

Chapitre 4

Distribution des échantillons aléatoires

Université de Paris Ouest

2012–2013

Objectifs du chapitre

Rappel :

L'inférence statistique consiste à induire les caractéristiques inconnues d'une population à partir d'un échantillon.

- ▶ échantillon représentatif ?
- ▶ échantillon suffisamment grand ?


Sommaire

- 1** Un exemple pour comprendre
- 2** Distribution des échantillons aléatoires
- 3** Un exemple de calcul
- 4** Conclusion

Un exemple avec une petite population

Le score d'*Agpar* mesure la santé d'un nouveau-né.

$\mathcal{P} = \{5 \text{ enfants}\}, \mu = 8$.




Un exemple avec une petite population

Le score d'*Agpar* mesure la santé d'un nouveau-né.

$\mathcal{P} = \{5 \text{ enfants}\}, \mu = 8$.

échantillon de taille 2




éch. AB			
$\bar{x} = 8,5$			

Un exemple avec une petite population

Le score d'*Agpar* mesure la santé d'un nouveau-né.

$\mathcal{P} = \{5 \text{ enfants}\}, \mu = 8$.

échantillon de taille 2




éch. AB	éch. AC		
$\bar{x} = 8,5$	$\bar{x} = 9$		

Un exemple avec une petite population

Le score d'*Agpar* mesure la santé d'un nouveau-né.

$\mathcal{P} = \{5 \text{ enfants}\}, \mu = 8$.

échantillon de taille 2




éch. AB	éch. AC	...	éch. DE
$\bar{x} = 8,5$	$\bar{x} = 9$...	$\bar{x} = 7,5$

Un exemple avec une petite population

Le score d'*Agpar* mesure la santé d'un nouveau-né.

$\mathcal{P} = \{5 \text{ enfants}\}, \mu = 8$.

échantillon de taille 2



éch. AB	éch. AC	...	éch. DE
$\bar{x} = 8,5$	$\bar{x} = 9$...	$\bar{x} = 7,5$


Si l'échantillon est **tiré au sort**, alors la moyenne observée \bar{x} est **aléatoire** !

Suite de l'exemple : distribution des échantillons

Le score d'*Agpar* mesure la santé d'un nouveau-né.

$\mathcal{P} = \{5 \text{ enfants}\}, \mu = 8$.

échantillon de taille 2




Si l'échantillon est **tiré au sort**, alors la moyenne empirique \bar{x} est **aléatoire** !

Suite de l'exemple : distribution des échantillons

Le score d'*Agpar* mesure la santé d'un nouveau-né.

$\mathcal{P} = \{5 \text{ enfants}\}, \mu = 8$.

échantillon de taille 2



Si l'échantillon est **tiré au sort**, alors la moyenne empirique \bar{x} est **aléatoire** !

Exemple : à retenir

Si l'échantillon est **tiré au sort**, alors la moyenne empirique \bar{x} est **aléatoire**.

- ▶ On aimerait connaître la distribution de \bar{x}
- ▶ Si l'échantillon est grand, peu de chances d'avoir un échantillon "anormal" ?

Notations : \bar{x} vs \bar{X}_n


En fonction du contexte, deux notations

- ▶ \bar{x} : moyenne observée sur un **un échantillon fixé**
- ▶ \bar{X}_n : moyenne empirique d'un **échantillon aléatoire**

Notations : \bar{x} vs \bar{X}_n

En fonction du contexte, deux notations

- ▶ \bar{x} : moyenne observée sur un **un échantillon fixé**
- ▶ \bar{X}_n : moyenne empirique d'un **échantillon aléatoire**



Pour l'échantillon AB , $\bar{x} = 8,5$
mais \bar{X}_n peut valoir $8.5/9/7.5/\dots$

Sommaire

- 1** Un exemple pour comprendre
- 2** Distribution des échantillons aléatoires
 - Protocole d'échantillonnage
 - Échantillons aléatoires pour une variable quantitative
 - Échantillons aléatoires pour une variable qualitative
- 3** Un exemple de calcul
- 4** Conclusion

Protocole : qu'est-ce qu'un échantillon aléatoire ?

On a besoin d'un modèle mathématique précis pour le tirage d'un échantillon de n personnes.

