

## Statistiques déductives :

### I Généralités sur les test d'hypothèse :

Dans les statistiques déductives, contrairement aux statistiques descriptives, on essaie, à partir des observations faites, de tirer des conclusions. Pour cela, les épidémiologistes utilisent des tests d'hypothèse.

#### A Les tests de comparaison :

Le plus souvent, les test utilisés en statistiques déductives sont des **tests de comparaison** soit :

- entre 2 populations : on constitue alors 2 échantillons représentatifs et on essaie de déterminer *s'il existe une différence significative entre ces 2 échantillons pour le caractère étudié*. Le but étant d'extrapoler le résultat aux 2 populations primitives.
- Entre une population donnée A et la population générale de référence : on constitue alors un échantillon représentatif de la population A et on essaie de déterminer *s'il existe une différence significative entre l'échantillon et la population générale* et donc, in fine, entre A et la population générale.

#### B La définition des hypothèses :

La première étape d'une étude statistique, ici d'un test de comparaison, est la **formulation d'hypothèses** que le test permettra ensuite de confirmer / infirmer. On définira, au début de chaque test, 2 hypothèses jouant un rôle symétrique :

1. **H<sub>0</sub> = hypothèse nulle** :
  - « Il n'y a pas de différence observée entre les deux groupes »
  - « Il n'existe pas de lien entre les 2 caractères étudiés, les fluctuations observées sont donc dues au hasard »
2. **H<sub>1</sub> = hypothèse alternative**.
  - « Il y a une différence significative entre les deux groupes »
  - « Il existe bien un lien entre les 2 caractères étudiés, les fluctuations observées ne sont donc pas dues au hasard. »

Les tests sont donc des techniques permettant de décider si on accepte ou si on rejette H<sub>0</sub>, en ayant fixé le risque d'erreur  $\alpha$  accompagnant cette décision.

**NB** : On choisit toujours pour **H<sub>0</sub>** l'hypothèse qu'il serait le plus grave de rejeter à tort.

#### C La notion de risque :

**Rappel de statistique descriptive** : Lors de l'estimation d'une valeur  $x$  par un IC,  $\alpha$  représente le **risque d'erreur** dans l'estimation de  $x$ , c'est à dire *le risque pour que l'IC ne contienne pas la vraie valeur de  $x$* . Il est généralement fixé à 5%

En statistique déductive, on a :

1.  $\alpha$  ou risque de première espèce représente : **le risque de rejeter H<sub>0</sub> si H<sub>0</sub> est vraie**. Ce risque d'erreur est maîtrisé, c'est à dire qu'il est fixé (le plus souvent à 5%) avant l'application du test statistique.
2.  $1 - \alpha$  représente la **probabilité d'accepter H<sub>0</sub> si H<sub>0</sub> est vrai**
3.  $\beta$  ou risque de seconde espèce représente le **risque d'accepter H<sub>0</sub> si H<sub>0</sub> est fausse**. Ce risque d'erreur est négligé et peut donc être assez important.
4.  $1 - \beta$  représente la **puissance du test**. Il s'agit de la **probabilité de rejeter H<sub>0</sub> si H<sub>0</sub> est fausse**.

On définit la **règle du rejet** uniquement à partir de **H0** et **d'α**. Le tableau suivant récapitule bien toutes ces notions :

		$\alpha$	$1-\alpha$	$\beta$	$1-\beta$
<b>H0</b>	<b>vraie/fausse ?</b>	vraie	vraie	fausse	fausse
	<b>Acceptation / rejet?</b>	rejet	acceptation	acceptation	rejet
<b>H1</b>	<b>Vraie / fausse ?</b>	fausse	fausse	vraie	vraie
	<b>Acceptation/rejet ?</b>	acceptation	rejet	rejet	acceptation

### D Les étapes d'un test d'hypothèse :

Pour mettre en oeuvre un test d'hypothèse, on suivra TOUJOURS les étapes suivantes :

1. définir H0 et H1. Les deux hypothèses jouent des rôles **symétriques**.
2. Déterminer le caractère des données à étudier/comparer :
  - qualitative/qualitative
  - qualitative/quantitative
  - quantitative/quantitative
3. Choisir le test en fonction du type de données On nomme **Z** le paramètre qui sera calculé.
4. Choisir le seuil d'erreur de 1<sup>ère</sup> espèce α généralement fixé à 5%.
5. Recueillir les données, calculer Z et utiliser la règle de rejet (définie à partir de H0 et de α) : Il s'agit de **comparer Z par rapport à une valeur théorique** de référence
6. Interpréter des résultats :
  - Au niveau de l'échantillon : Accepte-t-on H0 ?
  - Au niveau de la population : peut-on extrapoler les résultats à la population générale ?

