



STATISTICA I

Inferenza statistica

13° settimana

A.A. 2008/2009

Carla Rampichini

Test Unilaterali

- In molti casi, l'ipotesi alternativa si concentra su una particolare direzione

$$H_0: \mu \leq 3$$

$$H_1: \mu > 3$$



Questo è un test sulla coda **destra** perchè l'ipotesi alternativa è focalizzata sulla coda destra, al di sopra della media 3

$$H_0: \mu \geq 3$$

$$H_1: \mu < 3$$



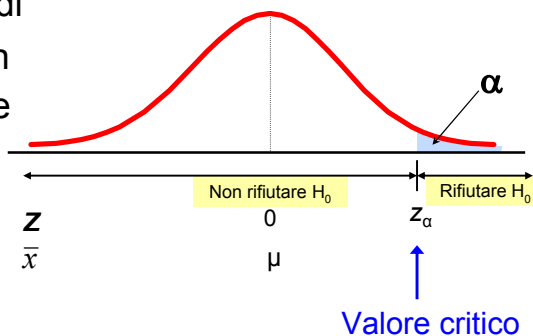
Questo è un test sulla coda **sinistra** perchè l'ipotesi alternativa è focalizzata sulla coda sinistra, al di sotto della media 3

Test sulla coda destra

- C'è solo un valore critico, perchè l'area di rifiuto è solo in una delle code

$$H_0: \mu \leq 3$$

$$H_1: \mu > 3$$

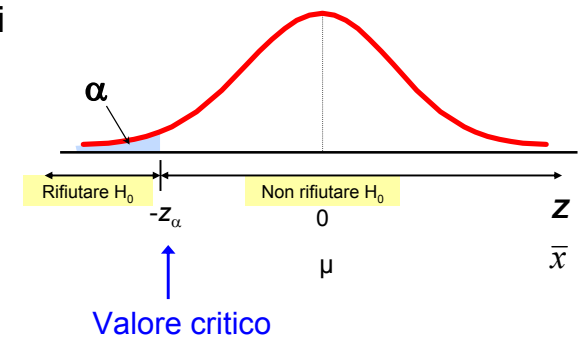


Test sulla coda di sinistra

- C'è solo un valore critico, perchè l'area di rifiuto è solo in una delle code

$$H_0: \mu \geq 3$$

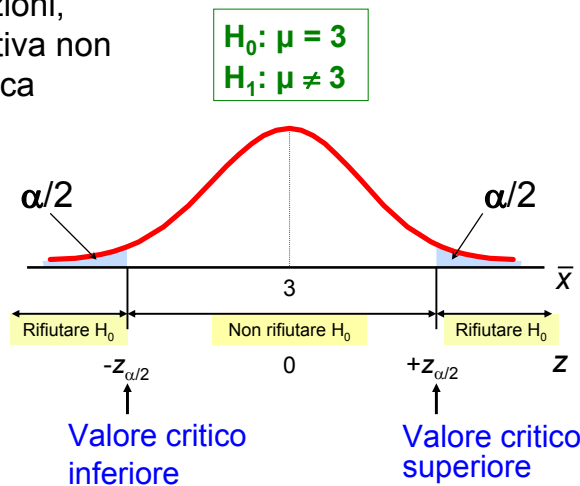
$$H_1: \mu < 3$$



Test bilaterali

- In alcune situazioni, l'ipotesi alternativa non specifica un'unica direzione

- Ci sono due valori critici, che definiscono i due intervalli della regione di rifiuto



Esempio verifica di ipotesi

Verificare l'ipotesi che il numero medio di TV nelle case italiane sia uguale a 3. (assumiamo $X \sim N(\mu, \sigma = 0.8)$)

- Fornire le appropriate ipotesi nulla e alternativa
 - $H_0: \mu = 3$, $H_1: \mu \neq 3$ (test bilaterale)
- Specificare il livello di significatività desiderato
 - viene scelto $\alpha = .05$ per questo test
- Scegliere la dimensione del campione
 - viene selezionato un campione di dimensione $n = 100$

Esempio verifica di ipotesi

(continuazione)

- Determinare la tecnica appropriata
 - σ è nota quindi utilizziamo la statistica test Z
- Calcola i valori critici
 - per $\alpha = .05$ i valori critici z sono ± 1.96
- Raccogli i dati e calcola la statistica test
 - Supponiamo che i risultati campionari siano $n = 100$, $\bar{X} = 2.84$ ($\sigma = 0.8$, si assume nota)


Quindi il valore della statistica test è:

$$z = \frac{\bar{x} - \mu_0}{\frac{\sigma}{\sqrt{n}}} = \frac{2.84 - 3}{\frac{0.8}{\sqrt{100}}} = \frac{-0.16}{0.08} = -2.0$$

Esempio verifica di ipotesi

(continuazione)

- La statistica test calcolata sul campione cade nella regione di rifiuto?




