

## COEFFICIENT DE CONCENTRATION (C5, F3)

(15 / 01 / 2020, © Monfort, Dicostat2005, 2005-2020)

La notion de **concentration** peut se « résumer » à l'aide d'une grandeur (en général scalaire) associée à une **loi de probabilité** : cette grandeur est donc une **caractéristique légale**.

Ainsi, on considère un **espace probabilisé**  $(\Omega, \mathcal{F}, P)$  et un **espace d'observation**  $(\mathcal{X}, \mathcal{B})$  dans lequel  $\mathcal{X}$  est un **espace topologique** muni de sa **tribu borélienne**  $\mathcal{B}$ .

On suppose que la **lp**  $P^\xi$  de la **va**  $\xi : \Omega \mapsto \mathcal{X}$  est une **loi unimodale**. Alors, si  $C \in \mathcal{B}$  est une **partie mesurable** donnée qui est aussi une **partie centrale** de  $P^\xi$ , la **probabilité**  $P^\xi(C)$  peut constituer un indicateur de concentration élémentaire relatif à  $P^\xi$ . Si  $Q = \mathcal{X} \setminus C$  est une **queue** de  $P^\xi$ , le rapport  $P^\xi(C) / P^\xi(Q) = (1 - P^\xi(C))^{-1} \cdot P^\xi(C)$  représente un autre indicateur de concentration.

Un **coefficient de concentration**, ou parfois **coefficient d'inégalité**, est une mesure scalaire de la **dispersion** ou du « **degré d'uniformité** » d'une **va** positive ou de sa **loi**. Il décrit donc la « répartition » d'une va positive (taille des individus, revenu des ménages, chiffre d'affaires des entreprises, etc). On parle aussi d'**indice de concentration**, ou parfois d'**indice d'inégalité**.

Il existe de nombreux coefficients de ce type, qui sont souvent sans dimension (ie de dimension nulle) pr aux **unités de mesure**.

(i) **Coefficient théoriques**. On considère un **espace probabilisé**  $(\Omega, \mathcal{F}, P)$  et une **vars** positive  $\xi : \Omega \mapsto \mathbf{R}_+$  de **loi**  $P^\xi = \xi(P)$ .

On appelle :

(a) **coefficient de C. GINI**, ou **coefficient de C. GINI - M.O. LORENZ**, (théorique) le nombre :

$$(1) \quad \gamma_G = 2 \cdot \int_{\mathbf{R}_+} F(x) dG(x) - 1,$$

où  $F$  est la **fr** associée à  $P^\xi$  et  $G(x) = (E \xi)^{-1} \int_0^x dF(u)$ ,  $\forall x \in \mathbf{R}_+$ . L'indice  $\gamma_G$  dérive de la courbe  $(u = F(x), v = G(x))_{x \in \mathbf{R}_+}$ , paramétrée par  $x$  (cf **coefficient de GINI**) ;

(b) **coefficient d'entropie généralisée**, ou **coefficient d'entropie d'ordre  $\alpha$** , (théorique) le nombre :

$$(2) \quad \varepsilon(\alpha) = \int_{\mathbf{R}_+} \{1 - (f(x))\}^\alpha dF(x), \quad \forall x \in ]-1, +\infty[,$$

dont l'**entropie** constitue un cas particulier (avec  $\alpha \rightarrow 0$ ), où l'on note  $f = P^\xi / d\lambda_1$  la **densité** de  $P^\xi$  pr à la **mesure de LEBESGUE**.

(ii) **Coefficient empiriques.** Les coefficient précédents possèdent des analogues empiriques (cf **statistique naturelle**) : ces derniers sont obtenus en remplaçant  $F$  (resp  $P^\xi$ ) par la **fonction de répartition empirique**  $F_N$  (resp par la **loi empirique**  $P_N$ ) associée à un  $N$ -**échantillon**.

Si  $X = (X_1, \dots, X_N) : \Omega \mapsto \mathbf{R}_+^N$  est un **échantillon aléatoire** (non nécessairement indépendant), les **statistiques** suivantes sont des exemples de **coefficients de concentration empiriques**, ou **coefficients d'inégalité empiriques** :

(a) le **coefficient de C. GINI** (empirique) :

$$(3) \quad G_N = (2 N^2)^{-1} \cdot (1 / \bar{X}_N) \cdot \sum_{\alpha=1}^N \sum_{\beta=1}^N |X_\alpha - X_\beta|,$$

généralement associé à la « **courbe** » de **concentration empirique** du même nom (ou **courbe de C. GINI - O. LORENZ**), définie à partir des points (cf **courbe de LORENZ**) :

$$(4) \quad \begin{aligned} U_\alpha &= \alpha / N \\ V_\alpha &= \sum_{n=1}^\alpha X_n / \sum_{n=1}^N X_n, \end{aligned} \quad \forall \alpha = 1, \dots, N,$$

où  $X_n$  désigne la coordonnée d'indice  $n$  de l'échantillon  $X$  ordonné de façon croissante (cf **statistique d'ordre**). Ainsi,  $U_\alpha$  représente le nombre relatif cumulé d'**unités statistiques**, et  $V_\alpha$  la valeur relative cumulée de la variable  $\xi$  observée sur ces unités ;

(b) l'**indice de O.C. HERFINDAHL - A.O. HIRSCHMAN** (empirique), défini selon :

$$(5) \quad H_N^2 = \sum_{n=1}^N p_n^2, \quad \text{avec } p_n = (\sum_{\alpha=1}^N X_\alpha)^{-1} \cdot X_n = X_n / e_N' X \text{ (poids des unités),}$$

qui s'écrit aussi  $H_N^2 = N^{-1} (C_N^2 + 1)$ , où  $C_N^2$  est le carré du **coefficient de variation** empirique :  $C_N^2 = S_N^2 / \bar{X}_N^2$ , avec  $S_N^2 = N^{-1} \sum_{n=1}^N (X_n - \bar{X}_N)^2$ . Le coefficient  $(H_N^2)' = 1 - H_N^2$  est aussi appelé **indice de A.O. HIRSCHMAN** ;

