

La predizione o regressione


Lezioni di Psicometria
Giovanni Battista Flebus

Definizione di Predizione (1)

- Il termine di predizione in statistica e psicometria ha un significato molto limitato: si usa per indicare che una misurazione di un comportamento è usata per predire la misurazione di un altro comportamento.
- Le misurazioni sono generalmente dei test mentali (abilità, profitto, personalità, atteggiamenti, temperamenti) o dati fisici o altre rilevazioni comportamentali.

Concetto della predizione statistica

A punteggi **alti** di un test (**predittore**) corrispondono punteggi **alti** di un altro test (comportamento da predire o **stimare**)



si può usare
la prima
misurazione
per predire la
seconda

a punteggi **bassi** del predittore corrispondono punteggi **bassi** del predetto,

La predizione fa ricorso al concetto matematico di **funzione**

- Una funzione matematica è una regola che lega un insieme di numeri, usando costanti e variabili (e anche altre funzioni matematiche).

Esempi di funzione:

- $y = k+x$
- $y = \log_{10}(x)$
- $y = 3x^3 + 4x^2 + 11x + k$

Una funzione molto utile è quella che descrive la retta

$$y = x m + a$$

Definizione di predizione (2)

- Dovremo trasformare il punteggio del test predittore con una **equazione di una retta**, che predica al meglio (ovvero commettendo meno errori possibili) il punteggio ottenuto dal soggetto nel test predetto.
- L'equazione per trasformare il punteggio è la seguente:

$$\hat{y}_i = x_i \cdot m + a$$

Definizione di predizione (3)

Si deve tenere conto che le predizioni non sono precise, e quindi la funzione dovrebbe essere scritta sempre così

$$y = mx + a + e$$


dove **e** indica la parte di errore della predizione.

Studieremo solo la relazione **lineare**

Equazione di regressione

$$\hat{y}_i = x_i \cdot m + a$$

- La **costante additiva** a è chiamata **intercetta**. Rappresenta il punto in cui la retta incontra l'asse delle ordinate, ossia il valore che la predizione assume quando il predittore è uguale a zero




Equazione di regressione

$$\hat{y}_i = x_i \cdot m + a$$

- La **costante moltiplicativa** m è chiamata **pendenza** o **coefficiente angolare**.

Rappresenta il cambiamento in y all'aumentare di **una unità** in x .



Esempi di predizione

- Un test di abilità verbale predice il profitto a scuola
- Una scala di Stima di sé è usata per predire il Senso di benessere e di salute psicofisica
- Il punteggio di Coscienziosità predice il livello di efficienza nel lavoro di gruppo.

Piccolo esempio numerico

- Raccogliamo un piccolo numero di osservazioni:
 - Abilità verbale (un test psicometrico)
 - Profitto scolastico (voto scolastico dato da insegnanti)
- Supponiamo che entrambe le misurazioni siano delle scale a intervalli

Osservazioni per otto studenti

Studente	Test abilità verbale	Voto scolastico
A	12	8
B	10	7
C	14	8
D	9	5
E	9	6
F	13	9
G	11	7
H	8	5

Riportiamo in un grafico cartesiano le otto coppie di osservazioni

- In ascissa indichiamo la variabile indipendente (Abilità verbale)
- In ordinata riportiamo il valore della variabile dipendente (Voto scolastico)
- Osserviamo la distribuzione dei punteggi

voto

9
8
7
6
5

Stud	Test abilità verbale	Voto scolastico
A	12	8
B	10	7
C	14	8
D	9	5
E	9	6
F	13	9
G	11	7
H	8	5

ab_verbale

8

9

10

11

12

13

14

H

D

E


B


G


A

F

C










Come stabilire i parametri della retta di predizione?

Che criterio si può seguire?


- Si stabilisce che il criterio fondamentale è quello di cercare la retta che rende minimi gli errori.
- Tuttavia i metodi derivanti dall'analisi matematica risultano più efficace se si considerano non gli errori ma i loro quadrati.
- Quindi saranno gli errori elevati al quadrato il criterio da minimizzare e l'equazione che si otterrà si chiama appunto **equazione dei minimi quadrati.**



Errore di previsione negativo per lo studente F

Errore di previsione positivo per lo studente D

Stud	Test abilità verbale	Voto scolastico
A	12	8
B	10	7
C	14	8
D	9	5
E	9	6
F	13	9
G	11	7
H	8	5



