

Faculté des Sciences Juridiques  
Economiques & Sociales –Fes-

**D.TOUIJAR**  
**2010-11**

# LES TESTS D'HYPOTHESE

**SEMESTRE 5**

Sections **C & D**

# Attention !

*N'essayez pas de comprendre le cours en lisant  
tout (e) seul(e) Ce document.*

*Par contre, je vous recommande vivement d'assister à  
toutes les séances en espérant mieux cerner le  
programme de statistique IV*

# INTRODUCTION GENERALE

- Il y a en statistique deux approches: La description et L'inférence.
- L'inférence statistique , rappelons le, a pour but d'étendre les propriétés de l'échantillon à la population entière et de valider ou de rejeter des hypothèses a priori ou formulées après une étape descriptive.

Les deux principaux champs d'étude de  
**l'inférence statistique** sont :

- L'estimation de paramètres : déjà traité en S4 (statistique III).
- Les Tests statistiques : qui font l'objet du programme de ce semestre **5**.

# PROGRAMME DE CE SEMESTRE

- **Chapitre 1: Les Tests paramétriques**
- **Chapitre 2: Les Tests non paramétriques**

# BIBLIOGRAPHIE

<b>Titre</b>	<b>Auteurs</b>	<b>Code</b>
Handbook of PARAMETRIC and NONPARAMETRIC STATISTICAL PROCEDURES	DJ. Sheskin	
Méthodes statistiques	B. Grais	stat22
Introduction à la statistique	J.P Bélisle ;J.Desrosiers	stat20
Eléments de statistiques	J. Desrosiers	stat25

# **Chapitre 1**

## **Les Tests paramétriques**

# Introduction

- Soit  $X_1, X_2, \dots, X_n$  un échantillon aléatoire relatif à la V.A. parente  $X$  de loi  $\mathcal{L}(\theta)$ , où  $\theta \in \Theta$  est un paramètre réel inconnu.
- Le semestre précédent, on cherchait à estimer  $\theta$ . Mais il arrive qu'on ait une idée préconçue sur sa valeur:  $\theta = \theta_0$
- On désire alors tester la validité de cette hypothèse, en la confrontant à une hypothèse alternative.

– Cette dernière exprime une tendance différente au sujet du paramètre.

– **Exemple :**

- Est-ce que le taux de chômage au Maroc est  $p_0$  ?
- Est-ce que l'espérance de vie au Maroc est  $\mu_0$  ? ...ou a augmenté ?

# Méthodologie du test d'hypothèse

– On suppose que  $\Theta$  est partitionné en  $\Theta_0$  et  $\Theta_1$ :

$$\Theta = \Theta_0 \cup \Theta_1 \quad \text{et} \quad \Theta_0 \cap \Theta_1 = \emptyset$$

– Exprimons le fait que  $\theta \in \Theta_0$  par l'hypothèse  $H_0$

et le fait que  $\theta \in \Theta_1$  par  $H_1$

✓  $H_0$ : «  $\theta \in \Theta_0$  »

✓  $H_1$ : «  $\theta \in \Theta_1$  »

**Définition:** Un test d'hypothèse, est une règle de décision permettant, au vu de la réalisation  $(x_1, x_2, \dots, x_n)$  de l'E.A., de répondre à la question « dans lequel des deux sous ensemble se trouve  $\theta$ ? »

➤  $H_0$  : s'appelle l'hypothèse nulle.

➤  $H_1$  : s'appelle l'hypothèse alternative.

➤ Si  $\Theta_0$  se réduit au seul point  $\theta_0$  :  $\Theta_0 = \{\theta_0\}$

$H_0$  devient  $H_0 : \ll \theta = \theta_0 \gg$  et sera appelée l'hypothèse simple.

➤ Soit l'hypothèse simple  $H_0: \ll \theta = \theta_0 \gg$

➤ Si  $H_1$  est telle que  $H_1: \ll \theta > \theta_0 \gg$  ; alors on dit que le test est unilatéral à droite:

$$T.U.D. \left\{ \begin{array}{l} H_0 : " \theta = \theta_0 " \\ \# \\ H_1 : " \theta > \theta_0 " \end{array} \right.$$

➤ Si  $H_1$  est telle que  $H_1: \ll \theta < \theta_0 \gg$  ; alors on dit que le test est unilatéral à gauche:

$$T.U.G. \left\{ \begin{array}{l} H_0 : " \theta = \theta_0 " \\ \# \\ H_1 : " \theta < \theta_0 " \end{array} \right.$$

➤ Si  $H_1$  est telle que  $H_1: \ll \theta \neq \theta_0 \gg$  ;

alors on dit que le test est bilatéral :

$$T.B. \left\{ \begin{array}{l} H_0 : " \theta = \theta_0 " \\ \# \\ H_1 : " \theta \neq \theta_0 " \end{array} \right.$$

- **Exemple Introductif :**

- un fabricant de lessive prétend que son produit est efficace dans 75% des cas. Une association de consommateurs désire tester le produit.

- A notre problème on associe le modèle statistique suivant:

Notons par **X** la V.A. qui donne le résultat de l'utilisation du détachant sur un vêtement:

- $X = \begin{cases} 1 & \text{avec proba} = p & \text{si la tâche disparaît} \\ 0 & \text{avec proba} = 1 - p & \text{si la tâche persiste} \end{cases}$

- D'où

- $X \rightsquigarrow \mathcal{B}(p)$

- Soit  $X_1, X_2, \dots, X_{100}$  l'E.A. relatif à  $X$

- Alors  $F = \frac{S_{100}}{100} = \frac{X_1 + X_2 + \dots + X_{100}}{100}$  est le

meilleur estimateur de  $p$ .

- On a alors 2 hypothèses opposées :

- La première est soutenue par le fabricant

$$H_0 : \ll p = 0,75 \gg$$


- Ce que conteste l'association, en lui opposant une hypothèse alternative:

$$H_1 : \ll p < 0,75 \gg$$

- Alors avec un peu de bon sens, l'association suit la procédure suivante:

On accepte le produit si  $f \geq 70\%$   
donc pas de poursuite judiciaire.

On refuse si  $f < 70\%$



- Où  $f$  est la proportion des 100 vêtements tachés et testés pour lesquels le produit a été efficace.
- Cette procédure s'appelle « **Règle de décision** ». Et  $c = 70\% = 0,70$  s'appelle **valeur critique** du test.

$$\begin{cases} \text{Si } f < c = 0,7 \text{ alors } H_0 \text{ est rejetée au profit de } H_1 \\ \text{Si } f \geq c = 0,7 \text{ alors } H_0 \text{ n'est pas rejetée.} \end{cases}$$

 Remarque :

- $R_0 = [0 ; 0,7[$  : zone de rejet de  $H_0$   
=Région critique
- $\bar{R}_0 = [0,7 ; 1]$  : zone de non-rejet de  $H_0$   
=Région d'acceptation
- Cette règle de décision peut conduire à deux types d'erreurs:

- On rejette  $H_0$  alors que  $H_0$  est vraie:

$RH_0/H_0$  vraie

- On l'appelle « **erreur de première espèce** »

- On ne rejette pas  $H_0$  alors que  $H_1$  est vraie:

$NRH_0/H_1$  vraie;

- c'est « **l'erreur de seconde espèce** ».

- On définit alors la probabilité de commettre l'une ou l'autre erreur:

- 1)-

$$\alpha = P(RH_0 / H_0 \text{ Vraie}) = P_0(RH_0)$$

- C'est le **risque** de première espèce.

- 2)-

$$\beta = P(NRH_0 / H_1 \text{ Vraie}) = P_1(NRH_0)$$

- C'est le **risque** de seconde espèce.

- Définition: On appelle puissance du test la quantité  $\pi$  :

$$\pi = 1 - \beta = P_1(RH_0)$$

- Voici un tableau résumant toutes les situations

Décision \ Réalité	$RH_0$	$NRH_0$
$H_0$ Vraie	Erreur de 1 <sup>ère</sup> espèce	Bonne Décision
$H_1$ Vraie	Bonne Décision	Erreur de 2 <sup>ème</sup> espèce

+  $\alpha$  est généralement **petit**; c'est le risque que court l'association en lançant, à tort, une action contre le fabricant.

- **Question:** Quel risque court l'association en lançant, à tort, une action contre le fabricant ?
- Calculons dans notre cas  $\alpha$  :
- Si  $H_0$  est vraie, alors  $X \rightsquigarrow \mathcal{B}(0,75)$ .

- En supposant les cond<sup>θ</sup> T.C.L. vérifiées sous  $H_0$  :

- $$Z = \sqrt{n} \frac{F - 0,75}{\sqrt{0,75 \times 0,25}} \approx \mathcal{N}(0, 1).$$

$$\alpha = P_0(F < 0,7) = P_0\left(Z < 10 \times \frac{0,7 - 0,75}{0,43}\right)$$

$$= P_0(Z < -1,16) = P_0(Z > 1,16) = 12,3\%$$

- **Problème:** Peut-on contrôler le risque  $\alpha$ , en jouant sur la valeur critique  $c$  ?
- **Réponse : Oui**
- **Exemple :** si on pense que prendre un risque de 5% est acceptable, on a :

$$\alpha = 0,05 = P_0(RH_0) = P_0(F < c) = P_0\left(Z < \sqrt{n} \times \frac{c - p_0}{\sqrt{p_0 q_0}}\right)$$

$$\Rightarrow \frac{c - 0,75}{0,43} \times 10 = -z_{0,05} = -1,645 \Rightarrow c = p_0 - z_\alpha \sqrt{\frac{p_0 q_0}{n}} = 0,68$$

- A partir du seuil  $c=68\%$  on rejette  $H_0$

# Que signifie l'hypothèse nulle?

- - hypothèse sur la base de laquelle est définie la distribution de probabilité (théorie de la décision):
  - L'hypothèse  $H_0$  entraîne la connaissance de la loi de la statistique de test .

Par exemple, si le dé est équilibré, l'hypothèse nulle entraîne que le nombre d'apparition d'un numéro (cinq par exemple) sur  $n$  lancers, suit la loi binomiale  $\mathcal{B}(n, p_0)$ , où  $p_0$  est la probabilité (supposée connue) ici égale à  $1/6$ .

- Négation d'une hypothèse de recherche.
- Spécification d'un paramètre égal à zéro.  
L'hypothèse nulle est exacte ( $\mu=\mu_0$ ), l'hypothèse alternative est indéfinie:
  - L'hypothèse nulle  $H_0$  est une hypothèse de non différence [ il n'y a pas de différence significative entre les échantillons A et B]. Elle est formulée de façon à être rejetée.
- La statistique inférentielle procède généralement par le rejet de l'hypothèse nulle.
- Un test d'hypothèse constitue donc une sorte de démonstration par l'absurde en probabilité.