(c) l'**indice de A.F. SHORROKS**, ou **indice d'entropie généralisée**, (empirique), qui consiste en une famille d'indices de la forme :

$$(6) \quad S_N(\alpha) = N^{-1} \alpha^{-1} (\alpha - 1)^{-1} \cdot \sum_{n=1}^N \{(X_n / \bar{X}_N)^\alpha - 1\}, \quad \forall \alpha \in \mathbf{R}_+^* .$$

Lorsque  $\alpha \rightarrow 0+$ , on obtient la **déviation logarithmique moyenne** :

$$(7) \quad S_N(0) = N^{-1} \cdot \sum_{n=1}^N \text{Log} (\bar{X}_N / X_n).$$

Lorsque  $\alpha \rightarrow 1-$ , on obtient le **coefficient de H. THEIL** (cf **entropie**) :

$$(8) \quad S_N(1) = N^{-1} \sum_{n=1}^N (X_n / \bar{X}_N) \text{Log} (X_n / \bar{X}_N) ;$$

lorsque  $\alpha = 2$ , on obtient une relation simple avec le coefficient de variation empirique :

$$(9) \quad S_N(2) = (1/2) C_N^2;$$

(d) le **coefficient de PARETO** (cf [loi de PARETO](#)).

(iii) Si les poids  $p_n$  définis précédemment sont ordonnés par valeurs décroissantes, on appelle **distribution de poids** le vecteur  $p = (p_1, \dots, p_N)' \in S_N$  (**simplexe** de dimension  $N - 1$  de  $\mathbf{R}^N$ ). La concentration des unités  $n$ , appréciée à travers ces poids, peut alors être définie (empiriquement) à l'aide d'une fonction  $c_N : S_N \mapsto \mathbf{R}$ .

Pour définir une notion de **concentration relative**, on dit qu'une distribution  $p'$  fondée sur  $N$  unités est **plus concentrée** qu'une distribution  $p''$  fondée sur le même nombre d'unités ssi :

$$(10) \quad c_N(p') > c_N(p'').$$

La fonction  $c_N$  doit vérifier des propriétés interprétables :

(a) **symétrie** :  $c_N(\sigma(p)) = c_N(p)$ ,  $\forall \sigma \in \sigma_N$  (groupe des **permutations** de  $N_N^*$ )

;

(b) non décroissance par **agrégation** quelconque. Si deux unités  $\alpha$  et  $\beta \neq \alpha$  sont « regroupées », l'indicateur de concentration  $c_N$  ne doit pas décroître, ie :

$$(11) \quad c_N(p_1, \dots, p_\alpha + p_\beta, \dots, p_{\beta-1}, 0, p_{\beta+1}, \dots, p_N) \geq c_N(p),$$

pour tout couple  $(\alpha, \beta)$  tq  $\beta \neq \alpha$  et toute distribution  $p$  fondée sur  $X$  ;

(c) non décroissance par **agrégation** ordonnée. Si l'on regroupe une unité  $\beta$  avec une unité antérieure  $\alpha < \beta$  (ie une unité strictement plus importante), l'indicateur de concentration  $c_N$  doit croître :

$$(12) \quad c_N(p_1, \dots, p_\alpha + p_\beta, \dots, p_{\beta-1}, 0, p_{\beta+1}, \dots, p_N) > c_N(p),$$

pour tout  $(\alpha, \beta)$  tq  $\beta \neq \alpha$  et toute distribution  $p$  fondée sur  $X$  ;

(d) décroissance avec  $N$  dans le cas « uniforme » : si les unités sont de même importance, avec  $X_n = X_0$  (donné),  $\forall n$ , (ie si  $p_n = p_0 = N^{-1}$ ,  $\forall n$ ), la fonction  $c_N$  doit diminuer lorsque le nombre  $N$  d'unités augmente :

$$(13) \quad N' < N'' \Rightarrow c_{N'}(e_{N'} C / N') > c_{N''}(e_{N''} C / N''),$$

où  $e_N = (1, \dots, 1)' \forall \mathbf{R}^N$ ,  $\forall N \in \mathbf{N}^*$ .

(iv) A titre d'exemple, si  $f$  est une fonction adéquate, on peut définir un **indicateur de A. JACQUEMIN** de la forme :

$$(14) \quad c_N(p) = \sum_{n=1}^N p_n f(p_n).$$

Ainsi :

(a) si  $f$  est une fonction **constante** discontinue tq  $f(p_n) = 1, \forall n \leq \alpha$ , et  $f(p_n) = 0, \forall n > \alpha$ , on définit le poids des  $\alpha$  premières unités  $C_\alpha$  (avec  $\alpha / N \leq C_\alpha \leq 1$ ) ;

(b) si  $f$  est la fonction linéaire  $f(p_n) = p_n$ , on définit le coefficient de HERFINDAHL-HIRSCHMAN précédent (avec  $1 / N \leq H_N^2 \leq 1$ ) ;

(c) si  $f$  est la fonction logarithmique  $f(p_n) = -\text{Log } p_n, \forall n$ , on définit l'entropie (empirique) de la distribution  $p$ , ie  $E_N = -\sum_{n=1}^N p_n \text{Log } p_n$  (avec  $0 \leq E_N \leq \text{Log } N$ ).