

LA DISTANZA DELLE ALTERNATIVE NELLE VERIFICHE DI IPOTESI RIGUARDANTI LE DISTRIBUZIONI MULTINOMIALI *

di Michele ZENGA **

1. Introduzione e sommario

In un precedente lavoro [1] si è mostrata l'opportunità di misurare in una multinomiale a k classi la distanza di una alternativa, caratterizzata dalle probabilità (p_1, p_2, \dots, p_k) , dalle probabilità $(\pi_1, \pi_2, \dots, \pi_k)$ dell'ipotesi di

nullità, utilizzando la funzione $\Delta = \max \left\{ \frac{|p_i - \pi_i|}{\pi_i} ; i = 1, 2, \dots, k \right\}$.

In [1] si è anche proceduto alla determinazione delle numerosità campionarie necessarie, impiegando il consueto test basato sulla statistica X^2 di Karl-Pearson, per avere valori piccoli di α (probabilità di errori di prima specie) e di $\max \beta$ (β è la probabilità di errori di seconda specie; $\max \beta$ è riferito alle alternative con $\Delta \geq \delta$, essendo $\delta > 0$). Una caratteristica singolare riscontrata dall'esame di dette numerosità campionarie è che esse aumentano enormemente all'aumentare di k .

In questo lavoro si effettueranno dei confronti fra Δ e la consueta funzione

di distanza $H^2 = \sum \frac{(p_i - \pi_i)^2}{\pi_i}$, e fra Δ e la funzione $\Gamma = \sum |p_i - \pi_i|$. In

particolare si mostrerà come varia H^2 sul luogo dei punti ω_δ dello spazio parametrico Ω in cui $\Delta = \delta$, nonché come varia Γ su ω_δ . Si ricaveranno anche le variazioni di Δ sul luogo dei punti ω_η dello spazio parametrico in cui $H = \eta$, nonché sul luogo dei punti ω_γ in cui $\Gamma = \gamma$. Nel presente lavoro si verificherà inoltre se il test basato su X^2 è adeguato quando si vogliono caratterizzare le alternative con la funzione Δ . Partendo dalla constatazione che su ω_δ la differenza fra $\max H^2$ e $\min H^2$ cresce al crescere di k , si riuscirà a spiegare anche il perché del considerevole aumento, all'aumentare di k , delle numerosità campionarie riscontrate in [1]. Ciò sarà sufficiente per ritenere inadeguato il test basato su X^2 nel caso in cui sia necessario caratterizzare le alternative, invece che con la consueta funzione H^2 , tramite la funzione Δ . Il lavoro porta così alla conclusione che in questo ultimo caso sarà forse meglio basare il test su una statistica analoga a Δ come è ad esempio la statistica

$$Z = \max \left\{ \frac{|n_i - n \pi_i|}{\sqrt{n \pi_i}} ; i = 1, 2, \dots, k \right\};$$

* Lavoro sostenuto finanziariamente anche con il supporto del ministero della Pubblica Istruzione.

** Libera Università degli Studi di Trento - Facoltà di Economia e Commercio.

dove n è la numerosità campionaria ed n_i indica la frequenza osservata nella classe i^{ma} della multinomiale.

2. Funzioni di distanza

Si abbia una multinomiale a k classi con probabilità (p_1, p_2, \dots, p_k) e con numero di prove n . Lo spazio parametrico Ω può considerarsi un sottospazio dello spazio euclideo k -dimensionale E^k le cui coordinate (p_1, \dots, p_k) sono

tali che $\sum_1^k p_i = 1, p_i \geq 0$ ($i = 1, 2, \dots, k$).

Per misurare la distanza di un generico punto (p_1, p_2, \dots, p_k) da un prefissato punto di Ω , le cui coordinate si indicheranno con $(\pi_1, \pi_2, \dots, \pi_k)$, esistono diversi criteri. Il più impiegato consiste nel calcolare la media

quadratica ponderata delle differenze relative assolute $\zeta_i = \frac{|p_i - \pi_i|}{\pi_i}$

con pesi π_i , data dall'espressione

$$H = \sqrt{\sum \left(\frac{p_i - \pi_i}{\pi_i} \right)^2 \cdot \pi_i} = \sqrt{\sum \frac{(p_i - \pi_i)^2}{\pi_i}} \quad (1)$$

Un altro tipo di media delle differenze relative assolute potrebbe essere la media aritmetica ponderata data dall'espressione

$$\Gamma = \sum \zeta_i \cdot \pi_i = \sum |p_i - \pi_i| \quad (2)$$

Un criterio del tutto diverso dalla (1) e dalla (2) è stato introdotto in [1] ed è dato dalla funzione

$$\Delta = \max \{ \zeta_i; i = 1, 2, \dots, k \} \quad (3)$$

Dal punto di vista formale tutti e tre i criteri sono ben definiti. La (1) e la (2), essendo delle medie, non tengono conto dei valori che possono essere assunti dalle singole ζ_i in corrispondenza ad un valore prefissato, rispettivamente, di H e di Γ . Vedremo in seguito che le singole ζ_i possono assumere valori di gran lunga più elevati dei valori prefissati di H e di Γ .

La (3) effettua un controllo delle singole deviazioni delle p_i da π_i . Il significato della (3) è immediato. Infatti, se $\Delta \geq \delta$ significa che almeno una differenza relativa assoluta è maggiore o uguale a δ . Se $\Delta = \delta$ significa che vi è almeno una ζ_i uguale a δ e che nessuna è maggiore di δ . Se $\Delta < \delta$ significa che tutte le differenze relative assolute sono inferiori a δ .

