

# Statistica I corso A-E

Lezione XXXII

**Statistica Inferenziale**

**Prova d'ipotesi**

Noi utilizzeremo nel calcolo degli intervalli di confidenza e nelle prove di ipotesi le seguenti statistiche test

$$Z_n = \frac{\bar{X}_n - \mu}{\frac{\sigma}{\sqrt{n}}} \sim N(0,1) \quad \sigma \text{ è nota}$$

← statistica Z

$$t_{n-1} = \frac{\bar{X}_n - \mu}{\frac{S}{\sqrt{n}}} \sim t\text{-Student}$$

S deviazione campionaria  
 $S^2 = \text{Varianza campionaria}$

$$\chi^2_{n-1} = \frac{(n-1)S^2}{\sigma^2} \text{ - Chi quadro}$$

# Cos'è un'ipotesi?

- Un'ipotesi è una affermazione (assunzione) circa il parametro della popolazione:



- media della popolazione

**Esempio: In questa città, il costo medio della bolletta mensile per il cellulare è  $\mu = \$42$**

- proporzione della popolazione

**Esempio: In questa città, la proporzione di adulti con il cellulare è  $p = .68$**

# L'ipotesi Nulla, $H_0$


- Rappresenta l'ipotesi (numerica) che deve essere verificata

**Esempio:** Il numero medio di TV nelle case americane è uguale a tre ( $H_0 : \mu = 3$ )

- Si riferisce sempre al parametro della popolazione, non alla statistica campionaria

$$H_0 : \mu = 3$$

$$\cancel{H_0 : \bar{X} = 3}$$



# L'ipotesi Nulla, $H_0$

- Iniziamo con l'assunzione che l'ipotesi nulla sia vera
  - Simile alla nozione di innocenza a meno che venga dimostrata la colpevolezza
- **Si riferisce allo status quo**
- Contiene sempre “=”, “ $\leq$ ” o “ $\geq$ ”
- Può o può non essere rifiutata





# L'ipotesi Alternativa, $H_1$

- È l'opposto dell'ipotesi nulla
  - e.g., Il numero medio di TV nelle case americane non è uguale a 3 (  $H_1: \mu \neq 3$  )
- **Sfida lo status quo**
- Può o può non essere sostenuta
- È generalmente l'ipotesi che il ricercatore cerca di dimostrare contro lo status quo

# Processo della Verifica di Ipotesi

Affermazione: l'età  
media della  
popolazione è 60.  
(Ipotesi nulla:

$$H_0: \mu = 60)$$



Popolazione




Adesso selezioniamo un  
campione casuale

È  $\bar{x}_n = 35$  probabile se  $\mu = 60$ ?



