

Chapitre 4

DISTRIBUTIONS D'ECHANTILLONNAGE et INTERVALLES DE VARIATION

Chapitre 4 (suite 1)

1. Introduction

2. Estimation d'une moyenne

- Distribution d'échantillonnage
- Intervalles de variation

3. Estimation d'une proportion

- Distribution d'échantillonnage
- Intervalles de variation

4. Estimation d'une variance

- Distribution d'échantillonnage
- Estimation sans biais

Chapitre 4 (suite 1)

3. Estimation d'une proportion

3.1 Variable qualitative

3.2 Fréquence empirique : statistique et estimateur

3.3 Fluctuations d'échantillonnage de la fréquence empirique

exemple théorique

3.4 Propriétés de la fréquence empirique

3.5 Distribution d'échantillonnage de la fréquence empirique

variable qualitative dichotomique :
théorème central-limite

3.6 Quantiles de la fréquence empirique

3.7 Intervalles de variation de la fréquence empirique

interprétation d'un intervalle de variation

3.8 Précision dans l'estimation de la proportion

3.9 Taille minimum de l'échantillon pour une précision minimum

3. Estimation d'une proportion

X variable qualitative dichotomique
de \mathcal{P} dans $E = \{\text{oui, non}\}$

⇒ un paramètre

proportion de "oui" = p *connue* dans \mathcal{P}

échantillon de **X** issu de \mathcal{P} de taille n

- étudier les propriétés de l'estimation ponctuelle du paramètre proportion p par la fréquence f observée sur un échantillon de taille n
- la fréquence observée f *varie* d'un échantillon à l'autre
- étudier les variations (fluctuations) de la fréquence observée f sur tous les échantillons de même taille n

3.1 Variable qualitative (1)

- Exemple : résultats au DEUG en 1994

$\mathcal{P} = \{ \text{étudiants inscrits en 2d année de DEUG S.H. à Nanterre en 1994} \}$

$N = 617$

$X = \text{"réussite au DEUG"} : \text{oui, non}$
variable qualitative dichotomique

$p = \text{proportion de réussite} = \mathbf{0,75}$
connue dans \mathcal{P}

échantillon de X issu de \mathcal{P} de taille
 $n = 40$

➤ la proportion de réussite p est estimée par la fréquence de réussite observée f

① quelle fréquence f s'attend-on à observer sur l'échantillon de taille $n = 40$?

② quelle précision a-t-on en estimant la proportion de réussite p par f sur un échantillon de taille $n = 40$?

③ serait-on surpris d'observer une fréquence de réussite $f = \mathbf{88\%}$ sur l'échantillon de taille $n = 40$?

3.1 Variable qualitative (2)

- Exemple : résultats au DEUG en 1994

$\mathcal{P} = \{ \text{étudiants inscrits en 2d année de DEUG S.H. à Nanterre en 1994} \}$

$N = 617$

$X = \text{"réussite au DEUG"} : \text{oui, non}$
variable qualitative dichotomique

$p = \text{proportion de réussite} = \mathbf{0,75}$
connue dans \mathcal{P}

échantillon de X issu de \mathcal{P} de taille
 $n = 40$

➤ la proportion de réussite p est
estimé par la fréquence de réussite
observée f

④ à partir de quelle limite une
fréquence de réussite f observée
sur un échantillon de taille $n = 40$
peut-elle être considérée comme
"surprenante" ?

⑤ dans quel intervalle s'attend-on
raisonnablement à observer la
fréquence de réussite f sur
l'échantillon de taille $n = 40$?

3.2 Fréquence empirique : statistique et estimateur

La variable qui représente toutes les valeurs observées f sur tous les échantillons possibles de taille n est appelée **fréquence empirique** et notée F_n

F_n est une **statistique** : une variable calculée à partir des observations (x_1, x_2, \dots, x_n) qui permet de résumer numériquement ces observations

- les propriétés de la statistique dépendent de la taille de l'échantillon n

f est la valeur calculée sur l'échantillon observé de taille n : c'est une **estimation** de du paramètre p

- une estimation est propre à l'échantillon observé

F_n est l'ensemble de toutes les estimations possibles f sur tous les échantillons de taille n : c'est un **estimateur** de p

3.3 Fluctuations d'échantillonnage de la fréquence empirique

population de tous les échantillons de taille n

- un individu est un échantillon de taille n

$F_n =$ *fréquence empirique*

⇒ **variable quantitative** définie de la population des échantillons de taille n dans **[0, 1]**

⇒ deux paramètres $\left\{ \begin{array}{l} \text{moyenne de } F_n \\ \text{écart-type de } F_n \end{array} \right.$

⇒ **forme** de la distribution (loi) de F_n

➤ **étudier les variations (fluctuations) de la fréquence empirique**

➤ étudier la *"loi des fréquences"*

Exemple théorique (1)

- **Exemple : sexe**


$\mathcal{P} = \{ \text{personnes} \} \quad N = 4$

$X = \text{"sexe"}$

variable qualitative dichotomique sur

$E = \{ \text{féminin, masculin} \}$

| variable X | n_i | p_i |
|--------------|-------|-------|
| masculin = M | 2 | 0,5 |
| féminin = F | 2 | 0,5 |
| total | 4 | 1 |



→ un paramètre **connu** dans \mathcal{P}

$p = \text{proportion de femmes} = 0,5$

$(1-p = \text{proportion d'hommes} = 0,5)$

Exemple théorique (2)

