  est la réalisation d'un vecteur  $(X_1, \dots, X_n)$  où  $X_i$  sont des variables aléatoires indépendantes et de même loi (va iid).

On dit que  $(x_1, \dots, x_n)$  est un échantillon.

Un estimateur d'un paramètre  $\theta \in \mathbb{R}$  ou  $\mathbb{R}^n$  est une fonction des  $n$  VA  $X_i$  notée  $\hat{\theta}$  ou  $\hat{\theta}(x_1, \dots, x_n)$

Remarque:  $\hat{\theta}(x_1, \dots, x_n)$  est une fonction aléatoire appelée statistique

## Qualités d'un estimateur: $\hat{\theta}$

### • Biais de l'estimateur: moyenne $\Rightarrow$ non aléatoire

$$\text{Biais}(\hat{\theta}) = E[\hat{\theta}] - \theta$$

moyenne de l'estimé - la vraie valeur

C'est une fonction non aléatoire de  $\theta$  notée  $b(\theta)$

<small>1<sup>ère</sup> réalisation</small>	o	o	o	o	o
$\hat{\theta}(x_1, \dots, x_n)$	o	o	o	o	o
$x$	x			x	
$\theta$					
$x$					
$\hat{\theta}(x_1, \dots, x_n)$	x			x	
<small>2<sup>ème</sup> réalisation</small>					

l'estimateur  $X$  est non biaisé: pas d'erreur systématique.

l'estimateur  $o$  est biaisé: il y a une erreur systématique. (ex: balance en 0 mal réglé)

Dans les applications pratiques, on veut  $E[\hat{\theta}] - \theta = 0$ ; on dit que l'estimateur est non biaisé. On veut biais faible

### • Variance de l'estimateur

$$\text{Var} \hat{\theta} = E[(\hat{\theta} - E[\hat{\theta}])^2] = E[\hat{\theta}^2] - (E[\hat{\theta}])^2$$

Var  $\hat{\theta}$  fournit une précision sur l'estimation. Plus var  $\hat{\theta}$  est faible meilleur est l'estimateur. On veut var faible



0	0	0	0	0
x	x	x	x	x
x	x	x	x	x
0	0	0	0	0

$$\text{Var } X < \text{Var } 0$$

$\Rightarrow X$  préférable

• Erreur quadratique moyenne d'un estimateur:

$$EQM(\hat{\theta}) = E[(\hat{\theta} - \theta)^2]$$

l'estimateur  $\hat{\theta}$  est d'autant meilleur que  $EQM(\hat{\theta})$  est faible

Remarque: 
$$EQM(\hat{\theta}) = \text{Var } \hat{\theta} + (\text{Biais } (\hat{\theta}))^2$$

Si on a  $\text{var } \hat{\theta}$  et  $\text{Biais } \hat{\theta}$ , pas le peine de calculer  $EQM(\hat{\theta})$

En effet 
$$EQM(\hat{\theta}) = E[(\hat{\theta} - E[\hat{\theta}] + E[\hat{\theta}] - \theta)^2]$$

$$= E[(\hat{\theta} - E[\hat{\theta}])^2] + E[(E[\hat{\theta}] - \theta)^2] + 2E[(\hat{\theta} - E[\hat{\theta}])(E[\hat{\theta}] - \theta)]$$

donc 
$$EQM(\hat{\theta}) = \text{Var } \hat{\theta} + \underbrace{E[(\text{Biais } \hat{\theta})^2]}_{(\text{Biais } \hat{\theta})^2} + 2(E[\hat{\theta}] - \theta) \underbrace{E[\hat{\theta} - E[\hat{\theta}]]}_{E[\hat{\theta}] - E[E[\hat{\theta}]]}$$

$$E[\hat{\theta}] - E[E[\hat{\theta}]] = 0$$

Définition: On dit que l'estimateur  $\hat{\theta}$  est convergent si

$$\hat{\theta} \xrightarrow[n \rightarrow \infty]{P} \theta$$

Condition suffisante de convergence:

Si  $\text{biais } (\hat{\theta}) \xrightarrow[n \rightarrow \infty]{} 0$  et  $\text{var } (\hat{\theta}) \xrightarrow[n \rightarrow \infty]{} 0$  alors

$\hat{\theta}$  est convergent

$$\left. \begin{array}{l} \text{biais} \rightarrow 0 \\ \text{var} \rightarrow 0 \end{array} \right\} \Rightarrow EQM(\hat{\theta}) \rightarrow 0$$

$\Rightarrow$  conv en moyenne quadratique  $\Rightarrow$  conv en proba

En effet  $\text{biais } (\hat{\theta}) \xrightarrow[n \rightarrow \infty]{} 0$

$\text{Var } \hat{\theta} \xrightarrow[n \rightarrow \infty]{} 0$

$\Rightarrow EQM(\hat{\theta}) \xrightarrow[n \rightarrow \infty]{} 0 \Leftrightarrow \hat{\theta} \xrightarrow[n \rightarrow \infty]{mq} \theta$

on sait que  $\hat{\theta} \xrightarrow[n \rightarrow \infty]{mq} \theta \Rightarrow \hat{\theta} \xrightarrow[n \rightarrow \infty]{P} \theta$



## II Exemples:

Exemple 1: Soit  $(X_1, \dots, X_n)$  un échantillon tel que  $E[X_i] = m$  et  $\text{var } X_i = \sigma^2$ . On suppose que  $\sigma^2$  est connue et on désire estimer  $\theta = m$ .

Comparer  $\hat{\theta}_1 = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}$  et  $\hat{\theta}_2 = \frac{2}{n(n+1)} \sum_{i=1}^n i X_i$

Biais: \*  $E[\hat{\theta}_1] - \theta = E[\hat{\theta}_1] - m$

$$= E\left[\frac{1}{n} \sum_{i=1}^n X_i\right] - m$$

$$= \frac{1}{n} \sum_i \underbrace{E[X_i]}_m - m = \boxed{0}$$

$\hat{\theta}_1$  est un estimateur non biaisé de  $m$   $1+2+\dots+n$

\*  $E[\hat{\theta}_2] - m = \frac{2}{n(n+1)} \left( \sum_{i=1}^n i E[X_i] \right) - m$

$$= \frac{2}{n(n+1)} m \left( \frac{n(n+1)}{2} \right) - m = \boxed{0}$$

$\hat{\theta}_2$  non biaisé

Variances:

Rq: Si  $X_1, \dots, X_n$  sont  $n$  VA indépendantes, alors

$$\text{Var} \sum_{i=1}^n X_i = \sum_{i=1}^n \text{Var } X_i$$

\*  $\text{Var } \hat{\theta}_1 = \frac{1}{n^2} \text{Var}(\sum X_i) = \frac{1}{n^2} \sum_{i=1}^n \overbrace{\text{Var } X_i}^{\sigma^2} = \frac{\cancel{\sigma^2}}{\cancel{n^2}} = \boxed{\frac{\sigma^2}{n}}$

Rq:  $\text{Var } \hat{\theta}_1 \xrightarrow{n \rightarrow +\infty} 0$  Donc  $\hat{\theta}_1$  est convergent  
 Biais  $\hat{\theta}_1 = 0$

\*  $\text{Var } \hat{\theta}_2 = \frac{4}{\sigma^2(n+1)^2} \sum_{i=1}^n \underbrace{\text{Var}(i X_i)}_{i^2 \text{Var}(X_i)} = \frac{4 \sigma^2}{n^2(n+1)^2} \sum_{i=1}^n i^2$

$$\frac{4 \sigma^2}{n^2(n+1)^2} \frac{n(n+1)(n+2)}{6}$$

$\text{Var } \hat{\theta}_2 = \frac{2}{3} \sigma^2 \frac{2n+1}{n(n+1)}$

$\text{Var } \hat{\theta}_2 \xrightarrow{n \rightarrow +\infty} 0$  Donc  $\hat{\theta}_2$  est convergent  
 Biais  $\hat{\theta}_2 = 0$



On préférera  $\hat{\theta}_1$  à  $\hat{\theta}_2$  si  $\text{Var } \hat{\theta}_1 < \text{Var } \hat{\theta}_2$

$$\text{si } \frac{\sigma^2}{n} < \frac{2}{3} \sigma^2 \frac{2n+1}{n(n+1)} \sim \frac{4}{3} \frac{\sigma^2}{n}$$

Ok on préférera  $\hat{\theta}_1$  à  $\hat{\theta}_2$

$$\hat{\theta}_3 = \hat{m}^n = \frac{1}{n} \sum_{i=1}^n x_i$$

$$E[\hat{m}^n] = \frac{1}{n} \sum_{i=1}^n E[x_i] = m^n$$

$$\text{Var}(\hat{m}^n) = E\left[\left(\frac{1}{n} \sum_{i=1}^n x_i\right)^2\right] - (m^n)^2$$

$$= E[x_1^2 + x_2^2 + \dots + x_n^2] - m^{2n}$$

$$= \frac{1}{n} \sum_{i=1}^n E[x_i^2] - m^{2n} = \frac{(m^2 + \sigma^2)^n}{n} - m^{2n}$$

Exemple 2:

mêmes hypothèses mais on désire estimer  $\sigma^2$

$$m = E[x_i]$$

$$\sigma^2 = E[(x_i - m)^2]$$

1<sup>er</sup> Cas: m connu

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - m)^2$$

$$E[\hat{\sigma}^2] - \sigma^2 = \frac{1}{n} \sum_{i=1}^n E[(x_i - m)^2] - \sigma^2 = \sigma^2 - \sigma^2 = 0$$

$\hat{\sigma}^2$  non biaisé

$$\text{Var } \hat{\sigma}^2 = \frac{1}{n^2} \sum_{i=1}^n \text{Var} (x_i - m)^2 = \frac{n \text{Var} (x_1 - m)^2}{n^2}$$

les  $x_i$  ont la même loi  $\Rightarrow$  m variance

$$\text{Var } \hat{\sigma}^2 = \frac{\text{Var} (x_1 - m)^2}{n} \xrightarrow{n \rightarrow +\infty} 0 \quad \text{donc } \hat{\sigma}^2 \text{ converge}$$

2<sup>ème</sup> Cas: m inconnu:

$$\tilde{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \underbrace{\bar{x}}_{\hat{m}})^2$$

Biais?  $\tilde{\sigma}^2$  converge?

