


Chapitre 3 Introduction à la Statistique Inférentielle

Chap 3.

1. Introduction
2. Fluctuations d'échant.
3. Estimation
4. Intervalle de fluctuation d'une moyenne empirique
5. Intervalle de confiance d'une moyenne théorique

1. Introduction aux méthodes statistiques

Schéma de l'urne:



X_i Variable aléatoire, réalisation de X
(ou mesure X de l'individu i)

Population cible, N individus
Variable aléatoire X , Loi P

On peut compliquer ce schéma pour un problème **multivarié**:
Revient à considérer une variable ayant plusieurs composantes.

$$\begin{cases} X = X^c, & c = 1, \dots, k \\ X = (X^1, X^2, \dots, X^k) \end{cases}$$

On peut alors calculer les moments de la population:

Moyenne théorique:

$$\mu = \frac{1}{N} \sum_{i=1}^N X_i$$

Variance:

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (X_i - \mu)^2$$

Statistique descriptive ou exploratoire ou analyse des données:


Description de la distribution de ces variables en population.

Suppose que l'on dispose de toutes les valeurs de la population.


Principaux paramètres caractérisant les distributions (variables discrètes ou continues):

- Moyenne
 - Variance
 - Distribution elle-même
- Permettent comparaisons entre les groupes

Cas discret:
histogramme





Densité de probabilité




Fonction de répartition

Cas continu:
fonction densité



Souvent difficile d'accéder à l'ensemble de la population. On doit alors se baser sur une partie de cette population: l'échantillon.



Population cible, N individus
Variable aléatoire X , Loi P

$$X = (X^1, X^2, \dots, X^k)$$

$$X_1, X_2, X_3, \dots, X_N$$


$$X_1, X_2, \dots, X_n$$

On considère ici que les variables de l'échantillon :

- sont extraites de la population de manière indépendante;
- sont identiquement distribuées.

Le même loi de probabilité s'applique: loi P , dépendant d'un paramètre inconnu θ , paramètre de population ou paramètre théorique.

Estimation des paramètres θ de $P \Rightarrow S$.



$$\begin{pmatrix} X_{1,1}, X_{1,2}, \dots, X_{1,n} \\ X_{2,1}, X_{2,2}, \dots, X_{2,n} \\ \dots \\ X_{k,1}, X_{k,2}, \dots, X_{k,n} \end{pmatrix} \Rightarrow \begin{pmatrix} S_1^n(X) \\ S_2^n(X) \\ \dots \\ S_k^n(X) \end{pmatrix} = S^n(X)$$

Démarche probabiliste: démarche déductive partant de la population, connaissant sa distribution, vers les observations.

On parle de calcul de probabilités.

On parlera d'intervalle de pari, de calcul de risque, etc ...



Démarche Statistique: démarche inductive : partant d'une partie de la population appelé échantillon, on estimera des paramètres inconnus de cette population, et d'une manière plus générale, on essayera de répondre à des questions inférentielles sur cette population observée qu'en partie ...

Chap 3.

1. Introduction
2. Fluctuations d'échant.
3. Estimation
4. Intervalle de fluctuation moy. empirique
5. Intervalle de confiance moy. théorique

2. Fluctuations d'échantillonnage

Considérons une variable aléatoire X suivant une loi f dans une population donnée.

n-échantillon: échantillon de taille n regroupant un ensemble de **variables aléatoires indépendantes et identiquement distribuées, de même loi f que X .**

En pratique: (X_1, X_2, \dots, X_n) == observations réalisées

$$\text{avec } E(X_i) = \mu \quad ; \quad \text{VAR}(X_i) = \sigma^2$$

Fluctuations d'une moyenne empirique

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \Rightarrow E(\bar{X}) = \mu \quad ; \quad \text{VAR}(\bar{X}) = \frac{\sigma^2}{n}$$

Fluctuations d'une variance empirique

$$S^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 \Rightarrow E\left(\frac{n}{n-1} S^2\right) = \sigma^2$$

Théorème Central-Limite (TCL)

Sous les hypothèses précédentes, on montre que

**Moyenne échantillonnage
standardisée**

$$Z = \frac{(\bar{X} - \mu)}{\sigma / \sqrt{n}} \xrightarrow{n \rightarrow \infty} N(0,1)$$

∀ distribution sous-jacente, pour de **grands échantillons**:
distribution d'échantillonnage connue = la loi normale.