Qui, $z = -2.0 < -1.96$, quindi il valore della statistica test cade nella regione di rifiuto

Esempio verifica di ipotesi

(continuazione)

- Prendere una decisione ed interpretare il risultato



Siccome $z = -2.0 < -1.96$, rifiutiamo l'ipotesi nulla e concludiamo che ci sono sufficienti evidenze che il numero medio di TV nelle case italiane non sia uguale a 3



Esempio: p -value


- Qual è la probabilità di osservare una media campionaria di 2.84 (o un valore più lontano dalla media, in entrambe le direzioni) se la vera media è $\mu = 3$?

$\bar{x} = 2.84$ viene standardizzato
 $\rightarrow z = -2.0$

$$P(z < -2.0) = .0228$$

$$P(z > 2.0) = .0228$$

p -value
 $= 2 \times .0228 = .0456$




Esempio: p -value

(continuazione)

- Confrontare il p -value con α
 - Se p -value $< \alpha$, rifiutare H_0
 - Se p -value $\geq \alpha$, non rifiutare H_0

qui: p -value = .0456
 $\alpha = .05$

poichè $.0456 < .05$,
 rifiutiamo l'ipotesi nulla



p -value verso livello di significatività

- La procedura classica dei test di significatività può essere di 2 tipi
 1. si calcola una probabilità – il p -value – che indica quanto sia *inusuale* ottenere il risultato osservato se l'ipotesi nulla è vera e quindi usa il p -value per valutare l'evidenza dei dati CONTRO l'ipotesi nulla. La decisione se rifiutare o meno l'ipotesi è lasciata al ricercatore, che esprime un giudizio in base al contesto in cui deve decidere.
 2. si fissa un limite – il **livello di significatività** – per questa probabilità e quindi si rifiuta automaticamente l'ipotesi nulla se il p -value supera questo limite.
- Di solito si preferisce il secondo approccio perchè:
 - consente al ricercatore di studiare la **potenza del test** nel rifiutare l'ipotesi nulla al variare dell'ipotesi alternativa e di decidere l'ampiezza campionaria di conseguenza.
 - esiste una **corrispondenza biunivoca** tra l'intervallo di confidenza al livello $1 - \alpha$ per la media e un test a due code per quella media: valori plausibili prodotti dall'intervallo di confidenza sono esattamente quelli che non sarebbero rifiutati in un test a due code con significatività α .

P-value vs livello di significatività: pro e contro

- Uno svantaggio dell'approccio con livello di significatività fissato a priori è che il processo decisionale è fissato **prima** di vedere i dati e questo rende più rigido il giudizio del ricercatore:
- Un p-value grande implica un'evidenza debole, mentre un p-value piccolo implica un'evidenza forte
- **Il livello di significatività può essere visto come il massimo p-value per il quale si rifiuta l'ipotesi nulla**
- Storicamente, l'approccio del p-value fu sviluppato e diffuso da R. A. Fisher, scienziato brillante ed esperto analista di dati, mentre l'approccio basato sul livello di significatività è stato sviluppato dai due statistici-matematici J. Neyman and E. Pearson. Neyman sviluppò anche la nozione di intervallo di confidenza
- La discussione su quale di questi due approcci sia il migliore è accesa ancora oggi, ma molti statistici applicati sono favorevoli ad un approccio 'combinato': fissano il livello di significatività a priori per pianificare l'esperimento, una volta osservato il campione, procedono alla stima per intervalli e utilizzano il p-value per valutare l'evidenza empirica in fase di test delle ipotesi.

