

ANNEXE 1-F : DÉVELOPPEMENT DE LA FORMULE DE CALCUL DE L'INDICE DE GINI

Dans le cas où le nombre d'observations est fini (cas discret), la différence moyenne de Gini s'écrit ¹ :

$$\Delta = \frac{1}{N^2} \sum_{j=1}^n \sum_{k=1}^n |y_j - y_k| f_j f_k$$

où

n est le nombre de valeurs distinctes observées

où f_j est la fréquence de la valeur y_j dans la distribution, de sorte que

$$N = \sum_{j=1}^n f_j \text{ est le nombre d'observations}$$

Lorsque les observations sont groupées par classes, la valeur y_j est la valeur moyenne de la variable Y dans la classe j .

Écrivons

$$v_j = \frac{f_j}{N}, \text{ la fraction de la population appartenant à la classe } j.$$

La valeur moyenne de la variable Y s'écrit alors

$$\mu = \frac{1}{N} \sum_{j=1}^n f_j y_j = \sum_{j=1}^n v_j y_j$$

Soit

$$M = \sum_{j=1}^n f_j y_j, \text{ la somme des valeurs de la variable } Y, \text{ et}$$

$$w_j = \frac{f_j y_j}{\sum_{k=1}^n f_k y_k} = \frac{f_j y_j}{N \mu} = \frac{v_j y_j}{\mu}, \text{ la fraction de la somme allouée à la classe } j.$$

¹ Dans cette formule chaque observation est comparée à chacune des observations, y compris à elle-même ; c'est la différence moyenne avec répétition. Kendall et Stuart (1991, p. 58) donnent aussi la formule sans répétition. Lorsque N est grand, la différence est négligeable.

Développons maintenant la formule de la différence moyenne de Gini :

$$\Delta = \frac{1}{N^2} \sum_{j=1}^n \sum_{k=1}^n |y_j - y_k| f_j f_k$$

$$\Delta = \sum_{j=1}^n \sum_{k=1}^n |y_j - y_k| v_j v_k$$

$$\Delta = \sum_{j=1}^n \sum_{k=1}^n |v_j v_k y_j - v_j v_k y_k|$$

$$\Delta = \sum_{j=1}^n \sum_{k=1}^n |v_k \mu w_j - v_j \mu w_k|$$

$$\Delta = \mu \sum_{j=1}^n \sum_{k=1}^n |v_k w_j - v_j w_k|$$

La suite du développement s'appuie sur deux observations. D'abord,

$$v_k w_j - v_j w_k = 0 \text{ pour } k = j.$$

Ensuite, si les observations ont été rangées, en vue de la construction d'une courbe de Lorenz, par ordre croissant des rapports w_j/v_j , alors

$$[k < j] \Rightarrow \left[\frac{w_j}{v_j} \geq \frac{w_k}{v_k} \right] \Rightarrow [v_k w_j - v_j w_k \geq 0]$$

et on peut écrire

$$\Delta = 2\mu \sum_{j=1}^n \sum_{k < j} |v_k w_j - v_j w_k| = 2\mu \sum_{j=1}^n \sum_{k < j} (v_k w_j - v_j w_k)$$

$$\Delta = 2\mu \left(\sum_{j=1}^n \sum_{k < j} v_k w_j - \sum_{j=1}^n \sum_{k < j} v_j w_k \right)$$

$$\Delta = 2\mu \left(\sum_{j=1}^n w_j \sum_{k < j} v_k - \sum_{j=1}^n v_j \sum_{k < j} w_k \right)$$

Développons le premier des deux termes entre parenthèses :

$$\sum_{j=1}^n w_j \sum_{k < j} v_k = w_1 v_0 + w_2 (v_1) + w_3 (v_1 + v_2) + w_4 (v_1 + v_2 + v_3) + \dots$$

où $v_0 = 0$.

$$\sum_{j=1}^n w_j \sum_{k<j} v_k = \sum_{k=1}^n v_k \sum_{j>k} w_j = \sum_{k=1}^n v_k \left(1 - \sum_{j \leq k} w_j\right) = \sum_{k=1}^n v_k \left(1 - \sum_{j=1}^k w_j\right)$$

Pour finir, complétons la notation en posant

$$Cw_j = \sum_{k=1}^j w_k$$

On obtient alors

$$\sum_{j=1}^n w_j \sum_{k<j} v_k = \sum_{k=1}^n v_k (1 - Cw_k) = 1 - \sum_{k=1}^n v_k Cw_k = 1 - \sum_{j=1}^n v_j Cw_j$$

Et il résulte

$$\Delta = 2\mu \left(1 - \sum_{j=1}^n v_j Cw_j - \sum_{j=1}^n v_j Cw_{j-1}\right)$$

L'indice de concentration de Gini est simplement le rapport de la différence moyenne de Gini sur deux fois la moyenne :

$$G = \frac{\Delta}{2\mu} = 1 - \left(\sum_{j=1}^n v_j Cw_j + \sum_{j=1}^n v_j Cw_{j-1}\right) = 1 - \sum_{j=1}^n v_j (Cw_j + Cw_{j-1})$$