

# 4.1 DISTRIBUTIONS ÉCHANTILLONNALES

cours 22

# Aujourd'hui, nous allons voir

- ✓ Distributions échantillonnales

# Les statistiques

Étant donné une population, on peut s'intéresser à toute sorte de chose la concernant.

## Définition

Soit  $P$  une population, une **variable statistique**  $X$  sur  $P$  est une fonction qui attribue à chaque individu un élément d'un ensemble  $M$ .

$$X : P \longrightarrow M$$

On discernera deux cas en fonction de l'ensemble d'arrivé de la fonction.

### Définition

On dira d'une **variable statistique** qu'elle est **quantitative** si l'ensemble des **valeurs** qu'elle peut prendre est un ensemble de nombres.

### Exemple

L'âge, poids, taille, etc.


### Définition

On dira d'une **variable statistique** qu'elle est **qualitative** si l'ensemble des **modalités** qu'elle peut prendre n'est pas un ensemble de nombres.

### Exemple



Le sexe, la couleur des cheveux, fumeur, etc.

Variables statistiques



Quantitatives

Qualitatives



Discrètes

Continues

Nominales

Ordinales

Si par exemple, on s'intéresse au poids des chevreuils du Québec, avoir disons 3 000 000 de poids est beaucoup d'informations!

On s'intéresse donc à certaines mesures plus simples pour d'écrire une variable statistique.

## Mesures de tendance centrale

**Mode:** La donnée qui apparaît le plus souvent

**Médiane:** Si les données sont placées en ordre, c'est la donnée qui divise les données en deux.

**Moyenne:**

$$\mu = \frac{1}{n} \sum_{k=1}^n x_k$$

# Mesures de dispersion

Étendue:

$$x_{max} - x_{min}$$

Écart moyen:

$$EM = \frac{1}{n} \sum_{k=1}^n |x_i - \mu|$$







Variance:

$$\sigma^2 = \frac{1}{n} \sum_{k=1}^n (x_i - \mu)^2$$

# Statistique descriptive.

En statistique descriptive, on considère des variables statistiques sur des populations

On recueille l'information et on la présente.



# Inférence statistique

Dans les faits, aller chercher l'information pour toute une population est très difficile, voire impossible.

C'est pour cette raison qu'on observe plutôt un échantillon.

Mais comment fait-on pour déterminer si notre échantillon représente bien la population?

Avec les probabilités.

## Population

## Échantillon

Taille	$N$	$n$
Moyenne	$\mu$	$\bar{x}$
Variance	$\sigma^2$	$s^2$
Écart type	$\sigma$	$s$
Proportion	$\pi$	$p$

## Exemple

Regardons une population de 5 personnes et considérons la variable statistique: le nombre de cellulaires dans les 5 dernières années.

A	2
B	1
C	0
D	3
E	4

$$\mu = \frac{1}{5}(2 + 1 + 0 + 3 + 4) = 2$$

$$\begin{aligned}\sigma^2 &= \frac{1}{5}((2 - 2)^2 + (1 - 2)^2 + (0 - 2)^2 + (3 - 2)^2 + (4 - 2)^2) \\ &= 2\end{aligned}$$

## Exemple

Regardons une population de 5 personnes et considérons la variable statistique: le nombre de cellulaires dans les 5 dernières années.

$$\mu = 2 \quad \sigma^2 = 2$$

A	2
B	1
C	0
D	3
E	4

Si on prend un échantillon avec remise de taille 2

	$\bar{x}$								
AA	2	BA	1,5	CA	1	DA	2,5	EA	3
AB	1,5	BB	1	CB	0,5	DB	2	EB	2,5
AC	1	BC	0,5	CC	0	DC	1,5	EC	2
AD	2,5	BD	2	CD	1,5	DD	3	ED	3,5
AE	3	BE	2,5	CE	2	DE	3,5	EE	4

## Exemple

Regardons une population de 5 personnes et considérons la variable statistique: le nombre de cellulaires dans les 5 dernières années.