**NB** : L'acceptation de H0 implique forcément le rejet de H1 et *vice versa*.

### II L'étude de la liaison entre deux caractères qualitatifs :

Dans la suite du cours, nous garderons, pour tous les types de test abordés, la méthode d'application d'un test d'hypothèse mise en place ci-dessus. Pour l'étude de la liaison entre 2 caractères qualitatifs, on peut choisir d'utiliser soit :

1. un test de comparaison des pourcentages
2. un test du  $X^2$

**Toutes les formules (sauf celles des ddl) fournies dans la suite de la fiche ne sont pas à connaître !**

## II L'étude de la liaison entre deux caractères qualitatifs :

### A Le test de comparaison des pourcentages :

Soient **2 groupes A et B** et une caractéristique **qualitative x** (couleur des yeux etc.) . On peut se demander si **la proportion d'individus du groupe A présentant x coïncide avec la proportion d'individus du groupe B présentant x.**

1) définir H0 et H1.

- **H0** : il n'y a **pas de différence observée entre les groupes A et B**, c'est à dire que la la proportion d'individus du groupe A présentant x coïncide avec la proportion d'individus du groupe B présentant x.
- **H1** : il existe une **différence significative entre les groupes A et B**, c'est à dire que la la proportion d'individus du groupe A présentant x est différente de celle du groupe B.

2) Déterminer le caractère des données à étudier/comparer : Les variables sont :

- des types d'individus → variable **qualitative**
- une caractéristique x **qualitative**

3) Choisir le test en fonction du type de données : En présence de données qualitatives, on peut choisir d'utiliser un **test de comparaison des pourcentages.**

4) Choisir le seuil d'erreur de 1<sup>ère</sup> espèce  $\alpha$  généralement fixé à 5%.

5) Recueillir les données, calculer Z et utiliser la règle de rejet

La variable Z est ici représentée par **l'écart réduit  $\epsilon$** . On comparera :

1.  $\epsilon_{\text{calculée}} > \epsilon_{\text{th}}$  donné par la table de l'écart réduit, en fonction de  $\alpha$

$$2. \epsilon_{\text{calculée}} = \epsilon_{\text{exp}} = \frac{p_A - p_B}{\sqrt{\frac{p_A q_A}{n_A} + \frac{p_B q_B}{n_B}}}$$

6) Interpréter les résultats : Au niveau de l'échantillon :

1. si  $\epsilon_{\text{calculée}} > \epsilon_{\text{th}}$  alors **on rejette H0** et on accepte H1.
2. si  $\epsilon_{\text{calculée}} < \epsilon_{\text{th}}$  alors **on accepte H0** et on rejette H1.

Si le / les échantillon(s) considérés sont **représentatifs** de la population, on pourra alors extrapoler le résultat obtenu à l'ensemble de la population.

7) Exemple :

Soient 2 populations : la population française et la population suédoise. On se demande si il y a la **même proportions d'individus ayant des yeux bleus en France et en Suède**. Pour cela, on constitue par TAS (tirage au sort) **2 échantillons A et B représentatifs** des populations françaises et suédoises. On obtient le tableau des données suivant :

Échantillon	A = français	B = Suédois	total
Yeux bleus	60	150	210
Yeux non bleus	140	50	190
total	200	200	400

1. définir H0 et H1 :
  - **H0** : il n'y a **pas de différence observée entre les populations françaises et suédoises**, c'est à dire qu'il y a la même proportions d'individus ayant des yeux bleux en France et en Suède.
  - **H1** : il existe une **différence significative entre les populations françaises et suédoises**, c'est à dire qu'il n'y a pas la même proportion de personnes ayant les yeux bleux en France et en Suède.
2. Déterminer le caractère des données à étudier/comparer :
  - nationalité française / suédoise → caractère **qualitatif**
  - couleur des yeux → caractère **qualitatif**
3. Choisir le test en fonction du type de données : Nous somme en présence de 2 caractères qualitatifs, on pourra donc choisir d'utiliser un **test de comparaison des pourcentages**.
4. Choisir le seuil d'erreur de 1<sup>ère</sup> espèce  $\alpha$  : Ici, le risque de première espèce est fixé à **5%**.
5. Recueillir les données, calculer Z et utiliser la règle de rejet :
  - $\epsilon_{th} = 1,96$  pour  $\alpha = 5\%$
  - L'énoncé vous donne  $\epsilon_{calculée} = 10,09$
6. Interpréter les résultats :
  - Au niveau des échantillons,  $\epsilon_{calculée} > \epsilon_{th}$ , alors **on rejette H0 et on accepte H1**. Ainsi, il n'y a pas la même proportion de personnes ayant les yeux bleux en France et en Suède. On constate que **les yeux bleus sont donc plus fréquents dans l'échantillon de Suédois**.
  - Les échantillons A et B étant **représentatifs**, on peut alors extrapoler à l'ensemble des deux populations et dire que **les yeux bleus sont plus fréquents dans la population Suédoise**.