- Exemple : sexe

$\mathcal{P} = \{ \text{personnes} \}$ $N = 4$

$X = \text{"sexe"}$

variable qualitative dichotomique sur
 $E = \{ \text{féminin, masculin} \}$

→ un paramètre **connu** dans \mathcal{P}

$p = \text{proportion de femmes} = 0,5$

échantillons de X issu de \mathcal{P} de taille
 $n = 2$: il y en a **16**

pour chacun des 16 échantillons
la fréquence observée f varie

| échantillon | (X_1, X_2) | nb de femmes | F_2 |
|-------------|----------------------|--------------|-------|
| 1 | $(x_1 = M, x_2 = M)$ | 0 | 0 |
| 2 | (M, M) | 0 | 0 |
| 3 | (M, F) | 1 | 0,5 |
| 4 | (M, F) | 1 | 0,5 |
| 5 | (M, M) | 0 | 0 |
| 6 | (M, M) | 0 | 0 |
| 7 | (M, F) | 1 | 0,5 |
| 8 | (M, F) | 1 | 0,5 |
| 9 | (F, M) | 1 | 0,5 |
| 10 | (F, M) | 1 | 0,5 |
| 11 | (F, F) | 2 | 1 |

f

Exemple théorique (3)

- Exemple : sexe

population des échantillons de taille $n = 2$ de taille 16

F_2 = "fréquence de femmes"


variable quantitative sur $[0, 1]$

distribution de F_2 : "loi des fréquences"

| variable F_2 | n_i | $n_i f_i$ | $n_i f_i^2$ |
|----------------|-------|-----------|---------------------|
| 0 | 4 | 0 | 0 |
| 0,5 | 8 | 4 | $8 \times 0,25 = 2$ |
| 1 | 4 | 4 | 4 |
| total | 16 | 8 | 6 |

$$\sum n_i f_i = 8 \quad \sum n_i f_i^2 = 6$$

→ forme de la loi de F_2



→ deux paramètres pour la loi de F_2

$$\left\{ \begin{array}{l} \text{moyenne de } F_2 = 8 / 16 = 0,5 = p \\ \text{variance de } F_2 = (6 / 16) - 0,5^2 \\ \quad \quad \quad = 0,125 = p(1-p) / 2 \end{array} \right.$$

3.4 Propriétés de la fréquence empirique (1)

- La moyenne de la fréquence empirique F_n est égale à p

"la moyenne des fréquences est égale à la proportion dans la population"

⇒ la fréquence empirique F_n est un estimateur sans biais de p

- La variance de la fréquence empirique F_n est égale à $\frac{p(1-p)}{n}$

– plus la taille de l'échantillon est grande plus l'estimation de la proportion est précise

– la variabilité de l'estimation tend vers 0 quand la taille de l'échantillon devient infinie

⇒ la fréquence empirique F_n est un estimateur convergent de variance minimum de p

3.4 Propriétés de la fréquence empirique (2)

- X variable qualitative dichotomique définie de \mathcal{P} dans $E = \{ \text{oui, non} \}$

proportion de "oui" = p

échantillon de X issu de \mathcal{P} de taille n

- F_n fréquence empirique sur les échantillons de taille n

variable quantitative sur $[0, 1]$

$$\left\{ \begin{array}{l} \text{moyenne de } F_n = p \\ \text{variance de } F_n = p(1-p) / n \\ \text{écart-type de } F_n = \sqrt{p(1-p) / n} \end{array} \right.$$

⇒ la fréquence empirique est un **bon** estimateur de la proportion p de X dans \mathcal{P} : il est sans biais, convergent et de variance minimum

- en pratique, on utilisera la **fréquence observée** f sur l'échantillon comme **estimation ponctuelle** de p

3.4 Propriétés de la fréquence empirique (3)

- Exemple : résultats au DEUG en 1994

$\mathcal{P} = \{ \text{étudiants inscrits en 2d année de DEUG S.H. à Nanterre en 1994} \}$

$N = 617$

$X = \text{"réussite au DEUG"} : \text{oui, non}$
variable qualitative dichotomique
un paramètre **connu** dans \mathcal{P}

$p = \text{proportion de réussite} = \mathbf{0,75}$

échantillon de X issu de \mathcal{P} de taille
 $n = 40$

➤ la moyenne de $F_n = p = 0,75$

① on s'attend en moyenne à observer une fréquence de réussite égale à $p = 75\%$ sur l'échantillon de taille $n = 40$, comme sur n'importe quel autre échantillon de taille n

➤ l'écart-type de $F_n = \sqrt{p(1-p) / n}$
 $= \sqrt{0,75 \times 0,25 / 40}$
 $= 0,0685$

② la variabilité de l'estimation de la proportion de réussite p par la fréquence observée sur un échantillon de taille $n = 40$ est de $0,0685$ (6,85%)

3.4 Propriétés de la fréquence empirique (4)

- Exemple : résultats au DEUG en 1994

$\mathcal{P} = \{ \text{étudiants inscrits en 2d année de DEUG S.H. à Nanterre en 1994} \}$

$N = 617$

$X = \text{"réussite au DEUG"} : \text{oui, non}$
variable qualitative dichotomique
un paramètre **connu** dans \mathcal{P}

$p = \text{proportion de réussite} = \mathbf{0,75}$

échantillon de X issu de \mathcal{P} de taille
 $n = 100$

➤ la moyenne de $F_n = p = 0,75$

➤ l'écart-type de $F_n = \sqrt{p(1-p) / n}$
 $= \sqrt{0,75 \times 0,25 / 100}$
 $= 0,0433$