En pratique, on considère que la moyenne échantillonnage suit une loi normale

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

Chap 3.

1. Introduction
2. Fluctuations d'échant.
3. Estimation
4. Intervalle de fluctuation moy. empirique
5. Intervalle de confiance moy. théorique

3. Estimation



Population cible, N individus
Variable aléatoire X, Loi P
 $X_1, X_2, X_3, \dots, X_N$
P de paramètre $\theta = \theta^N(X)$

Observations:
Echantillon
n individus X_1, X_2, \dots, X_n
Paramètre empirique $S^n(X)$

Démarche statistique:

estimer un paramètre théorique (ou paramètre en population ou paramètre de la distrib. théorique) à l'aide d'un échantillon de n observations issues de cette population. On supposera vérifiée l'hypothèse d'échantillonnage aléatoire simple.

Exemple: \bar{X}, s^2, F estimateurs de μ_X, σ_X^2, P

3.1 Estimateur naturel ou estimateur fonctionnel

Estimateur naturel: estimateur qui se calcule dans l'échantillon de la même manière que dans la population.

Exemple:

Moyenne théorique en population: $\mu = \frac{\sum_{i=1}^N X_i}{N}$

Moyenne empirique, estimateur naturel de μ : $\bar{X} = \frac{\sum_{i=1}^n X_i}{n}$

De même: variance empirique S^2 estimera de façon naturelle la variance théorique σ^2 .

3.2 Biais d' un estimateur

Soit $S(X)$ un estimateur d' un paramètre θ .

Biais de S:

$$b(\theta) = E[S(X)] - \theta$$

Calculé en utilisant la distribution d' échantillonnage de S.

Applications:

- **Biais d' une moyenne empirique = 0**, moyenne empirique est donc un estimateur sans biais de la moyenne théorique;
- **Biais d' une variance empirique**,
Variance empirique, estimateur naturel:

$$E(S^2) = \frac{n}{n-1} \sigma^2 \quad \Rightarrow \quad \text{Estimateur biaisé}$$

- **Estimateur de la variance: préférable d' utiliser**

$$S^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n-1} = \frac{n}{n-1} S^2 \quad \text{et donc} \quad E\left(\frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n-1}\right) \approx \sigma^2 \quad \Rightarrow \quad \text{Considééré comme un estimateur non biaisé}$$

Estimateur sans biais: $S(X)$, fonction des observations X_i , est un estimateur sans biais du paramètre θ si et seulement si $E(S(X)) = \theta$.

On préférera tjs un estimateur de biais inférieur, si possible nul, et de variance minimale.

3.3 Variance d' un estimateur

Variance d' un estimateur $S(X)$ d' un paramètre θ connu
= variance de sa distribution d' échantillonnage

$$\text{Var}(S(X)) = E\left[\left(S(X) - E(S(X))\right)^2\right]$$

Si $S(X)$ est un estimateur sans biais de θ alors

$$\text{Var}(S(X)) = E\left[\left(S(X) - \theta\right)^2\right]$$

Entre deux estimateurs de θ , l' un non-biaisé et l' autre biaisé, on choisira celui qui dont la variance est la plus faible, c' est-à-dire celui qui, dans l' échantillon, s' écartera en moyenne le moins du paramètre.

Un estimateur est dit optimal s' il est celui parmi les estimateurs sans biais qui a la variance minimum.

3.3 Estimateur consistant

Considérons un échantillon constitué par toute la population: $n=N$;
Estimateur **consistent** si il est alors égal au paramètre en population:

$$S^N(X) = \theta^N$$

Note: toujours le cas des estimateurs naturels.

Estimateur est dit **convergent** si lorsque $n \rightarrow \infty$
(échantillon de la taille de la population entière):

$$S^n(X) = \theta$$

Note: il suffit pour cela qu'il soit sans biais.

