

Verifica di ipotesi e p-value

Un'introduzione minimale

Luca La Rocca¹

Dipartimento di Scienze Fisiche, Informatiche e Matematiche
Università degli Studi di Modena e Reggio Emilia

Insegnamento di Analisi Statistica dei Dati
Corsi di Laurea Magistrale in Informatica e Matematica
Anno Accademico 2018/2019

¹<http://personale.unimore.it/rubrica/dettaglio/llarocca>

Ipotesi nulla

Dato un modello statistico, indicizzato dal parametro $\theta \in H$, per il dato $z \in \mathcal{Z}$, si dice **ipotesi statistica** un suo sottomodello (senz'altro individuato da un sottoinsieme H_0 di H).

Un'ipotesi $H_0 \subset H$ si dice **ipotesi nulla** quando rappresenti uno “status quo” contro il quale si cerca evidenza nel dato; riterremo $\theta \in H_0$ sino a prova contraria (fornita da z).

Per esempio, se consideriamo il **modello esponenziale** per i tempi di sopravvivenza non censurati della tabella 1.4, nel testo di riferimento, supponendoli i.i.d. $\text{Exp}(1/\mu)$, può interessarci come ipotesi nulla

$$H_0 : \mu = 1000 \quad (\text{giorni})$$

individuata dal singoletto $\{\mu_0\} = \{1000\}$ di $H = \mathbb{R}_+^* \dots$

Ipotesi semplici e composite

... si dice **semplice** un'ipotesi statistica individuata da un singolo valore del parametro e **composita** un'ipotesi statistica che non sia semplice.

Per esempio, se consideriamo $X \sim \text{Binom}(m, \pi)$ e $Y \sim \text{Binom}(n, \psi)$, indipendenti, per i conteggi della tabella 3.1, nel testo di riferimento, definito il **rapporto dei pronostici** $\rho = \{\pi/(1 - \pi)\} / \{\psi/(1 - \psi)\}$, potrebbe interessarci come ipotesi nulla

$$H_0 : \rho = 1$$

individuata dal sottospazio parametrico $\{(\pi, \psi) \in]0, 1[^2 : \pi = \psi\}$.

Discrepanza dall'ipotesi nulla

Supponiamo che $d_0(z)$ quantifichi la **discrepanza** tra H_0 e z , nel senso che $d_0(z) = 0$ se z è perfettamente compatibile con H_0 , mentre $d_0(z) < \underline{d} < 0$ o $d_0(z) > \overline{d} > 0$ indicano scarsa compatibilità.

Avremo **tipicamente**

$$d_0(z) = \inf_{\theta \in H_0} d(\theta, z),$$

o più semplicemente $d_0(z) = d(\theta_0, z)$ se $H_0 = \{\theta_0\}$, dove $d(\theta, z)$ quantifica la discrepanza tra θ e z (con $d(\hat{\theta}(z), z) = 0$ per un opportuno stimatore $\hat{\theta}$ per θ come in particolare quello di massima verosimiglianza).

Nell'esempio del **modello esponenziale**, possiamo prendere

$$d(\mu, x_{1:n}) = \frac{\bar{x}_n - \mu}{\mu} = \frac{\bar{x}_n}{\mu} - 1,$$

di modo che dati scarsamente compatibili con μ_0 corrisponderanno a valori particolarmente bassi o alti della **statistica test** $n\bar{X}_n/\mu_0$ (ottenuta dal pivot $n\bar{X}_n/\mu \sim \text{Gamma}(n, 1)$ ponendo $\mu = \mu_0$).

Valori “estremi” della statistica test ci forniranno evidenza “sufficiente” per **rifiutare** H_0 ; altrimenti, visto che $\theta \in H_0$ sino a prova contraria, finiremo per **accettare** H_0 (almeno provvisoriamente).

