

GIORGIO VITTADINI

UN INDICE NORMALIZZATO PER LA MISURA
DELLA DISUGUAGLIAZZA FRA LE COMPONENTI
DI UNA VARIABILE CASUALE BIDIMENSIONALE

(Estratto dagli "Annali della Facoltà di Scienze Politiche
dell'Università di Milano", III - 1983)



MARZORATI EDITORE MILANO - 1983

UN INDICE NORMALIZZATO PER LA MISURA
DELLA DISUGUAGLIANZA FRA LE COMPONENTI
DI UNA VARIABLE CASUALE BIDIMENSIONALE

1. Una recente rilettura di quanto è stato scritto sulla Dissomigianza — concetto introdotto da C. Gini nel lontano 1914 e ripreso in seguito da altri autori fra cui, in particolare, T. Salvemini e G. Landenna (1) — ha suggerito l'idea di proporre un semplice indice per misurare la « disegualanza » che caratterizza le componenti di una variabile casuale bidimensionale (X, Y) .

La presentazione di tale indice verrà fatta nelle righe che seguono dopo un breve richiamo sulla classe di Fréchet delle funzioni di ripartizione bidimensionale $F(x, y)$ aventi prefissate marginali $G_1(x)$ e $G_2(y)$.

2. Sia (X, Y) una variabile casuale bidimensionale le cui componenti assumono la stessa serie di modalità t_1, t_2, \dots, t_n , caso al quale ci si può sempre ricongiungere aggiungendo alle determinazioni della X gli eventuali valori assunti solo dalla Y e viceversa, ed attribuendo probabilità nulla ai nuovi valori.

Siano inoltre:

$$\begin{aligned} F(t_i, t_j) &= \Pr. (X \leq t_i, Y \leq t_j), \\ G_1(t_i) &= \Pr. (X \leq t_i), \\ G_2(t_j) &= \Pr. (X \leq t_j), \end{aligned}$$

le funzioni di ripartizione rispettivamente di (X, Y) , di X e di Y e $f(t_i, t_j)$, $g(t_i)$ e $g(t_j)$ le corrispondenti funzioni di probabilità. È evidente che la predetta $F(t_i, t_j)$ può sempre essere intesa come una funzione della classe di Fréchet (2) generata associando fra loro, in tutti i modi possibili, le componenti X ed Y di (X, Y) aventi prefissate funzioni di ripartizione $G_1(t_i)$ e $G_2(t_j)$, classe alla quale, come è noto, appartengono le due funzioni $F'(t_i, t_j)$ e $F''(t_i, t_j)$ che in corrispondenza di ogni coppia (t_i, t_j) assumono rispettivamente:

- (1) $F^o(t_i, t_j)$ il valore minore fra $G_i(t_i)$ e $G_k(t_j)$,
 (2) $F^l(t_i, t_j)$ il valore maggiore fra 0 e $G_i(t_i) + G_k(t_j) - 1$.

3. Ciò premesso, si definiscono « uguali » le componenti di (X, Y) se, al variare delle prove, assumono determinazioni la cui differenza è sempre nulla.
 Ne discende che se X e Y sono « uguali » nel senso suddetto si verifica necessariamente che:

$$(3) \quad \begin{aligned} F(t_i, t_i) &= G_i(t_i) = G_i(t_i), & (i = 1, 2, \dots, k) \\ f(t_i, t_j) &= g_i(t_i) = g_i(t_i), & (i = 1, 2, \dots, k) \\ f(t_i, t_j) &= 0 & (i \neq j) \end{aligned}$$

e, di conseguenza, che il valor medio:

$$(4) \quad d_{xy} = \sum_{i=1}^k \sum_{j=1}^k |t_i - t_j| f(t_i, t_j)$$

risulta nullo, cioè: $d_{xy} = 0$.

Se le componenti di (X, Y) non sono fra loro « uguali », vale a dire sono « disuguali », non valgono allora le condizioni (3) e si ha di conseguenza: $d_{xy} > 0$.

Stante il fatto che è possibile dimostrare (3), che il valor medio (4) soddisfa alle condizioni:
 a) di essere simmetrico rispetto alle due variabili casuali X ad Y e

- sempre non negativo,
 b) di annullarsi se, e solo se, X ed Y sono « uguali »,
 c) di soddisfare alla relazione triangolare della distanza,

viene naturale assumere la (4) medesima come indice per la misura della « disugualianza » fra le due componenti di (X, Y) .

4. Deve ora osservarsi che l'indice (4) assume il suo « minimo » valore (4) se la funzione $F(t_i, t_j)$ che caratterizza (X, Y) coincide con la funzione $F^o(t_i, t_j)$ definita con la (1).