Se non è probabile,

**RIFIUTA**

Ipotesi Nulla



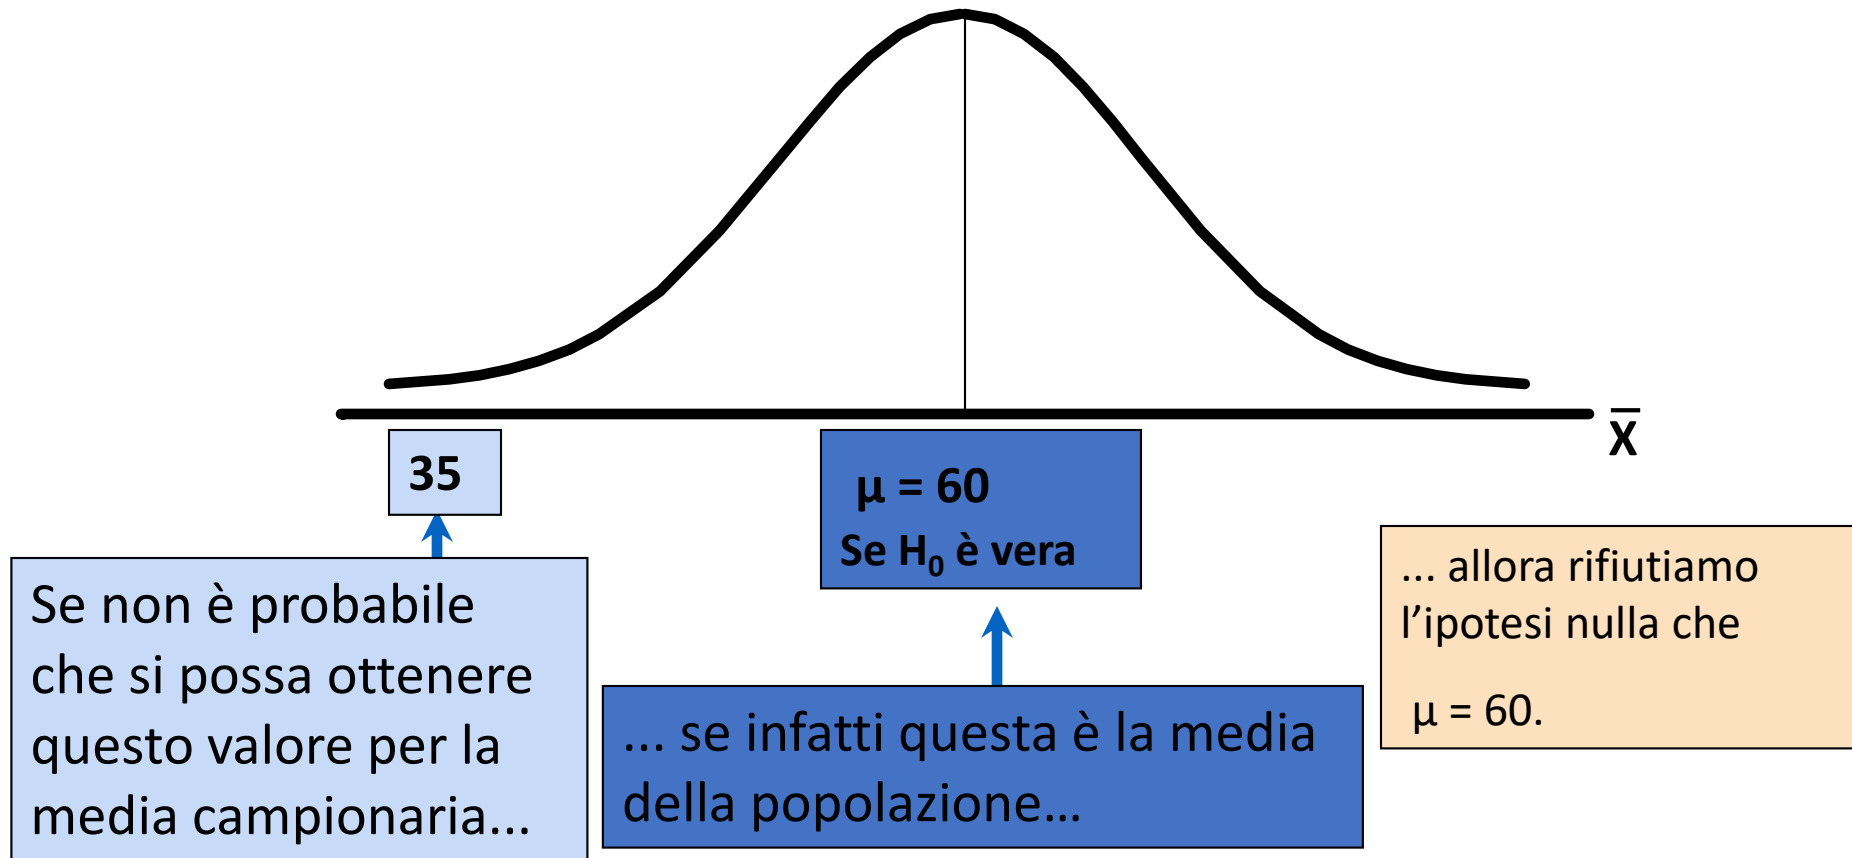
Supponiamo  
l'età media  
del campione  
sia 20:  $\bar{x}_n = 35$



