

LA REGRESSIONE LINEARE

ANALISI DELLA DIPENDENZA

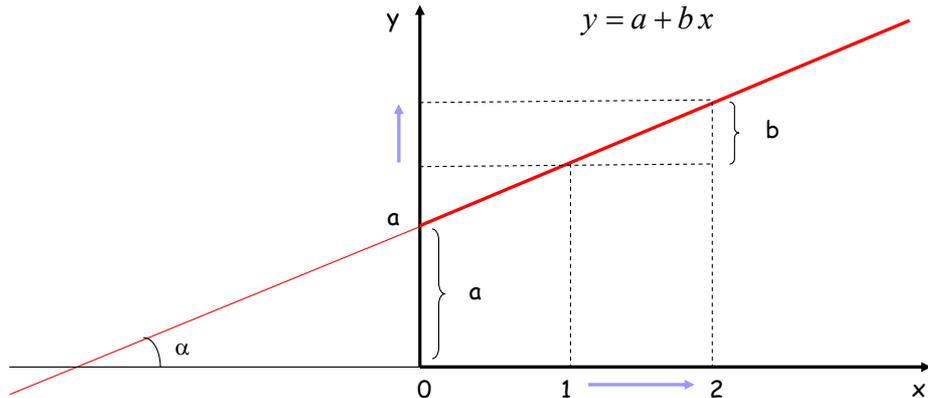
- **La Regressione Lineare**
- Quando tra due variabili c'è una relazione di dipendenza, si può cercare di prevedere il valore di una variabile in funzione del valore assunto dall'altra.
- Questo ha significato in senso stretto quando si ipotizza una relazione di causalità tra la variabile **indipendente**, su cui si agisce, e quella **dipendente**, su cui si vuole produrre un effetto.
- Volendo costruire un **modello statistico** per prevedere Y in funzione di X, si pone la questione di quale relazione funzionale ipotizzare tra la variabile indipendente X e la variabile dipendente Y.
- Il modello più semplice di relazione tra due variabili è quello lineare di primo grado, rappresentato da una retta, la cui equazione è :

$$y = a + bx$$

- Una volta determinata la retta, il modello permetterà di stimare il valore della variabile Y sulla base del valore assunto dalla X
- Per ottenere un buon modello, e quindi delle buone previsioni, occorre determinare la retta che meglio *descrive* i punti osservati: in pratica, si tratta di determinare i due coefficienti a e b che compaiono nell'equazione della retta: $y = a + b x$

ANALISI DELLA DIPENDENZA

- Ripassiamo un po' di geometria (e di trigonometria ...):
 - il parametro **a** è l'**intercetta** della retta con l'asse delle ordinate
 - il parametro **b** è il **coefficiente angolare**: misura l'inclinazione della retta (è la tangente dell'angolo α formato dalla retta con l'asse delle ascisse)
- In pratica:
 - a ci dice quanto vale Y quando X vale 0
 - b ci dice di quanto aumenta Y all'aumentare di una unità di X



ANALISI DELLA DIPENDENZA

- Se i punti fossero solo due, o fossero tutti allineati, determinare la retta interpolante sarebbe facile (per due punti passa una sola retta), ma sfortunatamente nella realtà i dati osservativi non sono mai esattamente allineati
- Per determinare la retta di regressione che meglio descrive i dati osservati è allora necessario stabilire un criterio *statistico* di valutazione della bontà del modello:

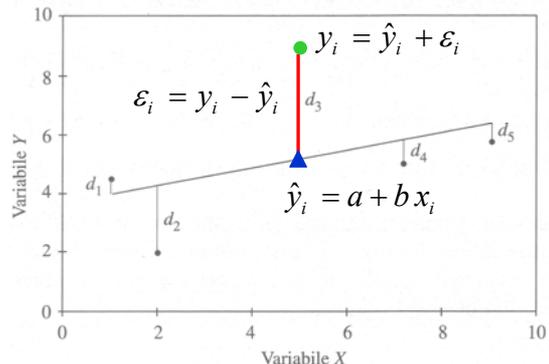
$$\hat{y}_i = a + b x_i \quad \forall i$$

- L'errore che si commette prevedendo ciascun Y osservato con il modello, può essere misurato come differenza tra il dato reale e quello previsto:

$$y_i = \hat{y}_i + \varepsilon_i$$

cioè, per ciascuna osservazione i , si commette un errore

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

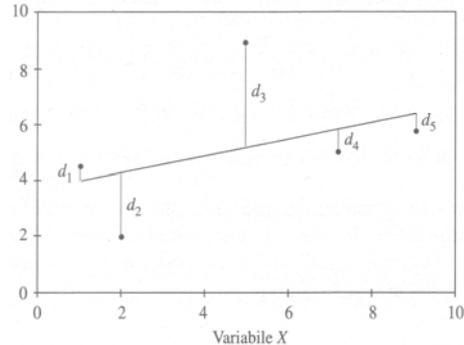


ANALISI DELLA DIPENDENZA

- **Il Metodo dei Minimi Quadrati**
- Il criterio detto dei **minimi quadrati** prevede di valutare la bontà del modello sulla base della somma dei quadrati di tutti errori di stima commessi:

$$\sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \sum_{i=1}^n (y_i - a - b x_i)^2 = \min$$

- La retta migliore, secondo questo criterio, è quella che minimizza la somma dei quadrati degli scarti dei valori stimati da quelli osservati, detti anche **residui** della regressione.
- Perché proprio il quadrato dei residui ?
 - per evitare che residui positivi e negativi si compensino
 - il valore assoluto è matematicamente più scomodo da gestire e non sempre porta ad una soluzione univoca
 - il quadrato dà peso maggiore agli scarti più grandi, che sono anche quelli che ci disturbano di più: è meglio fare tanti piccoli errori che non un errore molto grosso



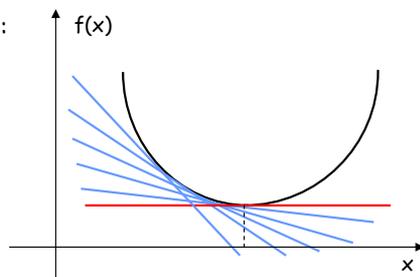
ANALISI DELLA DIPENDENZA

- **Ricerca del minimo di una funzione**
- Il problema è determinare i coefficienti a e b del modello in modo da minimizzare la quantità :

$$\sum_{i=1}^n (y_i - a - b x_i)^2 = \min$$

- La soluzione di questo problema in matematica è semplice: si tratta di trovare il minimo di una funzione $f(x)$
- La soluzione ad un problema di ricerca del minimo di una funzione si determina trovando i punti "di svolta" della funzione, in cui la curva cambia andamento (concavità) : in un punto di svolta, la retta tangente alla curva risulta orizzontale
- L'inclinazione della retta tangente ad una curva in un punto è data dalla derivata prima della $f(x)$ in quel punto, indicata come: $f'(x)$
- Quindi nel punto di svolta la derivata prima $f'(x)$ della funzione $f(x)$ si annulla
- Allora per determinare i punti di minimo di una funzione $f(x)$ è necessario imporre che valga zero la sua derivata prima rispetto a x , in questo modo si determina il punto x in cui vale:

$$f'(x) = \frac{\partial f(x)}{\partial x} = 0$$

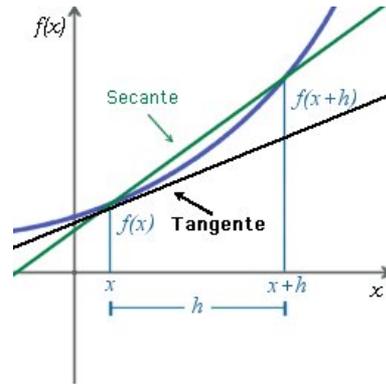


MATEMATICA

- **La Derivata di una Funzione**
- La derivata di una funzione reale di variabile reale $f(x)$ nel punto x è definita come il limite per h tendente a 0 del rapporto incrementale:

$$f'(x) = \lim_{h \rightarrow 0} \frac{f(x+h) - f(x)}{h}$$

cioè dell'incremento descritto dalla funzione quando la variabile X varia da x ad $(x+h)$, diviso l'incremento h stesso