## II L'étude de la liaison entre deux caractères qualitatifs :

### B Le test du $\chi^2$ :

Soient **2 groupes A et B** et une caractéristique **qualitative x** (couleur des yeux etc.) . On peut se demander si **la proportion d'individus du groupe A présentant x coïncide avec la proportion d'individus du groupe B présentant x.**

1) définir H0 et H1.

- **H0** : il n'y a **pas de différence observée entre les groupes A et B**, c'est à dire que la proportion d'individus du groupe A présentant x coïncide avec la proportion d'individus du groupe B présentant x.
- **H1** : il existe une **différence significative entre les groupes A et B**, c'est à dire que la proportion d'individus du groupe A présentant x est différente de celle du groupe B.

2) Déterminer le caractère des données à étudier/comparer : Les variables sont :

- des types d'individus → variable **qualitative**
- une caractéristique x **qualitative**

3) Choisir le test en fonction du type de données En présence de données qualitatives, on peut choisir d'utiliser un **test du  $\chi^2$ .**

4) Choisir le seuil d'erreur de 1<sup>ère</sup> espèce  $\alpha$  généralement fixé à 5%.

5) Recueillir les données, calculer Z et utiliser la règle de rejet

La variable Z est ici représentée par le  $\chi^2$ . On comparera :

1.  $\chi^2_{th}$  est donnée par la table du  $\chi^2$  en croisant :

- $\alpha$  le risque de première espèce
- **le nombre de degré de liberté.**

Pour le test du  $\chi^2$ , le nombre de ddl vaut :  **$(n_{lignes} - 1) \times (nb_{colonnes} - 1)$**

$$2. \chi^2_{calculée} = \chi^2_{exp} = \sum \frac{(O_i - C_i)^2}{C_i}$$

6) Interpréter les résultats : Au niveau de l'échantillon :

1. si  $\chi^2_{calculée} \geq \chi^2_{th}$  alors **on rejette H0** et on accepte H1.
2. si  $\chi^2_{calculée} < \chi^2_{th}$  alors **on accepte H0** et on rejette H1.

Si le / les échantillon(s) considérés sont **représentatifs** de la population, on pourra alors extrapoler le résultat obtenu à l'ensemble de la population.

7) Exemple :

Soient 2 populations : la population française et la population suédoise. On se demande si il y a la **même proportions d'individus ayant des yeux bleus en France et en Suède**. Pour cela, on constitue par TAS 2 échantillons A et B représentatifs des populations françaises et suédoises. On obtient le tableau des données suivant :

Échantillon	A = français	B = Suédois	total
Yeux bleus	60	150	210
Yeux non bleus	140	50	190
total	200	200	400

1. définir H0 et H1 :

- H0 : il n'y a pas de différence observée entre les populations françaises et suédoises, c'est à dire qu'il y a la même proportions d'individus ayant des yeux bleus en France et en Suède.
- H1 : il existe une **différence significative entre les populations françaises et suédoises**, c'est à dire qu'il n'y a pas la même proportion de personnes ayant les yeux bleus en France et en Suède.

2. Déterminer le caractère des données à étudier/comparer :

- nationalité française / suédoise → caractère **qualitatif**
- couleur des yeux → caractère **qualitatif**

3. Choisir le test en fonction du type de données : Nous somme en présence de 2 caractères qualitatifs, on pourra donc choisir d'utiliser un test du  $\chi^2$ .

