



[www.sce.unimore.it](http://www.sce.unimore.it)

Scienze della Comunicazione  
e dell'Economia

# REGRESSIONE LINEARE SEMPLICE

Legacy Edition  
Copyright 25 ottobre 2012

Luca La Rocca  
[luca.larocca@unimore.it](mailto:luca.larocca@unimore.it)

UNIVERSITÀ DEGLI STUDI DI MODENA E REGGIO EMILIA



Previsione di un carattere quantitativo

Correlazione lineare

Retta di regressione

Propensione marginale all'importazione

## Previsione di un carattere quantitativo

Correlazione lineare

Retta di regressione

Propensione marginale all'importazione

Consideriamo il caso di un'azienda che abbia appena assunto un nuovo venditore e voglia prevederne le vendite nell'anno a venire:

*supponendo per semplicità che*

- ▶ *l'azienda continui a vendere gli stessi prodotti allo stesso prezzo,*
- ▶ *il venditore neoassunto sia **omogeneo** ai venditori già in forza all'azienda,*

*la **previsione** potrà basarsi sulle vendite realizzate dai venditori già in forza all'azienda nel corso dell'ultimo anno.*

La tabella seguente (Rees, 2001) riporta le vendite realizzate (in migliaia di sterline inglesi, nell'ultimo esercizio) da  $n = 8$  venditori di una certa azienda. . .

Venditore	Vendite (migliaia di sterline)
Andrea	105
Barbara	120
Carlo	160
Diana	155
Elisa	70
Francesco	150
Giovanna	185
Massimo	130
Totale	1075

Vogliamo prevedere il **numero aleatorio**

$$Y_{n+1} = \text{“vendite del neoassunto”}$$

sulla base delle vendite osservate

$$y_1, \dots, y_n$$

realizzate dagli  $n$  venditori già in forza all'azienda. . .

. . . quale distribuzione useremo per  $Y_{n+1}$ ?

In primo luogo sembra naturale assegnare

$$\begin{aligned}\mathbb{E}[Y_{n+1}] &= \bar{y} \\ \text{sd}(Y_{n+1}) &= \text{sd}_y\end{aligned}$$

dove  $\text{sd}_y$  è la deviazione standard di  $y_1, \dots, y_n \dots$

... per esempio, con riferimento ai dati di Rees, assegneremo

$$\begin{aligned}\mathbb{E}[Y_{n+1}] &= 134.4 \\ \text{sd}(Y_{n+1}) &= 33.8\end{aligned}$$

Valore atteso e deviazione standard di  $Y_{n+1}$  bastano per dare:

- ▶ una **previsione puntuale** (con **errore standard di previsione**)

$$Y_{n+1} = 134.4 \pm 33.8$$

- ▶ una **previsione per intervallo** (basata sul teorema di Chebyshev)

$$66.8 = 134.4 - 2 \times 33.8 \leq Y_{n+1} \leq 134.4 + 2 \times 33.8 = 202.0$$

con probabilità almeno pari al 75%.

Si noti che un **intervallo di previsione**

- ▶ si riferisce a un futuro valore osservabile
- ▶ in esso contenuto con “buona” probabilità

mentre un **intervallo di stima**

- ▶ si riferisce a un parametro incognito
- ▶ in esso contenuto a meno di non osservare un campione “cattivo”

e dunque si tratta di due cose diverse (adottando l’approccio frequentista e non quello bayesiano).

In secondo luogo possiamo assegnare a  $Y_{n+1}$ , come approssimazione, una **distribuzione normale**: nella misura in cui tale approssimazione è valida, essa ci consente di migliorare la nostra previsione per intervallo:


$$66.8 = 134.4 - 2 \times 33.8 \leq Y_{n+1} \leq 134.4 + 2 \times 33.8 = 202.0$$

con probabilità 95%, oppure

$$95.5 = 134.4 - 1.15 \times 33.8 \leq Y_{n+1} \leq 134.4 + 1.15 \times 33.8 = 173.3$$

con probabilità 75% (in quanto  $z_{12.5\%} = 1.15$ ).

Si ricordi che il teorema di Chebyshev tipicamente sovrastima pesantemente la variabilità di una distribuzione (caso peggiore).



In realtà attribuendo direttamente  $\bar{y}$  e  $sd_y$  alla distribuzione di  $Y_{n+1}$ , senza considerarli stime di  $\mu$  e  $\sigma$  incognite, sottovalutiamo la nostra **incertezza** sul fenomeno oggetto di previsione.

Converrà allora porre  $\mathbb{E}[Y_{n+1}] = \bar{y}$  e

$$\hat{se}(Y_{n+1}) = \sqrt{s_y^2 + \frac{s_y^2}{n}} = s_y \sqrt{1 + \frac{1}{n}}$$

dove  $s_y = sd_y \sqrt{\frac{n}{n-1}}$  tiene conto dell'incertezza su  $\sigma$  e l'incertezza su  $\mu$  è incorporata sommando il quadrato del suo errore standard stimato alla varianza stimata (fonti indipendenti di incertezza)...