Test sulla media, varianza incognita

- Consideriamo il carattere $X \sim N(\mu, \sigma^2)$, **con media e varianza incognite**
- Si dispone di un campione casuale di ampiezza n
- Vogliamo sottoporre a verifica empirica un'ipotesi riguardante la media della popolazione μ , in una delle forme
 - $H_0: \mu \leq \mu_0$ vs $H_1: \mu > \mu_0$
 - $H_0: \mu \geq \mu_0$ vs $H_1: \mu < \mu_0$
 - $H_0: \mu = \mu_0$ vs $H_1: \mu \neq \mu_0$
- La migliore statistica test è la media campionaria; però σ non è nota \rightarrow **dovremo sostituire σ con la deviazione standard campionaria S**

Test sulla media di una distribuzione normale con σ incognita

- **statistica test T**

$$t = \frac{\bar{x} - \mu_0}{s / \sqrt{n}} \sim t_{n-1}$$

T ha distribuzione t di Student con $n-1$ gdl

Consideriamo il test

$$\begin{aligned} H_0: \mu &= \mu_0 \\ H_1: \mu &> \mu_0 \end{aligned}$$

La **regola di decisione** è:

$$\text{rifiutare } H_0 \text{ se } t = \frac{\bar{x} - \mu_0}{s / \sqrt{n}} > t_{n-1, \alpha}$$

Test T sulla Media (σ non nota) *(continuazione)*

- Per un test bilaterale:

Consideriamo il test

$$\begin{aligned} H_0: \mu &= \mu_0 \\ H_1: \mu &\neq \mu_0 \end{aligned}$$

(Assumiamo che la popolazione abbia distribuzione normale, e la varianza della popolazione non sia nota)

La **regola di decisione** è rifiutare H_0 se:


$$t = \frac{\bar{x} - \mu_0}{s / \sqrt{n}} < -t_{n-1, \alpha/2}$$

o

$$t = \frac{\bar{x} - \mu_0}{s / \sqrt{n}} > t_{n-1, \alpha/2}$$

Esempio: test bilaterale sulla media di una distribuzione normale (σ non nota)

- Il costo medio di una camera doppia in hotel a Roma si dice che sia 168 € per notte.
- Un campione casuale di 25 hotel ha fornito $M(\bar{x}) = 172.50$ € e $s = 15.40$ €.
- Verifica l'ipotesi ad un livello di significatività $\alpha = 0.05$.



$$H_0: \mu = 168$$

$$H_1: \mu \neq 168$$

Soluzione esempio: test T bilaterale

$$H_0: \mu = 168$$


$$H_1: \mu \neq 168$$

$$\alpha = 0.05$$

$$n = 25$$

σ è incognita, quindi usiamo la statistica T

Valore Critico:
 $t_{24, .025} = \pm 2.0639$



$$t_{n-1} = \frac{\bar{x} - \mu}{s / \sqrt{n}} = \frac{172.50 - 168}{15.40 / \sqrt{25}} = 1.46$$

Non rifiutare H_0 :

non c'è evidenza sufficiente che il costo medio differisca da 168 €

Test sulla media di una distribuzione normale con varianza incognita

X_1, \dots, X_n , con $X \sim N(\mu, \sigma^2)$, σ^2 incognita.

► $H_0: \mu = \mu_0$, di dimensione α : $P(x \in R | H_0) = \alpha$

► Statistica test \bar{X} , $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$.

► La regione critica R varia in base all'ipotesi alternativa:

• $H_1: \mu > \mu_0$, $R = \{x: \bar{X} \geq \mu_0 + t_{(\alpha, g)} \frac{S}{\sqrt{n}}\}$

• $H_1: \mu < \mu_0$, $R = \{x: \bar{X} \leq \mu_0 - t_{(\alpha, g)} \frac{S}{\sqrt{n}}\}$

• $H_1: \mu \neq \mu_0$, $R = \{x: \bar{X} \leq \mu_0 - t_{(\alpha/2, g)} \frac{S}{\sqrt{n}}, \bar{X} \geq \mu_0 + t_{(\alpha/2, g)} \frac{S}{\sqrt{n}}\}$

► I quantili $t_{(\alpha, g)}$ sono relativi ad una v.c. T di Student con $g = n - 1$ gradi di libertà.

► Per n grande ($n > 100$) la distribuzione della v.c. T di Student è approssimata dalla $N(\mu, \sigma^2) \Rightarrow$ i quantili $t_{(\alpha, g)}$ possono essere sostituiti dai quantili z_α .

