

Analisi Multivariata dei Dati

Introduzione al corso e al modello statistico

Marcello Gallucci

Milano-Bicocca

Programma Odierno

- I numeri del corso
- Programma del corso
- Concetti Statistici Introduttivi



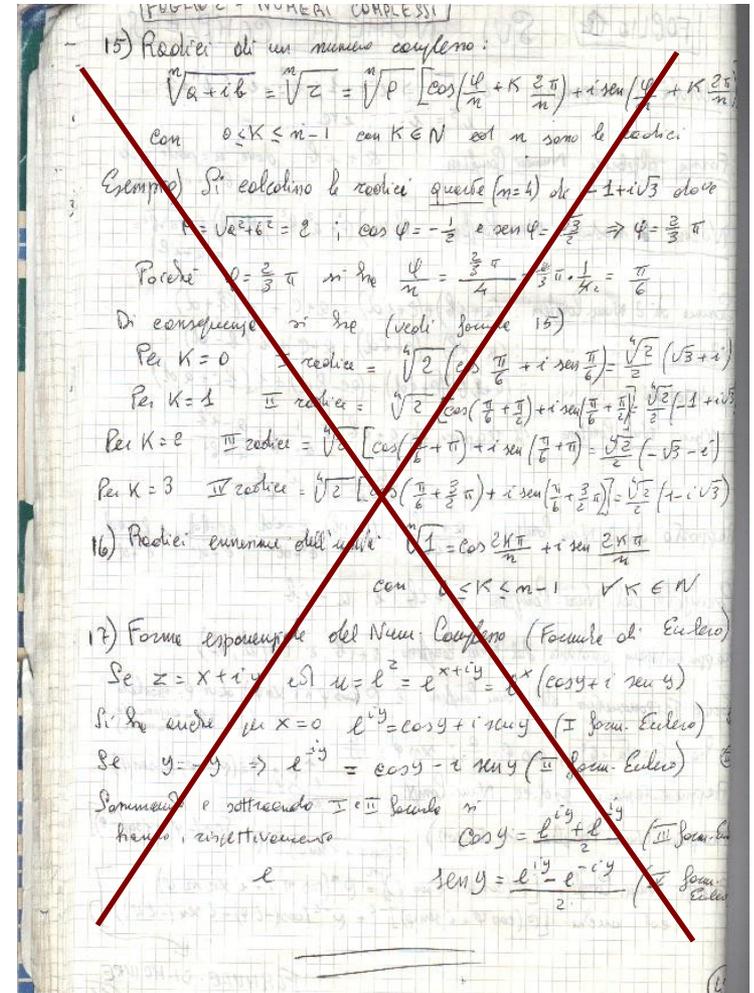
Numeri del Corso

- 21 lezioni, 2 ore l'una (a parte le pause)
- 18 ore di esercitazioni
- 2 appelli a sessione + recuperi
- 8 CFU



Stile del Corso

- Enfasi sui concetti
- Enfasi sul ragionamento statistico
- Minimo utilizzo di formule
- Utilizzo di software per i calcoli
- Enfasi sulla interpretazione dei risultati





- Il programma SPSS verra' usato per condurre i calcoli necessari alle analisi
- L'utilizzo di SPSS verra' insegnato nelle esercitazioni
- **Varie fonti offrono guide pratiche a SPSS**
- **Materiale online del libro di testo**

Esercitazioni

- Il corso si completa di 16 ore di esercitazione da tenersi nelle aule informatiche
- Lo scopo delle esercitazioni e' di imparare ad eseguire ed interpretare praticamente le analisi statistiche studiate a lezione



- Le esercitazione inizieranno tra due settimane. I gruppi verranno fatti dopo l'iscrizione al gruppo via pagina web del corso



Modelli statistici per le scienze sociali

Seconda edizione

Marcello Gallucci
Luigi Leone
Manuela Berlingeri

Modelli statistici
per le scienze sociali

070001000014



Libri di Testo

Il libro di testo è *Gallucci, Leone, Berlingeri (2011). Modelli statistici nelle scienze sociali, seconda edizione*

Le “lezioni” possono essere scaricate dalla pagina del corso

I capitoli da studiare sono elencati nel materiale del corso

<http://elearning.unimib.it/course/view.php?id=5601>

Esami

- L'esame è scritto e si svolge nei laboratori informatici dove lo studente potrà utilizzare il software statistico per rispondere alle domande

1) Domande a scelta multipla

2) Domande aperte riguardanti una ricerca empirica su cui lo studente condurrà le analisi usando SPSS.



- Tutti possono integrare il voto con l'esame orale
- L'esame orale potrebbe abbassare il voto!!

Scopi del Corso

- Lo studio **approfondito** di alcune importanti Tecniche Statistiche Univariate

- Analisi della varianza

- Regressione lineare e logistica

- Modelli lineari generalizzati

Inteso come ripasso
di corsi precedenti

- Studio di tecniche **multivariate** per l'analisi di grandezze psicologiche osservate ripetutamente nel tempo o in modalità ripetute

- Analisi della Varianza a misure ripetute

- Modelli misti

- Analisi fattoriale

Focus centrale del corso

- Cosa sono ?
 - Per capire le tecniche multivariate dobbiamo ricordare cosa sono le tecniche univariate
 - Per ricordare le tecniche univariate dobbiamo ricordare la logica delle tipo tecniche statistiche che andremo a studiare
 - Tecniche volte allo studio delle relazioni tra variabili

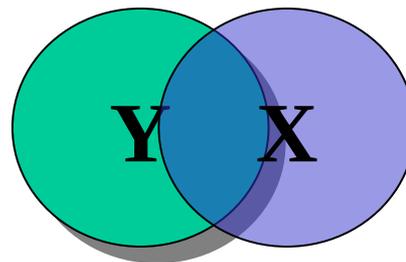
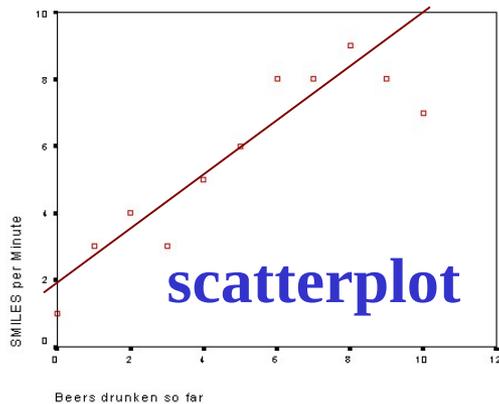
Tecniche Univariate

Tecniche volte a studiare e quantificare gli **effetti di una o più variabili **indipendenti** (variabili esplicative o predittori) su una variabile **dipendente** (variabile di interesse)**

- Cosa intendiamo per “effetti”
- Cosa intendiamo per “variabile dipendente”
- Cosa intendiamo per “variabili indipendenti”

Relazioni statistiche

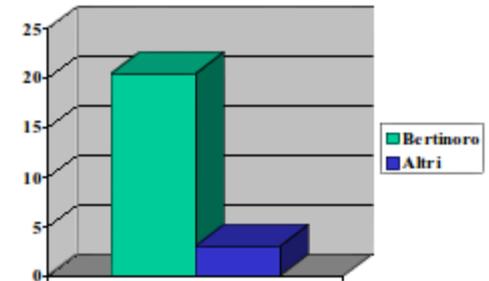
La maggior parte delle tecniche statistiche che conosciamo (e incontreremo) definiscono un **modello statistico** delle **relazioni** fra variabili di interesse



Path Diagram

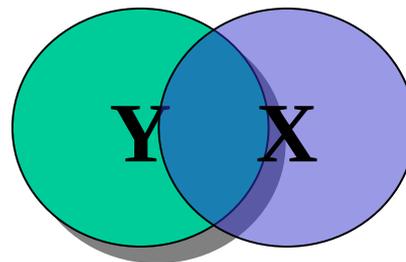
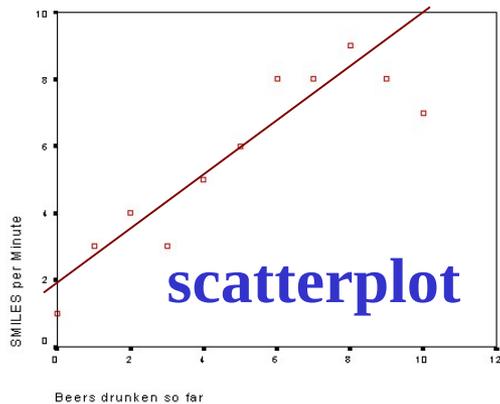


Differenze medie



Modello Statistico

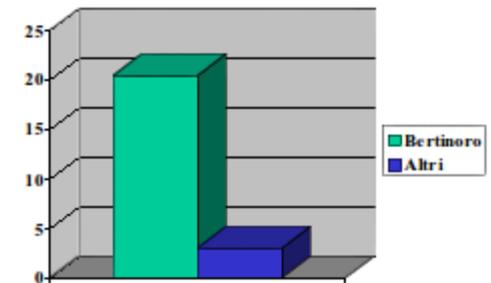
Un semplice **modello statistico** è una rappresentazione efficiente e compatta dei dati raccolti per descrivere un fenomeno empirico