- Il rapporto incrementale rappresenta il coefficiente angolare della retta secante che interseca la curva della funzione $f(x)$ nei punti x e $x+h$
- Quando l'incremento h tende a 0, la retta secante tende (cioè si avvicina fino) a coincidere con la tangente alla curva nel punto x : quindi il limite del rapporto incrementale ci fornisce il coefficiente angolare della retta tangente nel punto x
- La derivata, cioè proprio questo limite, rappresenta dunque l'inclinazione della retta tangente alla funzione $f(x)$ nel punto x

DERIVATE ELEMENTARI

$$\frac{d}{dx} a = 0$$

$$\frac{d}{dx} x = 1$$

$$\frac{d}{dx} ax = a$$

$$\frac{d}{dx} x^a = a x^{a-1}$$

$$\frac{d}{dx} \frac{1}{x} = -\frac{1}{x^2}$$

$$\frac{d}{dx} \sqrt{x} = \frac{1}{2\sqrt{x}}$$

$$\frac{d}{dx} e^x = e^x$$

$$\frac{d}{dx} a^x = a^x \ln a \quad (a > 0)$$

$$\frac{d}{dx} \ln x = \frac{1}{x} \quad (x > 0)$$

$$\frac{d}{dx} \sin x = \cos x$$

$$\frac{d}{dx} \cos x = -\sin x$$

REGOLE DI DERIVAZIONE

$$\frac{d}{dx} (f(x) + g(x)) = f'(x) + g'(x).$$

$$\frac{d}{dx} (cf(x)) = cf'(x).$$

$$\frac{d}{dx} (f(x)g(x)) = f'(x)g(x) + f(x)g'(x).$$

$$\frac{d}{dx} \left(\frac{1}{f(x)} \right) = -\frac{f'(x)}{f(x)^2}.$$

$$\frac{d}{dx} \left(\frac{f(x)}{g(x)} \right) = \frac{g(x)f'(x) - f(x)g'(x)}{g(x)^2}.$$

$$\frac{d}{dx} (f(g(x))) = f'(g(x))g'(x).$$

ANALISI DELLA DIPENDENZA

- **Stima dei parametri ai minimi quadrati**
- Nel nostro caso vogliamo minimizzare una funzione $f(a,b)$ rispetto ad a e b : dovremo imporre che siano nulle le *derivate prime parziali* della funzione rispetto ad a e b :

$$\sum_{i=1}^n (y_i - a - bx_i)^2 = \min$$

- Derivando la funzione prima rispetto ad a e poi rispetto ad b , e ponendo a zero tali derivate, si ottiene un sistema di due equazioni di primo grado in due incognite (a e b):

$$\begin{cases} \frac{\partial \sum (y_i - a - bx_i)^2}{\partial a} = 0 \\ \frac{\partial \sum (y_i - a - bx_i)^2}{\partial b} = 0 \end{cases} \Rightarrow \begin{cases} -2 \sum (y_i - a - bx_i) = 0 \\ -2 \sum (y_i - a - bx_i) x_i = 0 \end{cases} \Rightarrow$$

$$\begin{cases} \sum (y_i - a - bx_i) = 0 \\ \sum (y_i - a - bx_i) x_i = 0 \end{cases}$$

Sistema di equazioni normali di regressione

- Risolvendo il sistema rispetto ad a e b , si determinano le stime ai minimi quadrati dei parametri della retta di regressione

ANALISI DELLA DIPENDENZA

■ Soluzione del sistema di equazioni normali

$$\begin{cases} \sum (y_i - a - b x_i) = 0 \\ \sum (y_i - a - b x_i) x_i = 0 \end{cases} \Rightarrow \begin{cases} \sum y_i - n a - b \sum x_i = 0 \\ \sum x_i y_i - a \sum x_i - b \sum x_i^2 = 0 \end{cases} \Rightarrow$$

$$\begin{cases} n \bar{y} - n a - b n \bar{x} = 0 \\ \sum x_i y_i - a n \bar{x} - b \sum x_i^2 = 0 \end{cases} \Rightarrow \begin{cases} a = \bar{y} - b \bar{x} \\ \sum x_i y_i - a n \bar{x} - b \sum x_i^2 = 0 \end{cases} \Rightarrow$$

$$\sum x_i y_i - (\bar{y} - b \bar{x}) n \bar{x} - b \sum x_i^2 = 0$$

$$\sum x_i y_i - n \bar{x} \bar{y} + n b \bar{x}^2 - b \sum x_i^2 = 0$$

$$\frac{\sum x_i y_i}{n} - \frac{n \bar{x} \bar{y}}{n} + b \left(\frac{n \bar{x}^2}{n} - \frac{\sum x_i^2}{n} \right) = 0$$

$$\frac{\sum x_i y_i}{n} - \bar{x} \bar{y} = -b \left(\bar{x}^2 - \frac{\sum x_i^2}{n} \right) \Rightarrow b = \frac{\frac{\sum x_i y_i}{n} - \bar{x} \bar{y}}{\frac{\sum x_i^2}{n} - \bar{x}^2} = \frac{\text{Cov}(x, y)}{\sigma^2(x)}$$

$$\text{Cov}(x, y) = M(x, y) - \bar{x} \bar{y}$$

$$V(x) = M(x^2) - \bar{x}^2$$

ANALISI DELLA DIPENDENZA

■ I coefficienti di regressione

■ I parametri del modello vengono chiamati anche **coefficienti di regressione**:

$$\hat{b} = \frac{\sigma_{xy}}{\sigma_x^2}$$

$$\hat{a} = \bar{y} - \hat{b} \bar{x}$$

Equazione della retta di regressione:

$$y = \hat{a} + \hat{b} x$$

- Bisogna calcolare prima il valore di b e poi quello di a. Il "cappello" sopra a e b sottolinea che si tratta delle *stime*, ai minimi quadrati, dei parametri del modello.
- Il metodo di calcolo più veloce per b è utilizzare l'espressione che compare nell'ultimo passaggio della soluzione del sistema di equazioni normali:

$$\hat{b} = \frac{\text{Cov}(x, y)}{\sigma^2(x)} = \frac{M(x, y) - \bar{x} \bar{y}}{M(x^2) - \bar{x}^2} = \frac{\frac{\sum x_i y_i}{n} - \bar{x} \bar{y}}{\frac{\sum x_i^2}{n} - \bar{x}^2}$$

che ha il vantaggio di non richiedere il calcolo di scarti
(in pratica utilizza le formule indirette per la varianza e la covarianza)

ANALISI DELLA DIPENDENZA

■ Interpretazione dei coefficienti di regressione

- Il segno del coefficiente di regressione dipende da quello della covarianza: $\hat{b} = \frac{\sigma_{xy}}{\sigma_x^2}$ e indica quindi se la relazione è diretta o inversa
- Ricordiamo che, nell'equazione della retta $y = \hat{a} + \hat{b}x$ b rappresenta il coefficiente angolare, cioè l'inclinazione della retta

| | | |
|---------|---|---|
| $b > 0$ | relazione diretta, cioè y cresce al crescere di x | la retta è crescente, inclinazione positiva |
| $b = 0$ | assenza di relazione (lineare), y non varia al variare di x | la retta è orizzontale, inclinazione nulla |
| $b < 0$ | relazione inversa, cioè y diminuisce all'aumentare di x | la retta è decrescente, inclinazione negativa |

- Il valore assoluto di b indica di quanto varia la Y al variare di una unità della X
- Il coefficiente a rappresenta l'intercetta della retta con l'asse Y : indica quanto vale Y quando X vale 0 ; quando $a = 0$, la retta passa per l'origine degli assi cartesiani, cioè per il punto di coordinate $(0, 0)$

ANALISI DELLA DIPENDENZA

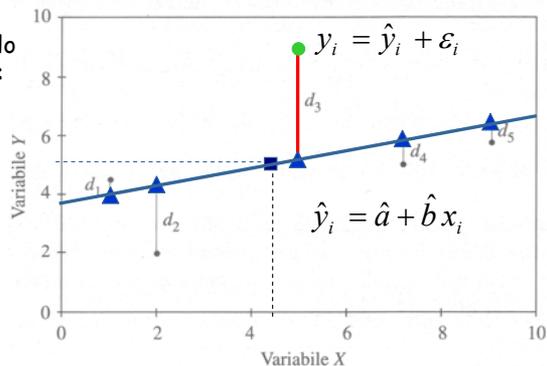
■ Proprietà della regressione ai minimi quadrati

