

REDONDANCE (C5, F3, G6)

(11 / 10 / 2020, © Monfort, Dicostat2005, 2005-2020)

On appelle parfois **redondance** une **caractéristique légale** comparable à celles de **coefficient de concentration**, d'**entropie**, ou d'**information**.

(i) Soit (Ω, \mathcal{F}, P) un **espace probabilisé** et $\xi : \Omega \mapsto \mathbf{R}_+$ une **vars** positive (ie non négative) de **loi** P^ξ . On suppose que $\xi \cdot \text{Log } \xi \in \mathcal{L}_{\mathbf{R}^+}^1(\Omega, \mathcal{F}, P)$ et l'on pose $\mu = E \xi$.

On appelle **coefficient de redondance**, ou **indice de redondance**, théorique (au sens de H. THIEL) le scalaire :

$$(1) \quad \rho(\xi) = E \{(\xi / \mu) \cdot \text{Log}(\xi / \mu)\}.$$

(ii) Soit $X = (X_1, \dots, X_N)$ un **échantillon iid** constitué de **répliques** $X_n \sim P^\xi$ de ξ . On définit les **proportions empiriques** f_n selon (cf **fréquence empirique**) :

$$(2) \quad f_n = X_n / e_N' X, \quad \forall n \in N_N^*,$$

ainsi que l'**entropie empirique** $H_N(p)$ selon :

$$(3) \quad H_N(p) = \sum_{n=1}^N f_n \cdot \text{Log}(1 / f_n),$$

avec $f = (f_1, \dots, f_N)$.

On établit que $\max_f H_N(f) = \text{Log } N$. Par suite, on définit le **coefficient de redondance**, ou **indice de redondance**, empirique $R_N(X)$ (ou $R_N(f)$, ou simplement R_N) comme l'**écart** (en niveau) pr à ce maximum :

$$(4) \quad R_N = \max_f H_N(f) - H_N(f) = \text{Log } N - H_N(f).$$

(iii) On établit les propriétés suivantes :

(a) **convergence presque sûre** :

$$(5) \quad R_N \rightarrow \rho(\xi) \text{ (P-p.s.) ;}$$

(b) **convergence en loi**. Si $\xi \text{Log } \xi \in \mathcal{L}_{\mathbf{R}^+}^2(\Omega, \mathcal{F}, P)$, alors :

$$(6) \quad N^{1/2} \cdot (R_N - \rho(\xi)) \rightarrow \mathcal{L}_{N \rightarrow +\infty} \mathcal{N}_1(0, \sigma^2) \quad \text{(loi normale),}$$

avec $\sigma^2 = \mu^{-2} E \{ \xi \text{Log } \xi - \alpha (\xi / \mu) - \xi + \mu \}^2$ et $\alpha = E (\xi \text{Log } \xi)$.