

## Caso studio 12

Per studiare la curva di domanda di un bene che sta per essere introdotto sul mercato, si rilevano i dati riguardanti il prezzo imposto e il numero di pezzi venduti in 7 punti vendita pilota, nell'arco di una settimana. I dati sono riportati in tabella:

| Punto vendita | Prezzo (in euro) | Numero di pezzi |
|---------------|------------------|-----------------|
| 1             | 12,6             | 47              |
| 2             | 14,5             | 42              |
| 3             | 12               | 54              |
| 4             | 11,6             | 57              |
| 5             | 12,9             | 51              |
| 6             | 13,5             | 46              |
| 7             | 13,9             | 39              |

Come varia la quantità venduta in funzione del prezzo? Come prevedere la quantità venduta per un certo valore del prezzo?

## Regressione

- Concetto utilizzato quando *entrambi i caratteri* ( $X$  e  $Y$ ) sono *quantitativi*
- In questo caso si preferisce utilizzare direttamente la distribuzione doppia unitaria

| $X$   | $Y$   |
|-------|-------|
| $x_1$ | $y_1$ |
| $x_2$ | $y_2$ |
| ...   | ...   |
| $x_n$ | $y_n$ |

- Solitamente si intende che la variabile  $Y$  dipenda da  $X$ . Quindi  $X$  è chiamata **variabile indipendente** (o **esplicativa**) mentre  $Y$  è chiamata **variabile dipendente** (o **risposta**).

2

- L'obiettivo è capire come  $X$  influenza  $Y$  e approssimare tale relazione tramite una semplice funzione matematica

$$y = f(x)$$

- Un'analisi preliminare può essere effettuata tramite un **grafico a dispersione** che consiste nel rappresentare punti di coordinate

$$(x_i, y_i), \quad i = 1, \dots, n$$

3

## Esempio

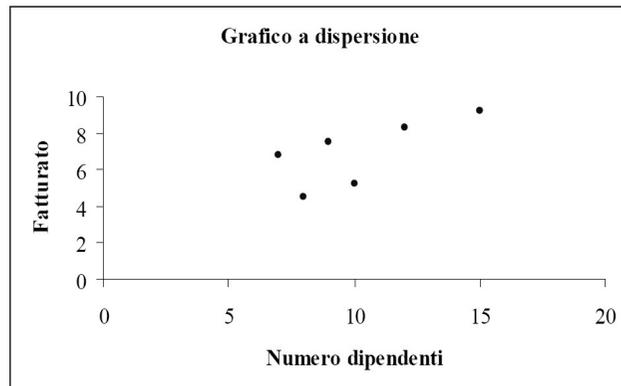
- Per un collettivo di  $n = 6$  imprese sono state rilevate le modalità dei caratteri *numero di dipendenti* ( $X$ ) e *fatturato* ( $Y$ ).

| Dipendenti | Fatturato |
|------------|-----------|
| 15         | 9,2       |
| 10         | 5,2       |
| 8          | 4,5       |
| 7          | 6,8       |
| 12         | 8,3       |
| 9          | 7,5       |

- Sulla base di questi dati si vuole stabilire come il numero di dipendenti *influenzi* il fatturato di un'impresa.

4

- Dal *grafico a dispersione* si nota che al crescere di  $X$  cresce  $Y$ .



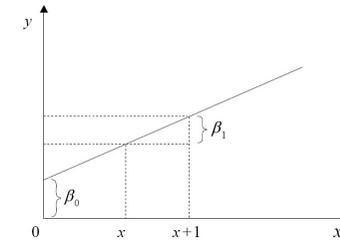
5

## Regressione lineare semplice

- In questo ambito, per approssimare la relazione tra  $Y$  e  $X$  si utilizza una funzione lineare

$$Y = \beta_0 + \beta_1 X$$

dove  $\beta_0$  (*intercetta*) e  $\beta_1$  (*coefficiente angolare*) sono chiamati **parametri della retta interpolatrice**.



- I parametri della retta ( $\beta_0$  e  $\beta_1$ ) vanno scelti in modo da approssimare al meglio la relazione tra  $Y$  e  $X$ , ossia *minimizzando l'errore di previsione*. Il metodo normalmente utilizzato a tale fine è conosciuto con il nome di *metodo dei minimi quadrati*.

