

## MÉTHODE DE EFRÖN (C12, F, G, H)

(21 / 04 / 2020, © Monfort, Dicostat2005, 2005-2020)

La **méthode de EFRÖN** est une méthode générale d'estimation par « **ré-échantillonnage** » effectué à partir de la **loi empirique**, ie par **simulation** basée sur celle-ci. Le **statisticien** estime ainsi une **caractéristique** relative à une **loi de probabilité** (théorique), puis assimile l'**estimation** obtenue à la « **vraie valeur** » de cette caractéristique.

(i) Soit  $(\Omega, \mathcal{F}, \mathcal{P})$  un **modèle statistique** (sous forme non paramétrée),  $(\mathcal{X}_0, \mathcal{B}_0)$  un **espace d'observation**,  $\xi : \Omega \mapsto \mathcal{X}_0$  une **va** donnée, de **loi**  $P^\xi$ , et  $X = (X_1, \dots, X_N)$  un **échantillon iid** issu de  $\xi$ , ie un **échantillon indépendant** et de loi commune  $P^\xi$ . Soit  $(\mathcal{X}, \mathcal{B}, \mathcal{P}^X) = (\mathcal{X}_0^N, \mathcal{B}_0^{\otimes N}, \mathcal{P}^X)$  le **modèle d'échantillonnage** (à distance finie), image du modèle de base initial par  $X$ , avec :

$$(1) \quad P^X = (P^\xi)^{\otimes N} \in \mathcal{P}^X.$$

On considère le **problème d'estimation** suivant. Soit  $(\Gamma, \mathcal{B}_\Gamma)$  un espace de **caractéristiques** associé à  $\mathcal{P}^X$  et  $T_N$  une **statistique** définie par l'**application mesurable**  $t_N : \mathcal{X}_0^N \times \mathcal{P}^\xi \mapsto \Gamma$  selon :

$$(2) \quad T_N = t_N(X, P^\xi), \quad \forall P^\xi \in \mathcal{P}^\xi = \xi(\mathcal{P}).$$

Pour estimer une caractéristique  $\gamma = c(P^\xi)$  associée à la lp  $P^\xi$ , la **méthode de B. EFRÖN** (équivalent anglais : « *bootstrap method* ») consiste en la **procédure statistique** suivante :

(a) tirage avec remise d'un **N-échantillon aléatoire**  $X^* = (X_1^*, \dots, X_N^*)$  à l'aide de la **loi empirique**  $P_N = N^{-1} \sum_{n=1}^N \delta(X_n)$  associée à  $X$ , où  $\delta(a)$  désigne la **loi de DIRAC** placée au point  $a$  (cf **échantillon avec remise**, **tirage bernoullien**) ;

(b) calcul de l'**estimateur** de  $\gamma$  défini par la statistique :

$$(3) \quad T_N^* = t_N(X^*, P_N).$$

(ii) A titre d'exemples :

(a) si  $\mathcal{X} = \mathbf{R}$ , et  $\mathcal{P} = \{\mathcal{N}_1(\gamma) : \gamma = (\mu, \sigma) \in \mathbf{R} \times \mathbf{R}_+^*\}$  (famille des **lois normales** scalaires), on peut estimer le couple  $\gamma$  (**moyenne** et **écart-type**) à l'aide de la statistique (cf **normalisation**, deuxième sens)  $t_N(X, P^\xi) = (\bar{X}_N - \mu) / \sigma$ , où  $\bar{X}_N$  désigne la **moyenne empirique** associée à  $X$  ;

(b) soit  $\Gamma = \mathcal{F}$  l'ensemble des fr  $F$  associées aux lois  $P^\xi$  et  $p \in ]0, 1[$ . On peut calculer  $t_N(X, P^\xi) = F_N^{-1}(p) - F^{-1}(p)$ , où  $F_N$  désigne la **fonction de répartition empirique** de  $X$  (ie la fr associée à  $P_N$ ) et  $F_N^{-1}$  (resp  $F^{-1}$ ) l'inverse continue à droite de  $F_N$  (resp de  $F$ ) (cf **fonction quantile**).

(iii) La méthode permet ainsi d'étudier une « statistique »  $T_N$  qui peut aussi dépendre de  $P^\xi$  (cf eg **fonctionnelle**, **fonction pivotale**). Elle s'applique aussi au cas où  $\mathcal{P}$  est une famille paramétrée  $(P_\theta)_{\theta \in \Theta}$ , avec  $\Theta \subset \mathbf{R}^Q$  (ie une famille « paramétrique ») : on remplace alors  $F_N$  par la **fonction de vraisemblance** estimée au point  $\theta_N^\sim$  (cf **estimateur du maximum de vraisemblance**).

(iv) La lp de la statistique  $T_N$  est appelée **loi de B. EFRON** (en anglais : « *bootstrap distribution* »).

Si  $\Gamma = \mathbf{R}$  et  $s_N : \mathcal{X} \mapsto \Gamma$  est une fonction mesurable définissant une statistique  $S_N = s_N(X)$  comme estimateur du paramètre  $\gamma = c(P^\xi)$ , le choix de la statistique  $t_N = s_N - \gamma$ , ie de  $t_N(X) = s_N(X) - c(P^\xi)$ , permet de calculer le **biais** de l'estimateur  $S_N$ , ie  $B_{S(N)} = E s_N(X) - c(P^\xi)$ . Ceci est à rapprocher de la **méthode de QUENOUILLE** (« jackknife »).