② la variabilité de l'estimation de la proportion de réussite p par la fréquence observée sur un échantillon de taille $n = 100$ est de $0,0433$ (4,33%)

inférieure à celle obtenue pour un échantillon de taille $n = 40$

3.5 Distribution d'échantillonnage de la fréquence empirique (1)

Variable qualitative dichotomique : théorème central-limite

- X variable *qualitative dichotomique* de proportion de "oui" p dans \mathcal{P}
 - si n est "suffisamment" grand $n \geq 30$
 - si les proportions p et $(1-p)$ ne sont pas "trop" proches de 0 ou de 1
 $np \geq 5$ et $n(1-p) \geq 5$

la fréquence empirique F_n *suit approximativement un modèle normal* de moyenne p et d'écart-type $\sqrt{p(1-p)/n}$

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

3.5 Distribution d'échantillonnage de la fréquence empirique (2)

Variable qualitative dichotomique : théorème central-limite

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

⇒ lorsque les valeurs de p et n sont **connues** on peut calculer approximativement à l'aide du modèle normal sur F_n

- la fonction de répartition $P(F_n \leq f)$ proportion d'échantillons de taille n de X issus de \mathcal{P} ayant une fréquence observée inférieure à f
- la loi de probabilité $P(c \leq F_n \leq d)$
- les quantiles
- les intervalles de variation

3.5 Distribution d'échantillonnage de la fréquence empirique (3)

Conditions de l'approximation normale

➤ les proportions p et $(1-p)$ ne sont pas "*trop*" proches de 0 ou de 1

$$np \geq 5 \text{ et } n(1-p) \geq 5$$

- **sur un échantillon de taille n**
 np : effectif moyen "*attendu*" de "*oui*"
 $n(1-p)$: effectif moyen "*attendu*" de "*non*"
- **plus la taille de l'échantillon est grande plus la proportion peut être "*proche*" de 0 ou de 1**

| proportion | | taille de l'échantillon n |
|---------------------|---------------------|--------------------------------|
| p | $1-p$ | |
| 0,5 | 0,5 | 30 |
| 0,25 | 0,75 | 30 |
| $1/6 \approx 0,167$ | $5/6 \approx 0,833$ | 30 |
| 0,15 | 0,85 | 34 |
| 0,1 | 0,9 | 50 |
| 0,05 | 0,95 | 100 |
| 0,01 | 0,99 | 500 |
| 0,001 | 0,999 | 5000 |

Exemple variable qualitative (1)

- Exemple : résultats au DEUG en 1994

$\mathcal{P} = \{ \text{étudiants inscrits en 2d année de DEUG S.H. à Nanterre en 1994} \}$

$X = \text{"réussite au DEUG"} : \text{oui, non}$
variable qualitative dichotomique
un paramètre **connu** dans \mathcal{P}

$p = \text{proportion de réussite} = \mathbf{0,75}$


échantillon de X issu de \mathcal{P} de taille

$n = 40$ ($n \geq 30$)

$np = 30 \geq 5$ et $n(1-p) = 10 \geq 5$

alors la fréquence empirique F_n suit
approximativement une loi normale

$$F_n \underset{\text{approx}}{\sim} \mathcal{N}(0,75; 0,0685)$$



Exemple variable qualitative (2)

- **Exemple : résultats au DEUG en 1994**

$\mathcal{P} = \{ \text{étudiants inscrits en 2d année de DEUG S.H. à Nanterre en 1994} \}$

$X = \text{"réussite au DEUG"} : \text{oui, non}$
variable qualitative dichotomique
un paramètre **connu** dans \mathcal{P}

$p = \text{proportion de réussite} = \mathbf{0,75}$

échantillon de X issu de \mathcal{P} de taille

$$n = 40 \quad F_n \underset{\text{approx}}{\sim} \mathcal{N}(0,75; 0,0685)$$

➤ $P(F_n > 0,88) = 0,0287$

➔ **2,87%** des échantillons de taille $n = 40$ ont une fréquence de réussite supérieure à 88%

③ on serait surpris d'observer une fréquence de réussite supérieure à 88% sur un échantillon de taille $n = 40$

Exemple variable qualitative (3)

- Exemple : résultats au DEUG en 1994

$\mathcal{P} = \{ \text{étudiants inscrits en 2d année de DEUG S.H. à Nanterre en 1994} \}$

$X = \text{"réussite au DEUG"} : \text{oui, non}$
variable qualitative dichotomique

échantillon de X issu de \mathcal{P} de taille

$n = 30$

$$np = 22,5 \geq 5 \text{ et } n(1-p) = 7,5 \geq 5$$

$$F_n \underset{\text{approx}}{\sim} \mathcal{N}(0,75; 0,0791)$$


➤ $P(F_n > 0,88) = 0,0505$

$n = 100$

$$np = 75 \geq 5 \text{ et } n(1-p) = 25 \geq 5$$

$$F_n \underset{\text{approx}}{\sim} \mathcal{N}(0,75; 0,0433)$$

➤ $P(F_n > 0,88) = 0,00135$



3.6 Quantiles de la fréquence empirique (1)

X variable qualitative dichotomique de \mathcal{P} dans $E = \{ \text{oui, non} \}$

\Rightarrow un paramètre *connu* dans \mathcal{P}

proportion de "oui" = p

échantillon de X issu de \mathcal{P} de taille n

➤ rechercher la limite à partir de laquelle la fréquence observée sur l'échantillon de taille n , estimation de la proportion p , peut être considérée comme "surprenante" :

- soit "étonnamment" faible :
 $\alpha\%$ des fréquences les plus faibles
- soit "étonnamment" élevée :
 $\alpha\%$ des fréquences les plus élevées

