

# METODI STATISTICI PER LA RICERCA SOCIALE

## CAPITOLO 7. CONFRONTO TRA DUE GRUPPI

Alessandra Mattei

Dipartimento di Statistica, Informatica, Applicazioni (DiSIA)  
Università degli Studi di Firenze  
mattei@disia.unifi.it

LM-88 SOCIOLOGIA E RICERCA SOCIALE

## Confronto tra due gruppi

- Soggetti cardiopatici trattati con bypass sopravvivono più a lungo di soggetti cardiopatici non trattati con bypass?
- Passano più tempo su internet gli uomini o le donne?
- I laureati guadagnano più dei diplomati?
- Un intervento di microcredito migliora il benessere economico di famiglie che vivono in condizioni di povertà?
- Un corso di formazione professionale aiuta l'inserimento nel mondo del lavoro di giovani svantaggiati?
- Le performance di studenti con lacune in matematica migliorano dopo un corso di recupero?

## Confronto tra due gruppi: Confrontare due (sotto-)popolazioni

- Obiettivo: Stabilire se due popolazioni sono uguali (o diverse)
- Confronto tra due campioni: I due campioni provengono dalla stessa popolazione ossia da popolazioni aventi un parametro caratteristico di uguale valore?
- Esiste evidenza (*significatività statistica*) che le osservazioni campionarie siano generati da due popolazioni diverse?

# Variabili esplicative e variabili risposta

- Le sotto-popolazioni sono in genere definite da una variabile che prende il nome di *variabile esplicativa*
  
- La variabile che interessa confrontare prende il nome di *variabile risposta*

# Variabili esplicative e variabili risposta: Esempi

- Un intervento di microcredito migliora il benessere economico di famiglie che vivono in condizioni di povertà?
  - ✓ Variabile Esplicativa = Microcredito (Popolazione delle famiglie che hanno accesso a un microcredito *versus* Popolazione delle famiglie che non hanno accesso a un microcredito)
  - ✓ Variabile risposta = Indicatore di benessere economico della famiglia (La famiglia vive al di sopra o al di sotto della soglia di povertà)
- Un corso di formazione professionale aiuta l'inserimento nel mondo del lavoro di giovani svantaggiati?
  - ✓ Variabile Esplicativa = Frequenza del corso di formazione (Popolazione di giovani svantaggiati che frequentano il corso di formazione *versus* Popolazione di giovani svantaggiati che non frequentano il corso di formazione)
  - ✓ Variabile risposta = Status occupazionale a sei mesi dalla fine del corso di formazione
- Esempio: Le performance di studenti con lacune in matematica migliorano dopo un corso di recupero?
  - ✓ Variabile Esplicativa = "Tempo: Prima *versus* dopo" (Popolazione di studenti con lacune in matematica prima del corso di recupero *versus* Popolazione di studenti con lacune in matematica prima del dopo il corso di recupero )
  - ✓ Variabile risposta = Punteggio a un test di matematica

# Campioni dipendenti e indipendenti

- Confronto tra popolazioni indipendenti: le unità appartenenti a una popolazione sono indipendenti dalle unità appartenenti all'altra popolazione
- I soggetti nelle due popolazioni sono diversi e non esiste alcuna forma di "appaiamento" tra i due gruppi
- Campioni indipendenti: Campioni selezionati in modo indipendente da popolazioni indipendenti
- Popolazioni dipendenti: Esiste una relazione ("accoppiamento") naturale tra ciascuna unità di una popolazione e ciascuna unità dell'altra popolazione
- Campioni dipendenti: Campioni selezionati da popolazioni dipendenti
- Studi longitudinali, Misure ripetute, Dati appaiati: Coppie di osservazioni relative a una stessa unità statistica
- Esempi di popolazioni dipendenti
  - ✓ Punteggio a un test di matematica di uno stesso studente con lacune in matematica prima e dopo il corso di recupero
  - ✓ Il volume delle vendite di una stessa azienda prima e dopo una specifica campagna pubblicitaria
  - ✓ La stessa unità sperimentale prima delle cure e dopo la cura

