

ESTIMATION.

Estimation ponctuelle

Exercice 1.

On a vu que la variance empirique est un estimateur biaisé de la variance.
Soit X une variable aléatoire d'espérance m et de variance σ^2 . On pose :

$$\bar{X}_n = \frac{1}{n} \sum_{k=1}^n X_k \quad S_n = \frac{1}{n} \sum_{k=1}^n (X_k - m)^2 \quad T_n = \frac{1}{n-1} \sum_{k=1}^n (X_k - \bar{X}_n)^2$$

1. Montrer que S_n est un estimateur sans biais de σ^2 . Quel est son inconvénient ?
2. Montrer que T_n est un estimateur sans biais de σ^2 . (on s'inspirera fortement du calcul vu dans le cours "premier estimateur de la variance"¹)

RÉPONSE:

1. Outils utilisés :

- (a) définition de "sans biais"
- (b) linéarité de l'espérance , formule $V(\alpha Y + \beta) = \alpha^2 V(Y)$
- (c) , König–Huygens "à l'envers" $E(Y^2) = V(Y) + (E(Y))^2$

1. on pourrait même ne pas refaire tous ces calculs

Soit $n \in \mathbb{N}^*$

$$\begin{aligned}
 E(S_n) &= E\left(\frac{1}{n} \sum_{k=1}^n (X_k - m)^2\right) \\
 &= \frac{1}{n} \sum_{k=1}^n E((X_k - m)^2) && \text{linéarité de l'espérance} \\
 &= \frac{1}{n} \sum_{k=1}^n [E(X_k - m)^2 + V(X_k - m)] && \text{K-H "à l'envers"} \\
 &= \frac{1}{n} \sum_{k=1}^n [E(X_k - m)^2 + V(X_k - m)] && \text{linéarité de l'espérance} \\
 &= \frac{1}{n} \sum_{k=1}^n [(m - m)^2 + V(X_k)] && \text{formule } V(\alpha Y + \beta) = \alpha^2 V(Y) \\
 &= \frac{1}{n} \sum_{k=1}^n [\sigma^2] \\
 &= \sigma^2
 \end{aligned}$$

Comme on cherche à estimer σ^2 , le biais qui est la différence entre ce que l'on mesure et ce que l'on veut estimer vaut :

$$b(S_n) = E(S_n) - \sigma^2 = 0$$

l'estimateur S_n est donc non biaisé.

Son inconvénient il faut connaître la valeur exacte de l'espérance pour pouvoir le calculer, or il est courant que l'on cherche à déterminer et la variance et l'espérance d'un échantillon.

2.

Remarque : Ce calcul est presque identique à celui vu pour "premier estimateur de la variance". On a besoin de calculs préalables

$$\begin{aligned}
 E(\overline{X}_n) &= E\left(\frac{1}{n-1} \sum_{k=1}^n X_k\right) \\
 &= \frac{1}{n-1} \sum_{k=1}^n E(X_k) && \text{linéarité de l'espérance} \\
 &= \frac{n}{n-1} m
 \end{aligned}$$

et, d'une autre écriture de T_n

$$\begin{aligned}
 T_n &= \frac{1}{n-1} \sum_{k=1}^n (X_k - \bar{X}_n)^2 \\
 &= \frac{1}{n-1} \sum_{k=1}^n (X_k^2 + \bar{X}_n^2 - 2X_k \bar{X}_n) \\
 &= \frac{1}{n-1} \left(\sum_{k=1}^n X_k^2 + \sum_{k=1}^n \bar{X}_n^2 - 2 \sum_{k=1}^n X_k \bar{X}_n \right) \\
 &= \frac{1}{n-1} \left(\sum_{k=1}^n X_k^2 + n\bar{X}_n^2 - 2\bar{X}_n \sum_{k=1}^n X_k \right) && \text{constantes par rapport à l'indice } k \\
 &= \frac{1}{n-1} \left(\sum_{k=1}^n X_k^2 + n\bar{X}_n^2 - 2n\bar{X}_n \bar{X}_n \right) && \text{définition de } \bar{X}_n \\
 &= \frac{1}{n-1} \left(\sum_{k=1}^n X_k^2 - n\bar{X}_n^2 \right) \\
 &= \frac{1}{n-1} \left(\sum_{k=1}^n X_k^2 \right) - \frac{n}{n-1} \bar{X}_n^2
 \end{aligned}$$