3. Variazioni di H e di Γ su ω_δ

Si indichi con $\zeta_{(1)}$ e con $\zeta_{(k)}$ rispettivamente la più piccola e la più grande fra le ζ_i . Dalle proprietà delle medie potenziate si deduce che

$$\zeta_{(1)} \leq \Gamma \leq H \leq \zeta_{(k)} = \Delta \quad (4)$$

Si considerino ora i punti dello spazio parametrico giacenti su ω_δ . Dalla (4) si ricava che su ω_δ si ha l'uguaglianza $\Delta = \delta$ e che vale la relazione $\Gamma \leq H \leq \delta$.

Per studiare le variazioni di Γ e H su ω_δ faremo, per semplicità, l'ipotesi che sotto H_0 si abbia

$$\pi_1 = \pi_2 = \dots = \pi_k = \frac{1}{k} .$$

Cominciamo ad esaminare le variazioni di Γ su ω_δ . Dalla (2) si ricava la scomposizione che segue:

$$\Gamma = \sum |p_i - 1/k| = \sum_{(p_i \geq 1/k)} (p_i - 1/k) + \sum_{(p_i < 1/k)} (1/k - p_i) .$$

Dovendo essere $\sum_1^k (p_i - 1/k) = 0$, si avrà

$$\sum_{(p_i \geq 1/k)} (p_i - 1/k) = - \sum_{(p_i < 1/k)} (p_i - 1/k) .$$

Per comodità di scrittura si ponga ora :

$$\Gamma_1 = \sum_{(p_i \geq 1/k)} (p_i - 1/k) \text{ e } \Gamma_2 = \sum_{(p_i < 1/k)} (1/k - p_i) .$$

Risulta pertanto $\Gamma_1 = \Gamma_2$ ed inoltre $\Gamma = \Gamma_1 + \Gamma_2$. (5)
 Pertanto massimizzare (minimizzare) Γ equivale a massimizzare (minimizzare) Γ_1 oppure Γ_2 .

Minimo di Γ su ω_δ

Per studiare l'andamento di Γ su ω_δ bisogna tener presente che almeno uno scarto relativo $|p_i - 1/k| / \frac{1}{k}$ è uguale a δ . Dal momento che siamo alla ricerca del minimo di Γ , si ipotizzerà di avere, senza perdere in generalità, un solo scarto relativo pari a δ e inoltre si ipotizzerà che esso sia positivo.

Ne consegue che $\min_{\omega_\delta} \Gamma_1 = \frac{1}{k} \delta$ e che si raggiunge se non vi sono altri scarti positivi.

Dall'uguaglianza $\Gamma_1 = \Gamma_2$ consegue che anche $\min_{\omega_\delta} \Gamma_2 = \frac{1}{k} \delta$ e quindi

$$\min_{\omega_\delta} \Gamma = \frac{2}{k} \delta . \tag{6}$$

Si noti che l'uguaglianza $\Gamma_2 = \sum_{(p_i < 1/k)} (1/k - p_i) = \frac{1}{k} \delta$ si può conseguire

in diversi modi. Ad esempio, si può avere una sola differenza $(1/k - p_i)$ uguale a $\frac{1}{k} \delta$ oppure avere $(k-1)$ scarti $(1/k - p_i) \geq 0$ la cui somma è $\frac{1}{k} \delta$.

Si noti inoltre che $\min \Gamma$ è inversamente proporzionale al numero k delle classi della multinomiale.

Massimo di Γ su ω_δ

Bisogna distinguere fra k pari e k dispari. Se k è pari su ω_δ è possibile ottenere che tutti gli scarti relativi siano uguali al massimo consentito δ . Ciò si realizza con $k/2$ scarti relativi positivi e $k/2$ scarti relativi negativi.

Consegue che per k pari $\max \Gamma = \delta$. Per k dispari non si possono avere k scarti relativi assoluti uguali a δ . Dal vincolo $\Gamma_1 = \Gamma_2$ e dal vincolo

$$\frac{|p_i - 1/k|}{\frac{1}{k}} \leq \delta \quad \text{deriva che} \quad \max_{\omega_\delta} \Gamma_1 = \frac{k-1}{2} \frac{\delta}{k} \quad \text{e che si può raggiungere}$$

se vi sono almeno $\frac{k-1}{2}$ scarti positivi. Supponiamo per assurdo che

$$\Gamma_1 > \frac{k-1}{2} \frac{\delta}{k}. \quad \text{Ciò si può realizzare se vi sono almeno} \quad \frac{k-1}{2} + 1$$

scarti positivi. Ne consegue che devono esservi allora al più $\frac{k-1}{2}$ scarti negativi. Quand'anche ciascuno di questi raggiungesse in valore assoluto il massimo consentito δ , la loro somma sarebbe inferiore a Γ_1 , ma ciò non è possibile in quanto $\Gamma_1 = \Gamma_2$.

$$\text{In definitiva} \quad \max_{\omega_\delta} \Gamma_1 = \frac{k-1}{2} \frac{\delta}{k} \quad \text{e quindi} \quad \max_{\omega_\delta} \Gamma = \frac{k-1}{k} \delta. \quad (7)$$

Deriva da tutto quanto precede che su ω_δ la funzione Γ oscilla da un valore minimo di $\delta \cdot \frac{2}{k}$ ad un valore massimo pari a δ o $\delta \cdot \frac{k-1}{k}$. Si noti come all'aumentare di k la differenza fra $\max_{\omega_\delta} \Gamma$ e $\min_{\omega_\delta} \Gamma$ aumenti.

Si analizzerà ora come varia H^2 su ω_δ . Nel caso in cui $\pi_i = 1/k$ ($i = 1, 2, \dots, k$)