Il criterio può essere espresso
con la formula

$$\sum_{i=1}^N \varepsilon_i^2 = \sum_{i=1}^N (Y_i - \hat{Y}_i)^2 = \min$$

La formula completa

$$Y = m X + a + \varepsilon$$

Variabile dipendente, spiegata, **valore osservato**

Pendenza

Intercetta

Variabile indipendente o predittore

errore

Stima di y , **valore predetto**

$$Y = m X + a$$

La formula più precisa

$$Y = mX + a$$

Segno della stima

$$\hat{Y}_i = mX_i + a$$

Pedice che indica **per un valore i fra quelli osservati**

Formula di calcolo

$$m = r \frac{S_y}{S_x} =$$

$$\frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sum (X_i - \bar{X})^2} = \frac{N \sum XY - \sum X \sum Y}{N \sum X^2 - (\sum X)^2}$$

$$a = \bar{Y} - m\bar{X}$$

Applicazione della formule

$$m = \frac{N \sum XY - \sum X \sum Y}{N \sum X^2 - (\sum X)^2}$$

somma X	somma Y	quad X	quad Y	prod XY
150	95	1668	673	1056

$$m = \frac{8 * 611 - 86 * 55}{8 * 956 - (86)^2} =$$

Coefficiente
angolare o
moltiplicativo

$$\frac{4888 - 4730}{7648 - 7396} = \frac{158}{252} = 0,626$$

Applicazione della formule

somma X	somma Y	quad X	quad Y	prod XY
150	95	1668	673	1056

$$a = \bar{Y} - m\bar{X}$$

Coefficiente
additivo o
intercetta

$$a = 6,875 - 0,626 * 10,75 = 0,135$$

$$\hat{Y} = 0,135 + 0,626 * X$$

Equazione di
regressione

$$\hat{Y} = 0,135 + 0,626 * X$$

Equazione di regressione

	abilità	voto	Voto predetto
	8	5	5,15
	9	5	5,78
	9	6	5,78
	10	7	6,4
	11	7	7,03
	12	8	7,66
	13	9	8,29
	14	8	8,91
somma	86	55	55
media	10,75	6,875	6,875

Regressione con SPSS...

- Menu Analizza
- Poi Regressione
- Poi Lineare
- Compare la finestra di scelta
- Per il momento non facciamo niente altro e diamo l'OK
- Fra i risultati, solo alcuni sono immediatamente comprensibili

Qui la variabile
dipendente (una sola)

Qui le variabili
indipendenti o predittori
(una o più)

Dipendente: voto

Blocco 1 di 1

Indietro Avanti

Indipendenti: ab_verbale

Metodo: Immetti

Variabile di selezione: Regola...

Etichette casi:

Peso Minimi quadrati pesati:

OK Incolla Reimposta Annulla Guida

Statistiche...
Grafici...
Salva...
Opzioni...
Stile...

Coefficienti^a

Modello		Coefficienti non standardizzati		Coefficienti standardizzati	t	Sig.
		B	Errore std.	Beta		
1	(Costante)	,135	1,255		,107	,918
	ab_verbale	,627	,115	,912	5,460	,002

a. Variabile dipendente: Voto_scolastico

Ecco la costante moltiplicativa: è il valore che moltiplica il punteggio dell'abilità verbale

$$\hat{Y} = 0,135 + 0,626 * X$$

Coefficienti^a

Modello	Coefficienti non standardizzati		Coefficienti standardizzati	t	Sig.
	B	Errore std.	Beta		
1	(Costante)	,135		,107	,918
	ab_verbale	,627	,912	5,460	,002

a. Variabile dipendente: voto_scolastico

Costante additiva. E' il valore della VD quando la VI è uguale a zero. In psicologia ha un senso relativo, dovuto all'arbitrarietà delle unità di misura (per i test mentali)

$$\hat{Y} = 0,135 + 0,626 * X$$

Ricordiamo la correlazione fra le due misurazioni

Correlazioni

		ab_verbale	Voto_scolastico
ab_verbale	Correlazione di Pearson	1	,912**
	Sig. (2-code)		,002
	N	8	8
Voto_scolastico	Correlazione di Pearson	,912**	1
	Sig. (2-code)	,002	
	N	8	8

** . La correlazione è significativa al livello 0,01 (2-code).

Coefficienti^a

Modello		Coefficienti non standardizzati		Coefficienti standardizzati	t	Sig.
		B	Errore std.	Beta		
1	(Costante)	,135	1,255		,107	,918
	ab_verbale	,627	,115	,912	5,460	,002

a. Variabile dipendente: Voto_scolastico

Coefficiente beta standardizzato: con una sola VI, è uguale a r.

Indica l'ammontare di cambiamento della VD per ogni unità della VI, se entrambe le variabili sono standardizzate.

Riepilogo del modello

Modello	R	R-quadrato	R-quadrato corretto	Errore std. della stima
1	,912 ^a	,832	,805	,644

a. Stimatori: (Costante), ab_verbale

R multiplo: indica la precisione della predizione.
Importante nella regressione multipla.

In quella semplice, $R = r$.

È un valore sempre positivo, anche quando r è negativo.