En utilisant la formule de König-Huygens "à l'envers" sur \bar{X}_n

$$E(\bar{X}_n^2) = V(\bar{X}_n) + E(\bar{X}_n)^2 = \frac{\sigma^2}{n} + m^2$$

On a de même

$$E(X_k^2) = V(X_k) + E(X_k)^2 = \sigma^2 + m^2$$

On peut donc calculer l'espérance de T_n

$$\begin{aligned}
 E(T_n) &= E \left(\frac{1}{n-1} \sum_{k=1}^n X_k^2 - \frac{n}{n-1} \bar{X}_n^2 \right) \\
 &= \frac{1}{n-1} \sum_{k=1}^n E(X_k^2) - \frac{n}{n-1} E(\bar{X}_n^2) && \text{linéarité} \\
 &= \frac{1}{n-1} \sum_{k=1}^n (\sigma^2 + m^2) - \frac{n}{n-1} \left(\frac{\sigma^2}{n} + m^2 \right) \\
 &= \frac{n}{n-1} (\sigma^2 + m^2) - \frac{n}{n-1} \left(\frac{\sigma^2}{n} + m^2 \right) \\
 &= \frac{n-1}{n-1} \sigma^2 \\
 &= \sigma^2
 \end{aligned}$$

L'espérance de l'estimateur est égale à ce que l'on veut estimer, l'estimateur T_n est sans biais.

Remarque : L'inconvénient précédent a disparu, le calcul de T_n ne dépend que de l'échantillon et non plus de la connaissance préalable de m

*

Exercice 2.

D'après Romain Boillaud On dispose de $n > 2$ observations indépendantes X_1, X_2, \dots, X_n de même loi de Poisson de paramètre $\lambda > 0$ inconnu. On souhaite estimer le paramètre $\theta = e^{-\lambda}$.

Pour tout $k \in \mathbb{N}^*$, on pose

$$Y_k = \begin{cases} 1 & \text{si } X_k = 0 \\ 0 & \text{sinon} \end{cases}$$

On introduit également :

$$\bar{Y}_n = \frac{1}{n} \sum_{k=1}^n Y_k \quad S_n = \sum_{k=1}^n X_k$$

1. (a) Montrer que Y_k suit une loi de Bernoulli de paramètre $e^{-\lambda}$.
 (b) Calculer $E(Y_k)$ puis $E(\bar{Y}_n)$. En déduire que \bar{Y}_n est un estimateur sans biais de θ .
 (c) Calculer la variance de \bar{Y}_n et en déduire que cet estimateur est convergent.
2. Expliquer pourquoi S_n suit une loi de Poisson et trouver son paramètre
3. On pose pour $i \in \mathbb{N}$

$$\varphi(i) = \mathbb{P}_{S_n=i}(X_1 = 0)$$

Montrer que pour $i \in \mathbb{N}$

$$\varphi(i) = \left(\frac{n-1}{n}\right)^i$$

4. On pose $T_n = \varphi(S_n)$
 - (a) À l'aide du théorème de transfert, montrer que $E(T_n) = e^{-\lambda}$.
 - (b) Montrer que T_n est un estimateur sans biais de θ .
 - (c) Montrer $V(T_n) = e^{-2\lambda} (e^{\lambda/n} - 1)$ et en déduire que T_n est un estimateur convergent.
5. Comparer les risques quadratiques de T_n et \bar{Y}_n .

