

# Sull'interpretazione e scomposizione dell'indice di concentrazione

Laura Grassini, Università di Firenze.

In questo lavoro viene introdotta una definizione alternativa dell'indice di concentrazione di una funzione non negativa  $g(x)$  della variabile statistica  $x \geq 0$ , riferito a  $N$  osservazioni. La formula proposta consente una immediata interpretazione economica e statistica dell'indice e lo studio della sua scomponibilità qualora le  $N$  osservazioni originarie siano raggruppate in classi. La proprietà di scomponibilità dell'indice di concentrazione viene quindi discussa in vista della sua utilità applicativa.

## 1. Introduzione

Il concetto di curva di Lorenz, tradizionalmente associato allo studio della distribuzione personale del reddito, è stato esteso e generalizzato trovando utile applicazione nell'analisi di numerosi altri fenomeni economici (cfr. Mahalanobis, 1960; Iyengar, 1960; Kakwani, 1977; Grassini, 1982). La curva di Lorenz e il noto indice (o rapporto) di concentrazione  $Gx$  di una variabile statistica non negativa  $x$  con funzione di ripartizione  $F(x)$ , introdotto da Gini (Gini, 1914) e definito, nella letteratura anglosassone, "indice del Gini" o "indice Gini-Lorenz" sono, infatti, il caso particolare della curva e dell'indice di concentrazione  $C$  di una trasformata non negativa di  $x$ ,  $y = g(x)$ , quando  $g(x)=x^{(*)}$ .

Mahalanobis e Iyengar, nel 1960, seguirono questa impostazione nell'analizzare i dati sulla spesa in beni di consumo in India e definirono, appunto, curva di concentrazione la curva di Lorenz generalizzata. Successivamente Kakwani (Kakwani, 1977, 1980) ha sviluppato una trattazione più generale e rigorosa.

Questa impostazione ha contribuito notevolmente allo sviluppo della metodologia statistica sulla concentrazione. Lo studio tradizionale della concentrazione di una variabile, attraverso la curva di Lorenz e l'indice del Gini, è di tipo univariato e prescinde, cioè, dalle relazioni che essa ha con altre

---

(\*) In questa nota, per la definizione dell'indice  $C$  seguiremo uno schema molto semplice in cui la variabile  $y$  viene definita come trasformazione della variabile statistica (o casuale) non negativa  $x$ , mediante una funzione non negativa  $g(x)$ . Questo schema presenta carattere di generalità potendo anche essere riferito allo studio della dipendenza fra grandezze. In questo caso, infatti, date due variabili casuali non negative  $z$  e  $u$ , con funzione di ripartizione congiunta  $L(z,u)$ , la  $g(\cdot)$  potrebbe rappresentare la relazione  $E(z|u=u_0) = g(u_0)$ .

grandezze. L'analisi mediante  $C$  consente invece di recuperare queste informazioni che contribuiscono a spiegare la natura della variabile stessa (\*\*).

Generalmente la definizione di  $C$  avviene ricorrendo al suo significato geometrico e solo attraverso alcune elaborazioni successive è possibile darne una interpretazione statistica ed economica. In questa nota si propone una diversa definizione dell'indice  $C$  riferito ad un numero finito  $N$  di osservazioni ( $(N-1)/N \approx 1$ ), che consente un'immediata interpretazione economica, statistica e, inoltre, lo studio della sua scomponibilità qualora le  $N$  osservazioni originarie siano raggruppate in classi. La definizione di  $C$  qui introdotta rappresenta una estensione della formulazione proposta da Pyatt (1976) per l'indice del Gini  $Gx$ .

## 2. Definizione di indice di concentrazione

Date  $N$  osservazioni sulla variabile  $x \geq 0$  rilevata su  $N$  individui, ove  $(N-1)/N \approx 1$ , l'indice del Gini di  $x$  è rappresentabile come (Pyatt, 1976):

$$Gx = \frac{1}{N^2 \bar{x}} \sum_{i=1}^N \sum_{j=1}^N A_{ij} \quad (1)$$

dove  $\bar{x}$  è il valore medio di  $x$  e:

$$A_{ij} = \begin{cases} 0 & \text{se } x_j \leq x_i \\ x_j - x_i & \text{altrimenti} \end{cases}$$

Per l'interpretazione di  $Gx$ , si ipotizza il seguente gioco statistico. Ogni individuo  $i$  estrae a caso dalla popolazione degli  $N$  valori  $x_k$  ( $k=1,2, \dots, N$ ) il valore  $x_j$  di cui si può, eventualmente, appropriare. Se  $x_j > x_i$ , ha convenienza ad appropriarsi di  $x_j$ , nel caso contrario a rifiutarlo. Nessun individuo può perdere a questo gioco: tutti, escluso il "più ricco", hanno infatti un guadagno atteso positivo.  $Gx$  rappresenta, pertanto, il guadagno atteso medio degli  $N$  individui, rapportato al valore  $\bar{x}$ .