- Stimati i parametri, possiamo produrre i valori previsti dal modello in corrispondenza degli x osservati:

$$\hat{y}_i = \hat{a} + \hat{b}x_i \quad \forall i$$

- La retta di regressione passa per il baricentro del sistema, infatti quando x assume il valore x medio:

$$\begin{aligned} \hat{y}(\bar{x}) &= \hat{a} + \hat{b}\bar{x} = \\ &= (\bar{y} - \hat{b}\bar{x}) + \hat{b}\bar{x} = \bar{y} \end{aligned}$$



- Per ciascun $x(i)$ possiamo ora calcolare anche l'errore commesso prevedendo Y con il modello, come scarto tra il valore osservato e quello stimato: questi errori sono detti **residui** di regressione

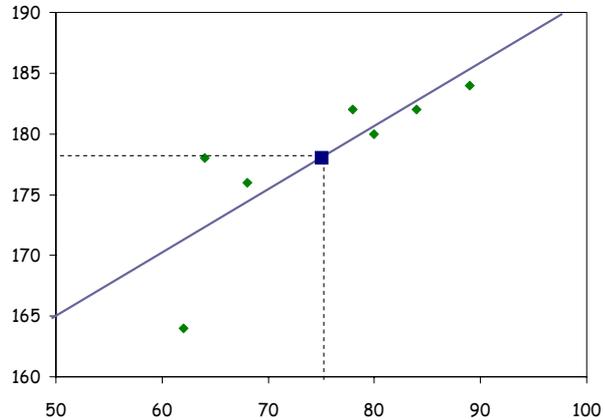
$$\varepsilon_i = y_i - \hat{y}_i \quad \forall i$$

- I residui sono importanti per la valutazione della bontà del modello, cioè la sua capacità di adattarsi ai dati osservati

ANALISI DELLA DIPENDENZA

- Esercizio. Determiniamo la retta di regressione ai minimi quadrati per la relazione tra le variabili Y=altezza e X=peso:

| i | x(i) | y(i) |
|---|------|------|
| 1 | 62 | 164 |
| 2 | 64 | 178 |
| 3 | 68 | 176 |
| 4 | 75 | 178 |
| 5 | 78 | 182 |
| 6 | 80 | 180 |
| 7 | 84 | 182 |
| 8 | 89 | 184 |



$$\hat{b} = \frac{\sigma_{xy}}{\sigma_x^2}$$

$$\hat{a} = \bar{y} - \hat{b}\bar{x}$$

- Osserviamo che tutto quello che ci serve per determinare i coefficienti di regressione della retta, lo abbiamo in realtà già calcolato per il coefficiente di correlazione

ANALISI DELLA DIPENDENZA

- Riprendiamo il prospetto di calcolo del coefficiente di regressione:

| i | x(i) | y(i) | x(i)-Mx | y(i)-My | [x(i)-Mx] ² | [y(i)-My] ² | (x(i)-Mx)(y(i)-My) |
|--------|-------|--------|---------|---------|------------------------|------------------------|--------------------|
| 1 | 62 | 164 | -13,00 | -14,00 | 169,00 | 196,00 | 182,00 |
| 2 | 64 | 178 | -11,00 | 0,00 | 121,00 | 0,00 | 0,00 |
| 3 | 68 | 176 | -7,00 | -2,00 | 49,00 | 4,00 | 14,00 |
| 4 | 75 | 178 | 0,00 | 0,00 | 0,00 | 0,00 | 0,00 |
| 5 | 78 | 182 | 3,00 | 4,00 | 9,00 | 16,00 | 12,00 |
| 6 | 80 | 180 | 5,00 | 2,00 | 25,00 | 4,00 | 10,00 |
| 7 | 84 | 182 | 9,00 | 4,00 | 81,00 | 16,00 | 36,00 |
| 8 | 89 | 184 | 14,00 | 6,00 | 196,00 | 36,00 | 84,00 |
| Totale | 600 | 1424 | 0 | 0 | 650,00 | 272,00 | 338,00 |
| Media | 75,00 | 178,00 | | | 81,25 | 34,00 | 42,25 |

$$\sigma_x^2 = 81,25 \quad \sigma_y^2 = 34 \quad \sigma_{xy} = 42,25$$

$$b = \frac{\sigma_{xy}}{\sigma_x^2} = \frac{42,25}{81,25} = 0,52 \quad a = \bar{y} - b\bar{x} = 178 - 0,52 \cdot 75 = 139$$

- Il valore di b ci dice che, al variare di una unità di x, il valore di y varia di 0,52
- Ora possiamo disegnare la retta di regressione, determinandone due punti a scelta

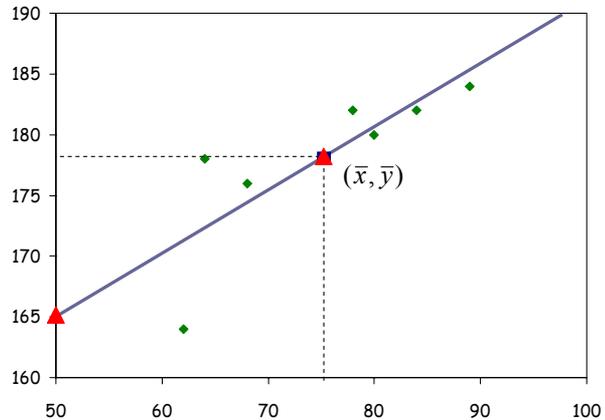
ANALISI DELLA DIPENDENZA

- Finalmente scriviamo l'equazione della retta di regressione:

$$\hat{b} = \frac{\sigma_{xy}}{\sigma_x^2} = 0,52$$

$$\hat{a} = \bar{y} - \hat{b}\bar{x} = 139$$

$$\hat{y} = 139 + 0,52x$$



- Per disegnare la retta di regressione, è sufficiente determinarne due punti a scelta:
 - uno in realtà lo conosciamo già: è il punto medio (baricentro) del sistema
 - per l'altro scegliamo ad es. $x = 50$, da cui $y = 139 + 0,52 * 50 = 165$
- A vederla così non sembra che l'intercetta sia 139: questo dipende dal fatto che i punti sono molto lontani dall'origine e noi abbiamo "tagliato" la figura

ANALISI DELLA DIPENDENZA

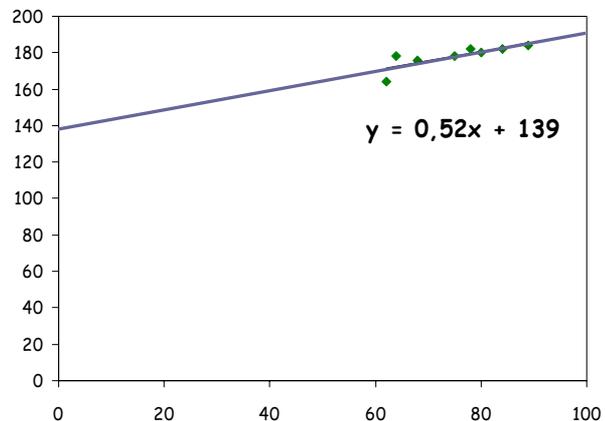
- Se disegniamo il grafico e la retta di regressione a partire dall'origine degli assi, vediamo che tutto torna:

$$\hat{y} = 139 + 0,52x$$

- La retta interseca l'asse delle ordinate proprio nel punto 139
- L'inclinazione apparente della retta nel disegno dipende dalla scala degli assi: abbiamo usato due scale diverse per l'asse X e per l'asse Y
- Avevamo già calcolato il coefficiente di correlazione

$$\rho_{xy} = \frac{\sigma_{xy}}{\sigma_x \sigma_y} = 0,8039$$

- Un coefficiente di correlazione pari a 0,8 ci dice che i punti sono abbastanza ben allineati lungo la retta, ma ora vediamo meglio come valutare la capacità del modello di descrivere i dati osservati



ANALISI DELLA DIPENDENZA

■ Valutazione del modello

- La bontà dell'interpolazione fornita dal modello si giudica sulla base della dispersione dei punti **osservati** intorno alla retta di regressione:
 - l'interpolazione è esatta quando la retta passa per tutti i punti osservati, che devono essere quindi perfettamente allineati
 - più i punti osservati si discostano dalla retta → minore è la validità del modello, che diventa sempre meno efficace, fino a perdere praticamente di significato
- Il modello stimato può essere valutato, coerentemente con il criterio che è stato utilizzato per costruirlo, sulla base della somma dei quadrati degli scarti tra valori osservati e valori stimati, cioè la somma dei quadrati dei residui di regressione:

$$\sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

- I residui della regressione lineare ai minimi quadrati godono di 4 importanti proprietà: tutte queste proprietà derivano dalle equazioni normali, ovvero dalle condizioni che sono state imposte per determinare i parametri della retta di regressione, in modo da minimizzare la somma dei quadrati dei residui stessi