Campione

# Motivazione per Rifiutare $H_0$

Distribuzione Campionaria di  $\bar{X}$





# Livello di Significatività e la Regione di Rifiuto


Livello di significatività =  $\alpha$

✦ **Representa i valori critici**

$$H_0: \mu = 3$$

$$H_1: \mu \neq 3$$

Test a due code




**Regione di rifiuto è ombreggiata**

$$H_0: \mu \leq 3$$

$$H_1: \mu > 3$$


Test coda destra



$$H_0: \mu \geq 3$$

$$H_1: \mu < 3$$

Test coda sinistra



# Livello di Significatività, $\alpha$

- **Definisce i valori della statistica campionaria che sono improbabili se l'ipotesi nulla è vera**
  - Definisce la **regione di rifiuto** della distribuzione campionaria
- È indicato con  **$\alpha$**  (livello di significatività)
  - Valori comuni sono 0.01, 0.05, or 0.10
- Fissato a priori dal ricercatore
- Fornisce il **valore critico** del test

# Errori nel Processo Decisionale

- **Errore di Primo Tipo o prima specie**
  - Rifiutare un'ipotesi nulla quando quest'ultima è vera
  - **Considerato un tipo di errore molto serio**

La probabilità dell'errore di prima specie è  $\alpha$

- $\alpha$  è anche detto **livello di significatività** del test
- $\alpha$  è scelto a priori dal ricercatore

# Errori nel Processo di Decisione

- **Errore di Secondo Tipo o seconda specie**

- Non rifiutare l'ipotesi nulla quando quest'ultima è falsa

La probabilità dell'errore di secondo tipo è  $\beta$

La quantità  $1 - \beta$  è detta **potenza del test**

**Il termine potenza del test è dovuto al fatto che**

$1 - \beta$  è la probabilità di rigettare l'ipotesi nulla quando questa non è vera

# Risultati e Probabilità

**Legenda:**  
**Risultato**  
**(Probabilità)**

## Possibili Risultati Verifica di Ipotesi

	Stato di Natura	
Decisione	$H_0$ Vera	$H_0$ Falsa
Non Rifiutare $H_0$	No errore ( $1 - \alpha$ )	Errore Secondo Tipo ( $\beta$ )
Rifiutare $H_0$	Errore Primo tipo ( $\alpha$ ) Livello di significatività del test	No Errore ( $1 - \beta$ ) Potenza del test

## Riassumendo:

**Errore di prima specie:** è l'errore che si commette rifiutando l'ipotesi nulla  $H_0$  quando  $H_0$  è vera.

Il **livello di significatività** è la probabilità di rifiutare  $H_0$  quando  $H_0$  è vera:

$$P(\text{rifiuto } H_0 \mid H_0) = \alpha \text{ (}\alpha \text{ è il livello di significatività);}$$

**Errore di seconda specie:** è l'errore che si commette non rifiutando l'ipotesi nulla quando questa non è vera.

$$P(\text{non rifiuto } H_0 \mid H_1) = \beta$$

La probabilità di commettere un errore di seconda specie si indica con  $\beta$ .

**N.B:** Come traduciamo in un evento l'affermazione « rifiuto  $H_0$  » e « non rifiuto  $H_0$  »? Cosa implica nella pratica «  $\mid H_0$  » (dato  $H_0$ ) oppure «  $\mid H_1$  » (dato  $H_1$ )?

**Domanda:** Come traduciamo in un evento l'affermazione « rifiuto  $H_0$  » e « *non rifiuto*  $H_0$  »? Cosa implica nella pratica «  $| H_0$  » (dato  $H_0$ ) oppure «  $| H_1$  » (dato  $H_1$ )? Supponiamo che  $H_0$  sia  $\theta = \theta_0$  e  $H_1$  sia  $\theta = \theta_1$

- Errore di prima specie: rifiutare  $H_0$  quando  $H_0$  è vera  $P(\text{rifiutare } H_0 | H_0) = \alpha$  (livello di significatività)
- Errore di seconda specie: non rifiutare  $H_0$  quando  $H_0$  non è vera  $P(\text{non rifiutare } H_0 | H_1) = \beta$