... dopo di che assegneremo a  $\frac{Y_{n+1} - \mathbb{E}[Y_{n+1}]}{\hat{se}(Y_{n+1})}$  la **distribuzione t di Student** con  $n - 1$  gradi di libertà (invece di quella normale standard).

Nell'esempio di Rees troveremo

$$\hat{se}(Y_{n+1}) = 33.8 \times \sqrt{\frac{8}{7}} \times \sqrt{1 + \frac{1}{8}} = 33.8 \times \sqrt{\frac{9}{7}} = 38.3$$

e dunque (invece che  $66.8 \leq Y_{n+1} \leq 202.0$ ) prevederemo

$$44.0 = 134.4 - 2.36 \times 38.3 \leq Y_{n+1} \leq 134.4 + 2.36 \times 38.3 = 224.8$$

con probabilità 95% (visto che  $t_{0.025} = 2.36$  con 7 gradi di libertà).

Supponiamo ora che l'azienda si avvalga di un **test attitudinale** per la selezione dei suoi venditori:

*in questo caso oltre alla **variabile risposta**  $Y$  (le vendite) abbiamo una **variabile esplicativa**  $X$  (il punteggio al test) sulla base della quale (conoscendo il punteggio ottenuto dal venditore neoassunto) è ragionevole sperare di migliorare la nostra previsione.*

La tabella seguente (Rees, 2001) riporta le vendite realizzate (in migliaia di sterline inglesi, nell'ultimo esercizio) e il punteggio conseguito al test (su un'opportuna scala) da  $n = 8$  venditori di una certa azienda: se il punteggio del neoassunto è  $x_{n+1} = 60$ , quale sarà la nostra previsione? come useremo questa informazione?

	Vendite ( $Y$ )	Punteggio ( $X$ )
Andrea	105	45
Barbara	120	75
Carlo	160	85
Diana	155	65
Elisa	70	50
Francesco	150	70
Giovanna	185	80
Massimo	130	55
Totale	1075	525

Previsione di un carattere quantitativo


**Correlazione lineare**

Retta di regressione

Propensione marginale all'importazione

La distribuzione doppia (o congiunta) di due caratteri quantitativi (continui)  $X$  e  $Y$  si può rappresentare nel piano euclideo mediante un **diagramma di dispersione**: ogni unità statistica sarà rappresentata da un simbolo (es. una croce) centrato nel punto che ha come coordinate, rispetto a un'opportuna coppia di assi cartesiani ortogonali, i valori assunti da  $X$  e  $Y$  sull'unità rappresentata.

La figura seguente rappresenta i dati di Rees (in verde i venditori per i quali i caratteri sono entrambi “sopra media” o entrambi “sotto media”, in rosso i venditori per i quali un carattere è “sopra media” e l'altro “sotto media”). . .




... diremo che c'è

- ▶ **concordanza** tra  $X$  e  $Y$  se modalità “grandi” di  $X$  si associano più frequentemente a modalità “grandi” di  $Y$ , mentre modalità “piccole” di  $X$  si associano più frequentemente a modalità “piccole” di  $Y$  (come nel precedente diagramma);
- ▶ **discordanza** tra  $X$  e  $Y$  se modalità “grandi” di  $X$  si associano più frequentemente a modalità “piccole” di  $Y$ , mentre modalità “piccole” di  $X$  si associano più frequentemente a modalità “grandi” di  $Y$  (es. temperatura e consumo di elettricità in una località fredda, come mostra il diagramma successivo... ovvero la Figura 16.2.2 di Borra & Di Ciaccio, 2008).

Questo tipo di associazione tra caratteri (ordinali) si dice anche **cograduazione/contrograduazione**.





Diremo che c'è **interdipendenza lineare** tra  $X$  e  $Y$  se le loro modalità osservate tendono a disporsi lungo una retta, ovvero se la loro “nuvola di punti” ha forma (approssimativamente) “ellissoidale”:

- ▶ questa tendenza è esibita in una certa misura dal diagramma di dispersione che rappresenta i dati di Rees;
- ▶ la Figura 16.2.2 di Borra & Di Ciaccio (2008) esibisce questa tendenza limitatamente ai valori bassi della temperatura (oppure ai valori elevati, ma con diversa pendenza. . . infatti in questo secondo caso il consumo di elettricità si mantiene praticamente costante. . . complessivamente si tratta di interdipendenza lineare “a tratti”).

La concordanza/discordanza tra caratteri (quantitativi) linearmente interdipendenti si dice **correlazione lineare**. . .

... se è stato riscontrato per via grafica che qualitativamente  $X$  e  $Y$  sono linearmente correlate, una quantificazione della forza della loro associazione è fornita dal **coefficiente di correlazione lineare** tra  $X$  e  $Y$ :

$$-1 \leq r_{xy} \leq +1$$

dove il segno tiene conto della direzione in cui l'associazione si sviluppa (concordanza/discordanza).