Test sulla Proporzione della Popolazione

- Riguarda **variabili categoriche**
- Due possibili risultati
 - “Successo” (una certa caratteristica è presente)
 - “Insuccesso” (la caratteristica non è presente)
- La frazione o proporzione della popolazione nella categoria dei “successi” è indicata con π
- Assumiamo che il campione sia grande

Proporzioni

(continuazione)

- La proporzione campionaria di successi viene indicata con p

$$p = \frac{X}{n} = \frac{\text{numero di successi nel campione}}{\text{dimensione del campione}}$$

- Quando $n\pi(1 - \pi) > 9$, la distribuzione di p può essere approssimata con una distribuzione normale con media e deviazione standard:

$$E(p) = \pi$$

$$\sigma_p = \sqrt{\frac{\pi(1 - \pi)}{n}}$$

Verifica di ipotesi su proporzioni

$$np(1 - p) > 9$$

- La distribuzione campionaria di p è approssimativamente normale, quindi usiamo la statistica test Z :


$$Z = \frac{p - \pi_0}{\sqrt{\frac{\pi_0(1 - \pi_0)}{n}}}$$

$$np(1 - p) < 9$$

Non discusso in questo corso

Esempio: test Z su proporzioni

Una società di marketing afferma che il suo tasso di risposta alla mailing è dell'8%. Per verificare questa ipotesi, si considera un campione aleatorio di 500 clienti e si ottengono 25 risposte. Verificare l'ipotesi ad un livello $\alpha = .05$.



Verifica approssimazione normale: la nostra approssimazione per π è

$$p = 25/500 = .05$$

$$np(1 - p) = (500)(.05)(.95) = 23.75 > 9$$

Test Z sulla proporzione: soluzione

$$H_0: \pi = .08$$

$$H_1: \pi \neq .08$$


$$\alpha = .05$$

$$n = 500, p = .05$$

$$\text{Valori Critici: } \pm 1.96$$

Statistica Test:

$$z = \frac{p - \pi_0}{\sqrt{\frac{\pi_0(1 - \pi_0)}{n}}} = \frac{.05 - .08}{\sqrt{\frac{.08(1 - .08)}{500}}} = -2.47$$



Decisione:

Rifiutare H_0 con $\alpha = .05$

Conclusione:


C'è evidenza empirica sufficiente per rifiutare l'ipotesi che il tasso di risposta sia dell'8%.

Soluzione p-value

(continuazione)

Calcolare il p-value e confrontare con α

(Per un test bilaterale il p-value è sempre a due code)



Rifiutare H_0 perchè p-value = .0136 < α = .05

Potenza del Test

- Ricordare i possibili risultati della verifica di ipotesi:

Decisione	Stato di Natura	
	H_0 Vera	H_0 Falsa
Non Rifiutare H_0	No errore ($1 - \alpha$)	Errore di II Tipo (β)
Rifiutare H_0	Errore di I Tipo (α)	No Errore ($1 - \beta$)

**Legenda:
Risultato
(Probabilità)**

- β rappresenta la probabilità dell'errore di II tipo
- $1 - \beta = P(x \notin R | H_1)$ è la **potenza del test** sotto H_1
 → probabilità di rifiutare l'ipotesi nulla quando è falsa

Potenza = $P(x \notin R)$ probabilità di rifiutare l'ipotesi nulla

Errori e potenza del test

- Il **livello di significatività α** è la probabilità di rifiutare l'ipotesi nulla quando è vera, cioè la probabilità di commettere un errore di I tipo.
- Un **errore di II tipo** consiste nel NON rifiutare l'ipotesi nulla quando è FALSA. La probabilità di commettere errore di II tipo si indica con β e in generale non è nota.
- La **potenza del test** è la **probabilità di rifiutare l'ipotesi nulla**. Sotto H_1 la potenza del test è pari a $1 - \beta$, mentre sotto H_0 è pari al livello di significatività α , che è anche la probabilità di errore di I tipo.
- Il calcolo della potenza del test richiede la conoscenza del valore di μ sotto H_1 . Spesso l'ipotesi alternativa è composta e a volte anche bidirezionale, quindi non c'è un unico valore di μ sotto H_1 .
- Di solito si calcola la potenza del test per tutti i valori di interesse e per vari valori della dimensione campionaria, così da scegliere il valore di n appropriato per garantire una potenza del test adeguata per alternative di particolare interesse per lo studio che si sta conducendo. NB: La potenza è una proprietà del test (regola decisionale) → i dati campionari non servono!