- La conclusion finale, une fois que le test a été effectué, est toujours donnée en termes d'hypothèse nulle. Soit qu'on conclue "rejetons  $H_0$  en faveur de  $H_1$ " ou qu'on conclue "ne pas rejeter  $H_0$ "; nous ne concluons jamais "rejeter  $H_1$ ", ou même "accepter  $H_1$ ".
- Si nous concluons "ne pas rejeter  $H_0$ ", ceci ne signifie pas nécessairement que l'hypothèse nulle est vraie, il suggère seulement qu'il n'y ait pas d'évidence suffisante contre  $H_0$  en faveur de  $H_1$ . Rejeter l'hypothèse nulle suggère, alors, que l'hypothèse alternative *peut* être vraie.

# **ANALYSE UNIVARIEE**

## **Cas d'un seul ECHANTILLON**

**(Comparaison par rapport à 1 standard (ou fixe))**

# I- Tests Relatifs à Une Proportion

- **1- Test Unilatéral à gauche pour la proportion**

- *i)* Formulation des hypothèses

$$T.U.G. \begin{cases} H_0 : " p = p_0 " \\ \# \\ H_1 : " p < p_0 " \end{cases}$$

- *ii)* si le T.C.L. est vérifié sous  $H_0$  alors


R.D

$$\begin{cases} Si f < c_\alpha = p_0 - z_\alpha \sqrt{\frac{p_0 q_0}{n}} \text{ on rejette } H_0 \\ Si f \geq c_\alpha = p_0 - z_\alpha \sqrt{\frac{p_0 q_0}{n}} \text{ on ne rejette pas } H_0 \end{cases}$$

En effet; commençons d'abord par un petit rappel sur les valeurs critiques :

*Courbe de densité de la loi normale centrée réduite*

$$Z = \frac{F - p_0}{\sqrt{p_0 q_0 / n}}$$




où

$$P(Z > +z_\alpha) = \alpha$$

et

$$\text{où } z_\alpha = -z_{1-\alpha}$$

D'où :



$$\alpha = P_0(RH_0) = P_0(F < c_\alpha) = P_0 \left( \frac{F - p_0}{\sqrt{p_0 q_0 / n}} < \frac{c_\alpha - p_0}{\sqrt{p_0 q_0 / n}} \right)$$

$$\Rightarrow \frac{c_\alpha - p_0}{\sqrt{p_0 q_0 / n}} = -z_\alpha \Rightarrow c_\alpha = p_0 - z_\alpha \sqrt{p_0 q_0 / n}$$

- **Calcul du risque  $\beta$  (pour un risque  $\alpha$  fixé):**
  - Puisque l'hypothèse alternative  $H_1$  est composée, alors pour chaque valeur du paramètre  $p$  de  $H_1$ , on peut calculer un  $\beta$  (respectivement un  $\pi$ ). Soit  $p_1$  cette valeur, alors :

$$\beta_1 = P(F \geq c_\alpha / p = p_1) = P_1(F \geq c_\alpha)$$

$$\pi_1 = P(F < c_\alpha / p = p_1) = P_1(F < c_\alpha)$$

- Revenons à notre exemple et calculons  $\pi$  pour  $p = p_1 = 0,65$  et  $\alpha = 5\%$ :

$$\pi_1 = P_1(F < c_\alpha) = P_1 \left( \underbrace{\sqrt{n} \frac{F - p_1}{\sqrt{p_1 q_1}}}_{Z_1} < \sqrt{n} \frac{c_\alpha - p_1}{\sqrt{p_1 q_1}} \right)$$

- Sous  $H_1$ ,  $Z_1$  est normale; or  $c_\alpha = 0,68$   
d'où :

$$\pi_1 = P_1(Z_1 < 0,629) = 73,5\%$$

$$\Rightarrow \beta_1 = 26,5\%$$

- **Si**  $p = p_2 = 0,60$  :



$$\pi_2 = P_1(Z_2 < 1,63) = 94,8\%$$

$$\Rightarrow \beta_2 = 5,2\%$$

- **Remarque:** Plus  $p_1$  s'éloigne de  $p_0$  et plus la puissance du test augmente ( $\beta \downarrow$ ) et réciproquement. Autrement, lorsque les deux hypothèses  $H_0$  et  $H_1$  sont très différents, la probabilité de commettre l'erreur de second espèce est faible.
- Si  $\alpha$  et  $\beta$  sont petits, on dit que le test une bonne règle de décision.

**Loi de  
F sous  
 $H_1$**

**Loi de  
F sous  
 $H_0$**



- **Remarque** : Les logiciels utilisent souvent le niveau de signification  $\alpha_0$  (*p-value*) d'une réalisation  $f$  de  $F$  : c'est le plus petit  $\alpha$  à partir duquel on ne peut plus rejeter  $H_0$  :

$$P_0(F < f) = \alpha_0$$

Si dans notre exemple on suppose que  $f = 0,65$

Alors :  $\alpha_0 = P_0(F < f)$   
 $= P_0(Z < -2,309) = 1\%$

Le test est donc significatif à 5%

Signe de la région de Rejet

$\alpha_0$ P-value	Interpretation
$\alpha_0 < 0,01$	very strong evidence against $H_0$
$0,01 \leq \alpha_0 < 0,05$	moderate evidence against $H_0$
$0,05 \leq \alpha_0 < 0,10$	suggestive evidence against $H_0$
$0,10 \leq \alpha_0$	little or no real evidence against $H_0$

- **2- Test Unilatéral à droite pour la proportion**


- *i)-F.H.*

$$T.U.D. \begin{cases} H_0 : " p = p_0 " \\ \# \\ H_1 : " p > p_0 " \end{cases}$$

- *ii)* si le T.C.L. est vérifié sous  $H_0$  alors la règle de décision devient :

$$\underline{\mathbf{R.D}} \begin{cases} \text{Si } f > c_\alpha = p_0 + z_\alpha \sqrt{\frac{p_0 q_0}{n}} \text{ on rejette } H_0 \\ \text{Si } f \leq c_\alpha = p_0 + z_\alpha \sqrt{\frac{p_0 q_0}{n}} \text{ on ne rejette pas } H_0 \end{cases}$$

En effet :



$$\alpha = P_0(RH_0) = P_0(F > c_\alpha) = P_0 \left( \frac{F - p_0}{\sqrt{p_0 q_0 / n}} > \frac{c_\alpha - p_0}{\sqrt{p_0 q_0 / n}} \right)$$

$$\Rightarrow \frac{c_\alpha - p_0}{\sqrt{p_0 q_0 / n}} = +z_\alpha \Rightarrow c_\alpha = p_0 + z_\alpha \sqrt{p_0 q_0 / n}$$

- **Remarque** : La *p-value* ici vaut :

$$\alpha_0 = P_0(F > f)$$

Si on teste  $p = 0,75$  #  $p > 0,75$  et si F vaut  $f = 0,65$

Alors :

$$\begin{aligned}\alpha_0 &= P_0(F > f) \\ &= P_0(Z > -2,309) = 99\%\end{aligned}$$

Le test n'est donc pas significatif à 5% ni à 95%

### 3- Test Bilatéral pour la proportion


F.H

$$T.B. \left\{ \begin{array}{l} H_0 : "p = p_0" \\ \# \\ H_1 : "p \neq p_0" \end{array} \right.$$

- Si T.C.L. On adopte la Règle de décision suivante :

R.D

$$\left\{ \begin{array}{l} Si f \notin [c_1; c_2] \text{ on rejette } H_0 \\ Si f \in [c_1; c_2] \text{ on ne rejette pas } H_0 \end{array} \right.$$



or  $f \in [c_1, c_2] \Leftrightarrow f \in [p_0 - c, p_0 + c] \Leftrightarrow |f - p_0| \leq c$

d'où  $f \notin [c_1, c_2] \Leftrightarrow |f - p_0| > c$

$$\alpha = P_0(RH_0) = P_0(|F - p_0| > c) = P_0\left(\frac{|F - p_0|}{\sqrt{p_0 q_0/n}} > \frac{c}{\sqrt{p_0 q_0/n}}\right)$$

$$\Rightarrow \frac{c}{\sqrt{p_0 q_0/n}} = z_{\alpha/2} \Rightarrow c = z_{\alpha/2} \sqrt{p_0 q_0/n}$$

- D'où:

R.D

$$\left\{ \begin{array}{l} \text{Si } |f - p_0| > z_{\alpha/2} \sqrt{\frac{p_0 q_0}{n}} \quad \text{on rejette } H_0 \\ \text{Si } |f - p_0| \leq z_{\alpha/2} \sqrt{\frac{p_0 q_0}{n}} \quad \text{on ne rejette pas } H_0 \end{array} \right.$$

**Remarque** Si on teste  $p = 0,75 \# p \neq 0,75$  et si F vaut  $f = 0,65$ , alors la *p-value* vaut ici :

$$\alpha_0 = P_0 \left( \left| \frac{F - p_0}{\sqrt{\frac{p_0 q_0}{n}}} \right| > \left| \frac{f - 0,75}{\sqrt{\frac{0,75 \times 0,25}{100}}} \right| \right)$$
$$= P_0 (|Z| > +2,309) = 2\%$$

Le test est donc significatif à **5%** et même à **2,5%**

## II- Tests Relatifs à Une Moyenne

- **1- Test Unilatéral à droite pour la moyenne**
- **Question** : est-ce que l'espérance de vie des marocains a augmenté depuis le dernier recensement ?
- Pour répondre à cette question, on doit confronter 2 hypothèses:

• *i)*-

$$T.U.D. \begin{cases} H_0 : " \mu = \mu_0 " \\ \# \\ H_1 : " \mu > \mu_0 " \end{cases}$$

• *ii)*-On adopte ensuite une Règle de décision basée sur la statistique  $\bar{X}$  et qui répondra à la question: à partir de quelle réalisation de  $\bar{X}$  décidera-t-on du rejet de  $H_0$  pour un risque  $\alpha$  ?

$$\begin{cases} Si \bar{x} > c & \text{on rejette } H_0 \\ Si \bar{x} \leq c & \text{on ne rejette pas } H_0 \end{cases}$$

- **1)- Détermination de C en fonction du risque  $\alpha$  :**

**a)** Si  $\sigma$  est connu et ( $X$  est normale ou  $n \geq 30$ )

$$\alpha = P_0(RH_0) = P_0(\bar{X} > c) = P_0\left(Z > \sqrt{n} \times \frac{c - \mu_0}{\sigma}\right)$$

$$\Rightarrow \frac{c - \mu_0}{\sigma} \times \sqrt{n} = z_\alpha \Rightarrow c = \mu_0 + z_\alpha \frac{\sigma}{\sqrt{n}}$$