La prova di ipotesi ha come obiettivo minimizzare entrambi gli errori. Il test che minimizza  $\alpha$  (alfa) e  $\beta$  (beta) fu formulato da **Neyman e Pearson** come segue: la regione di rifiuto deve avere la forma:

$$R : \frac{L(\theta_0)}{L(\theta_1)} < k$$

La costante  $k$  è scelta in modo che la probabilità che il rapporto tra la funzione di verosimiglianza calcolata in  $\theta_0$  (teta zero) e la funzione di verosimiglianza calcolata in  $\theta_1$  (teta uno) minore sia uguale al livello di significatività  $\alpha$  (alfa):  $P\left(\frac{L(\theta_0)}{L(\theta_1)} < k \mid H_0\right) = \alpha$

Oss: Ricordiamo che la funzione di verosimiglianza è la probabilità congiunta di osservare le osservazioni del campione fissato il parametro. Se  **$H_0$**  vera dovrei avere  **$L(\theta_0)$  maggiore di  $L(\theta_1)$**

## Come applicare la regola di decisione in pratica? Prova di ipotesi della media di una popolazione normale quando la varianza è nota

**Il test di Neyman-Pearson** nel caso di prova di ipotesi per la media di una popolazione normale,  $X \sim N(\mu, \sigma^2)$ ,

permette di dimostrare che la regione di rifiuto è una disequaglianza sulla media campionaria.

Esempio Regione Rifiuto:  $\bar{X}_n < x_c$  oppure,  $\bar{X}_n > x_c$ , oppure  $\bar{X}_n < x_L$  V  $\bar{X}_n > x_U$ , dove  $x_c$  è detto **valore critico** e così pure  $x_L$  e  $x_U$

Supponiamo che **la varianza sia nota** mentre la media sia incognita.

$$H_0 \text{ ---} > \mu = \mu_0$$

$$H_1 \text{ ---} > \mu = \mu_1$$

In generale si fissa un livello di significatività “ $\alpha$ ” e si cerca di capire come è fatta la regione di rifiuto. Il tipo di disequaglianza della regione di rifiuto dipende dal tipo di disequaglianza tra le due ipotesi



# PRIMO CASO: TEST UNILATERALE DESTRO

Immaginiamo ora che  $\mu_0 < \mu_1$ , quindi di questo tipo:


La regione di rifiuto si ha quando la media campionaria è maggiore di un certo valore  $x_c$ .

$$R: \bar{X}_n > x_c \text{ chi è}$$

La zona di rifiuto si trova nella parte che contiene l'ipotesi alternativa ovvero quando vado a finire troppo a destra di  $\mu_0$ . **Osserviamo che la regione di rifiuto deve contenere l'ipotesi alternativa.**

**Oss:**  $x_c$  è fissato e una volta fissato rifiuteremo l'ipotesi nulla se il valore osservato della media campionaria cade nella zona di rifiuto.

Il valore critico  $x_c$  viene fissato in base al livello di significatività  $\alpha$ .




la zona di rifiuto è quella rossa ed è nella direzione dove si trova l'ipotesi alternativa

## COME CALCOLIAMO IL VALORE CRITICO?

$$R: \bar{X}_n > x_c$$

Il valore critico  $x_c$  deve essere determinato in modo che:

$$P(R|H_0) = P(\bar{X}_n > x_c | H_0) = \alpha$$



Sappiamo che la media campionaria è una normale quindi possiamo standardizzarla ma rispetto a quale media della popolazione? Dobbiamo usare

$\mu = \mu_0$  (ipotesi  $H_0$ ) oppure  $\mu = \mu_1$  (ipotesi  $H_1$ )? La probabilità da calcolare è condizionata alla ipotesi nulla « $| H_0$ » cioè dobbiamo assumere che l'ipotesi nulla sia vera quindi la media di  $\bar{X}_n$  è  $\mu_0$ . Avremo dunque  $\bar{X}_n \sim N(\mu_0, \frac{\sigma^2}{n})$ .