~~$$\text{Biais } (\tilde{\sigma}^2): E[\tilde{\sigma}^2] - \sigma^2 = \frac{1}{n} \sum_{i=1}^n E[(x_i - \bar{x})^2] - \sigma^2$$~~

~~$$E[(x_i - \bar{x})^2] = E[(x_i - \bar{x} + m - m)^2] = E[(x_i - m + m - \bar{x})^2]$$~~

~~$$= E[(x_i - m)^2] + E[(m - \bar{x})^2] + 2 E[(x_i - m)(m - \bar{x})]$$~~

~~$$\text{Biais } \tilde{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n E[(x_i - m)^2] + \frac{1}{n} \sum_{i=1}^n E[(m - \bar{x})^2] + \frac{2}{n} \sum_{i=1}^n E[(x_i - m)(m - \bar{x})] - \sigma^2$$~~

$$= \frac{\sigma^2}{n} + 0 + \dots - \sigma^2$$



biais  $\tilde{\sigma}^2 = E[\tilde{\sigma}^2] - \sigma^2$

$$E[\tilde{\sigma}^2] = \frac{1}{n} \sum_{i=1}^n E\left[\left\{(X_i - m) + (m - \bar{X})\right\}^2\right]$$

$$= \frac{1}{n} \sum_{i=1}^n \underbrace{E[(X_i - m)^2]}_{\sigma^2} + \underbrace{E[(\bar{X} - m)^2]}_{\substack{E[\bar{X}] \\ \text{Var } \bar{X} = \frac{\sigma^2}{n}}} + 2 \underbrace{E[(X_i - m)(m - \bar{X})]}_{-\frac{2\sigma^2}{n}}$$

$$E\left[(X_i - m) \left(m - \frac{1}{n} \sum_{j=1}^n X_j\right)\right] = E\left[(X_i - m) \frac{1}{n} \sum_{j=1}^n (m - X_j)\right]$$

$$= \frac{1}{n} \sum_{j=1}^n -E\left[(X_i - m)(X_j - m)\right]$$

$i \neq j$   $\text{cov}(X_i, X_j) = 0$   $\text{car } X_i \text{ et } X_j \text{ ind}$   
 $i = j$   $\text{Var } X_i = \sigma^2$

$$= -\frac{\sigma^2}{n}$$

$$E[\tilde{\sigma}^2] = \sigma^2 - \frac{\sigma^2}{n} = \frac{n-1}{n} \sigma^2$$

$\tilde{\sigma}^2$  est biaisé

donc  $E\left[\frac{n}{n-1} \tilde{\sigma}^2\right] = \sigma^2$

On pose  $\sigma^{2*} = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$  non biaisé

faudrait montrer que cvg

13/12/93

Bon estimateur :   
 | Biais proche de 0 (moyenne de l'estimateur proche de la valeur moyenne)  
 | var faible  
 | Convergence

### III Inégalité de RAO-CRAMER - ESTIMATEUR EFFICACE

1) Cas d'un paramètre réel  $\theta \in \mathbb{R}$ :

On peut tjrs éliminer le biais en général (ex: valeur)

Le var est bornée ...



Définition: On appelle vraisemblance de  $(x_1, \dots, x_n)$  la fonction

$L(x_1, \dots, x_n; \theta)$  définie par:

\* Si  $x_i$  VA continues  $L(x_1, \dots, x_n; \theta) = \int (x_1, \dots, x_n; \theta)$   
densité de probabilité de  $(x_1, \dots, x_n)$

\* Si  $x_i$  VA discrètes  $L(x_1, \dots, x_n; \theta) = P[X_1 = x_1, \dots, X_n = x_n; \theta]$

Inégalité de RAO-CRAMER:

$$\text{Var } \hat{\theta} \geq \frac{[1 + b'(\theta)]^2}{-E\left[\frac{\partial^2 \ln L(x_1, \dots, x_n; \theta)}{\partial \theta^2}\right]} = \text{BRC}(\theta)$$

en général non biaisé  $\Rightarrow b'(\theta) = 0$   
 $\rightarrow 1$  au numérateur

$b'(\theta)$ : dérivée du biais

\* BRC( $\theta$ ) est appelée borne de Cramer-Rao de  $\theta$

Cette inégalité suppose que  $L(x_1, \dots, x_n; \theta)$  est 2 fois dérivable par rapport à  $\theta$ , et que les bornes du support de  $L$  sont indépendantes de  $\theta$ .

Par exemple, cette inégalité n'est pas valable lorsque  $X_i \sim U(0, \theta)$  et qu'on cherche à estimer  $\theta$ .

• Définition: Un estimateur non biaisé de  $\theta$  noté  $\hat{\theta}$  vérifiant  $\text{Var } \hat{\theta} = \text{Borne de RAO-CRAMER}$  est unique et appelé l'estimateur efficace de  $\theta$ .  
(c'est le meilleur)

Exemples

ex 1:  $X_i \sim N(m, \sigma^2)$ ,  $X_i$  indépendantes,  $\sigma^2$  connu, on cherche à estimer  $\frac{m}{\sigma}$ .

$$L(x_1, \dots, x_n; m) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left[-\frac{(x_i - m)^2}{2\sigma^2}\right]$$

ind

$$= \left(\frac{1}{2\pi\sigma^2}\right)^{n/2} \exp\left[-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - m)^2\right]$$



$$\ln L(x_1, \dots, x_n; m) = -\frac{n}{2} \ln(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - m)^2$$

$$\frac{\partial \ln L}{\partial m} = \frac{1}{\sigma^2} \sum_{i=1}^n (x_i - m) = \frac{1}{\sigma^2} \sum (x_i - m)$$

$$\frac{\partial^2 \ln L}{\partial m^2} = \frac{1}{\sigma^2} \sum_{i=1}^n (-1) = -\frac{n}{\sigma^2}$$

$$\frac{\partial^2 \ln L(x_1, \dots, x_n; m)}{\partial m^2} = -\frac{n}{\sigma^2}$$

$$E\left[\frac{-\partial^2 \ln L(x_1, \dots, x_n; m)}{\partial m^2}\right] = E\left[\frac{n}{\sigma^2}\right] = \frac{n}{\sigma^2}$$

Si  $\hat{m}$  est un estimateur non biaisé de  $m$  alors  $\text{Var } \hat{m} \geq \frac{\sigma^2}{n}$

Rq1:  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$  on a vu  $E[\bar{X}] = m$

$$\text{Var } \bar{X} = \frac{\sigma^2}{n}$$

$\bar{X}$  est l'estimateur efficace de  $m$  dans le cas de VA indépendantes de loi  $N(m, \sigma^2)$

Rq2: la variance optimale concernant l'estimation de  $m$  est  $\frac{\sigma^2}{n} \propto \frac{1}{n}$   
 → précision de l'estimation optimale

Rq3: lorsque les  $X_i$  sont indépendantes

$$L(x_1, \dots, x_n; \theta) = \prod_{i=1}^n L(x_i; \theta)$$

$$\ln L(x_1, \dots, x_n; \theta) = \sum_{i=1}^n \ln L(x_i; \theta)$$

$$\frac{\partial^2 \ln L(x_1, \dots, x_n; \theta)}{\partial \theta^2} = \sum_{i=1}^n \frac{\partial^2 \ln L(x_i; \theta)}{\partial \theta^2}$$

$$E\left[\frac{\partial^2 \ln L(x_1, \dots, x_n; \theta)}{\partial \theta^2}\right] = \sum_{i=1}^n E\left[\frac{\partial^2 \ln L(x_i; \theta)}{\partial \theta^2}\right]$$

Si les VA  $X_i$  ont la même loi, toutes les espérances sont égales donc

$$= n \cdot E\left[\frac{\partial^2 \ln L(X; \theta)}{\partial \theta^2}\right]$$

$$\text{Var } \hat{\theta} \geq \frac{(1 + b'(\theta))^2}{n E\left[\frac{\partial^2 \ln L(X; \theta)}{\partial \theta^2}\right]}$$



Ex 2:  $X_i \sim P(\lambda)$  chercher la borne de Rao-Cramer sur  $\lambda$  pour un estimateur non biaisé.

2) Cas où  $\theta = (\theta_1, \dots, \theta_p) \in \mathbb{R}^p$

la matrice de covariance de  $\hat{\theta} = (\hat{\theta}_1, \dots, \hat{\theta}_p)$  (définie par

$$\text{Cov}(\hat{\theta}) = E \left[ \begin{pmatrix} \hat{\theta} - E[\hat{\theta}] \\ \vdots \end{pmatrix} \begin{pmatrix} \hat{\theta} - E[\hat{\theta}] \\ \vdots \end{pmatrix}^t \right] \text{ vérifie } (---) \parallel \Rightarrow a \in \mathbb{R}$$

$$\text{Cov}(\hat{\theta}) \geq \mathbb{I}_\theta^{-1} \quad \text{pour un estimateur non biaisé de } \theta$$

avec  $\mathbb{I}_\theta = (\mathbb{I}_{ij})_{\substack{i=1, \dots, p \\ j=1, \dots, p}}$  et  $\mathbb{I}_{ij} = E \left[ \frac{-\partial^2 \ln L(X_1, \dots, X_n; \theta)}{\partial \theta_i \partial \theta_j} \right]$

$A \geq B$  signifie  $A - B$  matrice semi définie positive

$$\left( \begin{matrix} t \\ \alpha \end{matrix} (A - B) \alpha \geq 0 \quad \forall \alpha \right)$$

Semi définie positive

En particulier

$$\text{Var } \hat{\theta}_i \geq (\mathbb{I}_\theta^{-1})_{ii}$$



$\hat{\theta}_{no}$  est simple à implanter mais possède peu de bonnes propriétés.