D'où la règle de décision :

$$\left\{ \begin{array}{l} \text{Si } \bar{x} > c_{\alpha} = \mu_0 + z_{\alpha} \frac{\sigma}{\sqrt{n}} \quad \text{on rejette } H_0 \\ \text{Si } \bar{x} \leq c_{\alpha} = \mu_0 + z_{\alpha} \frac{\sigma}{\sqrt{n}} \quad \text{on ne rejette pas } H_0 \end{array} \right.$$

**b)** Si  $\sigma$  est inconnu et  $X$  est normale; on a la règle de décision :

$$\left\{ \begin{array}{l} \text{Si } \bar{x} > c_{\alpha} = \mu_0 + t_{n-1;\alpha} \frac{s}{\sqrt{n}} \quad \text{on rejette } H_0 \\ \text{Si } \bar{x} \leq c_{\alpha} = \mu_0 + t_{n-1;\alpha} \frac{s}{\sqrt{n}} \quad \text{on ne rejette pas } H_0 \end{array} \right.$$

**c)** Si  $\sigma$  est inconnu et  $n \geq 50$  ; on a la règle de décision

$$\left\{ \begin{array}{l} \text{Si } \bar{x} > c_{\alpha} = \mu_0 + z_{\alpha} \frac{s}{\sqrt{n}} \quad \text{on rejette } H_0 \\ \text{Si } \bar{x} \leq c_{\alpha} = \mu_0 + z_{\alpha} \frac{s}{\sqrt{n}} \quad \text{on ne rejette pas } H_0 \end{array} \right.$$

## II- Tests Relatifs à Une Moyenne

- 2- Test Unilatéral à gauche pour la moyenne

On doit confronter les deux hypothèses suivantes

1)-

$$T.U.G. \begin{cases} H_0 : " \mu = \mu_0 " \\ \# \\ H_1 : " \mu < \mu_0 " \end{cases}$$

• *ii*) - On adopte ensuite une Règle de décision basée sur la statistique  $\bar{X}$  et qui répondra à la question: à partir de quelle réalisation de  $\bar{X}$  décidera-t-on du rejet de  $H_0$  ?

$$\begin{cases} \text{Si } \bar{x} < c & \text{on rejette } H_0 \\ \text{Si } \bar{x} \geq c & \text{on ne rejette pas } H_0 \end{cases}$$

• De la même façon que précédemment, on a les règles de décision selon les cas :

**a)** Si  $\sigma$  est connu et ( $X$  est normale ou  $n \geq 30$ )

$$\left\{ \begin{array}{l} \text{Si } \bar{x} < c_{\alpha} = \mu_0 - z_{\alpha} \frac{\sigma}{\sqrt{n}} \quad \text{on rejette } H_0 \\ \text{Si } \bar{x} \geq c_{\alpha} = \mu_0 - z_{\alpha} \frac{\sigma}{\sqrt{n}} \quad \text{on ne rejette pas } H_0 \end{array} \right.$$

**b)** Si  $\sigma$  est inconnu et  $X$  est normale; on a la règle de décision :

$$\left\{ \begin{array}{l} \text{Si } \bar{x} < c_{\alpha} = \mu_0 - t_{n-1;\alpha} \frac{s}{\sqrt{n}} \quad \text{on rejette } H_0 \\ \text{Si } \bar{x} \geq c_{\alpha} = \mu_0 - t_{n-1;\alpha} \frac{s}{\sqrt{n}} \quad \text{on ne rejette pas } H_0 \end{array} \right.$$

c) Si  $\sigma$  est inconnu et  $n \geq 50$  ; on a la règle de décision

:

$$\left\{ \begin{array}{l} \text{Si } \bar{x} < c_{\alpha} = \mu_0 - z_{\alpha} \frac{s}{\sqrt{n}} \quad \text{on rejette } H_0 \\ \text{Si } \bar{x} \geq c_{\alpha} = \mu_0 - z_{\alpha} \frac{s}{\sqrt{n}} \quad \text{on ne rejette pas } H_0 \end{array} \right.$$

## II- Tests Relatifs à Une Moyenne


### 3- Test Bilatéral pour la moyenne

i)-

$$T.B. \left\{ \begin{array}{l} H_0 : " \mu = \mu_0 " \\ \# \\ H_1 : " \mu \neq \mu_0 " \end{array} \right.$$

*ii*)-On adopte la Règle de décision suivante :

$$\begin{cases} \text{Si } \bar{x} \notin [c_1; c_2] & \text{on rejette } H_0 \\ \text{Si } \bar{x} \in [c_1; c_2] & \text{on ne rejette pas } H_0 \end{cases}$$



$$\begin{aligned}\bar{x} \in [c_1; c_2] &\Leftrightarrow c_1 \leq \bar{x} \leq c_2 \Leftrightarrow \mu_0 - c \leq \bar{x} \leq \mu_0 + c \\ &\Leftrightarrow -c \leq \bar{x} - \mu_0 \leq +c \Leftrightarrow |\bar{x} - \mu_0| \leq c\end{aligned}$$

D'où la règle de décision suivante

$$\left\{ \begin{array}{l} \text{Si } |\bar{x} - \mu_0| > c \text{ on rejette } H_0 \\ \text{Si } |\bar{x} - \mu_0| \leq c \text{ on ne rejette pas } H_0 \end{array} \right.$$

On a les règles de décision selon les cas :

**a)** Si  $\sigma$  est connu et ( $X$  est normale ou  $n \geq 30$ )

$$\left\{ \begin{array}{l} \text{Si } |\bar{x} - \mu_0| > z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \quad \text{on rejette } H_0 \\ \text{Si } |\bar{x} - \mu_0| \leq z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \quad \text{on ne rejette pas } H_0 \end{array} \right.$$

**b)** Si  $\sigma$  est inconnu et  $X$  est normale

$$\left\{ \begin{array}{l} \text{Si } |\bar{x} - \mu_0| > t_{n-1; \alpha/2} \frac{s}{\sqrt{n}} \quad \text{on rejette } H_0 \\ \text{Si } |\bar{x} - \mu_0| \leq t_{n-1; \alpha/2} \frac{s}{\sqrt{n}} \quad \text{on ne rejette pas } H_0 \end{array} \right.$$

**c)** Si  $\sigma$  est inconnu et  $n \geq 50$  ; on a

$$\left\{ \begin{array}{l} \text{Si } |\bar{x} - \mu_0| > z_{\alpha/2} \frac{s}{\sqrt{n}} \quad \text{on rejette } H_0 \\ \text{Si } |\bar{x} - \mu_0| \leq z_{\alpha/2} \frac{s}{\sqrt{n}} \quad \text{on ne rejette pas } H_0 \end{array} \right.$$

### III- Tests Relatifs à Une Variance

- Dans ce paragraphe on supposera la normalité de la population
- **1- Test Unilatéral à droite pour la variance**

$$T.U.D. \begin{cases} H_0 : " \sigma^2 = \sigma_0^2 " \\ \# \\ H_1 : " \sigma^2 > \sigma_0^2 " \end{cases}$$

De la même façon que précédemment, on a les règles de décision selon les cas :

**a)** Si  $\mu$  est inconnue

La statistique utilisée est  $S^2$ ; d'où la R.D. est :

$$\left\{ \begin{array}{l} \text{Si } s^2 > \chi_{n-1;\alpha}^2 \frac{\sigma_0^2}{n-1} \quad \text{on rejette } H_0 \\ \text{Si } s^2 \leq \chi_{n-1;\alpha}^2 \frac{\sigma_0^2}{n-1} \quad \text{on ne rejette pas } H_0 \end{array} \right.$$

## 2- Test Unilatéral à gauche pour la variance

$$T.U.G. \begin{cases} H_0 : " \sigma^2 = \sigma_0^2 " \\ \# \\ H_1 : " \sigma^2 < \sigma_0^2 " \end{cases}$$

R.D. (pour  $\mu$  inconnue)

$$\begin{cases} Si \quad s^2 < \chi_{n-1;1-\alpha}^2 \frac{\sigma_0^2}{n-1} & \text{on rejette } H_0 \\ Si \quad s^2 \geq \chi_{n-1;1-\alpha}^2 \frac{\sigma_0^2}{n-1} & \text{on ne rejette pas } H_0 \end{cases}$$

### 3- Test Bilatéral pour la variance

$$T.B. \begin{cases} H_0 : " \sigma^2 = \sigma_0^2 " \\ \# \\ H_1 : " \sigma^2 \neq \sigma_0^2 " \end{cases}$$

Si  $\mu$  est inconnue

$$\left\{ \begin{array}{l} \text{Si } s^2 \notin \left[ \chi_{n-1;1-\alpha/2}^2 \frac{\sigma_0^2}{n-1} ; \chi_{n-1;\alpha/2}^2 \frac{\sigma_0^2}{n-1} \right] \\ \text{on rejette } H_0 \\ \text{Si } s^2 \in \left[ \chi_{n-1;1-\alpha/2}^2 \frac{\sigma_0^2}{n-1} ; \chi_{n-1;\alpha/2}^2 \frac{\sigma_0^2}{n-1} \right] \\ \text{on ne rejette pas } H_0 \end{array} \right.$$

# **ANALYSE UNIVARIEE**

## **Cas de 2 Echantillons Indépendants**

**(Comparaison de 2 paramètres)**

- **1- Test Bilatéral de comparaison de 2 Variances :**

- On suppose la normalité des 2 populations

- F.H.

$$\left\{ \begin{array}{l} H_0 : \sigma_1^2 = \sigma_2^2 \\ \# \\ H_1 : \sigma_1^2 \neq \sigma_2^2 \end{array} \right. \Leftrightarrow \left\{ \begin{array}{l} H_0 : \frac{\sigma_1^2}{\sigma_2^2} = 1 \\ \# \\ H_1 : \frac{\sigma_1^2}{\sigma_2^2} \neq 1 \end{array} \right.$$

## Cas où $\mu$ est inconnue

- Rapport critique (sous  $H_0$ ):

$$R_c = \frac{S_1^2}{S_2^2} \quad \text{Si } s_1^2 > s_2^2$$

Sinon  $R_c = \frac{S_2^2}{S_1^2}$  et F.H. devient alors

$$\left\{ \begin{array}{l} H_0 : \sigma_2^2 / \sigma_1^2 = 1 \\ H_1 : \sigma_2^2 / \sigma_1^2 \neq 1 \end{array} \right.$$