Si  $P^\xi = P_N$  (loi empirique), la statistique  $T_N^*$  suit la même loi que  $T_N$ .

(v) La **méthode de B. EFRON** peut aussi être présentée comme suit. Soit  $(\mathcal{X}_0^N, \mathcal{B}_0^{\otimes N}, \mathcal{P}^X)$  le modèle statistique précédent, où  $X = (X_1, \dots, X_N)$  est un **échantillon iid** selon  $P^\xi$ , et  $(\mathcal{Y}, \mathcal{G})$  un **espace mesurable** auxiliaire. On définit une statistique  $S$  à l'aide d'une application mesurable  $s : \mathcal{X} \mapsto \mathcal{Y}$  selon  $S = s(X)$ , avec  $\mathcal{X} = \mathcal{X}_0^N$ . On note alors  $P^S$  la loi de  $S$ ,  $F$  la fr de  $P^\xi \in \mathcal{P}^\xi$  et  $F_N$  la **fr empirique** associée à  $X$ .

Par suite, l'**estimateur de B. EFRON** (en anglais : « *bootstrap estimator* ») de  $P^S = \mathcal{L}_N(S / F)$  (loi de  $S$  sachant  $F$ , loi qui dépend de  $X$ ) est, par définition,  $\mathcal{L}_N(S / F_N)$  (ie est obtenu en remplaçant  $F$  par  $F_N$ ). Cet estimateur est « calculable » puisque, par hypothèse,  $X$  et  $F_N$  sont **observables** et que  $s$  est donnée.

(vi) L'interprétation de la méthode est la suivante. Si  $X^* = (X_1^*, \dots, X_N^*)$  est un échantillon iid selon la loi  $P_N$  (de fr associée  $F_N$ ), alors  $\mathcal{L}_N(S, F_N)$  n'est autre que la loi de  $S^* = s(X^*)$ .

En pratique, on peut approximer (et tabuler) cette loi par **simulation** (cf **méthodes de MONTE CARLO**) en tirant des échantillons tq  $X^*$ .

(vii) La méthode de EFRON permet aussi l'**évaluation d'une procédure statistique** lorsqu'il est possible de renouveler l'**échantillonnage** (cf **renouvellement**).

Ainsi,  $(\mathcal{X}, \mathcal{B}, (P_\theta^X)_{\theta \in \Theta})$  étant un modèle statistique associé à un **échantillon aléatoire**  $X = (X_1, \dots, X_N)$  et  $s : \mathcal{X} \mapsto \Theta$  une application mesurable définissant la statistique  $S = s(X)$  (ie un **estimateur** de  $\theta$ ), on peut tirer (avec remise), dans l'ensemble  $\{X_1, \dots, X_N\}$ ,  $k$  échantillons aléatoires  $X_i = (X_{i1}, \dots, X_{iN})$  (de même taille  $N$ ), iid selon la loi empirique  $P_N$  associée à  $X$  (où  $i = 1, \dots, k$ ).

Par suite, les statistiques  $S_i = s(X_i)$  ( $\forall i \in N_k^*$ ) permettent d'étudier (ou d'estimer) la **loi de l'estimateur**  $S$  lui-même. Dans ce contexte,  $P^k = k^{-1} \sum_{i=1}^k \delta(S_i)$  intervient souvent comme loi « empirique » associée aux  $S_i$ . En particulier, si  $\Theta = \mathbf{R}$ , on peut calculer :

$$(4) \quad \bar{S}_k = k^{-1} \sum_{i=1}^k S_i \quad (\text{moyenne des } S_i),$$

$$(5) \quad V_k^2 = (k-1)^{-1} \sum_{i=1}^k (S_i - \bar{S}_k)^2 \quad (\text{variance des } S_i).$$

Sous certaines hypothèses, un **test d'hypothèses** (asymptotique) peut se baser sur la **propriété asymptotique** :

$$(5) \quad \mathcal{L}((S - \bar{S}_k) / V_k) \xrightarrow{k \rightarrow +\infty} \mathcal{N}_1(0, 1) \quad (\text{loi normale réduite}).$$

(viii) De même, si  $X$  est un  $N$ -échantillon iid selon  $P_\theta^X$  et si le **paramètre**  $\theta$  est estimé à l'aide d'un estimateur  $T = t(X)$ , on peut étudier eg la **variabilité** de  $T$  pr à  $\theta$  en procédant comme suit :

(a) estimation de la fr  $F(\cdot, \theta)$  associée à  $P_\theta^X$  à l'aide de la fr empirique  $F_N$  ;

(b) tirage de  $k$  échantillons  $X_i$  de taille  $N$ , iid selon  $F_N$ , et calcul des estimateurs  $T_i = t(X_i)$  qui en résultent, avec  $i \in N_k^*$  ;

(c) calcul de la variabilité (eg **variance**) des  $T_i$  pr à  $T$  : cette variabilité estime alors celle de  $T$  pr à  $\theta$ .