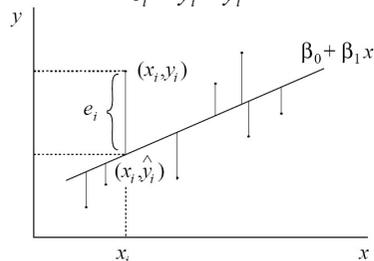
## Metodo dei minimi quadrati

- Per un certo valore dei parametri ( $\beta_0$  e  $\beta_1$ ) si definisce **valore teorico** (o **previsto**) corrispondente alla  $i$ -esima osservazione

$$\hat{y}_i = \beta_0 + \beta_1 x_i$$

- Il corrispondente **errore di previsione** (o **residuo**) è

$$e_i = y_i - \hat{y}_i$$



- La **somma dei quadrati dei residui** è una misura complessiva dell'errore di previsione, definita come

$$G(\beta_0, \beta_1) = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i)^2 \quad 7$$

- Il **metodo dei minimi quadrati** consiste nel *minimizzare la somma dei quadrati dei residui*,  $G(\beta_0, \beta_1)$ , rispetto ai parametri  $\beta_0$  e  $\beta_1$

- Si può dimostrare che il minimo si raggiunge quando il *coefficiente angolare* e l'*intercetta* sono pari, rispettivamente, a

$$\hat{\beta}_1 = \frac{\sigma_{XY}}{\sigma_X^2} \quad e \quad \hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x}$$

- La **retta di regressione** di  $Y$  da  $X$  si ottiene sostituendo a  $\beta_0$  e  $\beta_1$  i corrispondenti valori trovati con il metodo dei minimi quadrati

$$\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_i$$

8

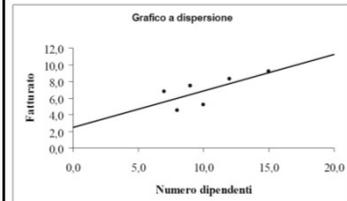
## Esempio

- Per il collettivo di  $n = 6$  imprese si ha:

| $x_i$ | $y_i$ | $(x_i - \bar{x})(y_i - \bar{y})$ | $(x_i - \bar{x})^2$ |
|-------|-------|----------------------------------|---------------------|
| 15    | 9,2   | 11,036                           | 23,361              |
| 10    | 5,2   | 0,286                            | 0,028               |
| 8     | 4,5   | 5,236                            | 4,694               |
| 7     | 6,8   | 0,369                            | 10,028              |
| 12    | 8,3   | 2,536                            | 3,361               |
| 9     | 7,5   | -0,681                           | 1,361               |
| 61,0  | 41,5  | 18,783                           | 42,833              |

$$\bar{x} = 61/6 = 10,17$$

$$\bar{y} = 41,5/6 = 6,92$$



$$\sigma_X^2 = 42,833/6 = 7,139$$

$$\sigma_{XY} = 18,783/6 = 3,13$$

$$\hat{\beta}_1 = \frac{18,783/6}{42,833/6} = 0,439$$

$$\hat{\beta}_0 = 6,917 - 0,439 \cdot 10,167 = 2,458$$

- Il calcolo della varianza e covarianza può essere effettuato con le formule semplificate nel modo seguente

| $x_i$ | $y_i$ | $x_i y_i$ | $x_i^2$ |
|-------|-------|-----------|---------|
| 15    | 9,2   | 138,0     | 225,0   |
| 10    | 5,2   | 52,0      | 100,0   |
| 8     | 4,5   | 36,0      | 64,0    |
| 7     | 6,8   | 47,6      | 49,0    |
| 12    | 8,3   | 99,6      | 144,0   |
| 9     | 7,5   | 67,5      | 81,0    |
| 61,0  | 41,5  | 440,7     | 663,0   |

$$\sigma_{XY} = 440,7/6 - 10,167 \cdot 6,917 = 3,13$$

$$\sigma_X^2 = 663/6 - 10,167^2 = 7,139$$

10

## Esercizio

Si considerino i dati del Caso Studio 12.

Si disegni il grafico a dispersione della quantità rispetto al prezzo e si commenti il risultato.

Si calcolino i parametri della retta di regressione con il metodo dei minimi quadrati e si determini la funzione della curva di domanda.

Si interpreti il valore del coefficiente angolare.

11

## Indice di determinazione

- Per misurare la bontà dell'adattamento della retta ai punti si può utilizzare la **varianza residua** data da

$$SQE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i)^2$$

- La devianza residua è sempre non negativa e quanto più è vicina a 0, tanto migliore è la bontà dell'adattamento della retta ai punti.
- Il massimo della varianza residua è dato dalla **varianza totale** di  $Y$ ,

$$\sigma_Y^2 = SQT = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2 = \frac{1}{n} \sum_{i=1}^n y_i^2 - \bar{y}^2$$