- Loi de  $R_c$  sous  $H_0$  :

$$R_c \rightsquigarrow \mathcal{F}(v_1; v_2)$$

- **R.D.**

$$\left\{ \begin{array}{l} \text{Si } r_c \notin \left[ F_{1-\alpha/2} (v_1; v_2) ; F_{\alpha/2} (v_1; v_2) \right] \\ \text{on rejette } H_0 \\ \text{Si } r_c \in \left[ F_{1-\alpha/2} (v_1; v_2) ; F_{\alpha/2} (v_1; v_2) \right] \\ \text{on ne rejette pas } H_0 \end{array} \right.$$

où  $v_i = n_i - 1$

- 2- Test Bilatéral de comparaison de 2 moyennes :

$$\begin{cases} H_0 : \mu_1 = \mu_2 \\ \# \\ H_1 : \mu_1 \neq \mu_2 \end{cases} \Leftrightarrow \begin{cases} H_0 : \mu_1 - \mu_2 = 0 \\ \# \\ H_1 : \mu_1 - \mu_2 \neq 0 \end{cases}$$

- On propose  $\bar{X}_1 - \bar{X}_2$  comme estimateur de  $\mu_1 - \mu_2$  :

- a)** Si  $\sigma_1$  et  $\sigma_2$  connus et ( $X_1$  normale ou  $n_1 \geq 30$ ) et ( $X_2$  normale ou  $n_2 \geq 30$ )

**R.D.**

$$\text{Si } |\bar{x}_1 - \bar{x}_2| > z_{\alpha/2} \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}} \quad \text{on rejette } H_0$$

$$\text{Si } |\bar{x}_1 - \bar{x}_2| \leq z_{\alpha/2} \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}} \quad \text{on ne rejette}$$

pas  $H_0$

b) Si  $\sigma_1$  et  $\sigma_2$  inconnus mais égales et  $X_1$  et  $X_2$  normales, alors la R.D. est la suivante :

$$\text{Si } |\bar{x}_1 - \bar{x}_2| > t_{\alpha/2; n_1+n_2-2} \hat{s} \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}$$

on rejette  $H_0$

$$\text{Si } |\bar{x}_1 - \bar{x}_2| \leq t_{\alpha/2; n_1+n_2-2} \hat{s} \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}$$

on ne rejette pas  $H_0$

•Où

$$\hat{S}^2 = \frac{(n_1 - 1)S_1^2 + (n_2 - 1)S_2^2}{(n_1 - 1) + (n_2 - 1)}$$

•c) Si  $\sigma_1$  et  $\sigma_2$  inconnus et  $n_1 \geq 50$  ,  $n_2 \geq 50$   
alors la R.D. est la suivante :

$$\left\{ \begin{array}{l}
 \text{Si } |\bar{x}_1 - \bar{x}_2| > z_{\alpha/2} \sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}} \quad \text{on rejette } H_0 \\
 \\
 \text{Si } |\bar{x}_1 - \bar{x}_2| \leq z_{\alpha/2} \sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}} \quad \text{on ne rejette} \\
 \text{pas } H_0
 \end{array} \right.$$

- **3- Test Bilatéral de comparaison de 2 Proportions :**

$$\begin{cases} H_0 : p_1 = p_2 \\ \# \\ H_1 : p_1 \neq p_2 \end{cases} \Leftrightarrow \begin{cases} H_0 : p_1 - p_2 = 0 \\ \# \\ H_1 : p_1 - p_2 \neq 0 \end{cases}$$

- On pose  $p_1 = p_2 = p$  et on propose comme estimateur de la proportion commune la fréquence commune des 2 échantillons :

$$f = \frac{n_1 f_1 + n_2 f_2}{n_1 + n_2}$$

- On suppose les conditions T.C.L. vérifiées sous  $H_0$
- La statistique utilisée est  $F_1 - F_2$
- Rapport critique (sous  $H_0$ ):

$$R_c = \frac{F_1 - F_2}{\sqrt{pq(1/n_1 + 1/n_2)}}$$
$$\approx \frac{F_1 - F_2}{\sqrt{f(1-f)(1/n_1 + 1/n_2)}}$$

- **R.D.**

$$\left\{ \begin{array}{l} \textit{Si } r_c \notin \left[ -z_{\alpha/2} ; +z_{\alpha/2} \right] \\ \text{on rejette } H_0 \\ \textit{Si } r_c \in \left[ -z_{\alpha/2} ; +z_{\alpha/2} \right] \\ \text{on ne rejette pas } H_0 \end{array} \right.$$

- **R.D.** s'écrit aussi :

$$\left\{ \begin{array}{l} \text{Si } |f_1 - f_2| > +z_{\alpha/2} \sqrt{f(1-f)(1/n_1 + 1/n_2)} \\ \text{on rejette } H_0 \\ \text{Si } |f_1 - f_2| \leq +z_{\alpha/2} \sqrt{f(1-f)(1/n_1 + 1/n_2)} \\ \text{on ne rejette pas } H_0 \end{array} \right.$$

# **ANALYSE UNIVARIEE**

## **Cas de 2 Echantillons Dépendants**

**(Comparaison de 2 moyennes)**

## **V- Test de Comparaison de 2 moyennes : cas de 2 échantillons appariés**

- **L'hypothèse testée est comme suit** : est ce que les deux échantillons dépendants proviennent de deux populations de même moyenne ?

- On teste deux produits auprès d'un même échantillon de 5 consommateurs. Chacun des consommateurs donne 2 notes, la première pour le produit A, l'autre pour le produits B.

On obtient le tableau ci-contre :

Produit	A	B
	13,3	14,15
	10,1	11,05
	8,5	9,5
	6,9	7,95
	3,7	4,85
Total	42,5	47,5

- Le problème posé est de savoir si les 2 séries de notes viennent de la même population de moyenne

$$\mu = \mu_A = \mu_B \quad ?$$

Remarque : Obligatoirement les 2 échantillons ont des tailles égales !

- Le test posé est formulé comme suit :

$$\left\{ \begin{array}{l} H_0 : \mu_A = \mu_B \\ \# \\ H_1 : \mu_A \neq \mu_B \end{array} \right. \iff \left\{ \begin{array}{l} H_0 : \mu_A - \mu_B = 0 \\ \# \\ H_1 : \mu_A - \mu_B \neq 0 \end{array} \right.$$

- On pose  $\bar{D} = \bar{X}_A - \bar{X}_B$  la statistique du test afin de tester la différence  $\mu_A - \mu_B$
- D'où  $T = \frac{\bar{D}}{\hat{\sigma}_{\bar{D}}} = \frac{\bar{D}}{S_{\bar{D}}} = \frac{\bar{D}}{S_D / \sqrt{n}} \rightsquigarrow t(n-1)$
- Un problème se pose c'est que les 2 échantillons (5 notes pour A et 5 pour B) n'étant plus indépendant (les notes sont probablement corrélées), il n'est plus possible de calculer la variance de  $D$  en faisant la somme des deux variances.

- R.D.

$$\left\{ \begin{array}{l} \text{Si } |t| > t_{\alpha/2;n-1} \\ \text{Si } |t| \leq t_{\alpha/2;n-1} \end{array} \right. \quad \begin{array}{l} \text{on rejette } H_0 \\ \text{on ne rejette pas } H_0 \end{array}$$

- A.N. : **Produit**

	$x_A$	$x_B$	$d=x_A - x_B$	$d^2$
	13,3	14,15	-0,85	0,72
	10,1	11,05	-0,95	0,90
	8,5	9,5	-1	1
	6,9	7,95	-1,05	1,10
	3,7	4,85	-1,15	1,32
<b>Total</b>	<b>42,5</b>	<b>47,5</b>	<b>-5</b>	<b>5,04</b>

- A.N. :

$$\bar{d} = \frac{-5}{5} = -1 \quad \overline{d^2} = \frac{5,04}{5} = 1,01$$

$$S_d^2 = 5 * (1,01 - 1) / 4 = 0,0125$$

$$D'ou\ t = \sqrt{5} * \frac{-1}{\sqrt{0,0125}} = -20$$

$$\Rightarrow |t| > t_{\alpha/2; 4} = 2,78$$

$\Rightarrow$  on rejette  $H_0$

- Voilà ce que donne Xlstat
- sous Excel

<b>t (valeur observée)</b>	<b>-20,000</b>
<b>t (valeur critique)</b>	<b>2,776</b>
<b>ddl</b>	<b>4</b>
<b>p-value bilatérale</b>	<b>&lt; 0,0001</b>
<b>Alpha</b>	<b>0,05</b>

**Conclusion :** Au seuil de signification  $\alpha=0,05$  on peut rejeter l'hypothèse nulle d'égalité des moyennes. Autrement dit, la différence entre les moyennes est significative.

# **ANALYSE BIVARIEE**

**Cas de deux Variables**

I

Test

sur le coefficient  
de corrélation  
de pearson

# **Test paramétrique sur le coefficient de Corrélacion de pearson : $\rho$**

- Dans ce paragraphe, nous allons aborder les questions relatives aux relations entre deux variables quantitatives X et Y en souhaitant montrer que la variable dépendante Y est fonction de la variable indépendante X.

- Pour ce on cherche à calculer le coefficient de corrélation théorique  $\rho$  sur la population :

$$\rho = \frac{\text{cov}(X, Y)}{\sigma_X \sigma_Y}$$

- Un estimateur de  $\rho$  sur un E.A. est le coefficient  $r$  (vu en S2) :

$$r = \hat{\rho} = \frac{\hat{\text{cov}}(X, Y)}{\hat{\sigma}_X \hat{\sigma}_Y} = \frac{\hat{\text{cov}}(X, Y)}{S_X S_Y} ; \text{ où } \hat{\text{cov}}(x, y) = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{n-1}$$

$$\text{et } S_X^2 = \frac{\sum (x_i - \bar{x})^2}{n-1}$$

$$d'où \quad r = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2 \sum (y_i - \bar{y})^2}} = \frac{\sum x_i y_i - \frac{1}{n} (\sum x_i)(\sum y_i)}{\sqrt{\left[ \sum x_i^2 - \frac{1}{n} (\sum x_i)^2 \right] \left[ \sum y_i^2 - \frac{1}{n} (\sum y_i)^2 \right]}}$$

## 1- Formulation des Hypothèses :

$$\begin{cases} H_0 : \rho = 0 \\ \# \\ H_1 : \rho \neq 0 \end{cases}$$

## 2- On propose la statistique du test, sous

$$H_0 : T = \frac{r}{S_r} = r \sqrt{\frac{(n-2)}{1-r^2}} \rightsquigarrow t (n-2)$$

## 3- R.D.

$$\begin{cases} \text{Si } |t| > t_{\alpha/2}(n-2) \text{ on rejette } H_0 \\ \text{Si } |t| \leq t_{\alpha/2}(n-2) \text{ on ne rejette pas } H_0 \end{cases}$$

- Condition d'application :
  - La liaison entre  $X$  et  $Y$  est supposée linéaire.
  - Les lois de  $X$  et  $Y$  sont supposées Normales.
  - La loi conditionnelle de  $Y/X$  (recip  $X/Y$ ) est normale.

