



METODI STATISTICI PER LA BIOINGEGNERIA

A.A. 2024-2025

Prof. Alessandra Bertoldo

Ing. Mattia De Francisci, Ing. Claudia Tarricone



ESERCIZIO 1

I dati a disposizione per il laboratorio sono stati raccolti per uno studio sull'insorgenza di stress in 20 soggetti affetti da ipertensione

L'obiettivo è investigare se esiste una relazione tra alcune variabili *pressione sanguigna, età, peso, estensione della superficie corporea, anni di ipertensione, battiti cardiaci, durata del sonno notte precedente* e il *livello di stress*



I dati sono contenuti nel file ***data_lab7.mat***, sono presenti:

- **X:** Matrice 2D di dimensioni 20x7 (20 soggetti, 7 variabili)
- **Y:** vettore 20x1 contenente le realizzazioni dell'indice di stress per i 20 soggetti
- **labels:** Array di celle di dimensioni 1x7 contenente i nomi delle variabili
 - **BP:** pressione sanguigna (mmHg)
 - **Age:** età (anni)
 - **Weight:** peso (kg)
 - **BSA:** body surface area (m²)
 - **Dur:** durata dell'ipertensione (anni)
 - **Pulse:** battiti cardiaci (battiti al min)
 - **Sleep hours:** durata del sonno (ore)



- Caricare i dati (**`data_lab7.mat`**).

*NOTA: non viene chiesta l'analisi per la ricerca di valori non utilizzabili (tipo NaN) perchè sono già stati testati e normalizzati tramite **`zscore`**. I dati sono quindi pronti all'uso.*

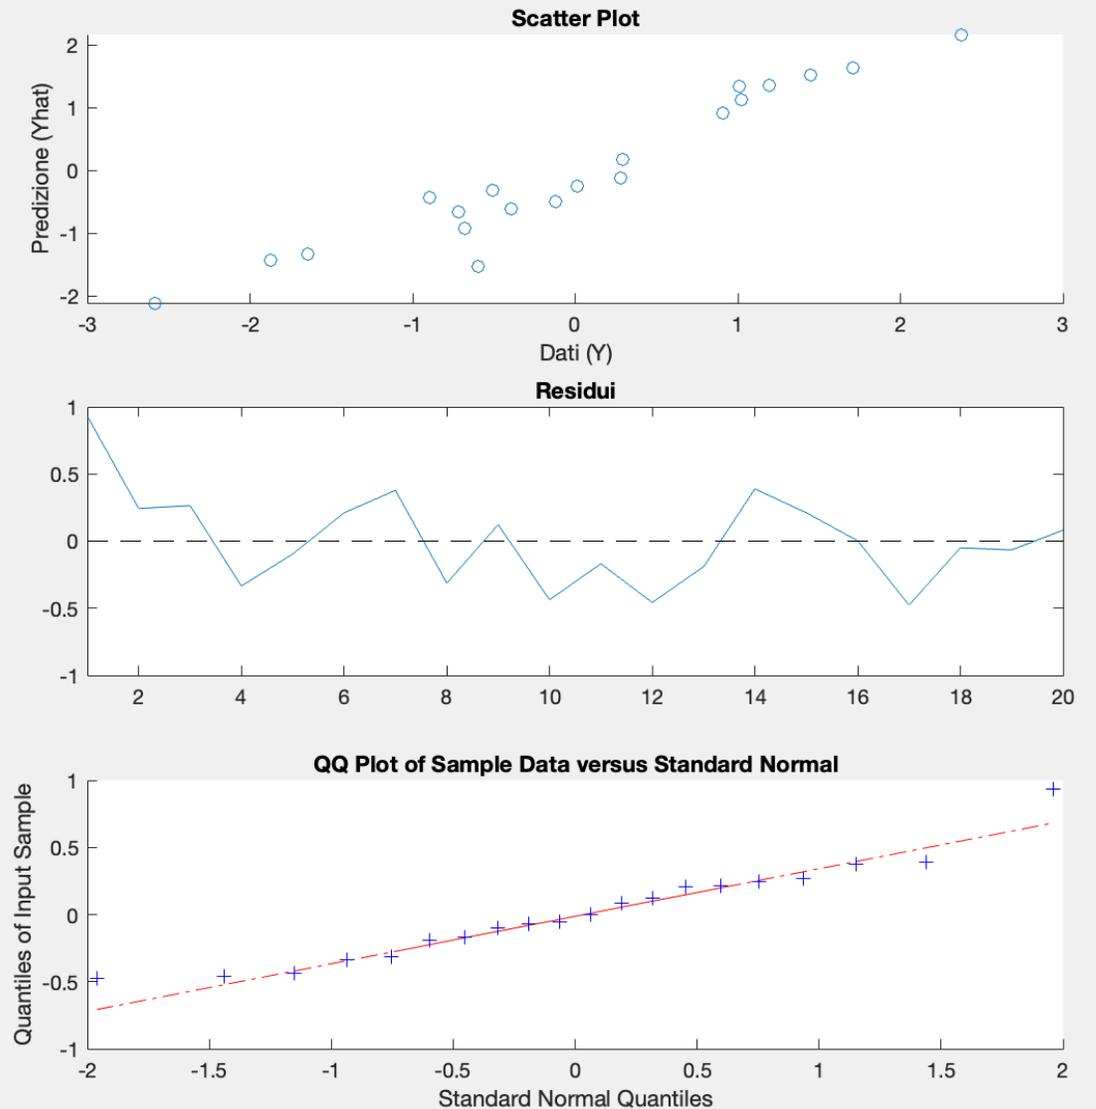
- Si richiede la stima di Y utilizzando tutte le variabili presenti in X. Calcolare:
 - residui (**`res`**) e somma dei residui al quadrato (SSE) (**`rss`**)
 - stima a posteriori dell'errore di misura (**`sigma_hat_2`**)
 - standard error (**`SE`**)
 - coefficiente di variazione (**`CV`**)
 - coefficiente di determinazione (**`R2`**)
 - R2 aggiustato (**`R2_adjusted`**)

