

MOYENNE EMPIRIQUE (F3)

(30 / 04 / 2018)

Une **moyenne empirique** est une **statistique naturelle** mise en correspondance avec celle d'**espérance mathématique**. En effet, cette expression concerne, le plus souvent, implicitement, la **moyenne arithmétique**.

(i) Soit (Ω, \mathcal{F}, P) un **espace probabilisé** et $\xi : \Omega \mapsto \mathbf{R}$ une **vars** de **loi** P^ξ . Soit $X = (X_1, \dots, X_N)$ un **N-échantillon** issu de la **variable parente** ξ .

On appelle **moyenne empirique (simple)** la **va** (ou **statistique**) suivante :

$$(1) \quad \bar{X}_N = N^{-1} \sum_{n=1}^N X_n = e_N' X / e_N' e_N \quad (\text{en notant } X \text{ en vecteur colonne}).$$

Autrement dit, \bar{X}_N s'interprète comme l'**espérance** de ξ calculée à l'aide de la **loi empirique** P_N associée à X , ie :

$$(2) \quad \bar{X}_N = E_N \xi = \int \xi dP_N.$$

(ii) Si $\lambda \in S_N$ (**simplexe** de \mathbf{R}^N) (cf **fonction de poids**), on appelle **moyenne empirique pondérée** (par λ) la **va** ou **statistique** suivante, définie comme **combinaison linéaire convexe** des coordonnées de X :

$$(3) \quad \bar{X}_N(\lambda) = \sum_{n=1}^N \lambda_n X_n = \lambda' X.$$

(iii) On montre que :

(a) si $\lambda = e_N / e_N' e_N = (1 / N, \dots, 1 / N)'$, alors $\bar{X}_N(\lambda) = \bar{X}_N$ (moyenne empirique « ordinaire ») ;

(b) si $\xi \in L_R^1(\Omega, \mathcal{F}, P)$, on a $E \bar{X}_N(\lambda) = \lambda' E X = \lambda' (E \xi) e_N = (E \xi) \lambda' e_N = E \xi = \mu_1$ (**moment** théorique simple d'ordre 1, ie espérance, de ξ) ;

(c) si X est un **échantillon iid** selon P^ξ et de carré intégrable, si μ désigne l'espérance de ξ et σ^2 sa **variance**, on a $V \bar{X}_N = N^{-1} \sigma^2$ et \bar{X}_N est asymptotiquement gaussienne (cf **normalité asymptotique**, **théorème de la limite centrale**), ie :

$$(4) \quad \mathcal{L}\{N^{1/2} \cdot \sigma^{-1} \cdot (\bar{X}_N - \mu)\} \rightarrow_{N \rightarrow +\infty} \mathcal{N}(0, 1) \text{ (loi normale réduite)}.$$

Si, de plus, $\xi \sim \mathcal{N}(\mu, \sigma^2)$ (**loi normale**), alors (cas où σ^2 est « inconnue ») :

$$(5) \quad \mathcal{L}\{N^{1/2} \cdot (S_N^*)^{-1} \cdot (\bar{X}_N - \mu)\} = \mathcal{S}_{N-1} \quad (\text{loi de STUDENT à } N - 1 \text{ degrés de liberté}),$$

où S_N^* désigne l'écart-type empirique associé à la **variance empirique** « corrigée »
 $(S_N^*)^2 = (N - 1) \sum_{n=1}^N (X_n - \bar{X}_N)^2$;

(d) si $X^i = (X_{i1}, \dots, X_{i,N(i)})$ est un échantillon iid comme la vars ξ_i (avec $i \in N_2^*$),
 si X_1 est indépendant de X_2 et si $\xi_i \sim \mathcal{N}(\mu_i, \sigma_i^2)$, alors la statistique (**écart**) :

$$(6) \quad D_{N(1),N(2)} = \bar{X}^1 - \bar{X}^2$$

vérifie :

$$(7) \quad (D_{N(1),N(2)} - \delta_{12}) / \sigma_{12} \sim \mathcal{N}(0, 1),$$

où \bar{X}_i est la moyenne empirique associée à X^i , S_i^2 sa variance empirique brute (ie non corrigée), $\delta_{12} = \mu_1 - \mu_2$, et $\sigma_{12}^2 = (\sigma_1^2 / N_1) + (\sigma_2^2 / N_2)$ (variance « combinée »).
 Ce résultat sert à divers **tests** portant sur les différences entre moyennes δ_{12} .

(iii) Si $\xi : \Omega \mapsto \mathbf{R}^K$ est un **vecteur aléatoire** et X un échantillon iid selon ξ , la moyenne empirique (vectorielle) de ξ (ou de X) est définie par le vecteur des moyennes empiriques (scalaires) des coordonnées de ξ , ie :

$$(8) \quad \bar{X}_N = N^{-1} \sum_{n=1}^N X_n = e_N' X / e_N' e_N,$$

X désignant ici la (N,K) -**matrice** $(X_1' \dots X_N')$, dont les lignes sont $X_n' = (X_{n1}, \dots, X_{nK})$, $\forall n \in N_N^*$, et par $e_N = (1, \dots, 1)'$ le premier vecteur bissecteur de \mathbf{R}^N . On note souvent \bar{X}_N sous la forme :

$$(9) \quad \bar{X}_N = (\bar{X}_1, \dots, \bar{X}_k), \quad \text{avec } \bar{X}_k = N^{-1} \sum_{n=1}^N X_{nk}, \quad \forall k \in N_K^*.$$

(iv) On montre que :

(a) si $\xi \in L_{\mathbf{R}^K}^1(\Omega, \mathcal{F}, P)$, \bar{X}_N est un **estimateur sans biais** de $E \xi$ (moyenne théorique de ξ), ie :

$$(10) \quad E \bar{X}_N = E \xi;$$

(b) si $\xi \in L_{\mathbf{R}^K}^2(\Omega, \mathcal{F}, P)$ et si X est un échantillon iid selon P^ξ , alors (en notant $V \xi$ la **matrice de covariance** théorique de ξ) :

$$(11) \quad V \bar{X}_N = N^{-1} \cdot V \xi;$$

(c) si $\xi \sim \mathcal{N}_K(\mu, \Sigma)$ (**loi normale multidimensionnelle**) et si X est iid selon P^ξ , on a :

$$\begin{aligned} \bar{X}_N &\sim \mathcal{N}_K(\mu, N^{-1} \Sigma), \\ (12) \quad N \cdot (\bar{X}_N - \mu)' \Sigma^{-1} (\bar{X}_N - \mu) &\sim \mathcal{X}_K^2 \quad (\text{loi du chi-deux à } K \text{ dl}). \end{aligned}$$