In altre parole: il coefficiente di correlazione lineare è una misura algebrica di quanto una nuvola di punti ellissoidale (ellissoide) sia allungata (abbia un asse più lungo dell'altro) in diagonale.

Il coefficiente di correlazione lineare  $r_{xy}$  gode delle seguenti proprietà:

- ▶  $r_{xy} > 0$  se e soltanto se l'ellissoide è allungato in direzione Sud Ovest - Nord Est (concordanza);
- ▶  $r_{xy} < 0$  se e soltanto se l'ellissoide è allungato in direzione Nord Ovest - Sud Est (discordanza);
- ▶  $r_{xy} = 0$  se e soltanto se l'ellissoide ha gli assi paralleli agli assi coordinati (assenza di correlazione lineare);
- ▶  $|r_{xy}| = 1$  se e soltanto se le modalità osservate si dispongono esattamente lungo una retta inclinata (ellissoide degenera);
- ▶ tanto più grande è  $|r_{xy}|$ , tanto più l'ellissoide sarà allungato e i suoi punti si disporranno approssimativamente lungo una retta (vedremo che  $r_{xy}^2$  potrà interpretarsi come una proporzione).




Osserviamo che:

- ▶ il caso dell'ellissoide degenere individuato da  $r_{xy} = 1$  o  $r_{xy} = -1$  è il caso di una “relazione funzionale lineare” tra  $X$  e  $Y$  (caso che sarà illustrato più avanti);
- ▶ il caso dell'ellissoide con assi paralleli agli assi coordinati ( $r_{xy} = 0$ ) è il caso dell'indipendenza stocastica tra  $X$  e  $Y$  (nell'ambito dell'assunto qualitativo di interdipendenza lineare tra  $X$  e  $Y$ );
- ▶ il coefficiente di correlazione lineare non misura altri tipi di associazione tra  $X$  e  $Y$  (es. non misura la dipendenza quadratica di  $Y$  da  $X$ ).


I due diagrammi di dispersione seguenti illustrano queste due ultime situazioni. . .



**Dipendenza Quadratica**



**Indipendenza Stocastica**



Il coefficiente di correlazione lineare tra  $X$  e  $Y$  è **definito** come

$$r_{xy} = \frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{sd_x} \right) \left( \frac{y_i - \bar{y}}{sd_y} \right)$$

ovvero come “media del prodotto delle variabili standardizzate”; si avrà

- ▶ un contributo positivo per ogni coppia di scarti concordi

$$x_i > \bar{x} \quad \text{e} \quad y_i > \bar{y} \quad \text{oppure} \quad x_i < \bar{x} \quad \text{e} \quad y_i < \bar{y},$$

- ▶ un contributo negativo per ogni coppia di scarti discordi

$$x_i > \bar{x} \quad \text{e} \quad y_i < \bar{y} \quad \text{oppure} \quad x_i < \bar{x} \quad \text{e} \quad y_i > \bar{y}.$$

Per il **calcolo** del coefficiente di correlazione lineare tra  $X$  e  $Y$  conviene avvalersi della formula

$$r_{xy} = \frac{\overline{xy} - \bar{x}\bar{y}}{sd_x sd_y}$$

dove  $\overline{xy}$  è la media del prodotto delle due variabili:

$$\overline{xy} = \frac{1}{n} \sum_{i=1}^n x_i y_i$$

la tabella seguente illustra il calcolo di  $\overline{xy} = 73350/8 = 9168.8$  per l'esempio del venditore neoassunto e permette di trovare

$$r_{xy} = \frac{9168.8 - 134.4 \times 65.6}{33.8 \times 13.6} = 0.77.$$

	Vendite (Y)	Punteggio (X)	Prodotto (XY)
Andrea	105	45	4725
Barbara	120	75	9000
Carlo	160	85	13600
Diana	155	65	10075
Elisa	70	50	3500
Francesco	150	70	10500
Giovanna	185	80	14800
Massimo	130	55	7150
Totale	1075	525	73350

Previsione di un carattere quantitativo

Correlazione lineare

**Retta di regressione**

Propensione marginale all'importazione

Tornando al problema di prevedere  $Y_{n+1}$ , sapendo che  $x_{n+1} = 60$ , osserviamo innanzitutto che


*se le osservazioni si disponessero esattamente lungo una retta, troveremmo una **relazione funzionale lineare** tra le vendite  $Y$  e il punteggio al test  $X$ , ovvero avremmo*

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

dove

- ▶  $\beta_0$  è l'**intercetta** e
- ▶  $\beta_1$  è il **coefficiente angolare** (o "pendenza")

*della retta in questione (univocamente determinata dall'ellissoide degenere)...*



La figura precedente illustra la situazione limite di una relazione funzionale lineare tra  $Y$  e  $X$  prendendo  $\beta_0 = 10$  e  $\beta_1 = 2$ , conservando  $x_1, \dots, x_8$  e sostituendo  $y_i$  con  $\beta_0 + \beta_1 x_i$ , per ogni  $i = 1, \dots, 8$ .

