
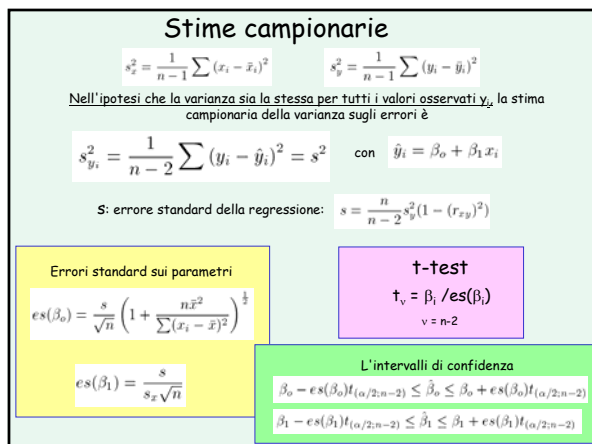


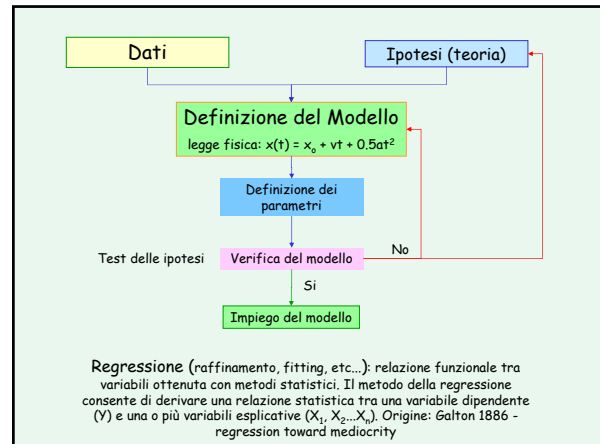


Ulteriori Conoscenze di Informatica e Statistica

Carlo Meneghini

Dip. di fisica - via della Vasca Navale 84,
st. 83 (I piano) tel.: 06 55 17 72 17

meneghini@fis.uniroma3.it



$$\sum_i (y_i^{exp} - \bar{y})^2 = \sum_i (y_i^{th} - \bar{y})^2 + \sum_i (y_i^{exp} - y_i^{th})^2$$

$$SST = SSR + SSE$$

SST= somma dei quadrati della differenza tra dati e valor medio
 SSR= somma dei quadrati degli scarti tra punti teorici e valor medio (sulla retta di regressione)
 SSE= somma dei quadrati degli scarti tra valori sperimentali e teorici

$$R^2 = \frac{SSR}{SST} = \frac{\sum_i (y_i^{th} - \bar{y})^2}{\sum_i (y_i^{exp} - \bar{y})^2}$$

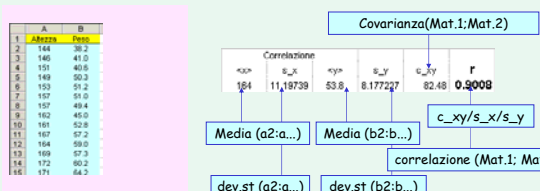
R^2 indica la frazione della varianza dei dati che si può spiegare mediante la curva di regressione

$$r = \frac{C_{xy}}{s_x s_y}$$

$$C_{xy} = \frac{1}{n-1} \sum (x_i - \bar{x})(y_i - \bar{y})$$
 Covarianza

$$s_x = \sqrt{\frac{1}{n-1} \sum (x_i - \bar{x})^2}$$
 Deviazione standard

calcolare:
 $\bar{x}, \bar{y}, s_x, s_y, C_{xy}$

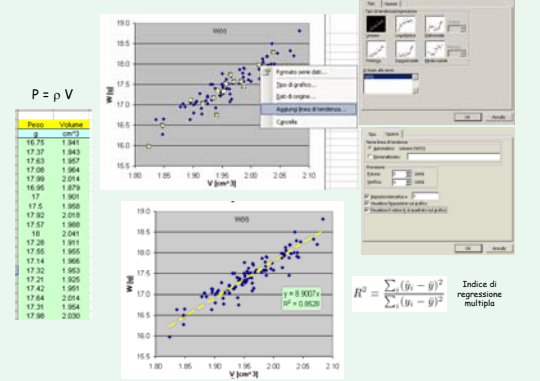


Quanto è significativa la correlazione?