Regione di rifiuto

Diremo **regione di rifiuto** l'insieme dei dati scarsamente compatibili con l'ipotesi nulla:

$$\mathcal{R} = \{z \in \mathcal{Z} \mid d_0(z) < \underline{d} \text{ o } d_0(z) > \bar{d}\}$$

nel **caso bilaterale** o

$$\mathcal{R} = \{z \in \mathcal{Z} \mid d_0(z) < \underline{d}\}$$

nel **caso unilaterale sinistro** e

$$\mathcal{R} = \{z \in \mathcal{Z} \mid d_0(z) > \bar{d}\}$$

nel **caso unilaterale destro**.

Ipotesi alternativa

Si dice **ipotesi alternativa** il complemento dell'ipotesi nulla in H :
 $H_1 = H \setminus H_0$.

Nell'esempio del **modello esponenziale**, avremo

$$\mathcal{R} = \{x_{1:n} \in \mathbb{R}_+^n \mid n\bar{x}_n/\mu_0 < \underline{g}_n \text{ o } n\bar{x}_n/\mu_0 > \bar{g}_n\},$$

se $H_1 = \{\mu \in \mathbb{R}_+^* \mid \mu \neq \mu_0\}$, cioè nel caso bilaterale, oppure

$$\mathcal{R} = \{x_{1:n} \in \mathbb{R}_+^n \mid n\bar{x}_n/\mu_0 > \bar{g}_n\},$$

se $H_1 = \{\mu \in \mathbb{R}_+^* \mid \mu > \mu_0\}$, cioè nel caso unilaterale destro;
in questo caso $H = [\mu_0, \infty[$ o $H_0 =]0, \mu_0]$.

Analogamente nel caso unilaterale sinistro. Si noti che è l'ipotesi alternativa a determinare il tipo di regione di rifiuto.

Errori di prima e seconda specie

Si dice **errore di prima specie** l'errore commesso quando $\theta \in H_0$; poiché $\theta \in H_0$ sino a prova contraria, cercheremo di controllare la probabilità di commetterlo

$$\alpha = \mathbb{P}_{\theta_0}\{\mathbf{X}_{1:n} \in \mathcal{R}\} = \sup_{\theta \in H_0} \mathbb{P}_{\theta}\{\mathbf{X}_{1:n} \in \mathcal{R}\},$$

per esempio richiedendo $\alpha = 0.05$ (**livello di significatività**).

Si dice **errore di seconda specie** l'errore commesso quando $\theta \in H_1$; poiché tipicamente $\sup_{\theta \in H_1} \mathbb{P}_{\theta}\{\mathbf{X}_{1:n} \in \mathcal{R}\} = \alpha$, dobbiamo accontentarci di valutare la **potenza** della procedura di verifica di ipotesi

$$\beta = \mathbb{P}_{\theta_1}\{\mathbf{X}_{1:n} \in \mathcal{R}\}$$

in corrispondenza di un particolare valore alternativo per θ .

Il p-value

In pratica si preferisce spesso calcolare

$$p = \mathbb{P}\{d_0(Z) > d_0(z^\bullet)\}$$

in caso di alternativa unilaterale destra e

$$p = \mathbb{P}\{d_0(Z) < d_0(z^\bullet)\}$$

in caso di alternativa unilaterale sinistra, dove z^\bullet è il dato osservato, raddoppiando il valore ottenuto in caso di alternativa bilaterale.

In questo modo si ottiene il **minimo valore di α per cui si rifiuta H_0** e si finisce per rifiutare H_0 quando il valore p , detto anche **livello di significatività osservato**, è “piccolo”.

Un p-value


Nell'esempio del **modello esponenziale** per i tempi di sopravvivenza non censurati della tabella 1.4, nel test di riferimento, considerando per semplicità l'alternativa unilaterale $\mu > \mu_0$, possiamo calcolare

$$p = \mathbb{P}_{\mu_0}(n\bar{X}_n/\mu_0 > n\bar{x}_n^\bullet/\mu_0) = 0.1819,$$

dove $n\bar{x}_n^\bullet/\mu_0 = 53.146$ è il valore osservato della statistica test $n\bar{X}_n/\mu_0$ ($n = 47$, $\bar{x}_n^\bullet = 1130.766$ e $\mu_0 = 1000$).