# Confronto tra gruppi: Schema

- Confronto tra medie di variabili quantitative
  - ✓ Popolazioni:  $Y_1$  con media  $\mathbb{E}[Y_1] = \mu_1$ ;  $Y_2$  con media  $\mathbb{E}[Y_2] = \mu_2$
  - ✓ Parametro di interesse  $\mu_D \equiv \mu_2 - \mu_1$
  - ✓ Obiettivo: Fare inferenza sulla differenza tra le medie  
 $\mu_D = \mu_2 - \mu_1$
- Confronto tra proporzioni (medie di variabili binarie)
  - ✓ Popolazioni:  $Y_1 \sim Ber(\pi_1)$  versus  $Y_2 \sim Ber(\pi_2)$
  - ✓ Parametro di interesse  $\pi_D \equiv \pi_2 - \pi_1$
  - ✓ Obiettivo: Fare inferenza sulla differenza tra le proporzioni  
 $\pi_D = \pi_2 - \pi_1$

# Confronto tra medie di variabili quantitative

- Variabile di interesse:  $Y$  (variabile quantitativa)
- Popolazioni:  $Y_1$  con media  $\mathbb{E}[Y_1] = \mu_1$ ;  $Y_2$  con media  $\mathbb{E}[Y_2] = \mu_2$
- Parametro di interesse  $\mu_D \equiv \mu_2 - \mu_1$
- Obiettivo: Fare inferenza sulla differenza tra le medie  $\mu_D = \mu_2 - \mu_1$
- Situazioni:
  1. Popolazioni Normali indipendenti con varianze note
  2. Popolazioni Normali indipendenti con varianze ignote ma uguali
  3. Popolazioni Normali indipendenti con varianze ignote
  4. Popolazioni qualsiasi indipendenti e campioni di grandi dimensioni
  5. Popolazioni Normali dipendenti

## Confronto tra medie: Popolazioni Normali indipendenti

- Popolazioni:  $Y_1 \sim N(\mu_1, \sigma_1^2)$  versus  $Y_2 \sim N(\mu_2, \sigma_2^2)$  indipendenti
- Campioni casuali indipendenti:

$(Y_{11}, \dots, Y_{n_1})$  *i.i.d.*  $(Y_{12}, \dots, Y_{n_2})$  *i.i.d.* indipendenti

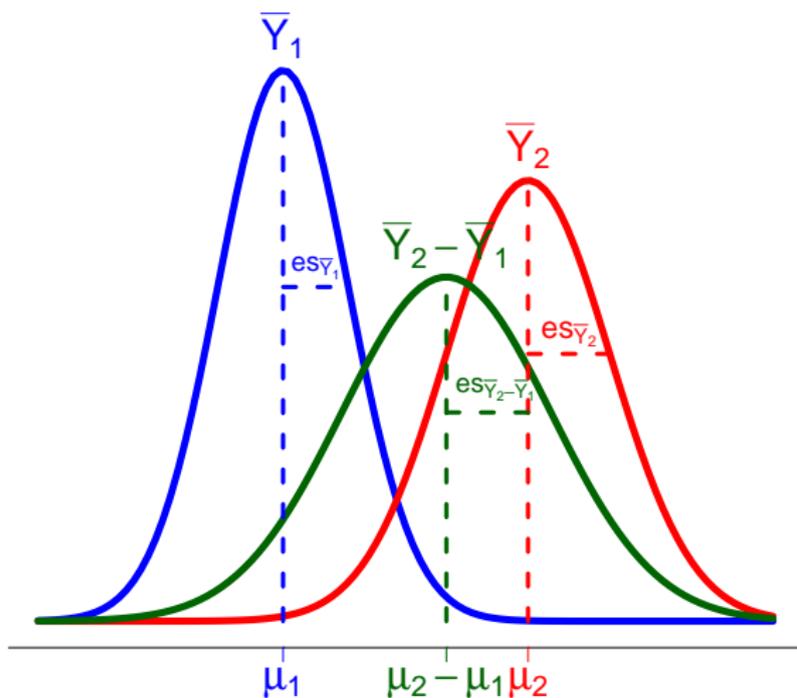
- Medie campionarie:  $\bar{Y}_1 = \frac{1}{n_1} \sum_{i=1}^{n_1} Y_{i1}$  e  $\bar{Y}_2 = \frac{1}{n_2} \sum_{i=1}^{n_2} Y_{i2}$
- Stimatore per la differenza tra medie:  $\bar{Y}_D = \bar{Y}_2 - \bar{Y}_1$
- Distribuzioni campionarie

$$\bar{Y}_1 \sim N\left(\mu_1, \frac{\sigma_1^2}{n_1}\right) \quad \text{e} \quad \bar{Y}_2 \sim N\left(\mu_2, \frac{\sigma_2^2}{n_2}\right)$$