## IV. Méthode du maximum de vraisemblance

### V.1. Définitions

L'estimateur du maximum de vraisemblance de  $\theta$  est défini par

$$\hat{\theta}_{nv} = \underset{\theta}{\operatorname{arg\,max}} L(x_1, \dots, x_n; \theta) \quad \rightarrow \text{fonc. de } \theta$$

$L(x_1, \dots, x_n; \theta)$  étant la vraisemblance de  $\theta$  ( $f(x_1, \dots, x_n; \theta)$  ou  $P[X_1 = x_1, \dots, X_n = x_n; \theta]$ )

Dans la mesure où les hypothèses de la borne de Rao Cramer sont vérifiées (ie  $L(x_1, \dots, x_n; \theta)$  2 fois dérivable et bornes du support de  $L(x_1, \dots, x_n; \theta)$  indépendantes de  $\theta$ ), la détermination de  $\hat{\theta}_{nv}$  se fait à l'aide des équations suivantes:

$$\theta \in \mathbb{R} \quad \frac{\partial L(x_1, \dots, x_n; \theta)}{\partial \theta} = 0 \quad \text{ou} \quad \frac{\partial \ln L(x_1, \dots, x_n; \theta)}{\partial \theta} = 0$$

On vérifie que la solution donne un maximum en étudiant

$$\frac{\partial L(x_1, \dots, x_n; \theta)}{\partial \theta} \geq 0 \quad \text{ou en cas de problème}$$

$$\frac{\partial^2 L(x_1, \dots, x_n; \hat{\theta}_{nv})}{\partial \theta^2} < 0 \quad (\text{condition assurant que } \hat{\theta}_{nv} \text{ est un maximum local})$$

$\theta$	$\hat{\theta}_{nv}$
$\frac{\partial^2 L}{\partial \theta^2}$	$< 0$
$\frac{\partial L}{\partial \theta}$	
$L$	




ex 3:  $X_i \sim P(\lambda)$   $\lambda$ ?

$$L(x_1, \dots, x_n; \lambda) = \prod_{i=1}^n P[X_i = x_i; \lambda] = \prod_{i=1}^n \frac{\lambda^{x_i}}{x_i!} e^{-\lambda}$$
$$= \frac{\lambda^{\sum x_i}}{\prod x_i!} e^{-n\lambda}$$

$$\ln L(\cdot) = \sum x_i \ln \lambda - n\lambda - \ln(\prod x_i!)$$

$$\frac{\partial \ln L(\cdot)}{\partial \lambda} \geq 0 \Leftrightarrow \frac{\sum x_i}{\lambda} - n \geq 0 \Leftrightarrow \lambda \leq \bar{x}$$



$\lambda = \bar{x}$  est le maximum global unique de  $L(x_i; \lambda)$

on pose  $\boxed{\hat{\lambda}_{ML} = \bar{X}}$

04/01/2020

$$f(x_1, \dots, x_n; \theta) = \prod_{i=1}^n f(x_i; \theta)$$

$$\boxed{\hat{\theta}_{ML}} \text{ vérifie } f(x_1, \dots, x_n; \hat{\theta}_{ML}) \geq f(x_1, \dots, x_n; \theta) \quad \forall \theta$$



$\theta \in \mathbb{R}^p$  On résoud  $\frac{\partial L(x_1, \dots, x_n; \theta)}{\partial \theta_i} = 0 \quad \forall i = 1, \dots, p$

ou  $\frac{\partial \ln L(x_1, \dots, x_n; \theta)}{\partial \theta_i} = 0 \quad \forall i = 1, \dots, p$

### V. 2. Propriétés:

\*  $\hat{\theta}_{nv}$  est asymptotiquement sans biais  $\lim_{n \rightarrow +\infty} E[\hat{\theta}_{nv}] - \theta = 0$

\*  $\hat{\theta}_{nv}$  est convergent

\*  $\hat{\theta}_{nv}$  est asymptotiquement efficace  $\text{Var } \hat{\theta}_{nv} \underset{n \rightarrow +\infty}{\sim} \text{BRC}(\theta)$  borne de Rao Cramer

(ie  $\lim_{n \rightarrow +\infty} \frac{\text{Var } \hat{\theta}_{nv}}{\text{BRC}(\theta)} = 1$ ) /

\* Invariance fonctionnelle

Soit  $\mu = h(\theta)$ , où  $h$  est une  $f^{\circ}$  bijective d'un ouvert  $O \subset \mathbb{R}^p$  dans un ouvert  $V \subset \mathbb{R}^p$  alors

$$\hat{\mu}_{nv} = h(\hat{\theta}_{nv})$$

\*  $\sqrt{I_n(\theta)} (\hat{\theta}_{nv} - \theta) \xrightarrow[n \rightarrow +\infty]{L} N(0, I_p)$

$$\text{où } I_n(\theta) = E \left[ \frac{-\partial^2 \ln L(x_1, \dots, x_n; \theta)}{\partial \theta^2} \right]$$

est l'information de FISHER (c'est le dénominateur de la borne de Rao Cramer).

$\hat{\theta}_{nv}$  possède plein de bonnes propriétés mais peut être difficile à implémenter

### V. 3. Exemples:

ex 1:  $X_i \sim N(m, \sigma^2)$   $\sigma^2$  connu  $m$  inconnu


$$L(x_1, \dots, x_n; m) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} \exp - \frac{(x_i - m)^2}{2\sigma^2}$$



$$\ln L(x_1, \dots, x_n; m) = -\frac{1}{2} \ln 2\pi\sigma^2 - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - m)^2$$

$$\frac{\partial \ln L}{\partial m} \geq 0 \Leftrightarrow +\frac{1}{\sigma^2} \sum_{i=1}^n (x_i - m)(-1) \geq 0$$

$$\Leftrightarrow \sum x_i \geq nm \Leftrightarrow \boxed{m \leq \frac{1}{n} \sum x_i = \bar{x}}$$



$\bar{x}$  est un maximum  
global unique de

$$L(x_1, \dots, x_n; m)$$

$$\boxed{\hat{m}_{nv} = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}}$$

Ex 2:  $m$  inconnu,  $\sigma^2$  inconnu

$$\frac{\partial \ln L}{\partial m} = 0 \text{ et } \frac{\partial \ln L}{\partial \sigma^2} = 0$$

$$m = \bar{x} \text{ et } -\frac{n}{2} \frac{1}{\sigma^2} + \frac{1}{2} \frac{1}{\sigma^4} \sum_{i=1}^n (x_i - m)^2 = 0$$

$$m = \bar{x} \text{ et } \sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - m)^2$$

j'admets que  $(m = \bar{x}, \sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - m)^2)$  est l'argument du maximum de  $L(x_1, \dots, x_n; \theta)$

On pose

$$\boxed{\begin{aligned} \hat{m}_{nv} &= \bar{X} \\ \hat{\sigma}_{nv}^2 &= \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 \end{aligned}}$$



## IV Méthode des moments:

### IV.1. Définition

Soient  $n$  VA  $x_1, \dots, x_n$  iid dont la loi dépend d'un paramètre  $\theta = (\theta_1, \dots, \theta_p) \in \mathbb{R}^p$ . Le <sup>principe</sup> paramètre de l'estimation  $\theta$  consiste à donner une valeur approchée de  $\theta$  à l'aide de  $x_1, \dots, x_n$ .

En général  $\theta$  s'exprime en fonction de  $m_1, \dots, m_p$  avec  $m_i = E[X_j^i]$  (indépendant de  $j$  car toutes les VA  $X_j$  ont la même loi), de la façon suivante

$$\theta = h(m_1, \dots, m_p)$$

l'estimateur des moments de  $\theta$  est défini par

$$\hat{\theta}_{no} = h(\hat{m}_1, \dots, \hat{m}_p) \quad \text{avec} \quad \hat{m}_i = \frac{1}{n} \sum_{j=1}^n X_j^i$$

### IV.2. Exemple:

$$X_j \sim N(m, \sigma^2) \quad X_j \text{ iid} \quad \theta = (m, \sigma^2)$$

$$m_1 = E[X_j] = m$$

$$m_2 = E[X_j^2] = \text{Var} X_j + E[X_j]^2 = \sigma^2 + m^2$$

$$\text{Rq: } \begin{cases} m = m_1 \\ \sigma^2 = m_2 - m_1^2 \end{cases}$$

On pose

$$\hat{m}_{no} = \frac{1}{n} \sum_{j=1}^n X_j$$

$$\hat{\sigma}_{no}^2 = \frac{1}{n} \sum_{j=1}^n X_j^2 - \left( \frac{1}{n} \sum_{j=1}^n X_j \right)^2$$

### IV.3. Propriétés:

\*  $\hat{\theta}_{no}$  est convergent (vers  $\theta$ )

$$* \sqrt{n} (\hat{\theta}_{no} - \theta) \xrightarrow[n \rightarrow +\infty]{L} N(0, \Sigma)$$

$\Sigma$  matrice  $p \times p$  indépen-  
dante de  $n$

$\hat{\theta}_{no}$  peut être biaisé, non biaisé, efficace ou non.  $\rightarrow$  pas terrible ni con-  
propriétés

$\hat{\theta}_{no}$  simple à implémenter mais il possède peu de bonnes propriétés.



## VI Estimation BAYESIENNE

L'estimation Bayésienne consiste à supposer que le paramètre inconnu  $\theta$  est la réalisation d'une va  $\Theta$  qui possède une appelée Loi A PRIORI (densité de probabilité à priori dans le cas continu).