Hypothèses

- ▶ n tirages **uniformes** : chaque individu a la même chance d'être tiré au sort.
- ▶ Les tirages sont **indépendants**.
- ▶ Les tirages se font **avec remise**.

Échantillons aléatoires pour une variable quantitative

X variable continue, de moyenne μ et d'écart-type σ .

\bar{X}_n désigne la moyenne empirique d'un échantillon **tiré au sort**.

Formule

Si $n \geq 30$, alors

$$\bar{X}_n \stackrel{\text{approx.}}{\sim} \mathcal{N} \left(\mu, \frac{\sigma}{\sqrt{n}} \right).$$

Échantillons aléatoires pour une variable quantitative

X variable continue, de moyenne μ et d'écart-type σ .

\bar{X}_n désigne la moyenne empirique d'un échantillon **tiré au sort**.

Formule

Si $n \geq 30$, alors

$$\bar{X}_n \stackrel{\text{approx.}}{\sim} \mathcal{N} \left(\mu, \frac{\sigma}{\sqrt{n}} \right).$$


Exemple : $X = \text{"Âge"}$, $\mu = 41$, $\sigma = 23$.

Si $n = 30$, \bar{X}_{30} est l'âge moyen de 30 Français tirés au hasard.

$$\bar{X}_{30} \stackrel{\text{approx.}}{\sim} \mathcal{N} \left(41, \frac{23}{\sqrt{30}} \right) = \mathcal{N} (41; 4, 20).$$

Exemples de \bar{X}_n quand n varie

X = "Âge", $\mu = 41$, $\sigma = 23$.




Exemples de \bar{X}_n quand n varie

X = "Âge", $\mu = 41$, $\sigma = 23$.

Si $n = 30$, \bar{X}_{30} est l'âge moyen de 30 Français tirés au hasard.

$$\bar{X}_{30} \sim \mathcal{N}(41; 4, 20)$$




Exemples de \bar{X}_n quand n varie

X = "Âge", $\mu = 41$, $\sigma = 23$.

Si $n = 30$, \bar{X}_{30} est l'âge moyen de 30 Français tirés au hasard.

Si $n = 80$, \bar{X}_{80} est l'âge moyen de 80 Français tirés au hasard.

$$\bar{X}_{30} \sim \mathcal{N}(41; 4, 20) \quad \bar{X}_{80} \sim \mathcal{N}(41; 2, 57)$$



Échantillons aléatoires pour une variable qualitative

X variable qualitative, de proportion p .

On note F_n la moyenne empirique d'un échantillon **tiré au sort**.

Formule

Si $n \geq 30$, $np \geq 5$ et $n(1 - p) \geq 5$, alors

$$F_n \xrightarrow{\text{approx.}} \mathcal{N} \left(p, \frac{\sqrt{p(1-p)}}{\sqrt{n}} \right).$$

Échantillons aléatoires pour une variable qualitative

X variable qualitative, de proportion p .

On note F_n la moyenne empirique d'un échantillon **tiré au sort**.

Formule

Si $n \geq 30$, $np \geq 5$ et $n(1 - p) \geq 5$, alors

$$F_n \stackrel{\text{approx.}}{\sim} \mathcal{N} \left(p, \frac{\sqrt{p(1-p)}}{\sqrt{n}} \right).$$

Exemple : \mathcal{P} = "utilisateurs de Facebook en France", X = "Sexe",
 p = "proportion de femmes" = 0.54.

Soit F_n la proportion de femmes parmi 30 utilisateurs tirés au hasard.

Échantillons aléatoires pour une variable qualitative

X variable qualitative, de proportion p .

On note F_n la moyenne empirique d'un échantillon **tiré au sort**.

Formule

Si $n \geq 30$, $np \geq 5$ et $n(1 - p) \geq 5$, alors

$$F_n \stackrel{\text{approx.}}{\sim} \mathcal{N} \left(p, \frac{\sqrt{p(1-p)}}{\sqrt{n}} \right).$$

Exemple : \mathcal{P} = "utilisateurs de Facebook en France", X = "Sexe", p = "proportion de femmes" = 0.54.