A	2
B	1
C	0
D	3
E	4

$$\mu = 2$$
$$\sigma^2 = 2$$

Considérons l'expérience aléatoire de piger un échantillon au hasard

$\bar{X}$  : moyenne de l'échantillon

	$\bar{x}$								
AA	2	BA	1,5	CA	1	DA	2,5	EA	3
AB	1,5	BB	1	CB	0,5	DB	2	EB	2,5
AC	1	BC	0,5	CC	0	DC	1,5	EC	2
AD	2,5	BD	2	CD	1,5	DD	3	ED	3,5
AE	3	BE	2,5	CE	2	DE	3,5	EE	4

## Exemple

Regardons une population de 5 personnes et considérons la variable statistique: le nombre de cellulaires dans les 5 dernières années.

$\bar{X}$  : moyenne de l'échantillon

L'ensemble de réalisation est

1 2 3 4 5 4 3 2 1

{0, 0,5, 1, 1,5, 2, 2,5, 3, 3,5, 4}

	$\bar{x}$								
AA	2	BA	1,5	CA	1	DA	2,5	EA	3
AB	1,5	BB	1	CB	0,5	DB	2	EB	2,5
AC	1	BC	0,5	CC	0	DC	1,5	EC	2
AD	2,5	BD	2	CD	1,5	DD	3	ED	3,5
AE	3	BE	2,5	CE	2	DE	3,5	EE	4

## Exemple

Regardons une population de 5 personnes et considérons la variable statistique: le nombre de cellulaires dans les 5 dernières années.

$\bar{x}_i$	$f(\bar{x}_i)$	1	2	3	4	5	4	3	2	1
0	1/25	{0, 0,5, 1, 1,5, 2, 2,5, 3, 3,5, 4}								
0,5	2/25									
1	3/25									
1,5	4/25									
2	5/25									
2,5	4/25									
3	3/25									
3,5	2/25									
4	1/25									

$$E(\bar{X}) = \sum_{i=1}^9 \bar{x}_i f(\bar{x}_i) = 2$$
$$\text{Var}(\bar{X}) = \sum_{i=1}^9 \bar{x}_i^2 f(\bar{x}_i) - \mu_{\bar{X}}^2 = 1$$

L'exemple précédant illustre les définitions suivantes

## Définition

Étant donnée une variable aléatoire quantitative d'une population de taille  $N$ . Considérons l'expérience aléatoire qui consiste à piger un échantillon de taille  $n$ .

La variable aléatoire

$\bar{X}$  : la moyenne de l'échantillon

On nomme la distribution de cette variable aléatoire, la **distribution échantillonnale de la moyenne**  $\bar{X}$

## Échantillon avec remise

Étant donnée une population de taille  $n$  ainsi qu'une variable statistique  $X$ . On aimerait avoir un lien entre la moyenne et l'écart type de  $X$  et l'espérance et l'écart type de la variable aléatoire  $\bar{X}$ .

Soit  $\mu$  la moyenne de  $X$  et  $\sigma^2$  la variance de  $X$

On peut voir l'expérience aléatoire de piger un échantillon de taille  $n$  comme une suite d'expérience consistant à piger un individu.

$X_i$  : la valeur de la variable statistique.

$$\bar{X} = \frac{X_1 + X_2 + \cdots + X_n}{n}$$

## Échantillon avec remise

Soit  $\mu$  la moyenne de  $X$  et  $\sigma^2$  la variance de  $X$

$X_i$  : la valeur de la variable statistique.

$$\bar{X} = \frac{X_1 + X_2 + \cdots + X_n}{n}$$

Mais  $E(X_i) = \mu$   $\text{Var}(X_i) = \sigma^2$

$$\begin{aligned} E(\bar{X}) &= E\left(\frac{X_1 + X_2 + \cdots + X_n}{n}\right) \\ &= \frac{1}{n} E(X_1 + X_2 + \cdots + X_n) \\ &= \frac{1}{n} (E(X_1) + E(X_2) + \cdots + E(X_n)) \\ &= \frac{1}{n} (\mu + \mu + \cdots + \mu) \\ &= \frac{n\mu}{n} \\ &= \mu \end{aligned}$$