\Rightarrow ces limites sont définies à partir des *quantiles* de la fréquence empirique F_n

\Rightarrow elles sont calculées en utilisant le fait que la fréquence empirique F_n suit approximativement une loi normale

3.6 Quantiles de la fréquence empirique (2)

X variable qualitative dichotomique de \mathcal{P}
dans $E = \{ \text{oui, non} \}$

de proportion de "oui" = p dans \mathcal{P}

échantillon de X issu de \mathcal{P} de taille $n \geq 30$

avec $np \geq 5$ et $n(1-p) \geq 5$

- la fréquence empirique F_n suit approximativement un modèle normal de moyenne p et d'écart-type $\sqrt{p(1-p)/n}$

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

⇒ le quantile d'ordre α de F_n s'écrit :

$$p + z_\alpha \sqrt{\frac{p(1-p)}{n}}$$

où z_α quantile d'ordre α de $Z \sim \mathcal{N}(0,1)$

⇒ le quantile d'ordre α de F_n avec $\alpha < 0,5$ s'écrit :

$$p - z_{1-\alpha} \sqrt{\frac{p(1-p)}{n}}$$

où $z_{1-\alpha}$ quantile d'ordre $1-\alpha$ de $Z \sim \mathcal{N}(0,1)$

Exemple variable qualitative (1)

- Exemple : résultats au DEUG en 1994

$\mathcal{P} = \{ \text{étudiants inscrits en 2d année de DEUG S.H. à Nanterre en 1994} \}$

$X = \text{"réussite au DEUG"} : \text{oui, non}$
variable qualitative dichotomique
un paramètre **connu** dans \mathcal{P}

$p = \text{proportion de réussite} = \mathbf{0,75}$

échantillon de X issu de \mathcal{P} de taille
 $n = 40$ ($n \geq 30$)

$np = 30 \geq 5$ et $n(1-p) = 10 \geq 5$

alors la fréquence empirique F_n suit
approximativement une loi normale

$$F_n \underset{\text{approx}}{\sim} \mathcal{N}(0,75; 0,0685)$$

➤ quantile d'ordre 95% de la **fréquence**

$$0,75 + z_{0,95} \times 0,0685 =$$

$$0,75 + 1,645 \times 0,0685 =$$

$$0,75 + 0,113 = 0,863$$

➔ 95% **des échantillons** de X issus de
 \mathcal{P} de taille $n = 40$ ont une fréquence
de réussite inférieure à **86,3%**

④ une **fréquence** de réussite supérieure
à **86,3%** observée sur un échantillon
de taille $n = 40$ sera considéré comme
"étonnamment" élevé

Exemple variable qualitative (2)

- Exemple : résultats au DEUG en 1994

échantillon de X issu de \mathcal{P} de taille

$$n = 40 \quad (n \geq 30)$$

$$np = 30 \geq 5 \text{ et } n(1-p) = 10 \geq 5$$

alors la fréquence empirique F_n suit approximativement une loi normale

$$F_n \underset{\text{approx}}{\sim} \mathcal{N}(0,75; 0,0685)$$


➤ quantile d'ordre 5% de la fréquence

$$0,75 - z_{0,95} \times 0,0685 =$$

$$0,75 - 0,113 = 0,637$$

➔ 5% des échantillons de X issus de \mathcal{P} de taille $n = 40$ ont une fréquence de réussite inférieure à 63,7%

④ une fréquence de réussite inférieure à 63,7% observée sur un échantillon de taille $n = 40$ sera considéré comme "étonnamment" faible



3.7 Intervalles de variation de la fréquence empirique (1)

X variable qualitative dichotomique de \mathcal{P} dans $E = \{ \text{oui, non} \}$

\Rightarrow un paramètre **connu** dans \mathcal{P}
proportion de "oui" = p

échantillon de **X** issu de \mathcal{P} de taille **n**

➤ rechercher un intervalle dans lequel on a une chance $(1-\alpha)$ de trouver l'estimation de la proportion **p** sur un échantillon de taille **n**

\Rightarrow cet intervalle est l'**intervalle de variation** (ou **intervalle de pari**, ou **intervalle de fluctuation**) de la fréquence empirique F_n à $(1-\alpha)$ ou au risque α noté **$I_{1-\alpha}(F_n)$**

3.7 Intervalles de variation de la fréquence empirique (2)

- Exemple : résultats au DEUG en 1994

$\mathcal{P} = \{ \text{étudiants inscrits en 2d année de DEUG S.H. à Nanterre en 1994} \}$

$X = \text{"réussite au DEUG"} : \text{oui, non}$
variable qualitative dichotomique
un paramètre **connu** dans \mathcal{P}

$p = \text{proportion de réussite} = \mathbf{0,75}$

échantillon de X issu de \mathcal{P} de taille
 $n = 40$

➤ la proportion de réussite p est estimée par la fréquence de réussite observée f

⑤ dans quel intervalle s'attend-on raisonnablement à trouver f la fréquence de réussite observée sur l'échantillon de taille $n = 40$?