- La differenza tra la varianza totale e quella residua è chiamata **varianza spiegata** che è sempre non negativa

$$SQR = SQT - SQE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$$

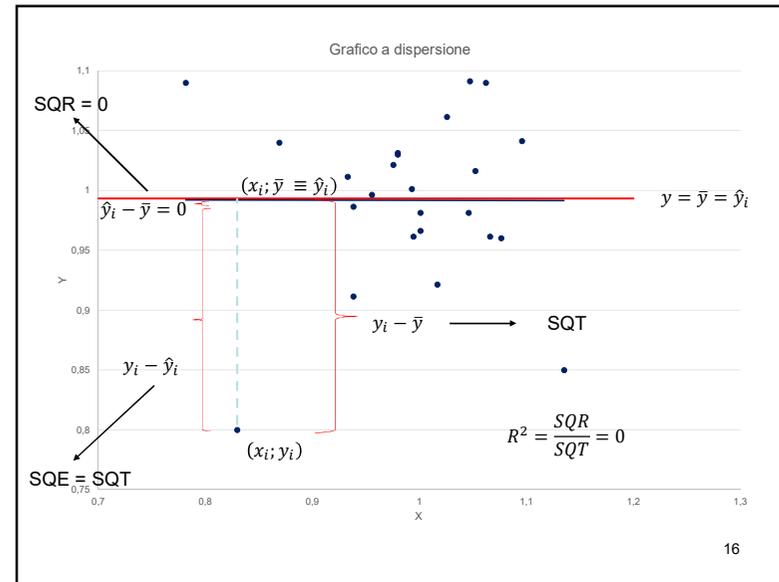
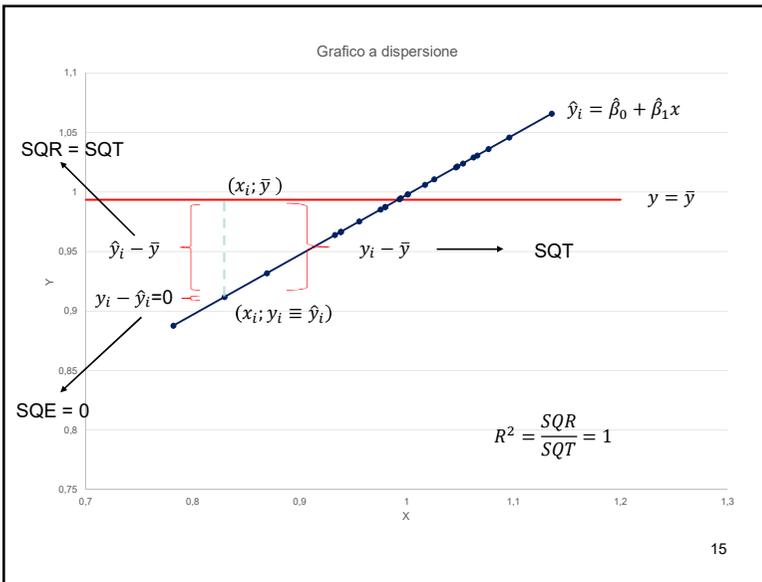
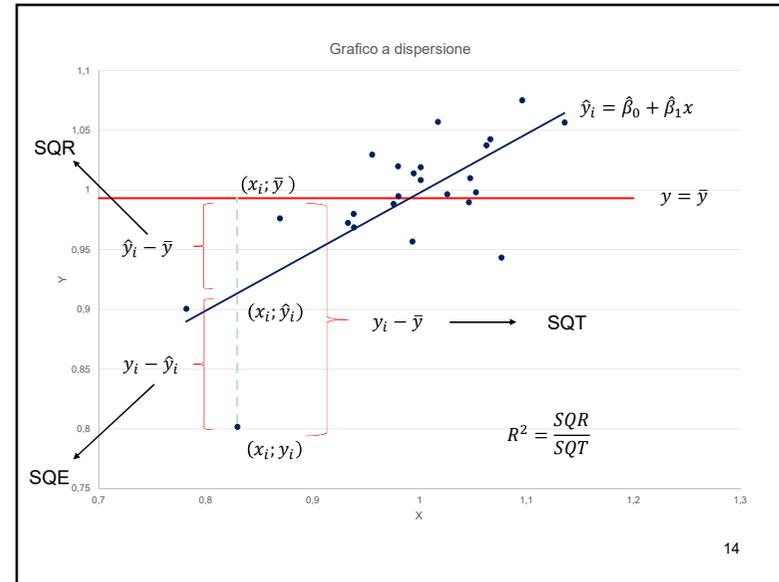
12

- E' quindi possibile costruire un *indice relativo* (varia tra 0 e 1) per misurare la bontà dell'adattamento, chiamato di **indice di determinazione**, come