ANALISI DELLA DIPENDENZA

■ Le 4 Proprietà dei Residui di Regressione

$$\sum_{i=1}^n \varepsilon_i = \sum_{i=1}^n (y_i - \hat{y}_i) = 0$$

$$\sum_{i=1}^n (y_i - \hat{y}_i) x_i = 0$$

$$\sum_{i=1}^n (y_i - \hat{y}_i) \hat{y}_i = 0$$

$$\sum_{i=1}^n (y_i - \hat{y}_i) (\hat{y}_i - \bar{y}) = 0$$

$$\hat{y}_i = a + b x_i$$

$$y_i = \hat{y}_i + \varepsilon_i$$

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

- Le prime due proprietà derivano direttamente, anzi non sono altro che le condizioni imposte dalle equazioni normali di regressione:

$$\begin{cases} \sum (y_i - a - b x_i) = 0 \\ \sum (y_i - a - b x_i) x_i = 0 \end{cases} \quad \text{ovvero} \quad \begin{cases} \sum (y_i - \hat{y}_i) = 0 \\ \sum (y_i - \hat{y}_i) x_i = 0 \end{cases}$$

ANALISI DELLA DIPENDENZA

- Dimostriamo le altre due:

$$\sum_{i=1}^n (y_i - \hat{y}_i) \hat{y}_i = 0$$

$$\sum_{i=1}^n (y_i - \hat{y}_i)(a + b x_i) = a \sum_{i=1}^n (y_i - \hat{y}_i) + b \sum_{i=1}^n (y_i - \hat{y}_i) x_i = 0$$

sono proprio le prime due proprietà = 0

$$\sum_{i=1}^n (y_i - \hat{y}_i)(\hat{y}_i - \bar{y}) = 0$$

$$\sum_{i=1}^n (y_i - \hat{y}_i)(\hat{y}_i - \bar{y}) = \sum_{i=1}^n (y_i - \hat{y}_i) \hat{y}_i - \bar{y} \sum_{i=1}^n (y_i - \hat{y}_i) = 0$$

questa è la terza proprietà = 0

- Teniamole presenti: fra un attimo ci torneranno utili

ANALISI DELLA DIPENDENZA

- Esercizio. Verifica empirica delle 4 proprietà dei residui di regressione ai minimi quadrati per il modello appena stimato:

$$\hat{y} = 139 + 0,52x$$

| i | x(i) | y(i) | y(i)^ | y^~My | y-y^ | (y-y^) x | (y-y^) y^ | (y-y^)(y^~My) |
|--------|-------|--------|--------|-------|-------|-----------|------------|---------------|
| 1 | 62 | 164 | 171,24 | -6,76 | -7,24 | -448,8800 | -1239,7776 | 48,9424 |
| 2 | 64 | 178 | 172,28 | -5,72 | 5,72 | 366,0800 | 985,4416 | -32,7184 |
| 3 | 68 | 176 | 174,36 | -3,64 | 1,64 | 111,5200 | 285,9504 | -5,9696 |
| 4 | 75 | 178 | 178,00 | 0,00 | 0,00 | 0,0000 | 0,0000 | 0,0000 |
| 5 | 78 | 182 | 179,56 | 1,56 | 2,44 | 190,3200 | 438,1264 | 3,8064 |
| 6 | 80 | 180 | 180,60 | 2,60 | -0,60 | -48,0000 | -108,3600 | -1,5600 |
| 7 | 84 | 182 | 182,68 | 4,68 | -0,68 | -57,1200 | -124,2224 | -3,1824 |
| 8 | 89 | 184 | 185,28 | 7,28 | -1,28 | -113,9200 | -237,1584 | -9,3184 |
| Totale | 600 | 1424 | 1424 | 0,00 | 0,00 | 0,0000 | 0,0000 | 0,0000 |
| Media | 75,00 | 178,00 | 178,00 | | | | | |

ANALISI DELLA DIPENDENZA

■ Devianza (e Varianza) Residua

- Il modello viene valutato sulla base della somma dei quadrati degli scarti tra valori osservati e valori stimati:

$$\sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

- Questa quantità è detta **devianza residua**, in quanto è la *devianza dei residui* di regressione (che ricordiamo hanno media nulla)

- Il termine **devianza** indica semplicemente la varianza *non divisa* per n , quindi tutto quello che diciamo per la devianza vale anche per la varianza

- La quantità:

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

$$\begin{aligned} M(\hat{y}) &= M(\hat{a} + \hat{b}x) = M(\bar{y} - \hat{b}\bar{x} + \hat{b}x) = \\ &= M(\bar{y}) + \hat{b}M(x - \bar{x}) = \bar{y} \end{aligned}$$

- prende invece il nome di **devianza spiegata** dal modello (o devianza di regressione), in quanto *devianza dei valori stimati* dal modello: rappresenta la parte di variabilità della Y descritta dal modello di regressione
- Devianza spiegata e devianza residua sono legate tra loro e con la **devianza totale** della variabile dipendente

ANALISI DELLA DIPENDENZA

■ Scomposizione della Devianza (e della Varianza) di Y

- La devianza della variabile Y può essere scomposta in due componenti:

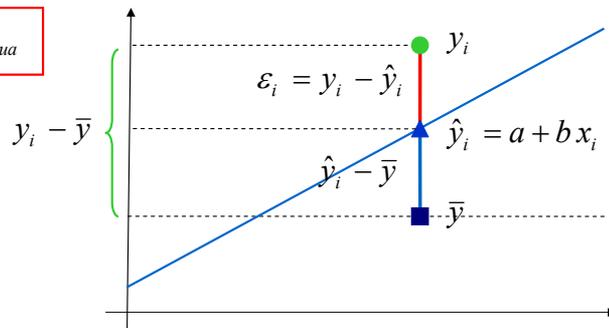
$$\sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2 + \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$$

cioè come somma della **devianza residua** e della **devianza spiegata** dal modello

- Devianza spiegata e residua sono quindi due quantità complementari e la loro somma è pari alla devianza totale della Y . Lo stesso vale anche per la varianza, basta dividere tutto per n :

$$\sigma_y^2 = \sigma_{\text{modello}}^2 + \sigma_{\text{residua}}^2$$

- Capiamo il significato della scomposizione:



ANALISI DELLA DIPENDENZA

- Dimostrazione:

$$(a + b)^2 = a^2 + b^2 + 2ab$$

$$\begin{aligned} \sum_{i=1}^n (y_i - \bar{y})^2 &= \sum_{i=1}^n (y_i - \hat{y}_i + \hat{y}_i - \bar{y})^2 = \sum_{i=1}^n [(y_i - \hat{y}_i) + (\hat{y}_i - \bar{y})]^2 \\ &= \sum_{i=1}^n (y_i - \hat{y}_i)^2 + \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 + 2 \sum_{i=1}^n (y_i - \hat{y}_i)(\hat{y}_i - \bar{y}) = \\ &= \sum_{i=1}^n (y_i - \hat{y}_i)^2 + \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 \end{aligned}$$

= 0 per la quarta proprietà dei residui di regressione

devianza residua + devianza spiegata dal modello

- Lo stesso vale ovviamente anche per la varianza, basta dividere tutto per n, quindi possiamo scrivere anche la scomposizione della varianza totale di Y:

$$\sigma_y^2 = \sigma_{\text{modello}}^2 + \sigma_{\text{residua}}^2$$

- In virtù di questa scomposizione, si può costruire un indice standardizzato (compreso tra 0 e 1) per valutare la bontà del modello di regressione

ANALISI DELLA DIPENDENZA

- **Il Coefficiente di Determinazione R^2**
- Per valutare la bontà del modello si introduce il **coefficiente di determinazione R^2** rapporto tra la devianza del modello e la devianza totale della y:

$$R^2 = \frac{\sigma_{\text{modello}}^2}{\sigma_y^2} = \frac{\sum (\hat{y}_i - \bar{y})^2}{\sum (y_i - \bar{y})^2}$$