Supponiamo che ad ogni valore  $x_i$  di  $x$  sia associato il valore  $y_i$  della variabile  $y$ , ottenibile attraverso una generica funzione a valori non negativi  $g(\cdot)$ , tale che  $y_i = g(x_i)$ . Si può definire, allora, l'indice di concentrazione  $C$  di  $g(x)$ , rispetto alle  $N$  osservazioni, come:

$$C = \frac{1}{N^2 \bar{y}} \sum_{i=1}^N \sum_{j=1}^N B_{ij} \quad (2)$$

---

(\*\*) L'idea di studiare la dipendenza fra grandezze mediante misure di concentrazione è già presente in un articolo di Gini del 1910 (Gini, 1910).

dove  $\bar{y}$  è il valore medio di  $y$  e:

$$B_{\bar{y}} = \begin{cases} 0 & \text{se } x_j \leq x_i \\ y_j - y_i & \text{altrimenti} \end{cases}$$

$C$  rappresenta una generalizzazione di  $Gx$  con cui coincide se  $g(x)=x$  ed è il guadagno atteso medio di  $y$  condizionato ad un guadagno positivo di  $x$ , rapportato al valore  $\bar{y}$ .

Secondo la (2) il legame fra  $x$  e  $y$  può essere così interpretato: se l'individuo *i.esimo* è disposto ad appropriarsi di  $x_i$ , è disposto anche a modificare l'ammontare posseduto di  $y$ . Inoltre, in base alle espressioni (1) e (2) si può ritrovare la seguente relazione già dimostrata per altra via (Pyatt, Chen e Fei, 1980; Kakwani, 1980, pp. 173 e segg.):

$$- Gy \leq C \leq Gy \quad (3)$$

dove  $Gy$  è l'indice del Gini calcolato sulla variabile  $y$ .

Il caso  $C = Gy$  ( $= -Gy$ ) si ha se e solo se a variazioni positive di  $x$  corrispondono sempre variazioni non negative (non positive) di  $y$ . Negli altri casi, un valore positivo (negativo) di  $C$  significa una concordanza "in media" positiva (negativa) fra  $x$  e  $y$  in termini di "predominanza" delle variazioni positive (negative) su quelle negative (positive), secondo la (2).

Dal punto di vista geometrico, infine, è facile dimostrare che  $C$  rappresenta il doppio dell'area compresa fra la retta di equidistribuzione e la spezzata congiungente i punti  $(p_k; q_k)$  dove (v. Fig. 1):

$$p_k = \frac{k}{N} \quad q_k = \frac{1}{N \bar{y}} \sum_{j=1}^k y_{[j]}$$

e  $y_{[j]}$  rappresenta l'ordinamento dei valori di  $y$  corrispondente a valori crescenti di  $x$ . Infatti, in tal caso, poiché  $x_j > x_i$  se  $j > i$ , si ha:

$$C = \frac{1}{N^2 \bar{y}} \sum_{j=2}^N \sum_{i=1}^{j-1} (y_j - y_i)$$

### 3. Scomposizione dell'indice di concentrazione

Supponiamo che le  $N$  osservazioni siano raggruppate in  $T$  classi rispetto a valori crescenti di  $x$  e che la numerosità  $n_t$  di ogni classe  $t(t=1, 2, \dots, T)$  di estremi  $[x_{t-1}^*, x_t^*)$ , con  $x_0^*=0$  e l'ultima classe aperta, sia tale che  $(n_t - 1)/n_t \approx 1$ . Siano, inoltre,  $\bar{x}_t, \bar{y}_t$  i valori medi di  $x$  e  $y$  corrispondenti alla classe *t.esima* (\*).

(\*) È questa la struttura, ad esempio, dei dati derivanti dalle indagini sui bilanci familiari che vengono utilizzati nello studio della relazione fra spesa in beni di consumo e reddito.