RÉPONSE:

1. (a) Une variable aléatoire qui ne prend que deux valeurs 0 et 1 est une variable de Bernoulli, pour connaître son paramètre il faut calculer $P(Y_k = 1) = P(X_k = 0) = \frac{\lambda^0}{0!} e^{-\lambda} = e^{-\lambda}$

$$Y_n \leftrightarrow \mathcal{B}(e^{-\lambda})$$

(b) D'après le cours

$$E(Y_n) = e^{-\lambda}$$

Calcul classique

$$\begin{aligned} E(\bar{Y}_n) &= E\left(\frac{1}{n} \sum_{k=1}^n Y_k\right) \\ &= \frac{1}{n} \sum_{k=1}^n E(Y_k) && \text{linéarité de l'espérance} \\ &= \frac{1}{n} \sum_{k=1}^n e^{-\lambda} \\ &= \frac{n}{n} e^{-\lambda} \\ &= e^{-\lambda} \end{aligned}$$

$$E(\bar{Y}_n) = \theta$$

L'espérance de l'estimateur est égale à ce que l'on veut estimer, c'est la définition de "sans biais"

(c) outils et techniques pour le calcul de la variance

- propriétés de la loi de Bernoulli
- $V(X + Y) = V(X) + V(Y)$ **en cas d'indépendance**
- $V(\alpha X + \beta) = \alpha^2 V(X)$

On a

$$\begin{aligned} V(\bar{Y}_n) &= V\left(\frac{1}{n} \sum_{k=1}^n Y_k\right) \\ &= \frac{1}{n^2} V\left(\sum_{k=1}^n Y_k\right) && \text{formule } V(\alpha X + \beta) = \alpha^2 V(X) \\ &= \frac{1}{n^2} \sum_{k=1}^n V(Y_k) && \text{les } (Y_k) \text{ sont indépendants} \\ &= \frac{1}{n^2} \sum_{k=1}^n e^{-\lambda} (1 - e^{-\lambda}) && \text{loi de Bernoulli} \\ &= \frac{1}{n^2} e^{-\lambda} (1 - e^{-\lambda}) \sum_{k=1}^n 1 && \text{constante / k} \\ &= \frac{e^{-\lambda} (1 - e^{-\lambda})}{n} \end{aligned}$$

outils pour "estimateur convergent"

- i. Techniques proches de celles vue en cours
- ii. Décomposition du risque quadratique en biais variance.

iii. Caractérisation d'un estimateur convergent avec la limite du risque quadratique

D'après le cours

$$r(\overline{T}_n) = b(\overline{Y}_n)^2 + V(\overline{Y}_n) = 0^2 + V(\overline{Y}_n) = \frac{e^{-\lambda}(1 - e^{-\lambda})}{n}$$

Or

$$\lim_{n \rightarrow +\infty} \frac{e^{-\lambda}(1 - e^{-\lambda})}{n} = 0$$

Donc

$$\lim_{n \rightarrow +\infty} r(\overline{Y}_n) = 0$$

Donc l'estimateur \overline{Y}_n est convergent

2. On sait que la somme de variables aléatoires suivant des lois de Poisson indépendantes suit une loi de Poisson, plus précisément

$$S_n \hookrightarrow \mathcal{P}(n\lambda)$$

3. Soit $i \in \mathbb{N}$

$$\begin{aligned} \varphi(i) &= \mathbb{P}_{S_n=i}(X_1 = 0) \\ &= \frac{\mathbb{P}([S_n = i] \cap [X_1 = 0])}{\mathbb{P}(S_n = i)} && \text{définition d'une proba conditionnelle} \\ &= \frac{\mathbb{P}([S_{n-1} = i] \cap [X_1 = 0])}{\mathbb{P}(S_n = i)} \\ &= \frac{\mathbb{P}(S_{n-1} = i)\mathbb{P}(X_1 = 0)}{\mathbb{P}(S_n = i)} && \text{indépendance par lemme des coalitions} \\ &= \frac{\frac{((n-1)\lambda)^i}{i!} e^{-\lambda(n-1)} \mathbb{P}(X_1 = 0)}{\mathbb{P}(S_n = i)} && \text{car } S_{n-1} \hookrightarrow \mathcal{P}((n-1)\lambda) \\ &= \frac{\frac{((n-1)\lambda)^i}{i!} e^{-\lambda(n-1)} \mathbb{P}(X_1 = 0)}{\frac{(n\lambda)^i}{i!} e^{-n\lambda}} && \text{car } S_n \hookrightarrow \mathcal{P}(n\lambda) \\ &= \frac{\frac{((n-1)\lambda)^i}{i!} e^{-\lambda(n-1)} e^{-\lambda}}{\frac{(n\lambda)^i}{i!} e^{-n\lambda}} && \text{car } X_1 \hookrightarrow \mathcal{P}(\lambda) \\ &= \frac{(n-1)^i e^{-n\lambda}}{n^i e^{-n\lambda}} \\ &= \left(\frac{n-1}{n}\right)^i \end{aligned}$$