Sotto l'ipotesi di indipendenza

$$\bar{Y}_2 - \bar{Y}_1 \sim N\left(\mu_2 - \mu_1, \frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}\right) \iff \bar{Y}_D \sim N\left(\mu_D, \frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}\right)$$

## Confronto tra medie: Popolazioni Normali indipendenti



# Confronto tra medie: Popolazioni Normali indipendenti

- Utilizzando la distribuzione campionaria della differenza tra le medie campionarie si possono costruire intervalli di confidenza e eseguire test delle ipotesi per la differenza tra medie
- Obiettivo: Valutare se  $\mu_1 = \mu_2 \iff \mu_2 - \mu_1 = \mu_1 - \mu_2 = 0$
- Intervalli di confidenza:

Stima puntuale  $\pm$  Margine di errore

- Ipotesi

$$\begin{array}{llll} H_0 : \mu_1 = \mu_2 & \text{vs} & H_a : \mu_2 \neq \mu_1 & \iff & H_0 : \mu_D = 0 & \text{vs} & H_a : \mu_D \neq 0 \\ H_0 : \mu_1 = \mu_2 & \text{vs} & H_a : \mu_2 > \mu_1 & \iff & H_0 : \mu_D = 0 & \text{vs} & H_a : \mu_D > 0 \\ H_0 : \mu_1 = \mu_2 & \text{vs} & H_a : \mu_2 < \mu_1 & \iff & H_0 : \mu_D = 0 & \text{vs} & H_a : \mu_D < 0 \end{array}$$

## Inferenza per la differenza tra le medie

### Popolazioni Normali indipendenti con varianze note

- Popolazioni:  $Y_1 \sim N(\mu_1, \sigma_1^2)$  versus  $Y_2 \sim N(\mu_2, \sigma_2^2)$  indipendenti,  $\sigma_1^2$  e  $\sigma_2^2$  note
- Campioni casuali indipendenti:

$(Y_{11}, \dots, Y_{n_1})$  *i.i.d.*  $(Y_{12}, \dots, Y_{n_2})$  *i.i.d.* indipendenti

- Stimatore della differenza tra le medie:  $\bar{Y}_2 - \bar{Y}_1$
- Errore standard dello stimatore della differenza tra le medie

$$es(\bar{Y}_2 - \bar{Y}_1) = \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}$$

- Distribuzione campionaria dello stimatore della differenza tra le medie

$$\bar{Y}_2 - \bar{Y}_1 \sim N\left(\mu_2 - \mu_1, \frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}\right) \text{ quindi } \frac{(\bar{Y}_2 - \bar{Y}_1) - (\mu_2 - \mu_1)}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} \sim N(0, 1)$$

## Intervallo di confidenza per la differenza tra le medie Popolazioni Normali indipendenti con varianze note

Intervallo di confidenza al livello di confidenza  $1 - \alpha$

$$IC_{1-\alpha}(\mu_2 - \mu_1) = \left[ (\bar{y}_2 - \bar{y}_1) - z_{\alpha/2} \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}; (\bar{y}_2 - \bar{y}_1) + z_{\alpha/2} \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}} \right]$$

## Intervallo di confidenza per la differenza tra le medie

### Popolazioni Normali indipendenti con varianze note: Esempio

- Obiettivo: Confrontare il peso medio (in grammi) di neonati nati da madri non fumatrici (popolazione 1) il peso medio (in grammi) di neonati nati da madri fumatrici (popolazione 2)
- Varianze note:  $\sigma_1^2 = \sigma_F^2 = 50850$  e  $\sigma_2^2 = \sigma_{\bar{F}}^2 = 60025$
- Sintesi dei dati campionari:

Madre fumatrice:	$n_F = 100$	$\bar{y}_F = 2150$
Madre non fumatrice:	$n_{\bar{F}} = 120$	$\bar{y}_{\bar{F}} = 3375$

- Differenza tra medie campionarie e suo errore standard

$$\bar{y}_2 - \bar{y}_1 = \bar{y}_F - \bar{y}_{\bar{F}} = -1225 \quad e \quad es(\bar{Y}_F - \bar{Y}_{\bar{F}}) = \sqrt{\frac{50850}{120} + \frac{60025}{100}} = 32$$

- Livello di confidenza:  $1 - \alpha = 0.95 \implies z_{\alpha/2} = 1.96$

- Intervallo di confidenza

$$IC_{1-\alpha}(\mu_F - \mu_{\bar{F}}) = [-1225 - 1.96 \cdot 32; -1225 + 1.96 \cdot 32] = [-1287.719; -1162.281]$$