Path Diagram



Differenze medie

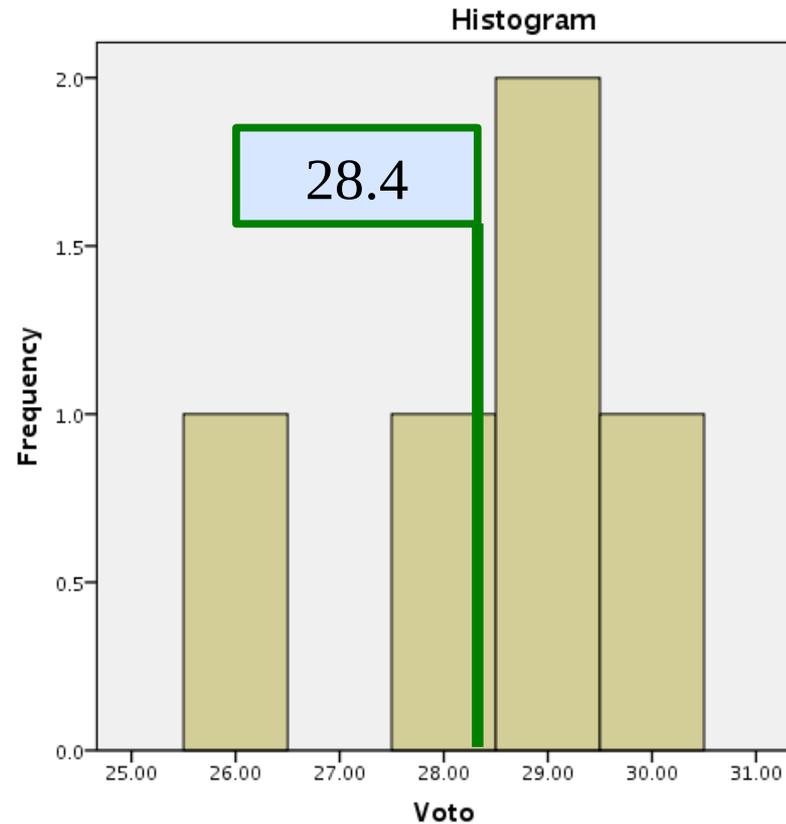


Esempio: la media

Q: “Come vanno gli studenti al mio corso?”

R: “Hanno una media del 28.4”

$$\frac{\sum_i X_i}{N} = \bar{X}$$

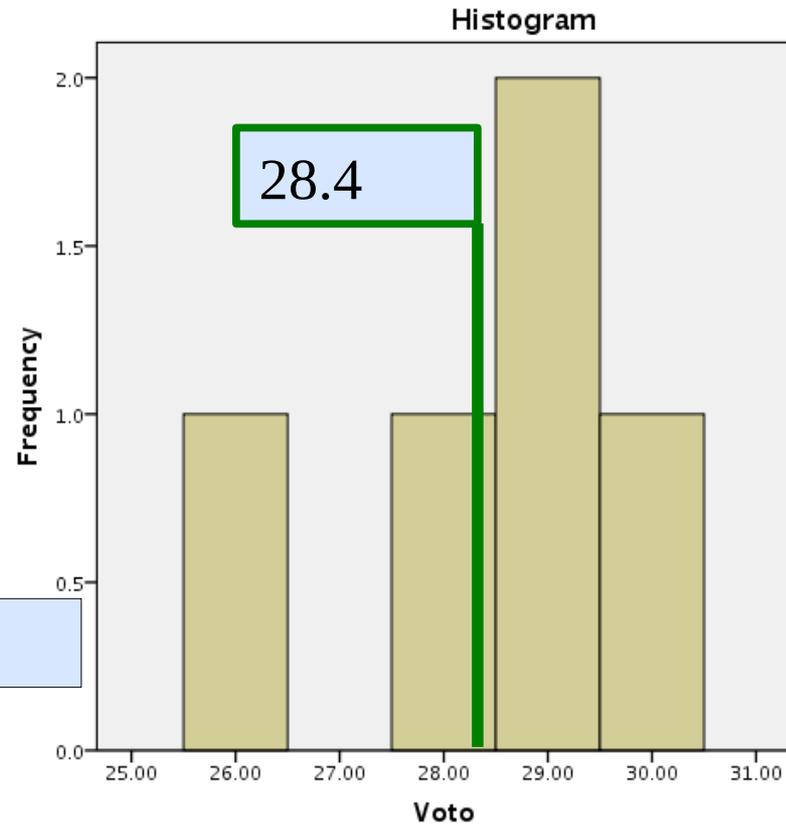


Introduzione

Il modello statistico e la rappresentazione che ne facciamo serve (tra l'altro) a tre scopi:

- Descrizione efficiente e compatta
- Predizione del futuro
- Inferenza sulla popolazione

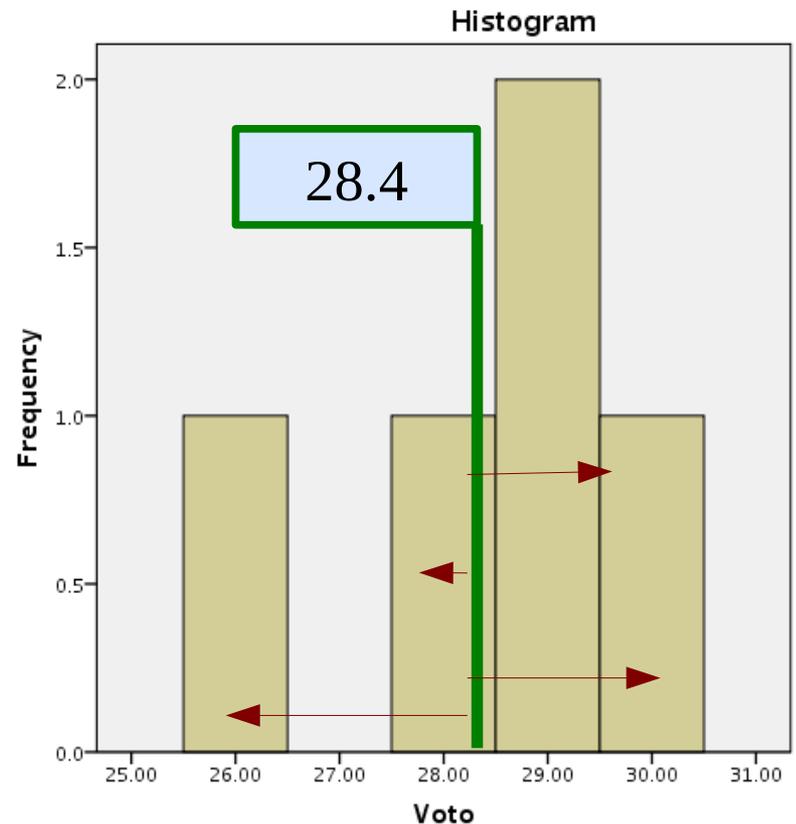
Cioè: comprensione del fenomeno



Errore di approssimazione

Come tutte le rappresentazioni compatte ed efficienti, anche quella statistica è una approssimazione dei dati rappresentati

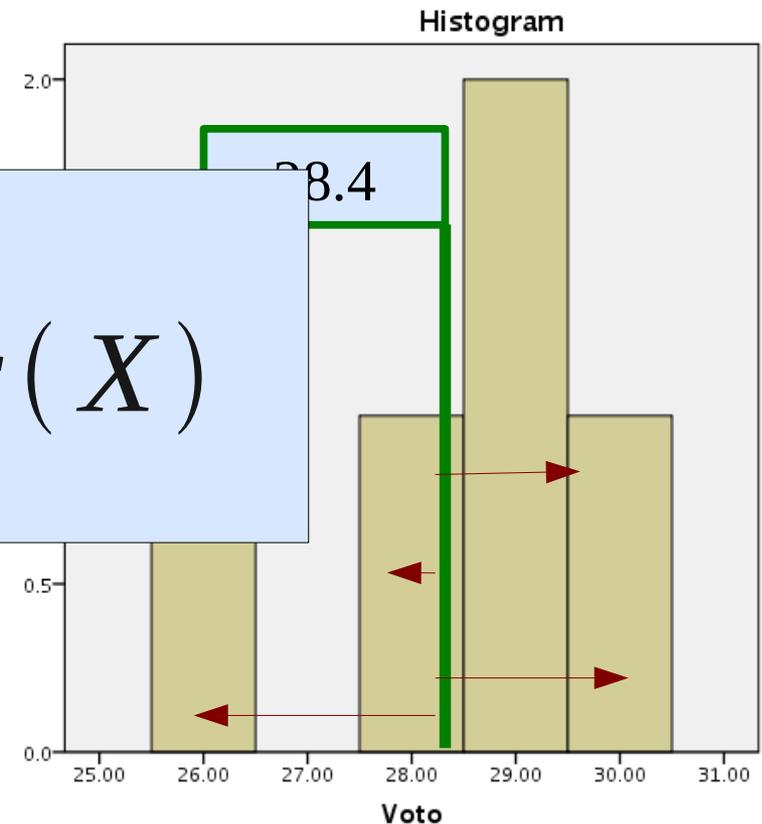
Se, per semplificare, diremo che la performance è di 28.4, misrappresenteremo alcuni dei voti effettivi



Errore di approssimazione

Calcolando questo errore per ogni caso (ogni studente), elevandolo al quadrato (sbagliare in più o in meno è uguale) e facendo la media per ogni caso, quantifichiamo l'errore medie associato alla media