## •Exemple

•Le service des études économiques de la société  $\alpha$  veut mesurer l'incidence de la modulation de la pression marketing (variable  $X$ : explicative) sur la vente de flacons de parfums (variable  $Y$ : expliquée). Il enregistre, alors, les ventes  $y_i$  (en milliers de flacons) ainsi que les dépenses publicitaires  $x_i$  (en milliers de DH) dans 5 zones qui forment un échantillon aléatoire

$x_i$	5	6	9	12	18
$y_i$	25	30	35	45	65

- On cherche à étudier la liaison pouvant exister entre les variables aléatoires  $X$  et  $Y$ . Pour ce, on représente dans un repère orthogonal les points  $(x_i, y_i)$ . La forme de ce nuage nous renseigne sur la nature de la liaison entre  $X$  et  $Y$  et le type de courbe qui ajustera le mieux, c'est est une droite (*ajustement linéaire ou droite de régression*).

$i$	$x_i$	$y_i$	$x_i y_i$	$x_i^2$	$y_i^2$
1	5	25	125	25	625
2	6	30	180	36	900
3	9	35	315	81	1225
4	12	45	540	144	2025
5	18	65	1170	324	4225
<b>TOTAL</b>	<b>50</b>	<b>200</b>	<b>2330</b>	<b>610</b>	<b>9000</b>

$$r = \frac{330}{\sqrt{110 \times 1000}} = 0,99$$

$$\Rightarrow t = .99 \sqrt{\frac{3}{1 - .99^2}} = 12.16$$

Or  $t_{,025}(3) = 3,18$  d'où  $|t| > t_{,025}(3)$

$$\Rightarrow RH_0$$


Or  $P(|T| > 12,16) = 0,0012 = 0,12\%$

## Conclusion:


- Le coefficient de corrélation entre les ventes et les dépenses publicitaires est très significativement différent de 0.

**Table A2 Table of Student's *t* Distribution**

Two-tailed	.80	.50	.20	.10	.05	.02	.01	.001
One-tailed	.40	.25	.10	.05	.025	.01	.005	.0005
<i>p</i>	.60	.75	.90	.95	.975	.99	.995	.9995
<i>df</i>								
1	.325	1.000	3.078	6.314	12.706	31.821	63.657	636.619
2	.289	.816	1.886	2.920	4.303	6.965	9.925	31.598
3	.277	.765	1.638	2.353	3.182	4.541	5.841	12.924
4	.271	.741	1.533	2.132	2.776	3.747	4.604	8.610
5	.267	.727	1.476	2.015	2.571	3.365	4.032	6.869
$\infty$	.253	.674	1.282	1.645	1.960	2.326	2.576	3.291



Test unilatéral



Test bilatéral

# **Tests non paramétriques**

## **Chapitre 2**

# Introduction

- Les tests statistiques qui imposent des conditions d'application relatives aux paramètres de la population sont appelés des **tests paramétriques**.
- Un **test non paramétrique** est donc un test d'hypothèse pour lequel il n'est pas nécessaire de spécifier la forme de la distribution de la population étudiée.
- Les méthodes non paramétriques requièrent peu d'hypothèses concernant la population étudiée. Elles ignorent notamment l'hypothèse classique de la normalité de la population.
- Ces tests peuvent être appliqués à de petits échantillons. Ils peuvent s'appliquer à des caractères qualitatifs, à des grandeurs de mesure. On peut les utiliser dans le cas des données incomplètes ou imprécises.

- **En résumé :**

- **- Quelles sont les conditions d'application des tests non paramétriques ?**

Lorsque:

- - pour la variable quantitative, il n'est pas possible d'émettre certaines hypothèses :
  - normalité de la distribution ;
  - égalité des variances, ...
- - L'inférence ne concerne pas un paramètre dans la distribution de population
- - la taille de l'échantillon devient trop faible (hypothèses précédentes invérifiables )

- Le problème qui se pose alors est de savoir quand la distribution d'une population est normale.
- Il existe plusieurs tests statistiques qui permettent de vérifier si des données proviennent d'une population normalement distribuée. Citons par exemple le test de  $\chi^2$  et celui de Kolmogorov-Smirnov et son extension test de Lilliefort...
- On peut parfois, se faire une idée quant à la normalité des données en examinant la distribution de ces derniers dans l'échantillon:
  - Les données sont-elles relativement groupées autour d'une tendance centrale ? N'y a-t-il pas une distribution clairement bimodale incompatible avec la propriété de normalité ? N'y a-t-il pas des données aberrantes...?

# **ANALYSE UNIVARIE**

**A- Cas d'un seul  
échantillon**

I- Tests  
d'ajustements  
de  
**Khi-deux**

# INTRODUCTION

► Le but de ce test est de vérifier, en se basant sur les données d'un E.A., la concordance entre une distribution observée (empirique) et une distribution théorique. Soit  $X$  la V.A. parente relative à un E.A. de taille  $n$ . Cet échantillon fournit  $n$  observations qu'on répartit en  $K$  modalités (dans le cas discret) ou  $K$  classes (dans le cas continu), notées  $C_1, C_2, \dots, C_K$  auxquelles on associe les effectifs aléatoires  $N_1, N_2, \dots, N_K$  de

Réalisations  $n_{o1}, n_{o2}, \dots, n_{ok}$  ; on a alors les contraintes suivantes :

$$\sum_{i=1}^k N_i = n \quad \text{et} \quad \sum_{i=1}^k n_{oi} = n$$

On pense que ces observations proviennent d'une loi théorique  $L$ . A fin de tester cette hypothèse, on pose :

$$\left\{ \begin{array}{l} H_0 : X \rightsquigarrow L \\ \# \\ H_1 : X \not\rightsquigarrow L \end{array} \right.$$

▶ Sous  $H_0$ , la loi  $L$  fait correspondre à  $C_1, C_2, \dots, C_K$  les probabilités  $p_1, p_2, \dots, p_K$  et par suite les effectifs théorique  $n_{t1} = np_1, n_{t2} = np_2, \dots, n_{tk} = np_k$ , avec :  $\sum_{i=1}^k n_{ti} = n$

**▶ I) Cas où la loi ne dépend pas de paramètres**

▶ Soit la statistique :

$$D^2 = \sum_{i=1}^k \frac{(N_i - n_{ti})^2}{n_{ti}}$$

•Théorème :

–Si  $n \rightarrow \infty$   $D^2 \rightsquigarrow \chi^2_{k-1}$

–D'où la règle de décision du test :

$$\begin{cases} \text{Si } d^2 > \chi^2_{k-1;\alpha} & \text{on rejette } H_0 \\ \text{Si } d^2 \leq \chi^2_{k-1;\alpha} & \text{on ne rejette pas } H_0 \end{cases}$$

► OÙ :

$$d^2 = \sum_{i=1}^k \frac{(n_{oi} - n_{ti})^2}{n_{ti}}$$
$$= \sum_{i=1}^k \frac{(n_{oi})^2}{n_{ti}} - n$$

► Remarque : 1) le ddl (k-1) vient du fait que les  $N_i$  sont liés par la relation

$$\sum_{i=1}^k N_i = n$$

Remarque : 2) le théorème s'applique si  $np_i \geq 5 \quad \forall i$ , quitte à regrouper les classes qui ne vérifient pas la condition.

## 1) Ajustement à 1 loi Uniforme discrète

Exemple : considérons l'expérience suivante effectuée avec un dé. On désire vérifier si ce dé est réellement bien balancé. Après 96 essais, on obtient les résultats suivants:

Résultats	1	2	3	4	5	6
Fréquences observées	12	18	20	13	10	23

- Quelle conclusion peut-on tirer de cette expérience ? ( $\alpha = 5\%$ ).

<b>Modalité <math>x_i</math></b>	<b><math>n_{oi}</math></b>	<b><math>p_i</math></b>	<b><math>n_{ti} = np_i</math></b>
<b>1</b>	<b>12</b>	<b>1/6</b>	<b>16</b>
<b>2</b>	<b>18</b>	<b>1/6</b>	<b>16</b>
<b>3</b>	<b>20</b>	<b>1/6</b>	<b>16</b>
<b>4</b>	<b>13</b>	<b>1/6</b>	<b>16</b>
<b>5</b>	<b>10</b>	<b>1/6</b>	<b>16</b>
<b>6</b>	<b>23</b>	<b>1/6</b>	<b>16</b>
<b>TOTAL</b>	<b>96</b>	<b>1</b>	<b>96</b>

- On émet deux hypothèses :

$$\left\{ \begin{array}{l} H_0 : X \rightsquigarrow \bigcup_{\{1,2,\dots,6\}} \\ \# \\ H_1 : X \not\rightsquigarrow \bigcup_{\{1,2,\dots,6\}} \end{array} \right.$$

- Peut-on rejeter  $H_0$  au risque de 5% ?

$$\left\{ \begin{array}{l} Si \ d^2 > \chi_{5;0,05}^2 \quad \text{on rejette } H_0 \\ Si \ d^2 \leq \chi_{5;\alpha}^2 \quad \text{on ne rejette pas } H_0 \end{array} \right.$$

•Le calcul de la réalisation  $d^2$  :

$x_i$	$n_{oi}$	$n_{ti}$	$(n_{ti} - n_{oi})^2$	$[(n_{ti} - n_{oi})^2] / n_{ti}$
<b>1</b>	<b>12</b>	<b>16</b>	<b>16</b>	<b>1</b>
<b>2</b>	<b>18</b>	<b>16</b>	<b>4</b>	<b>0,25</b>
<b>3</b>	<b>20</b>	<b>16</b>	<b>16</b>	<b>1</b>
<b>4</b>	<b>13</b>	<b>16</b>	<b>9</b>	<b>0,56</b>
<b>5</b>	<b>10</b>	<b>16</b>	<b>36</b>	<b>2,25</b>
<b>6</b>	<b>23</b>	<b>16</b>	<b>49</b>	<b>3,06</b>
<b>TOTAL</b>	<b>96</b>	<b>96</b>		$d^2=8,12$

- Or  $d^2 = 8,12$  et  $\chi^2_{5; 0,05} = 11,07$
- D'où on ne peut rejeter  $H_0$  au niveau 5%.