- L'intervallo contiene solo valori negativi, quindi si ha evidenza al livello di confidenza del 95% che il peso medio di neonati da madri fumatrici sia inferiore al peso medio di neonati da madri non fumatrici

## Test per la differenza tra le medie

### Popolazioni Normali indipendenti con varianze note

- Popolazioni:  $Y_1 \sim N(\mu_1, \sigma_1^2)$  versus  $Y_2 \sim N(\mu_2, \sigma_2^2)$  indipendenti,  $\sigma_1^2$  e  $\sigma_2^2$  note
- Campioni casuali indipendenti:

$(Y_{11}, \dots, Y_{n_1})$  i.i.d.  $(Y_{12}, \dots, Y_{n_2})$  i.i.d. indipendenti

- Ipotesi nulla:  $H_0 : \mu_2 = \mu_1$  ossia  $H_0 : \mu_D = 0$
- Statistica test

$$\bar{Y}_2 - \bar{Y}_1 \quad \mapsto \quad Z = \frac{(\bar{Y}_2 - \bar{Y}_1) - 0}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}}$$

- Sotto l'ipotesi nulla

$$\bar{Y}_2 - \bar{Y}_1 \sim N\left(0, \frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}\right) \implies Z \sim N(0, 1)$$

## Test per la differenza tra le medie

### Popolazioni Normali indipendenti con varianze note

- Livello di significatività del test =  $\alpha$
- Regione Critica (Regione di Rifiuto)

Ipotesi alternativa	Regione di Rifiuto
$H_a : \mu_2 \neq \mu_1$	$Z \leq -z_{\alpha/2}$ oppure $Z \geq z_{\alpha/2}$
$H_a : \mu_2 > \mu_1$	$Z \geq z_{\alpha}$
$H_a : \mu_2 < \mu_1$	$Z \leq -z_{\alpha}$

- P-valore: Sia  $z^{oss}$  il valore osservato della statistica test  $Z$

Ipotesi alternativa	P-valore
$H_a : \mu_2 - \mu_1 \neq 0$	$P(Z < - z_{oss}  \text{ oppure } Z >  z_{oss} ; H_0)$ $= 2 \cdot (1 - P(Z \leq  z_{oss} ; H_0))$
$H_a : \mu_2 - \mu_1 > 0$	$P(Z \geq z_{oss}; H_0) = (1 - P(Z \leq z_{oss}; H_0))$
$H_a : \mu_2 - \mu_1 < 0$	$P(Z \leq z_{oss}; H_0)$

**Nota bene.** Il p-valore è calcolato usando la distribuzione Normale standard (la distribuzione campionaria di  $Z$  sotto  $H_0$ )

## Test per la differenza tra le medie

### Popolazioni Normali indipendenti con varianze note: Esempio I

- Obiettivo: Confrontare se il peso medio (in grammi) di neonati nati da madri non fumatrici (popolazione 1) è uguale al peso medio (in grammi) di neonati nati da madri fumatrici (popolazione 2)

$$H_0 : \mu_F = \mu_{\bar{F}} \quad \text{vs} \quad H_a : \mu_F \neq \mu_{\bar{F}} \iff H_0 : \mu_D = 0 \quad \text{vs} \quad H_a : \mu_D \neq 0$$

- Varianze note:  $\sigma_1^2 = \sigma_{\bar{F}}^2 = 50850$  e  $\sigma_2^2 = \sigma_{\bar{F}}^2 = 60025$
- Sintesi dei dati campionari:

Madre fumatrice:	$n_F = 100$	$\bar{y}_F = 2150$
Madre non fumatrice:	$n_{\bar{F}} = 120$	$\bar{y}_{\bar{F}} = 3375$

- Differenza tra medie campionarie e suo errore standard

$$\bar{y}_2 - \bar{y}_1 = \bar{y}_F - \bar{y}_{\bar{F}} = -1225 \quad \text{e} \quad \text{es}(\bar{Y}_F - \bar{Y}_{\bar{F}}) = \sqrt{\frac{50850}{120} + \frac{60025}{100}} = 32$$