- R^2 misura la frazione di varianza (o di devianza) della Y spiegata dal modello
- R^2 si può scrivere anche come:

$$R^2 = \frac{\sigma_{\text{modello}}^2}{\sigma_y^2} = \frac{\sigma_y^2 - \sigma_{\text{residua}}^2}{\sigma_y^2} = 1 - \frac{\sigma_{\text{residua}}^2}{\sigma_y^2}$$

- Assume valori compresi tra 0 e 1:
 - vale 1 quando il modello spiega completamente la varianza della Y: i residui sono tutti nulli, cioè i punti sono perfettamente allineati
 - vale 0 quando la varianza descritta dal modello è nulla: questo accade quando la retta di regressione risulta parallela all'asse X, cioè

$$\hat{y}_i = \bar{y} \Rightarrow \sum (\hat{y}_i - \bar{y})^2 = 0$$

ANALISI DELLA DIPENDENZA

- Osserviamo che per calcolare R^2 è necessario calcolare tutti gli $y(i)$ stimati per ogni $x(i)$ osservato, e tutti gli scarti tra i valori stimati e $M(y)$

$$R^2 = \frac{\sigma_{\text{modello}}^2}{\sigma_y^2} = \frac{\sum (\hat{y}_i - \bar{y})^2}{\sigma_y^2} = 1 - \frac{\sigma_{\text{residua}}^2}{\sigma_y^2} = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sigma_y^2}$$

- Oppure, con la seconda formulazione, dobbiamo calcolare tutti gli scarti tra gli y stimati e quelli osservati (cioè i residui)
- Possiamo però sviluppare R^2 anche in un altro modo:

$$R^2 = \frac{\sigma_{\text{modello}}^2}{\sigma_y^2} = \frac{V(\hat{y})}{V(y)} = \frac{V(\hat{a} + \hat{b}x)}{V(y)} = \frac{\hat{b}^2 V(x)}{V(y)} = \frac{\hat{b}^2 \sigma_x^2}{\sigma_y^2} = \left(\frac{\sigma_{xy}}{\sigma_x} \right)^2 \frac{\sigma_x^2}{\sigma_y^2} = \frac{\sigma_{xy}^2}{\sigma_x^4} \frac{\sigma_x^2}{\sigma_y^2} = \frac{\sigma_{xy}^2}{\sigma_x^2 \sigma_y^2} = \left(\frac{\sigma_{xy}}{\sigma_x \sigma_y} \right)^2 = \rho^2$$

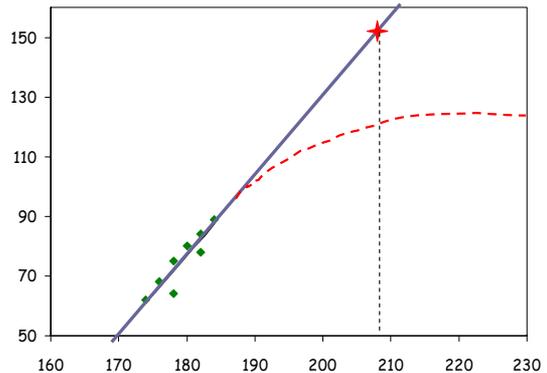
- Il coefficiente di determinazione R^2 (solo per il modello lineare di primo grado cioè per la retta di regressione) è uguale al quadrato del coefficiente di correlazione ρ^2
- Quindi il quadrato del coefficiente di correlazione ci fornisce la frazione di varianza spiegata dal modello, senza calcolare i residui e nemmeno gli y stimati

ANALISI DELLA DIPENDENZA

- **Considerazioni sull'applicabilità di un modello (lineare)**
- Quando R^2 è basso significa che il modello lineare non riesce a descrivere adeguatamente il fenomeno, non si adatta bene ai dati, e quindi anche le nostre *previsioni* saranno poco affidabili.
- Quando R^2 è elevato, diciamo prossimo a 1, il modello descrive bene i dati empirici, spiegando gran parte della variabilità osservata della variabile dipendente.
- La capacità *descrittiva* del modello è dunque buona, almeno relativamente ai dati osservati. Si può allora ritenere utilizzabile il modello a scopi *previsivi*?
- Il passaggio dalla descrizione dei dati osservati alla previsione di nuovi dati e comportamenti è un problema di generalizzabilità dei risultati di un modello (validità esterna)
- La possibilità di operare generalizzazioni si basa su assunzioni "ragionevoli" come:
 - "ordine" della natura: se le cose sono andate in un certo modo finora non c'è ragione che non funzionino così anche in futuro (e in passato: attualismo)
 - determinismo degli eventi: nessun evento avviene per caso, ma è determinato da precedenti eventi; ovvero, se le cose funzionano in un certo modo, la ragione c'è sempre, e quindi continueranno ...
- Questi principi sono plausibili, ma non assicurati: nessuno può garantire che anche le prossime osservazioni si comporteranno allo stesso modo.

ANALISI DELLA DIPENDENZA

- **Considerazioni sull'applicabilità di un modello (lineare)**
- Assai più azzardato è utilizzare un modello per fare previsioni per valori x esterni al campo di variazione dei dati osservati, sui quali il modello è stato stimato: questo tipo di previsioni, dette *estrapolazioni*, portano spesso a conclusioni errate (es. sopravvalutare un trend di crescita positivo)
- Raramente i fenomeni sono lineari, oppure lo sono solo su una parte limitata del loro campo di esistenza: utilizzare un modello lineare è quasi sempre una *semplificazione* del fenomeno reale, che può risultare accettabile per determinate applicazioni

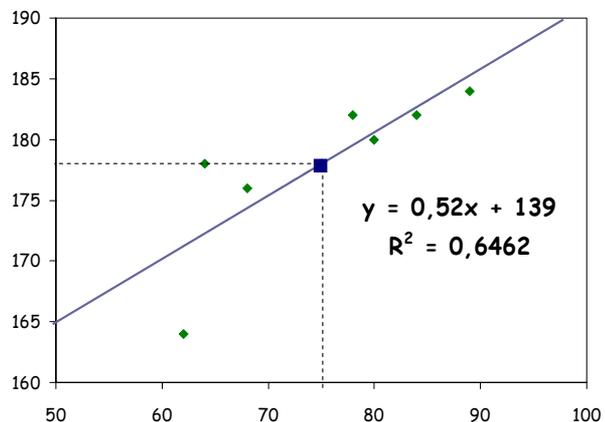


- I risultati del modello non devono essere accettati ciecamente: occorre sempre considerarne criticamente le possibili limitazioni

ANALISI DELLA DIPENDENZA

- **Esercizio.** Torniamo al nostro esempio, per valutare la bontà del modello stimato: determiniamo i punti stimati e calcoliamo la varianza spiegata e la varianza residua

| i | $x(i)$ | $y(i)$ |
|--------|--------|--------|
| 1 | 62 | 164 |
| 2 | 64 | 178 |
| 3 | 68 | 176 |
| 4 | 75 | 178 |
| 5 | 78 | 182 |
| 6 | 80 | 180 |
| 7 | 84 | 182 |
| 8 | 89 | 184 |
| Totale | 600 | 1424 |
| Media | 75,00 | 178,00 |



- Il modello spiega circa il 65% della varianza complessiva della Y : possiamo ritenerci soddisfatti?
- Nelle scienze sociali e comportamentali difficilmente si trovano modelli che spieghino molta varianza, perché i fenomeni sono complessi e dipendono da molti fattori diversi, inoltre le relazioni possono essere non lineari

ANALISI DELLA DIPENDENZA

- Prospetto di calcolo del coefficiente di determinazione R^2 :

| i | x(i) | y(i) | $\hat{y}(i)$ | $\hat{y}(i)-My$ | $y(i)-\hat{y}(i)$ | $y(i)-My$ | $[\hat{y}(i)-My]^2$ | $[y(i)-\hat{y}(i)]^2$ | $[y(i)-My]^2$ |
|--------|-------|--------|--------------|-----------------|-------------------|-----------|---------------------|-----------------------|---------------|
| 1 | 62 | 164 | 171,24 | -6,76 | -7,24 | -14,00 | 45,70 | 52,42 | 196,00 |
| 2 | 64 | 178 | 172,28 | -5,72 | 5,72 | 0,00 | 32,72 | 32,72 | 0,00 |
| 3 | 68 | 176 | 174,36 | -3,64 | 1,64 | -2,00 | 13,25 | 2,69 | 4,00 |
| 4 | 75 | 178 | 178,00 | 0,00 | 0,00 | 0,00 | 0,00 | 0,00 | 0,00 |
| 5 | 78 | 182 | 179,56 | 1,56 | 2,44 | 4,00 | 2,43 | 5,95 | 16,00 |
| 6 | 80 | 180 | 180,60 | 2,60 | -0,60 | 2,00 | 6,76 | 0,36 | 4,00 |
| 7 | 84 | 182 | 182,68 | 4,68 | -0,68 | 4,00 | 21,90 | 0,46 | 16,00 |
| 8 | 89 | 184 | 185,28 | 7,28 | -1,28 | 6,00 | 53,00 | 1,64 | 36,00 |
| Totale | 600 | 1424 | 1424 | 0,00 | 0,00 | 0,00 | 175,76 | 96,24 | 272,00 |
| Media | 75,00 | 178,00 | 178,00 | | | | 21,97 | 12,03 | 34,00 |

$$\sigma_{modello}^2 = 21,97 \quad \sigma_{residua}^2 = 12,03 \quad \sigma_y^2 = 34 = \sigma_{modello}^2 + \sigma_{residua}^2$$

