

# **Statistiques Appliquées à la Psychologie**

## **UV PY213B**

### **Présentation du cours 2000/2001**

#### **Organisation matérielle**

Cours magistral: 13 heures  
mardi 11h30 - 12h30 - Amphi 3

Travaux dirigés: séances de deux heures  
lundi 13h45 à 15h45 - A222  
lundi 16h à 18h - A221  
lundi 16h à 18h - A212  
mercredi 13h45-15h45 - A326  
mercredi 16h à 18h - B213

Contrôle des connaissances: (contrôle continu)  
Examen de 3 heures en janvier

## Bibliographie

- N. Guéguen. Manuel de Statistiques pour Psychologues, Dunod
- B. Cadet Méthodes statistiques en psychologie. P.U. de Caen
- G. Mialaret. Statistiques appliquées aux sciences humaines. PUF
- B. Beaufils. Statistiques appliquées à la psychologie. Tome 1. LEXIFAC Bréal
- M. Reuchlin. Précis de Statistiques. PUF Coll. Le Psychologue.
- Colin, Lavoie, Delisle. Initiation aux méthodes quantitatives en Sc. Humaines CDR. No 310-LAV V2098/A

## **Contenu**

Statistiques descriptives : résumer, donner une vue synthétique d'un ensemble de données

Statistiques "mathématiques" : distributions théoriques  
Corrélation linéaire, Test du  $\chi^2$ , aperçu sur les autres tests.

Transparents du CM et polycopiés de TD 1998/99 sur internet (au format .pdf lisible par Acrobat Reader) :

<http://geai.univ-brest.fr/enseignements/py213b.html>

## **Pourquoi faut-il étudier les statistiques ?**

Les statistiques sont-elles utiles au psychologue ?

Les statistiques, il y a des calculatrices et des logiciels pour faire cela ?

# **Introduction – Vocabulaire**

## **Collecte des données**

### **Sur qui ?**

Population

Individu statistique, unité statistique, sujet

### **A propos de quoi ?**

Attribut, caractère, variable statistique

Modalités d'une variable : exhaustives - exclusives

Champ ou domaine de variation

### **Nature d'une variable statistique**

Variables nominales – échelle nominale

Variables ordinaires – échelle ordinaire

Variables numériques discrètes ou continues

Echelles d'intervalles, échelles de rapports

## Recueil et présentation d'un ensemble de données

Individus :  $s_1, s_2, \dots, s_N$

Variables étudiées :  $X, Y, \dots$

**Tableau protocole :**

	$X$	$Y$
$s_1$	$x_1$	$y_1$
$s_2$	$x_2$	$y_2$
...	...	...
$s_N$	$x_N$	$y_N$

Recensement ou tri à plat: **tableau d'effectifs**

Modalités	Effectifs	Fréquences
$a_1$	$n_1$	$f_1$
$a_2$	$n_2$	$f_2$
...	...	
$a_k$	$n_k$	$f_k$
	$N$	1 (ou 100%)

Variable regroupée en classes :

Classes	Effectifs	Fréquences
$[a_1, a_2[$	$n_1$	$f_1$
$[a_2, a_3[$	$n_2$	$f_2$
...	...	
$[a_k, a_{k+1}[$	$n_k$	$f_k$
	$N$	1 (ou 100%)

Etude conjointe de deux variables : **tableau de contingence**

$X \setminus Y$	$b_1$	$b_2$	$\dots$	$b_j$	$\dots$	$b_l$	
$a_1$	$n_{11}$	$n_{12}$		$n_{1j}$	$\dots$	$n_{1l}$	
$a_2$	$n_{21}$	$n_{22}$			$\dots$		
$\dots$							
$a_i$	$n_{i1}$	$n_{i2}$		$n_{ij}$	$\dots$		
$\dots$							
$a_k$	$n_{k1}$	$n_{k2}$			$\dots$	$n_{kl}$	
	$N_{\cdot 1}$						$N$

# Représentations graphiques

## Variables nominales

Mod.	Eff.	Freq.	%
Bleus	2811	0,41	41%
Gris	3132	0,46	46%
Brun	857	0,13	13%
Total	6800	1	100%


Diagrammes à bandes



## Diagrammes circulaires ou semi-circulaires

Méthode de construction : construire un tableau de proportionnalité


Modalités	Bleu	Gris	Brun
Fréq.	0,41	0,46	0,13
Angle	74	83	23



## Variable ordinaire : diagramme en bâtons

On a demandé à 240 sujets s'ils fermaient à clef la porte de leur appartement.