$$E(\bar{X}) = \mu$$

$$\begin{aligned}\text{Var}(\bar{X}) &= \text{Var}\left(\frac{X_1 + X_2 + \cdots + X_n}{n}\right) \\ &= \frac{1}{n^2} \text{Var}(X_1 + X_2 + \cdots + X_n) \\ &= \frac{1}{n^2} (\text{Var}(X_1) + \text{Var}(X_2) + \cdots + \text{Var}(X_n)) \\ &= \frac{1}{n^2} (\sigma^2 + \sigma^2 + \cdots + \sigma^2) \\ &= \frac{n\sigma^2}{n^2} = \frac{\sigma^2}{n}\end{aligned}$$

$$E(\bar{X}) = \mu$$

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

Ici on peut remarquer que plus la taille de l'échantillon est grande plus la variance de  $\bar{X}$  diminue



À priori, on ne connaît pas la distribution de la variable statistique  $X$   
et donc on ne connaît pas non plus la distribution de la variable  
aléatoire  $\bar{X}$

**Théorème** (Théorème central limite)

Soit  $X_1, X_2, \dots, X_n$  des variables aléatoires indépendantes ayant  
toutes la même distribution de probabilité.

$$S = \sum_{k=1}^n X_k \quad \text{alors quand } n \rightarrow \infty$$

$$Y = \frac{S - E(S)}{\sqrt{\text{Var}(S)}} \sim N(0, 1)$$

À l'aide du théorème central limite, on peut déduire que si

$X$  a comme moyenne  $\mu$  et variance  $\sigma^2$

$$E(\bar{X}) = \mu \qquad \text{Var}(\bar{X}) = \frac{\sigma^2}{n} = \sigma_{\bar{X}}^2 \qquad \sigma_{\bar{X}} = \sqrt{\frac{\sigma^2}{n}}$$

$$\frac{\bar{X} - \mu}{\sigma_{\bar{X}}} \sim N(0, 1)$$

et ce peut importe la distribution de  $X$

Faites les exercices suivants

#4.1 à 4.3

## Échantillon sans remise

Soit  $\mu$  la moyenne de  $X$  et  $\sigma^2$  la variance de  $X$

$X_i$  : la valeur de la variable statistique.

$$\bar{X} = \frac{X_1 + X_2 + \cdots + X_n}{n}$$

Ici puisque les variables aléatoires  $X_i$  suivent des lois hypergéométriques

on aura plutôt

$$E(\bar{X}) = \mu \qquad \text{Var}(\bar{X}) = \frac{\sigma^2}{n} \left( \frac{N - n}{N - 1} \right)$$

## Échantillon sans remise

$$E(\bar{X}) = \mu \qquad \text{Var}(\bar{X}) = \frac{\sigma^2}{n} \left( \frac{N - n}{N - 1} \right)$$

On a donc un facteur de correction pour tenir en compte le fait que l'échantillon est fait sans remise

Or, très souvent, la taille de l'échantillon est très petite en comparaison à la taille de la population.

$$N = 10\,000 \qquad n = 100$$

$$\frac{N - n}{N - 1} = \frac{9\,900}{9\,999} = 0,9901 \approx 1$$

La distribution d'échantillonnage suit donc une loi normale

$$\frac{\bar{X} - \mu}{\sigma_{\bar{X}}} \sim N(0, 1)$$

Si l'échantillon est avec remise

$$\sigma_{\bar{X}} = \sqrt{\frac{\sigma^2}{n}}$$

Si l'échantillon est sans remise

$$\sigma_{\bar{X}} = \sqrt{\frac{\sigma^2}{n} \left( \frac{N - n}{N - 1} \right)}$$

Faites les exercices suivants

#4.4

## Aujourd'hui, nous avons vu

La distribution d'échantillonnage suit donc une loi normale

$$\frac{\bar{X} - \mu}{\sigma_{\bar{X}}} \sim N(0, 1)$$

Si l'échantillon est avec remise

$$\sigma_{\bar{X}} = \sqrt{\frac{\sigma^2}{n}}$$

Si l'échantillon est sans remise

$$\sigma_{\bar{X}} = \sqrt{\frac{\sigma^2}{n} \left( \frac{N - n}{N - 1} \right)}$$

Devoir:

4.1 à 4.4