Le but de l'estimation Bayésienne consiste à estimer  $\theta$  (la réalisation de la va  $\Theta$ ) à l'aide d'un estimateur noté  $\hat{\theta}(x)$  de façon à minimiser une fonction (appelée fonction de coût):  $E[c(\theta, \hat{\theta}(x))]$  qui représente l'erreur entre  $\theta$  et  $\hat{\theta}(x)$

Remarque: L'estimateur  $\hat{\theta}$  est construit à partir de la loi des va  $X$ ; mais aussi à l'aide de la loi à priori

### VI.1 - ESTIMATEUR de la moyenne à Posteriori ( $\hat{\theta}_{\text{MOAP}}(x)$ )

$\hat{\theta}_{\text{MOAP}}(x)$  est l'estimateur qui minimise  $E[(\theta - \hat{\theta}(x))^2]$  (coût quadratique). Il est défini par:

$$\hat{\theta}_{\text{MOAP}}(x) = E[\theta/x] \quad \begin{array}{l} \text{moyenne de la loi de } \theta/x \\ \text{appelée loi à POSTERIORI} \end{array}$$

Preuve: On cherche à minimiser  $E[(\theta - \hat{\theta}(x))^2]$  ie On cherche  $\hat{\theta}(x)$  qui minimise  $E\left[E[(\theta - \hat{\theta}(x))^2 | x]\right]$

$$\begin{aligned} E[(\theta - \hat{\theta}(x))^2 | x] &= E[\theta^2/x] - 2 \underbrace{E[\theta \hat{\theta}(x)/x]}_{-2\hat{\theta}(x)E[\theta/x]} + \underbrace{E[\hat{\theta}^2(x)|x]}_{\hat{\theta}^2(x)} \\ &= E[\theta^2/x] - E[\theta/x]^2 + E[\theta/x]^2 - 2\hat{\theta}(x)E[\theta/x] + \hat{\theta}^2(x) \\ &= \text{Var}(\theta/x) + (\hat{\theta}(x) - E[\theta/x])^2 \end{aligned}$$

$\hat{\theta}$  simple à implémenter mais possède peu de bonnes propriétés



à  $x$  fixé, on a  $E[(\theta - \hat{\theta}(x))^2 | x] \geq \text{Var}(\theta | x)$

il y a égalité pour  $\hat{\theta}(x) = E[\theta | x]$

donc  $E[\theta | x]$  minimise  $E[(\theta - \hat{\theta}(x))^2 | x]$

Limitons nous au cas continu pour simplifier ( $x_1, \dots, x_n$  via de densités  $f(x_i; \theta)$ )

$$E[(\theta - \hat{\theta}(x))^2] = \int_{\mathbb{R}^n} E[(\theta - \hat{\theta}(x))^2 | x] f(x_1, \dots, x_n; \theta) dx_1 \dots dx_n$$

puis que  $\hat{\theta}(x) = E[\theta | x]$  minimise  $\forall x$ ,  $\hat{\theta}(x) = E[\theta | x]$  minimise aussi  $E[(\theta - \hat{\theta}(x))^2]$  CQFD

⊗ exemple (Ex 3 TD3):

• Résistance inconnue  $\theta$

• On a  $N$  mesures  $x_i = \theta + \underbrace{b_i}_{\text{erreur}}$  avec  $b_i \sim \mathcal{P}(0, \sigma_b^2)$

Il est clair que  $x_i \sim \mathcal{P}(\theta, \sigma_b^2)$

la loi  $N(\theta, \sigma_b^2)$  est la loi de  $x_i / \theta$

• On suppose qu'on dispose d'une loi a priori sur  $\theta$  qui est  $N(m, \sigma^2)$

ie 
$$p(\theta) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp - \frac{(\theta - m)^2}{2\sigma^2}$$

$$\hat{\theta}_{\text{MOA}} = E[\theta | x] \quad x = (x_1, \dots, x_n)$$

Calcul de  $E[\theta | x]$  1) loi de  $\theta | x$

Règle de BAYES 
$$p(\theta | \underbrace{x_1, \dots, x_n}_x) = \frac{p(x_1, \dots, x_n | \theta) p(\theta)}{p(x_1, \dots, x_n)}$$

$$p(\theta) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp - \frac{(\theta - m)^2}{2\sigma^2} \quad \text{connu}$$



$$p(x_1, \dots, x_n | \theta) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma_b^2}} \exp\left[-\frac{(x_i - \theta)^2}{2\sigma_b^2}\right]$$

$x_i$  ind

$$p(x_1, \dots, x_n) = \int p(x_1, \dots, x_n, \theta) d\theta = \int \underbrace{p(x_1, \dots, x_n | \theta)}_{\text{connu}} \underbrace{p(\theta)}_{\text{connu}} d\theta$$

$p(x_1, \dots, x_n)$  est évidemment indépendant de  $\theta$ . Souvent, il n'est pas nécessaire de le calculer.

$$p(x_1, \dots, x_n | \theta) p(\theta) = C \exp\left[-\frac{1}{2}\left[\frac{(\theta - m)^2}{\sigma^2} + \frac{1}{\sigma_b^2} \sum_{i=1}^n (x_i - \theta)^2\right]\right]$$

$$\text{donc } p(\theta | x_1, \dots, x_n) \propto \exp\left[-\frac{1}{2}\left[\theta^2\left(\frac{1}{\sigma^2} + \frac{n}{\sigma_b^2}\right) - 2\theta\left(\frac{m}{\sigma^2} + \frac{\sum_{i=1}^n x_i}{\sigma_b^2}\right)\right]\right]$$

proportionnel

$$\exp\left[-\frac{1}{2} \frac{(\theta - m_p)^2}{\sigma_p^2}\right] = \exp\left[-\frac{1}{2\sigma_p^2} (\theta^2 - 2\theta m_p + m_p^2)\right]$$

$$p(\theta | x_1, \dots, x_n) \propto \exp\left[-\frac{1}{2} \frac{(\theta - m_p)^2}{\sigma_p^2}\right]$$

$$\text{avec } \frac{1}{\sigma_p^2} = \frac{1}{\sigma^2} + \frac{n}{\sigma_b^2}$$

$$m_p = \left(\frac{m}{\sigma^2} + \frac{n\bar{x}}{\sigma_b^2}\right) \sigma_p^2 = \frac{\frac{m}{\sigma^2} + \frac{n\bar{x}}{\sigma_b^2}}{\frac{1}{\sigma^2} + \frac{n}{\sigma_b^2}}$$

$$\text{ie } m_p = \bar{x} \left(\frac{\sigma^2}{\sigma^2 + \frac{\sigma_b^2}{n}}\right) + m \left(\frac{\frac{\sigma_b^2}{n}}{\sigma_b^2/n + \sigma^2}\right)$$

$$\theta | x \sim \mathcal{N}(m_p, \sigma_p^2)$$

$$\hat{\theta}_{\text{MOAP}} = E[\theta | x] = m_p = \bar{x} \left(\frac{\sigma^2}{\sigma^2 + \frac{\sigma_b^2}{n}}\right) + m \left(\frac{\frac{\sigma_b^2}{n}}{\sigma_b^2/n + \sigma^2}\right)$$

valeur nominale

$$\text{quand } n \text{ gd } \frac{\sigma_b^2}{n} \ll \sigma^2 \quad \hat{\theta}_{\text{MOAP}} \approx \bar{x}$$

precision valeur R      précision appareil de mesure

On ne tient plus compte de la valeur a priori  $m$  (on ne fait pas confiance au fournisseur)

quand  $n$  petit ( $n=0$ )  $\frac{\sigma_b^2}{n} \gg \sigma^2 \quad \hat{\theta}_{\text{MOAP}} \approx m$



## Ex. 2. Estimateur du Maximum A Posteriori ( $\hat{\theta}_{MAP}$ )

L'estimateur  $\hat{\theta}(x)$  qui minimise  $E[C(\theta, \hat{\theta}(x))]$  avec


$$C(\theta, \hat{\theta}(x)) = \begin{cases} 1 & \text{si } |\theta - \hat{\theta}(x)| > \Delta \\ 0 & \text{si } |\theta - \hat{\theta}(x)| < \Delta \end{cases}$$

$\Delta$  "arbitrairement" petit est défini par

$$\hat{\theta}_{MAP} = \arg \max_{\theta} p(\theta/x) \quad \text{ie} \quad p(\hat{\theta}_{MAP}/x) \geq p(\theta/x)$$

Pour l'exemple précédent  $\theta/x \sim N(m_p, \sigma_p^2)$

donc  $\hat{\theta}_{MAP} = \hat{\theta}_{MAP}$





## VII Estimation par intervalle de confiance.

1) Principe: Dans certaines applications, il est plus réaliste de donner une information de la forme  $a < \theta < b$  plutôt que de dire  $\hat{\theta} = c$ .

Un intervalle de confiance pour l'estimation du paramètre  $\theta$  est un intervalle de cette forme  $[d_1, d_2]$  tel que

$$P[d_1 < \theta < d_2] = \alpha$$

En général  $\alpha = 0,95$  ;  $0,99$  ou  $0,90$  et s'appelle le paramètre de confiance.

### 2) Détermination pratique de l'intervalle

On cherche à l'aide d'un estimateur  $\hat{\theta}$  de  $\theta$  (obtenu grâce à la méthode des moments ou du maximum de vraisemblance) une statistique  $T(X_1, \dots, X_n)$  dont la loi est connue et qui dépend de  $\theta$ .