	Jam.	Parf.	Souv.	T. souv.	Tjrs
Eff.	25	55	35	50	75



**Variable numérique discrète** : même type de construction ; graduation régulière sur l'axe des abscisses.

Exemple : nombre de garçons dans des familles de 5 enfants

Mod.	0	1	2	3	4	5
Eff.	5	18	32	29	14	2




**Variable numérique regroupée en classes : histogramme.**

Un histogramme est formé de rectangles adjacents :

- dont la base est proportionnelle à l'amplitude de la classe
- dont l'aire est proportionnelle à l'effectif de la classe

Classe	Eff.	Amplitude	Densité
[155, 166[	8	11	0.73
[166, 170[	9	4	2.25
[170, 172[	7	2	3.5
[172, 176[	9	4	2.25
[176, 190]	7	14	0,5



# Fonction de répartition

## Définitions

$X$  une variable statistique numérique  
Population d'effectif total  $N$ .

**Effectif cumulé croissant** d'une valeur numérique  $x$  quelconque: nombre d'individus  $n_c(x)$  pour lesquels la variable  $X$  est strictement inférieure à  $x$ .

**Fréquence cumulée croissante :**

$$F(x) = \frac{n_c(x)}{N}$$

**Fonction de répartition :** fonction numérique  $F$  telle que, pour tout  $x$ ,

$$F(x) = \frac{n_c(x)}{N}$$

## Représentation graphique, cas d'une variable discrète

Exemple: nombre de garçons dans des familles de 5 enfants

Mod.	0	1	2	3	4	5	
Eff.	5	18	32	29	14	2	
Eff. Cum.	0	5	23	55	84	98	100
Fréq. Cum.	0	5%	23%	55%	84%	98%	100%

$$\text{Si } x \leq 0 \quad F(x) = 0$$

$$\text{Si } 0 < x \leq 1 \quad F(x) = 0.05$$


$$\text{Si } 1 < x \leq 2 \quad F(x) = 0.23$$

$$\text{Si } 2 < x \leq 3 \quad F(x) = 0.55$$

$$\text{Si } 3 < x \leq 4 \quad F(x) = 0.84$$


$$\text{Si } 4 < x \leq 5 \quad F(x) = 0.98$$

$$\text{Si } x > 5 \quad F(x) = 1$$



**Cas d'une variable répartie en classes :** hypothèse d'équirépartition des effectifs à l'intérieur d'une classe.

Classes	Effect.		$x$	$n_c(x)$	$F(x)$
[155, 166[	8		155	0	0
[166, 170[	9		166	8	20%
[170, 172[	7		170	17	40.25%
[172, 176[	9		172	24	60%
[176, 190]	7		176	33	80.25%
Total	40		190	40	100%



# Caractéristiques de position

## Mode, classe modale

Mode d'une série statistique (nominale, ordinale ou numérique) : modalité correspondant à l'effectif le plus élevé.

N.B. Une série statistique peut admettre plusieurs modes.

Classe modale d'une série statistique regroupée en classes : classe qui a la plus forte densité.

N.B. : c'est la classe correspondant au rectangle de hauteur maximale dans l'histogramme.

## Médiane

Variable ordinale ou numérique.

Les individus sont *classés par valeurs croissantes de la variable*. La médiane est la valeur du caractère observée sur l'individu “médian”, à savoir :

- Si  $N$  est impair, la médiane est la modalité observée sur l'individu de rang  $\frac{N+1}{2}$
- Si  $N$  est pair et si le caractère est numérique, la médiane est la moyenne des modalités observées sur les individus de rangs  $\frac{N}{2}$  et  $\frac{N}{2} + 1$ .

Dans le cas d'une variable regroupée en classes :

- La médiane est l'abscisse du point du diagramme cumulatif correspondant à la fréquence cumulée 50%.
- La médiane peut être calculée par *interpolation linéaire*:

$$Md = a_i + (a_{i+1} - a_i) \frac{0.5 - F_i}{F_{i+1} - F_i}$$

où  $[a_i, a_{i+1}]$  est la classe contenant l'individu médian et  $F_i, F_{i+1}$  désignent les fréquences cumulées des valeurs  $a_i$  et  $a_{i+1}$ .

