

# Chapitre 3. Estimation par intervalle

Pierre Duchesne

February 2, 2017

Considérons le caractère étudié  $X$ : l'apport hebdomadaire de capitaux dans une entreprise. Ce caractère est une variable aléatoire.

Il est décidé de modéliser ce phénomène par une variable normale, ainsi  $X \sim \mathcal{N}(\mu, \sigma^2)$ .

Le paramètre d'intérêt dans un premier temps est  $\mu$ , l'apport hebdomadaire moyen.

Supposons que l'on ait prélevé un échantillon en centaine de milliers de dollars canadien:

$$\mathcal{E} : 1.37, 0.92, 0.67, 1.16;$$

Ainsi, la réalisation  $\mathcal{E} : X_1, X_2, X_3, X_4$  permet de construire une **estimation ponctuelle**.

On a vu que la meilleure estimation ponctuelle de  $\mu$  est:

$$\hat{\mu} = \bar{x} = \frac{1}{4} \sum_{i=1}^4 = 1.03,$$

qui impliquerait ici que l'entreprise enregistre en moyenne 103 000\$ par semaine.

L'estimation ponctuelle ne fournit qu'un nombre sans mention aucune de la précision de cette estimation.

L'estimation par intervalle en tient compte.

Elle se présente sous la forme: *Il y a 95 chances sur 100 que  $\mu$  soit compris entre 0.99 et 1.07.*

Dans les médias, 95 chances sur 100 est souvent rapporté comme **19 fois sur 20**.

La longueur de l'intervalle, ici  $1.07 - 0.99 = 0.08$ , est à la fois fonction de la précision de l'estimation ponctuelle ainsi que du degré de confiance qu'on accorde à l'énoncé.

Parfois, on préférera rapporter un intervalle sous la forme:

$$1.03 \pm 0.04,$$

afin de faire ressortir **l'estimation ponctuelle** et la **mesure de précision**.

Le degré de confiance dans l'intervalle sera appelé le **niveau de confiance**.

Dans une perspective fréquentiste (par opposition à une perspective bayésienne), un niveau de confiance de 95%, disons, s'interprète ainsi:

*Si on prélève 100 échantillons de taille  $n = 4$ , on doit s'attendre à ce que 95 d'entre eux contiennent la vraie valeur de  $\mu$ .*

*Autrement dit, 95 d'entre eux auront une valeur de  $\bar{x}$  telle que l'écart  $|\bar{x} - \mu| \leq 0.04$ .*

On note que  $\mu$  n'est pas aléatoire, c'est un paramètre. Il n'y a pas de sens à affirmer que la probabilité que  $\mu$  soit dans l'intervalle est 95%. C'est plutôt l'intervalle qui est aléatoire, qui contiendra  $\mu$  avec probabilité 95%.

# Construction d'un intervalle de confiance: principe général

Soit  $X$  un caractère étudié dont la loi dépend d'un paramètre inconnu  $\theta$ .

Soit  $\mathcal{E} : X_1, \dots, X_n$  un échantillon aléatoire de taille  $n$  et soit  $x_1, \dots, x_n$  une réalisation.

On définira un **pivot** pour  $\theta$  une variable aléatoire à la fois fonction de  $\mathcal{E}$  et de  $\theta$  qui présente les caractéristiques suivantes:

- (i) Sa loi soit entièrement connue;
- (ii) Elle deviendrait une statistique si la valeur de  $\theta$  était connue.

**Exemple:** Supposons que  $X \sim \mathcal{N}(\theta, 1)$ .

La variable aléatoire  $\bar{X}$  est telle que  $\bar{X} \sim \mathcal{N}(\theta, n^{-1})$  et ce **n'est pas** un pivot.

Par contre,  $n^{1/2}(\bar{X} - \theta) \sim \mathcal{N}(0, 1)$  est fonction de l'échantillon aléatoire, fonction de  $\theta$ , et de loi entièrement connue. Ainsi c'est bel et bien un pivot.

Nous aurons avantage à définir un pivot à partir d'un estimateur de  $\theta$ . Plus l'estimateur sera **bon**, plus le pivot correspondant sera considéré **bon**.