Riepilogo del modello

Modello	R	R-quadrato	R-quadrato corretto	Errore std. della stima
1	,912 ^a	,832	,805	,644

a. Stimatori: (Costante), ab_verbale

Quadrato di R multiplo. Se moltiplicato per 100, dà la percentuale di varianza spiegata dalla VI

Riepilogo del modello


Modello	R	R-quadrato	R-quadrato corretto	Errore std. della stima
1	,912 ^a	,832	,805	,644

a. Stimatori: (Costante), ab_verbale

R quadrato corretto: dà una stima del possibile coefficiente ripetuto su un nuovo campione. Si abbassa molto se è calcolato su pochi casi e su molte variabili.

Predizione usando i punti standardizzati

Trasformiamo le due serie di dati in valori standardizzati



Opzione Descrittive
per avere i valori
standardizzati

- Poi applichiamo la regressione e guardiamo i risultati

Regressione con i valori standardizzati

Coefficienti^a

Modello	Coefficienti non standardizzati		Coefficienti standardizzati	t	Sign.
	T	Errore std	Beta		
1 (Costante)	,000	,156		,000	1,000
Z_ab_verbale	,912	,167	,912	5,460	,002

a. Variabile dipendente: Z_voto

La costante moltiplicativa è uguale a r_{xy}

La costante additiva è uguale a zero

Coefficienti standardizzati	t	Sig.
Beta		
,912	,107	,918
,912	5,460	,002

L'equazione si semplifica...

$$\hat{z}_{yi} = z_{xi} \cdot r_{xy}$$

\hat{z}_{yi} = zeta predetto

z_{xi} = zeta predittore

r_{xy} = coefficiente di correlazione

Notiamo alcuni elementi...

Statistiche descrittive

	Media	Deviazione std.	Varianza
ab_verbale	10,7500	2,1213	4,5000
voto	6,8750	1,4577	2,1250
Predetti Grezzi	6,8750	1,3300	1,7690
Predetti standardizzati	,0000	,9124	,8325

Le medie dei valori predetti e dei valori osservati sono uguali

Notiamo alcuni elementi...

Statistiche descrittive

	Media	Deviazione std.	Varianza
ab_verbale	10,7500	2,1213	4,5000
voto	6,8750	1,4577	2,1250
Predetti Grezzi	6,8750	1,3300	1,7690
Predetti standardizzati	,0000	,9124	,8325

Le medie dei predetti standardizzati è uguale a zero

Notiamo alcuni elementi...

Statistiche descrittive

	Media	Deviazione std.	Varianza
ab_verbale	10,7500	2,1213	4,5000
voto	6,8750	1,4577	2,1250
Predetti Grezzi	6,8750	1,3300	1,7690
Predetti standardizzati	,0000	,9124	,8325

La deviazione standard dei valori predetti è uguale al coefficiente di correlazione

Notiamo alcuni elementi...

Statistiche descrittive

	Media	Deviazione std.	Varianza
ab_verbale	10,7500	2,1213	4,5000
voto	6,8750	1,4577	2,1250
Predetti Grezzi	6,8750	1,3300	1,7690
Predetti standardizzati	,0000	,9124	,8325

La varianza dei valori predetti prende il nome di varianza spiegata dalla regressione

Notiamo alcuni elementi...

Statistiche descrittive

	Media	Deviazione std.	Varianza
ab_verbale	10,7500	2,1213	4,5000
voto	6,8750	1,4577	2,1250
Predetti Grezzi	6,8750	1,3300	1,7690
Predetti standardizzati	,0000	,9124	,8325

Il rapporto fra varianza spiegata e varianza totale è pari a $\frac{1,7690}{2,1250} = 0,8325$, ossia varianza dei predetti standardizzati, uguale al coefficiente di determinazione

La varianza dei punteggi predetti dipende dal coefficiente di correlazione

Correlazione elevata

- Buona predizione
- Stime vicine ai valori osservati

Correlazione bassa

- Cattiva predizione
- Stime dei valori osservati attorno alla **media della variabile dipendente**

Casi estremi: $r = 1$

$$Y = mX + a$$

Correlazione perfetta

- Nessun errore

$$Y = mX + a + 0err \Rightarrow Y = mX + a$$

Casi estremi: $r=0$

Correlazione nulla

- Predizione assente
- Stime dei valori osservati **sempre** uguali alla **media**

$$Y = mX + a$$



$$Y = 0 + a$$

Statistiche descrittive

	Media	Deviazione std.	Varianza
ab_verbale	10,7500	2,1213	4,5000
voto	6,8750	1,4577	2,1250
Predetti Grezzi	6,8750	1,3300	1,7690

Perché stimare dei valori che abbiamo già in realtà?

- Per testare le capacità del test di predizione, per poterlo poi usare in situazioni reali, dove non si conosce il punteggio da predire.