Errore di secondo tipo

Assumiamo che la popolazione abbia distribuzione normale e la varianza della popolazione sia nota. Consideriamo il test

$$\begin{aligned} H_0 : \mu &= \mu_0 \\ H_1 : \mu &> \mu_0 \end{aligned}$$

La regola di decisione è:

$$\text{Rifiutare } H_0 \text{ se } z = \frac{\bar{x} - \mu_0}{\sigma / \sqrt{n}} > z_\alpha$$

$$\text{Rifiutare } H_0 \text{ se } \bar{x} = \bar{x}_c > \mu_0 + z_\alpha \sigma / \sqrt{n}$$


Se l'ipotesi nulla è falsa e la vera media è μ^* , allora la probabilità dell'errore di secondo tipo è

$$\beta = P(\bar{X} < \bar{x}_c | \mu = \mu^*) = P\left(Z < \frac{\bar{x}_c - \mu^*}{\sigma / \sqrt{n}}\right)$$

Esempio errore di II tipo

- Errore di II tipo corrisponde alla probabilità di NON rifiutare un'ipotesi nulla falsa

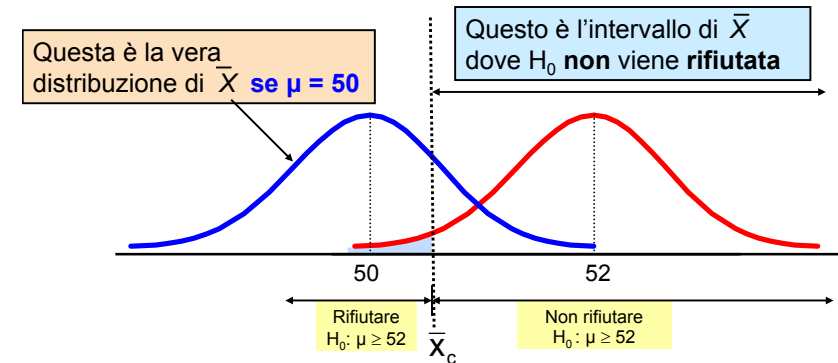
Supponiamo che $H_0: \mu \geq 52$ non venga rifiutata quando infatti la vera media è $\mu^* = 50$



Esempio errore di II tipo


(continuazione)

- Supponiamo che $H_0: \mu \geq 52$ non venga rifiutata quando infatti la vera media è $\mu^* = 50$



Esempio Errore di Secondo Tipo (continuazione)

- Supponiamo che $H_0: \mu \geq 52$ non venga rifiutata quando infatti la vera media è $\mu^* = 50$




Calcolo di beta

- Supponiamo $n = 64$, $\sigma = 6$, e $\alpha = .05$

$$\bar{x}_c = \mu_0 - z_\alpha \frac{\sigma}{\sqrt{n}} = 52 - 1.645 \frac{6}{\sqrt{64}} = 50.766$$

(per $H_0: \mu \geq 52$)

Quindi $\beta = P(\bar{X} \geq 50.766 | \mu^* = 50)$




Calcolo di β

(continuazione)

- Supponiamo $n = 64$, $\sigma = 6$, e $\alpha = .05$

$$P(\bar{X} \geq 50.766 | \mu^* = 50) = P\left(Z \geq \frac{50.766 - 50}{\frac{6}{\sqrt{64}}}\right) = P(Z \geq 1.02) = 0.1539$$



Esempio potenza del test

Se vale $H_1: \mu^* = 50$:

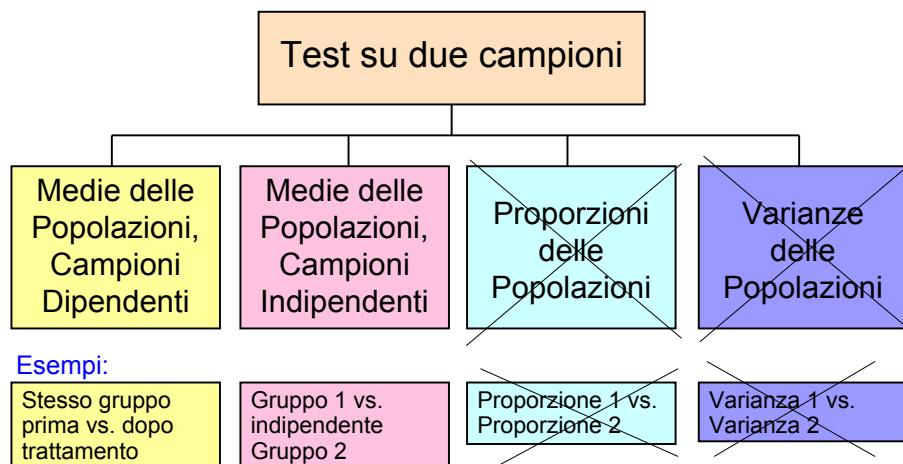
- Probabilità dell'errore di II tipo: $\beta = 0.1539$
- Potenza del test: $1 - \beta = 1 - 0.1539 = 0.8461$