Chap 3.

1. Introduction
2. Fluctuations d'échant.
3. Estimation
4. Intervalle de fluctuation moy. empirique
5. Intervalle de confiance moy. théorique

4. Intervalle de fluctuation d'une moyenne empirique

La variance permet de quantifier la dispersion d'une variable. On s'intéresse maintenant ici aux *fluctuations d'échantillonnage résultant de la dispersion de la variable*.

Donner l'intervalle de fluctuation d'une variable == donner dans quel intervalle les valeurs de l'échantillon (ou les valeurs de paramètres (moyenne, variance...) calculés à partir de cet échantillon) doivent se situer. Cet intervalle ne peut être qu'approché.

C'est donc un problème probabiliste!

L'intervalle de fluctuation (ou de variation) d'une moyenne empirique (observée) d'une variable X est caractérisée par:

- Une distribution normale $N(\mu, \sigma^2)$ avec μ et σ connus.
- Une distribution qcq si $n > 30$ (grand échantillon).

= intervalle fixe vérifiant

$$P(\bar{X} \in I_f) = 1 - \alpha$$

$$I_f = \left[\mu - \frac{\sigma}{\sqrt{n}} e_{1-\frac{\alpha}{2}}, \mu + \frac{\sigma}{\sqrt{n}} e_{1-\frac{\alpha}{2}} \right]$$

(Z variable normale centrée réduite)

Où $e_{1-\alpha/2}$ = quantile défini par

$$P\left(Z \in \left[-e_{1-\frac{\alpha}{2}}, +e_{1-\frac{\alpha}{2}}\right]\right) = 1 - \alpha \quad \text{avec} \quad Z \approx N(\mu, \sigma^2)$$

Intervalle de fluctuation (ou de variation) d'une proportion observée P_0 d'une variable binaire X distribuée suivant une loi de Bernoulli de probabilité π

= intervalle fixe vérifiant

$$P(P_0 \in I_f) = 1 - \alpha$$

$$I_f = \left[\pi_0 - \frac{\pi_0(1-\pi_0)}{\sqrt{n}} e^{1-\frac{\alpha}{2}}, \pi_0 + \frac{\pi_0(1-\pi_0)}{\sqrt{n}} e^{1-\frac{\alpha}{2}} \right]$$

Valable si

$$\begin{aligned} n\pi_0 &\geq 5 \\ n\pi_0(1-\pi_0) &\geq 5 \end{aligned}$$

Chap 3.

1. Introduction
2. Fluctuations d' échant.
3. Estimation
4. Intervalle de fluctuation moy. empirique
5. Intervalle de confiance moy. théorique

5. Intervalle de confiance d' une moyenne théorique

Intervalle de confiance d' une moyenne théorique d' une variable X suivant une distribution normale $N(\mu, \sigma^2)$ avec σ connue.

= intervalle fixe vérifiant

$$P(I_c \ni \mu) = 1 - \alpha$$

Construit à partir de l' intervalle de fluctuation:

$$P(\bar{X} \in I_f) = 1 - \alpha$$

$$\Leftrightarrow P\left(\mu - \frac{\sigma}{\sqrt{n}} e_{1-\frac{\alpha}{2}} \leq \bar{X} \leq \mu + \frac{\sigma}{\sqrt{n}} e_{1-\frac{\alpha}{2}}\right) = 1 - \alpha$$

$$\Leftrightarrow P\left(\bar{X} - \frac{\sigma}{\sqrt{n}} e_{1-\frac{\alpha}{2}} \leq \mu \leq \bar{X} + \frac{\sigma}{\sqrt{n}} e_{1-\frac{\alpha}{2}}\right) = 1 - \alpha$$

ou

$$P(I_c \ni \mu) = 1 - \alpha$$
$$I_c = \left[\bar{X} - \frac{\sigma}{\sqrt{n}} e_{1-\frac{\alpha}{2}}, \bar{X} + \frac{\sigma}{\sqrt{n}} e_{1-\frac{\alpha}{2}} \right]$$