On exprime la probabilité  $P[a < T(X_i) < b] = \alpha$  sous la forme

$$P[d_1 < \theta < d_2] = \alpha$$

### 3) Exemples

Ex 1:  $X_i \sim \mathcal{N}(m, \sigma^2)$   $\sigma^2$  connue,  $m$  inconnue

On sait que  $\hat{\theta} = \frac{1}{n} \sum_{i=1}^n X_i$  est un bon estimateur de  $m$

(pour loi  $\mathcal{N}$ ,  $\hat{\theta}$  sans biais, convergent, efficace)

et que  $\hat{\theta} \sim \mathcal{N}(m, \frac{\sigma^2}{n})$  (dans les mesures où les VA sont indépendantes)

(en effet  $E[\frac{1}{n} \sum_{i=1}^n X_i] = \frac{1}{n} \sum_{i=1}^n E[X_i] = m$  et

$$\text{Var}\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n^2} \text{Var}\left(\sum_{i=1}^n X_i\right) \underset{\substack{\text{ind.} \\ X_i}}{=} \frac{\sum \text{Var } X_i}{n^2} = \frac{\sigma^2}{n}$$



On pose  $T(X_1, \dots, X_n) = \frac{1}{n} \sum_{i=1}^n X_i$  ou  $\leftarrow$  la loi est connue et dépend de  $\theta$

$$T(X_1, \dots, X_n) = \frac{\frac{1}{n} \sum_{i=1}^n X_i - m}{\sigma/\sqrt{n}} \sim \mathcal{N}(0, 1) \rightarrow \text{Tabulé}$$


Rq:  $T(X_1, \dots, X_n)$  n'est pas unique

Intervalle de confiance pour m:


il se détermine grâce à

$$P[a < T(X_1, \dots, X_n) < b] = \alpha$$

Prenons  $\alpha = 0,95 = 95\%$




On détermine a et b à l'aide des tables



$$b = 1,96$$

$$a = -1,96$$



Donc  $P\left[-1,96 < \frac{\frac{1}{n} \sum X_i - m}{\sigma/\sqrt{n}} < 1,96\right] = 95\%$

$$-1,96 < \frac{\bar{X} - m}{\sigma/\sqrt{n}} < 1,96 \Leftrightarrow -1,96 \frac{\sigma}{\sqrt{n}} < \bar{X} - m < 1,96 \frac{\sigma}{\sqrt{n}}$$

$$\Leftrightarrow \bar{X} - 1,96 \frac{\sigma}{\sqrt{n}} < m < \bar{X} + 1,96 \frac{\sigma}{\sqrt{n}}$$

$\left[\bar{X} - 1,96 \frac{\sigma}{\sqrt{n}}, \bar{X} + 1,96 \frac{\sigma}{\sqrt{n}}\right]$  est l'intervalle de confiance pour m avec  $\alpha = 0,95$




Ex 2:  $X_i \sim N(m, \sigma^2)$   $m$  inconnue

On cherche un intervalle de confiance pour  $\sigma^2$

On sait que  $\hat{\sigma}^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$  est un estimateur non biaisé et convergent de  $\sigma^2$ .

On montre que  $T(X_1, \dots, X_n) = \frac{1}{\sigma^2} \sum_{i=1}^n (X_i - \bar{X})^2 = \frac{n-1}{\sigma^2} \hat{\sigma}^2$  suit une loi du  $\chi^2_{n-1}$



les tables donnent  $\begin{cases} a = \text{---} \\ b = \text{---} \end{cases}$

$$a < T(X_1, \dots, X_n) < b \iff a < \frac{1}{\sigma^2} \sum (X_i - \bar{X})^2 < b$$

$$\iff \frac{\sum (X_i - \bar{X})^2}{b} < \sigma^2 < \frac{\sum (X_i - \bar{X})^2}{a}$$

Ex 3:  $X_i \sim N(m, \sigma^2)$  Intervalle de confiance pour  $m$ ,  $\sigma^2$  étant inconnue

On sait que  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$  est un bon estimateur de  $m$   
et que  $\bar{X} \sim N(m, \frac{\sigma^2}{n})$

On ne peut pas prendre  $T(X_1, \dots, X_n) = \bar{X}$  car  $\bar{X}$  dépend non seulement de  $m$  mais aussi de  $\sigma^2$ .

$$U = \frac{\bar{X} - m}{\sigma/\sqrt{n}} \sim N(0, 1)$$

$$\text{On sait que } V = \frac{1}{\sigma^2} \sum_{i=1}^n (X_i - \bar{X})^2 \sim \chi^2_{n-1}$$

Donc  $\frac{U}{\sqrt{\frac{V}{n-1}}} \sim t_{n-1}$   
loi de Student ou du  $t$ , à  $n-1$  d° de liberté



On pose  $T(x_1, \dots, x_n) = \frac{\frac{\bar{x} - m}{\sigma/\sqrt{n}}}{\sqrt{\frac{1}{\sigma^2} \sum (x_i - \bar{x})^2} \frac{1}{\sqrt{n-1}}}$

$$= \frac{\bar{x} - m}{\sqrt{\sum (x_i - \bar{x})^2}} \sqrt{n(n-1)} \sim t_{n-1}$$

## VIII Méthode des moindres carrés : Exemple de la régression linéaire

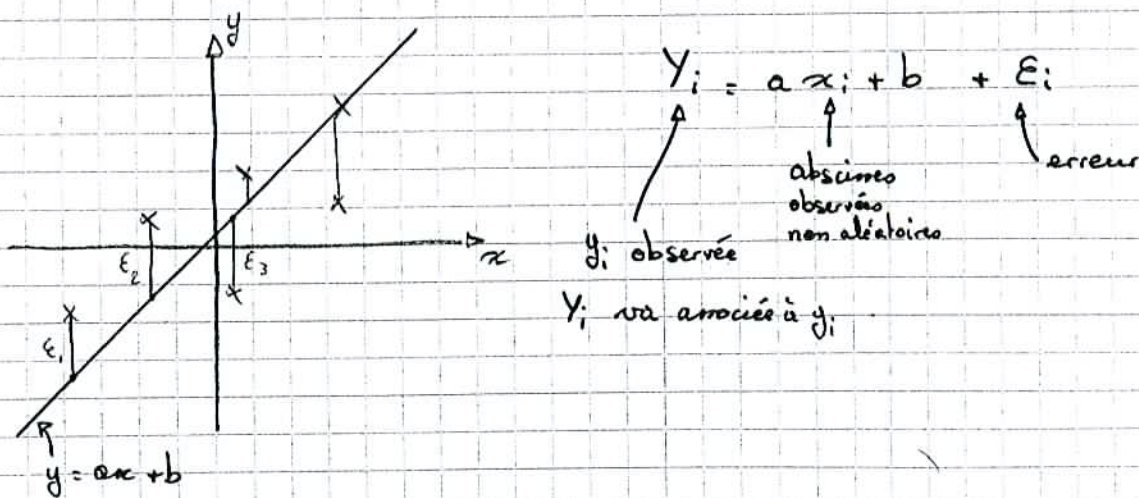
### 1) Principe

On a un nuage de points  $(x_i, y_i)$  et on cherche à estimer une relation fonctionnelle entre  $y_i$  et  $x_i$ .

Par exemple, on cherche la "meilleure" droite qui passe par ces points  $(x_i, y_i)$

### 2) Méthode:

On modélise les couples  $(x_i, y_i)$  de la façon suivante :  
(cas de la meilleure droite)



On détermine alors  $a$  et  $b$  de façon à minimiser

$$g(a, b) = \sum_{i=1}^n \epsilon_i^2 = \sum_{i=1}^n (y_i - a x_i - b)^2$$



(cf cours d'optimisation,  $g(a, b)$  admet un minimum global unique qui vérifie:  $\frac{\partial g(a, b)}{\partial a} = 0 \Leftrightarrow \sum_{i=1}^n 2(y_i - a x_i - b)(-x_i) = 0$  (1)

$$\frac{\partial g(a, b)}{\partial b} = 0 \Leftrightarrow \sum_{i=1}^n 2(y_i - a x_i - b)(-1) = 0 \quad (2)$$

$$(2) \quad n\bar{y} - an\bar{x} - nb = 0 \quad \Rightarrow \quad \boxed{b = \bar{y} - a\bar{x}}$$

$$\text{avec } \bar{y} = \frac{1}{n} \sum y_i \quad \text{et} \quad \bar{x} = \frac{1}{n} \sum x_i$$

$$(1) \quad \sum y_i x_i - a \sum x_i^2 - nb \bar{x} = 0$$

$$\frac{1}{n} \sum y_i x_i - \frac{a}{n} \sum x_i^2 - (\bar{y} - a\bar{x})\bar{x} = 0$$

$$\text{d'où} \quad \boxed{a = \frac{\frac{1}{n} \sum_{i=1}^n y_i x_i - \bar{y}\bar{x}}{\frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{x}^2}}$$



Si  $\sigma_X \neq 0$  :  $a = \frac{E(XY) - E(X)E(Y)}{\sigma_X^2} = \rho_{X,Y} \frac{\sigma_Y}{\sigma_X}$  et  $b = E(Y) - aE(X) = E(Y) - \rho_{X,Y} \frac{\sigma_Y}{\sigma_X} E(X)$ .

Nous trouvons alors l'approximation affine :

$$\hat{Y} = E(Y) + \rho_{X,Y} \frac{\sigma_Y}{\sigma_X} [X - E(X)].$$

La droite  $y = ax + b$  porte le nom de *droite de régression de Y en X*. Son équation peut s'écrire sous la forme :

$$\frac{y - m_Y}{\sigma_Y} = \rho_{X,Y} \frac{x - m_X}{\sigma_X} \quad \text{[III.21a]}$$

Cette droite passe par le point  $[E(X), E(Y)]$  appelé *centre de gravité de la probabilité unité* sur  $\mathbb{R}^2$ .

L'écart quadratique moyen minimum obtenu entre  $Y$  et son approximation affine  $\hat{Y}$  est alors de :

$$\begin{aligned} E[Y - E(Y) - \rho_{X,Y} \frac{\sigma_Y}{\sigma_X} [X - E(X)]]^2 &= E[Y - E(Y)]^2 + \rho_{X,Y}^2 \frac{\sigma_Y^2}{\sigma_X^2} E[X - E(X)]^2 - 2\rho_{X,Y} \frac{\sigma_Y}{\sigma_X} E[Y - E(Y)][X - E(X)] \\ &= \sigma_Y^2 + \sigma_Y^2 \rho_{X,Y}^2 - 2\sigma_Y^2 \rho_{X,Y}^2 = \sigma_Y^2 [1 - \rho_{X,Y}^2]. \end{aligned}$$

Cet écart est d'autant plus grand que la variance de  $Y$  est grande (grande dispersion des valeurs que peut prendre  $Y$ ) et que la corrélation linéaire de  $X$  et de  $Y$  est petite.