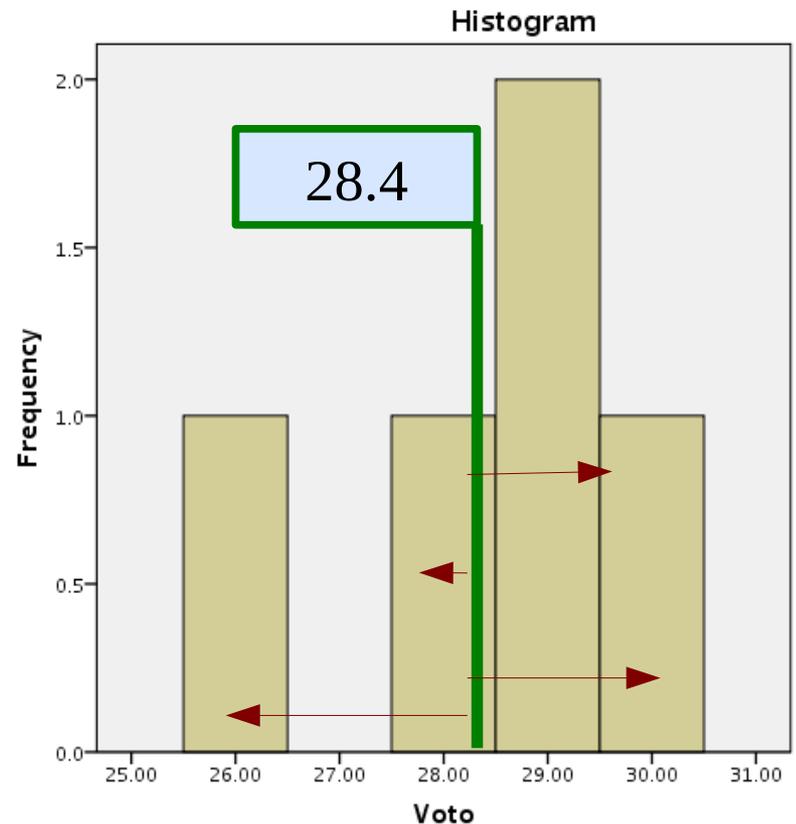
$$\frac{\sum_i (X_i - \bar{X})^2}{N - 1} = \text{Var}(X)$$



Inferenza statistica

Il modello statistico è associato ad una serie di test inferenziali che ci consentono di trarre conclusioni sulla popolazione di riferimento

$$\frac{\bar{X} - \mu}{\sqrt{\frac{\text{Var}(X)}{N}}} = ttest$$

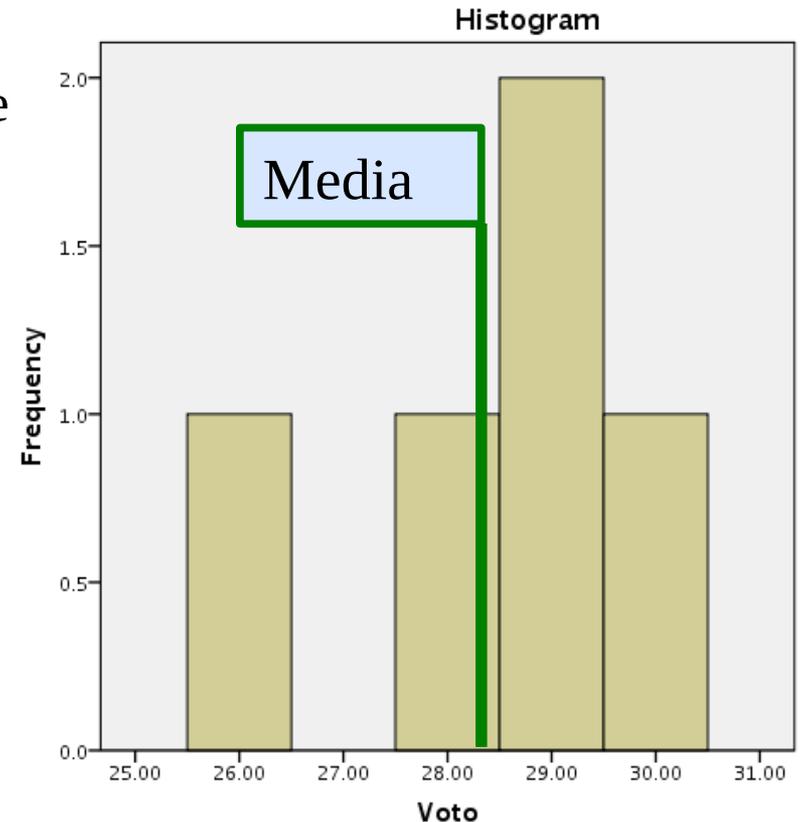


Modello statistico

Il modello statistico sarà una buona rappresentazione dei dati

se:

- I parametri sono modellati correttamente
- Gli errori sono modellati correttamente
- La struttura dei dati è rispettata



Scegliere un modello statistico

Per costruire un corretto modello statistico dei nostri dati dobbiamo sapere una serie di cose:

- Cosa ci serve il modello (lo scopo dell'analisi)
- Che tipo di variabili abbiamo
- Che tipo di relazioni vogliamo studiare
- Quali sono le unità di misurazioni dei dati
- Come sono strutturati i nostri dati

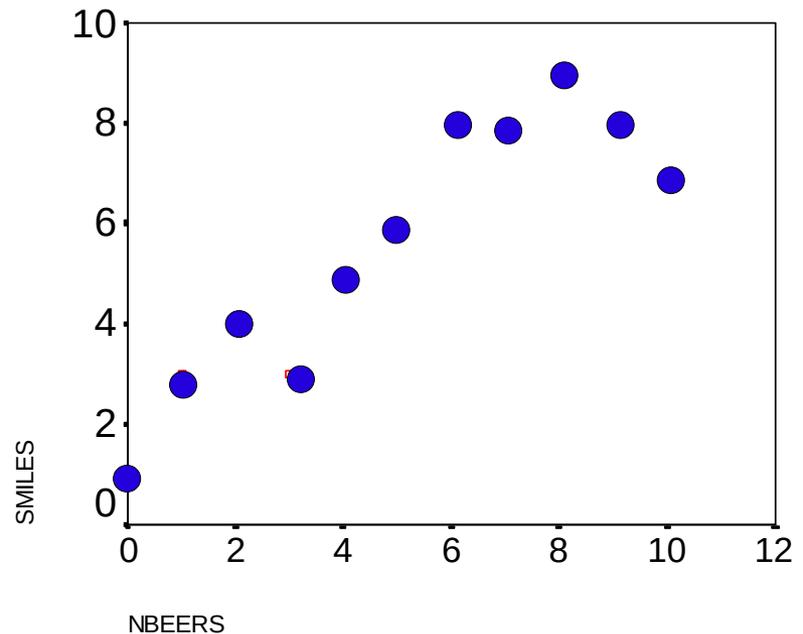
Il modello di regressione

(Capitolo 2)

Concentti fondamentali

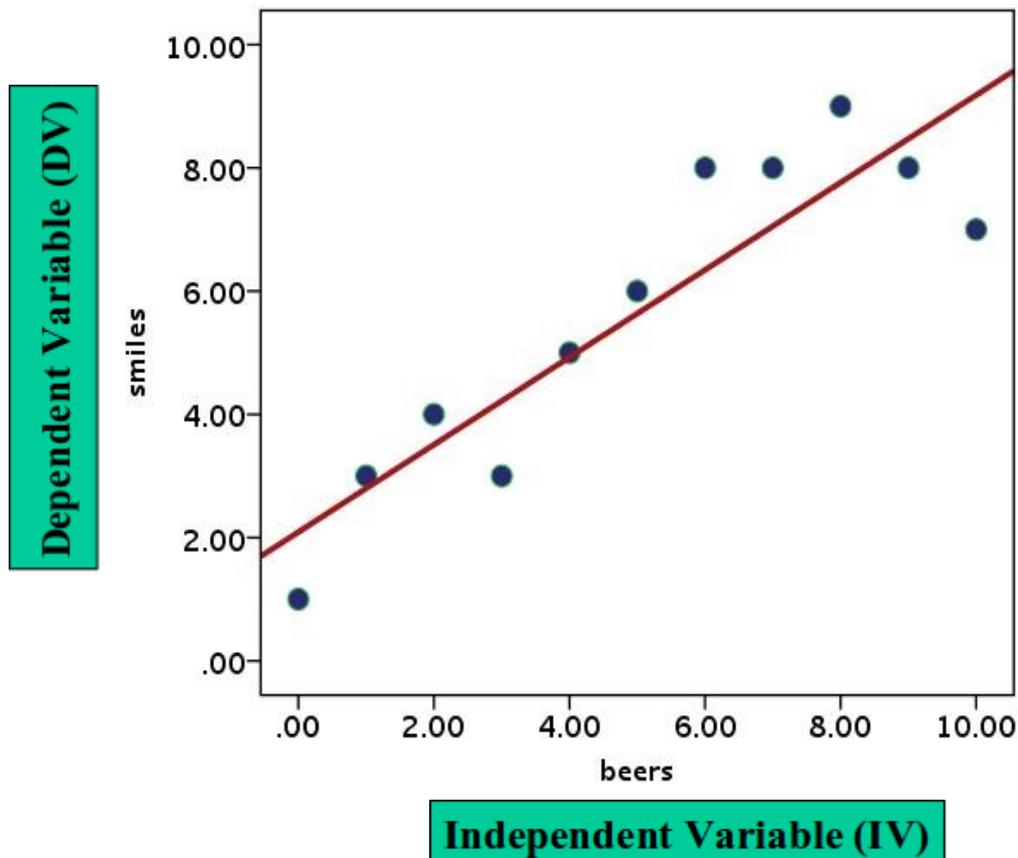
Consideriamo ora questa ipotetica ricerca: siamo andati in un pub ed abbiamo contato quanti sorrisi le persone ai tavoli producevano (ogni 10 minuti) e quante birre avevano bevuto fino a quel momento