- Livello di significatività del test:  $\alpha = 0.05$
- Regione Critica (Regione di Rifiuto):  $\alpha = 0.05 \implies \alpha/2 = 0.025 \implies z_{\alpha/2} = 1.96$   
Quindi

$$RC_{0.05} = Z \leq -1.96 \quad \text{oppure} \quad Z \geq 1.96$$

## Test per la differenza tra le medie

### Popolazioni Normali indipendenti con varianze note: Esempio I

- Valore osservato della statistica test

$$\begin{aligned} z_{oss} &= \frac{\bar{y}_F - \bar{y}_{\bar{F}}}{\sqrt{\frac{\sigma_F^2}{n_F} + \frac{\sigma_{\bar{F}}^2}{n_{\bar{F}}}}} = \frac{2150 - 3375}{\sqrt{\frac{50850}{120} + \frac{60025}{100}}} \\ &= \frac{-1225}{\sqrt{423.75 + 600.25}} = \frac{-1225}{\sqrt{1024}} = \frac{-1225}{32} = -38.28 \end{aligned}$$

- Decisione: Il valore osservato della statistica test appartiene alla regione di rifiuto:  $z_{oss} = -38.28 < -1.96 = -z_{0.025} \implies$  I dati mostrano evidenza contraria all'ipotesi nulla al livello di significatività del 5%
- P-valore

$$\begin{aligned} P &= 2 \cdot (1 - P(Z \leq |-38.28|; H_0)) = 2 \cdot (1 - P(Z \leq 38.28; H_0)) \\ &= 2 \cdot (1 - 1) = 0.000 \end{aligned}$$

## Test per la differenza tra le medie

### Popolazioni Normali indipendenti con varianze note: Esempio II

- Obiettivo: Valutare se un nuovo farmaco contro l'ipertensione riduce la pressione sanguigna
- Popolazione 1 = Soggetti ipertesi a cui è somministrato il farmaco standard
- Popolazione 2 = Soggetti ipertesi a cui è somministrato il nuovo farmaco

$$H_0 : \mu_2 = \mu_1 \quad \text{vs} \quad H_a : \mu_2 < \mu_1 \iff H_0 : \mu_D = 0 \quad \text{vs} \quad H_a : \mu_D < 0$$

- Varianze note:  $\sigma_1^2 = 420$  e  $\sigma_2^2 = 420$
- Campioni:

$u_{i1}$	1	2	3	4	5	6	7	8	9	10	11	12
$y_{i1}$	178	153	186	118	178	174	162	175	158	178	133	157

$u_{i2}$	1	2	3	4	5	6	7	8	9	10
$y_{i2}$	117	166	118	168	153	115	140	150	133	156

## Test per la differenza tra le medie

### Popolazioni Normali indipendenti con varianze note: Esempio II

- Livello di significatività del test:  $\alpha = 0.01$
- Regione Critica (Regione di Rifiuto):  $z_{0.01} = 2.33 \implies RC_{0.01} = Z \leq -2.33$
- Valore osservato della statistica test

$$\bar{y}_1 = \frac{1950}{12} = 162.5 \quad \bar{y}_2 = \frac{1416}{10} = 141.6$$

$$\begin{aligned} z_{oss} &= \frac{\bar{y}_2 - \bar{y}_1}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} = \frac{141.6 - 162.5}{\sqrt{\frac{420}{12} + \frac{420}{10}}} \\ &= \frac{20.9}{\sqrt{35 + 42}} = \frac{-20.9}{\sqrt{77}} = \frac{-20.9}{8.775} = -2.38 \end{aligned}$$

- Decisione: Il valore osservato della statistica test appartiene alla regione di rifiuto:  $z_{oss} = -2.38 < -2.33 = z_{0.01} \implies$  I dati mostrano evidenza contraria all'ipotesi nulla al livello di significatività del 1%
- P-valore:  $P = P(Z \leq -2.38; H_0) = 1 - P(Z \leq 2.38; H_0) = 1 - 0.9911385 = 0.008615$

## Inferenza per la differenza tra le medie

### Popolazioni Normali indipendenti con varianze ignote ma uguali

- Popolazioni:  $Y_1 \sim N(\mu_1, \sigma_1^2)$  versus  $Y_2 \sim N(\mu_2, \sigma_2^2)$  indipendenti,  $\sigma_1^2$  e  $\sigma_2^2$  ignote ma  $\sigma_1^2 = \sigma_2^2 \equiv \sigma^2$
- Campioni casuali indipendenti:

$(Y_{11}, \dots, Y_{m1})$  *i.i.d.*  $(Y_{12}, \dots, Y_{n2})$  *i.i.d.* indipendenti

- Stimatore della differenza tra le medie:  $\bar{Y}_2 - \bar{Y}_1$
- Errore standard dello stimatore della differenza tra le medie

$$es(\bar{Y}_2 - \bar{Y}_1) = \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}} = \sqrt{\frac{\sigma^2}{n_1} + \frac{\sigma^2}{n_2}} = \sqrt{\sigma^2 \left[ \frac{1}{n_1} + \frac{1}{n_2} \right]}$$