➤ si "**raisonnablement**" veut dire "dans 90% des cas" on cherchera l'intervalle de variation à 90% (au risque 10%) de la fréquence empirique F_n

➤ si "**raisonnablement**" veut dire "dans 95% des cas" on cherchera l'intervalle de variation à 95% (au risque 5%) de la fréquence empirique F_n

3.7 Intervalles de variation de la fréquence empirique (3)

X variable qualitative dichotomique de \mathcal{P}
dans $E = \{ \text{oui, non} \}$
de proportion de "oui" = p dans \mathcal{P}

échantillon de X issu de \mathcal{P} de taille $n \geq 30$
avec $np \geq 5$ et $n(1-p) \geq 5$

➤ la fréquence empirique F_n suit
approximativement un modèle normal de
moyenne p et d'écart-type $\sqrt{p(1-p)/n}$

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

⇒ l'intervalle de variation à $(1-\alpha)$ ou au
risque α de F_n s'écrit :

$$I_{1-\alpha}(F_n) \approx \left[p \pm z_{1-\frac{\alpha}{2}} \sqrt{\frac{p(1-p)}{n}} \right]$$

où $z_{1-\frac{\alpha}{2}}$ quantile d'ordre $1 - \frac{\alpha}{2}$ de $Z \sim \mathcal{N}(0,1)$

Exemple variable qualitative (1)

- Exemple : résultats au DEUG en 1994

échantillon de X issu de \mathcal{P} de taille

$$n = 40 \quad (n \geq 30)$$

$$np = 30 \geq 5 \text{ et } n(1-p) = 10 \geq 5$$

alors la fréquence empirique F_n suit approximativement une loi normale

$$F_n \underset{\text{approx}}{\sim} \mathcal{N}(0,75; 0,0685)$$

- intervalle de variation à 90% (au risque 10%) de la fréquence de réussite :

$$\begin{aligned} I_{90\%}(F_n) &\approx \left[p \pm z_{0,95} \sqrt{\frac{p(1-p)}{n}} \right] \\ &\approx \left[0,75 \pm 1,645 \sqrt{\frac{0,75 \times 0,25}{40}} \right] \\ &\approx [0,75 \pm 0,113] = [0,637 ; 0,863] \end{aligned}$$

- ➔ 90% des échantillons de X issus de \mathcal{P} de taille $n = 40$ ont une fréquence de réussite comprise entre 63,7% et 86,3%

- ⑤ dans 90% des cas, sur un échantillon de taille $n = 40$ on s'attend à observer une fréquence de réussite comprise entre 63,7% et 86,3%

Exemple variable qualitative (2)

- **Exemple : résultats au DEUG en 1994**

échantillon de X issu de \mathcal{P} de taille

$$n = 40 \quad (n \geq 30)$$

$$np = 30 \geq 5 \text{ et } n(1-p) = 10 \geq 5$$

alors la fréquence empirique F_n suit approximativement une loi normale

$$F_n \underset{\text{approx}}{\sim} \mathcal{N}(0,75; 0,0685)$$

➤ *intervalle de variation à 95% (au risque 5%) de la fréquence de réussite :*

$$\begin{aligned} I_{95\%}(F_n) &\approx \left[p \pm z_{0,975} \sqrt{\frac{p(1-p)}{n}} \right] \\ &\approx \left[0,75 \pm 1,96 \sqrt{\frac{0,75 \times 0,25}{40}} \right] \\ &\approx [0,75 \pm 0,134] = [0,616 ; 0,884] \end{aligned}$$

➔ 95% des échantillons de X issus de \mathcal{P} de taille $n = 40$ ont une fréquence de réussite comprise entre 61,6% et 88,4%

⑤ dans 95% des cas, sur un échantillon de taille $n = 40$ on s'attend à observer une fréquence de réussite comprise entre 61,6% et 88,4%

Exemple variable qualitative (3)

- Exemple : résultats au DEUG en 1994

échantillon de X issu de \mathcal{P} de taille


$$n = 40$$

la fréquence empirique F_n suit
approximativement une loi normale

$$F_n \underset{\text{approx}}{\sim} \mathcal{N}(0,75; 0,0685)$$

➤ intervalle de variation à 90%
(au risque 10%) de la fréquence de
réussite : $I_{90\%}(F_n) \approx [0,637 ; 0,863]$

➤ intervalle de variation à 95%
(au risque 5%) de la fréquence de
réussite : $I_{95\%}(F_n) \approx [0,616 ; 0,884]$



Exemple variable qualitative (4)

- **Exemple : résultats au DEUG en 1994**

$\mathcal{P} = \{ \text{étudiants inscrits en 2d année de DEUG S.H. à Nanterre en 1994} \}$

$X = \text{"réussite au DEUG"} : \text{oui, non}$
variable qualitative dichotomique

échantillon de X issu de \mathcal{P} de taille

$n = 30$ $np = 22,5 \geq 5$ et $n(1-p) = 7,5 \geq 5$
 $F_n \underset{\text{approx}}{\sim} \mathcal{N}(0,75; 0,0791)$

➤ intervalle de variation à 95% (au risque 5%) de la fréquence de réussite :

$$I_{95\%}(F_n) \approx \left[0,75 \pm 1,96 \sqrt{\frac{0,75 \times 0,25}{30}} \right]$$
$$\approx [0,75 \pm 0,155] = [0,595 ; 0,905]$$

$n = 100$ $np = 75 \geq 5$ et $n(1-p) = 25 \geq 5$

$$F_n \underset{\text{approx}}{\sim} \mathcal{N}(0,75; 0,0433)$$

➤ intervalle de variation à 95% (au risque 5%) de la fréquence de réussite :

$$I_{95\%}(F_n) \approx \left[0,75 \pm 1,96 \sqrt{\frac{0,75 \times 0,25}{100}} \right]$$
$$\approx [0,75 \pm 0,085] = [0,665 ; 0,835]$$

Exemple variable qualitative (5)