4. Choisir le seuil d'erreur de 1<sup>ère</sup> espèce  $\alpha$  : Ici, le risque de première espèce est fixé à **5%**.

5. Recueillir les données, calculer de Z et utiliser la règle de rejet :

- il y a  $(n_{\text{lignes}} - 1) \times (nb_{\text{colonnes}} - 1) = 1 \times 1 = 1$ . Donc, pour  $\alpha = 5\%$ ,  $\chi^2_{\text{Tn}} = 3.841$
- L'énoncé vous donne  $\chi^2_{\text{calculé}} = 81.2$

6. Interpréter les résultats :

- Au niveau des échantillons,  $\chi^2_{\text{calculé}} \gg \chi^2_{\text{Tn}}$  alors **on rejette H0 et on accepte H1**. Ainsi, **il n'y a pas la même proportion de personnes ayant les yeux bleus en France et en Suède**. On constate que les yeux sont donc plus fréquents dans l'échantillon de Suédois.
- Les échantillons A et B étant **représentatifs**, on peut alors extrapoler à l'ensemble des deux populations et dire que **les yeux bleus sont plus fréquents dans la population Suédoise**.

**NB :** Attention à toujours bien distinguer :

1. l'aspect *statistique* et ses conclusions
2. l'aspect *médical* et ses conclusions qui peuvent être différentes.

### III L'étude de la liaison entre des caractères qualitatifs et quantitatifs :

Pour l'étude de la liaison entre un caractère qualitatif et un caractère quantitatif, on peut choisir d'utiliser soit :

3. un test de comparaison des moyennes
4. un test du T student

#### A Le test de comparaison des moyennes :

Soient **2 populations 1 et 2** et une caractéristique **quantitative** x (taille, poids etc.) de moyenne  $\mu$ . On se demande si, **en moyenne, la variable x des individus de la population 1 coïncide avec celle des individus de la population 2**. On met en place par TAS **2 groupes/échantillons représentatifs** des populations 1 et 2.

1) définir H0 et H1.

- **H0** : il n'y a **pas de différence observée entre les groupes A et B**, c'est à dire qu'en moyenne, la variable x des individus du groupe 1 coïncide avec celle des individus du groupe 2.
- **H1** : il existe **une différence significative entre les groupes A et B**, c'est à dire qu'en moyenne, la variable x des individus du groupe 1 ne coïncide pas avec celle des individus du groupe 2.

2) Déterminer le caractère des données à étudier/comparer : Les variables sont :

- des types d'individus → variable **qualitative**
- une caractéristique x **quantitative**

3) Choisir le test en fonction du type de données En présence de données qualitatives et quantitatives, pour  $n_1$  et  $n_2 > 30$ , on peut choisir d'utiliser un test de **comparaison des moyennes**.

4) Choisir le seuil d'erreur de 1<sup>ère</sup> espèce  $\alpha$  généralement fixé à 5%.

5) Recueillir les données, calculer Z et utiliser la règle de rejet

La variable Z est ici représentée par **l'écart réduit  $\epsilon$** . On comparera :

1.  $\epsilon_{th}$  donné par la table de l'écart réduit, en fonction de  $\alpha$

$$2. \epsilon_{calculée} = \epsilon_{exp} = \frac{m_1 - m_2}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}}$$

avec

$m_1$  = moyenne du paramètre x calculée sur l'échantillon n°1

$m_2$  = moyenne du paramètre x calculée sur l'échantillon n°2

$s_1$  = écart type calculé sur l'échantillon n°1

$s_2$  = écart type calculé sur l'échantillon n°2

6) Interpréter les résultats : Au niveau de l'échantillon :

1. **si  $\epsilon_{calculée} > \epsilon_{th}$  alors on rejette H0** et on accepte H1.
2. **si  $\epsilon_{calculée} < \epsilon_{th}$  alors on accepte H0** et on rejette H1.

Si le / les échantillon(s) considérés sont **représentatifs** de la population, on pourra alors extrapoler le résultat obtenu à l'ensemble de la population.

7) Exemple :

Soient 2 populations : la population des **hommes** et la population des **femmes**. On se demande si, en moyenne, la taille des individus de la population des hommes coïncide avec celle des individus de la population des femmes. On met en place par TAS 2 groupes/échantillons représentatifs de 200 femmes et de 200 hommes. On obtient les moyennes suivantes :

Échantillon	Hommes	Femmes
n	n1=200	n2=200
m	m1 = 1,74 m	m2 = 1,68 m
s	S1 = 0,85	s2 = 0,8