Legenda:
Risultato
(Probabilità)

Decisione	Stato di Natura	
	H_0 Vera	H_0 Falsa
Non Rifiutare H_0	No errore $1 - \alpha = 0.95$	Errore di II tipo $\beta = 0.1539$
Rifiutare H_0	Errore di I tipo $\alpha = 0.05$	No errore $1 - \beta = 0.8461$

(Il valore di β e la potenza saranno diversi per diversi valori di μ^*)

Test su due campioni



Confronto tra le medie di due popolazioni

Consideriamo un carattere rilevato su due popolazioni (X sulla prima, Y sulla seconda)

Il confronto tra due medie si può esprimere in termini di **differenza**

$\begin{cases} H_0: \mu_X \geq \mu_Y \\ H_1: \mu_X < \mu_Y \end{cases}$ equivale a $\begin{cases} H_0: \mu_X - \mu_Y \geq 0 \\ H_1: \mu_X - \mu_Y < 0 \end{cases}$ (test coda sinistra)	$\begin{cases} H_0: \mu_X \leq \mu_Y \\ H_1: \mu_X > \mu_Y \end{cases}$ equivale a $\begin{cases} H_0: \mu_X - \mu_Y \leq 0 \\ H_1: \mu_X - \mu_Y > 0 \end{cases}$ (test coda destra)	$\begin{cases} H_0: \mu_X = \mu_Y \\ H_1: \mu_X \neq \mu_Y \end{cases}$ equivale a $\begin{cases} H_0: \mu_X - \mu_Y = 0 \\ H_1: \mu_X - \mu_Y \neq 0 \end{cases}$ (test bidirezionale)
--	--	--

Differenza tra medie di campioni dipendenti

- Confrontiamo le medie di 2 popolazioni appaiate
 - Misure ripetute (prima/dopo)
 - Dati appaiati

	Popolazione 1	Popolazione 2	
Media popolazione	μ_X	μ_Y	<i>n</i> coppie <i>2n</i> osservazioni
Dev. Std. popolazione	σ_X	σ_Y	
Ampiezza campione	<i>n</i>	<i>n</i>	

- Assunzioni:
 - Entrambe le popolazioni hanno distribuzione Normale
 - Campione casuale di coppie

Differenza tra due medie (campioni dipendenti)

- Idea: calcolare le differenze ... $D_i = X_i - Y_i$
- ... e poi calcolare la differenza media $\bar{D} = \frac{1}{n} \sum_{i=1}^n D_i$
- Infatti, le differenze D_i sono *n* v.a. indipendenti e identicamente distribuite con valore atteso

$$E(D_i) = E(X_i - Y_i) = E(X_i) - E(Y_i) = \mu_X - \mu_Y$$
- Dalle proprietà della media campionaria segue che

$$E(\bar{D}) = E(D_i) = \mu_X - \mu_Y$$

Questa è la differenza oggetto di ipotesi

$$\bar{D} \sim \text{Normale}$$

Differenza tra due medie (campioni dipendenti)

- Per sottoporre a test l'ipotesi nulla che la differenza tra le medie sia d_0 si usa la statistica test

$$T_0 = \frac{\bar{D} - d_0}{S_d / \sqrt{n}} \stackrel{H_0}{\sim} t_{n-1}$$


Essendo passati dalle 2*n* osservazioni alle *n* differenze si ha un test *t* come per la media di una singola popolazione

- d_0 = differenza tra medie sotto H_0 , p.e $H_0: \mu_X - \mu_Y = d_0$
- S_d = deviazione standard campionaria delle differenze
- *n* = dimensione del campione (n. di coppie = n. di differenze)

Differenza tra due medie(campioni dipendenti)

Campioni dipendenti: test per verificare se la differenza è nulla ($d_0 = 0$)