## ▶ II) Cas d'une loi discrète dépendant de paramètres

▶ Soit la statistique :

$$D^2 = \sum_{i=1}^k \frac{(N_i - n_{ti})^2}{n_{ti}}$$

• **Théorème :**

-Si  $n \rightarrow \infty$   $D^2 \rightsquigarrow \chi^2_{k-m-1}$

où  $m$  est le nombre de paramètres à estimer.

# 1) Ajustement à 1 loi de poisson

**Exemple :** Le nombre d'accidents de travail en une journée pour une période de 100 jours est réparti comme suit :

<b>Modalité <math>x_i</math></b>	<b>0</b>	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>	<b>6</b>	<b>TOTAL</b>
<b>Effectif <math>n_i</math></b>	13	27	27	19	9	4	1	<b>100</b>

Tester au risque de 5% si les données proviennent d'1 loi de poisson.

- On émet deux hypothèses :

$$\left\{ \begin{array}{l} H_0 : X \rightsquigarrow \mathcal{P}(\lambda) \\ \# \\ H_1 : X \not\rightsquigarrow \mathcal{P}(\lambda) \end{array} \right.$$

- R.D (puisque  $\lambda$  est le seul à estimer) :

$$\left\{ \begin{array}{l} Si \ d^2 > \chi_{k-2;\alpha}^2 \quad \text{on rejette } H_0 \\ Si \ d^2 \leq \chi_{k-2;\alpha}^2 \quad \text{on ne rejette pas } H_0 \end{array} \right.$$

- Estimation de  $\lambda$  :

$$\hat{\lambda} = \frac{\sum_{i=1}^k n_{oi} x_i}{n} = \frac{200}{100} = 2$$

<i>Modalité <math>x_i</math></i>	<i><math>n_{oi}</math></i>	<i><math>n_{oi}x_i</math></i>
<b>0</b>	<b>13</b>	<b>0</b>
<b>1</b>	<b>27</b>	<b>27</b>
<b>2</b>	<b>27</b>	<b>54</b>
<b>3</b>	<b>19</b>	<b>57</b>
<b>4</b>	<b>9</b>	<b>36</b>
<b>5</b>	<b>4</b>	<b>20</b>
<b>6</b>	<b>1</b>	<b>6</b>
<b>TOTAL</b>	<b>100</b>	<b>200</b>

• Le Tableau théorique pour  $\lambda=2$  :

$x_i$	$p_i$	$n_{ti} = n p_i$
<b>0</b>	<b>0,1353</b>	<b>13,53</b>
<b>1</b>	<b>0,2707</b>	<b>27,07</b>
<b>2</b>	<b>0,2707</b>	<b>27,07</b>
<b>3</b>	<b>0,1804</b>	<b>18,04</b>
<b>4</b>	<b>0,0902</b>	<b>9,02</b>
<b>5</b>	<b>0,0361</b>	<b>3,61</b>
<b>6</b>	<b>0,0120</b>	<b>1,20</b>
<b>7</b>	<b>0,0034</b>	<b>0,34</b>
<b>8</b>	<b>0,0009</b>	<b>0,09</b>
<b>9</b>	<b>0,0002</b>	<b>0,02</b>
TOTAL	1	

5,26

**K=6**

•Le calcul de la réalisation  $d^2$  :

$x_i$	$n_{oi}$	$n_{ti}$	$(n_{ti} - n_{oi})^2$	$[(n_{ti} - n_{oi})^2] / n_{ti}$
<b>0</b>	13	13,53	0,2809	0,0208
<b>1</b>	27	27,07	0,0049	0,0002
<b>2</b>	27	27,07	0,0049	0,0002
<b>3</b>	19	18,04	0,9216	0,0511
<b>4</b>	9	9,02	0,0004	0
<b>5 et +</b>	5	5,26	0,0676	0,0129
<b>TOTAL</b>	100	100		$d^2=0,0852$

- $d^2 = 0,0852$  et  $\chi^2_{4; 0,05} = 9,49$

$$d^2 \ll \chi^2_{4; 5\%}$$

- D'où on ne peut rejeter l'idée que les données proviennent d'une loi de poisson

## ▶ **III) Cas d'une loi continue dépendant de paramètres**

### 1) Ajustement à 1 loi Normale

- ▶ **Exemple** : Est ce que les données ci-dessous –représentant la distribution de 685 ménages selon le revenu en centaines de DH- proviennent d'une population normalement distribuée ?
- ▶ ( $\alpha = 5\%$ ).

•Le Tableau observable :

<i>Classes</i>	$n_i$	$x_i$
<b>[5 , 15[</b>	<b>41</b>	<b>10</b>
<b>[15 , 25[</b>	<b>75</b>	<b>20</b>
<b>[25 , 35[</b>	<b>62</b>	<b>30</b>
<b>[35 , 45[</b>	<b>226</b>	<b>40</b>
<b>[45 , 55[</b>	<b>89</b>	<b>50</b>
<b>[55 , 65[</b>	<b>109</b>	<b>60</b>
<b>[65 , 75[</b>	<b>83</b>	<b>70</b>
<b>TOTAL</b>	<b>685</b>	<b>-----</b>

$n_i x_i$	$n_i x_i^2$
<b>410</b>	<b>4100</b>
<b>1500</b>	<b>3000</b>
<b>1860</b>	<b>55800</b>
<b>9040</b>	<b>361600</b>
<b>4450</b>	<b>222500</b>
<b>6540</b>	<b>392400</b>
<b>5810</b>	<b>406700</b>
<b>29610</b>	<b>1473100</b>

• On émet deux hypothèses :

•  $\left\{ \begin{array}{l} H_0 \\ H_1 \end{array} \right. \quad X \rightsquigarrow \mathcal{N}(\mu, \sigma^2)$

•  $\left\{ \begin{array}{l} H_0 \\ H_1 \end{array} \right. \quad X \not\rightsquigarrow \mathcal{N}(\mu, \sigma^2)$

• Estimation de  $\mu$  et de  $\sigma^2$  :

$$\hat{\mu} = \bar{x} = \frac{\sum_{i=1}^7 n_{oi} x_i}{n} = \frac{29610}{685} = 43,2263 \text{ cdh}$$

$$s_e^2 = \frac{\sum_{i=1}^7 n_{oi} x_i^2}{685} - \hat{\mu}^2 = \frac{1473100}{685} - 1868,5111$$

$$\cong 282 \Rightarrow \hat{\sigma}^2 = s^2 = \frac{n}{n-1} s_e^2 = 282,4123$$

**R.D.**

$$\left\{ \begin{array}{l} \text{Si } d^2 > \chi_{k-3;\alpha}^2 \quad \text{on rejette } H_0 \\ \text{Si } d^2 \leq \chi_{k-3;\alpha}^2 \quad \text{on ne rejette pas } H_0 \end{array} \right.$$

- Posons :

- $Z = \frac{X - \hat{\mu}}{\hat{\sigma}} \rightsquigarrow \mathcal{N}(0, 1)$  sous  $H_0$

- **Le Tableau théorique :**

$[z_{i-1} ; z_i[$	$p_i$	$n_{ti}$	$(n_{ti}-n_{oi})^2/n_{ti}$
$] -\infty ; -1,68[$	<b>0,0465</b>	<b>31,8525</b>	<b>2,6270</b>
$[-1,68 ; -1,08[$	<b>0,0936</b>	<b>64,1160</b>	<b>1,8476</b>
$[-1,08 ; -0,49[$	<b>0,1720</b>	<b>117,8200</b>	<b>26,4460</b>
$[-0,49 ; 0,11[$	<b>0,2317</b>	<b>158,7145</b>	<b>28,5250</b>
$[0,11 ; 0,70[$	<b>0,2142</b>	<b>146,7270</b>	<b>22,7116</b>
$[0,70 ; 1,30[$	<b>0,1452</b>	<b>99,4620</b>	<b>0,9147</b>
$[1,30 ; +\infty[$	<b>0,0968</b>	<b>66,3080</b>	<b>4,2020</b>
<b>TOTAL</b>	<b>1,0000</b>	<b>685</b>	<b>87,2739</b>

- $d^2 = 87,2739$  et  $\chi^2_{4; 0,05} = 9,49$

$$d^2 \gg \chi^2_{4; 5\%}$$

- D'où on peut rejeter l'idée que les données proviennent d'une loi NORMALE.

II

1-Test de Kolmogorov

-

Smirnov

Le test de *Kolmogorov-Smirnov* est un test d'ajustement à une loi «continue». On extrait un échantillon aléatoire  $(X_1, X_2, \dots, X_n)$  de fonction de répartition observée  $\hat{F}$ . On pense que cet échantillon provient d'une population distribuée selon une loi  $\mathcal{L}$  inconnue de fonction de répartition théorique  $F_0$ . Le test se formule comme suit :

$$\left\{ \begin{array}{l} H_0 : \hat{F} = F_0 \\ \# \\ H_1 : \hat{F} \neq F_0 \end{array} \right. \quad \text{ou} \quad \left\{ \begin{array}{l} H_0 : X \rightsquigarrow \mathcal{L} \\ \# \\ H_1 : X \not\rightsquigarrow \mathcal{L} \end{array} \right.$$

Où :

$\hat{F}(x)$  est la fonction de répartition empirique

La règle de décision se base sur l'écart maximal entre les deux fonctions de répartition; plus cet écart est grand plus on a tendance à rejeter l'hypothèse nulle:

$$D = \max_{i=1, \dots, n} \left\{ \left| \hat{F}(x_{(i)}) - F_0(x_{(i)}) \right|, \left| \hat{F}(x_{(i-1)}) - F_0(x_{(i)}) \right| \right\}$$

où  $x_{(i)}$  est la  $i^{\text{ème}}$  réalisation par ordre ↗

**Exemple :** *Un chercheur entreprend une étude pour évaluer si la distribution de la durée que prend la migraine chez des patients pour répondre à une dose d'un médicament administrée est normale, avec un temps moyen de réponse de 90 secondes et un écart type de 35 secondes (c.-à-d.,  $\mathcal{N}(90, 35^2)$ ). On relève chez 7 patients le temps (en secondes) que met la migraine pour disparaître après l'administration du médicament. Après classement par ordre croissant, on obtient : 21, 32, 38, 90, 90, 145, 155.*

*Les données proviennent-elles d'une loi normale*

*$\mathcal{N}(90, 35^2)$  ?*

F.H.

$$\left\{ \begin{array}{l} H_0 : \hat{F} = F_0 \\ \# \\ H_1 : \hat{F} \neq F_0 \end{array} \right. \quad \text{ou} \quad \left\{ \begin{array}{l} H_0 : X \rightsquigarrow \mathcal{N}(90, 35^2) \\ \# \\ H_1 : X \not\rightsquigarrow \mathcal{N}(90, 35^2) \end{array} \right.$$