La procédure générale afin de construire un intervalle de confiance est de fixer un **niveau de confiance**  $1 - \alpha$ . Les valeurs de  $\alpha$  les plus courantes sont  $\alpha = 1\%, 5\%, 10\%$ . À partir du pivot  $T_\theta = t_\theta(X_1, \dots, X_n)$ , on détermine alors deux **bornes aléatoires**, c'est-à-dire deux statistiques:

$$T_1 = t^*(X_1, \dots, X_n),$$

et

$$T_2 = t^{**}(X_1, \dots, X_n),$$

satisfaisant la relation

$$P(T_1 < \theta < T_2) = 1 - \alpha.$$

Ainsi, un intervalle de confiance de niveau  $1 - \alpha$  pour le paramètre  $\theta$ , est donné par l'intervalle:

$$t_1 < \theta < t_2,$$

où

$$t_1 = t^*(x_1, \dots, x_n),$$

et

$$t_2 = t^{**}(x_1, \dots, x_n).$$

Ainsi  $t_1$  et  $t_2$  sont des réalisations de  $T_1$  et  $T_2$ , respectivement.

# Intervalle de confiance pour $\mu$ et pour $\sigma^2$ dans une population normale

Soit  $X$  un caractère étudié de loi  $\mathcal{N}(\mu, \sigma^2)$ . Soit  $\mathcal{E} : X_1, \dots, X_n$  un échantillon aléatoire.

On présume disposer d'une réalisation  $x_1, \dots, x_n$ .

**Intervalle de confiance pour  $\mu$  quand  $\sigma^2$  est connu**

L'estimateur naturel de  $\mu$  est  $\bar{X}$  qui est de loi  $\mathcal{N}(\mu, \frac{\sigma^2}{n})$ . Le pivot à considérer est:

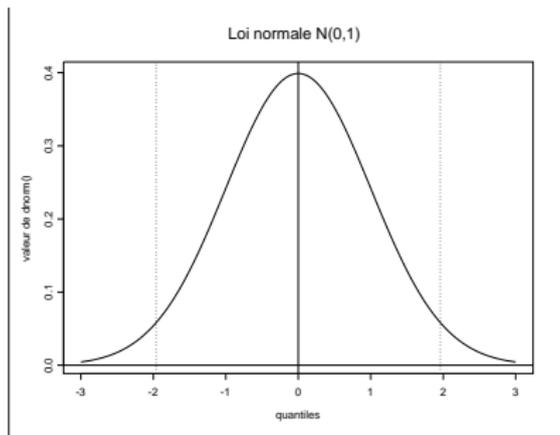
$$T_\mu(X_1, \dots, X_n) = n^{1/2} \left( \frac{\bar{X} - \mu}{\sigma} \right) \sim \mathcal{N}(0, 1).$$

Considérons  $\alpha_1$  et  $\alpha_2$  tels que  $\alpha_1 + \alpha_2 = \alpha$ . Posons  $z_{\alpha_1}$  et  $z_{\alpha_2}$  deux quantiles tels que

$$P(\mathcal{N}(0, 1) \leq z_{1-\alpha_j}) = 1 - \alpha_j,$$

c'est-à-dire

$$P(\mathcal{N}(0, 1) > z_{1-\alpha_j}) = \alpha_j.$$



Nous aurons alors:

$$P\left(-z_{1-\alpha_1} < n^{1/2} \left(\frac{\bar{X} - \mu}{\sigma}\right) < z_{1-\alpha_2}\right) = 1 - \alpha_1 - \alpha_2 = 1 - \alpha.$$

Or

$$\begin{aligned}n^{1/2} \left(\frac{\bar{X} - \mu}{\sigma}\right) < z_{1-\alpha_2} &\iff \bar{X} - \mu < z_{1-\alpha_2} \frac{\sigma}{n^{1/2}}, \\ &\iff \bar{X} - z_{1-\alpha_2} \frac{\sigma}{n^{1/2}} < \mu.\end{aligned}$$

De même,

$$\begin{aligned}n^{1/2} \left(\frac{\bar{X} - \mu}{\sigma}\right) > -z_{1-\alpha_1} &\iff \bar{X} - \mu > -z_{1-\alpha_1} \frac{\sigma}{n^{1/2}}, \\ &\iff \bar{X} + z_{1-\alpha_1} \frac{\sigma}{n^{1/2}} > \mu.\end{aligned}$$

