

## MODELLO DI REGRESSIONE LINEARE: principali simboli e formule.

Nota Bene: dopo la breve introduzione iniziale in questa pagina, la pagina seguente è una rassegna schematica dei principali simboli e formule visti a lezione ed applicati ad esercitazione anche con la lettura del tabulato Excel.

Introduzione.

Fissato il prezzo di vendita  $x_t$  di un prodotto per tutto il mese corrente, il valore del fatturato  $y_t$  alla fine dello stesso mese **non è predeterminato** in funzione del prezzo  $x_t$  **tramite una funzione matematica** quale p. es., per semplicità, una retta o simili

$$y_t = \beta_0 + \beta_1 x_t \quad (1)$$

Ciò perché il valore del fatturato  $y_t$  alla fine mese corrente è in realtà **uno dei valori possibili di una v.a.**  $Y_t$ . Infatti il valore  $y_t$  osservato alla fine del mese è influenzato da tante altre variabili i cui valori **non possono essere né prefissati né conosciuti** dall'azienda venditrice del prodotto. Quindi l'azienda **non può conoscere con certezza** il valore fatturato  $y_t$  del mese **prima** che sia arrivata la fine del mese stesso, ossia il fatturato è una **v.a.**  $Y_t$ .

Che il valore del fatturato  $y_t$  alla fine mese corrente sia in effetti uno dei valori possibili di una v.a.  $Y_t$  risulta anche dal fatto che se si rappresentano su un sistema di assi cartesiani le coppie (prezzo, fatturato) ovvero le coppie  $(x_t, y_t)$  ( $t = 1, 2, \dots, n$ ) relative a  $n$  mesi passati, si vede che, in generale, tali coppie si dispongono nel piano cartesiano secondo **un grafico che non soddisfa la definizione matematica di funzione**, si ha bensì un **diagramma di dispersione** (vedere i grafici mostrati a lezione dai docenti, o le fotocopie dei lucidi presso Yellow Print, od anche la figura nel libro di Ross a pag. 59).

Ciò premesso, **con il modello di regressione lineare** si vogliono raggiungere i due obiettivi seguenti:

(A) **non abbandonare del tutto** la comoda ed utile nozione di funzione matematica quale è, per semplicità, la funzione  $\beta_0 + \beta_1 x_t$  nella (1) di cui sopra, e si vuole però anche:

(B) **tenere conto che il fatturato è in realtà una v.a.**  $Y_t$  il cui valore  $y_t$  al tempo  $t$  non è determinato come funzione matematica  $\beta_0 + \beta_1 x_t$  (o altra) del prezzo  $x_t$  fissato dall'azienda.

Si considera allora un modello matematico alternativo alla funzione  $y_t = \beta_0 + \beta_1 x_t$  (1) di cui sopra, ovvero si considera il modello matematico-probabilistico, detto "modello di regressione lineare", dato da

$$Y_t = \beta_0 + \beta_1 x_t + \varepsilon_t \quad (2)$$

dove  $\varepsilon_t$ , e quindi  $Y_t$ , sono v.a. che soddisfano certe ipotesi che implicano l'importante conseguenza che

$$E(Y_t) = \beta_0 + \beta_1 x_t \quad (3)$$

Con le formule (2) e (3) si raggiungono i due obiettivi (A) e (B) di cui sopra. Infatti, da una parte, con la formula (2), **né** il fatturato osservato  $y_t$  **né** la v.a. fatturato  $Y_t$  stessa sono determinati come funzione matematica  $\beta_0 + \beta_1 x_t$  del prezzo  $x_t$  fissato dall'azienda (ciò è dovuto alla presenza della v.a.  $\varepsilon_t$ ).

Dall'altra parte però, con la formula (3), si ha che **il fatturato medio atteso**  $E(Y_t)$ , ovvero **il fatturato in media, è determinato** come **funzione matematica**  $\beta_0 + \beta_1 x_t$  del prezzo fissato  $x_t$  dall'azienda (ciò è ancora dovuto alla presenza della v.a.  $\varepsilon_t$  che, come specificato più avanti, è tale che  $E(\varepsilon_t) = 0$ ).

Del modello di regressione lineare si danno in quanto segue: l'equazione, le ipotesi, le conseguenze delle ipotesi, le stime puntuali dei parametri e la retta stimata, la scomposizione della varianza totale ed il coefficiente di determinazione.