Si noti come l'esistenza di una relazione funzionale lineare tra  $Y$  e  $X$  ci permetterebbe di ottenere, conoscendo il punteggio  $x_{n+1}$  ottenuto dal neoassunto al test attitudinale, una **previsione esatta** delle sue vendite:

$$y_{n+1} = \beta_0 + \beta_1 x_{n+1}$$

In realtà le osservazioni non si dispongono esattamente lungo una retta, ma si limitano a esibire una certa correlazione lineare (formando un ellissoide con  $r_{xy} = 0.77$ ) di modo che non esiste una retta che passi per tutte le osservazioni, mentre ne esistono diverse che passano attraverso la nube (più o meno “vicine” alle varie osservazioni).


In questo caso possiamo ipotizzare una **relazione statistica lineare** tra le vendite  $Y$  e il punteggio al test  $X$ :

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


dove  $\epsilon$  è un termine di errore (casuale) specifico del venditore; le due figure seguenti mostrano due possibili relazioni statistiche lineari da cui i dati dell'esempio potrebbero avere avuto origine. . .



Relazione Statistica Lineare (Ipotesi 1)



Relazione Statistica Lineare (Ipotesi 2)



Nell'ipotesi di relazione statistica lineare tra  $Y$  e  $X$ , dati i **coefficienti di regressione**  $\beta_0$  e  $\beta_1$  e l'**errore standard di regressione**  $\sigma = sd(\epsilon)$ , assumendo  $\mathbb{E}[\epsilon] = 0$ , la previsione di  $Y_{n+1}$  conoscendo  $x_{n+1}$  sarà

$$Y_{n+1} = \beta_0 + \beta_1 x_{n+1} \pm \sigma$$

e si tratterà di una **previsione migliorata** perché

$$\sigma < sd(Y_{n+1})$$

in quanto, supponendo  $\epsilon_{n+1}$  e  $X_{n+1}$  indipendenti, ovvero supponendo la variabile  **$X$  esogena**, si trova

$$Var(Y_{n+1}) = \beta_1^2 Var(X_{n+1}) + \sigma^2.$$

Quali valori prenderemo per  $\beta_0$ ,  $\beta_1$  e  $\sigma$ ?

Non conoscendo i valori veri (di popolazione) ricorreremo a delle **stime**  $\hat{\beta}_0$ ,  $\hat{\beta}_1$  e  $\hat{\sigma}$  il cui calcolo (sulla base delle modalità osservate di  $X$  e  $Y$ ) ci accingiamo a discutere...

... supponiamo, in prima battuta, di avere già trovato  $\hat{\beta}_0$  e  $\hat{\beta}_1$ : si dice **residuo** dell' $i$ -esima osservazione  $y_i$  rispetto alla retta con intercetta  $\hat{\beta}_0$  e pendenza  $\hat{\beta}_1$  la quantità empirica

$$e_i = y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i = y_i - \hat{y}_i$$

ovvero l'errore di previsione stimato per l' $i$ -esima osservazione, usando  $\hat{\beta}_0$  e  $\hat{\beta}_1$  come stime di  $\beta_0$  e  $\beta_1$ ; le quantità  $\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_i$ ,  $i = 1, \dots, n$ , si dicono **valori predetti**.




Poiché il residuo  $e_i$  stima l'errore di previsione  $\epsilon_i$ , per  $i = 1, \dots, n$ , appare naturale (ed è sempre possibile) richiedere che  $\hat{\beta}_0$  e  $\hat{\beta}_1$  determinino residui a media nulla:


$$\bar{e} = \frac{e_1 + \dots + e_n}{n} = 0$$

Stimeremo allora l'errore standard di regressione  $\sigma$  mediante la deviazione standard dei residui:

$$\hat{\sigma} = \sqrt{\frac{e_1^2 + \dots + e_n^2}{n}}$$

Perché dunque non fare tutto il possibile per rendere piccola  $\hat{\sigma}$ ?  
In effetti è il criterio che si segue per trovare  $\hat{\beta}_0$  e  $\hat{\beta}_1 \dots$





... più in dettaglio, definito lo **Scarto Quadratico Medio** della retta con intercetta  $\beta_0$  e pendenza  $\beta_1$  rispetto alle osservazioni  $(x_1, y_1) \dots (x_n, y_n)$  come

$$SQM(\beta_0, \beta_1) = \frac{1}{n} \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i)^2$$


di modo che  $\hat{\sigma} = \sqrt{SQM(\hat{\beta}_0, \hat{\beta}_1)}$ , determineremo  $\hat{\beta}_0$  e  $\hat{\beta}_1$  minimizzando  $SQM(\beta_0, \beta_1)$  sotto il vincolo (in realtà superfluo)

$$\frac{1}{n} \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i) = \bar{y} - \beta_0 - \beta_1 \bar{x} = 0.$$

La figura seguente mostra la superficie individuata da  $SQM(\beta_0, \beta_1)$  al variare di  $\beta_0$  e  $\beta_1$  (nell'esempio dei venditori)...