<u>Birre</u>	<u>Sorrisi</u>
0	1
1	3
2	4
3	3
4	5
5	6
6	8
7	8
8	9
9	8
10	7



Concentti fondamentali

Lo scopo della retta di regressione è di rappresentare la relazione lineare tra la variabile indipendente e la dipendente



Nel caso più semplice, abbiamo una retta semplice

$$y_i = a + b \cdot x_i + e_i$$

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

Concetti fondamentali

La retta può essere descritta mediante due coefficienti: il termine costante ed il coefficiente angolare

Coefficients^a

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	2.091	.684		3.057	.014
	NBEERS	.709	.116	.898	6.132	.000

a. Dependent Variable: SMILES

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

Termine costante
(o intercetta)

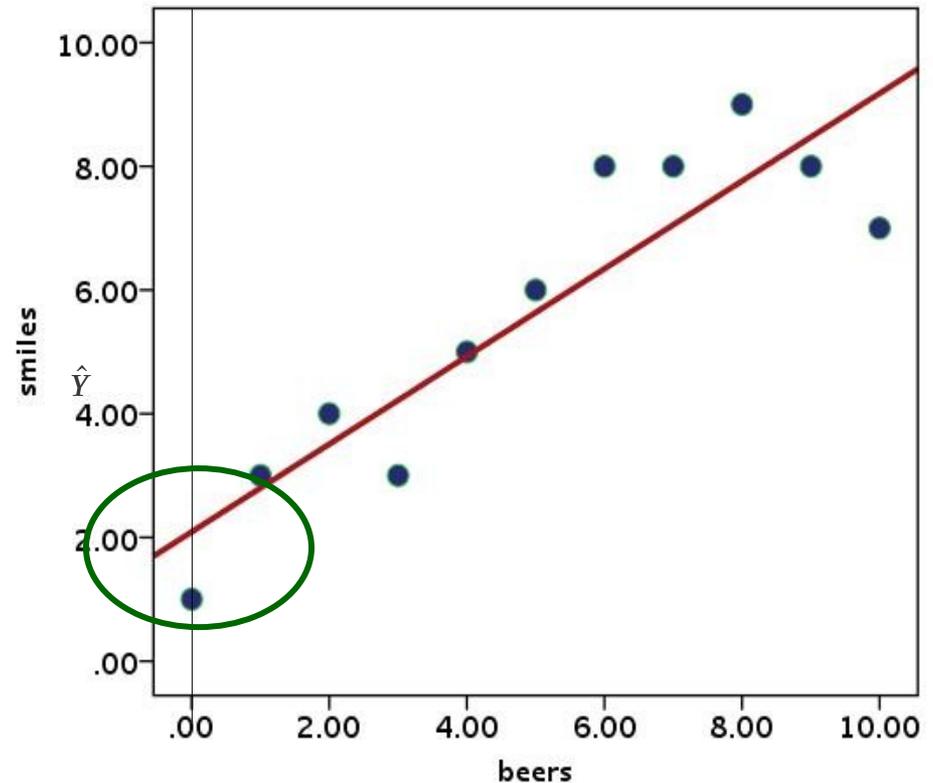
Coefficiente di
regressione
(angolare)

Coefficiente costante

a l'intercetta della linea: indica il valore atteso (medio) della VD per la VI=0

$$\hat{y} = a + b \cdot 0$$

Quando un partecipante ha bevuto zero birre, mostra (in media) 2.09 sorrisi

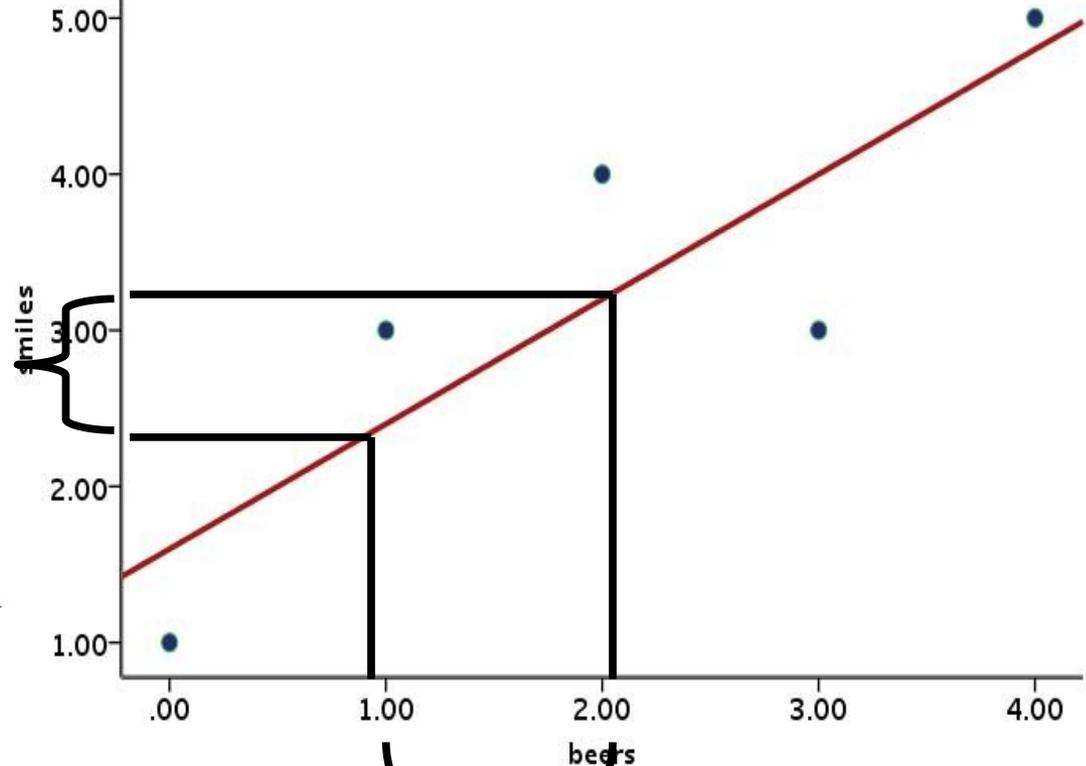


Coefficiente di regressione

B è il coefficiente angolare della retta: indica il cambiamento atteso nella VD al variare di una unità della VI

I sorrisi aumentano di B unità

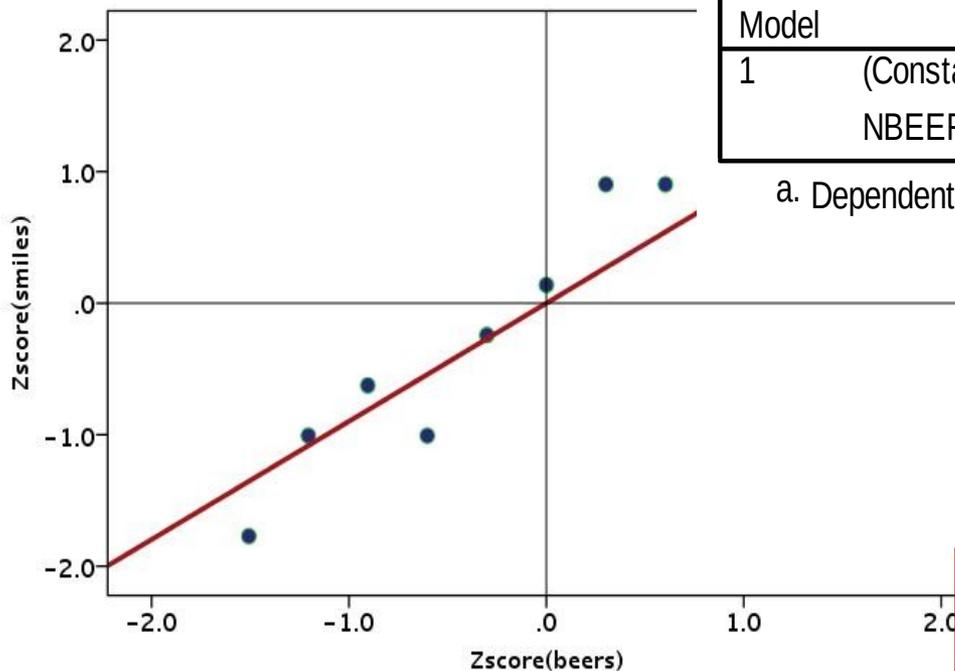
Per ogni birra che si beve, i sorrisi aumentano in media di .709 unità



Per una unità in più della VI: una birra in più

Coefficienti standardizzati

Il coefficiente **Beta** equivale al coefficiente di regressione calcolato dopo aver standardizzato tutte le variabili



Coefficients^a

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	2.091	.684		3.057	.014
	NBEERS	.709	.116	.898	6.132	.000

a. Dependent Variable: SMILES

Il coefficiente standardizzato è uguale al coefficiente r di Pearson

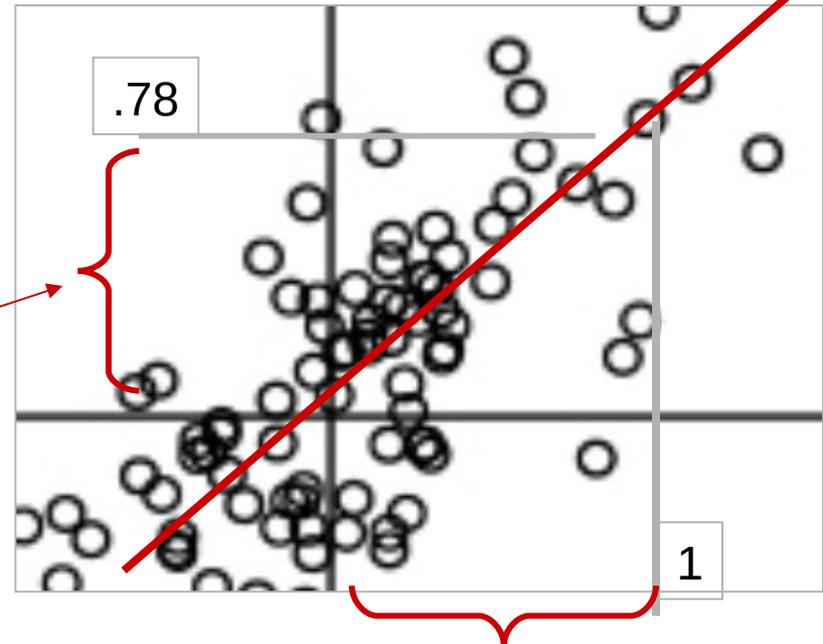
Correlazione: Interpretazione

- La correlazione indica il cambiamento atteso in v , al variare di x di una deviazione standard

Legge di relazione $r=0.78$

$$\hat{v}_z = r_{xv} x_z$$

Mi aspetto una scostamento pari a 78% della dev.std di v



Mi muovo di una dev.std.