- Exemple : résultats au DEUG en 1994

échantillon de X issu de \mathcal{P} de taille

$$n = 30 \quad F_n \underset{\text{approx}}{\sim} \mathcal{N}(0,75; 0,0791)$$


$$I_{95\%}(F_n) \approx [0,75 \pm 0,155] = [0,595 ; 0,905]$$

$$n = 40 \quad F_n \underset{\text{approx}}{\sim} \mathcal{N}(0,75; 0,0685)$$

$$I_{95\%}(F_n) \approx [0,75 \pm 0,134] = [0,616 ; 0,884]$$

$$n = 100 \quad F_n \underset{\text{approx}}{\sim} \mathcal{N}(0,75; 0,0433)$$

$$I_{95\%}(F_n) \approx [0,75 \pm 0,085] = [0,665 ; 0,835]$$



3.7 Intervalles de variation de la fréquence empirique (4)

Remarques

- tous les intervalles de variation de la fréquence empirique sont centrés sur la proportion p dans la population \mathcal{P}
- l'intervalle de variation dépend
 - de la valeur du paramètre p
 - du niveau $(1-\alpha)$ ou du risque α
 - de la taille de l'échantillon n
- l'intervalle de variation ne dépend pas
 - de la fréquence observée f
- l'intervalle de variation à $(1-\alpha)$ peut s'écrire :

$$I_{1-\alpha}(F_n) \approx \left[p \pm z_{1-\frac{\alpha}{2}} \sqrt{\frac{p(1-p)}{n}} \right] = [p \pm e]$$

e est la **demi-longueur** de l'intervalle
 $2e$ est l'amplitude ou longueur de l'intervalle

Interprétation d'un intervalle de variation (1)

- un intervalle de variation est *fixe* : ses bornes sont fixes, calculées une fois pour toute, pour tous les échantillons de taille n
- une fréquence observée f est *variable* : elle change pour chaque échantillon
- l'intervalle de variation au niveau $(1-\alpha)$ (au risque α) est déterminé pour que :
 - $(1-\alpha)\%$ des valeurs de F_n (des fréquences observées f) appartiennent à l'intervalleet
 - $\alpha\%$ des valeurs de F_n (des fréquences observées f) n'appartiennent pas à l'intervalle

Interprétation d'un intervalle de variation (2)

➤ l'intervalle de variation au niveau **95%** (au risque **5%**) est déterminé pour que :

- **95%** des valeurs de F_n (des fréquences observées f) appartiennent à l'intervalle

et

- **5%** des valeurs de F_n (des fréquences observées f) n'appartiennent pas à l'intervalle

➤ par construction, par exemple sur **100** échantillons de taille n de \mathbf{X} issus de \mathcal{P} , en moyenne :

- **95** échantillons auront une fréquence observée f qui appartiendra à l'intervalle de variation à **95%**

et

- **5** échantillons auront une fréquence observée f qui n'appartiendra pas à l'intervalle de variation à **95%**

Interprétation d'un intervalle de variation (3)

- **Exemple : résultats au DEUG en 1994**

$\mathcal{P} = \{ \text{étudiants inscrits en 2d année de DEUG S.H. à Nanterre en 1994} \}$

$X = \text{"réussite au DEUG"} : \text{oui, non}$
variable qualitative dichotomique
un paramètre **connu** dans \mathcal{P} :

$p = \text{proportion de réussite} = \mathbf{0,75}$

échantillon de X issu de \mathcal{P} de taille
 $n = 40$: on observe $f = 88\%$

$I_{95\%}(F_n) \approx [0,75 \pm 0,134] = [0,616 ; 0,884]$

donc f appartient à l'intervalle de variation à 95%

① échantillon d'étudiants tiré au sort dans \mathcal{P} : on a observé un parmi les 95% des échantillons qui ont une fréquence de réussite observée dans l'intervalle de variation à 95%

② échantillon d'étudiants non tiré au sort dans \mathcal{P} : on ne peut pas mettre en doute le fait qu'il est représentatif des étudiants de 2d année de DEUG S.H. à Nanterre en 1994 pour la réussite au DEUG

Interprétation d'un intervalle de variation (4)

- Exemple : résultats au DEUG en 1994

$\mathcal{P} = \{ \text{étudiants inscrits en 2d année de DEUG S.H. à Nanterre en 1994} \}$

$X = \text{"réussite au DEUG"} : \text{oui, non}$
variable qualitative dichotomique

$p = \text{proportion de réussite} = \mathbf{0,75}$

échantillon de X issu de \mathcal{P} de taille $n = 40$: on observe $f = 60\%$

$$I_{95\%}(F_n) \approx [0,75 \pm 0,134] = [0,616 ; 0,884]$$

donc f n'appartient pas à l'intervalle de variation à 95%

- ① échantillon d'étudiants tiré au sort dans \mathcal{P} : on a observé un parmi les 5% des échantillons pour lesquels f est en dehors de $I_{95\%}(F_n)$
- ② étudiants d'un groupe de TD (non tiré au sort dans \mathcal{P}) : a priori non représentatif et les observations le confirment
- ③ échantillon d'étudiants tiré au sort en 2005 : $\mathcal{P} = \{ \text{étudiants en 2005} \}$
la proportion de réussite au DEUG n'est plus la même

3.8 Précision dans l'estimation de la proportion

La demi-longueur e de l'intervalle de variation à $(1-\alpha)$ représente la **précision** à $(1-\alpha)$ dans l'estimation de la proportion p sur un échantillon de taille n , ou la **marge d'erreur** d'échantillonnage au risque α

$$e = z_{1-\frac{\alpha}{2}} \sqrt{\frac{p(1-p)}{n}}$$

où $z_{1-\frac{\alpha}{2}}$ quantile d'ordre $1 - \frac{\alpha}{2}$ de $Z \sim \mathcal{N}(0,1)$