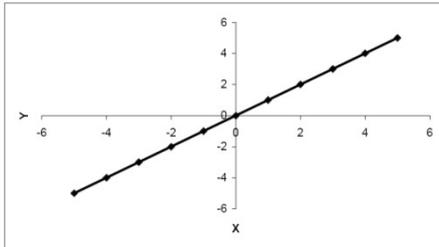
$$R^2 = 1 - \frac{SQE}{SQT} = \frac{SQR}{SQT}$$

- Una *formula alternativa* per l'indice di determinazione è

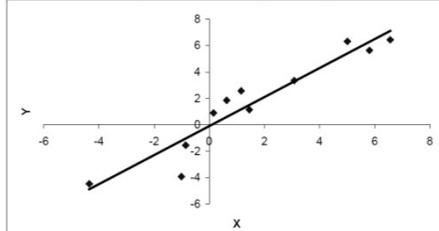
$$R^2 = \frac{\sigma_{xy}^2}{\sigma_x^2 \sigma_y^2}$$



- $R^2 = 1 \Rightarrow$  interpolazione perfetta

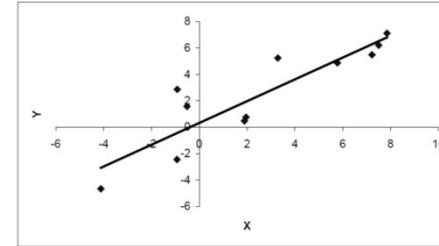


- $R^2 = 0,92$  interpolazione quasi perfetta

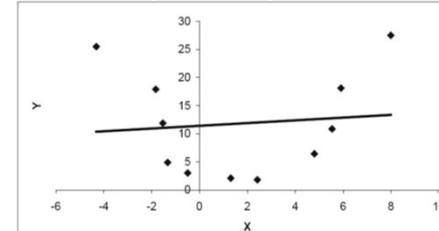


17

- $R^2 = 0,72$  interpolazione buona



- $R^2 = 0,02$  interpolazione pessima



18

## Esempio

- Per il collettivo di  $n = 6$  imprese si ha:

| $x_i$ | $y_i$ | $\hat{y}_i$ | $(y_i - \hat{y}_i)^2$ | $y_i^2$ |
|-------|-------|-------------|-----------------------|---------|
| 15    | 9,2   | 9,0362      | 0,0268                | 84,64   |
| 10    | 5,2   | 6,8436      | 2,7014                | 27,04   |
| 8     | 4,5   | 5,9665      | 2,1507                | 20,25   |
| 7     | 6,8   | 5,5280      | 1,6179                | 46,24   |
| 12    | 8,3   | 7,7206      | 0,3357                | 68,89   |
| 9     | 7,5   | 6,4051      | 1,1989                | 56,25   |
| 61,0  | 41,5  | 41,5        | 8,0314                | 303,31  |

$$\sigma_y^2 = SQT = 303,31/6 - 6,917^2 = 2,707$$

$$SQE = 8,031/6 = 1,339$$

$$R^2 = 1 - \frac{1,339}{2,707} = 0,506$$

19

## Esercizio

Si considerino i dati del Caso Studio 12.

Si calcoli il valore dell'indice di determinazione e se ne interpreti il risultato.

Qual è il valore dell'indice di correlazione di Bravais-Pearson per i dati a disposizione?

20

## Previsione

- Una volta calcolati i parametri della retta di regressione  $(\beta_0, \beta_1)$ , è possibile **prevedere il valore di**  $Y$  in corrispondenza di un nuovo valore di  $X$  indicato con  $x_{n+1}$ . Il valore previsto si calcola come:

$$\hat{y}_{n+1} = \hat{\beta}_0 + \hat{\beta}_1 x_{n+1}$$

- La previsione è particolarmente utilizzata nell'analisi di serie storiche quando, ad esempio, si vuole prevedere il *prodotto interno lordo* di un paese in base ai valori osservati di questo indicatore in un certo periodo di tempo.

### Esempio

- Sulla base dei dati dell'esempio precedente si vuole prevedere il fatturo per un'impresa che ha 20 dipendenti. Si ha:

$$\hat{y}_7 = 2,458 + 0,439 \cdot 20 = 11,229$$

21

## Esercizio

Si considerino i dati del Caso Studio 12.

Si preveda la quantità venduta in corrispondenza di un prezzo di 14 euro.

Ha senso utilizzare i dati a disposizione per prevedere la quantità venduta in corrispondenza di un prezzo di 7 euro?

22

## Dove e come studiare

- Libro di testo: S. Borra, A. Di Ciaccio (2014), Cap. 16 (escluso paragrafo 16.6)
- Svolgere 'Esercitazione 4', esercizi 1 e 2.
- Svolgere gli esercizi nel file 'Esercizi di statistica bivariata.xls', fogli non precedentemente svolti.

23