Test inferenziale

I coefficienti vengono testati per la loro significatività statistica mediante il t-test **t test**

Coefficients^a

Model	Unstandardized Coefficients		Standardized Coefficients	t	Sig.	
	B	Std. Error	Beta			
1	(Constant)	2.091	.684		3.057	.014
	NBEERS	.709	.116	.898	6.132	.000

a. Dependent Variable: SMILES

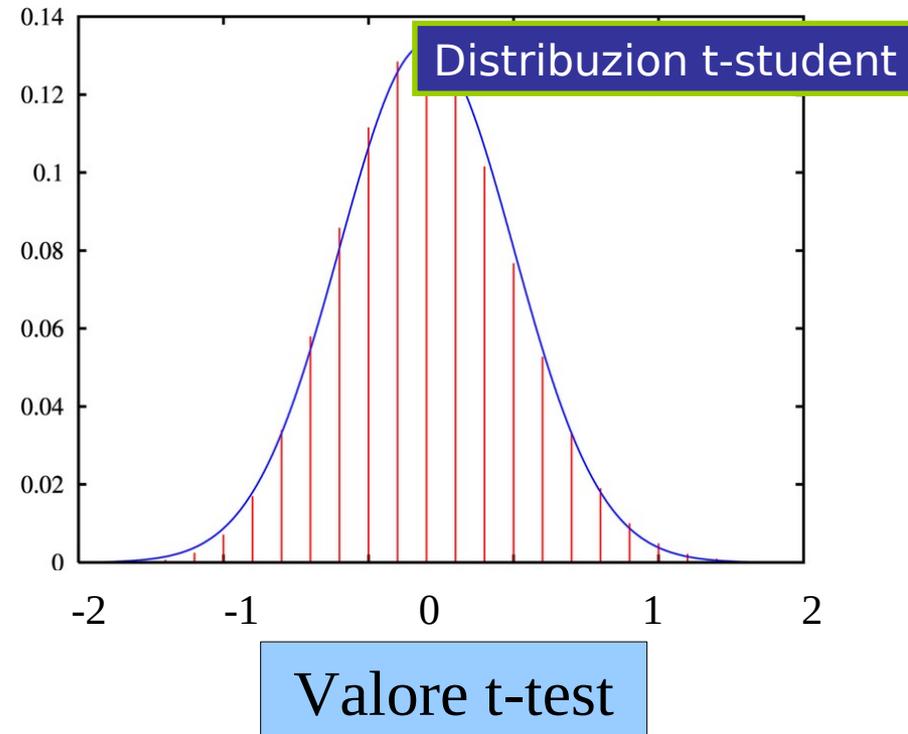
Se Sig. < 0.05, diremo che B (e β) sono significativamente diversi da zero

Valore "p"

- Uno dei test più usati è il t-test

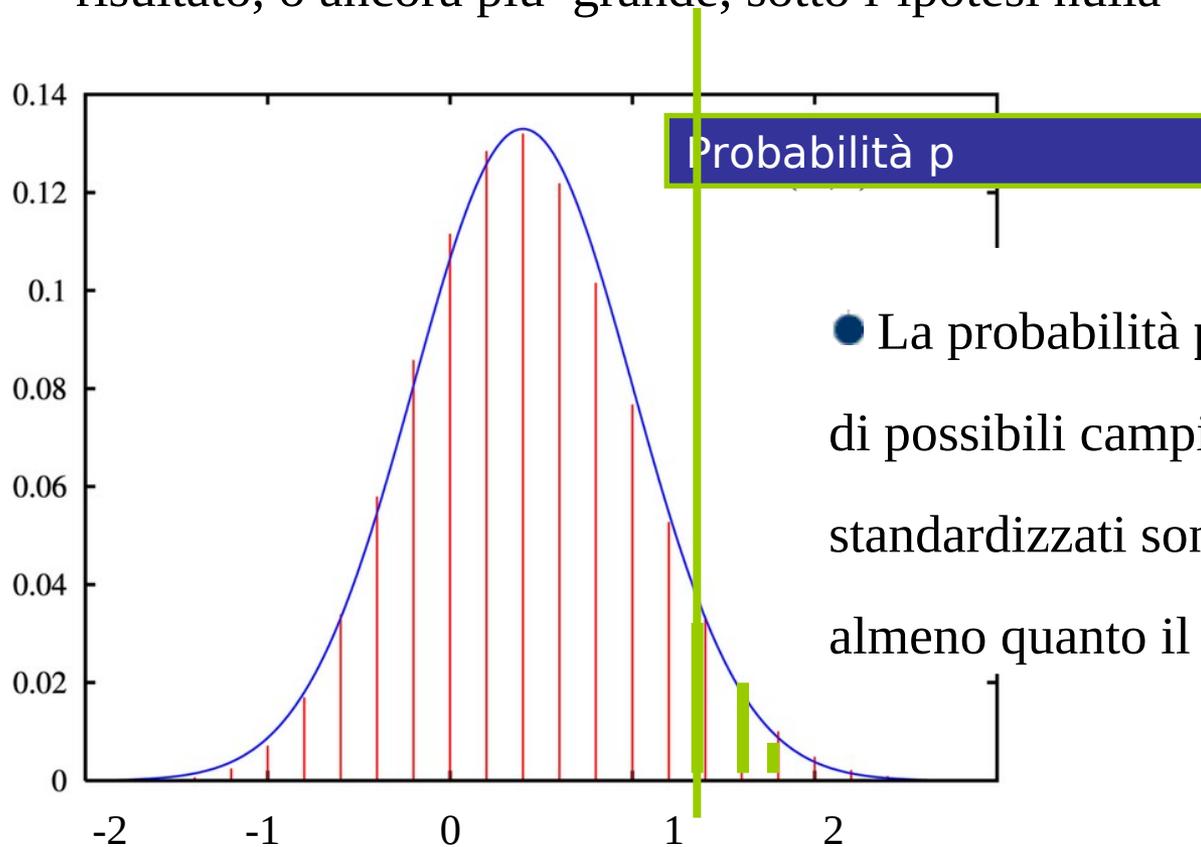
$$\frac{S}{\sqrt{\frac{\text{Var}(S)}{N}}} = ttest$$

S=parametro stimato



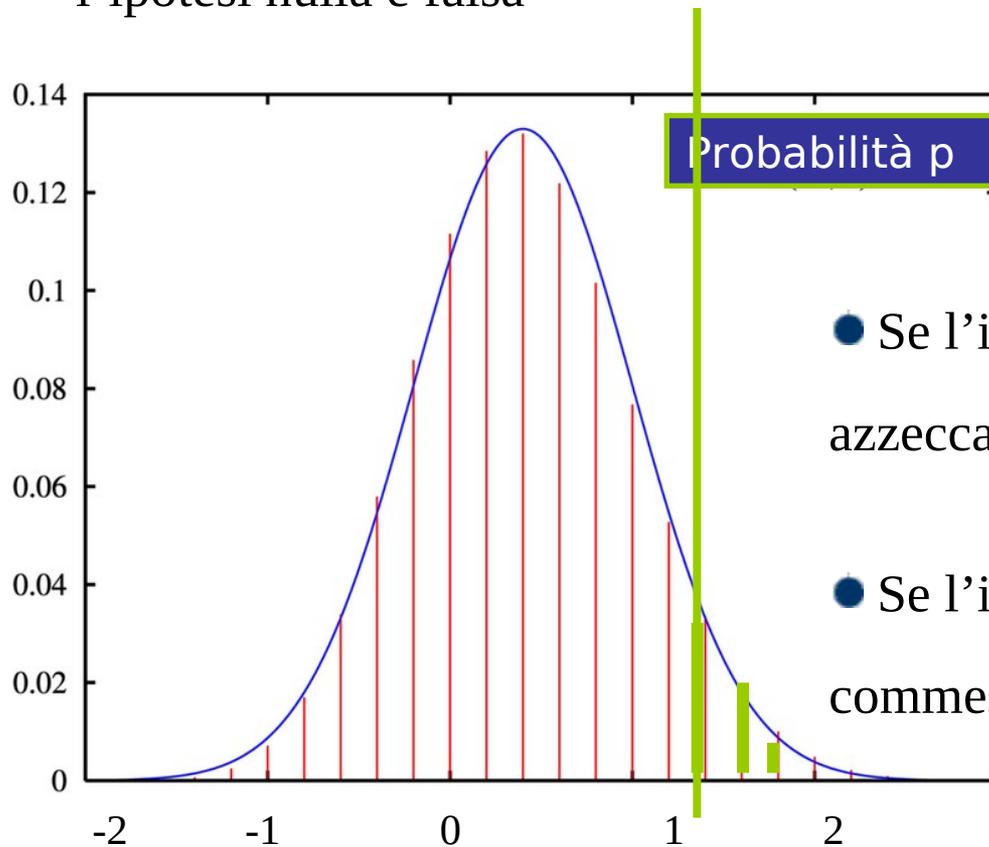
Test Inferenziale

- In generale, il valore p indica la probabilità di ottenere il nostro risultato, o ancora più grande, sotto l'ipotesi nulla