## Moyenne arithmétique

Caractère numérique.

- Calcul à partir d'un tableau protocole

$$\mu = \frac{\sum_{i=1}^N x_i}{N}$$

- Calcul à partir d'un tableau d'effectifs

$$\mu = \frac{1}{N} \sum_{i=1}^k n_i a_i = \sum_{i=1}^k f_i a_i$$

Exemple :

Mod.	Effect.	$n_i a_i$
0	5	0
1	18	18
2	32	64
3	29	87
4	14	56
5	2	10
Total	100	235

$$\mu = 2,35$$

– Cas d'une variable répartie en classes

On considère que la masse de chaque classe est concentrée au centre  $c_i = \frac{a_i + a_{i+1}}{2}$  de la classe.

Exemple :

Classes	Effect.	Centres	$n_i c_i$
[155, 166[	8	160,5	1284
[166, 170[	9	168	1512
[170, 172[	7	171	1197
[172, 176[	9	174	1566
[176, 190[	7	183	1281
	40		6840

$$\mu = \frac{6840}{40} = 171$$

# Caractéristiques de dispersion

## Etendue

$x_1, x_2, \dots, x_n$ : valeurs observées d'une variable statistique numérique.

$$x_{\max} = \text{Max}(x_1, x_2, \dots, x_n)$$

$$x_{\min} = \text{Min}(x_1, x_2, \dots, x_n)$$

L'étendue de la variable est :

$$e = x_{\max} - x_{\min}$$

## Quartiles

Soit une série statistique numérique de médiane  $M$ .

Premier quartile  $Q_1$ : médiane de la série des observations strictement inférieures à  $M$ .

Deuxième quartile  $Q_2$ : médiane  $M$  de la série complète.

Troisième quartile  $Q_3$ : médiane de la série des observations strictement supérieures à  $M$ .

Cas d'une variable continue :

$$F(Q_1) = 0.25 ; F(M) = 0.5 ; F(Q_3) = 0.75$$

$F$  est la fonction de répartition

L'écart interquartile est défini par :

$$Iq = Q_3 - Q_1$$

Représentation graphique permettant de visualiser l'étendue et les quartiles : *boîte à moustaches*.

Généralisation : déciles, centiles...

## Ecart moyen

– A partir d'un tableau protocole

$$E_m = \frac{\sum_{i=1}^N |x_i - \mu|}{N}$$

– A partir d'un tableau d'effectifs

$$E_m = \frac{1}{N} \sum_{i=1}^k n_i |a_i - \mu| = \sum_{i=1}^k f_i |a_i - \mu|$$

## Variance et écart type

Définition : La variance est la moyenne des carrés des écarts à la moyenne.

- A partir d'un tableau protocole

$$V = \frac{\sum_{i=1}^N (x_i - \mu)^2}{N}$$

- A partir d'un tableau d'effectifs

$$V = \frac{1}{N} \sum_{i=1}^k n_i (a_i - \mu)^2 = \sum_{i=1}^k f_i (a_i - \mu)^2$$

L'écart type est donné par :  $\sigma = \sqrt{V}$ .

*Calcul pratique*

“Moyenne des carrés moins carré de la moyenne”

$$V = \frac{\sum_{i=1}^N x_i^2}{N} - \mu^2$$

$$V = \left( \frac{1}{N} \sum_{i=1}^k n_i a_i^2 \right) - \mu^2$$

## Remarques

Cas d'une variable répartie en classes : utiliser les centres de classes.

Unités, effet d'un changement d'origine ou d'unités.