Superficie della Funzione di Perdita



Esiste un unico minimo (tale che  $\bar{y} = \beta_0 + \beta_1 \bar{x}$ )



... sono dunque univocamente determinate le stime ai **minimi quadrati**

$$\hat{\beta}_1 = r_{xy} \frac{sd_y}{sd_x}$$
$$\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x}$$

che nel caso del venditore neoassunto valgono

$$\hat{\beta}_1 = 0.77 \times \frac{33.8}{13.6} = 1.9$$
$$\hat{\beta}_0 = 134.4 - 1.9 \times 65.6 = 9.8$$

come già riportato nel grafico della retta di regressione.

Con riferimento all'esempio dei venditori, i coefficienti di regressione (stimati) godono della seguente **interpretazione**:

$$\hat{\beta}_1 = 1.9 \text{ migliaia di sterline / punto della scala del test}$$

è l'incremento nelle vendite corrispondente all'incremento di un punto nel risultato del test, mentre

$$\hat{\beta}_0 = 9.8 \text{ migliaia di sterline}$$

sono le vendite corrispondenti a un venditore che consegue punteggio nullo nel test. . .

. . . poiché i punteggi osservati vanno da un minimo di 45 a un massimo di 85, l'interpretazione di  $\hat{\beta}_0$  non è affidabile (posto che abbia senso considerare un venditore. . . assunto. . . con 0 punti al test attitudinale).

A questo punto siamo quasi pronti a dare, per il venditore neoassunto con punteggio  $x_{n+1} = 60$ , la previsione

$$Y_{n+1} = \hat{\beta}_0 + \hat{\beta}_1 x_{n+1} \pm \hat{\sigma}$$

dove  $\hat{\beta}_0 = 9.8$ ,  $\hat{\beta}_1 = 1.9$  e

$$\hat{\sigma} = \sqrt{SQM(\hat{\beta}_0, \hat{\beta}_1)} = \sqrt{\frac{e_1^2 + \dots + e_n^2}{n}}$$

dove il “quasi” è relativo al fatto che ci conviene prima introdurre una formula alternativa per la stima dell'errore standard di regressione. . .

... basata sulla seguente **decomposizione della varianza totale** (varianza marginale di  $Y$ ):

$$\begin{aligned} sd_y^2 &= \frac{1}{n} \sum_{i=1}^n (\hat{\beta}_0 + \hat{\beta}_1 x_i - \bar{y})^2 + \frac{1}{n} \sum_{i=1}^n (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i)^2 \\ &= R^2 \times sd_y^2 + \hat{\sigma}^2 \end{aligned}$$

dove  $R^2$  si dice **coefficiente di determinazione** della retta di regressione (è la proporzione di varianza totale spiegata da  $X$ ).

Si dimostra che  $R^2 = r_{xy}^2$  e se ne ricava la seguente formula alternativa per la stima dell'errore standard di regressione:

$$\hat{\sigma} = sd_y \times \sqrt{1 - r_{xy}^2}$$

di modo che  $\hat{\sigma} \leq sd_y$  (uguaglianza solo nel caso in cui  $r_{xy} = 0$ ).

Nell'esempio del venditore neoassunto si trova

$$R^2 = (0.77)^2 = 0.5929$$

di modo che la retta di regressione di  $Y$  (vendite) su  $X$  (punteggio al test attitudinale) spiega il 59% della varianza totale; ne segue

$$\hat{\sigma} = \sqrt{1 - 0.5929} \times 33.8 = 0.638 \times 33.8 = 21.6$$

migliaia di sterline e quindi (se  $x_{n+1} = 60$ ) prevederemo

$$Y_{n+1} = 9.8 + 1.9 \times 60 \pm 21.6 = 123.8 \pm 21.6.$$

laddove (ignorando  $x_{n+1}$ ) prevedevamo

$$Y_{n+1} = \bar{y} \pm sd_y = 134.4 \pm 33.8$$



L'informazione  $x_{n+1} = 60$  **corregge** e **precisa** la nostra previsione.

- ▶ una **previsione puntuale più bassa** delle vendite del neoassunto, da 134.8 a 123.8 migliaia di sterline, perché il neoassunto ha conseguito un punteggio al test attitudinale inferiore alla media;
- ▶ una **minore incertezza nella previsione** delle vendite del neoassunto, nella misura in cui l'errore standard di previsione passa da 33.8 a 21.6 migliaia di sterline (errore standard di regressione) in virtù della correlazione lineare tra vendite e punteggio.

La minore incertezza nella previsione si traduce, a parità di probabilità, in un intervallo di previsione più corto. . .

... se si può usare una distribuzione normale per  $Y_{n+1}$ , quando si sappia che  $X_{n+1} = 60$ , assegnando

$$\begin{aligned}\mathbb{E}[Y_{n+1} | X_{n+1} = 60] &= 123.8 \\ \text{sd}(Y_{n+1} | X_{n+1} = 60) &= 21.6\end{aligned}$$


troveremo la **previsione per intervallo**


$$80.6 = 123.8 - 2 \times 21.6 \leq Y_{n+1} \leq 123.8 + 2 \times 21.6 = 167.0$$


con probabilità 95%, da confrontare con la previsione incondizionata

$$66.8 = 134.4 - 2 \times 33.8 \leq Y_{n+1} \leq 134.4 + 2 \times 33.8 = 202.0$$

di modo che la lunghezza sarà scesa da 135 a 86 migliaia di sterline.







