

TIPS E RIFLESSIONI SULLA LA REGRESSIONE MULTILINEARE

Introduzione

Tutti i fenomeni collettivi complessi (economici, demografici, meteorologici, naturali, quelli legati all'inquinamento ...) sono strettamente collegati, all'interno e all'esterno, ad una complessa rete di relazioni, per cui studiare un fenomeno con una relazione a due sole variabili è spesso senza senso, anche se, e ne siamo certi, l'usare più variabili, non risolverà fino in fondo il problema, pur aumentando la *verisimiglianza popperiana*.

Una volta ammesso che il fenomeno ha relazioni interne fra variabili anche complesse, scelta la variabile dipendente y (variabile *risposta*), es., prezzi, consumi, crescita..., ci poniamo il problema di come essa vari in media al variare di altri caratteri che scegliamo (*variabili indipendenti esplicative o regressori*).

Questo studio, che è una rappresentazione matematica della realtà o *modello della realtà*, viene denominato *regressione lineare multipla*, se pensiamo che ciascun valore osservato della variabile dipendente o risposta sia esprimibile come funzione lineare dei corrispondenti valori delle *variabili indipendenti esplicative*, più un termine residuo ε per indicare che il modello *non può* riprodurre la *realtà*. La *linearità* quindi è relativa non alle variabili esplicative (lineari o non lineari), ma ai *coefficienti* della relazione. **Naturalmente tutti i modelli sono falsi, ma spesso utili.**

Si voglia trovare così la relazione fra k variabili indipendenti (x_1, x_2, \dots, x_k) e la variabile dipendente y . Il modello è un'equazione del tipo:

Modello di regressione multipla con k variabili indipendenti:

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + e_i$$

The diagram shows the equation $Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + e_i$ with arrows pointing to specific terms from labels in pink boxes: 'Y-intercetta' points to β_0 , 'Coefficiente di regressione parziale' points to β_1 , and 'Errore casuale' points to e_i .

Di Y e delle variabili X_1, X_2, \dots, X_k ho n valori sperimentali (serie di dati) per ciascuna variabile. In termini matriciali:

1 - \mathbf{Y} (i suoi elementi sono indicati con il generico y_i) è un vettore di osservazioni (n righe x 1 colonna) sulla variabile dipendente o risposta.

2 - \mathbf{X} è una matrice ($n \times k$) di osservazioni sui K regressori o variabili indipendenti o esplicative. La matrice contiene anche una colonna supplementare (la prima) composta da n valori tutti uguali a uno in corrispondenza dell'intercetta del modello. Il modello geometricamente corrisponde ad un iperpiano a k dimensioni.

3 - $\boldsymbol{\beta}$ è un vettore con $(k + 1)$ *parametri incogniti*; il primo è $\beta_0 = 1$

4 - $\boldsymbol{\varepsilon}$ (e nell'espressione del modello) è un vettore ($n \times 1$) di disturbi stocastici o termini dell'errore.

Le matrici e i vettori sono così definiti

$$y = \begin{pmatrix} y_1 \\ y_2 \\ y_3 \\ \vdots \\ y_n \end{pmatrix}_{(n \times 1)} \quad X = \begin{pmatrix} 1 & x_{11} & x_{12} & \cdot & \cdot & x_{1k} \\ 1 & x_{21} & x_{22} & \cdot & \cdot & x_{2k} \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ 1 & x_{n1} & x_{n2} & \cdot & \cdot & x_{nk} \end{pmatrix}_{(n \times (k+1))}$$

$$\beta = \begin{pmatrix} \beta_c \\ \beta_1 \\ \beta_2 \\ \cdot \\ \cdot \\ \beta_k \end{pmatrix}_{(k+1) \times 1} \quad \varepsilon = \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \varepsilon_3 \\ \cdot \\ \cdot \\ \varepsilon_n \end{pmatrix}_{(n \times 1)}$$

N.B.

La matrice X ha la prima colonna unitaria nel caso in cui si consideri un modello con intercetta β nel sistema di riferimento multidimensionale

Il fatto di non conoscere gli n errori (e o ϵ) impedisce di fatto la conoscenza del valore reale dei coefficienti \mathbf{B} ; ci accontenteremo di ricavare solo le loro stime \mathbf{b} . In tal caso lavoreremo su la seguente espressione semplificata del modello:

I coefficienti del modello sono stimati sulla base di dati campionari

Modello di regressione multipla con k variabili indipendenti :

Stima (o valore previsto di Y)

Stima dell'intercetta

Stima dei coefficienti di regressione parziale

$$\hat{Y}_i = b_0 + b_1 X_{1i} + b_2 X_{2i} + \dots + b_k X_{ki}$$

Si ha così un sistema di n equazioni esprimibile nel linguaggio matriciale con l'espressione condensata:

$$\mathbf{Y} = \mathbf{X} \mathbf{b}$$

La scelta e il tipo delle variabili esplicative (x , x^2 , $1/x$ ecc.) viene suggerita e dalle teorie relative al fenomeno in gioco e dal buonsenso. Si può anche usare una serie di scatterplot (matrice di scatterplot) fra ciascuna coppia di variabili osservando le loro relazioni (dirette o inverse, lineari o non lineari, l'eventuale presenza di outliers e la forza della loro relazione.

Nel prossimo tip faremo degli esempi applicativi.