Si  $\sigma_X = 0$  : nous avons  $X - m_X = 0$  presque sûrement. La minimisation de l'expression [III.20] est indéterminée et tout revient en se fixant  $a = 0$ , à chercher un nombre  $b$  tel que  $E[Y - b]^2$  soit minimum. D'après ce que nous avons dit sur la variance de  $Y$ , on trouve  $b = m_Y$ .

Nous constatons que si  $\rho_{X,Y} = 0$ , la droite de régression de  $Y$  en  $X$  devient  $y - m_Y = 0$ . Comme dans le cas précédent, la meilleure approximation de  $Y$  au sens des moindres carrés, sous forme d'une fonction affine de  $X$  est  $Y = m_Y$ .


**Remarque :** Ces résultats peuvent s'obtenir plus simplement de manière géométrique en considérant l'espace de Hilbert  $L^2(\Omega, \mathcal{A}, P)$  des variables aléatoires du second ordre définies sur  $\Omega$  :

D'après les propriétés des espaces de Hilbert, trouver l'approximation affine  $aX + b$  de  $Y$  qui minimise  $E[Y - aX - b]^2$  est équivalent à projeter orthogonalement le vecteur  $Y$  sur l'espace vectoriel noté  $\text{sp}\{X, 1\}$  engendré par les vecteurs  $X$  et  $1$  (variable aléatoire  $1_{\Omega}(\omega)$ ) :

$$Y - aX - b \perp X \Leftrightarrow E[(Y - aX - b)X] = 0$$

$$Y - aX - b \perp 1 \Leftrightarrow E[(Y - aX - b)1] = 0$$

et l'on retrouve les équations précédentes.



On pourrait chercher également une approximation de  $X$  comme fonction affine de  $Y$ . Un raisonnement équivalent donnerait une *droite de régression de X en Y* qui aurait pour équation si  $\sigma_Y \neq 0$  :  $x = E(X) + \rho_{X,Y} \frac{\sigma_X}{\sigma_Y} [y - E(Y)]$ . Soit :



## Chap 2: Tests statistiques

### I Généralités:

Un test statistique est un mécanisme qui permet de décider à partir d'un échantillon  $X = (X_1, \dots, X_n)$  entre deux (ou plus) hypothèses notées  $H_0$  et  $H_1$ . (ou  $H_0, H_1, H_2, \dots$ )


$H_0$  s'appelle l'hypothèse nulle. Tandis que  $H_1$  s'appelle l'hypothèse alternative.

Rq: On se limite dans ce cours à  $\frac{2}{1}$  hypothèses

Elaborer une stratégie de Test, c'est déterminer une statistique notée  $T(X_1, \dots, X_n)$  telle que:

si  $T(x_1, \dots, x_n) \in \Delta$  alors on rejette l'hypothèse  $H_0$   
(c'est à dire on accepte  $H_1$ )

si  $T(x_1, \dots, x_n) \notin \Delta$  alors on accepte l'hypothèse  $H_0$



Vocabulaire:  $\{(x_1, \dots, x_n) / \underbrace{T(x_1, \dots, x_n) \in \Delta}_{\text{on rejette } H_0}\}$  s'appelle la région critique du test

On distinguera dans ce cours les tests dits paramétriques des tests non paramétriques. Un test est paramétrique si la forme de la loi des VA  $X_i$  est connue et que l'on cherche à tester la valeur d'un ou de plusieurs de ses paramètres.

Exemple:  $X_i \sim N(m, \sigma^2)$   $\sigma^2$  connue  
Test n°1  $H_0: m=1$   $H_1: m=2$

On parle d'hypothèses simples lorsqu'elles sont réduites à un point. (1 seule valeur des paramètres)  
le test n°1 est un test d'hypothèses simples.



Test n°2:  $(H_0) m > 0$   $(H_1) m \leq 0$

Ce test est un test paramétrique à hypothèses appelées hypothèses

Composées.

Test n°3:  $(H_0) X \sim N(m, \sigma^2)$   $(H_1) \text{ non } H_0$

Ce test est non paramétrique car il porte sur la loi des  $X_i$  et non pas sur ses paramètres.

Rq: Pour le test n°1 on pourrait envisager la stratégie suivante

$$\text{Rejet de } H_0 \text{ si } \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i > 1,5$$

la région critique est séparée par un hyperplan (droite pour  $n=2$ , plan pour  $n=3$ ).

Pour déterminer la performance d'un test, on s'intéressera aux risques de se tromper:

① risque de 1<sup>ère</sup> espèce  
risque  $\alpha$

$$\alpha = P[\text{Rejeter } H_0 / H_0 \text{ vraie}]$$

② risque de 2<sup>nde</sup> espèce  
risque  $\beta$

$$\beta = P[\text{Rejeter } H_1 / H_1 \text{ vraie}]$$

Un test sera d'autant meilleur que  $\alpha$  et  $\beta$  seront "petits"

$\alpha$  et  $\beta$  jouent des rôles parfaitement symétriques et pourant:

Ex. 1:  $(H_0)$  le patient est sain

$(H_1)$  le patient est atteint d'une maladie  $X$

(Rq: le patient est sain signifie absence de maladie  $\Rightarrow$  hypothèse nulle)



$\alpha = P[\text{on décide que le patient est malade} / \text{le patient est sain}]$   
probabilité de fausse alarme (PFA)

$\beta = P[\text{on décide que le patient est sain} / \text{le patient est malade}]$   
probabilité de non détection (PND)

Dans la mesure où on a le choix, on privilégiera  $\beta$

Ex 2:  $H_0$  non  $H_1$  (absence d'avion)  
 $H_1$  un avion bombarde l'NF (présence d'avion)

$\alpha$ : PFA

$\beta$ : PND

Définition: On appelle puissance du test  $\Pi = 1 - \beta$   
(probabilité de détection)

II Exemple:

$X_i \sim N(m, \sigma^2)$   $\sigma^2$  connue  
 $(X_1, \dots, X_n)$  échantillon  $H_0$   $m = m_0$   $H_1$   $m = m_1 > m_0$

Étudions la stratégie suivante:

Rejet de  $H_0$  si  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i > S_\alpha$  (seuil  $S_\alpha$ )  
dépend du risque  $\alpha$

Détermination de  $S_\alpha$ : On se fixe  $\alpha$  (en général 0,1 ; 0,5 ; 0,01 ; ou 0,05)


$$\alpha = 0,01 = P[\text{rejet } H_0 / H_0 \text{ vraie}]$$
$$= P[\bar{X} > S_\alpha / m = m_0]$$

On sait que  $\bar{X} \sim N(m, \frac{\sigma^2}{n})$

$$= P[\bar{X} > S_\alpha / \bar{X} \sim N(m_0, \frac{\sigma^2}{n})]$$



$$\alpha = 0,01 = P\left[\frac{\bar{X} - m_0}{\sigma/\sqrt{n}} > \frac{S_\alpha - m_0}{\sigma/\sqrt{n}} \mid U \sim N(0,1)\right] = \int_{\frac{S_\alpha - m_0}{\sigma/\sqrt{n}}}^{+\infty} \frac{1}{\sqrt{2\pi}} e^{-u^2/2} du$$



les tables donnent

$$\frac{S_\alpha - m_0}{\sigma/\sqrt{n}} = \dots$$

d'où  $S_\alpha = \dots$

plus  $\alpha \downarrow$ , plus  $S_\alpha \rightarrow$

Calcul de  $\beta$  (ou de  $\pi = 1 - \beta$ )

$$\beta = P[\text{rejeter } H_1 / H_1 \text{ vraie}] = P[\bar{X} < S_\alpha / m = m_1]$$

$$= P\left[V: \frac{\bar{X} - m_1}{\sigma/\sqrt{n}} < \frac{S_\alpha - m_1}{\sigma/\sqrt{n}} \mid V \sim N(0,1)\right]$$

On détermine  $\beta = \int_{-\infty}^{\frac{S_\alpha - m_1}{\sigma/\sqrt{n}}} \frac{1}{\sqrt{2\pi}} e^{-u^2/2} du$


à l'aide des tables de la loi normale.

plus  $\alpha \downarrow$ , plus  $S_\alpha \rightarrow$  et donc plus  $\beta \rightarrow$

$\alpha$  et  $\beta$  varient en sens inverse ( $\beta$  fct<sup>o</sup> décroissante de  $\alpha$ )


Autre représentation  $\alpha = P[\bar{X} > S_\alpha \mid \bar{X} \sim N(m_0, \frac{\sigma^2}{n})]$

$$\beta = P[\bar{X} < S_\alpha \mid \bar{X} \sim N(m_1, \frac{\sigma^2}{n})]$$





Z001



Si on cherche à minimiser  $\alpha + \beta$ , il faut placer  $S_\alpha$  à l'intersection des 2 courbes.

III Théorème (ou LEMME) de NEYMAN-PEARSON (1933)

(NP)

L'approche de NP consiste à fixer  $\alpha$  et à chercher un test qui minimise  $\beta$ . (pour cette valeur de  $\alpha$  fixé). On dit souvent que le test de NP est optimal.