$\begin{cases} H_0: \mu_X - \mu_Y \geq 0 \\ H_1: \mu_X - \mu_Y < 0 \end{cases}$ (test coda sinistra)	$\begin{cases} H_0: \mu_X - \mu_Y \leq 0 \\ H_1: \mu_X - \mu_Y > 0 \end{cases}$ (test coda destra)	$\begin{cases} H_0: \mu_X - \mu_Y = 0 \\ H_1: \mu_X - \mu_Y \neq 0 \end{cases}$ (test bidirezionale)
--	--	--



Rifiutare H_0 se $t_0 < -t_{n-1, \alpha}$

Rifiutare H_0 se $t_0 > t_{n-1, \alpha}$

Rifiutare H_0 se $t_0 < -t_{n-1, \alpha/2}$
o $t_0 > t_{n-1, \alpha/2}$

$$\text{dove } t_0 = \frac{\bar{d} - 0}{s_d / \sqrt{n}}$$

Campioni dipendenti: esempio

I rappresentanti della vostra azienda partecipano ad un workshop sul "servizio ai clienti". La partecipazione ha o non ha prodotto un cambiamento nel numero di reclami?

Si dispone dei seguenti dati:

Rappresent.	Numero di Reclami:		(2) - (1) Differenze, d_i
	Prima (1)	Dopo (2)	
C.B.	6	4	- 2
T.F.	20	6	-14
M.H.	3	2	- 1
R.K.	0	0	0
M.O.	4	0	-4
			-21

$$\bar{d} = \frac{1}{n} \sum_{i=1}^n d_i = -4.2$$

$$s_d = \sqrt{\frac{\sum_i (d_i - \bar{d})^2}{n-1}} = 5.67$$

Campioni dipendenti: soluzione

La partecipazione al workshop ha prodotto un cambiamento nel numero di reclami (ad $\alpha = 0.01$)?

$$\begin{cases} H_0 : \mu_X - \mu_Y = 0 \\ H_1 : \mu_X - \mu_Y \neq 0 \end{cases}$$


$$\alpha = .01 \quad \bar{d} = -4.2$$

$$\text{Valore Critico} = \pm 4.604$$

$$\text{g.d.l.} = n - 1 = 4$$

Statistica Test:

$$t_0 = \frac{\bar{d} - d_0}{s_d / \sqrt{n}} = \frac{-4.2 - 0}{5.67 / \sqrt{5}} = -1.66$$



Decisione: non rifiutare H_0
(la statistica T non è nella regione di rifiuto)

Conclusione: Non c'è un cambiamento significativo nel numero di reclami.

Differenza tra due medie (campioni indipendenti)

Medie delle popolazioni, campioni indipendenti

Obiettivo: Sottoporre a test un'ipotesi riguardante la differenza fra le medie di due popolazioni, es.

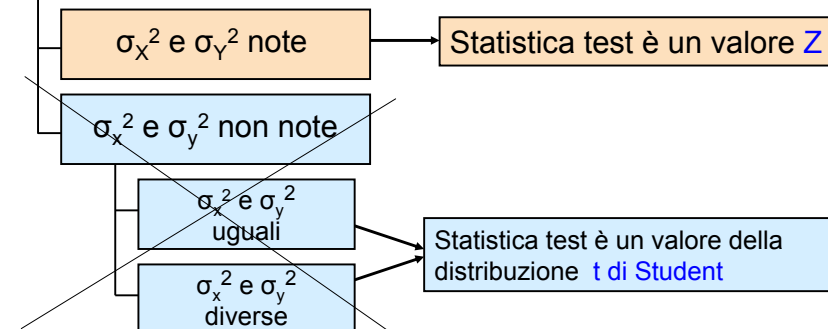
$$H_0: \mu_X - \mu_Y = d_0$$

	Popolazione 1	Popolazione 2
Media popolazione	μ_X	μ_Y
Dev. Std. popolazione	σ_X	σ_Y
Ampiezza campione	n_X	n_Y

Campioni indipendenti: i valori di un campione non influenzano i valori dell'altro \rightarrow si hanno $n_X + n_Y$ variabili aleatorie mutuamente indipendenti

Differenza tra due medie (campioni indipendenti)

Medie delle popolazioni, campioni indipendenti



Differenza tra due medie (campioni indipendenti)

Medie delle popolazioni, campioni indipendenti

σ_X^2 e σ_Y^2 note *

σ_X^2 e σ_Y^2 non note

Assunzioni:

1. Due campioni casuali indipendenti (in generale i due campioni hanno dimensione diversa, ma possono anche avere identica dimensione)
2. Entrambe le popolazioni hanno distribuzione Normale
3. Le varianze delle popolazioni sono note a priori