In realtà ponendo  $sd(Y_{n+1}|X_{n+1} = x_{n+1}) = \hat{\sigma}$  sottovalutiamo la nostra **incertezza** sul fenomeno oggetto di previsione:

- ▶ usando i dati non solo per stimare  $\sigma$ , ma anche per stimare  $\beta_0$  e  $\beta_1$ , converrà sostituire  $\hat{\sigma}$  con la sua versione “corretta”

$$\hat{\sigma}_+ = \hat{\sigma} \sqrt{\frac{n}{n-2}};$$

- ▶ inoltre i valori  $\hat{\beta}_0$  e  $\hat{\beta}_1$  sono affetti da incertezza e questa si rifletterà sull'assegnazione  $\mathbb{E}[Y_{n+1}|X_{n+1} = x_{n+1}] = \hat{\mu}_{x_{n+1}}$ , dove abbiamo introdotto la quantità  $\hat{\mu}_{x_{n+1}} = \hat{\beta}_0 + \hat{\beta}_1 x_{n+1} \dots$

... in effetti  $\hat{\beta}_0$  e  $\hat{\beta}_1$  sono stime (corrette) con **errori standard**

$$se(\hat{\beta}_0) = \frac{\sigma}{\sqrt{n}} \sqrt{1 + \left(\frac{\bar{x}}{sd_x}\right)^2}$$

$$se(\hat{\beta}_1) = \frac{\sigma}{sd_x \sqrt{n}}$$

provenienti da stimatori<sup>1</sup> con correlazione  $-\bar{x} \frac{se(\hat{\beta}_1)}{se(\hat{\beta}_0)}$  di modo che

$$se(\hat{\mu}_{x_{n+1}}) = \frac{\sigma}{\sqrt{n}} \sqrt{1 + \left(\frac{x_{n+1} - \bar{x}}{sd_x}\right)^2} \text{ e di conseguenza...}$$

<sup>1</sup>Gli stimatori ai minimi quadrati di  $\beta_0$  e  $\beta_1$  hanno varianza minima tra quelli corretti che sono funzioni lineari dei dati (Teorema di Gauss-Markov).



... l'**errore standard di previsione**, comprensivo di tutta la nostra incertezza, sarà

$$\begin{aligned}\hat{se}(Y_{n+1}|X_{n+1} = x_{n+1}) &= \sqrt{\hat{\sigma}_+^2 + \hat{se}(\hat{\mu}_{x_{n+1}})^2} \\ &= \hat{\sigma}_+ \sqrt{1 + \frac{1}{n} \left[ 1 + \left( \frac{x_{n+1} - \bar{x}}{sd_x} \right)^2 \right]}\end{aligned}$$

tanto maggiore quanto più  $x_{n+1}$  è lontano da  $\bar{x}$ ; si veda al riguardo la Figura 17.4.1 di Borra & Di Ciaccio (2008).

Al crescere di  $n$  l'incertezza sulla nostra previsione si riduce all'errore standard di regressione  $\sigma$ , ma resta il problema che la previsione non sarà affidabile se  $x_{n+1}$  non appartiene al campo di variazione dei dati: **estrapolare** è più azzardato che **interpolare**.



Nell'esempio di Rees la stima "corretta" dell'errore standard di regressione sarà

$$\hat{\sigma}_+ = 21.6 \times \sqrt{\frac{8}{6}} = 24.9$$

e quindi gli errori standard (stimati) di  $\beta_0$  e  $\beta_1$  saranno

$$\hat{s}e_0 = \frac{24.9}{\sqrt{8}} \times \sqrt{1 + \left(\frac{65.6}{13.6}\right)^2} = 43.4$$

$$\hat{s}e_1 = \frac{24.9}{13.6 \times \sqrt{8}} = 0.65$$

di modo che scriveremo (stime puntuali con errore standard)

$$\beta_0 = 9.8 \pm 43.4$$

$$\beta_1 = 1.9 \pm 0.65$$

per esprimere la nostra incertezza sui valori dell'intercetta e del coefficiente angolare.

In particolare, concentrandoci sul parametro che ci interessa di più, per la sua interpretazione, troveremo che l'**incremento nelle vendite corrispondente all'incremento di un punto nel test attitudinale** potrebbe tranquillamente essere di sole mille sterline (o di ben tremila sterline).