Usiamo la statistica Z:  $Z_n = \frac{\bar{X}_n - \mu_0}{\frac{\sigma}{\sqrt{n}}} \sim N(0,1)$ .

Procedura: dato il livello di significatività  $\alpha$  troviamo il valore critico della statistica Z  $z_c$  che soddisfa  $P(Z_n > z_c) = \alpha$ . Dal disegno si comprende che  $z_c = z_{1-\alpha}$  quindi troviamo il valore critico  $x_c$  risolvendo  $\frac{x_c - \mu_0}{\frac{\sigma}{\sqrt{n}}} = z_{1-\alpha}$  cioè  $x_c = \mu_0 + \frac{\sigma}{\sqrt{n}} z_{1-\alpha}$


$$P(\bar{X}_n > x_c | H_0) = \alpha$$

devo trovare  $x_c$ ?  
dato  $\alpha$

$$\alpha = P(\bar{X}_n > x_c | H_0) = P\left(\frac{\bar{X}_n - \mu_0}{\sigma/\sqrt{n}} > z_c\right) = \alpha$$

dato  $\alpha$  trovo  $z_c = z_{1-\alpha}$  usando  
le tabelle

$$Z \sim N(0,1)$$



$$R: \bar{X}_n > \mu_0 + \frac{\sigma}{\sqrt{n}} z_{1-\alpha}$$

$$\frac{x_c - \mu_0}{\frac{\sigma}{\sqrt{n}}} = z_{1-\alpha}$$
$$x_c - \mu_0 = \frac{\sigma}{\sqrt{n}} z_{1-\alpha}$$
$$x_c = \mu_0 + \frac{\sigma}{\sqrt{n}} z_{1-\alpha}$$

# Come determino la potenza del test dato $x_c$ ?

La **potenza del test** è  $1 - \beta$  dove  $\beta$  è la probabilità dell'errore di seconda specie

$$P(\text{non rifiuto } H_0 | H_1) = \beta$$

Nel caso di TEST UNILATERALE DESTRO la **regione di rifiuto** è  $\bar{X}_n > x_c$  mentre quella di accettazione (non rifiuto) è  $\bar{X}_n \leq x_c$

$$P(\text{non rifiuto } H_0 | H_1) = \beta = P(\bar{X}_n \leq x_c | H_1) = P(Z \leq z_q) = P(Z \leq z_\beta) = F(z_\beta)$$

$$1 - \beta = P(\bar{X}_n > x_c | H_1) = P(Z > z_q)$$

Dove il valore critico di Z è calcolato supponendo che la media sia  $z_q = \frac{x_c - \mu_1}{\frac{\sigma}{\sqrt{n}}}$

ATTENZIONE il pedice di  $z_q$  è  $\beta$  perché  $\beta$  è l'area lasciata alla sinistra di  $z_q$

## Esercizio 6

Da una popolazione distribuita in modo normale avente media ( $\mu$ ) incognita e varianza  $\sigma^2=16$  viene estratto un campione casuale di  $n=64$  elementi. Date le seguenti due ipotesi:

$$H_0 : \mu=20$$

$$H_1 : \mu = 22$$

a) Definire la probabilità di commettere un errore di prima specie e quindi determinare il punto critico e la regione di rifiuto per l'ipotesi nulla al livello di significatività  $\alpha=0.05$ ;

b) Definire la potenza del test e quindi calcolarne il valore nella situazione considerata.

(Si tenga conto che alcuni quantili della distribuzione Normale standardizzata  $Z$  sono i seguenti:  $z_{0.0091} = -2.36$ ,  $z_{0.950} = 1.640$ ,  $z_{0.965} = 1.812$ ,  $z_{0.975} = 1.96$ ,  $z_{0.985} = 2.17$ ,  $z_{0.99} = 2.326$ ,  $z_{0.995} = 2.576$ ).