III.1. Cas de variables aléatoires continues et d'hypothèses simples

$(H_0) \theta = \theta_0$        $(H_1) \theta = \theta_1$

$X_i$  possède une densité de probabilité sous chacune des 2 hypothèses notées  $f(x_i; \theta_0)$  et  $f(x_i; \theta_1)$

densité de  $X_i$  sous  $H_0$       densité de  $X_i$  sous  $H_1$

A  $\alpha$  fixé, le test qui minimise  $\beta$  est de la forme

Rejet de  $H_0$  si  $\frac{L(x_1, \dots, x_n | H_1)}{L(x_1, \dots, x_n | H_0)} > S_\alpha$

Rq:  $L(x_1, \dots, x_n | H_i) = \prod_{j=1}^n f(x_j, \theta_i) = f(x_1, \dots, x_n; \theta_i)$

Exemple:  $X_i \sim N(m, \sigma^2)$        $\sigma^2$  connue

$(H_0) m = m_0$        $(H_1) m = m_1$

Le test de NP est défini

Rejet de  $H_0$  si  $\frac{\prod_{j=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} \exp - \frac{(x_j - m_1)^2}{2\sigma^2}}{\prod_{j=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} \exp - \frac{(x_j - m_0)^2}{2\sigma^2}} > S_\alpha$



$$\text{Si } \exp - \frac{1}{2\sigma^2} \left[ \sum_{j=1}^n (x_j - m_1)^2 - \sum_{j=1}^n (x_j - m_0)^2 \right] > S_\alpha$$

(on prend le ln)

$$\text{Si } \sum_{j=1}^n (x_j^2 - 2m_1 x_j + m_1^2 - x_j^2 + 2m_0 x_j - m_0^2) < k_\alpha$$

$$\underbrace{-2(m_1 - m_0)n\bar{x}}_{< 0} + n(m_1^2 - m_0^2) < k_\alpha$$

$$\boxed{\text{Si } m_1 > m_0} \quad \boxed{\text{Rejet de } H_0 \text{ si } \bar{x} > \mu_\alpha}$$

$$\boxed{\text{Si } m_1 < m_0} \quad \boxed{\text{Rejet de } H_0 \text{ si } \bar{x} < \mu_\alpha}$$

On retrouve la stratégie du § II

Rq: Effectuer un test de NP c'est:

1) déterminer la zone de rejet de  $H_0$  (zone critique)  
région

2) On se fixe  $\alpha$  (= 0,01 par ex) et on détermine  $\mu_\alpha$

3) On calcule la statistique de test (ici  $\bar{x} = \frac{1}{n} \sum x_i$ )

que l'on compare à  $\mu_\alpha$  et on accepte ou rejette l'hypothèse  $H_0$  avec le risque  $\alpha = -$

4) On calcule  $\beta$



Une représentation habituelle permettant d'analyser les performances d'un test consiste à tracer les courbes COR (Caractéristiques Opérationnelles du Récepteur) définies par  $PD = 1 - \beta = f(\alpha)$   
 ↳ probabilité de Détection

$$\alpha = PFA = P[\text{Rejeter } H_0 / H_0 \text{ vraie}]$$


$$\beta = PND = P[\text{Rejeter } H_1 / H_1 \text{ vraie}]$$

exemple: On se fixe  $\alpha = P[\bar{X} > S_\alpha / m = m_0]$

$$= P[\bar{X} > S_\alpha / \bar{X} \sim N(m_0, \frac{\sigma^2}{n})]$$

$$= P[\underbrace{\frac{\bar{X} - m_0}{\sigma/\sqrt{n}}}_U > \frac{S_\alpha - m_0}{\sigma/\sqrt{n}} / U \sim N(0,1)]$$

$$= \int_{\frac{S_\alpha - m_0}{\sigma/\sqrt{n}}}^{+\infty} \frac{1}{\sqrt{2\pi}} e^{-u^2/2} du$$



$$\int_x^{+\infty} \frac{1}{\sqrt{2\pi}} e^{-u^2/2} du = \text{erfc}(x) \quad \text{Table}$$

↳  $\uparrow$   $\text{fit}^{\circ}$  MATLAB

$+x \nearrow, +\text{erfc} \downarrow$

Donc  $\frac{S_\alpha - m_0}{\sigma/\sqrt{n}} = \text{erfc}^{-1}(\alpha)$

$$S_\alpha = m_0 + \frac{\sigma}{\sqrt{n}} \text{erfc}^{-1}(\alpha)$$

$$PD = 1 - \beta = P[\text{accepter } H_1 / H_1 \text{ vraie}]$$

$$= P[\text{rejeter } H_0 / H_1 \text{ vraie}]$$

$$= P[\bar{X} > S_\alpha / \bar{X} \sim N(m_1, \frac{\sigma^2}{n})]$$

$$= \text{erfc}\left(\frac{S_\alpha - m_1}{\sigma/\sqrt{n}}\right) = PD$$


Courbes COR:

$$PD = \text{erfc}\left[\frac{-\sqrt{n}(m_1 - m_0)}{\sigma} + \text{erfc}^{-1}(\alpha)\right]$$

Interprétations:  $\circledast$  plus  $n \rightarrow$  plus  $\text{erfc} \rightarrow$  plus  $PD \rightarrow$   
 qd  $n \rightarrow +\infty$   $PD \rightarrow 1$



- ② plus  $m_1 - m_0 \rightarrow$  plus PD  $\rightarrow$   <sup>$H_0$  et  $H_1$  "éloignés"</sup>
- ③ plus  $\nabla \rightarrow$  plus PD  $\rightarrow$



III. 2. Cas discret:  $(X = (X_1, \dots, X_n))$  est un échantillon de VA discrètes)

Lemme de Neyman - Pearson:

Parmi tous les tests dont le risque de 1<sup>ère</sup> espèce est  $\leq \alpha$ , il en existe un de puissance (PD =  $1 - \beta$ ) maximale défini par

$$\text{Rejet de } H_0 \text{ si } \frac{L(x_1, \dots, x_n / H_1)}{L(x_1, \dots, x_n / H_0)} > S_\alpha$$

Exemple:  $X_i \sim P(\lambda)$   $(H_0) \lambda = \lambda_0$   $(H_1) \lambda = \lambda_1$  ( $\lambda_1 > \lambda_0$ )

$$\text{Rejet de } H_0 \text{ si } \frac{P[X_1 = x_1, \dots, X_n = x_n / H_1]}{P[X_1 = x_1, \dots, X_n = x_n / H_0]} > S_\alpha$$

$$\text{si } \frac{\prod_{i=1}^n e^{-\lambda_1} \frac{\lambda_1^{x_i}}{x_i!}}{\prod_{i=1}^n e^{-\lambda_0} \frac{\lambda_0^{x_i}}{x_i!}} > S_\alpha$$

$$-n(\lambda_1 - \lambda_0) + \sum_{i=1}^n x_i (\ln \lambda_1 - \ln \lambda_0) > \ln S_\alpha$$

$$\text{Rejet de } H_0 \text{ si } \sum_{i=1}^n x_i > \mu_\alpha$$



A.N.s  $n=2$   $\lambda_0 = 1$   $\lambda_1 = 2$   $\alpha = 0,05$

$$\alpha = 0,05 = P[\text{Rejeter } H_0 / H_0 \text{ vraie}] = P\left[\sum_{i=1}^2 X_i > \mu_\alpha / \lambda = \lambda_0\right]$$

Si  $\lambda = \lambda_0$   $X_i \sim P(\lambda_0)$  alors on montre que  $X_1 + X_2 \sim P(2\lambda_0)$


$$\alpha = 0,05 = P[U > \mu_\alpha / U \sim P(2)]$$

Si  $\mu_\alpha \leq 0$   $P[U > \mu_\alpha] = 1$   $\alpha = 1$

Si  $\mu_\alpha \in ]0,1]$   $P[U > \mu_\alpha] = 1 - P[U=0] = 1 - \frac{(2\lambda_0)^0}{0!} e^{-2\lambda_0} \neq 0,865$   
Table

Si  $\mu_\alpha \in ]1,2]$   $P[U > \mu_\alpha] = 1 - P[U=0 \text{ ou } U=1] \dots$

Si  $\mu_\alpha \in ]3,4]$   $P[U > \mu_\alpha] = P[U > 4] = 0,0527$



Si  $\mu_\alpha \in ]4,5]$   $P[U > \mu_\alpha] = 0,0166$

Conclusion: Le test de risque  $\alpha \leq 0,05$  le plus puissant est  
 Rejet de  $H_0$  si  $x_1 + x_2 > 5$   
 il admet un risque de 1<sup>ère</sup> espèce  $\alpha \neq 0,0166$

Rq: Si n grand, on approche la loi de U par une loi normale en vertu du théorème de la limite centrale

ici on aurait  $U = \sum_{i=1}^n X_i \approx P(n\lambda, n\lambda)$

IV Test du rapport des vraisemblances généralisé:

(ou Test GLR (Generalized Likelihood ratio))

Ce test est adapté aux hypothèses composées  $\begin{cases} H_0: \theta \in A \\ H_1: \theta \in B \end{cases}$

où les ensembles A et B ne sont pas tous deux réduits à un point.



Le test GLR est défini par

$$\text{Rejet de } H_0 \text{ si } \frac{L(x_1, \dots, x_n; \hat{\theta}_1(n))}{L(x_1, \dots, x_n; \hat{\theta}_0(n))} > S_\alpha$$

où  $\hat{\theta}_0(n)$  et  $\hat{\theta}_1(n)$  sont les estimateurs du maximum de vraisemblance de  $\theta$  sous les hypothèses  $H_0$  et  $H_1$  respectivement.

$$R_0: \frac{L(x_1, \dots, x_n; \hat{\theta}_1(n))}{L(x_1, \dots, x_n; \hat{\theta}_0(n))} = \frac{\sup_{\theta \in B} L(x_1, \dots, x_n; \theta)}{\sup_{\theta \in A} L(x_1, \dots, x_n; \theta)}$$

### IV Test du $\chi^2$ :

Le test du  $\chi^2$  est un test d'ajustement (ou d'adéquation) non paramétrique, de la forme  $H_0: L = L_0$  <sup>une certaine loi</sup>

$$H_1: L \neq L_0$$

On se propose de tester si l'échantillon  $(X_1, \dots, X_n)$  est de loi  $L_0$  (discrète ou continue) ou non.