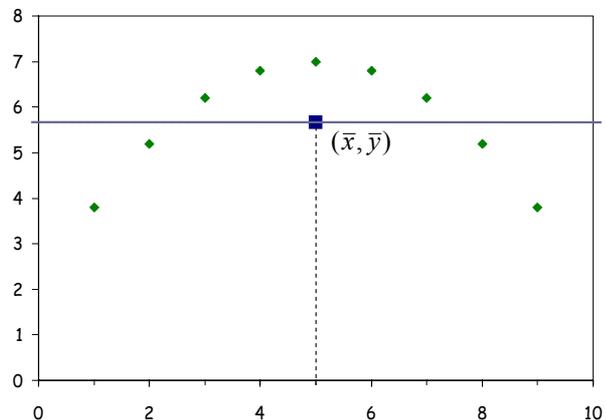
$$R^2 = \frac{\sigma_{modello}^2}{\sigma_y^2} = \frac{21,97}{34} = 0,6462 \quad oppure \quad R^2 = 1 - \frac{\sigma_{residua}^2}{\sigma_y^2} = 1 - \frac{12,03}{34} = 0,6462$$

- Conoscendo già il valore del coefficiente di correlazione, potevamo risparmiarci tutti questi calcoli: $R^2 = \rho_{xy}^2 = (0,8039)^2 = 0,6462$

ANALISI DELLA DIPENDENZA

- Esercizio.
Ritorniamo all'esempio di due variabili legate da una relazione quadratica esatta:
 $Y = 2 + 2x - 0,2x^2$

| i | x(i) | y(i) |
|--------|------|------|
| 1 | 1 | 3,8 |
| 2 | 2 | 5,2 |
| 3 | 3 | 6,2 |
| 4 | 4 | 6,8 |
| 5 | 5 | 7 |
| 6 | 6 | 6,8 |
| 7 | 7 | 6,2 |
| 8 | 8 | 5,2 |
| 9 | 9 | 3,8 |
| Totale | 45 | 51 |
| Media | 5,00 | 5,67 |



- Dal grafico si evidenzia chiaramente la relazione quadratica tra le due variabili, che disegna una parabola con la concavità rivolta verso il basso
- Come risulta la retta di regressione ?

ANALISI DELLA DIPENDENZA

- Esempio. Un caso particolare di retta di regressione si verifica quando la stima di b risulta uguale a 0:

$$\begin{cases} \hat{b} = 0 \\ \hat{a} = \bar{y} - b\bar{x} = \bar{y} \end{cases} \Rightarrow \hat{y}_i = \bar{y}$$

- La retta interseca l'asse delle ordinate nel punto $M(y)$
- La stima è sempre pari a $M(y)$, per qualunque valore di x
- La varianza spiegata dal modello è nulla

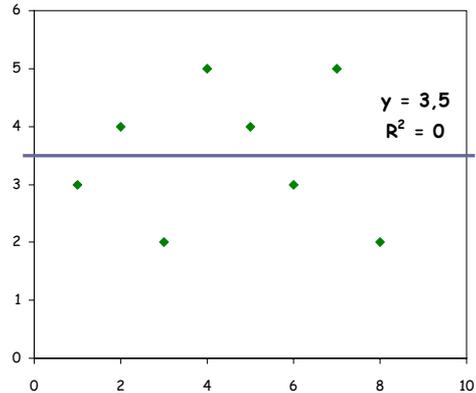
$$\sum (\hat{y}_i - \bar{y})^2 = 0$$

- La varianza residua è massima, cioè uguale alla varianza totale di Y

$$\sum (y_i - \hat{y}_i)^2 = \sum (y_i - \bar{y})^2$$

- Il coefficiente di determinazione R^2 :

$$R^2 = \frac{\sigma_{regress}^2}{\sigma_y^2} = 1 - \frac{\sigma_{resid}^2}{\sigma_y^2} = \rho_{xy}^2 = 0$$

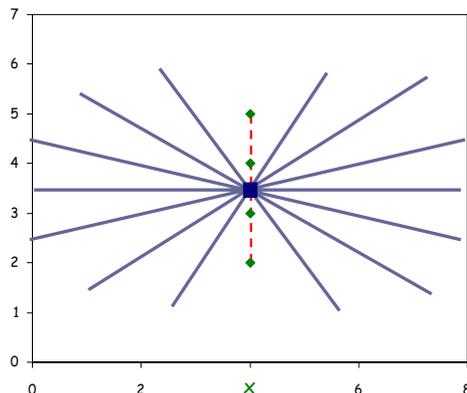


ANALISI DELLA DIPENDENZA

- **La Collinearità**
- Un problema, detto **collinearità**, si verifica quando i valori di X sono molto vicini tra loro: in questo caso la determinazione della retta di regressione risulta incerta
- Vediamo cosa succede nella situazione limite in cui tutti gli $x(i)$ vengano a coincidere esattamente:

$$\hat{b} = \frac{Cov(x, y)}{\sigma^2(x)} = \frac{Cov(k, y)}{\sigma^2(k)} = \frac{0}{0}$$

- La stima di b assume una forma *indeterminata*
- Ciò equivale a dire che *qualunque* retta passante per il punto medio del sistema è la retta interpolante ai minimi quadrati
- Non dimentichiamo infatti che i residui vengono calcolati parallelamente all'asse Y
- In pratica non si verificherà mai il caso limite della coincidenza di tutti i valori di X , ma basta che siano molto vicini perché il calcolo di b risulti molto instabile, e quindi il modello sia privo di significato
- Significato: se la X osservata non varia, non può neanche spiegare la variabilità di Y

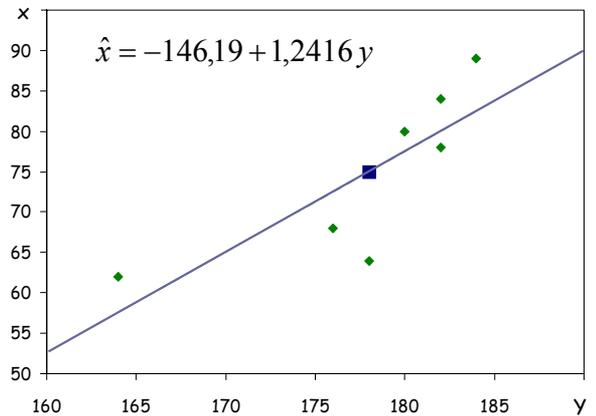


ANALISI DELLA DIPENDENZA

- L'altra Retta di regressione
- Cambiamo le carte in tavola, e questa volta stimiamo, sempre sugli stessi dati usati finora, il modello per prevedere X in funzione di Y:

$$\hat{x} = c + d y$$

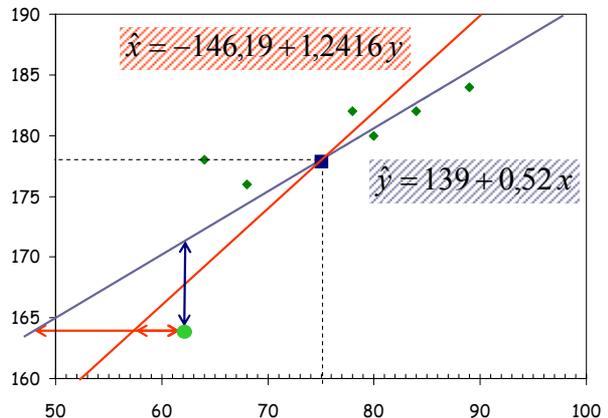
| i | x(i) | y(i) |
|--------|-------|--------|
| 1 | 62 | 164 |
| 2 | 64 | 178 |
| 3 | 68 | 176 |
| 4 | 75 | 178 |
| 5 | 78 | 182 |
| 6 | 80 | 180 |
| 7 | 84 | 182 |
| 8 | 89 | 184 |
| Totale | 600 | 1424 |
| Media | 75,00 | 178,00 |