4. On pose $T_n = \varphi(S_n)$

- (a) Le théorème de transfert, et comme les sommes sont finies donc absolument convergentes

$$\begin{aligned}
 E(T_n) &= E(\varphi(S_n)) \\
 &= \sum_{i=0}^{+\infty} \varphi(i) \mathbb{P}(S_n = i) \\
 &= \sum_{i=0}^n \mathbb{P}_{S_n=i}(X_1 = 0) \mathbb{P}(S_n = i) \\
 &= \mathbb{P}(X_1 = 0) \\
 &= e^{-\lambda} \frac{\lambda^0}{0!} \\
 &= e^{-\lambda}
 \end{aligned}$$

définition

la CVA est assurée par probabilités totales avec le SCE ($[S_n = i]_i$)

car $X_1 \leftrightarrow$

- (b) On vient de montrer que l'espérance de l'estimateur T_n est égale à $e^{-\lambda} = \theta$ qui est le paramètre que l'on veut estimer.

T_n est un estimateur sans biais de θ .

Sous réserve de convergence (la convergence absolue se confond avec la convergence car les séries sont à termes positifs)

$$\begin{aligned}
E(T_n^2) &= E((\varphi(S_n))^2) \\
&= \sum_{i=0}^{+\infty} \varphi(i)^2 \mathbb{P}(S_n = i) && \text{théorème de transfert} \\
&= \sum_{i=0}^{+\infty} \varphi(i)^2 \mathbb{P}(S_n = i) && \text{théorème de transfert} \\
&= \sum_{i=0}^{+\infty} \left(\left(\frac{n-1}{n} \right)^i \right)^2 \mathbb{P}(S_n = i) && \text{question précédente} \\
&= \sum_{i=0}^{+\infty} \left(\left(\frac{n-1}{n} \right)^i \right)^2 e^{-n\lambda} \frac{(n\lambda)^i}{i!} && \text{loi de } S_n \\
&= \sum_{i=0}^{+\infty} \left(\left(\frac{n-1}{n} \right)^2 \right)^i e^{-n\lambda} \frac{(n\lambda)^i}{i!} \\
&= e^{-n\lambda} \sum_{i=0}^{+\infty} \frac{\left(\left(\frac{n-1}{n} \right)^2 (n\lambda) \right)^i}{i!} \\
&= \exp(-n\lambda) \cdot \exp\left(\left(\frac{n-1}{n} \right)^2 (n\lambda) \right) && \text{série exponentielle qui assure la convergence} \\
&= \exp(-n\lambda) \cdot \exp\left(\left(\frac{n-1}{n} \right)^2 (n\lambda) \right) \\
&= e^{\frac{\lambda}{n} - 2\lambda} && \text{calculs}
\end{aligned}$$

La formule de König–Huygens assure l'existence d'une variance et

$$\begin{aligned}
V(T_n) &= E(T_n^2) - E(T_n)^2 \\
&= e^{\frac{\lambda}{n} - 2\lambda} - (e^{-\lambda})^2 \\
&= e^{\frac{\lambda}{n} - 2\lambda} - (e^{-2\lambda}) \\
&= e^{\frac{\lambda}{n} - 2\lambda} - e^{-2\lambda} \\
&= e^{-2\lambda} \left(e^{\frac{\lambda}{n}} - 1 \right) \\
V(T_n) &= e^{-2\lambda} \left(e^{\frac{\lambda}{n}} - 1 \right)
\end{aligned}$$

D'après la décomposition risque quadratique en Biais/variance

$$r(T_n) = (b(T_n))^2 + V(T_n) = 0^2 + e^{-2\lambda} \left(e^{\frac{\lambda}{n}} - 1 \right)$$