## Organisation des calculs

- Cas d'une variable discrète

Mod.	Effect.	$n_i a_i$	$n_i a_i^2$
0	5	0	0
1	18	18	18
2	32	64	128
3	29	87	261
4	14	56	224
5	2	10	50
Total	100	235	681

$$\mu = 2.35 ; V = 6.81 - 2.35^2 = 1.29 ; \sigma = 1.13$$

- Cas d'une variable répartie en classes

Classes	Effect.	Centres	$n_i c_i$	$n_i c_i^2$
[155, 166[	8	160.5	1 284	206 082
[166, 170[	9	168	1 512	254 016
[170, 172[	7	171	1 197	204 687
[172, 176[	9	174	1 566	272 484
[176, 190]	7	183	1 281	234 423
	40		6 840	1 171 692

$$\mu = 171$$

$$V = \frac{1171692}{40} - 171^2 = 29292.3 - 29241 = 51.3$$

$$\sigma = \sqrt{51.3} = 7,16 \text{ cm}$$

# **Introduction à la notion de loi théorique**

## **Etudier une série expérimentale, pour quoi faire ?**

- Résumer les observations
- Situer un individu par rapport à son groupe  
Ex. : test spatial. Mais se pose alors le problème de la représentativité de ce groupe...
- Comment utiliser les résultats d'une étude expérimentale pour énoncer des lois générales ?

## **Hasard, aléatoire, variabilité individuelle**

- Un physicien qui recherche la valeur d'une grandeur physique, recherche un *nombre*.  
Exemple: résistivité du cuivre. Si un morceau de métal n'a pas cette résistivité, ce n'est pas du cuivre...
  - En biologie, en psychologie, les résultats obtenus prennent en compte une *variabilité individuelle* plus ou moins importante.  
Exemple: le QI moyen de la population humaine est 100. Un être vivant a un QI de 95. Que peut-on en conclure ?
- Autre aspect: recherche d'une information dans un bruit de fond.

## **Modèles théoriques du hasard**

Formalisation de l'effet du hasard : probabilités.

Les lois théoriques permettent, dans certaines situations pratiques de justifier des conclusions telles que :

- le hasard suffit seul à expliquer la variabilité
- le hasard ne suffit pas comme explication ; il y a “autre chose” .

Deux situations-types de l'effet du hasard :

- Variabilité due à des effets nombreux, de faible amplitude, additifs : loi normale
- Caractère de type dichotomique : succès/échec. Nombre de succès sur N individus tirés au hasard : loi binomiale.

# Loi Binomiale

## Combinaisons

$n!$  (lire *factorielle n*) désigne :  $1 \times 2 \times \dots \times n$

Le nombre de manières de choisir  $k$  éléments parmi  $n$  éléments est appelé *nombre de combinaisons de n éléments pris k à k*.

Il est noté  $C_n^k$ . On a :  $C_n^k = \frac{n!}{k! (n - k)!}$ .

## Epreuve et loi de Bernouilli

Variable statistique à 2 modalités : 1, 0 ou succès/échec

$p$  : fréquence de la modalité “succès”

Caractéristiques :  $\mu = p$ ,  $\sigma^2 = p(1 - p)$

## Loi binomiale : exemple introductif

Un QCM : 3 questions et 4 réponses dont une seule correcte par question.

Population très nombreuse.

Variable  $X$  : nombre de réponses correctes données par le sujet.

Si les sujets répondent au hasard, quelle est la fréquence de  $X = 2$  ?

## Loi binomiale

Soit  $n$  un nombre entier.


La variable  $X$ , “nombre de succès observés lorsqu’on répète  $n$  fois, de façon indépendante, une expérience de Bernouilli de paramètre  $p”$  suit une *loi binomiale de paramètres  $n$  et  $p$* .

- ses modalités sont  $0, 1, \dots, n$
- la fréquence de la modalité  $k$  est donnée par :

$$f_k = b(n, p, k) = C_n^k p^k (1 - p)^{n-k}$$

## Caractéristiques

$$\mu = np ; \sigma^2 = np(1 - p)$$



# Loi Normale

**Qu'est-ce qu'une variable théorique continue ?  
Pourquoi des lois théoriques continues ?**

- Variables “naturellement” continues (ex. taille)
- Variables regroupées en classes
- Approximation de lois discrètes.

**Comment est définie une loi théorique continue ?**

Loi d'une variable observée : histogramme, fonction de répartition.

Pour une loi théorique continue :

- densité  $f$  ; courbe  $y = f(x)$
- Fonction de répartition  $F$  ;  
courbe cumulative  $y = F(x)$

Fréquence de la classe  $[a, b[$  :  $F(b) - F(a)$

Notée aussi :  $P(a \leq X < b)$ .