Les manipulations ont isolé pour  $\mu$ . De

$$P\left(-z_{1-\alpha_1} < n^{1/2} \left(\frac{\bar{X} - \mu}{\sigma}\right) < z_{1-\alpha_2}\right) = 1 - \alpha,$$

nous avons obtenu:

$$P\left(\bar{X} - z_{1-\alpha_2} \frac{\sigma}{n^{1/2}} < \mu < \bar{X} + z_{1-\alpha_1} \frac{\sigma}{n^{1/2}}\right) = 1 - \alpha.$$

Ainsi l'intervalle de confiance de niveau  $1 - \alpha$  est:

$$\bar{X} - z_{1-\alpha_2} \frac{\sigma}{n^{1/2}} < \mu < \bar{X} + z_{1-\alpha_1} \frac{\sigma}{n^{1/2}}.$$

Si nous posons  $\alpha_1 = \alpha_2 = \alpha/2$ , alors l'intervalle de confiance est symétrique en ce sens que  $\bar{X}$  est le point milieu de l'intervalle. Autrement dit, l'estimation ponctuelle de  $\mu$  est le point milieu de l'intervalle de confiance.

Autre écriture:  $\mu \in \bar{X} \pm z_{1-\alpha/2} \frac{\sigma}{n^{1/2}}$ , au niveau de confiance  $1 - \alpha$ .

# Intervalle de confiance pour $\mu$ et pour $\sigma^2$ dans une population pas nécessairement normale

On vient de voir que l'intervalle  $\mu \in \bar{X} \pm z_{1-\alpha/2} \frac{\sigma}{\sqrt{n}}$ , au niveau de confiance  $1 - \alpha$ .

L'intervalle de confiance est exactement de niveau de confiance  $1 - \alpha$ , sous l'hypothèse que le caractère étudié  $X$  est de loi normale. En repassant la démarche, on voit que l'on a utilisé la normalité de la moyenne échantillonnale  $\bar{X}$ .

Si  $X$  est un caractère étudié qui n'est pas nécessairement de distribution normale, mais qui est tel que  $E(X) = \mu$  et  $\text{var}(X) = \sigma^2$ , alors le théorème limite central peut être invoqué afin de construire un intervalle de confiance dont le niveau de confiance sera approximativement égal à  $1 - \alpha$ .

# Rappel: Théorème Limite Central

Si on dispose d'un échantillon aléatoire, dont le caractère  $X$  est tel que  $E(X) = \mu$  et  $\text{var}(X) = \sigma^2$ , le Théorème Limite Central mentionne que:

$$\bar{X} \approx \mathcal{N}\left(\mu, \frac{\sigma^2}{n}\right).$$

On constate que la démarche est la même, mais alors l'intervalle de confiance  $\mu \in \bar{x} \pm z_{1-\alpha/2} \frac{\sigma}{n^{1/2}}$ , est **approximativement** de niveau de confiance  $1 - \alpha$ . L'approximation s'avère valable dès que  $n \geq 30$  dans ce contexte.

# Influence de la taille de l'échantillon sur la longueur de l'intervalle

Reprenons l'intervalle pour  $\mu$ , qui est  $\mu \in \bar{x} \pm z_{1-\alpha/2} \frac{\sigma}{n^{1/2}}$ , avec un niveau de confiance  $1 - \alpha$ .

La longueur de l'intervalle est donc:

$$2z_{1-\alpha/2} \frac{\sigma}{n^{1/2}}.$$

Ainsi, si  $n$  augmente, la longueur de l'intervalle diminue: *Plus nous disposons d'information, plus  $n$  sera donc grand, et plus l'inférence sera précise pour estimer  $\mu$ , et donc l'intervalle de confiance devient de plus en plus court (précis) à mesure que  $n$  augmente.*

# Influence du niveau de confiance sur la longueur de l'intervalle

La longueur de l'intervalle est:

$$2z_{1-\alpha/2} \frac{\sigma}{n^{1/2}}.$$

Plus le niveau de confiance  $1 - \alpha$  augmente, plus la longueur de l'intervalle augmente: *Plus nous désirons un niveau de confiance élevé que l'intervalle contiendra  $\mu$ , plus il faudra que l'intervalle de confiance soit large. Pourquoi ne pas choisir un niveau de confiance de 100%? Dans un tel cas, la longueur de l'intervalle serait infinie!*

Les niveaux de confiance courants:

$1 - \alpha$	90%	95%	99%
$z_{1-\alpha/2}$	1.644854	1.959964	2.575829