**Dati problema**  $n = 64$  campione casuale iid


$$X \sim N(\mu, \sigma^2) \quad \sigma^2 = 16$$

**Ipotesi**

$$H_0 : \mu_0 = 20$$

$$H_1 : \mu_1 = 22$$

$$\mu_1 > \mu_0$$



$$P(\text{RIFIUTARE } H_0 \mid H_0) = \alpha$$

PROBABILITÀ DI RIFIUTARE  $H_0$  QUANDO È VERA.

$$\mu_1 > \mu_0$$

$$\sigma^2 = 16 \quad \sigma = 4$$


$$n = 64$$

$$\mu_0 = 20$$

$$\mu_1 = 22$$


$$R: \bar{X}_m > X_c$$

$$P(\bar{X}_m > X_c) = \alpha = 0,05$$



NORMALIZZAZIONE

$$\frac{X_c - \mu_0}{\frac{\sigma}{\sqrt{n}}} = z_{1-\alpha}$$



$$\frac{X_c - \mu_0}{\frac{\sigma}{\sqrt{n}}} = \frac{X_c - 20}{\frac{4}{8}} = z_{0,95}$$

$$\text{'' } 1,64$$

$$X_c = 1,64 \cdot \frac{1}{2} + 20 = 20,22$$

$$R: \bar{X}_n > 20,22$$

La probabilità di commettere un errore di prima specie è la probabilità di rifiutare

$H_0$  quando  $H_0$  è vero

$$P(\text{Rifiutare } H_0 \mid H_0) = \alpha$$

La potenza del test è la  
 $H_0$  quando  $H_0$  è falsa

probabilità di rifiutare

$$P(\text{Rifiuto } H_0 \mid H_1) = 1 - \beta$$

Modo alternativo la potenza del Test è  $1 - \beta$  dove  $\beta$  è la probabilità dell'errore di 2° specie ovvero la possibilità di non rifiutare  $H_0$  quando  $H_0$  è falsa

$$\beta = P(\text{Non rifiuto } H_0 \mid H_1)$$



$$x_c = 20,22$$

$$\beta = P(\bar{X}_n \leq x_c | H_1) = P(Z \leq z_q) = P(Z \leq z_\beta) = F(z_q)$$

$$z_q = \frac{x_c - \mu_1}{\sigma/\sqrt{n}} = \frac{20,22 - 22}{4/8} = -2.36$$

L'esercizio fornisce  $z_{0.0091} = -2.36 \rightarrow \beta = 0.0091 \rightarrow$


$$\text{Potenza test} = 1 - \beta = 1 - 0.0091 = 0.9909$$

$$1 - \beta = P(\text{RIFIUTARE } H_0 | H_1) = P(\bar{X}_n > 20,22 | H_1) = P(Z > \bar{z})$$

$$\bar{z} = \frac{20,22 - \mu_1}{\frac{\sigma}{\sqrt{n}}} = \frac{20,22 - 22}{\frac{4}{8}} = -2,36$$

$\downarrow$   
 $z_{0,0091} = -2,36$

$$P(Z > z_{0,0091}) = 1 - \beta = 1 - 0,0091 = 0,9909$$



# Secondo CASO: TEST UNILATERALE SINISTRO

Immaginiamo ora che  $\mu_0 > \mu_1$ , quindi di questo tipo:


La regione di rifiuto si ha quando la media campionaria è minore di un certo valore  $X_c$ .

$$R: \bar{X}_n < x_c$$

La zona di rifiuto si trova nella parte che contiene l'ipotesi alternativa ovvero quando vado a finire troppo a sinistra di  $\mu_0$ . Osserviamo che la regione di rifiuto deve dalla parte dell'ipotesi alternativa.

Oss:  $x_c$  è fissato e una volta fissato rifiuteremo l'ipotesi nulla se il valore osservato della media campionaria cade nella zona di rifiuto.

Il valore critico  $x_c$  viene fissato in base al livello di significatività  $\alpha$ .



$$R: \bar{X}_n < x_c$$


$$P(\bar{X}_n < x_c | H_0) = P(Z < z_c) = \alpha$$

$$z_c = \frac{x_c - \mu_0}{\frac{\sigma}{\sqrt{n}}}$$

come determino lo z critico?