$F(a)$  : fréquence de la classe  $] -\infty, a[$  ou  $X < a$

Notée aussi :  $P(X < a)$

De même, pour la classe notée  $[b, +\infty[$  ou  $X \geq b$ ,  
 $P(X \geq b) = 1 - F(b)$ .

## Une loi théorique intéressante : la loi normale

*Problème:* Une loi théorique approchant bien les distributions expérimentales dans lesquelles la dispersion de la variable résulte d'effets nombreux, additifs, indépendants, du même ordre de grandeur.

## Situation type: planche de Galton

## Loi normale centrée réduite

## Vocabulaire :

centrée :  $\mu = 0$       réduite :  $\sigma = 1$

Une variable  $Z$  suit la loi normale centrée réduite si ses caractéristiques sont les suivantes :

Ensemble des modalités :  $]-\infty, +\infty[$

Densité :

$$f(x) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{x^2}{2}\right)$$

## Fonction de répartition

## Utilisation de cette loi : tables numériques


## Exemples :

$$P(-1 < Z < 1) \equiv 68\%$$

$$P(-2 < Z < 2) = 95\%$$

$$P(-3 < Z < 3) = 98\%$$

## Densité de la loi normale centrée réduite



## Loi normale – cas général

Une variable statistique  $X$  de moyenne  $\mu$  et d'écart-type  $\sigma$  suit la loi (est distribuée selon la loi) normale de paramètres  $\mu$  et  $\sigma$  si la variable  $Z$  définie par :

$$Z = \frac{X - \mu}{\sigma}$$

suit une loi normale centrée réduite.

## **Convergence de la loi binomiale vers la loi normale**

Passage du discret au continu: *correction de continuité*

A la modalité  $k$  de la loi binomiale, on fait correspondre la classe  $[k - 0.5, k + 0.5[$ .

### **Règle**

En pratique, on peut remplacer la loi binomiale de paramètres  $n$  et  $p$  par la loi normale de paramètres  $\mu = np$  et  $\sigma = \sqrt{np(1-p)}$  lorsque :

$$n \geq 30, \quad np \geq 15, \quad n(1-p) \geq 15$$

Exemple : loi binomiale telle que  $n = 30$  et  $p = 0.5$

$$P(X = 12) = 0.0806.$$

$$P(11.5 \leq \tilde{X} < 12.5) = 0.0800$$

$$F(X \leq 12) = 0.1808.$$

$$F(\tilde{X} < 12.5) = 0.1807$$

# **Analyses bivariées – Introduction**

Jusqu'à présent : études portant sur une seule variable.

## **Etude simultanée de deux variables nominales :**

Analyse croisée de deux variables (par ex. questionnaire d'enquête)

- Loisir préféré et sexe
- Opinion sur l'immigration et sensibilité politique

*Question posée :* les deux variables sont-elles *indépendantes* ou *dépendantes*?

*Outil :* analyse d'un tableau de contingence à l'aide d'un test du  $\chi^2$ .

## **Etude de la liaison entre deux variables numériques**

- Population d'étudiants. Variables: note de février et note de juin. Lien éventuel?
- Population de sujets: lien entre taille et poids

*Question posée :* Y a-t-il un lien, une *corrélation* entre les deux variables?

*Outil :* étude de la corrélation linéaire entre les deux variables

# Analyse d'un tableau de contingence

## Test du $\chi^2$

Exemple : préférences des publics masculin et féminin.  
Effectifs observés

	H	F	Total
Comédie	90	75	165
Drame	50	45	95
Variétés	160	80	240
Total	300	200	500

Goûts dépendants du sexe ?

Effectifs attendus (ou théoriques) si indépendance :

Dans chaque case : effectif =  $\frac{\text{total ligne} \times \text{total colonne}}{\text{total général}}$

	H	F
Comédie	99	66
Drame	57	38
Variétés	144	96

Calcul de la “distance” du  $\chi^2$

Mod.	$n_{ij}$	$t_{ij}$	$\frac{(n_{ij} - t_{ij})^2}{t_{ij}}$
H.C.	90	99	0.82
H.D.	...		0.86
H.V.			1.78
F.C.			1.23
F.D.			1.29
F.V.			2.67
			8.64

## Test du $\chi^2$

- 500 personnes : échantillon
- 2 sources de variation : effet du sexe, hasard
- *Si seul le hasard est en cause, la distance suit une loi du  $\chi^2$  à 2 ddl.*
- On se fixe un seuil de 5% (par exemple)
- *Si seul le hasard est en cause, on a seulement 5% de chances d'observer un  $\chi^2$  supérieur à la valeur critique  $\chi_c^2 = 5.991$ .*
- Or on a observé :  $\chi_{obs}^2 = 8.64$ .
- Conclusion : différence de goûts selon le sexe.