- la précision e dépend de p
- pour n fixé, la précision e ne change pas lorsque l'échantillon change
- pour n fixé, plus le niveau $(1-\alpha)$ augmente (le risque α diminue) plus la marge d'erreur augmente ou la précision diminue
- plus la taille de l'échantillon n augmente, plus la marge d'erreur diminue ou la précision augmente

Exemple variable qualitative (1)

- Exemple : résultats au DEUG en 1994

$\mathcal{P} = \{ \text{étudiants inscrits en 2d année de DEUG S.H. à Nanterre en 1994} \}$

$X = \text{"réussite au DEUG"} : \text{oui, non}$
variable qualitative dichotomique
un paramètre **connu** dans \mathcal{P}

$p = \text{proportion de réussite} = \mathbf{0,75}$

échantillon de X issu de \mathcal{P} de taille

$n = 40$ ($n \geq 30$)

$np = 30 \geq 5$ et $n(1-p) = 10 \geq 5$

alors la fréquence empirique F_n suit
approximativement une loi normale

$F_n \underset{\text{approx}}{\sim} \mathcal{N}(0,75; 0,0685)$

➤ intervalle de variation à 90%
(au risque 10%) de la **fréquence** de
réussite :

$$I_{90\%}(F_n) \approx \left[0,75 \pm 1,645 \sqrt{\frac{0,75 \times 0,25}{40}} \right]$$
$$\approx [0,75 \pm 0,113]$$

➔ la marge d'erreur à 90% dans
l'estimation de la proportion de
réussite sur **les échantillons** de taille
 $n = 40$ est de **11,3%**

Exemple variable qualitative (2)

- **Exemple : résultats au DEUG en 1994**

échantillon de X issu de \mathcal{P} de taille

$$n = 40 \quad (n \geq 30)$$

$$np = 30 \geq 5 \text{ et } n(1-p) = 10 \geq 5$$

alors la fréquence empirique F_n suit approximativement une loi normale

$$F_n \underset{\text{approx}}{\sim} \mathcal{N}(0,75; 0,0685)$$

➤ *intervalle de variation à 95% (au risque 5%) de la fréquence de réussite :*

$$\begin{aligned} I_{95\%}(F_n) &\approx \left[0,75 \pm 1,96 \sqrt{\frac{0,75 \times 0,25}{40}} \right] \\ &\approx [0,75 \pm 0,134] \end{aligned}$$

➔ *la marge d'erreur à 95% dans l'estimation de la proportion de réussite sur les échantillons de X issus de \mathcal{P} de taille $n = 40$ est de 13,4%*

Exemple variable qualitative (3)

- **Exemple : résultats au DEUG en 1994**

$\mathcal{P} = \{ \text{étudiants inscrits en 2d année de DEUG S.H. à Nanterre en 1994} \}$

$X = \text{"réussite au DEUG"} : \text{oui, non}$
variable qualitative dichotomique

échantillon de X issu de \mathcal{P} de taille

$$n = 30 \quad (n \geq 30)$$

$$np = 22,5 \geq 5 \text{ et } n(1-p) = 7,5 \geq 5$$

alors la fréquence empirique F_n suit approximativement une loi normale

$$F_n \underset{\text{approx}}{\sim} \mathcal{N}(0,75; 0,0791)$$

➤ intervalle de variation à 95% (au risque 5%) de la fréquence de réussite :

$$\begin{aligned} I_{95\%}(F_n) &\approx \left[0,75 \pm 1,96 \sqrt{\frac{0,75 \times 0,25}{30}} \right] \\ &\approx [0,75 \pm 0,155] = [0,595 ; 0,905] \end{aligned}$$

➔ la marge d'erreur à 95% dans l'estimation de la proportion de réussite sur les échantillons de X issus de \mathcal{P} de taille $n = 30$ est de 15,5%

Exemple variable qualitative (4)

- **Exemple : résultats au DEUG en 1994**

$\mathcal{P} = \{ \text{étudiants inscrits en 2d année de DEUG S.H. à Nanterre en 1994} \}$

$X = \text{"réussite au DEUG"} : \text{oui, non}$
variable qualitative dichotomique

échantillon de X issu de \mathcal{P} de taille

$$n = 100 \quad (n \geq 30)$$

$$np = 75 \geq 5 \text{ et } n(1-p) = 25 \geq 5$$

alors la fréquence empirique F_n suit approximativement une loi normale

$$F_n \underset{\text{approx}}{\sim} \mathcal{N}(0,75; 0,0433)$$

➤ intervalle de variation à 95% (au risque 5%) de la fréquence de réussite :

$$\begin{aligned} I_{95\%}(F_n) &\approx \left[0,75 \pm 1,96 \sqrt{\frac{0,75 \times 0,25}{100}} \right] \\ &\approx [0,75 \pm 0,085] = [0,665 ; 0,835] \end{aligned}$$

➔ la marge d'erreur à 95% dans l'estimation de la proportion de réussite sur les échantillons de X issus de \mathcal{P} de taille $n = 100$ est de 8,5%

Exemple variable qualitative (5)