1. définir H0 et H1 :
  - **H0** : il n'y a **pas de différence observée entre les populations des femmes et de hommes**, c'est à dire qu'en moyenne, la taille des hommes coïncide avec celle des femmes
  - **H1** : il existe une **différence significative entre les populations des femmes et des hommes**, c'est à dire qu'en moyenne, la taille des hommes ne coïncide pas avec celle des femmes. En moyenne les hommes sont plus grands que les femmes
2. Déterminer le caractère des données à étudier/comparer :
  - sexe → variable **qualitative**
  - taille → variable **quantitative**
3. Choisir le test en fonction du type de données : Nous sommes en présence de caractères **qualitatifs** et **quantitatifs**, avec  $n1 = n2 > 30$ , on pourra donc choisir d'utiliser un test de **comparaison des moyennes**.
4. Choisir le seuil d'erreur de 1<sup>ère</sup> espèce  $\alpha$  : Ici, le risque de première espèce est fixé à **5%**.
5. Recueillir les données, calculer de Z et utiliser la règle de rejet :
  - $\epsilon_{th} = 1,96$  pour  $\alpha = 5\%$
  - L'énoncé vous donne  $\epsilon_{calculée} = 8,81$
6. Interpréter les résultats :
  - Au niveau des échantillons,  $\epsilon_{calculée} > \epsilon_{th}$  alors **on rejette H0** et on accepte H1. Ainsi, en moyenne, **la taille des hommes de l'échantillon 1 ne coïncide pas avec celle des femmes de l'échantillon 2**. Les hommes de l'échantillon 1 sont plus grands que les femmes de l'échantillon 2.
  - Les échantillons 1 et 2 étant **représentatifs**, on peut alors extrapoler à l'ensemble des deux populations et dire que **d'une manière générale, les hommes sont plus grands que les femmes**.

### III L'étude de la liaison entre des caractères qualitatifs et quantitatifs :

#### B Le test du T student :

Soient 2 populations 1 et 2 et une caractéristique quantitative x (taille, poids etc.) de moyenne  $\mu$ . On se demande si, **en moyenne, la variable x des individus de la population 1 coïncide avec celle des individus de la population 2.** On met en place par TAS 2 groupes/échantillons représentatifs des populations 1 et 2.

1) définir H0 et H1.

- **H0** : il n'y a **pas de différence observée entre les groupes A et B**, c'est à dire qu'en moyenne, la variable x des individus du groupe 1 coïncide avec celle des individus du groupe 2.
- **H1** : il existe **une différence significative entre les groupes A et B**, c'est à dire qu'en moyenne, la variable x des individus du groupe 1 ne coïncide pas avec celle des individus du groupe 2.

2) Déterminer le caractère des données à étudier/comparer : Les variables sont :

- des types d'individus → variable **qualitative**
- une caractéristique x **quantitative**

3) Choisir le test en fonction du type de données En présence de données **qualitatives et quantitatives**, pour  $n_1$  ou  $n_2 < 30$ , on peut choisir d'utiliser un **test de T student**

4) Choisir le seuil d'erreur de 1<sup>ère</sup> espèce  $\alpha$  généralement fixé à **5%**.

5) Recueillir les données, calculer Z et utiliser la règle de rejet

La variable Z est ici représentée par l'écart réduit  $\epsilon$ . On comparera :

1. le T student théorique donné par la table du T student. On l'obtient en croisant :
  - la valeur d' $\alpha$
  - le nombre de ddl donné ici par  $(n_1 - 1) + (n_2 - 1)$

2. T student calculé = 
$$\frac{m_1 - m_2}{\sqrt{\frac{s^2}{n_1} + \frac{s^2}{n_2}}}$$

avec

$m_1$  = moyenne du paramètre x calculée sur l'échantillon n°1

$m_2$  = moyenne du paramètre x calculée sur l'échantillon n°2

$n_1$  = effectif de l'échantillon n°1

$n_2$  = effectif de l'échantillon n°2

s = l'écart type commun aux 2 échantillons.

6) Interpréter les résultats :

Au niveau de l'échantillon :

1. si  $T_{calculé} > T_{théorique}$  alors **on rejette H0** et on accepte H1.
2. si  $T_{calculé} < T_{théorique}$  alors **on accepte H0** et on rejette H1.

Si le / les échantillon(s) considérés sont **représentatifs** de la population, on pourra alors extrapoler le résultat obtenu à l'ensemble de la population.