**EQUAZIONE DEL MODELLO DI REGRESSIONE LINEARE**

$$Y_t = \beta_0 + \beta_1 x_t + \varepsilon_t \quad (t = 1, 2, \dots, n), \text{ dove}$$

- $x_t$  è una variabile non aleatoria in quanto i suoi valori possono essere prefissati per ogni  $t$
- $\beta_0$  e  $\beta_1$  sono due costanti o parametri non noti da stimare sulla base di  $n$  coppie di valori osservati  $(x_t, y_t)$  ( $t = 1, 2, \dots, n$ )
- $\varepsilon_t$  è una variabile aleatoria per ogni  $t = 1, 2, \dots, n$  detta v.a. "errore" o "residuo" che soddisfa le ipotesi del modello di regressione lineare

**IPOTESI DEL MODELLO DI REGRESSIONE LINEARE**

- $E(\varepsilon_t) = 0$
- $V(\varepsilon_t) = \sigma^2$  (parametro non noto da stimare, costante per ogni  $t = 1, 2, \dots, n$ )
- $Cov(\varepsilon_t, \varepsilon_s) = 0$  ( $\forall (t, s), t \neq s$ ) (ipotesi di indipendenza correlativa, o di non correlazione, delle v.a.  $\varepsilon_t$  che è verificata se, p. es., si assume che le v.a.  $\varepsilon_t$  siano stocasticamente indipendenti)
- $\varepsilon_t \sim N(0; \sigma^2)$  ( $t = 1, 2, \dots, n$ ) con le v.a.  $\varepsilon_t$  stocasticamente indipendenti

**CONSEGUENZE DELLE IPOTESI DEL MODELLO DI REGRESSIONE LINEARE**

- $E(\varepsilon_t) = 0$  e  $Y_t = \beta_0 + \beta_1 x_t + \varepsilon_t \Rightarrow E(Y_t) = \beta_0 + \beta_1 x_t$
- $V(\varepsilon_t) = \sigma^2$  e  $Y_t = \beta_0 + \beta_1 x_t + \varepsilon_t \Rightarrow V(Y_t) = \sigma^2$
- $\varepsilon_t \sim N(0; \sigma^2)$  (stoc. indep.  $t = 1, 2, \dots, n$ ) e  $Y_t = \beta_0 + \beta_1 x_t + \varepsilon_t \Rightarrow Y_t \sim N(\beta_0 + \beta_1 x_t; \sigma^2)$  (stoc. indep.  $t = 1, 2, \dots, n$ )

**STIME PUNTUALI DEI PARAMETRI e RETTA STIMATA**

- $\hat{\beta}_1 = \frac{\sigma_{XY}}{s_X^2}$  (dove  $\sigma_{XY}$  e  $s_X^2$  sono calcolati con le coppie osservate  $(x_t, y_t)$   $t = 1, 2, \dots, n$ )
- $\hat{\beta}_0 = \bar{y}_n - \hat{\beta}_1 \bar{x}_n$  (dove  $\bar{y}_n$  e  $\bar{x}_n$  sono calcolati con le coppie osservate  $(x_t, y_t)$   $t = 1, 2, \dots, n$ )
- $\hat{y}_t = \hat{E}(Y_t) = \hat{\beta}_0 + \hat{\beta}_1 x_t$  ( $t = 1, 2, \dots, n$ )
- $\hat{\sigma}^2 = \frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{n - 2}$

**SCOMPOSIZIONE DELLA VARANZA TOTALE  
E COEFFICIENTE DI DETERMINAZIONE  $R^2$**

- $\sum_{t=1}^n (y_t - \bar{y}_n)^2 = \text{varianza totale}$
- $\sum_{t=1}^n (y_t - \hat{y}_t)^2 = \text{varianza residua (o varianza non spiegata)}$
- $\sum_{t=1}^n (\hat{y}_t - \bar{y}_n)^2 = \text{varianza spiegata}$
- $$\sum_{t=1}^n (y_t - \bar{y}_n)^2 = \sum_{t=1}^n (y_t - \hat{y}_t)^2 + \sum_{t=1}^n (\hat{y}_t - \bar{y}_n)^2$$
- $$R^2 = \frac{\sum_{t=1}^n (\hat{y}_t - \bar{y}_n)^2}{\sum_{t=1}^n (y_t - \bar{y}_n)^2} \quad (0 \leq R^2 = \rho_{XY}^2 \leq 1)$$