- Exemple : résultats au DEUG en 1994

échantillon de X issu de \mathcal{P} de taille

$n = 30$

$$I_{95\%}(F_n) \approx [0,75 \pm 0,155] = [0,595 ; 0,905]$$

➤ la marge d'erreur à 95% est de 15,5%

$n = 40$


$$I_{95\%}(F_n) \approx [0,75 \pm 0,134] = [0,616 ; 0,884]$$

➤ la marge d'erreur à 95% de 13,4%

$n = 100$

$$I_{95\%}(F_n) \approx [0,75 \pm 0,085] = [0,665 ; 0,835]$$

➤ la marge d'erreur à 95% de 8,5%



3.9 Taille minimum de l'échantillon pour une précision minimum (1)

- Pour avoir une marge d'erreur à $(1-\alpha)$ inférieure à e sur l'estimation de la proportion p par la fréquence empirique :

$$z_{1-\frac{\alpha}{2}} \sqrt{\frac{p(1-p)}{n}} \leq e$$

la longueur (amplitude) de l'intervalle de variation au niveau $(1-\alpha)$ ou au risque α n'excède pas $2e$

⇒ la taille de l'échantillon n vérifie :

$$n \geq p(1-p) \left(\frac{z_{1-\frac{\alpha}{2}}}{e} \right)^2$$

- ➔ pour obtenir une marge d'erreur d'au plus e (ou une précision d'au moins e) il faut une taille d'échantillon d'au moins n

3.9 Taille minimum de l'échantillon pour une précision minimum (2)

Remarques

- la taille minimum n dépend de
 - la proportion p de la variable X
 - la marge d'erreur maximum e
 - le niveau $(1-\alpha)$ ou risque α

- la taille minimum n augmente lorsque
 - le produit $p(1-p)$ augmente
 - le niveau $(1-\alpha)$ augmente
le risque α diminue
 - la marge d'erreur maximum e diminue
la précision minimum e augmente

- vérifier que pour la taille n obtenue
 $n \geq 30$ $np \geq 5$ $n(1-p) \geq 5$

Exemple variable qualitative (1)

- **Exemple : résultats au DEUG en 1994**

$\mathcal{P} = \{ \text{étudiants inscrits en 2d année de DEUG S.H. à Nanterre en 1994} \}$

$X = \text{"réussite au DEUG"} : \text{oui, non}$
variable qualitative dichotomique

$p = \text{proportion de réussite} = \mathbf{0,75}$

échantillon de X issu de \mathcal{P} de taille n

si $n \geq 30$ $np = \mathbf{0,75} \times n \geq 5$

et $n(1-p) = \mathbf{0,25} \times n \geq 5$

alors $F_n \underset{\text{approx}}{\sim} \mathcal{N} \left(0,75; \sqrt{\frac{0,75 \times 0,25}{n}} \right)$

Exemple variable qualitative (2)

- Exemple : résultats au DEUG en 1994

➤ pour $n = 40$ l'intervalle de variation à 90% (au risque 10%) de la fréquence de réussite :

$$I_{90\%}(F_n) \approx [0,75 \pm 0,113]$$

➔ la marge d'erreur à 90% dans l'estimation de la proportion de réussite sur les échantillons de taille $n = 40$ est de 11,3%

➤ marge d'erreur à 90% d'au plus 10%

$$I_{90\%}(F_n) \approx \left[0,75 \pm 1,645 \sqrt{\frac{0,75 \times 0,25}{n}} \right]$$
$$\approx [0,75 \pm 0,1]$$

$$1,645 \sqrt{\frac{0,75 \times 0,25}{n}} \leq 0,1$$

$$n \geq 0,75 \times 0,25 \left(\frac{1,645}{0,1} \right)^2 = 50,74$$

$$n = 51 \geq 30$$

$$np = 0,75 \times 51 = 38,25 \geq 5$$

$$n(1-p) = 0,25 \times 51 = 12,75 \geq 5$$

➔ pour que la marge d'erreur à 90% dans l'estimation de la proportion de réussite n'excède pas 10% il faudra un échantillon d'au moins 51 étudiants

Exemple variable qualitative (3)

- Exemple : résultats au DEUG en 1994

➤ pour $n = 40$ l'intervalle de variation à 95% (au risque 5%) de la fréquence de réussite : $I_{95\%}(F_n) \approx [0,75 \pm 0,134]$

➔ la marge d'erreur à 95% dans l'estimation de la proportion de réussite sur les échantillons de taille $n = 40$ est de 13,4%

➤ marge d'erreur à 95% d'au plus 10%

$$I_{95\%}(F_n) \approx \left[0,75 \pm 1,96 \sqrt{\frac{0,75 \times 0,25}{n}} \right]$$
$$\approx [0,75 \pm 0,1]$$

$$n \geq 0,75 \times 0,25 \left(\frac{1,96}{0,1} \right)^2 = 72,03$$

$$n = 73 \geq 30$$

$$np = 0,75 \times 73 = 54,75 \geq 5$$

$$n(1-p) = 0,25 \times 73 = 18,25 \geq 5$$

➔ pour que la marge d'erreur à 95% dans l'estimation de la proportion de réussite n'excède pas 10% il faudra un échantillon d'au moins 73 étudiants

Exemple variable qualitative (4)

- Exemple : résultats au DEUG en 1994

➤ *marge d'erreur à 95% d'au plus 1%*

$$I_{95\%}(F_n) \approx \left[0,75 \pm 1,96 \sqrt{\frac{0,75 \times 0,25}{n}} \right]$$
$$\approx [0,75 \pm 0,01]$$

$$n \geq 0,75 \times 0,25 \left(\frac{1,96}{0,01} \right)^2 = 7203$$

➔ *pour que la marge d'erreur à 95% dans l'estimation de la proportion de réussite n'excède pas 1% il faudra un échantillon d'au moins 7203 étudiants*