Stat. Utilisée :  $D = \max_{i=1, \dots, n} \left\{ \left| \hat{F}(x_{(i)}) - F_0(x_{(i)}) \right|, \left| \hat{F}(x_{(i-1)}) - F_0(x_{(i)}) \right| \right\}$

Loi de D : à lire dans la table de K-S

RD.

$$\left\{ \begin{array}{l} \text{Si } d > d_{\alpha; n} \text{ on } RH_0 \\ \text{Si } d \leq d_{\alpha; n} \text{ on } NRH_0 \end{array} \right.$$

A.N. on range les  $x_j$  par ordre croissant puis on calcul

$$\hat{F}_i = \frac{N_i}{n} = \frac{\sum_{j=1}^i n_j}{n} \quad \text{avec } n_j \text{ l'effectif de la modalité } x_j$$

$x_i$	$z_i$	$F_0$	$\hat{F}$	$ \hat{F}(x_i) - F_0(x_i) $	$ \hat{F}(x_{i-1}) - F_0(x_i) $
21	-1,97	0,0244	1/7	0,1184	+0,0244
32	-1,66	0,0485	2/7	0,2373	0,0944
38	-1,49	0,0681	3/7	0,3605 <b>d'</b>	0,2176
90	0	0,5000	5/7	0,2143	+0,0714
145	1,57	0,9418	6/7	+0,0846	+0,2275 <b>d''</b>
155	1,86	0,9686	1	0,0314	+0,1114

$0,3605 = d = \sup(d', d'') < d_{0,05;7} = 0,483$  : on ne peut donc rejeter  $H_0$  (table de Kolmogorov-Smirnov)

## Remarques :

- Le test de l'Ajustement de  $\chi^2$  est utilisé pour X qualitative, discrète, ou éventuellement continue regroupée en classes
- Le test de Kolmogorov-Smirnov est utilisé pour des lois continues et parfois pour X qualitative ordinale
  
- Le test de Kolmogorov-Smirnov est meilleur que celui de l'Ajustement de  $\chi^2$  lorsque :
  - a)-la taille de l'E.A. est petite
  - b)- les effectifs théorique du  $\chi^2$  sont faibles.
  
- Si les paramètres de la loi théorique sont inconnus, on utilise une extension du test de Kolmogorov-Smirnov qui s'appelle le test de Lilliefors

II

2- Test de Lilliefors

## Exemple :

➤ On reprend l'exemple précédent mais en supposant que les paramètres ( $\mu$  et  $\sigma$ ) sont inconnus.

➤ D'abord on les estime, on trouve que 
$$\begin{cases} \hat{\mu} = 81,57 \\ \hat{\sigma} = 54,13 \end{cases}$$

$x_i$	$z_i$	$F_0$	$\hat{F}$	$ \hat{F}(x_i) - F_0(x_i) $	$ \hat{F}(x_{i-1}) - F_0(x_i) $
21	-1,12	0,1314	1/7	0,0115	+0,1314
32	-0,92	0,1788	2/7	0,1069	+0,0359
38	-0,8	0,2119	3/7	0,2167 <b>d'</b>	0,0739
90	0,16	0,5636	5/7	0,1507	+0,1350
145	1,17	0,8790	6/7	+0,0219	+0,1647 <b>d''</b>
155	1,36	0,9131	1	0,0869	+0,0559

$$RD \begin{cases} \text{Si } d > d_{\alpha;n} & \text{on } RH_0 \\ \text{Si } d \leq d_{\alpha;n} & \text{on } NRH_0 \end{cases}$$

$0,2167 = d = \sup(d', d'') < d_{0,02;7} = 0,348$  : on ne peut donc rejeter  $H_0$

(Utilisez la table de Lilliefors)

# **ANALYSE UNIVARIE**

**A- Cas de deux  
échantillons  
indépendants**

I  
Test du Kolmogorov  
-  
smirnov

- Il permet de tester si deux échantillons indépendants sont extraits de la même population.  
Il compare deux distributions cumulatives et est concerné par la concordance entre deux séries de valeurs
- On émet deux hypothèses :
 
$$\left\{ \begin{array}{l} H_0 : F_1 = F_2 \\ \# \\ H_1 : F_1 \neq F_2 \end{array} \right.$$
- Le test est basé sur l'écart maximum entre les deux fonctions de répartition empiriques :

$$D = \max_{i=1, \dots, n} \left\{ |F_1(X) - F_2(X)| \right\}$$

- Exemple : *Un enseignant a noté deux groupes d'étudiants (aléatoirement choisis) :*
- *Groupe 1 : 11 - 1 - 0 - 4 - 0*
- *Groupe 2 : 11 - 11 - 5 - 8 - 3*

- *Est-ce que les deux populations sont Identiquement distribuées?*

$$d=0,6 \leq d_{0,05;5;5}=0,8$$

$$\Rightarrow NRH_0$$

$x_i$	$y_i$	$F_1$	$F_2$	$ F_1 - F_2 $
0-0	-	2/5	0/5	0,4
1	-	3/5	0/5	0,6
-	3	3/5	1/5	0,4
4	-	4/5	1/5	0,6
-	5	4/5	2/5	0,4
-	8	4/5	3/5	0,2
11	11-11	5/5	5/5	0

# II Test U de Mann-Whitney

*(Test Bilatéral seulement !)*

pour le test Unilatéral voir T.D.

- C'est l'équivalent du test t pour la comparaisons de 2 moyennes (**E.A. indépendants**)
- C'est donc un test de comparaison des moyennes lorsque l'hypothèse de normalité ou de l'égalité des variances (pour 2 échantillons de tailles faibles) sont violées.
- On émet deux hypothèses :
- $H_0$  : Les deux échantillons proviennent d'une population identique (*même moyenne*)
- $H_1$  : Les deux échantillons proviennent de populations différentes

- Décision : le test de Mann-Whitney est basé sur la statistique  $\min(U_1, U_2)$  où :

$$U_1 = n_1 * n_2 + \frac{n_1 * (n_1 + 1)}{2} - R_1$$

et

$$U_2 = n_1 * n_2 + \frac{n_2 * (n_2 + 1)}{2} - R_2$$

- où  $n_1$  et  $n_2$  sont les tailles respectives des deux échantillons et  $R_i$  est la somme des rangs du  $i^{ème}$  échantillon. Les 2 échantillons étant mélangée en un seul puis on range ce dernier par ordre croissant. *A chaque valeur on affecte un rang. Si deux valeurs sont égales, on leur assigne le rang médian.*

- Si  $n_1$  et  $n_2 \leq 20$  : On rejette  $H_0$  quand la valeur calculée est inférieure à celle lue dans la table de Mann-Withney.

- Remarque:

$$U_1 + U_2 = n_1 \times n_2 \quad \text{et} \quad R_1 + R_2 = \frac{(n_1 + n_2) \times (n_1 + n_2 + 1)}{2}$$

- Exemple : On veut tester l'aptitude de 12 femmes et de 12 hommes pour un certain travail administratif. Voici les points obtenus:

- Femmes: 82 87 89 91 91 76 74 70 88 99 61 94

- Hommes: 80 79 92 65 70 84 95 78 81 85 73 70

a) F.H.

$$\begin{cases} H_0: \mu_1 = \mu_2 \\ H_1: \mu_1 \neq \mu_2 \end{cases}$$

b) Statistique utilisée :  $U = \min(U_1, U_2)$

c) Loi de U: table de Mann-Whitney Car( $n_1; n_2$ )  $\leq 20$

d) R.D.  $\begin{cases} \text{Si } u < u_{0,05;n_1;n_2} & \text{on rejette } H_0 \\ \text{Si } u \geq u_{0,05;n_1;n_2} & \text{on ne rejette pas } H_0 \end{cases}$

e) A.N.

On range les 24 valeurs par ordre croissant. On obtient le classement suivant:

61	65	70	70	70	73	74	76	78	79	80	81	82	84	85	87
F	H	F	H	H	H	F	F	H	H	H	H	F	H	H	F
88	89	91	91	92	94	95	99								
F	F	F	F	H	F	H	F								

On a :

$$n_1 = n_2 = 12 \text{ et}$$

$$R_1 = 1 + 4 + 7 + 8 + 13 + 16 + 17 + 18 + 19,5 + 19,5 + 22 + 24 = 169$$

$$R_2 = 2 + 4 + 4 + 6 + 9 + 10 + 11 + 12 + 14 + 15 + 21 + 23 = 131$$

$$\Rightarrow U_1 = 53 \text{ et } U_2 = 91 \Rightarrow U = 53$$

Or d'après la table de Mann-Withney (bilatéral) :

$$U < U_{0,05;12;12} = 37$$

D'où on ne peut rejeter  $H_0$

Remarque :

- On peut montrer que

$$E(U) = \frac{n_1 \times n_2}{2} \quad \text{et} \quad V(U) = \frac{n_1 \times n_2 \times (n_1 + n_2 + 1)}{12}$$

- Si  $n_1 ; n_2 > 20$  :

$$\frac{U - E(U)}{\sqrt{V(U)}} = \frac{U - \frac{n_1 \times n_2}{2}}{\sqrt{\frac{n_1 \times n_2 \times (n_1 + n_2 + 1)}{12}}} \approx \mathcal{N}(0,1)$$

- Pour notre cas :

$$z = \frac{53-72}{\sqrt{300}} = -1,097$$

- $|z| \leq z_{0,025} = 1,96 \Rightarrow$  On ne peut rejeter  $H_0$

# **ANALYSE UNIVARIE**

**B- Cas de deux  
échantillons  
dépendants**

I  
Test T  
de  
Wilcoxon

On dispose de deux séries de mesures :  $x_1, x_2, \dots, x_n$  et  $y_1, y_2, \dots, y_n$ , de variables X et Y continues, sur les mêmes  $n$  individus.

- On classe les  $n$  différences  $x_i - y_i$  par ordre croissant de leurs valeurs absolues, puis on note les rangs des différences  $> 0$  (notées +) dans l'interclassement.