Fig. 1 - Spezzata di concentrazione di  $g(x)$

In tal caso è noto che (Pyatt, 1976):

$$Gx = G_x^I + G_x^T \quad (4)$$

dove

$$G_x^I = \frac{1}{N^2 \bar{x}} \sum_{i=1}^I Gx_i \bar{x}_i n_i^2$$

$$G_x^T = \frac{1}{N^2 \bar{x}} \sum_{i=1}^I \sum_{k=1}^I A'_{ik} n_i n_k$$

con

$$A'_{ik} = \begin{cases} 0 & \text{se } \bar{x}_k \leq \bar{x}_i \ (k \leq i) \\ \bar{x}_k - \bar{x}_i & \text{altrimenti} \end{cases}$$

e  $Gx_i$  indice del Gini di  $x$  relativo alla classe  $i$ -esima.

Per la (2) e la (4), si ha:

$$C = C^I + C^T \quad (5)$$

dove

$$C^I = \frac{1}{N^2 \bar{y}} \sum_{i=1}^T C_i \bar{y}_i n_i^2$$

$$C^T = \frac{1}{N^2 \bar{y}} \sum_{i=1}^T \sum_{k=1}^T B'_{ik} n_i n_k$$

con

$$B'_{ik} = \begin{cases} 0 & \text{se } \bar{x}_k \leq \bar{x}_i \text{ (} k \leq i \text{)} \\ \bar{y}_k - \bar{y}_i & \text{altrimenti} \end{cases}$$

e  $C_i$  indice di concentrazione di  $y$  relativo alla classe  $i$ -esima. Diversamente avviene per  $G_y$ . Infatti, posti:

$$G_y^I = \frac{1}{N^2 \bar{y}} \sum_{i=1}^T G_{y_i} \bar{y}_i n_i^2$$

$$G_y^T = \frac{1}{N^2 \bar{y}} \sum_{i=1}^T \sum_{k=1}^T A''_{ik} n_i n_k$$

con

$$A''_{ik} = \begin{cases} 0 & \text{se } \bar{y}_k \leq \bar{y}_i \\ \bar{y}_k - \bar{y}_i & \text{altrimenti} \end{cases}$$

e  $G_{y_i}$  indice del Gini di  $y$  relativo alla classe  $i$ -esima, vale in generale:

$$G_y \geq G_y^I + G_y^T$$

Possiamo quindi scrivere:

$$G_y = G_y^I + G_y^T + W \quad (6)$$

dove la grandezza non negativa  $W$ , la cui definizione esplicita non ha qui rilevanza e per la quale rimandiamo a Mehran (1975a), rappresenta la componente di  $G_y$  dovuta alla sovrapposizione delle classi rispetto ai valori di  $y$ . Non è detto, infatti, che le classi si presentino disgiunte rispetto ai valori di  $y$ .

Quando a variazioni positive di  $x$  corrispondono variazioni non negative (non positive) di  $y$ , si ha:

$$C^I = G_y^I (= -G_y^I) \quad C^T = G_y^T (= -G_y^T) \quad W = 0$$

Infatti, poiché la (3) può essere riferita agli indici  $G_y$ , e  $C$ , allora:

$$- G_y^I \leq C^I \leq G_y^I$$

Inoltre, per la definizione di  $C^T$  e di  $G_y^T$ :

$$- G_y^T \leq C^T \leq G_y^T$$

#### 4. Osservazioni conclusive

La scomposizione di  $C$  si presenta assai interessante riguardo a:

1) la descrizione del legame di concordanza esistente fra  $x$  e  $y$  in relazione ad un determinato criterio di classificazione delle osservazioni. In questa ottica la (6) suggerisce una particolare interpretazione della componente  $W$  che, se diversa da zero, indicherebbe la non monotonicità di  $g(x)$  rispetto a  $x$ . Più in generale, si può dire che  $W$  rappresenti il potere discriminante di una variabile rispetto ad un determinato criterio di raggruppamento delle osservazioni. Più basso è il peso di  $W$  sul valore totale dell'indice  $G_y$ , più alto è il potere discriminante della variabile;

2) la possibilità di estendere a  $C$  i procedimenti utilizzati per la determinazione del valore massimo di  $G_x$  da dati raggruppati che consiste nella massimizzazione della componente  $G_x^I$  essendo  $G_x^T$  noto (Gastwirth, 1972; Gastwirth e Krieger, 1975; Mehran, 1975).