Or, à $\lambda > 0$ fixé

$$\lim_{n \rightarrow +\infty} \frac{\lambda}{n} = 0$$

par continuité de l'exponentielle

$$\lim_{n \rightarrow +\infty} \exp\left(\frac{\lambda}{n}\right) = e^0 = 1$$

et donc

$$\lim_{n \rightarrow +\infty} r(T_n) = 0$$

D'après le résultat du cours

(c) $(T_n)_{n \in \mathbb{N}^*}$ est un estimateur convergent de $\theta = e^{-\lambda}$

5. On étudie $R(T_n) - R(\bar{Y}_n)$ (longue étude des variations d'une fonction ...) et on trouve

$$r(\bar{Y}_n) \leq r(T_n)$$

*

Estimation par intervalle de confiance

Exercice 3 (Bernoulli en utilisant l'inégalité de Bienaymé Tchebichev).

On suppose que $X \leftrightarrow \mathcal{B}(p)$ et que (X_1, X_2, \dots, X_n) est un échantillon. On pose

$$\bar{X}_n = \frac{1}{n} \sum_{k=1}^n X_k$$

1. Donner l'espérance et la variance de \bar{X}_n . (cours)
2. Montrer que \bar{X}_n est un estimateur sans biais et convergent vers p . (cours).
3. Montrer que $\mathbb{P}(|\bar{X}_n - p| \leq \varepsilon) \geq 1 - \frac{p(1-p)}{n\varepsilon^2}$
4. Soit $\alpha \in]0; 1[$ Trouver α tel que $1 - \frac{p(1-p)}{n\varepsilon^2} = 1 - \alpha$
5. Montrer que $\mathbb{P}\left(|\bar{X}_n - p| \leq \sqrt{\frac{p(1-p)}{n\alpha}}\right) \geq 1 - \alpha$.
6. Montrer que pour tout $p \in]0; 1[$ $p(1-p) \leq 1/4$. En déduire que
7. Montrer que $\mathbb{P}\left(|\bar{X}_n - p| \leq \frac{1}{2\sqrt{n\alpha}}\right) \geq 1 - \alpha$.
8. En déduire un intervalle de confiance de niveau de confiance $1 - \alpha$ de p .

RÉPONSE:

1. C'est des calculs très classiques

$$\begin{aligned} E(\overline{X}_n) &= E\left(\frac{1}{n} \sum_{k=1}^n X_k\right) \\ &= \frac{1}{n} \sum_{k=1}^n E(X_k) && \text{linéarité} \\ &= \frac{1}{n}(np) = p \end{aligned}$$

$$\begin{aligned} V(\overline{X}_n) &= V\left(\frac{1}{n} \sum_{k=1}^n X_k\right) \\ &= \frac{1}{n^2} V\left(\sum_{k=1}^n X_k\right) && \text{formule } V(aX + b) = a^2V(X) \\ &= \frac{1}{n^2} \sum_{k=1}^n V(X_k) && \text{indépendance des variables aléatoire} \\ &= \frac{npq}{n^2} = \frac{pq}{n} \end{aligned}$$

Remarque : Dans le cadre de cet exercice nous savons que $X_n \hookrightarrow \mathcal{B}(n, p)$ on pourrait aller un peu plus. La méthode proposée est celle classique.

2. **outils utilisés**

- Définition d'estimateur sans biais.
- décomposition du risque quadratique en biais/variance.
- Caractérisation d'un estimateur par l'étude du risque quadratique.

On a vu que $E(\overline{X}_n) = p$ donc l'espérance de l'estimateur est égale à la quantité que l'on veut estimer.

\overline{X}_n est un estimateur sans biais de p

D'après la formule du cours

$$r(\overline{X}_n) = b(\overline{X}_n)^2 + V(\overline{X}_n) = 0 + \frac{pq}{n}$$