7) Exemple :

Soient 2 populations : la population des **hommes** et la population des **femmes**. On se demande si, en moyenne, la taille des individus de la population des hommes coïncide avec celle des individus de la population des femmes. On met en place par TAS 2 groupes/échantillons représentatifs de 200 femmes et de 200 hommes. On obtient les moyennes suivantes :

Échantillon	Hommes	Femmes
n	N1=10 (< 30)	N2=10 (<30)
m	m1 = 1,74 m	m2 = 1,68 m
s	S = 0,8	s = 0,8

- définir H0 et H1 :
  - H0** : il n'y a **pas de différence observée entre les populations des femmes et des hommes**, c'est à dire qu'en moyenne, la taille des hommes coïncide avec celle des femmes
  - H1** : il existe une **différence significative entre les populations des femmes et des hommes**, c'est à dire qu'en moyenne, la taille des hommes ne coïncide pas avec celle des femmes. En moyenne les hommes sont plus grands que les femmes
- Déterminer le caractère des données à étudier/comparer :
  - sexe → variable **qualitative**
  - taille → variable **quantitative**
- Choisir le test en fonction du type de données : Nous sommes en présence de caractères **qualitatifs** et **quantitatifs**, avec  $n1 < 30$ . On choisira donc d'utiliser un **test du T student**.
- Choisir le seuil d'erreur de 1<sup>ère</sup> espèce  $\alpha$  : Ici, le risque de première espèce est fixé à **5%**.
- Recueillir les données, calculer Z et utiliser la règle de rejet :
  - $\alpha = 5\%$  et **nb de ddl = (n1-1) + (n2-1) = 9+9 = 18**. La table du T student, nous donne Tstudent th = 2,1
  - Tstudent calculé = 3,4 (*je précise que vous n'aurez jamais à le calculer, il sera donné dans l'énoncé*)
- Interpréter les résultats :
  - Au niveau des échantillons,  $T_{calculé} > T_{th}$ , alors **on rejette H0** et on accepte H1. Ainsi, en moyenne, **la taille des hommes de l'échantillon 1 ne coïncide pas avec celle des femmes de l'échantillon 2**. Les hommes de l'échantillon 1 sont plus grands que les femmes de l'échantillon 2.

Les échantillons 1 et 2 étant **représentatifs**, on peut alors extrapoler à l'ensemble des deux populations et dire que **d'une manière générale, les hommes sont plus grands que les femmes**.

### III L'étude de la liaison entre des caractères qualitatifs et quantitatifs :

#### C Cas de séries appariées, méthode des couples :

On utilise la méthode des couples lorsqu'on étudie la liaison entre **deux variables qualitatives et quantitatives** dans 2 **échantillons non indépendants**.

Exemple : Soit un échantillon A de  $n$  patientes présentant une tumeur au sein. On s'intéresse à la *taille de cette tumeur avant et après un traitement par chimiothérapie*.

- La taille de la tumeur est une variable **quantitative**
- Le traitement est une variable **qualitative**.

Les 2 échantillons A (avant traitement) et A' (après traitement) ne sont **pas indépendants**. Ils sont donc **appariés**. On utilisera alors **la méthode des couples** avec soit :

1. **si  $n > 30$** , un test de **comparaison des moyennes** avec le paramètre écart réduit  $\varepsilon = m_d / \sqrt{\frac{s^2}{n}}$
2. **si  $n < 30$** , un test de **Tstudent** avec le paramètre T :  $t = m_d / \sqrt{\frac{s^2}{n}}$

#### IV Etude de liaison entre des caractères quantitatifs :

Pour étudier la liaison entre 2 variables quantitatives, on utilise un coefficient de corrélation  $r$ . Soient une population et **2 caractéristiques quantitatives  $x$  et  $y$**  (taille, poids, nombre de cigarettes etc.). On se demande **s'il existe un lien entre  $x$  et  $y$  et si oui, lequel**. On met en place par TAS un **échantillon représentatif** de la population.

1) définir  $H_0$  et  $H_1$ .

- **$H_0$**  : il n'y a **pas de lien entre les variables  $x$  et  $y$** .
- **$H_1$**  : il **existe un lien entre  $x$  et  $y$** , celui-ci pouvant être :
  1. positif
  2. négatif

2) Déterminer le caractère des données à étudier/comparer : Les 2 variables sont des variables **quantitatives**.

3) Choisir le test en fonction du type de données En présence de données **quantitatives**, pour un nombre suffisant de sujets, on choisira d'utiliser un **coefficient de corrélation**.

4) Choisir le seuil d'erreur de 1<sup>ère</sup> espèce  $\alpha$  généralement fixé à 5%.