Un **intervallo di confidenza** per  $\beta_1$  può trovarsi mediante un opportuno coefficiente di confidenza basato sulla distribuzione t di Student con  $n - 2$  gradi di libertà:

$$\begin{aligned}\hat{\beta}_1 - t_\alpha \hat{s}e_1 &\leq \beta_1 \leq \hat{\beta}_1 + t_\alpha \hat{s}e_1 \\ 1.9 - 2.45 \times 0.65 &\leq \beta_1 \leq 1.9 + 2.45 \times 0.65 \\ 1.9 - 1.6 &\leq \beta_1 \leq 1.9 + 1.6\end{aligned}$$

se prendiamo  $\alpha = 0.025$  (con  $n - 2 = 6$ ); concluderemo

$$0.3 \leq \beta_1 \leq 3.5$$

al livello di confidenza 95%.

La **verifica dell'ipotesi** di irrilevanza del test attitudinale

$$H_0 : \beta_1 = 0$$

può effettuarsi mediante la statistica test (osservata)

$$t = \frac{\hat{\beta}_1}{\hat{se}_1} = \frac{1.9}{0.65} = 2.92$$

da confrontarsi con un opportuno valore critico della distribuzione t di Student con  $n - 2$  gradi di libertà: se prendiamo  $\alpha = 0.025$  (con  $n - 2 = 6$ ) questo sarà  $t_\alpha = 2.45$  e concluderemo che il test attitudinale contribuisce significativamente a spiegare le vendite; la stessa conclusione si ottiene osservando che il valore zero non appartiene all'intervallo di confidenza.



L'errore standard di  $\hat{\mu}_{x_{n+1}} = \hat{\beta}_0 + \hat{\beta}_1 x_{n+1} = 9.8 + 1.9 \times 60 = 123.8$  può stimarsi come

$$\hat{se}(\hat{\mu}_{x_{n+1}}) = \frac{24.9}{\sqrt{8}} \sqrt{1 + \left(\frac{60 - 65.6}{13.6}\right)^2} = 9.5$$

e quindi per il parametro  $\mu_{x_{n+1}} = \beta_0 + \beta_1 x_{n+1}$  (per le **vendite medie dei venditori con punteggio  $x_{n+1}$** ) avremo la stima con errore standard

$$\mu_{x_{n+1}} = 123.8 \pm 9.5$$

da cui eventualmente ricaveremo un intervallo di confidenza usando la distribuzione t di Student con  $n - 2 = 6$  gradi di libertà.

Infine, per quanto riguarda la **previsione delle vendite** di un venditore neoassunto con punteggio  $x_{n+1} = 60$ , troveremo

$$\hat{se}(Y_{n+1}|X_{n+1} = 60) = \sqrt{(24.9)^2 + (9.5)^2} = 26.7$$

da confrontare con  $\hat{se}(Y_{n+1}) = 38.3$  (se non conosciamo  $x_{n+1}$ );  
usando la distribuzione t di Student con  $n - 2 = 6$  gradi di libertà  
per  $\frac{Y_{n+1} - \mathbb{E}[Y_{n+1}|X_{n+1}=x_{n+1}]}{\hat{se}(Y_{n+1}|X_{n+1}=x_{n+1})}$ , prevederemo quindi

$$58.4 = 123.8 - 2.45 \times 26.7 \leq Y_{n+1} \leq 123.8 + 2.45 \times 26.7 = 189.2$$

con probabilità 95% (lunghezza 131 da confrontare con 181).

Abbiamo visto che il coefficiente di determinazione  $R^2 = r_{xy}^2$  è la proporzione di varianza totale spiegata dalla retta di regressione. . .

. . . in quanto tale è una misura della **bontà di adattamento**<sup>2</sup> della retta di regressione ai dati (quindi della sua utilità) se sussistono le condizioni per stimarla (ai minimi quadrati):

- ▶ linearità della relazione statistica

$$Y_i = \beta_0 + \beta_1 X_i + \epsilon_i$$

ovvero correlazione lineare tra  $Y$  e  $X$ ;

---

<sup>2</sup>Al riguardo si veda anche la Sezione 17.3 di Borra & Di Ciaccio (2008) sulla tavola ANOVA e sul test F.

- ▶ omoschedasticità

$$sd(\epsilon_i) = \sigma$$

ovvero stessa deviazione standard per tutti i termini di errore;

- ▶ indipendenza stocastica dei termini d'errore  $\epsilon_1, \dots, \epsilon_n$  (in caso contrario SQM non è la funzione di perdita più adatta);
- ▶ normalità dei termini di errore

$$\epsilon_i \sim \mathcal{N}(0, \sigma)$$

che permette di interpretare i minimi quadrati in termini di “massima verosimiglianza” (in caso contrario non è detto che i minimi quadrati siano l'approccio migliore) e di usare una distribuzione t di Student a fini inferenziali (stima e previsione).



L'**analisi dei residui** permette di controllare se sussistono o meno le condizioni per stimare la retta di regressione (ai minimi quadrati).


Borra e Di Ciaccio (2008, Sezione 17.5) discutono questo argomento, mostrando fra l'altro grafici dei residui che segnalano:

- ▶ relazioni statistiche non lineari;
- ▶ eteroschedasticità (termini di errore con deviazioni standard diverse fra loro);
- ▶ termini di errore fra loro dipendenti (correlati);
- ▶ termini di errore non normali.