In tal caso, deve ritenersi che le due componenti di (X, Y) presentano fra loro la « minima » disugualianza la cui misura è fornita da:

$$(5) \quad d^o_{xy} = \sum_{i=1}^k \sum_{j=1}^k |t_i - t_j| f^o(t_i, t_j) = \min. d_{xy}$$

dove $f^o(t_i, t_j)$ è la funzione di probabilità associata a $F^o(t_i, t_j)$.

Ed è chiaro che sarà $d^o_{xy} = 0$ se, e solo se, le componenti di (X, Y) sono fra loro « uguali ».

D'altra canto, l'indice (4) assume il suo « massimo » valore (4), se la funzione $F(t_i, t_j)$ che caratterizza (X, Y) coincide con la funzione $F^l(t_i, t_j)$ definita con la (2).

In tal caso deve ritenersi che le due componenti di (X, Y) presentano fra loro la « massima » disugualianza la cui misura è fornita da:

$$(6) \quad d^l_{xy} = \sum_{i=1}^k \sum_{j=1}^k |t_i - t_j| f(t_i, t_j) = \max. d_{xy}$$

dove $f(t_i, t_j)$ è la funzione di probabilità associata a $F(t_i, t_j)$. Dalle (4), (5) e (6) discende che si può scrivere:

$$(7) \quad 0 \leq d^o_{xy} \leq d_{xy} \leq d^l_{xy}$$

e tale serie di disugualanze consente, in via naturale, di costruire il seguente indice normalizzato per la misura della disugualianza fra X ed Y :

$$(8) \quad D_{xy} = \frac{d_{xy} - d^o_{xy}}{d^l_{xy} - d^o_{xy}}$$

Detto indice, infatti, assume: valore 1, se X ed Y presentano fra loro la « massima » disugualianza, nel senso che rendono massimo il valore medio (4); assume valore 0, se X ed Y presentano la « minima » disugualianza nel senso che rendono minimo lo stesso valore (4). E, in particolare, si dirà che X ed Y sono fra loro « uguali », se $d_{xy} = 0$ nel qual caso è anche necessariamente $d^o_{xy} = 0$.

BIBLIOGRAFIA

- (1) C. Giuri, *Di una misura della dissomiglianza tra due gruppi di quantità e delle sue applicazioni allo studio delle relazioni statistiche*, « Atti del R. Ist. Ven. di Scienze, Lettere ed Arti », Tomo LXXIV, 1914-15; *Nuovi contributi alla teoria delle relazioni statistiche*, « Atti del R. Ist. Ven. di Scienze, Lettere ed Arti », Tomo LXXIV, 1914-15; T. Salvermini, *Nuovi procedimenti per il calcolo degli indici di dissomiglianza e di connessione*, « Statistica », 1949; *Dissomiglianza a più dimensioni*, « Atti della Soc. Ital. Stat. », 1951; *L'indice di dissomiglianza tra distribuzioni continue*, « Metron », vol. XVI, 1952; *Some alcuni aspetti della dissomiglianza e della concordanza*, « Riv. Ital. Stat. », vol. VII, 1953; *L'indice quadratico di dissomiglianza tra distribuzioni continue*, « Metron », vol. XVII, 1952.

distribuzione gaussiana, « Atti della Soc. Ital. Stat. », 1954; G. LANDENNA, *La dissimiglianza*, « Statistica », 1956;

(2) M. FRÉCHET, *Sur les tableaux de corrélation dont les marges sont données*, « Annales de l'Université de Lyon », s. III, fasc. 4: « Sciences », 1951;

(3) G. LANDENNA, *op. cit.*, (1).

(4) G. DALL'AGLIO, *Sugli estremi dei momenti delle funzioni di ripartizione doppia*, « Annali della Scuola Normale Superiore », 1956.

SUMMARY: *Index of dissimilarity of two dimensional random variable components.*

In this paper, following the concept of dissimilarity, introduced by C. Gini and closer examined by T. Salvemini and G. Landenna, an index of dissimilarity of two-dimensional random variable components is proposed. This index is introduced by the « class of Fréchet » of the two dimensional distribution function.

SOMMAIRE: *Un indice normalisé pour mesurer la dissimilarité entre les composantes d'une variable aléatoire bidimensionnelle.*

Une récente réflexion sur le concept de dissimilarité, introduit par C. Gini et, pour le suite, par d'autres auteurs (T. Salvemini et G. Landenna) a suggéré de proposer une nouvelle mesure de dissimilarité entre les deux composants de une variable aléatoire bidimensionnelle. Cet indice est introduit à partir de la « classe de Fréchet » concernant les variables bidimensionnelles.