5) Recueillir les données, calculer  $Z$  et utiliser la règle de rejet

- On recueille différentes valeurs de  $x$  et de  $y$ .
- On trace la courbe  **$y = f(x)$**
- On trace **la droite des moindres carrés**, c'est à dire la droite passant au plus près de chaque point de la courbe
- La **pen**te de cette droite est appelé **coefficient de corrélation  $r$** . Il est donné par la formule suivante :

$$r = \frac{\sum xy - \frac{\sum x \cdot \sum y}{n}}{\sqrt{(\sum x^2 - \frac{(\sum x)^2}{n})(\sum y^2 - \frac{(\sum y)^2}{n})}}$$

#### Concernant $r$ ...

1. il est toujours compris dans l'**intervalle  $[-1;1]$**
2. **si il n'existe pas ou est nul**, alors il n'y a **pas de corrélation** entre  $x$  et  $y$  au niveau de l'échantillon
3. **si  $r$  existe et  $r > 0$** , alors il existe une **corrélation positive** entre  $x$  et  $y$  au niveau de l'échantillon
4. **si  $r$  existe et  $r < 0$** , alors il existe une **corrélation négative** entre  $x$  et  $y$  au niveau de l'échantillon

6) Interpréter les résultats : Au niveau de l'échantillon si  **$|r_{\text{calculé}}| > |r_{\text{théorique}}|$**  trouvé dans la table de  $r$ , alors, **on rejette  $H_0$** . Il existe bien un lien significatif entre  $x$  et  $y$ .

Si le / les échantillon(s) considérés sont **représentatifs** de la population, on pourra alors extrapoler le résultat obtenu à l'ensemble de la population.

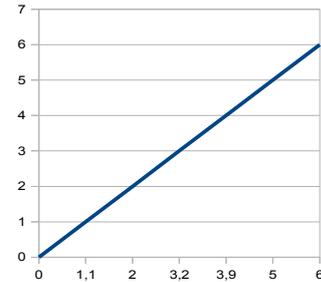
7) Exemple :

Soient la population des sujets **fumeurs ET** ayant **une tumeur au poumon**, et 2 caractéristiques **quantitatives** :

- $x$  = nombre de cigarettes fumées par jour
- $y$  = taille de la tumeur

On se demande s'il existe **un lien entre le nombre de cigarettes fumées et la taille de la tumeur et si oui, lequel**. On met en place par TAS, un échantillon **représentatif** de cette population. On relève pour chaque personne de l'échantillon les valeurs de  $x$  et  $y$ . A partir des données, on obtient :

- $r$  théorique = 0,71
- le graphe suivant :



Parallèlement,

- $r$  calculé = 0,78
- On a donc  **$r$  théorique <  $r$  calculé** → **on rejette  $H_0$**

**Conclusion :**

- Il existe bien une **corrélacion entre le nombre de cigarettes et la taille de la tumeur**
- Comme  $r > 0$ , cela signifie qu'il y a **corrélacion positive**, c'est à dire que *plus le sujet a fumé de cigarettes, et plus la taille de la tumeur augmente*.
- Comme l'échantillon a été réalisé par **TAS**, on peut extrapoler les résultats à l'ensemble de la population des fumeurs présentant une tumeur pulmonaire.

**V Les tests non paramétriques :**

On utilisera des tests non paramétriques lorsque les **effectifs sont trop faibles** (inférieurs à **5**) pour utiliser les tests classiques et qu'au moins une des 2 variables est une variable quantitative. Dans ce cas, les populations ne se distribuent pas normalement et les tests non paramétriques présentent une **excellente robustesse**.

Ce tableau résume bien quel test utiliser en fonction de l'effectif :

Effectif	Données Quantitatives	Données Qualitatives	Données Qualitatives - Quantitatives
>4 & <12	r' de Spearman	Comp % ou $\chi^2$	U Mann & Withney
>12 & < 30	Coeff de corrélation r	Comp % ou $\chi^2$	t Student
> 30	Coeff de corrélation r	Comp % ou $\chi^2$	Comp Moyennes

## V Les tests non paramétriques :

### A La liaison quantitatifs/ qualitatifs :test de U de Mann et Whitney

Soient 2 groupes de 5 individus chacun A et B et une caractéristique **quantitative** x (taille etc.) . On peut se demande **si la proportion d'individus du groupe A présentant x coïncide avec la proportion d'individus du groupe B présentant x.**

1) définir H0 et H1.

- **H0** : il n'y a **pas de différence observée entre les groupes A et B**, c'est à dire que la la proportion d'individus du groupe A présentant x coïncide avec la proportion d'individus du groupe B présentant x.
- **H1** : il existe une **différence significative entre les groupes A et B**, c'est à dire que la la proportion d'individus du groupe A présentant x est différente de celle du groupe B.

2) Déterminer le caractère des données à étudier/comparer : Les variables sont :

- des types d'individus → variable **qualitative**
- une caractéristique x **qualitative**

3) Choisir le test en fonction du type de données En présence de données **qualitatives et quantitatives**, et d'un effectif aussi réduit, on utilisera le **U de Mann et Whitney**.