- La probabilità p equivale alla proporzione di possibili campioni i cui scostamenti standardizzati sono distanti dall'ipotesi nulla almeno quanto il campione da noi osservato

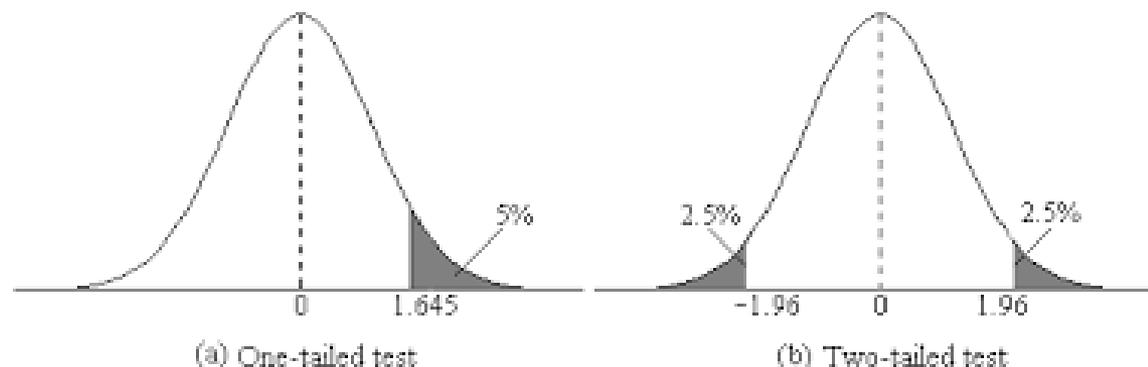
- Il valore p indica il rischio che noi prendiamo quando affermiamo che l'ipotesi nulla è falsa



- Se l'ipotesi nulla è falsa, ci abbiamo azzeccato
- Se l'ipotesi nulla è vera, abbiamo commesso un errore, detto del **Tipo I**

Test inferenziale e valore p

- Sulla base del valore del test inferenziale, possiamo ricavarci la probabilità corrispondente nella distribuzione (valore p)
- Nelle scienze sociali il valore **convenzionale** di significatività è 0.05 (5% di errore) o 0.01 (1 % errore)
- Il test può essere direzionale (una via) o di disequaglianza (due vie)
- Test ad una via (one-tail): il parametro (ad es., la media) =0 vs. >0 (o <)
- Test a due vie (two-tails): il parametro (ad es., la media) =0 vs. $\neq 0$



- La maggior parte dei test inferenziali confrontano la stima con il suo errore standard **errore standard**

$$\frac{S}{\sqrt{\frac{\text{Var}(S)}{N}}} = ttest$$

parametro stimato

Errore standard

Indica quanto variabilità ci aspettiamo nei valori della stima se ripetessimo la stima su tanti campioni presi dalla stessa popolazione

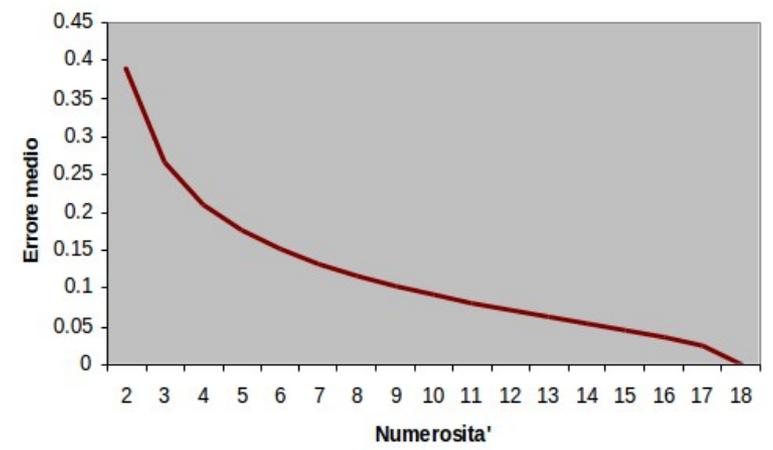
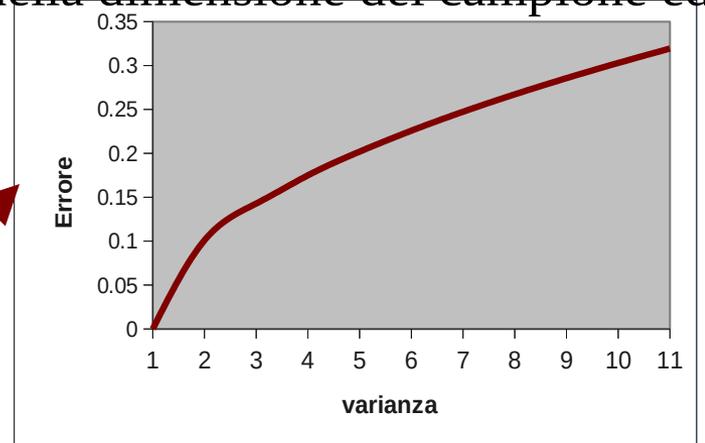
L'errore standard

Errore standard diminuisce all'aumentare della dimensione del campione ed aumenta all'aumentare della variabilità

Aumenta
all'aumentare della
varianza

$$ES = \sqrt{\frac{var(S)}{N}}$$

Diminuisce
all'aumentare della
numerosità



L'errore standard: conseguenze

- Se il carattere stimato ha poca variabilità, campioni piccoli possono dare buone stime
- Se il carattere stimato ha molta variabilità, campioni grandi sono necessari

Numerosità e tipi di fenomeni studiati

- Un conseguenza importante di questo principio e' che tanto più generale (uguale per tutti) e' il fenomeno che stiamo studiando, tanto meno casi ci serviranno (e viceversa)

Fenomeni generali:

Fenomeni neurologici

Fenomeni chimici

Studi di morfologia
del cervello

Studi di funzionalità

Fenomeni specifici:

Opinioni

Risposte
comportamentali a
stimoli complessi

Atteggiamenti

Intervallo di confidenza

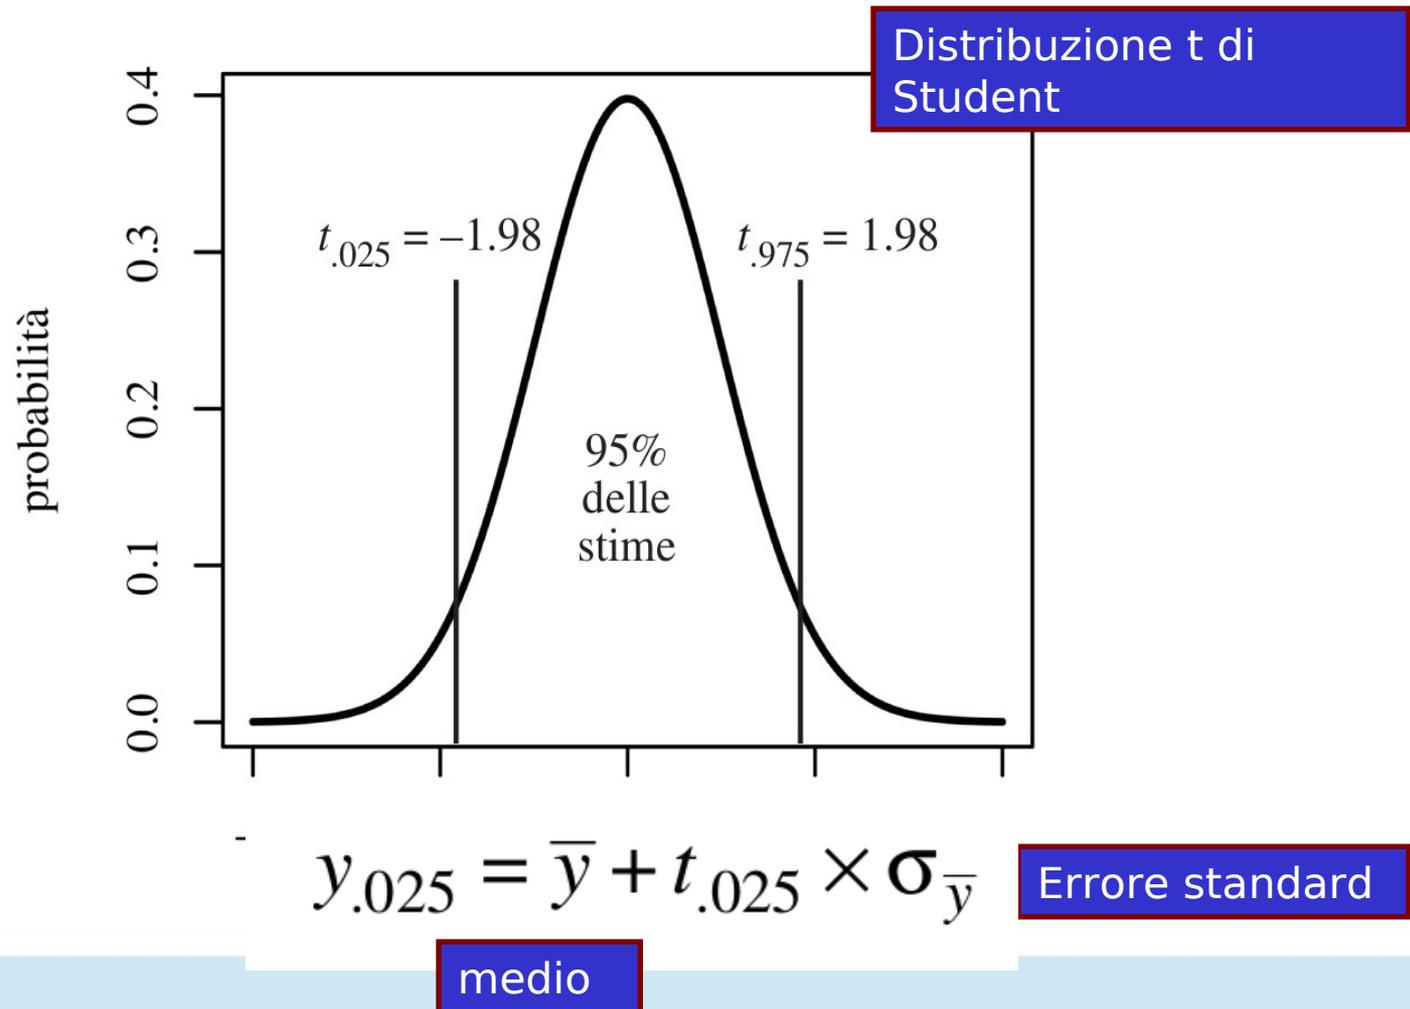
- L'errore standard consente di calcolare l'intervallo di confidenza di una stima (come la media, la correlazione, il coefficiente di regressione)