Parametri

- Le rilevazioni eseguite su un campione forniscono dei riassunti (variabili casuali) che stimano i **parametri** della popolazione.
- I parametri della popolazione possono essere uguali a zero (e non influenzano la regressione) o diversi da zero (e allora la influenzano).
- La distribuzione campionaria dei due coefficienti (angolare e additivo) seguono la curva normale in caso di ipotesi nulla e quindi si possono applicare le procedure che abbiamo già conosciuto per il coefficiente di correlazione
- La **significatività** è il valore di probabilità di trovare un coefficiente nullo, sotto l'ipotesi nulla.

Riassumendo

- La regressione statistica permette di **stimare** (o **predire**) il punteggio di un test (o di un'altra misurazione).
- Nella predizione del **singolo caso** non è mai possibile sapere se la predizione è esatta o molto sballata.
- Si può quantificare la predizione **totale**, fatta su tutti i casi (presenti e futuri): la quota di varianza spiegata (r^2) è un utile indice per definire la precisione della predizione.

Coefficienti^a

Modello		Coefficienti non standardizzati		Coefficienti standardizzati	t	Sig.
		B	Errore std.	Beta		
1	(Costante)	,135	1,255		,107	,918
	ab_verbale	,627	,115	,912	5,460	,002

a. Variabile dipendente: Voto_scolastico

I due parametri della regressione, come li abbiamo conosciuti

Coefficienti^a

Modello		Coefficienti non standardizzati		Coefficienti standardizzati	t	Sig.
		B	Errore std.	Beta		
1	(Costante)	,135	1,255		,107	,918
	ab_verbale	,627	,115	,912	5,460	,002

a. Variabile dipendente: Voto_scolastico

Due parametri richiedono una
doppia ipotesi nulla:

H0: il parametro additivo è uguale a zero e non
aiuta a migliorare la predizione

H1: il parametro è diverso da zero e serve a
migliorare la predizione

Coefficienti^a

Modello		Coefficienti non standardizzati		Coefficienti standardizzati	t	Sig.
		B	Errore std.	Beta		
1	(Costante)	,135	1,255		,107	,918
	ab_verbale	,627	,115	,912	5,460	,002

a. Variabile dipendente: Voto_scolastico

Errore standard della
 distribuzione campionaria dei
 due coefficienti, servono a
 calcolare il t di Student

Coefficienti^a

Modello		Coefficienti non standardizzati		Coefficienti standardizzati	t	Sig.
		B	Errore std.	Beta		
1	(Costante)	,135	1,255		,107	,918
	ab_verbale	,627	,115	,912	5,460	,002

a. Variabile dipendente: Voto_scolastico

il t di Student ci informa sulla rarità di un tale parametro sotto l'ipotesi nulla di mancanza di effetto nell'equazione di regressione

Coefficienti^a

Modello		Coefficienti non standardizzati		Coefficienti standardizzati	t	Sig.
		B	Errore std.	Beta		
1	(Costante)	,135	1,255		,107	,918
	ab_verbale	,627	,115	,912	5,460	,002

a. Variabile dipendente: Voto_scolastico

Significatività del t di Student dei due parametri: se la probabilità di ottenere quel valore è molto bassa, si rifiuta l'ipotesi nulla di assenza di effetto e si accetta l'ipotesi che il parametro è diverso da zero e serve nella predizione

Riepilogo del modello

Riepilogo del modello^b

Modello	R	R-quadrato	R-quadrato adattato	Errore standard della stima
1	,912 ^a	,832	,805	,644

a. Predittori: (costante), ab_verbale

b. Variabile dipendente: voto

Il coefficiente di correlazione multiplo (R maiuscolo) è la correlazione fra il predittore e il predetto. E' sempre positivo

Riepilogo del modello

Riepilogo del modello^b

Modello	R	R-quadrato	R-quadrato adattato	Errore standard della stima
1	,912 ^a	,832	,805	,644

a. Predittori: (costante), ab_variable

b. Variabile dipendente: vol

Il coefficiente quadrato di R è la quota di varianza predetta

Riepilogo del modello

Riepilogo del modello^b

Modello	R	R-quadrato	R-quadrato adattato	Errore standard della stima
1	,912 ^a	,832	,805	,644

a. Predittori: (costante), ab_verbale

b. Variabile dipendente: voto

Il coefficiente quadrato di R adattato è una stima di quanto si ridurrebbe il coefficiente di correlazione multiplo su un nuovo campione

Riepilogo del modello

Riepilogo del modello^b

Modello	R	R-quadrato	R-quadrato adattato	Errore standard della stima
1	,912 ^a	,832	,805	,644

a. Predittori: (costante), ab_verbale

b. Variabile dipendente: voto

L'errore standard della stima di R serve a stimare l'intervallo di fiducia entro cui ricade R nella popolazione