Quando entrambi i campioni sono grandi (diciamo >50) il test è approssimativamente valido anche senza le assunzioni 2 e 3

E' molto raro che le entrambe le varianze siano note a priori, per cui in pratica questo test è utile nelle situazioni in cui si dispone di grandi campioni

Differenza tra due medie (campioni indipendenti e grandi)

- Se i due campioni sono indipendenti e σ_X^2 e σ_Y^2 sono note, la varianza della differenza è

$$\sigma_{\bar{X}-\bar{Y}}^2 = \frac{\sigma_X^2}{n_X} + \frac{\sigma_Y^2}{n_Y}$$

- Se entrambe le popolazioni sono Normali, la variabile aleatoria

$$Z = \frac{(\bar{X} - \bar{Y}) - (\mu_X - \mu_Y)}{\sqrt{\frac{\sigma_X^2}{n_X} + \frac{\sigma_Y^2}{n_Y}}}$$

ha distribuzione Normale standard

Differenza tra due medie (campioni indipendenti e grandi)

La statistica test per $\mu_X - \mu_Y$ è:

$$Z_0 = \frac{(\bar{X} - \bar{Y}) - d_0}{\sqrt{\frac{\sigma_X^2}{n_X} + \frac{\sigma_Y^2}{n_Y}}} \stackrel{H_0}{\sim} N(0,1)$$

d_0 = differenza ipotizzata, es. $H_0: \mu_X - \mu_Y = d_0$ o $H_0: \mu_X - \mu_Y \geq d_0$

Quando le varianze NON sono note a priori vanno sostituite con le varianze campionarie: se entrambi i campioni sono grandi la statistica test ha ancora, con buona approssimazione, una distribuzione Normale standard

Differenza tra due medie (campioni indipendenti e grandi)

Campioni indipendenti: test per verificare se la differenza è nulla ($d_0 = 0$)

$$\begin{cases} H_0: \mu_X - \mu_Y \geq 0 \\ H_1: \mu_X - \mu_Y < 0 \end{cases}$$


(test coda sinistra)

$$\begin{cases} H_0: \mu_X - \mu_Y \leq 0 \\ H_1: \mu_X - \mu_Y > 0 \end{cases}$$


(test coda destra)

$$\begin{cases} H_0: \mu_X - \mu_Y = 0 \\ H_1: \mu_X - \mu_Y \neq 0 \end{cases}$$


(test bidirezionale)



Rifiutare H_0 se $z_0 < -z_\alpha$



Rifiutare H_0 se $z_0 > z_\alpha$



Rifiutare H_0 se $z_0 < -z_{\alpha/2}$
o $z_0 > z_{\alpha/2}$

Campioni indipendenti: esempio

- Il direttore di una catena di negozi riceve lamentele sui tempi di consegna del negozio X; a tal fine decide di effettuare un confronto con i tempi di consegna del negozio Y per appurare se vi è abbastanza evidenza empirica per affermare che X ha tempi più lunghi di Y

$$\begin{cases} H_0 : \mu_X - \mu_Y \leq 0 \\ H_1 : \mu_X - \mu_Y > 0 \end{cases}$$

- I dati sono due campioni casuali di tempi di consegna, espressi in giorni lavorativi

	Negozi X	Negozi Y
Ampiezza campione	80	60
Media campionaria	12.56	9.41
Varianza campionaria	5.22	2.87

Campioni indipendenti: soluzione

- I campioni sono indipendenti ed entrambi grandi → anche senza specificare la distribuzione di X e Y e anche se le varianze non sono note a priori si può usare la statistica test z_0 per campioni indipendenti

$$z_0 = \frac{(12.56 - 9.41) - 0}{\sqrt{\frac{5.22}{80} + \frac{2.87}{60}}} = 9.3672$$

- Al livello di significatività dell'1% la regione di rifiuto è a destra con $z_\alpha = 2.33$
- Poiché $9.37 > 2.33$ si rifiuta l'ipotesi nulla:** i tempi di consegna del negozio X sono significativamente maggiori di quelli del negozio Y

Intervalli di confidenza e test delle ipotesi

- Il **test delle ipotesi** ha la forma

$$statistica\ test = \frac{statistica - parametro}{dev.std. (statistica)}$$

- L'**intervallo di confidenza** ha la forma:

$$statistica \pm valore\ critico * dev.std. (statistica)$$