- Il grafico risulta rovesciato rispetto a prima, infatti questa volta troviamo la variabile Y sull'asse delle ascisse e la X sull'asse delle ordinate

ANALISI DELLA DIPENDENZA

- Riportando i valori stimati dai due modelli su uno stesso grafico, ci accorgiamo che la nuova retta di regressione non coincide con quella stimata in precedenza
- Come si spiega ?
- Il metodo dei minimi quadrati valuta i residui lungo l'asse della variabile indipendente
- I residui calcolati lungo l'asse Y risultano in generale diversi da quelli calcolati lungo l'asse X
- Quindi si hanno sempre due rette di regressione, che in generale non coincidono
- La retta di regressione per stimare Y in funzione di X è stata ottenuta minimizzando la somma dei quadrati dei residui di Y, calcolati parallelamente all'asse Y
- La retta di regressione per stimare X in funzione di Y si ottiene minimizzando la somma dei quadrati dei residui di X, calcolati parallelamente all'asse X



ANALISI DELLA DIPENDENZA

- Consideriamo le due rette di regressione e vediamo cosa hanno in comune:

$$\left. \begin{aligned} \hat{y} &= a + bx \Rightarrow \hat{b} = \frac{\sigma_{xy}}{\sigma_x^2} \\ \hat{x} &= c + dy \Rightarrow \hat{d} = \frac{\sigma_{xy}}{\sigma_y^2} \end{aligned} \right\} R^2 = \rho_{xy}^2 = \left(\frac{\sigma_{xy}}{\sigma_x \sigma_y} \right)^2 = \rho_{yx}^2$$

- Le rette di regressione ai minimi quadrati risultano diverse, ma il coefficiente di determinazione R^2 non cambia, essendo il quadrato del coefficiente di correlazione, che è una quantità simmetrica
- La frazione di variabilità di Y spiegata dalla regressione di Y in funzione di X è pari alla frazione di variabilità di X spiegata dalla regressione di X in funzione di Y
- C'è una relazione tra i due coefficienti di regressione b e d:

$$b \cdot d = \frac{\sigma_{xy}}{\sigma_x^2} \frac{\sigma_{xy}}{\sigma_y^2} = \frac{\sigma_{xy}^2}{\sigma_x^2 \sigma_y^2} = \rho^2 \quad \text{quindi} \quad \rho = \sqrt{bd}$$

- Le due rette di regressione coincidono quando i punti osservati sono perfettamente allineati: in questa situazione $r=1$ e quindi:

$$\rho = 1 \Rightarrow bd = 1 \Rightarrow b = 1/d$$

ANALISI DELLA DIPENDENZA

- Il Modello senza intercetta**

- Torniamo alla stima di Y in funzione di X, e consideriamo il modello ridotto eliminando il parametro a, ovvero una retta senza intercetta:

$$\hat{y} = bx$$

| i | x(i) | y(i) |
|--------|-------|--------|
| 1 | 62 | 164 |
| 2 | 64 | 178 |
| 3 | 68 | 176 |
| 4 | 75 | 178 |
| 5 | 78 | 182 |
| 6 | 80 | 180 |
| 7 | 84 | 182 |
| 8 | 89 | 184 |
| Totale | 600 | 1424 |
| Media | 75,00 | 178,00 |

- La stima di questo modello è molto semplice: dobbiamo minimizzare la somma dei quadrati dei residui, che in questo caso sono una funzione di una sola variabile (b)

$$\sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \sum_{i=1}^n (y_i - b x_i)^2 = \min$$

- Per determinare il punto di minimo, deriviamo la funzione rispetto a b, ottenendo una sola equazione:

$$-2 \sum_{i=1}^n (y_i - b x_i) x_i = 0$$

da cui:

$$\sum (x_i y_i - b x_i^2) = 0 \Rightarrow \sum x_i y_i - b \sum x_i^2 = 0$$

- La stima di b risulta diversa da quella del modello completo :

$$\hat{b} = \frac{\sum x_i y_i}{\sum x_i^2}$$

ANALISI DELLA DIPENDENZA

- Prospetto di calcolo del coefficiente di regressione:

| i | x(i) | y(i) | x(i) ² | x(i) y(i) |
|--------|-------|--------|-------------------|-----------|
| 1 | 62 | 164 | 3844 | 10168 |
| 2 | 64 | 178 | 4096 | 11392 |
| 3 | 68 | 176 | 4624 | 11968 |
| 4 | 75 | 178 | 5625 | 13350 |
| 5 | 78 | 182 | 6084 | 14196 |
| 6 | 80 | 180 | 6400 | 14400 |
| 7 | 84 | 182 | 7056 | 15288 |
| 8 | 89 | 184 | 7921 | 16376 |
| Totale | 600 | 1424 | 45650 | 107138 |
| Media | 75,00 | 178,00 | | |

$$\hat{b} = \frac{M(x \cdot y)}{M(x^2)} = \frac{107138}{45650} = 2,3469$$

$$\hat{y}_i = 2,3469 x_i$$

- E' facile verificare che questa retta di regressione NON passa per il punto medio del sistema :

$$\hat{y}(\bar{x}) = 2,3469 \cdot 75 = 176,02 \neq 178$$

- Adesso vogliamo di valutare la bontà del modello: calcoliamo dunque la varianza residua e quella di regressione spiegata dal modello, e vediamo cosa succede ...

ANALISI DELLA DIPENDENZA

- Prospetto di calcolo del coefficiente di determinazione R²:

| i | x(i) | y(i) | y^(i) | y^(i)-My | y(i)-y^(i) | y(i)-My | [y^(i)-My] ² | [y^(i)-y(i)] ² | [y(i)-My] ² |
|--------|-------|--------|---------|----------|------------|---------|-------------------------|---------------------------|------------------------|
| 1 | 62 | 164 | 145,51 | -32,49 | 18,49 | -14,00 | 1055,57 | 341,86 | 196,00 |
| 2 | 64 | 178 | 150,20 | -27,80 | 27,80 | 0,00 | 772,59 | 772,59 | 0,00 |
| 3 | 68 | 176 | 159,59 | -18,41 | 16,41 | -2,00 | 338,85 | 269,22 | 4,00 |
| 4 | 75 | 178 | 176,02 | -1,98 | 1,98 | 0,00 | 3,92 | 3,92 | 0,00 |
| 5 | 78 | 182 | 183,06 | 5,06 | -1,06 | 4,00 | 25,62 | 1,13 | 16,00 |
| 6 | 80 | 180 | 187,76 | 9,76 | -7,76 | 2,00 | 95,17 | 60,15 | 4,00 |
| 7 | 84 | 182 | 197,14 | 19,14 | -15,14 | 4,00 | 366,47 | 229,32 | 16,00 |
| 8 | 89 | 184 | 208,88 | 30,88 | -24,88 | 6,00 | 953,45 | 618,92 | 36,00 |
| Totale | 600 | 1424 | 1408,17 | -15,83 | 15,83 | 0,00 | 3611,63 | 2297,10 | 272,00 |
| Media | 75,00 | 178,00 | 176,02 | | | | 451,45 | 287,14 | 34,00 |

$$\sigma_{modello}^2 = 451,45 \quad \sigma_{residua}^2 = 287,14 \quad \sigma_y^2 = 34 \neq \sigma_{modello}^2 + \sigma_{residua}^2 !!$$

$$R^2 = \frac{\sigma_{modello}^2}{\sigma_y^2} \neq 1 - \frac{\sigma_{residua}^2}{\sigma_y^2} \neq \rho^2$$

- La varianza residua è maggiore della varianza totale di Y ...
- R² perde ogni significato, perché non vale più la scomposizione della varianza