L' intervallo di confidenza è un intervallo di valori plausibili per quel parametro (ad es., media) nella popolazione (ad es., bevitori di birra)

Dato che la nostra stima varia da campione a campione, IC indica in quale intervallo di valori è ragionevole che cada la stima ripetendo il campionamento

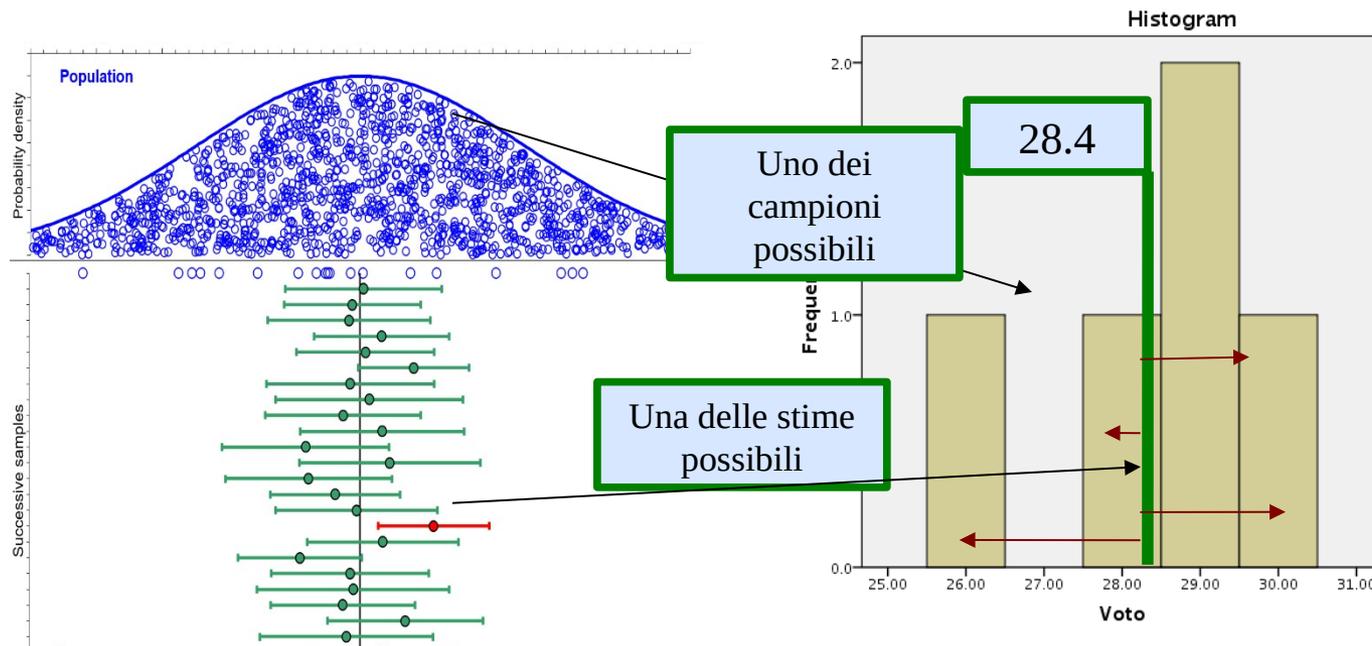
Intervallo di confidenza (IC)

L'IC è molto importante per capire i risultati ottenuti e cattura il concetto di *accuratezza* nella stima del parametro.



Variabilità delle stime

Se continuiamo ad estrarre campioni dalla popolazione, le stime del parametro (media) varieranno in funzione della variabilità dei dati della numerosità campionaria del campione



Intervallo di confidenza

- Viene prodotto dal software

Coefficients^a

Model		Unstandardized Coefficients		Standardize	t	Sig.	95.0% Confidence Interval for B	
		B	Std. Error	d Coefficients			Beta	Lower Bound
1	(Constant)	2.091	.684		3.057	.014	.543	3.638
	Birre	.709	.116	.898	6.132	.000	.448	.971

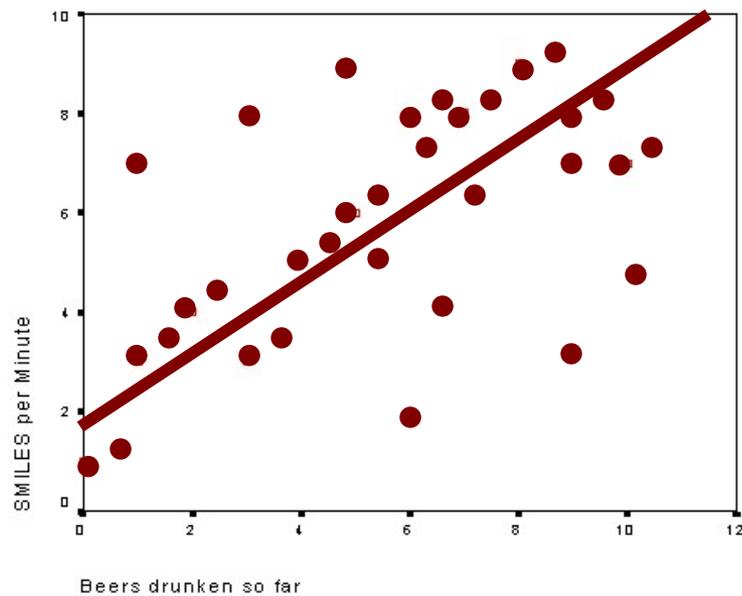
a. Dependent Variable: Sorrisi

Il coefficiente di regressione dell'esempio è "ragionevolmente", cioè con fiducia al 95% nell'intervallo .448-.971

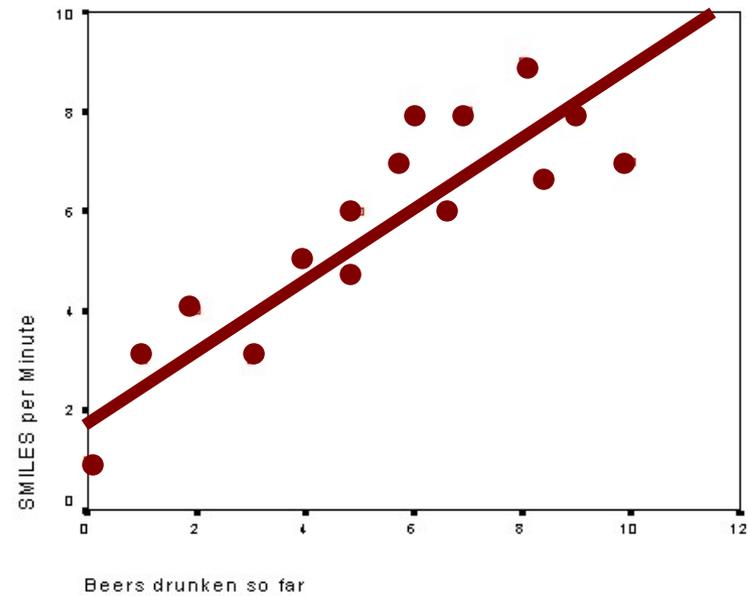
Bonta' di adattamento

Non tutte le rette di regressione hanno lo stesso potere predittivo, cioè la stessa capacità di adattarsi ai dati osservati