Quando le  $N$  coppie di osservazioni  $(x_i, y_i)$ ,  $i=1, 2, \dots, N$ , si presentano raggruppate in  $T$  classi rispetto a valori crescenti di  $x$  e solo le medie aritmetiche di  $x$  e  $y$  e le frequenze osservate di classe sono disponibili, due metodi vengono generalmente usati per la stima di  $C$ . Il primo consiste nel calcolo di  $C^T$  che, come abbiamo visto, coincide con  $C$  solo se  $C^I=0$ . Il secondo metodo consiste nell'adattamento di una funzione ai dati empirici per rappresentare la curva di concentrazione di  $g(x)$  e ripropone, quindi, i consueti problemi connessi con la scelta della forma analitica e del metodo di interpolazione (Kakwani, 1980, pp. 198 e segg.; Grassini, 1982a). A differenza della curva di Lorenz di  $x$ , infatti, la curva di concentrazione di  $g(x)$  non ha proprietà analitiche predeterminate poiché queste dipendono da quelle di  $g(x)$ . La scelta della forma analitica si basa, il più delle volte, sulla sua bontà di adattamento definita rispetto ad un determinato metodo di interpolazione.

L'ottenimento di una stima di intervallo di  $C$  consentirebbe di evitare questi inconvenienti e il procedimento di determinazione dei valori minimo e massimo di  $C$ , attraverso la massimizzazione e minimizzazione di  $C^I$ , essendo  $C^T$  noto, può consentire la formulazione di un metodo generale di stima di intervallo di  $C$ .

Questa nota ha carattere essenzialmente metodologico. L'autrice sta ultimando un lavoro in cui si affrontano gli aspetti applicativi dell'indice  $C$  e delle sue proprietà, per lo studio della relazione fra reddito e spesa in beni di consumo.

Si ringraziano i revisori per gli utili suggerimenti.

#### Riferimenti bibliografici

- Bhattacharya N., B. Mahalanobis (1967) "Regional Disparities in Household Consumption in India", *Journal of the American Statistical Association*, vol. 62.
- Blitz R.C., J.A. Brittain (1964) "An Extension of the Lorenz Diagram to the Correlation of Two Variables", *Metron*, vol. 23.
- Gastwirth J.L. (1972) "The Estimation of the Lorenz Curve and Gini Index", *Review of Economics and Statistics*, vol. 54.
- Gastwirth J.L., A.M. Kieger (1975) "On Bounding Moments from Grouped Data", *Journal of the American Statistical Association*, vol. 70.
- Gini C. (1910) "Indici di concentrazione e di dipendenza", *Biblioteca dell'Economista*, vol. XX, U.T.E.T., Torino.
- Gini C. (1914) "Sulla misura della concentrazione e della variabilità dei caratteri", *Atti del Regio Istituto Veneto di Scienze, Lettere ed Arti*, Tomo LXXIII, Parte II.
- Grassini L. (1982) "Un metodo deterministico per la stima delle elasticità engeliane da dati raggruppati", *Statistica*, n. 4.
- Grassini L. (1982a) "On the Estimation of Engel Elasticities with Application to Italian Data", *Proceedings of the 2nd Task Force Meeting on Input-Output Modeling 1981*, CP-32-82, International Institute for Applied System Analysis, Laxenburg, Vienna.
- Iyengar N.S. (1960) "On a Method of Computing Engel Elasticities from Concentration Curves". *Econometrica*, vol. 28.
- Kakwani N.C. (1977) "Application of Lorenz Curves in Economic Analysis", *Econometrica*, vol. 45.
- Kakwani N.C. (1980) *Income Inequality and Poverty* Oxford University Press.
- Mahalanobis P.C. (1960) "A Method of Fractile Graphical Analysis", *Econometrica*, vol. 28.
- Mehran F. (1975) "Bounds on the Gini Index based on Observed Points of the Lorenz Curve", *Journal of the American Statistical Association*, vol. 70.
- Mehran F. (1975a) "A Statistical Analysis on Income Inequality based on a Decomposition of the Gini Index", *Proceedings of the 40th Session of the International Statistical Institute*, Varsavia.
- Nygard F., A. Sandstrom (1981) *Measuring Income Inequality*, Almquist & Winsell, Stockholm.
- Pyatt G. (1976) "On the Interpretation and Disaggregation of Gini Coefficients", *Economic Journal*, vol. 86.
- Pyatt G., C.N. Chen, J. Fei (1980) "The Distribution of Income by Factor Components", *Quarterly Journal of Economics*, vol. 94.

#### Summary

This paper introduces an alternative formulation of the concentration index of a non negative function  $g(x)$  of a statistical variable  $x \geq 0$ , with respect to  $N$  observations. This formula offers an interesting interpretation of the index from an economic and statistical point of view and allows studying its decomposability when the  $N$  observations are grouped. The index decomposability is discussed with respect to its use in empirical applications.