Donc

$$\lim_{n \rightarrow +\infty} r_n(\overline{X}_n) = 0$$

\overline{X}_n est un estimateur convergent p

3. **outils utilisés**

- Bienaymée Tchebichef
- Événement contraire

Soit $\varepsilon > 0$, comme $\overline{X_n}$ admet une variance alors en utilisant l'inégalité de Bienaymée Tchebichev

$$\mathbb{P}(|\overline{X_n} - E(\overline{X_n})| > \varepsilon) \leq \frac{V(\overline{X_n})}{\varepsilon^2}$$

donc

$$\mathbb{P}(|\overline{X_n} - p| > \varepsilon) \leq \frac{p(1-p)}{n\varepsilon^2}$$

donc

$$1 - \mathbb{P}(|\overline{X_n} - p| > \varepsilon) \geq 1 - \frac{p(1-p)}{n\varepsilon^2}$$

en passant à l'événement contraire

$$\mathbb{P}(|\overline{X_n} - p| \leq \varepsilon) \geq 1 - \frac{p(1-p)}{n\varepsilon^2}$$

4.

$$\begin{aligned} 1 - \frac{p(1-p)}{n\varepsilon^2} = 1 - \alpha &\Leftrightarrow \frac{p(1-p)}{n\varepsilon^2} = \alpha \\ &\Leftrightarrow \varepsilon = \sqrt{\frac{p(1-p)}{n\alpha}} \end{aligned}$$

5. On savait que

$$\mathbb{P}(|\overline{X_n} - p| \leq \varepsilon) \geq 1 - \frac{p(1-p)}{n\varepsilon^2}$$

et en utilisant la question précédente

$$\mathbb{P}\left(|\overline{X_n} - p| \leq \sqrt{\frac{p(1-p)}{n\alpha}}\right) \geq 1 - \alpha$$

6. On peut étudier les variations de $x \mapsto (1-x)x$ sur l'intervalle $[0; 1]$ et en déduire la majoration demandée.

Méthode plus rapide

$$\begin{aligned} (1-p)p \leq \frac{1}{4} &\Leftrightarrow 4(1-p)p \leq 1 && \text{car } 4 > 0 \\ &\Leftrightarrow 0 \leq 1 - 4p + 4p^2 \\ &\Leftrightarrow 0 \leq (1-2p)^2 \end{aligned}$$

La dernière inégalité est vraie, donc par remontée d'équivalences :

$$\forall p \in [0; 1] \quad p(1-p) \leq \frac{1}{4}$$

7. D'après la question précédente

$$p(1-p) \leq \frac{1}{4}$$

donc comme les quantités considérées sont positives

$$\sqrt{\frac{p(1-p)}{n\alpha}} \leq \sqrt{\frac{1}{4n\alpha}}$$

On a donc

$$\left[|\bar{X}_n - p| \leq \sqrt{\frac{p(1-p)}{n\alpha}} \right] \subset \left[|\bar{X}_n - p| \leq \sqrt{\frac{1}{4n\alpha}} \right]$$

Par croissance d'une probabilité

$$\mathbb{P} \left(|\bar{X}_n - p| \leq \sqrt{\frac{p(1-p)}{n\alpha}} \right) \leq \mathbb{P} \left(|\bar{X}_n - p| \leq \sqrt{\frac{1}{4n\alpha}} \right)$$

et comme

$$1 - \alpha \leq \mathbb{P} \left(|\bar{X}_n - p| \leq \sqrt{\frac{p(1-p)}{n\alpha}} \right)$$

On obtient

$$1 - \alpha \mathbb{P} \left(|\bar{X}_n - p| \leq \sqrt{\frac{1}{4n\alpha}} \right)$$

8. outils utilisés

- Définition d'un intervalle de confiance
- "enlever des valeurs absolues" $|Y - b| \leq a \Leftrightarrow b - a \leq Y \leq b + a$

L'inégalité précédente peut s'écrire

$$1 - \alpha \leq \mathbb{P} \left(\bar{X}_n - \sqrt{\frac{1}{4n\alpha}} \leq p \leq \bar{X}_n + \sqrt{\frac{1}{4n\alpha}} \right)$$

La valeur que l'on veut estimer est compris dans l'intervalle de confiance $\left[\bar{X}_n - \sqrt{\frac{1}{4n\alpha}}; \bar{X}_n + \sqrt{\frac{1}{4n\alpha}} \right]$ non pas de façon sur mais avec une probabilité plus grande que $1 - \alpha$.

*

Exercice 4 (Bernouilli : en utilisant le théorème limite-centrale).