## Résumé

Tableau de contingence : effectifs observés  $n_{ij}$

Totaux par ligne :  $n_{i\cdot}$  par colonne :  $n_{\cdot j}$

Total général :  $N$  ou  $n_{..}$

$l$  lignes et  $c$  colonnes

Effectifs théoriques : tableau  $(t_{ij})$  avec :

$$t_{ij} = \frac{n_{i\cdot} n_{\cdot j}}{n_{..}} = \frac{\text{total ligne} \times \text{total colonne}}{\text{total général}}$$

Distance du  $\chi^2$  :

$$\chi_{obs}^2 = \sum_{i,j} \frac{(n_{ij} - t_{ij})^2}{t_{ij}}$$


Test proprement dit :

- Hypothèse : le hasard est seul en cause. Les variables sont indépendantes.
- On fixe un seuil  $\alpha$  (5%, 1%, ...)
- Lecture de la table : valeur critique  $\chi_c^2$  pour le seuil  $\alpha$  et  $(l - 1)(c - 1)$  ddl
- Intervalles d'acceptation et de rejet
- Comparaison de  $\chi_{obs}^2$  et de  $\chi_c^2$
- Conclusion :
  - Si  $\chi_{obs}^2 < \chi_c^2$ , indépendance acceptée
  - Si  $\chi_{obs}^2 > \chi_c^2$ , indépendance rejetée ; les variables dépendent l'une de l'autre.

*Remarques*

- Condition sur les effectifs théoriques minimaux
- Correction de Yates
- D'autres utilisations du test du  $\chi^2$

## Distributions du $\chi^2$



# Corrélation linéaire

Exemple :

- Sujets : étudiants  $s_i$
- Variables : note de février  $x_i$ , note de juin  $y_i$
- Y a-t-il un lien entre ces deux notes ?

Données :

	$X$	$Y$
$s_1$	$x_1$	$y_1$
$s_2$	$x_2$	$y_2$
...	...	...

## Nuage de points

## Covariance des variables $X$ et $Y$

$$Cov(X, Y) = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})$$

ou

$$Cov(X, Y) = \left( \frac{1}{n} \sum_{i=1}^n x_i y_i \right) - \bar{x} \bar{y}$$

## Coefficient de corrélation de Bravais Pearson

$$\rho = \frac{Cov(X, Y)}{\sigma(X)\sigma(Y)}$$

## Remarques

- Il existe des relations non linéaires
- Corrélation n'est pas causalité

# Echantillonnage

**Exemple**: échantillon - fluctuations d'échantillonnage

## Distribution d'échantillonnage

Population des individus

Caractère  $X$ , moyenne  $\mu$ , écart type  $\sigma$

Population des échantillons de taille  $n$ .

Variable  $\bar{X}$ : moyenne observée sur un échantillon.

Distribution de  $\bar{X}$ : *distribution d'échantillonnage*.

## Théorème de la limite centrée

La variable  $\bar{X}$ , moyenne observée sur un échantillon de taille  $n$ , a pour paramètres :

$$\text{Moy}(\bar{X}) = \mu ; \quad \text{Var}(\bar{X}) = \frac{\sigma^2}{n}$$

Si  $n$  est assez grand ( $n \geq 30$ ),  $\bar{X}$  est approximativement distribuée selon une loi normale.


## Cas d'une proportion

$X$ : variable dichotomique, modalités 0 et 1

Fréquence de la modalité 1 :  $p$

$F$  fréquence observée sur un échantillon de taille  $n$

$$\text{Moy}(F) = p ; \quad \text{Var}(F) = \frac{p(1-p)}{n}$$



## **Estimation de paramètres**

Variable  $X$  sur une population nombreuse  
Moyenne  $\mu$ , écart type  $\sigma$  inconnus

On a tiré un échantillon:

- Taille  $n$
- Moyenne observée sur l'échantillon :  $\bar{X}_{obs}$
- Ecart type de l'échantillon :  $s$ .