Nel caso di Test Parametrico Simmetrico



Dunque lo  $Z_c$  è proprio il quantile di ordine  $\alpha$

$$X_c = \mu_0 + \frac{\sigma}{\sqrt{n}} Z_\alpha$$

$$Z_\alpha = -Z_{1-\alpha}$$

$$Z_\alpha = \frac{X_c - \mu_0}{\frac{\sigma}{\sqrt{n}}}$$

$$X_c = \mu_0 - \frac{\sigma}{\sqrt{n}} Z_{1-\alpha}$$


# Secondo CASO: TEST UNILATERALE SINISTRO potenza del test

Ricordiamo  $\mu_0 > \mu_1$ , quindi la zona di rifiuto è  $R: \bar{X}_n < x_c$


Potenza del test

$$1 - \beta = P(\text{Rifiuto } H_0 \mid H_1) = P(\bar{X}_n < x_c \mid H_1) = P(Z < z_q) = P(Z < z_{1-\beta})$$

$$z_q = z_{1-\beta} = \frac{x_c - \mu_1}{\frac{\sigma}{\sqrt{n}}}$$



# Secondo CASO: TEST UNILATERALE SINISTRO




$$\mu_0 > \mu_1$$
$$R: \bar{X}_n < x_c$$

La zona di rifiuto si trova nella parte che contiene l'ipotesi alternativa ovvero quando vado a finire troppo a sinistra di  $\mu_0$

Il valore critico  $x_c$  viene fissato in base al livello di significatività  $\alpha$  usando la statistica Z.

$$P(\bar{X}_n < x_c | H_0) = P(Z < z_c) = \alpha$$

$$z_c = \frac{x_c - \mu_0}{\frac{\sigma}{\sqrt{n}}} = -z_{1-\alpha}$$




**NOTA BENE:**  $-z_{1-\alpha}$


Esercizio 6 Sostituendo le ipotesi

$$\mu_0 = 22$$

$$\mu_1 = 20$$



1) Determinare la legge di rifiuto a livello di significatività  $\alpha = 0,05$



$$R: \bar{X}_n < x_c$$

$$z_c = z_{0,05} = -z_{1-0,05} = -z_{0,95}$$

$$z_c = -1.64$$

$$\frac{X_C - \mu_0}{\frac{\sigma}{\sqrt{n}}} = Z_C \quad \begin{matrix} \mu_0 = 22 \\ \sigma = \sqrt{16} \\ n = 64 \end{matrix} \quad \frac{X_C - 22}{\frac{4}{8}} = -1,64$$

$$X_C = 22 - 1,64 \cdot \frac{1}{2} = 22 - 0,82 = 21,18$$

Potencia del test

$$1 - \beta = 1 - 0,0091$$



$$Z_\alpha = \frac{X_C - \mu_1}{\frac{\sigma}{\sqrt{n}}} = \frac{21,18 - 20}{\frac{4}{8}} = 1,18 \cdot 2 = 2,36$$



$$Z_{0,0091} = -2,36$$

$$2,36 = Z_{1-0,0091}$$

# TERZO CASO: TEST BILATERALE

Ipotesi  $H_0 \mu = \mu_0$   $H_1 \mu \neq \mu_0$

La regione di rifiuto si ha quando la media campionaria è maggiore di un certo valore  $x_U$  e minore di un certo valore  $x_L$



$$R: \bar{X}_n < x_L \quad \vee \quad \bar{X}_n > x_U$$

I valori critici  $x_L$  e  $x_U$  sono fissati in base al livello di significatività  $\alpha$ .

$$P(\bar{X}_n < x_L \vee \bar{X}_n > x_U) = \alpha \quad P(Z_n < -z_c \vee Z_n > z_c) = \alpha$$

$$z_c = z_{1-\frac{\alpha}{2}} \quad \frac{x_L - \mu_0}{\frac{\sigma}{\sqrt{n}}} = -z_c = -z_{1-\frac{\alpha}{2}}$$

$$\frac{x_U - \mu_0}{\frac{\sigma}{\sqrt{n}}} = z_c = z_{1-\frac{\alpha}{2}}$$