



**METODI STATISTICI PER LA BIOINGEGNERIA (B)**

**PARTE 12: ULTIME NOTE SULLA  
REGRESSIONE LINEARE**

**A.A. 2024-2025**

**Prof. Martina Vettoretti**



# IL PROBLEMA DEI MINIMI QUADRATI GENERALIZZATI

- Residui non a varianza omogenea e/o a campioni correlati → violate le assunzioni su cui si basa il metodo dei minimi quadrati lineari, ovvero:

$$\text{Var}(\varepsilon_i) = \sigma^2 \quad \forall i = 1, \dots, n$$

$$\text{Cov}(\varepsilon_i, \varepsilon_j) = 0 \quad \forall i \neq j$$



$$\text{Cov}(\boldsymbol{\varepsilon}) = \sigma^2 \cdot \mathbf{I}$$
$$\boldsymbol{\varepsilon} = [\varepsilon_1 \ \varepsilon_2 \ \dots \ \varepsilon_n]^T$$

- Se tali assunzioni risultano violate, possiamo comunque stimare i parametri del modello di regressione lineare, se ipotizziamo di conoscere la matrice di covarianza dei termini  $\varepsilon_i$  a meno di un fattore incognito  $\sigma^2$ :

$$\text{Cov}(\boldsymbol{\varepsilon}) = \sigma^2 \cdot \mathbf{V}$$

- $\sigma^2$  incognito
- $\mathbf{V}$  nota

- Problema dei **minimi quadrati lineari generalizzati**:

$$\hat{\boldsymbol{\beta}} := \underset{\boldsymbol{\beta}}{\text{argmin}} \left( \underbrace{(\mathbf{Y} - \mathbf{X} \cdot \boldsymbol{\beta})^T \mathbf{V}^{-1} (\mathbf{Y} - \mathbf{X} \cdot \boldsymbol{\beta})}_{\text{I quadrati dei residui vengono pesati per } \mathbf{V}^{-1} \rightarrow \text{osservazioni per cui la varianza dell'errore è minore vengono pesati di più}}$$

I quadrati dei residui vengono pesati per  $\mathbf{V}^{-1}$  → osservazioni per cui la varianza dell'errore è minore vengono pesati di più

- Soluzione del problema dei minimi quadrati generalizzati:

$$\hat{\beta} = (X^T V^{-1} X)^{-1} X^T V^{-1} Y$$

- Stima a posteriori di  $\sigma^2$ :

$$\hat{\sigma}^2 = \frac{SSE}{n - m - 1}$$

- Proprietà dello stimatore  $\hat{\beta}$ :

- $E[\hat{\beta}] = \beta$
- $cov(\hat{\beta}) = \hat{\sigma}^2 (X^T V^{-1} X)^{-1}$

- Due strumenti statistici per valutare la presenza di una relazione lineare tra due variabili:

- **Coefficiente di correlazione lineare di Pearson:**

$$\text{Corr}(X, Y) := \frac{\text{Cov}(X, Y)}{\sqrt{\text{Var}(X) \cdot \text{Var}(Y)}}$$

$$r_{X,Y} := \frac{\sum_{i=1}^n (x_i - \bar{x}) \cdot (y_i - \bar{y})}{(n-1)s_x s_y} \leftarrow \text{Stimatore campionario}$$

$s_X, s_Y$ : deviazioni standard campionarie dei campioni osservati per X ed Y rispettivamente ( $x_i, i = 1, \dots, n; y_i, i = 1, \dots, n$ ).

- **Regressione lineare semplice:**

$$Y = \beta_0 + \beta \cdot X + \varepsilon$$

- Che relazione sussiste tra i due?

# LEGAME TRA CORRELAZIONE E REGRESSIONE LINEARE SEMPLICE



- Si può dimostrare che il coefficiente di determinazione  $R^2$  di una regressione lineare semplice tra  $X$  e  $Y$  è equivalente al quadrato del coefficiente di correlazione lineare di Pearson tra  $X$  e  $Y$ ,  $r_{X,Y}$ .

$$R^2 = r_{X,Y}^2$$


- Inoltre si ha:

$$r_{X,Y} = \hat{\beta} \cdot \frac{S_X}{S_Y}$$

# ESEMPIO



- Analizziamo la relazione tra pressione arteriosa sistolica (X) e diastolica (Y) in un campione di 600 individui. Esercizio svolto in Matlab.



$$r^2 = 0.4205$$

$$Y = \beta_0 + \beta \cdot X + \varepsilon$$

$$\hat{\beta}_0 = 25.52$$

$$\hat{\beta} = 0.38$$

$$R^2 = 0.4205$$

$$\hat{\beta} \cdot \frac{S_X}{S_Y} = 0.6485$$

# LEGAME TRA CORRELAZIONE E REGRESSIONE LINEARE MULTIPLA



- Per la regressione lineare multipla, si può dimostrare che il coefficiente di determinazione  $R^2$  è equivalente al quadrato del coefficiente di correlazione lineare di Pearson tra l'outcome reale e quella predetta dal modello.

$$Y = X \cdot \beta + \varepsilon$$


$$\hat{Y} = X \cdot \hat{\beta}$$

$$R^2 = r_{Y, \hat{Y}}^2$$

# ESEMPIO



- Analizziamo la relazione tra pressione arteriosa diastolica ( $Y$ ) e pressione arteriosa sistolica ( $X_1$ ) ed età ( $X_2$ ) in un campione di 600 individui. Esercizio svolto in Matlab.



$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \varepsilon$$

$$\hat{\beta}_0 = 45.68$$

$$\hat{\beta}_1 = 0.42$$

$$\hat{\beta}_2 = -0.41$$

$$r^2 = 0.4885$$

$$R^2 = 0.4885$$



# ESEMPI DI DOMANDE D'ESAME SULLA REGRESSIONE LINEARE

# QUIZ 1



➤ Nel modello di regressione lineare semplice:

$$Y = \beta_0 + \beta \cdot X + \varepsilon$$

se il coefficiente  $\beta$  è negativo, e significativamente diverso da 0, significa che:

- a. Al crescere di  $X$ , il valor medio di  $Y$  aumenta
- b. Al crescere di  $X$ , il valor medio di  $Y$  diminuisce
- c. Al decrescere di  $X$ , il valor medio di  $Y$  diminuisce
- d. Nessuna delle precedenti



# QUIZ 2



- In un modello di regressione lineare che predice la pressione sanguigna diastolica [mmHg], la somma dei residui al quadrato (SSE) risulta pari a 25 [mmHg<sup>2</sup>] e la devianza della pressione sanguigna diastolica (SST) risulta pari a 100 [mmHg<sup>2</sup>]. Che percentuale della devianza della pressione sanguigna diastolica è spiegata dal modello di regressione lineare?
- a. 40%
  - b. 25%
  - c. 75%
  - d. 60%



# QUIZ 3



- Quale dei seguenti metodi di regolarizzazione non consente di ridurre la complessità di un modello di regressione lineare multipla?
- a. La regolarizzazione L2 o Ridge
  - b. La regolarizzazione L1 o LASSO
  - c. La regolarizzazione elastic net
  - d. Nessuna delle precedenti



# DOMANDE APERTE



1. Descrivi il modello di regressione lineare multipla. Come è possibile stimarne i parametri a partire da un campione di  $n$  osservazioni per le variabili coinvolte?
2. Cosa si intende per problema della multicollinearità nella regressione lineare multipla? Descrivi un approccio per mitigarlo.