On reprend les mêmes notations que dans l'exercice 3. On note Φ la fonction de répartition de la loi normale centrée réduite.

1. Pourquoi Φ est-elle une fonction bijective de $]-\infty; +\infty[$ dans $]0; 1[$.
2. Exprimer \bar{X}_n^* la variable réduite centrée associée à \bar{X}_n .
3. En citant un théorème du cours expliquer pourquoi

$$\lim_{n \rightarrow +\infty} \mathbb{P} \left(a \leq \sqrt{n} \frac{\bar{X}_n - p}{\sqrt{p(1-p)}} \leq b \right) = \Phi(b) - \Phi(a)$$

4. Soit $\alpha \in]0; 1[$, on pose $t_\alpha = \Phi^{-1}(1 - \alpha/2)$. Montrer que

$$\lim_{n \rightarrow +\infty} \mathbb{P} \left(\overline{X}_n - \frac{t_\alpha p(1-p)}{\sqrt{n}} \leq p \leq \overline{X}_n + \frac{t_\alpha p(1-p)}{\sqrt{n}} \right) = 1 - \alpha$$

5. en déduire que $\left[\overline{X}_n - \frac{t_\alpha}{2\sqrt{n}}; \overline{X}_n + \frac{t_\alpha}{2\sqrt{n}} \right]$ est un intervalle de confiance asymptotique au niveau $1 - \alpha$

RÉPONSE:

1. la fonction Φ est continue comme fonction de répartition d'une variable à densité ? De plus elle dérivable sur \mathbb{R} et pour $t \in \mathbb{R}$

$$\Phi'(t) = \phi(t) = \frac{1}{\sqrt{2\pi}} \exp(-t^2/2)$$

Donc ϕ est strictement positive et donc Φ est strictement croissante.

De plus

$$\lim_{x \rightarrow -\infty} \Phi(x) = 0 \quad \lim_{x \rightarrow +\infty} \Phi(x) = 1$$

On peut donc appliquer le théorème de la bijection monotone pour affirmer que Φ réalise une bijection de $]-\infty; +\infty[$ vers $]\lim_{x \rightarrow -\infty} \Phi(x); \lim_{x \rightarrow +\infty} \Phi(x)[=]0; 1[$.

2. **Outils utilisés**

- $Y^* = \frac{Y - E(Y)}{\sigma_Y}$ la formule pour centrée et réduire une variable
- Le calcul (classique) de $E(\overline{X}_n)$ et $V(\overline{X}_n)$

$S_n = X_1 + X_2 + \dots + X_n$ est la somme de n variables de Bernoulli indépendante de même paramètre p donc

$$S_n \hookrightarrow \mathcal{B}(n, p)$$

et on ait

$$\overline{X}_n = \frac{S_n}{n}$$

donc

$$E(\overline{X}_n) = \frac{1}{n} \times np = p \quad \sigma_{\overline{X}_n} = \sqrt{V(\overline{X}_n)} = \sqrt{\frac{1}{n^2} V(S_n)} = \sqrt{\frac{p(1-p)}{n}}$$

Donc

$$\begin{aligned} \overline{X}_n^* &= \frac{\overline{X}_n - E(\overline{X}_n)}{\sigma_{\overline{X}_n}} \\ &= \frac{\overline{X}_n - p}{\sqrt{\frac{p(1-p)}{n}}} \\ &= \sqrt{n} \times \frac{\overline{X}_n - p}{\sqrt{p(1-p)}} \end{aligned}$$

$\overline{X}_n^* = \sqrt{n} \times \frac{\overline{X}_n - p}{\sqrt{p(1-p)}}$ est la variable réduite centrée associée à \overline{X}_n .

3. Les variables aléatoires étant toute de même loi indépendantes et admettant une variance, nous pouvons appliquer le théorème central de la limite, pour a et b deux réels tels que $a \leq b$

$$\lim_{n \rightarrow +\infty} \mathbb{P} \left(a \leq \overline{X}_n^* \leq b \right) = \Phi(b) - \Phi(a)$$

$$\lim_{n \rightarrow +\infty} \mathbb{P} \left(a \leq \sqrt{n} \frac{\overline{X}_n - p}{\sqrt{p(1-p)}} \leq b \right) = \Phi(b) - \Phi(a)$$

4. outils utilisés

- manipulation d'inégalité
- propriétés de Φ .

