

LOI D'ÉCHANTILLONNAGE (F4, F5)

(26 / 04 / 2020, © Monfort, Dicostat2005, 2005-2020)

La loi de probabilité d'une statistique définie (ou calculée) à partir d'un échantillon est appelée **loi d'échantillonnage** ou **distribution d'échantillonnage**.

(i) Soit $(\Omega, \mathcal{F}, \mathcal{P})$ un **modèle statistique**, $(\mathcal{X}^N, \mathcal{B}^{\otimes N})$ un **espace d'échantillonnage** et $X : \Omega \mapsto \mathcal{X}^N$ un **échantillon** donné. A toute **mesure de probabilité** $P \in \mathcal{P}$ correspond une **loi de probabilité** possible $P^X = X(P)$ pour l'échantillon X . Par suite, si $(\mathcal{Y}, \mathcal{G})$ est un **espace mesurable** auxiliaire et $s : \mathcal{X}^N \mapsto \mathcal{Y}$ une application mesurable, la **statistique** S définie par $S = s(X) = s \circ X$ suit une loi définie selon :

$$(1) \quad P^S = P^{s(X)} = s(P^X) = (s \circ X)(P), \quad \text{où } P \in \mathcal{P}.$$

On dit que P^S est la **loi d'échantillonnage** associée à $X : P^X$ elle-même est l'exemple le plus simple d'une telle loi, avec $(\mathcal{Y}, \mathcal{G}) = (\mathcal{X}^N, \mathcal{B}^{\otimes N})$ et $s = \text{id}(\mathcal{X}^N)$.

(ii) Ainsi, la **loi du chi-deux** ou la **loi de FISHER-SNEDECOR** sont des lois d'échantillonnage classiques.

Comme toute l_p , P^S possède des **caractéristiques** (**moment**, **mode**, **quantile**, **fr**, **fc**, **densité**, etc) appelées **caractéristiques d'échantillonnage**.

(iii) Selon le **contexte statistique** :

(a) dans un **problème d'estimation**, S est généralement un **estimateur** : sa loi permet alors de définir des **régions de confiance** ;

(b) dans un **problème de test**, S est une **statistique de test** : sa loi permet de définir des **régions critiques d'un test**.

(iv) La notion de « loi d'échantillonnage » (tq P^S) se distingue de deux autres notions :

(a) celle de **loi empirique**, notée P_N , associée à l'échantillon X : P_N est une distribution aléatoire car elle dépend de X ;

(b) lorsque $\mathcal{Y} = \mathcal{X}^N$ et $s \neq \text{id}_{\mathcal{Y}}$, celle de **loi de l'échantillon**, ou **loi d'échantillon**, qui est la l_p de X . Notée P^X , cette loi est, par définition, l'image d'une **mesure de probabilité** $P \in \mathcal{P}$. Les deux notions coïncident lorsque $S = X$.

(v) La présentation précédente est de forme non paramétrée. Elle se particularise directement au cas d'un **modèle paramétrique**.

(vi) Lorsqu'une loi d'échantillonnage est de forme analytique complexe, on peut souvent en simplifier l'étude :

(a) soit par approximation : cf **approximation, approximation des lois, approximation d'une densité, loi approchée** ;

(b) soit en adoptant un point de vue asymptotique (ie $N \rightarrow +\infty$) : cf **loi asymptotique**.

(vii) Une situation classique concerne un **N-échantillon iid** $X = (X_1, \dots, X_N)$ issu d'une **vars** ξ (**variable parente**), de loi P^ξ , avec $\xi \in L_{\mathbb{R}^2}(\Omega, \mathcal{F}, \mathcal{P})$ (variable de carré intégrable). On note $\mu = E \xi$ et $\sigma^2 = V \xi$ (**moyenne** et **variance** théoriques).

Ainsi, X peut être un **échantillon avec remise**, ou encore un échantillon tiré dans une **population infinie**.

Par suite :

(a) si \bar{X}_N désigne la **moyenne empirique**, on montre que :

(a₁) $E \bar{X}_N = \mu$ (**espérance** de la moyenne empirique) : absence de **biais** ;

(a₂) $V \bar{X}_N = N^{-1} \sigma^2$ (**variance** de la moyenne empirique) ;

(a₃) si $P^\xi = \mathcal{N}(\mu, \sigma^2)$, alors $\mathcal{L}(\bar{X}_N) = \mathcal{N}(\mu, N^{-1} \sigma^2)$, ie $\mathcal{L}(U_N) = \mathcal{N}(0, 1)$, avec $U_N = (\sigma / N^{1/2})^{-1} (\bar{X}_N - \mu)$;

(a₄) si P^ξ est quelconque et si le **théorème de la limite centrale** est applicable, alors (mêmes notations) :

(2) $\mathcal{L}(U_N) \rightarrow_{N \rightarrow +\infty} \mathcal{N}(0, 1)$;

(b) si F_N désigne la **fréquence empirique** de l'ensemble des coordonnées X_n de X vérifiant une propriété donnée, on remplace dans ce qui précède μ par p et σ par $(p q)^{1/2}$ (cf **loi binômiale**) ;

(c) si $S_N^2 = N^{-1} \sum_{n=1}^N (X_n - \bar{X}_N)^2$ désigne la **variance empirique** (brute, ie non corrigée), alors :

(c₁) $E S_N^2 = N^{-1} (N - 1) \sigma^2$, ie $(N-1)^{-1} N S_N^2$ est un **estimateur sans biais** de σ^2 ;

(c₂) $V S_N^2 = E S_N^4 - N^{-2} (N - 1)^2 \sigma^4$;

(c₃) si $P^\xi = \mathcal{N}(\mu, \sigma^2)$, alors $\mathcal{L}(N \sigma^{-2} S_N^2) = \mathcal{X}_{N-1}^2$ (**loi du chi-deux** à $N-1$ **dl**) ;

(C₄) si P^ξ est quelconque et si le **théorème de la limite centrale** est applicable, alors l'égalité précédente est asymptotiquement vraie (cf **loi asymptotique**).