I due grafici seguenti, relativi all'esempio dei venditori, non mostrano evidenza contro linearità, omoschedasticità e indipendenza (si suppongano i venditori in ordine di assunzione). . .



### Grafico dei Residui (1)



### Grafico dei Residui (2)



Un paio di avvertenze finali (prima di passare a un'applicazione):

- ▶ La stima ai minimi quadrati della retta di regressione è piuttosto sensibile alla presenza di **valori anomali**; questi possono essere individuati ispezionando visivamente il diagramma di dispersione (Borra & Di Ciaccio, 2008, Sezione 17.6).
- ▶ L'evidenza di un'associazione (lineare) tra due caratteri statistici non implica l'esistenza di una relazione causale tra gli stessi; si veda al riguardo la Sezione 17.7 di Borra & Di Ciaccio (2008).

Previsione di un carattere quantitativo

Correlazione lineare

Retta di regressione

**Propensione marginale all'importazione**

Vediamo ora un'applicazione in **ambito macroeconomico**, su dati relativi agli Stati Uniti d'America (cortesia del prof. G. Bonifati).

Le variabili di interesse sono



$M$  = "importazioni"

$Z$  = "spesa complessiva"

dove la spesa complessiva (PIL) è il totale di "consumi", "investimenti", "spesa pubblica" ed "esportazioni nette":  $Z = C + I + G + (X - M)$ ; si noti che  $M$  è parte di  $C + I + G$  e dunque, nel calcolo di  $Z$ , si elide.

È disponibile la **serie storica** di  $M$  e  $Z$  (cadenza quadrimestrale) dal primo quadrimestre del 1970 al primo quadrimestre del 2006;  $M$  e  $Z$  sono misurate in "miliardi di dollari attualizzati al 2000"...





Restringendo l'attenzione a un'opportuna **finestra temporale**, si può ipotizzare una relazione statistica lineare tra le importazioni  $M$  e la spesa complessiva  $Z$ :

$$M = \beta_0 + \beta_1 Z + \epsilon.$$

Il coefficiente  $\beta_1$  è detto **propensione marginale all'importazione** (di un dato paese, qui gli USA, in un dato momento storico, qui ancora da determinare); essa indica

*l'aumento delle importazioni corrispondente a un aumento unitario (1 miliardo di dollari) nella spesa complessiva (PIL)*

ed è l'oggetto di interesse nell'analisi che segue.

```
> load("datiUSAbonifati.rda")
> datiUSAantichi <- as.data.frame(datiUSA)[time(datiUSA) < 1990,]
> regLin1 <- lm(M~Z, data = datiUSAantichi)
> summary(regLin1)
```

```
Call:
lm(formula = M ~ Z, data = datiUSAantichi)
```

```
Residuals:
    Min       1Q   Median       3Q      Max
-45.039 -14.161   5.066  16.517  37.535
```

```
Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept) -2.604e+02  1.289e+01  -20.20  <2e-16 ***
Z            1.105e-01  2.279e-03   48.47  <2e-16 ***
---
```

```
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```
Residual standard error: 21.33 on 78 degrees of freedom
Multiple R-squared:  0.9679, Adjusted R-squared:  0.9675
F-statistic:  2349 on 1 and 78 DF,  p-value: < 2.2e-16
```

```
> load("datiUSAbbyBonifati.rda")
> datiUSArecenti<-as.data.frame(datiUSA)[time(datiUSA) >= 1990,]
> regLin2 <- lm(M~Z, data = datiUSArecenti)
> summary(regLin2)
```

```
Call:
lm(formula = M ~ Z, data = datiUSArecenti)
```

Residuals:

Min	1Q	Median	3Q	Max
-40.051	-13.701	-4.225	14.691	70.703

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	-1.264e+03	1.549e+01	-81.65	<2e-16 ***
Z	2.387e-01	1.512e-03	157.89	<2e-16 ***

---  
Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 21.04 on 63 degrees of freedom  
Multiple R-squared: 0.9975, Adjusted R-squared: 0.9974  
F-statistic: 2.493e+04 on 1 and 63 DF, p-value: < 2.2e-16

Pertanto, se nel ventennio 1970-1990 la propensione marginale all'importazione degli USA era pari a



$$11.05 \pm 0.23$$



**punti percentuali**, nel periodo dal 1990 al 2005 essa si attesta al livello di

$$23.87 \pm 0.15$$

**punti percentuali** (circa il doppio del livello precedente).

I valori di  $R^2$  (96.79% nel primo caso, 99.75% nel secondo) indicano un ottimo adattamento locale della retta di regressione (modello lineare).





-  **BORRA, S. & DI CIACCIO, A. (2008).**  
*Statistica: Metodologie per le Scienze Economiche e Sociali*  
(Seconda Edizione).  
McGraw-Hill, Milano.
-  **REES, D. G. (2001).**  
*Essential Statistics.*  
CRC Press, Boca Raton.