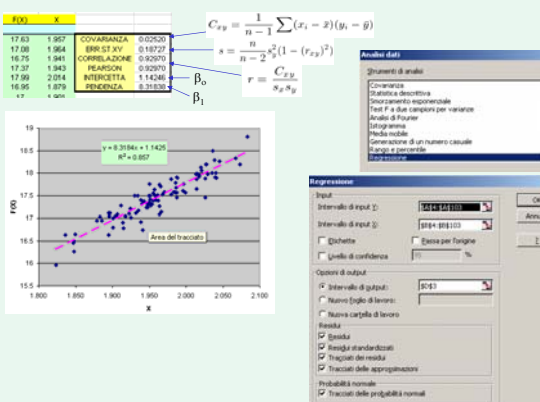
T-test sulla correlazione

$$t_\nu = \frac{r}{\sqrt{\frac{1-r^2}{n-2}}}$$

Intervallo di confidenza per la correlazione



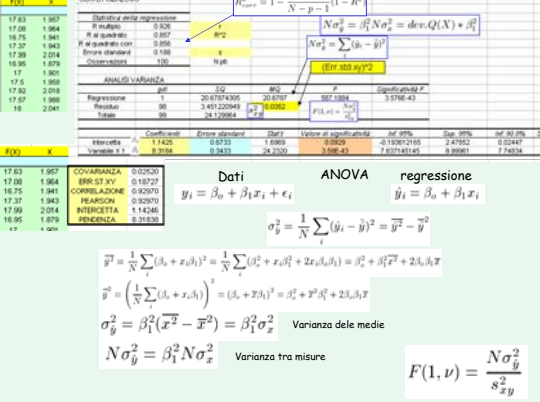
$$R^2 = \frac{\sum_i (y_i - \bar{y})^2}{\sum_i (y_i - \bar{y})^2}$$
 Indice di regressione multipla



$$C_{xy} = \frac{1}{n-1} \sum (x_i - \bar{x})(y_i - \bar{y})$$

$$s = \frac{n}{n-2} s_y^2 (1 - r^2)$$

$$r = \frac{C_{xy}}{s_x s_y}$$



$$R^2_{corr} = 1 - \frac{N-1}{N-p-1} (1 - R^2)$$

$$N\sigma_y^2 = \beta_1^2 N\sigma_x^2 = dev. Q(X) \cdot \beta_1^2$$

$$N\sigma_y^2 = \sum_i (y_i - \bar{y})^2$$

$$N\sigma_x^2 = \sum_i (x_i - \bar{x})^2$$

Dati: $y_i = \beta_0 + \beta_1 x_i + \epsilon_i$
 regressione: $\hat{y}_i = \beta_0 + \beta_1 x_i$