ANALISI DELLA DIPENDENZA

- Rispetto al sistema di equazioni normali derivate per la stima dei parametri del modello completo, in pratica non è stata imposta la prima condizione :

$$\begin{cases} \sum (y_i - a - b x_i) = 0 \\ \sum (y_i - a - b x_i) x_i = 0 \end{cases} \Rightarrow \begin{cases} \sum y_i - n a - b \sum x_i = 0 \\ \sum x_i y_i - a \sum x_i - b \sum x_i^2 = 0 \end{cases} \Rightarrow$$

$$\begin{cases} n \bar{y} - n a - b n \bar{x} = 0 \\ \sum x_i y_i - a n \bar{x} - b \sum x_i^2 = 0 \end{cases} \Rightarrow \begin{cases} a = \bar{y} - b \bar{x} \\ \sum x_i y_i - a n \bar{x} - b \sum x_i^2 = 0 \end{cases}$$

- Come conseguenza immediata, non vale più la prima proprietà dei residui:
 - la somma dei residui di regressione del modello ridotto non risulta uguale a 0
 - non è nulla nemmeno la somma degli scarti dei valori stimati dalla $M(y)$
 - la media dei valori stimati non coincide con la media di Y
 - la retta non passa per il baricentro del sistema
- La seconda proprietà continua a valere perché è la condizione imposta dall'unica equazione normale, derivata per la stima ai minimi quadrati del modello ridotto

ANALISI DELLA DIPENDENZA

- Proprietà dei residui di regressione nel modello senza intercetta

$$\begin{cases} \sum_{i=1}^n \varepsilon_i = \sum_{i=1}^n (y_i - \hat{y}_i) = 0 \\ \sum_{i=1}^n (y_i - \hat{y}_i) x_i = 0 \\ \sum_{i=1}^n (y_i - \hat{y}_i) \hat{y}_i = 0 \\ \sum_{i=1}^n (y_i - \hat{y}_i) (\hat{y}_i - \bar{y}) = 0 \end{cases} \Rightarrow \begin{cases} \hat{y}_i = b x_i \\ y_i = \hat{y}_i + \varepsilon_i \\ \varepsilon_i = y_i - \hat{y}_i \end{cases}$$

$$= \sum_{i=1}^n (y_i - \hat{y}_i) b x_i = b \sum_{i=1}^n (y_i - \hat{y}_i) x_i = 0$$

$$= \sum_{i=1}^n (y_i - \hat{y}_i) \hat{y}_i - \bar{y} \sum_{i=1}^n (y_i - \hat{y}_i) \neq 0$$

- Non valendo la quarta proprietà, non vale più nemmeno la scomposizione della devianza totale, perché il doppio prodotto non si annulla:

$$\sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2 + \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 + 2 \sum_{i=1}^n (y_i - \hat{y}_i) (\hat{y}_i - \bar{y}) =$$

$$- 2 \bar{y} \sum_{i=1}^n (y_i - \hat{y}_i)$$

ANALISI DELLA DIPENDENZA

Esempio.

Verifica empirica delle 4 proprietà dei residui di regressione ai minimi quadrati:

| i | x(i) | y(i) | y(i) [^] | y [^] -My | y-y [^] | (y-y [^]) x | (y-y [^]) y [^] | (y-y [^])(y [^] -My) |
|--------|-------|--------|-------------------|--------------------|------------------|-----------------------|------------------------------------|---|
| 1 | 62 | 164 | 145,51 | -32,49 | 18,49 | 1146,3467 | 2690,4117 | -600,7127 |
| 2 | 64 | 178 | 150,20 | -27,80 | 27,80 | 1778,9168 | 4175,0184 | -772,5940 |
| 3 | 68 | 176 | 159,59 | -18,41 | 16,41 | 1115,7303 | 2618,5567 | -302,0314 |
| 4 | 75 | 178 | 176,02 | -1,98 | 1,98 | 148,4392 | 348,3785 | -3,9172 |
| 5 | 78 | 182 | 183,06 | 5,06 | -1,06 | -82,8081 | -194,3461 | -5,3737 |
| 6 | 80 | 180 | 187,76 | 9,76 | -7,76 | -620,4425 | -1456,1439 | -75,6593 |
| 7 | 84 | 182 | 197,14 | 19,14 | -15,14 | -1272,0379 | -2985,4018 | -289,8930 |
| 8 | 89 | 184 | 208,88 | 30,88 | -24,88 | -2214,1445 | -5196,4735 | -768,1845 |
| Totale | 600 | 1424 | 1408,17 | -15,83 | 15,83 | 0,0000 | 0,0000 | -2818,3658 |
| Media | 75,00 | 178,00 | 176,02 | | | | | -352,2957 |

- Verifichiamo che la varianza totale di Y è ottenibile come:

$$\begin{aligned}\sigma_y^2 &= \sigma_{\text{modello}}^2 + \sigma_{\text{residua}}^2 + 2 \frac{-\bar{y} \sum (y_i - \hat{y}_i)}{8} = \\ &= 451,45 + 287,14 + 2 \cdot (-178 \cdot 15,83/8) = \\ &= 451,45 + 287,14 + 2 \cdot (-352,2957) = 34\end{aligned}$$

ANALISI DELLA DIPENDENZA

- Il modello ridotto, per la mancanza dell'intercetta, obbliga la retta a passare per l'origine degli assi:

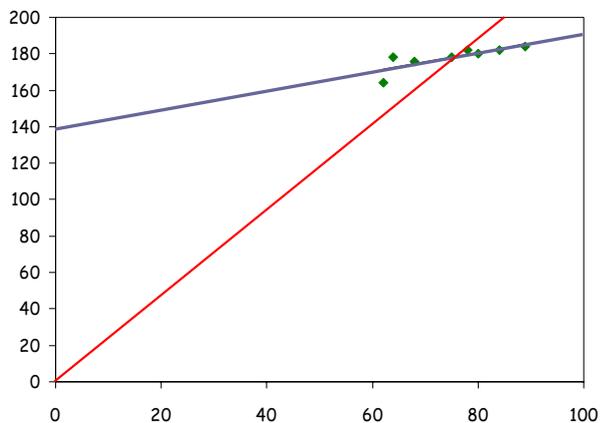
$$\hat{y} = 2,3469 x$$

- L'introduzione di questo vincolo peggiora la capacità del modello di adattarsi ai dati osservati, rispetto al modello completo

$$\hat{y} = 139 + 0,52 x$$

- In generale, l'introduzione di un vincolo in un modello ne peggiora sempre la capacità di adattamento
- Possiamo dire che, a parità di predittori, l'aumento di un parametro migliora sempre (o almeno non peggiora) la capacità descrittiva di un modello, mentre l'eliminazione di un parametro la riduce
- Per migliorare l'adattamento e descrivere anche relazioni non lineari, potremmo ad esempio passare ad un modello di secondo grado, con tre parametri:

$$\hat{y} = a + b x + c x^2$$

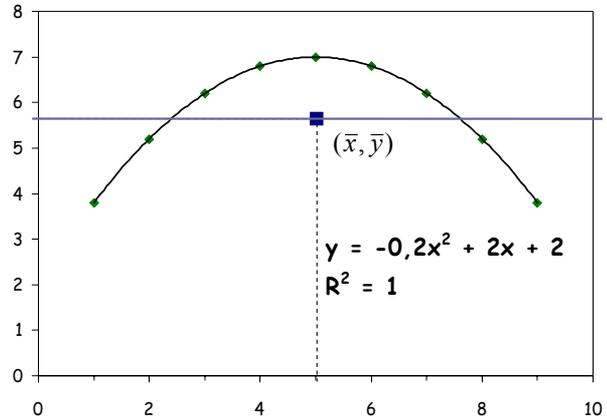


ANALISI DELLA DIPENDENZA

- Stimiamo ai minimi quadrati un modello di regressione quadratico sui dati già analizzati in precedenza con il modello di primo grado (retta)

$$\hat{y} = a + bx + cx^2$$

| i | x(i) | y(i) |
|--------|------|------|
| 1 | 1 | 3,8 |
| 2 | 2 | 5,2 |
| 3 | 3 | 6,2 |
| 4 | 4 | 6,8 |
| 5 | 5 | 7 |
| 6 | 6 | 6,8 |
| 7 | 7 | 6,2 |
| 8 | 8 | 5,2 |
| 9 | 9 | 3,8 |
| Totale | 45 | 51 |
| Media | 5,00 | 5,67 |



- In questo caso dovremo minimizzare la somma dei quadrati dei residui del modello rispetto ai tre parametri (a, b, c) ottenendo un sistema di 3 equazioni normali
- Risolvendo il sistema, troviamo un modello che si adatta perfettamente ai dati osservati: $R^2=1$