### **Estimation ponctuelle de la moyenne**

$$\hat{\mu} = \bar{X}_{obs}$$

### **Estimation ponctuelle de la variance et de l'écart type**

Variance corrigée, définie par :

$$\hat{\sigma}^2 = s_c^2 = \frac{n}{n-1} s^2$$

## **Estimation de la moyenne par un intervalle de confiance**

Problème: obtenir une affirmation du type:  $\mu$  est comprise entre ... et ...

En fait, plutôt: avec 95% de degré de confiance, j'estime que  $\mu$  est comprise entre ... et ...

### **Exemple**

Test sur une population. Score  $X$ .  
 $\mu$  et  $\sigma$  inconnus

Échantillon:

$$\begin{aligned} n &= 49 \\ \bar{X}_{obs} &= 25 \\ s &= 5.94; s^2 = 35.26 \end{aligned}$$

Estimation ponctuelle de  $\sigma$ :

$$s_c^2 = \frac{49}{48} \times 35.26 = 36; s_c = 6$$

### **Raisonnner sur une observation**

### **Raisonnner sur la distribution d'échantillonnage : intervalle de confiance**

- $\bar{X}$ : var. "moyenne sur un échantillon de taille 49"
- variable normale, moyenne  $\mu$
- Ecart type estimé  $S$  tel que:  $S^2 = \frac{s_c^2}{n} = \frac{36}{49}$
- Une valeur observée:  $\bar{X}_{obs} = 25$

Variable normale centrée réduite associée à  $\bar{X}$ :  $Z$

$$Z = \frac{\bar{X} - \mu}{S} ; \quad \bar{X} = SZ + \mu$$

Avec 95% de degré de confiance, on estime que la valeur  $Z_{obs}$  associée à  $\bar{X}_{obs}$  vérifie :

$$-1.96 \leq Z \leq 1.96$$

Calcul des valeurs extrêmes pour  $\mu$ :

Pour  $\bar{X}_{obs} = 25$  et  $Z = -1.96$ ,  $\mu = 26.68$

Pour  $\bar{X}_{obs} = 25$  et  $Z = 1.96$ ,  $\mu = 23.32$

## Conclusion

Avec un degré de confiance de 95%, on estime que :

$$23.32 \leq \mu \leq 26.68$$

## Remarques et compléments

– Si on veut donner une formule générale :

$$\bar{X}_{obs} - \frac{s_c}{\sqrt{n}}z_\alpha \leq \mu \leq \bar{X}_{obs} + \frac{s_c}{\sqrt{n}}z_\alpha$$

où  $z_\alpha$  est déterminé par :

$$P(-z_\alpha \leq Z \leq z_\alpha) = 1 - \alpha$$

- Normalité de la distribution parente
- Petits échantillons: on procède autrement si  $n < 30$ .
- Il existe une méthode analogue dans le cas des proportions

## Tests d'hypothèse

On reprend l'exemple précédent :

Test sur une population. Score  $X$

$\mu$  et  $\sigma$  inconnus

Echantillon :

$$\begin{aligned} n &= 49 \\ \bar{X}_{obs} &= 25 \\ s &= 5.94; s^2 = 35.26 \end{aligned}$$

**Problème :** Peut-on affirmer presque sûrement que, sur la population tout entière, la moyenne  $\mu$  est supérieure à 20 ?

- Hypothèse nulle  $H_0 : \mu = 20$
- Hypothèse alternative  $H_1 : \mu > 20$
- Seuil choisi : 1% par exemple
- Statistique de test :

$$Z = \frac{\bar{X} - 20}{E} \quad \text{avec} \quad E^2 = \frac{s_c^2}{n}$$

$$Z = \frac{7}{6}(\bar{X} - 20)$$

- Distribution de la statistique de test : loi normale centrée réduite
- Règle de décision et valeur critique :  $z_c = 2.33$
- Mise en œuvre du test et conclusion :

Ici :  $Z_{obs} = 5.83$ . On rejette donc  $H_0$ .