Soit F_n la proportion de femmes parmi 30 utilisateurs tirés au hasard.

Comme $30 \geq 30$, $30 \times 0.54 \geq 5$, $30 \times 0.46 \geq 5$,


$$F_n \stackrel{\text{approx.}}{\sim} \mathcal{N} \left(0.54, \frac{\sqrt{0.54 \times 0.46}}{\sqrt{30}} \right) = \mathcal{N} (0.54, 0.09).$$

Échantillons aléatoires pour une variable qualitative

\mathcal{P} = "utilisateurs de Facebook en France", X = "Sexe", $p = 0.54$

F_n = proportion de femmes parmi 30 utilisateurs tirés au hasard.

$$F_n \stackrel{\text{approx.}}{\sim} \mathcal{N}(0.54, 0.09).$$



Sommaire

- 1** Un exemple pour comprendre
- 2** Distribution des échantillons aléatoires
- 3** Un exemple de calcul
- 4** Conclusion

Un exemple de calcul

X = "Sexe", p = "proportion de femmes" = 0.54

F_n = proportion de femmes dans un échantillon de 30 individus.

Question :

On tire 30 utilisateurs au hasard, quelle est la probabilité d'avoir plus de 60% d'hommes ?

Un exemple de calcul

X = "Sexe", p = "proportion de femmes" = 0.54

F_n = proportion de femmes dans un échantillon de 30 individus.

Question :

On tire 30 utilisateurs au hasard, quelle est la probabilité d'avoir plus de 60% d'hommes ?

Cela revient à calculer $P(F_n \leq 0.40)$.

Au transparent précédent, nous avons vu que $F_n \sim \mathcal{N}(0.54; 0.09)$.

Un exemple de calcul

X = "Sexe", p = "proportion de femmes" = 0.54

F_n = proportion de femmes dans un échantillon de 30 individus.

Question :

On tire 30 utilisateurs au hasard, quelle est la probabilité d'avoir plus de 60% d'hommes ?

Cela revient à calculer $P(F_n \leq 0.40)$.

Au transparent précédent, nous avons vu que $F_n \sim \mathcal{N}(0.54; 0.09)$.

On **centre et on réduit** F_n :

$$\begin{aligned} P(F_n \leq 0.40) &= P\left(\frac{F_n - 0.54}{0.09} \leq \frac{0.40 - 0.54}{0.09}\right) \\ &= P(Z \leq -1.56) = F(-1.56) = 1 - F(1.56) = 0.0594. \end{aligned}$$

Un exemple de calcul

X = "Sexe", p = "proportion de femmes" = 0.54

F_n = proportion de femmes dans un échantillon de 30 individus.

Question :

On tire 30 utilisateurs au hasard, quelle est la probabilité d'avoir plus de 60% d'hommes ?

Cela revient à calculer $P(F_n \leq 0.40)$.

Au transparent précédent, nous avons vu que $F_n \sim \mathcal{N}(0.54; 0.09)$.

On **centre et on réduit** F_n :

$$\begin{aligned} P(F_n \leq 0.40) &= P\left(\frac{F_n - 0.54}{0.09} \leq \frac{0.40 - 0.54}{0.09}\right) \\ &= P(Z \leq -1.56) = F(-1.56) = 1 - F(1.56) = 0.0594. \end{aligned}$$

Réponse :

On a environ 6% de chance de tomber sur un échantillon comptant plus de 60% d'hommes.

Sommaire

- 1 Un exemple pour comprendre
- 2 Distribution des échantillons aléatoires
- 3 Un exemple de calcul
- 4 Conclusion

Conclusion

- ▶ Échantillon **tiré au sort** \Rightarrow moyenne empirique/fréquence empirique aléatoire.
- ▶ Si $n \geq 30$, on connaît la distribution de \bar{X}_n, F_n .

Conclusion

- ▶ Échantillon **tiré au sort** \Rightarrow moyenne empirique/fréquence empirique **aléatoire**.
- ▶ Si $n \geq 30$, on connaît la distribution de \bar{X}_n, F_n .

Rappel

Les formules ne sont valables que si l'échantillon est **aléatoire** et **uniforme** : chaque individu de \mathcal{P} a la même chance de faire partie de l'échantillon.