

## Théorie de l'estimation

ABDELOUHAB A  
Service de Biostatistique

Extraction de  $n$  échantillons d'une population  $P$

Si l'on extrait plusieurs échantillons représentatifs de taille  $n$  fixée, les différences observées entre les résultats obtenus sont dues à des *fluctuations d'échantillonnage*. A partir d'un échantillon, on n'a donc pas de certitudes mais des *estimations de paramètres*.

L'estimation d'un paramètre peut être faite

- par un seul nombre: estimation ponctuelle
- par 2 nombres entre lesquels le paramètre peut se trouver: estimation par intervalle

### I- Caractère qualitatif :

**I-1 : fluctuation d'échantillonnage d'un pourcentage**  
lorsqu'on évalue dans un ensemble de sujets ou « population » la proportion  $p$  de ceux qui présentent un caractère donné, on ne dispose le plus souvent dans la réalité que de groupes extraits de cette population. La proportion qu'ils nous fournissent  $p_0$  n'est pas la proportion exacte, elle s'en écarte plus ou moins selon le hasard de l'échantillonnage.

### I-1- 1 le pari :

la proportion observée  $p_0$  est susceptible de prendre des valeurs échelonnées de 0 à 1.  $q_0 = 1 - p_0$

les deux bornes de l'intervalle de pari sont données au risque  $\alpha$  par :

$$\text{pour } p : \quad p - \varepsilon \alpha \sqrt{pq/n} \leq p_0 \leq p + \varepsilon \alpha \sqrt{pq/n}$$

$$\text{pour } q : \quad 1 - p_i \geq q_0 \geq 1 - p_s$$

$p_i$  borne inférieure de l'intervalle de confiance de  $p$ .  
 $p_s$  borne supérieure de l'intervalle de confiance de  $p$

**I-1-3-table de l'écart réduit :**

donne pour tout écart réduit  $z$  le risque  $\alpha$  correspondant  
pour  $z=1.96$   $\alpha=0.05$

en résumé, si nous parions par exemple que la proportion  $p_0$  sur un échantillon de  $n=100$  extrait d'une population où  $p=50\%$

$p_0$  sera comprise entre 40% et 60% (donc  $i=10$ ) avec un risque de se tromper de 5%.

**I-1-4 Condition d'utilisation de la table ( validité de l'intervalle)**

La table de l'écart réduit ne donne une approximation convenable que pour les grands échantillons :  $n \geq 30$

$$n.p, n.q \geq 5$$

**I-1-5 puissance et risque d'un pari : si  $p=20\%$  ,  $n=50$** 

pour  $\alpha = 0.001$   $z\alpha = 3.29$   $i = 3.29 \cdot 0.057 = 0.19$   
pour  $\alpha = 0.50$   $z\alpha = 0.67$   $i = 0.67 \cdot 0.057 = 0.04$

plus en désire un risque d'erreur faible plus on est obligé de parier sur un intervalle étendu ; il y a antagonisme entre le risque et la puissance d'un pari

**I-1-6 utilisation des nombres au lieu des pourcentages :**

prenons par exemple  $p=20\%$  de  $n=50$   $\alpha=5\%$

l'intervalle de pari correspondant est 8%-32%

en traduisant les pourcentages en nombre :

$$0.08 \cdot 50 = 4 \quad 0.32 \cdot 50 = 16$$

donc on pari au risque de 5% que le nombre de boules noires sera compris entre 4 et 16.

**I-2 Estimation d'un pourcentage théorique :**

Faire une estimation c'est tenter de définir les paramètres d'une population, à partir des paramètres observés sur un échantillon.

**I-2-1 Estimation d'un pourcentage inconnu :**

Lorsqu'on observe un pourcentage  $p_0$  sur un échantillon, le problème est d'estimer le véritable pourcentage inconnu  $p$  de la population d'où est extrait l'échantillon.

Il nous faut donc estimer un intervalle dans lequel le pourcentage inconnu  $p$  de la population a la plus grande probabilité de se trouver : cet intervalle est appelé intervalle de confiance

L'observation d'un pourcentage  $p_0$  sur un échantillon de  $n$  cas permet d'assigner au pourcentage inconnu  $p$  l'intervalle de confiance avec le risque  $\alpha$  :

$$p_0 - \varepsilon \alpha \sqrt{p_0 q_0 / n} \leq p \leq p_0 + \varepsilon \alpha \sqrt{p_0 q_0 / n}$$

Aussi pour  $q$  :

$$1 - p_i \leq q \leq 1 - p_s$$

#### I-2-2 Conditions d'application (validité de l'intervalle)

Cette formule nécessite que l'effectif de l'échantillon soit suffisamment grand)  $n \geq 30$

Si on appelle  $p_i$  et  $q_i$  les bornes inférieures et de l'intervalle de confiance de  $p$  et de  $q$  il faut que :  $np_i, nq_i \geq 5$ .

#### I-2-3 Table de l'intervalle de confiance

il existe des tables donnant l'intervalle de confiance en fonction du pourcentage observé.