4) Choisir le seuil d'erreur de 1<sup>ère</sup> espèce  $\alpha$  généralement fixé à 5%.

5) Recueillir les données, calculer Z et utiliser la règle de rejet

La variable Z est ici représentée par le **U de mann et Whitney** On comparera :

1. U<sub>th</sub> donné par la table du U de Mann et Whitney en croisant :
  - n<sub>A</sub>
  - n<sub>B</sub> - n<sub>A</sub>, avec n<sub>B</sub> le plus grand des 2 effectifs
2. U calculé. (La méthode de calcul est exposée dans l'exemple qui suit)

6) Interpréter les résultats : Au niveau de l'échantillon :

1. **si U calculé > U<sub>th</sub>**, alors l'imbrication des 2 groupes est important et **on accepte H0**.
2. **si U calculé < U<sub>th</sub>**, alors l'imbrication des 2 groupes est très faible et **on rejette H0**

Si le / les échantillon(s) considérés sont **représentatifs** de la population, on pourra alors extrapoler le résultat obtenu à l'ensemble de la population.

7) Exemple :

Soient 2 populations : la population des **hommes** et la population des **femmes**. On se demande si, *en moyenne, la taille des individus de la population des hommes coïncide avec celle des individus de la population des femmes.* . On met en place par TAS 2 groupes/échantillons représentatifs de 5 femmes et de 5 hommes. On obtient les moyennes suivantes :

<b>Femmes (A)</b>	1m58	1m60	1m65	1m66	1m68
<b>Hommes (B)</b>	1m67	1m69	1m75	1m80	1m90

1. définir H0 et H1 :
  - **H0** : il n'y a **pas de différence observée entre les populations des femmes et de hommes**, c'est à dire qu'en moyenne, la taille des hommes coïncide avec celle des femmes
  - **H1** : il existe une **différence significative entre les populations des femmes et des hommes**, c'est à dire qu'en moyenne, la taille des hommes ne coïncide pas avec celle des femmes. En moyenne les hommes sont plus grands que les femmes
2. Déterminer le caractère des données à étudier/comparer :
  - sexe → variable **qualitative**
  - taille → variable **quantitative**
3. Choisir le test en fonction du type de données : Nous sommes en présence de caractères **qualitatifs** et **quantitatifs**, avec  $n_A = n_B = 5$ . On choisira donc d'utiliser un **test de U Mann et Whitney**
4. Choisir le seuil d'erreur de 1<sup>ère</sup> espèce  $\alpha$  : Ici, le risque de première espèce est fixé à **5%**.
5. Recueillir les données, calculer Z et utiliser la règle de rejet :
  - $\alpha = 5\%$  et  $n_A - n_B = 5 - 5 = 0$ . La table du U, nous donne  $U_{th} = 2$
  - Calcul de  $U_{calculé}$  :

Théorie	Exemple
On classe toutes les valeurs <b>par ordre croissant</b> en fonction de leur appartenance à A ou à B.	<b>1,58 / 1,60 / 1,65 / 1,66 / 1,67/ 1,68/ 1,69 / 1,75/ 1,80 / 1,90</b>
On cherche le paramètres $U_{BA}$ . Pour chaque membre de A, on cumule le nombre de membre de B qui lui sont passés devant.	<b><math>U_{BA} = 0 + 0 + 0 + 0 + 1 = 1</math></b>
<b>NB</b> : $U_{AB} + U_{BA} = n_A \times n_B$	<b>Ici, <math>U_{AB} + U_{BA} = n_A \times n_B = 25</math> Donc <math>U_{AB} = 25 - 1 = 24</math></b>

6. Interpréter les résultats :
  - Au niveau des échantillons,  $U_{calculé} < U_{th}$ , alors alors l'imbrication des 2 groupes est très faible et **on rejette H0**. Cela signifie qu'**il y a une différence de taille significative entre les hommes et les femmes**.

Les échantillons 1 et 2 étant **représentatifs**, on peut alors extrapoler à l'ensemble des deux populations et dire que **d'une manière générale, les hommes sont plus grands que les femmes**.

### B Le coefficient $r'$ de Spearman :

On l'utilise dans le cadre d'un **test de corrélation non paramétrique**. On utilise la même méthode que pour le coefficient de corrélation  $r$ , mais pour des échantillons de moins de 12 sujets et en utilisant la table théorique du  $r'$  de Spearman. La formule du coefficient  $r'$  est :

$$r' = 1 - \frac{6 \sum d_i^2}{n(n^2 - 1)}$$