bassa



alta



Errore di regressione

Notiamo che la predizione non corrisponde di norma ai valori osservati

$$\hat{y}_i = a + b_{yx} x_i$$

predetti

errore

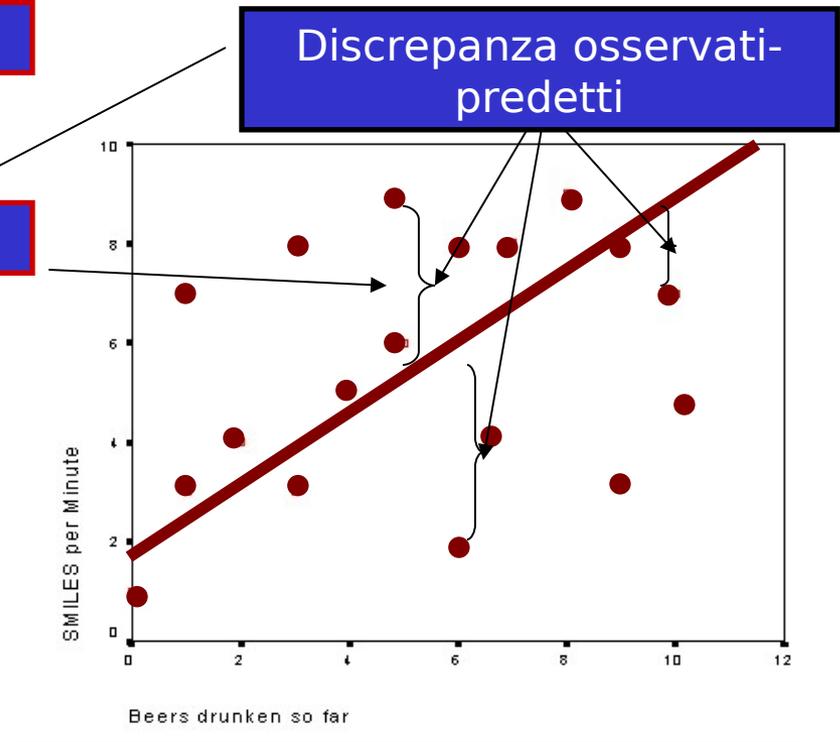
$$y_i - \hat{y}_i = y_i - (a + b_{yx} x_i)$$

Dunque i valori osservati di Y possono essere espressi come somma dei valori predetti e l'errore

$$y_i = (a + b_{yx} x_i) + (y_i - \hat{y}_i)$$

retta

errore



Quanto e' grande l'errore di regressione

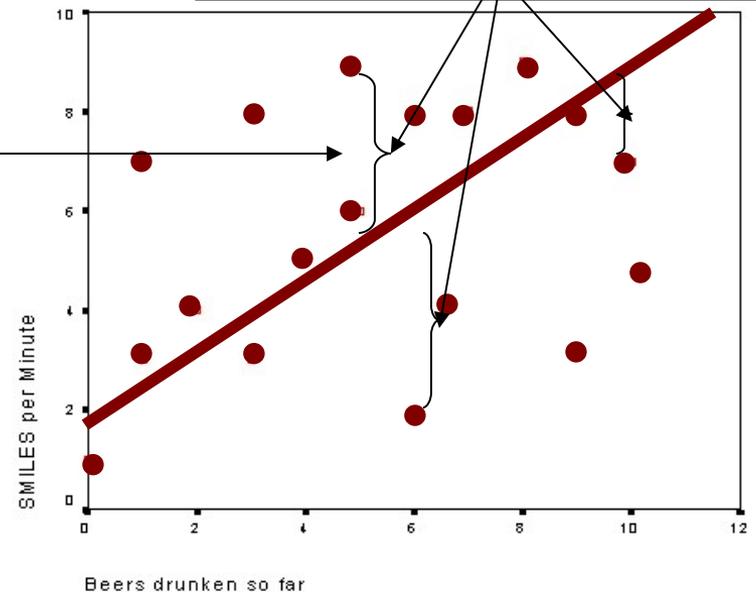
Calcoliamoci la distanza media tra i punti osservati e la retta

Le distanze si calcolano mediante le differenze al quadrato

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

Notiamo che questa e' una varianza, che chiameremo varianza di errore

Discrepanza osservati-predetti



Proporzione riduzione errore

Il modello si adatterà ai dati tanto più riduce l'errore di predizione rispetto a non usare tale modello

- La logica è di confrontare due casi:
 - L'errore calcolato per la regressione data
 - L'errore associato alla media, cioè errore associato a non utilizzare la regressione

Proporzione riduzione errore

Senza regressione l'unica predizione plausibile di Y e' la media di Y

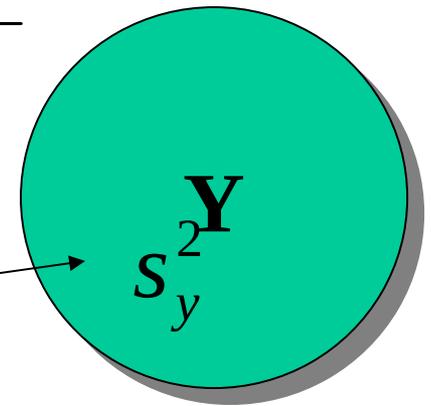
Predizione senza regressione

Errore senza regressione

$$\hat{y}_i = M_y$$

$$s_y^2 = \frac{\sum (y_i - M)^2}{n - 1}$$

Le deviazioni dalla media (la varianza) non siamo in grado di spiegarle



Proporzione riduzione errore

Con la regressione faremo una certa predizione

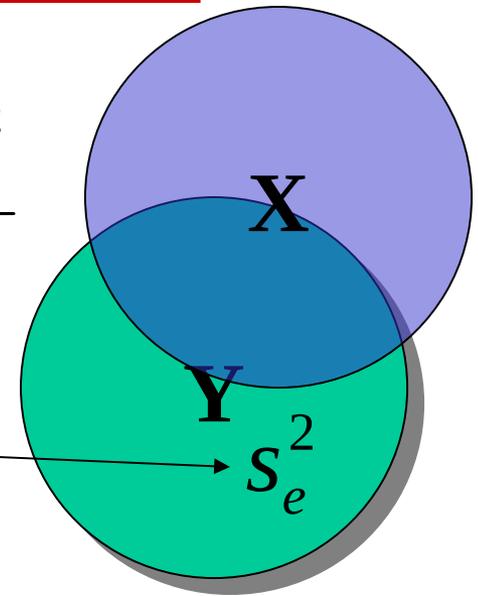
Predizione con regressione

$$\hat{y}_i = a + b_{yx} x_i$$

Errore con regressione

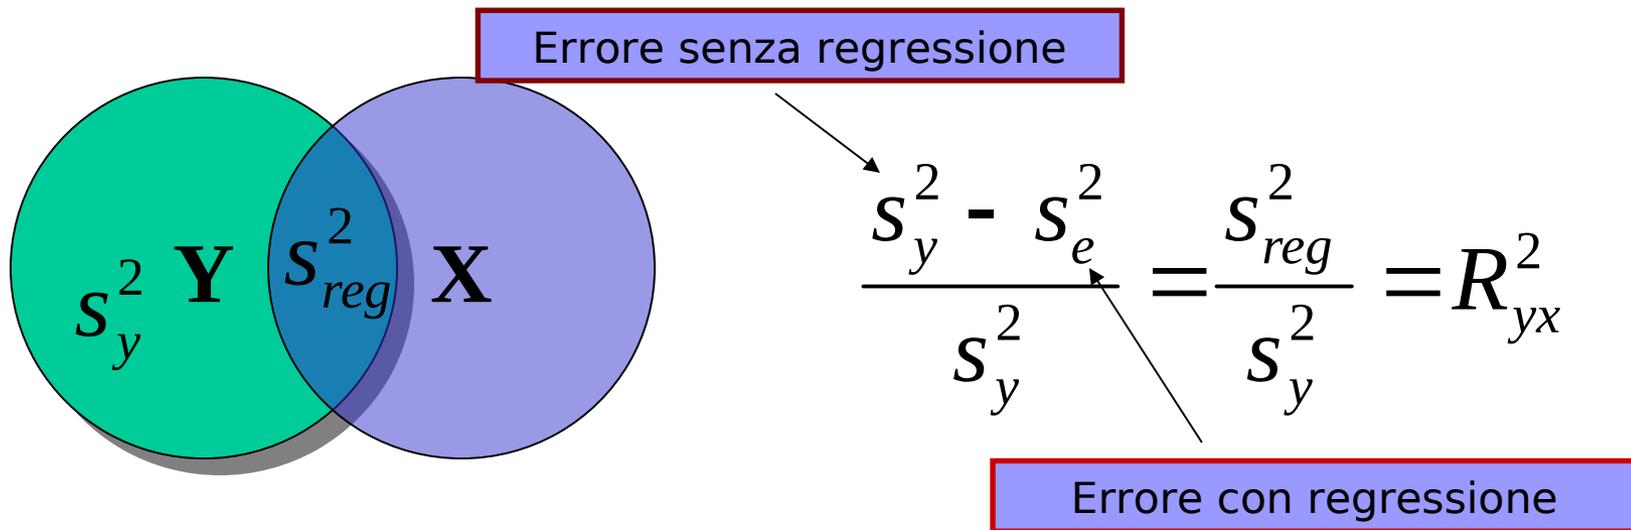
$$s_e^2 = \frac{\sum (y_i - \hat{y}_i)^2}{n - 1}$$

Le deviazioni dalla regressione (varianza di errore) non siamo in grado di spiegarle



R-quadro

Dunque il fit della regressione è tanto buono quanto riesce a migliorare la predizione, cioè a diminuire l'errore



Cioè: Quanto si riduce l'errore di predizione grazie al fatto che usiamo la regressione

Effetti Statistici

- Per effetto statistico si intende quanto il cambiamento di una o più variabili ha effetto sul cambiamento di un'altra variabile
- **Interpretazione esplicativa**: quanto siamo in grado di spiegare della variabilità di una variabile sulla base della variabilità delle altre (**basata sulle varianze**)
- **Interpretazione predittiva**: quanto siamo in grado di predire della variabilità di una variabile basandoci sulla variabilità delle altre (**basata sui coefficienti**)

Fine



Fine della Lezione I