Il p-value così ottenuto non è abbastanza piccolo da rifiutare H_0 , perché dovremmo accettare un errore di prima specie del 18%; lo sarebbe ancora meno con l'alternativa bilaterale ($p = 0.3638$).

Test statistic (value and distribution)



Il test esatto di Fisher

Nel caso dell'ipotesi nulla

$$H_0 : \rho = 1$$

sul **rapporto dei pronostici** $\rho = \{\pi/(1 - \pi)\} / \{\psi/(1 - \psi)\}$
relativo a $X \sim \text{Binom}(m, \pi)$ e $Y \sim \text{Binom}(n, \psi)$, indipendenti,
si può usare come statistica test $X \mid X + Y = x^\bullet + y^\bullet$
la cui distribuzione, se $\rho = 1$, è ipergeometrica
($x^\bullet + y^\bullet$ estrazioni, $m + n$ biglie in tutto, m biglie bianche)
qualunque sia il valore di $\pi = \psi$.

Significatività asintotica

Se $T_n = g_n(X_{1:n})$ è uno stimatore asintoticamente normale (di ordine $1/\sqrt{n}$) per $\xi = h(\theta)$, con errore standard asintotico $\sqrt{V_n/n}$, possiamo usare

$$Z_n = \frac{T_n - \xi_0}{\sqrt{V_n/n}} \approx \text{Norm}(0, 1)$$

come statistica test per calcolare un **p-value approssimato** contro l'ipotesi nulla $h(\theta) = \xi_0$.

Troveremo $p = 2\{1 - \Phi(|z_n^\bullet|)\}$, con l'**alternativa bilaterale** $h(\theta) \neq \xi_0$, dove z_n^\bullet è il valore osservato di Z_n e Φ la funzione di ripartizione normale standard.

Dualità con gli intervalli di confidenza

Se $d_0(z) = d(\theta_0, z)$ e $d(\theta, Z)$ è un pivot, la cui inversione produce l'intervallo di confidenza $[\underline{T}, \bar{T}]$ per θ , al livello γ , allora

$$Z \in \mathcal{R} \quad \Leftrightarrow \quad \theta_0 \notin [\underline{T}, \bar{T}]$$

e $\mathbb{P}_{\theta_0}\{Z \in \mathcal{R}\} = 1 - \gamma$.

Si noti che $\mathbb{P}_{\theta}\{\underline{T} \leq \theta \leq \bar{T}\} = \gamma$ è un'affermazione probabilistica relativa a un evento auspicabilmente osservato, valida per qualunque valore del parametro θ , mentre $p = \mathbb{P}\{d_0(Z) > d_0(z^\bullet)\}$ è un'affermazione probabilistica relativa a un evento non osservato, valida per un valore del parametro che stiamo mettendo in dubbio...

Una prassi discutibile

... ciò nonostante si è affermato l'uso di richiedere $p < 0.05$ come condizione per sostenere la validità di una nuova scoperta.

Al riguardo, occorre tenere presente che ci sono buone ragioni per abbassare la soglia di un ordine di grandezza

<https://www.nature.com/articles/s41562-017-0189-z>

e più in generale per abbandonare del tutto la prassi in questione

<http://andrewgelman.com/2017/09/26/abandon-statistical-significance/>

ridimensionando il ruolo del p-value nell'analisi dei dati.

Due caveat e uno spunto di lettura

- Il p-value **non è** la probabilità che l'ipotesi nulla sia vera.
- Il p-value **non può** fornire evidenza in favore dell'ipotesi nulla.
- The American Statistical Association's statement on p-values

<http://amstat.tandfonline.com/doi/abs/10.1080/00031305.2016.1154108#.WfKCl4bONE4>

is a recent synthesis on null hypothesis significance testing.