Mostrare **`scatterplot`** (dati vs predizione), plot dei residui e qq-plot per valutare il fit

$$R_{adj}^2 = \bar{R}^2 = \left(R^2 - \frac{m}{n-1} \right) \frac{n-1}{n-m-1} \quad m=\text{numero di colonne di X (esclusa intercetta)} \text{ e } n=\text{numero di dati}$$



- Commentare lo scatter-plot: com'è il fit?
- Commentare i residui:
 - Sono bianchi?
 - Ricalcano una distribuzione normale?
- Controllare i CV dei beta: sono accettabili?





- Valutare il Fattore di Inflazione della Varianza (**VIF**) per ogni variabile di X

$$VIF_j = (X^T X)_{jj}^{-1} = \frac{1}{1 - R_j^2}$$

- Per il suo calcolo, procedere con la formula $1/(1 - R_j^2)$, calcolando R_j^2 come segue:

$$\hat{\beta}_j = (X(:, \text{tutte tranne } j)^T X(:, \text{tutte tranne } j))^{-1} X(:, \text{tutte tranne } j)^T X(:, j)$$

Che equivale a stimare i parametri adottando $X(:, j)$ come variabile dipendente (cioè 'Y') e usando come predittori tutte le colonne (cioè le variabili) contenute in X eccetto la colonna j -esima.

$$R_j^2 = [\text{corr}(X(:, j), X(:, \text{tutte tranne } j)) \cdot \hat{\beta}_j]^2$$

- Selezionare le variabili da eliminare in base alla condizione $VIF > 10$ e salvare le restanti in

X_new



- Si ripeta la stima di **Y** utilizzando le variabili in **X_new**. Calcolare gli stessi indici richiesti per il modello con **X**
- Stimare Y (**Y_hat_mod**) mediante **X_mod**, contenente solamente le **ultime due** colonne di (**X_mod=X_new(:, end-1:end)**)
- Confrontare il modello ottenuto da **X_new** con quello ottenuto da **X_mod** tramite R2 aggiustato e calcolando AIC e BIC per entrambi. Quale modello viene selezionato?

$$AIC = n \log \frac{SSE}{n} + 2m$$

$$BIC = n \log \frac{SSE}{n} + m \log n$$

- Mostrare nella stessa figura **scatterplot** (dati vs predizione), plot dei residui e qq-plot per valutare il fit dei due modelli



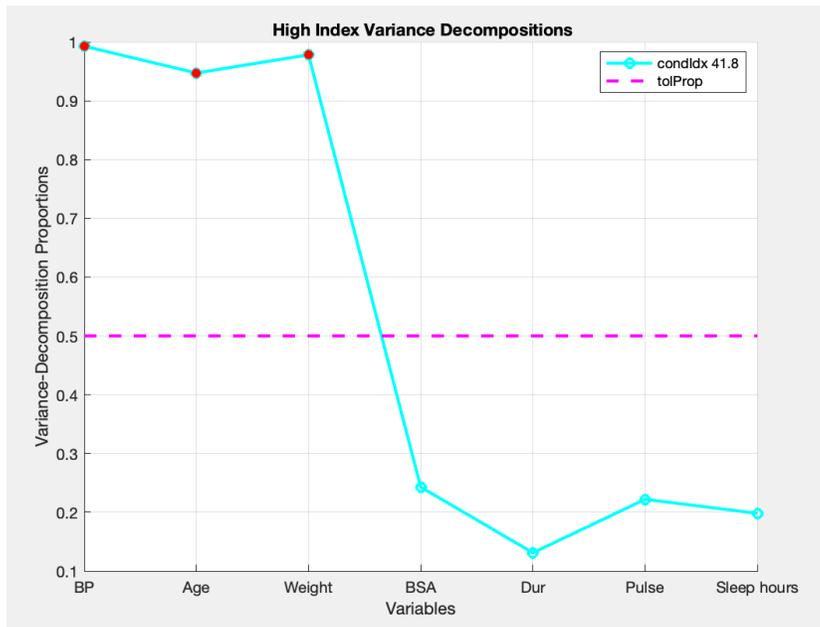
OPZIONALE

- Analizzare la presenza di multicollinearità tra variabili tramite **CN** (Numero di condizionamento) e stampare sulla command window il valore di CN

$$CN = \frac{\lambda_{max}}{\lambda_{min}}, \text{ con } \lambda_i \text{ } i=1 \dots N, \text{ autovalori della matrice di covarianza } X^T X$$

- Il valore di CN suggerisce la presenza di multicollinearità tra le variabili? (N.B. $CN > 1000$?)

- Esaminare la multicollinearità tra le variabili tramite l'Indice di Condizionamento (**CI**) mediante la funzione *collintest* (vedere l'help) e mostrare i risultati di CI in una figura (**TolIdx=10**). Sono state selezionate le stesse variabili di VIF?



BONUS: capire come viene calcolata la Variance Decomposition Proportions

(si vedano le prime 4 pagine il PDF allegato e il codice di collintest) N.B. non è materia d'esame