X	Y	$ D  =  X-Y $	Signe de la différence	Rang
$x_1$	$y_1$	$ d_1 $	-	$r_i$
.	.	.	-	.
.	.	.	-	.
.	.	.	+	.
.	.	.	+	.
.	.	.	-	.
.	.	.	+	.
.	.	.	-	.
.	.	.	-	.
.	.	.	+	.
$x_n$	$y_n$	$ d_n $	-	$r_n$

- **Si  $H_0$  est vraie**, X et Y sont de même loi, chaque différence peut être  $> 0$  ou  $< 0$  avec la probabilité  $1/2$ .
- s'il y a des différences nulles, on enlève les mesures correspondantes.
- On vérifie ensuite si la somme des rangs des différences positives diffère ou non de la somme des rangs des différences négatives. La somme de tous les rangs est égale à la somme des n premiers entiers :

avec n = nombre de paires non nulles

$$\sum R_+ + \sum R_- = \frac{n(n+1)}{2}$$

- L'hypothèse nulle, s'écrit alors :

$$H_0 : \sum R_+ = \sum R_- = \frac{\frac{n(n+1)}{2}}{2} = \frac{n(n+1)}{4}$$

- Si au contraire, les séries diffèrent, les sommes des rangs positifs et négatifs seront différentes.
- Le test en  $T$  consiste à comparer les rangs positifs ou négatifs à la valeur théorique sous  $H_0$ .

- Soit  $T_+ = \sum R_+$  la somme des rangs positifs et
- $T_- = \sum R_-$  la somme des rangs négatifs, on prend la plus petite des deux valeurs, donc  $T = \min(T_+ ; T_-)$ , et on lit la valeur théorique de T dans la table, en fonction du nombre "n" de paires non nulles. La différence n'est jamais significative, si "n" est inférieur à 5 (voir table).
- Si T observé  $\geq$  T théorique, on ne peut rejeter  $H_0$  d'où il n'existe pas de différence significative entre les deux séries.

- Exemple : soit un échantillon de 7 consommateurs qui notent 2 produits : Pour notre cas :

N° cons	Prod A	Prod B	d	Signe	rang
1	9	6	3	+	5
2	7	5	2	+	3
3	4	8	4	-	7
4	7,5	9	1,5	-	2
5	8,5	5	3,5	+	6
6	7,5	5	2,5	+	4
7	5	6	1	-	1

- $T_+ = 5 + 3 + 6 + 4 = 18$     $T_- = 7 + 2 + 1 = 10$     $\Rightarrow T = 10$
- Or  $T > T_{0,05;7} = 2 \Rightarrow$  on ne peut rejeter  $H_0$

- T tend vers une Loi normale si le nombre de paires est suffisamment grand, c'est à dire  $> 20$  Dans ce cas

- $$z = \frac{T - \frac{n(n+1)}{4}}{\sqrt{\frac{n(n+1)(2n+1)}{24}}} \approx \mathcal{N}(0,1)$$

# **ANALYSE BIVARIEE**

**Cas de deux Variables**

**I**

**Test  
sur le coefficient  
de corrélation  
des rangs  
de spearman**

- **Si l'une des conditions du test du coefficient de corrélation de Pearson n'est pas vérifiée, on utilise alors un test non paramétrique : le coefficient de corrélation des rangs de Spearman, qui utilise le rang des variables et non leurs valeurs.**
- **Il étudie l'existence d'une liaison entre 2 variables quantitatives.**

- On définit  $x'_i$  et  $y'_i$  les rangs des valeurs observées de X et de Y.
- On définit  $r_s$  le coefficient de corrélation des rangs de Spearman.

$$r_s = 1 - \frac{6 \sum (x'_i - y'_i)^2}{n(n^2 - 1)}$$

- Si  $|r_s|_{\text{observé}} \geq r_{s;\alpha}$  théorique (lu sur la table de Spearman), on peut rejeter  $H_0 : \rho_s = 0$
- d'où il existe une liaison significative entre les deux variables.

- Si  $n > 10$ ; on peut approximer la loi de la statistique .

$$t = \frac{r_S}{S_r} = r_S \sqrt{\frac{n-2}{1-r_S^2}} \rightsquigarrow t (n-2)$$

- Où  $S_r$  est l'écart type du coefficient de Spearman :

$$S_r = \sqrt{\frac{1-r_S^2}{n-2}}$$

- R.D.

$$\begin{cases} \text{Si } |t| > t_{\alpha/2}(n-2) & \text{on rejette } H_0 \\ \text{Si } |t| \leq t_{\alpha/2}(n-2) & \text{on ne rejette pas } H_0 \end{cases}$$

- **Exemple**

Une entreprise désire tester s'il y a un lien entre les statistiques des ventes de ses employés et les cours de perfectionnement offerts à tout son personnel. Un test passé par 9 vendeurs ayant suivi le cours donne un classement de leur aptitude à la vente. En utilisant les statistiques sur les ventes, on obtient alors les classements suivants:

• vendeur n° :	1	2	3	4	5	6	7	8	9
• rang du test	5	4	6	3	9	1	7	8	2
• rang des ventes	9	5	1	4	8	7	2	3	6
• $d_i = x'_i - y'_i$	-4	-1	5	-1	1	-6	5	5	-4

- On calcule  $r_s$  le coefficient de corrélation des rangs de Spearman.

$$r_s = 1 - \frac{6 \times 146}{9(81-1)} = 1 - \frac{876}{720} = -.22$$

**Table A18 Table of Critical Values for Spearman's Rho**

<i>n</i>	One-tailed level of significance			
	.05	.025	.01	.005
	Two-tailed level of significance			
	.10	.05	.02	.01
4	1.000	—	—	—
5	.900	1.000	1.000	—
6	.829	.886	.943	1.000
7	.714	.786	.893	.929
8	.643	.738	.833	.881
9	.600	.700	.783	.833
10	.564	.648	.745	.794

- Donc le  $r_{S;5\%}$  théorique vaut 0,7
- $|r_S| = 0,22 < 0,7$  (lu sur la table de Spearman), on ne peut rejeter  $H_0$ , d'où la liaison entre les cours de perfectionnement et les ventes n'est pas significative à 5%

II

Test du Khi-deux

## B- Test d'indépendance de $\chi^2$

▶ Soient  $X$  et  $Y$  deux V.A. qualitatives, sur une même population, de modalités resp<sup>es</sup>

▶  $X$  :  $x_1; x_2; \dots; x_i; \dots; x_m$

▶  $Y$  :  $y_1; y_2; \dots; y_j; \dots; y_k$

▶ Le tableau suivant résume la situation

# 1-TABLEAU DE CONTINGENCE

X \ Y	$y_1$	$y_2$	$\dots$	$y_j$	$\dots$	$y_k$	TOTAL
$x_1$	$n_{11}$	$n_{12}$				$n_{1k}$	$n_{1.}$
$x_2$	$n_{21}$	$n_{22}$				$n_{2k}$	$n_{2.}$
$\vdots$							$\vdots$
$x_i$				$n_{ij}$			$n_{i.}$
$\vdots$							$\vdots$
$x_m$	$n_{m1}$	$n_{m2}$				$n_{mk}$	$n_{m.}$
TOTAL	$n_{.1}$	$n_{.2}$	$\dots$	$n_{.j}$	$\dots$	$n_{.k}$	$n_{..}$

► On a les relations suivantes :

$$n_{i\bullet} = \sum_{j=1}^k n_{ij} \quad n_{\bullet j} = \sum_{i=1}^m n_{ij}$$

$$n_{\bullet\bullet} = n = \sum_{i=1}^m \sum_{j=1}^k n_{ij} = \sum_{j=1}^k \sum_{i=1}^m n_{ij}$$

---

$$p_{ij} = P(X = x_i; Y = y_j);$$

probabilité conjointe de  $(X, Y)$

$$p_{i\bullet} = P(X = x_i);$$

probabilité marginale de  $X$

---

$$p_{\bullet j} = P(Y = y_j);$$

probabilité marginale de  $Y$

---

$$\text{Si } X \perp\!\!\!\perp Y \Rightarrow p_{ij} = p_{i\bullet} \times p_{\bullet j}$$

---

► On désire savoir si  $X$  est indépendante de  $Y$ ; pour ce faire, on confronte les deux hypothèses suivantes :

- On émet deux hypothèses :

$$\left\{ \begin{array}{l} H_0 : X \text{ et } Y \text{ indépendantes} \\ \# \\ H_1 : X \text{ et } Y \text{ sont liées} \end{array} \right.$$

- On remarque : sous  $H_0$

$$p_{ij} = p_{i\bullet} \times p_{\bullet j}$$

Estimons :

$$\left\{ \begin{array}{l} p_{i\bullet} \quad \text{par} \quad \hat{p}_{i\bullet} = \frac{n_{i\bullet}}{n} \\ p_{\bullet j} \quad \text{par} \quad \hat{p}_{\bullet j} = \frac{n_{\bullet j}}{n} \\ p_{ij} \quad \text{par} \quad \hat{p}_{ij} = \frac{n_{ij}}{n} \end{array} \right.$$

Sous  $H_0$

$$n_{ij} = n\hat{p}_{ij} \approx n\hat{p}_{i\bullet} \times \hat{p}_{\bullet j} = \frac{n_{i\bullet} \times n_{\bullet j}}{n} = n_{tij}$$

► Posons

$$D^2 = \sum_{i=1}^m \sum_{j=1}^k \frac{(N_{ij} - n_{t ij})^2}{n_{t ij}}$$

► **Théorème :**

• Si  $n \rightarrow \infty$   $D^2 \rightsquigarrow \chi^2_{(k-1)(m-1)}$

• R.D

$\left\{ \begin{array}{l} \text{Si } d^2 > \chi^2_{(k-1)(m-1); \alpha} \quad \text{on rejette } H_0 \\ \text{Si } d^2 \leq \chi^2_{(k-1)(m-1); \alpha} \quad \text{on ne rejette pas } H_0 \end{array} \right.$



- On émet deux hypothèses :

$$\left\{ \begin{array}{l} H_0 : X \text{ et } Y \text{ indépendantes} \\ \# \\ H_1 : X \text{ et } Y \text{ sont liées} \end{array} \right.$$

- R.D.

$$\left\{ \begin{array}{l} Si \ d^2 > \chi_{1; 0,05}^2 \quad \text{on rejette } H_0 \\ Si \ d^2 \leq \chi_{1; 0,05}^2 \quad \text{on ne rejette pas } H_0 \end{array} \right.$$

## Le calcul de la réalisation $d^2$ :

	$n_{ij}$	$n_{t ij} = (n_{i.} \cdot n_{.j} / n)$	$(n_{ij} - n_{t ij})^2 / n_{t ij}$
(1,1)	105	113,8889	0,6938
(1,2)	95	86,1111	0,9176
(2,1)	100	91,1111	0,8672
(2,2)	60	68,8889	1,1470
TOTAL	360	360	3,6256

- Or  $\chi^2_{1;0,05} = 3,8415$  d'où  $d^2 \leq \chi^2_{1;0,05}$
- On ne peut donc rejeter l'indépendance