Par définition $t_\alpha = \Phi^{-1}(1 - \alpha/2)$, donc

$$\Phi(t_\alpha) = 1 - \alpha/2$$

De plus on sait que pour tout réel x

$$\Phi(-x) = 1 - \Phi(x)$$

donc

$$\Phi(-t_\alpha) = 1 - (1 - \alpha/2) = \alpha/2$$

de plus

$$\begin{aligned} -t_\alpha \leq \sqrt{n} \frac{\overline{X}_n - p}{\sqrt{p(1-p)}} \leq t_\alpha &\Leftrightarrow -t_\alpha \frac{\sqrt{p(1-p)}}{\sqrt{n}} \leq \overline{X}_n - p \leq t_\alpha \frac{\sqrt{p(1-p)}}{\sqrt{n}} && \text{positivité} \\ &\Leftrightarrow -t_\alpha \frac{\sqrt{p(1-p)}}{\sqrt{n}} \leq p - \overline{X}_n \leq t_\alpha \frac{\sqrt{p(1-p)}}{\sqrt{n}} && \text{en } \times -1 \\ &\Leftrightarrow \overline{X}_n - t_\alpha \frac{\sqrt{p(1-p)}}{\sqrt{n}} \leq p \leq t_\alpha \frac{\sqrt{p(1-p)}}{\sqrt{n}} + \overline{X}_n \end{aligned}$$

La question précédente donne

$$\lim_{n \rightarrow +\infty} \mathbb{P} \left(-t_\alpha \leq \sqrt{n} \frac{\overline{X}_n - p}{\sqrt{p(1-p)}} \leq t_\alpha \right) = \Phi(t_\alpha) - \Phi(-t_\alpha)$$

et donc

$$\lim_{n \rightarrow +\infty} \mathbb{P} \left(\overline{X}_n - t_\alpha \frac{\sqrt{p(1-p)}}{\sqrt{n}} \leq p \leq t_\alpha \frac{\sqrt{p(1-p)}}{\sqrt{n}} + \overline{X}_n \right) = 1 - \alpha/2 - \alpha/2$$

$$\lim_{n \rightarrow +\infty} \mathbb{P} \left(\overline{X}_n - \frac{t_\alpha p(1-p)}{\sqrt{n}} \leq p \leq \overline{X}_n + \frac{t_\alpha p(1-p)}{\sqrt{n}} \right) = 1 - \alpha$$

5. C'est la définition du cours

*

Exercice 5.

On veut estimer la masse m d'un certain objet. Pour cela, on effectue des pesées successives et l'on note m la moyenne obtenue. On admet que la variable aléatoire renvoyant le résultat d'une pesée de l'objet étudié suit la loi normale $\mathcal{N}(m, \sigma^2)$ avec $\sigma = 0.1$. On effectue une suite de pesées et on note X_i le résultat de la i -ième pesée.

1. On note $\bar{X}_n = \frac{1}{n} \sum_{k=1}^n X_k$. Quelle est la loi suivie par \bar{X}_n ?
2. Calculer l'espérance et la variance de \bar{X}_n .
3. On note $\bar{X}_n^* = \sqrt{n} \frac{\bar{X}_n - m}{\sigma}$. Quelle est la loi suivie par \bar{X}_n^* ?
4. On effectue 10 pesées et on obtient une masse moyenne de 45,5 grammes.
5. Trouver un réel x tel que

$$\mathbb{P}(|\bar{X}_{10} - m| \leq \frac{\sigma}{\sqrt{10}} x) \geq 0.9$$

On donne $\Phi(1,65) \approx 0,95$

6. Montrer que $\left[45,5 - \frac{\sigma}{\sqrt{10}} x; 45,5 + \frac{\sigma}{\sqrt{10}} x \right]$ est un intervalle de confiance au niveau de confiance 90% pour la masse m .
7. Déterminer quelle valeur de n il faut choisir pour que l'intervalle de confiance de niveau de confiance 90% soit de longueur 0.05.