**Principe:** On découpe le support de la loi  $L_0$  connue en  $k$  parties appelées classes et notées  $C_1 \dots C_k$ .

$$\text{On note } P_{0k} = P[X_j \in C_k \mid X_j \sim L_0]$$

Exemple:  $X_j \sim N(m, \sigma^2)$   $m=0, \sigma^2=1$   $C_1 = ]-\infty, 0[$   $C_2 = [0, 1]$   $C_3 = ]1, +\infty[$

$$P_{01} = P[X_j \in C_1] = \frac{1}{2}$$

$$P_{02} = \int_0^1 \frac{1}{\sqrt{2\pi e^{-x^2}}} dx$$

$$P_{03} = \int_1^{+\infty} \dots$$



On définit les va  $Y_j^k$  de la façon suivante :

$$Y_j^k = \begin{cases} 1 & \text{si } x_j \in C_k \\ 0 & \text{si } x_j \notin C_k \end{cases}$$

Alors  $Z_k = \sum_{j=1}^n X_j^k$  représente la va "nbre d'observations  $\in C_k$ "

D'après le théorème de la limite centrale, (les va  $Y_j^k$  sont ind. dans la mesure où les  $x_j$  le sont), pour n grand

$$Z_k \underset{\#}{\sim} \mathcal{P}(n P_{0k}, n P_{0k}(1-P_{0k})) \quad \text{car } E[Y_j^k] = 1 \cdot P[X_j \in C_k] + 0 \cdot P[X_j \notin C_k]$$

$$\text{Var } Y_j^k = P_{0k}(1-P_{0k}) = \frac{E[(Y_j^k)^2] - E[Y_j^k]^2}{P_{0k} - (P_{0k})^2}$$


De manière équivalente  $U_k = \frac{Z_k - n P_{0k}}{\sqrt{n P_{0k}}}$   $\sim N(0, 1 - P_{0k})$

Rq: les VA  $U_k$  ne sont pas indépendantes car  $\sum_{k=1}^K Z_k = n$

(n = nbre de  $x_i$ )

On admettra que sous l'hypothèse ( $H_0$ ) ( $x_i \sim L_0$ )

$$A = \sum_{k=1}^K \frac{(Z_k - n P_{0k})^2}{n P_{0k}} \xrightarrow[n \rightarrow \infty]{L} \chi_{k-1}^2$$



On rejette  $H_0$  si  $A > S_\alpha$

Le calcul de  $S_\alpha$  se fait comme suit, on se fixe  $\alpha$  (par ex 0,01)

$$\alpha = 0,01 = P[\text{rejeter } H_0 / H_0 \text{ vraie}]$$

$$= P[A > S_\alpha / x_i \sim L_0] = \int_{S_\alpha}^{+\infty} f_{k-1}(a) da \rightarrow \text{Tables du ?}$$

les tables du  $\chi^2$  donnent  $\frac{S_\alpha}{\xi}$



$$\sum_{k=1}^K \frac{(Z_k - n p_{0k})^2}{n p_{0k}} \xrightarrow[n \rightarrow +\infty]{L} \chi_{K-1}^2$$

$$Z_k = \sum_{j=1}^n Y_j^k \text{ donc } E[Z_k] = n E[Y_j^k] = n p_{0k}$$

$$\text{cov}(Z_i, Z_k) = E[Z_i Z_k] - E[Z_i] E[Z_k]$$

$$E[Z_i Z_k] = \sum_{j_1} \sum_{j_2} E[Y_{j_1}^i Y_{j_2}^k] = \sum_j E[Y_j^i Y_j^k]$$

$\underbrace{\hspace{10em}}_{0 \text{ pour } j_1 \neq j_2}$ 
 $\underbrace{\hspace{10em}}_{=0 \text{ pour } k \neq i}$

$$\text{donc } \boxed{\text{cov}(Z_i, Z_k) = -n^2 p_{0i} p_{0k}}$$

$$\text{Var } Z_i = \text{Var}\left(\sum_j Y_j^i\right) = \sum_j \text{Var}(Y_j^i) = n \left[ \underbrace{1 p_{0i} + 0(1-p_{0i})}_{E[(Y_j^i)^2]} - \underbrace{p_{0i}^2}_{(E[Y_j^i])^2} \right]$$

$$\boxed{E[Z_k] = n p_{0k}} \quad \text{et} \quad \boxed{\text{Var } Z_k = n p_{0k}(1-p_{0k})}$$

les variables aléatoires  $Z_k$  sont liées car  $\sum_{k=1}^K Z_k = n$   
↑  
 nbre d'observations  $E$  à la classe  $C_k$

Donc, on ne considère que

$$Z = \left( \frac{Z_1 - n p_{01}}{\sqrt{n}}, \frac{Z_2 - n p_{02}}{\sqrt{n}}, \dots, \frac{Z_{K-1} - n p_{0(K-1)}}{\sqrt{n}} \right) \xrightarrow[n \rightarrow +\infty]{} W(0, \Sigma)$$

$$\Sigma = \begin{pmatrix} p_1(1-p_1) & & & \\ -n p_1 p_2 & p_2(1-p_2) & & \\ & \dots & \dots & \\ -n p_1 p_{K-1} & & & p_{K-1}(1-p_{K-1}) \end{pmatrix}$$

1<sup>re</sup> théorème sur les formes quadratiques

$$X \sim N_p(\mu, \Sigma) \Rightarrow D^2 = (X - \mu)^T \Sigma^{-1} (X - \mu) \sim \chi_p^2$$

on applique ce théorème à  $Z$  et ça marche ...



$$Rq 1: A = \sum_{k=1}^K \frac{n}{p_{0k}} \left( \frac{Z_k}{n} - p_{0k} \right)^2$$

↑  
estimation de  $p_{0k}$

On comprend que si  $H_0$  est vraie  $\frac{Z_k}{n} \approx p_{0k}$  donc  $A$  est "petit"  
On aura alors  $A < S_{\alpha}$  et on acceptera  $H_0$

Rq 2: la loi de  $A$  est valable en théorie pour  $n = +\infty$ .

En pratique  $n$  est fini. On montre que la loi reste valable pour  $n$  fini si  $n p_{0k} > 4$  ou  $5 \quad \forall k$

On a intérêt à choisir des classes de façon à avoir  $p_{0k}$  "grand"  $\forall k$   
 $\Rightarrow$  classes équiprobables

Rq 3: Si  $L_0$  est imparfaitement connue ( $N_p$  paramètres inconnus)  
ex:  $N(m, \sigma^2)$ ,  $N_p = 2$

On estime  $m$  et  $\sigma^2$  et  $A \sim \chi^2_{K-1-N_p}$

VI Test de Kolmogorov: (VA continues)

Test d'ajustement:  $(H_0) L = L_0$

$(H_1) L \neq L_0$

On teste si la loi des VA  $X_i$  est  $L_0$  ou non à partir de l'observation

$x_1, \dots, x_n$ .


Le test de Kolmogorov est défini par:

$$\text{Rejet de } H_0 \text{ si } \sup_{x \in \mathbb{R}} |\hat{F}(x) - F_0(x)| > S_{\alpha}$$

où  $F_0(x)$  est la fct° de répartition théorique de  $L_0$

$$F_0(x) = \int_{-\infty}^x p_0(u) du$$

↑  
densité de proba  
associée à  $L_0$



et  $\hat{F}(x)$  est la fct° de répartition empirique




$$D_n = \sup_{x \in \mathbb{R}} |\hat{F}(x) - F_0(x)| = \sup_{i \in \{1, \dots, n\}} \left[ \max(E_i^+, E_i^-) \right]$$

$$E_i^+ = |\hat{F}(x_i^{*+}) - F_0(x_i^*)|$$

$$E_i^- = |\hat{F}(x_i^{*-}) - F_0(x_i^*)|$$

Si tous les  $x_i$  sont différents



$$\hat{F}(x_i^{*+}) = \frac{i}{n} \quad \text{et} \quad \hat{F}(x_i^{*-}) = \frac{i-1}{n}$$

$$D_n = \sup_i \left[ \max \left| \frac{i}{n} - F_0(x_i^*) \right|, \left| \frac{i-1}{n} - F_0(x_i^*) \right| \right]$$

Rq 3: • le test de Kolmogorov est plus puissant que le test du  $\chi^2$  dans la plupart des applications (puissance =  $1 - \beta$ )  
 • Attention, son utilisation est limitée aux lois continues


Rq 4:  $\alpha = P[\text{Rejeter } H_0 / H_0 \text{ vraie}]$

et on rejette  $H_0$  si  $D_n > S_\alpha$ , donc plus  $\alpha \rightarrow$   
 plus  $S_\alpha \downarrow$

et donc plus il est difficile d'accepter  $H_0$

Si on accepte  $H_0$ , le résultat est d'autant plus fiable que  $\alpha$  est grand





$$x_1^* \leq x_2^* \leq \dots \leq x_n^*$$

(On dit que  $(x_1^*, \dots, x_n^*)$  est la statistique d'ordre de  $(x_1, \dots, x_n)$ )

Rq: Si tous les  $x_i^*$  sont différents deux à deux, les sauts de la fonction en escalier sont de  $\frac{1}{n}$

On montre que  $D_n = \sup_{x \in \mathbb{R}} |\hat{F}(x) - F_0(x)|$  possède la même loi asymptotique ( $n \rightarrow \infty$ ) d'hypothèse  $H_0$  quelle que soit la loi à tester  $L_0$

$$P[\sqrt{n} D_n < y] \xrightarrow{n \rightarrow \infty} \sum_{k=-\infty}^{+\infty} (-1)^k \exp(-2k^2 y) = k(y)$$

Détermination de  $S_\alpha$ :

$$\alpha = P[\text{Rejeter } H_0 / H_0 \text{ vraie}]$$

$$\alpha = P[D_n > S_\alpha / H_0 \text{ vraie}]$$

$$\alpha = 1 - P[D_n \leq S_\alpha]$$

$$\alpha = 1 - P[\sqrt{n} D_n \leq \sqrt{n} S_\alpha]$$

$$\alpha \underset{\text{ngd}}{\#} 1 - k(\sqrt{n} S_\alpha)$$

On a alors construit des tables qui donnent  $S_\alpha$  en fonction de  $\alpha$

Rq 1: pour  $n \geq 80$      $\alpha = 0,05$      $S_\alpha \# \frac{1,3581}{\sqrt{n}}$

$\alpha = 0,01$      $S_\alpha \# \frac{1,6276}{\sqrt{n}}$

Rq 2: Calcul de  $D_n$