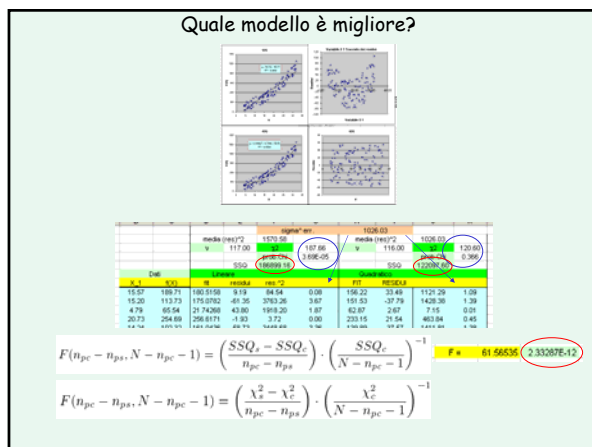
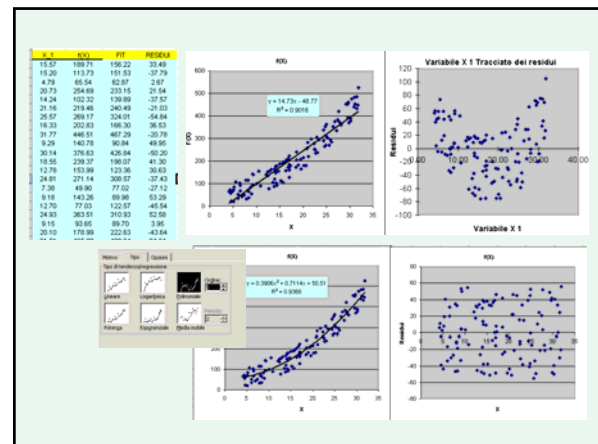
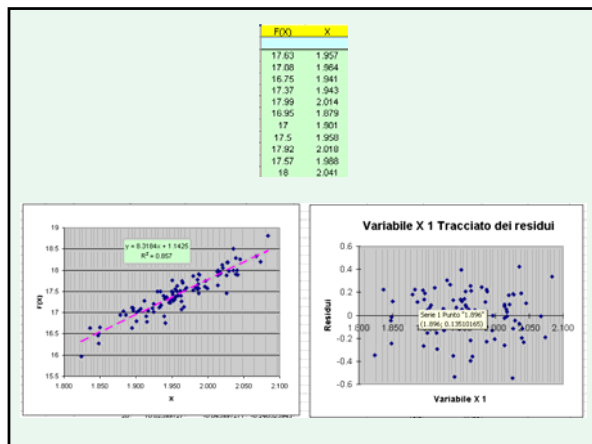
$$\sigma_y^2 = \frac{1}{N} \sum_i (y_i - \bar{y})^2 = \bar{y}^2 - \bar{y}^2$$

$$\bar{y}^2 = \frac{1}{N} \sum_i (\beta_0 + \beta_1 x_i)^2 = \beta_0^2 + 2\beta_0\beta_1\bar{x} + \beta_1^2\bar{x}^2$$

$$\sigma_y^2 = \beta_1^2 (\bar{x}^2 - \bar{x}^2) = \beta_1^2 \sigma_x^2$$
 Varianza delle medie

$$N\sigma_y^2 = \beta_1^2 N\sigma_x^2$$
 Varianza tra misure

$$F(1, \nu) = \frac{N\sigma_y^2}{s_{xy}^2}$$



AIC (Akaike information criteria)

$$AIC = N \log \left(\frac{SSQ_{res}}{N} \right) + 2n_p$$

N = numero di dati
 SSQ_{res} = somma dei quadrati dei residui
 n_p = numero di parametri

Alake, Hirotugu (1974). "A new look at the statistical model identification". *IEEE Transactions on Automatic Control* 19 (6) 716-723.

Criterio: si preferisce il modello con il valore minore di AIC

Correzioni per piccoli N

McQuarrie definition

$$AIC_q = \log \left(\frac{SSQ_{res}}{N - n_p} \right) + \frac{N + n_p}{N - n_p - 2}$$

Burnham definition

$$AIC_c = AIC + \frac{2n_p(n_p + 1)}{N - n_p - 1}$$

McQuarrie, A. D. R. and Tsai, C.-L., 1998. Regression and Time Series Model Selection. World Scientific.

Burnham, K. P. and D. R. Anderson, 2002. Model Selection and Multimodel Inference: A Practical-Theoretic Approach, 2nd ed. Springer-Verlag.

Nota: AIC è un criterio, non un test, non fornisce una valutazione del "rischio" statistico associato ad una scelta piuttosto che ad un'altra.

Fit (regressione) non lineare: χ^2

Ho una serie di osservazioni sperimentali x_i, y_i

Voglio cercare di riprodurre i dati sperimentali mediante una curva teorica:

$$f^{th}(X, p_1, p_2, \dots, p_m)$$

funzione degli x_i e di m parametri p_m i cui valori devono essere determinati. Cerco i valori dei parametri come quelli che minimizzano la funzione:

$$\chi^2_\nu = \sum_{i=1}^N \frac{(f^{th}_i - y_i)^2}{\sigma_i^2}$$

Se la funzione $f(x,p)$ scelta è corretta si ha: $y_i = f(x_i, p_1, p_2, \dots, p_m) + \epsilon_i$

quindi:

$$\chi^2_\nu = \sum_{i=1}^N \frac{(\epsilon_i)^2}{\sigma_i^2} \sim \nu$$

Gradi di libertà: $\nu = m - p - 1$