- Distribuzione campionaria dello stimatore della differenza tra le medie

$$\bar{Y}_2 - \bar{Y}_1 \sim N\left(\mu_2 - \mu_1, \sigma^2 \left[ \frac{1}{n_1} + \frac{1}{n_2} \right]\right) \text{ quindi } \frac{(\bar{Y}_2 - \bar{Y}_1) - (\mu_2 - \mu_1)}{\sqrt{\sigma^2 \left( \frac{1}{n_1} + \frac{1}{n_2} \right)}} \sim N(0, 1)$$

- Problema: la varianza  $\sigma^2$  non è nota

## Inferenza per la differenza tra le medie

### Popolazioni Normali indipendenti con varianze ignote ma uguali

- Stimatore congiunto (pooled) della varianza: Media ponderata degli stimatori corretti di  $\sigma_1^2$  e  $\sigma_2^2$  con pesi proporzionali alla dimensione dei due campioni

$$S_1^2 = \frac{1}{n_1 - 1} \sum_{i=1}^{n_1} (Y_{i1} - \bar{Y}_1)^2 \quad e \quad S_2^2 = \frac{1}{n_2 - 1} \sum_{i=1}^{n_2} (Y_{i2} - \bar{Y}_2)^2$$

Quindi

$$S_p^2 = \frac{(n_1 - 1)S_1^2 + (n_2 - 1)S_2^2}{n_1 + n_2 - 2}$$

- Statistica  $T$

$$T = \frac{(\bar{Y}_2 - \bar{Y}_1) - (\mu_2 - \mu_1)}{\sqrt{\frac{S_p^2}{n_1} + \frac{S_p^2}{n_2}}} = \frac{(\bar{Y}_2 - \bar{Y}_1) - (\mu_2 - \mu_1)}{\sqrt{S_p^2 \left( \frac{1}{n_1} + \frac{1}{n_2} \right)}} \sim t_{n_1 + n_2 - 2}$$

## Intervallo di confidenza per la differenza tra le medie

### Popolazioni Normali indipendenti con varianze ignote ma uguali

Intervallo di confidenza al livello di confidenza  $1 - \alpha$

$$IC_{1-\alpha}(\mu_2 - \mu_1) = \left[ (\bar{y}_2 - \bar{y}_1) - t_{(n_1+n_2-2),\alpha/2} \sqrt{s_p^2 \left( \frac{1}{n_1} + \frac{1}{n_2} \right)} \right. \\ \left. (\bar{y}_2 - \bar{y}_1) + t_{(n_1+n_2-2),\alpha/2} \sqrt{s_p^2 \left( \frac{1}{n_1} + \frac{1}{n_2} \right)} \right]$$

## Intervallo di confidenza per la differenza tra le medie

### Popolazioni Normali indipendenti con varianze ignote ma uguali: Esempio

- Obiettivo: Confrontare il voto medio alla fine del primo anno di studenti di istituti professionali in classi in cui si sono adottati metodi di insegnamento standard (popolazione 1) e in classi in cui si sono adottati metodi di interattivi (popolazione 2)

Metodo di insegnamento standard	Metodo di insegnamento interattivo
6.6	6.5
6.2	7.2
5.7	6.7
6.1	
5.4	

- Assunzione: Campioni estratti da popolazioni normali (indipendenti) di uguale varianza (incognita)
  - ✓ Ipotesi di normalità delle distribuzioni del voto medio
  - ✓ Ipotesi di uguale varianza (omoschedasticità) del voto medio nelle due popolazioni di classi

## Intervallo di confidenza per la differenza tra le medie

Popolazioni Normali indipendenti con varianze ignote ma uguali: Esempio

- Stima della differenza tra le medie

$$\bar{y}_2 - \bar{y}_1 = \frac{20.4}{3} - \frac{30}{5} = 6.8 - 6 = 0.8$$

- Stime delle varianze

$$s_1^2 = \frac{0.86}{5-1} = 0.215 \quad \text{e} \quad s_2^2 = \frac{0.26}{3-1} = 0.13$$

- Stima della varianza comune

$$s_p^2 = \frac{4 \cdot 0.215 + 2 \cdot 0.13}{5 + 3 - 2} = \frac{0.86 + 0.26}{6} = \frac{1.12}{6} = 0.187$$

- Stima dell'errore standard dello stimatore della differenza tra le medie

$$\hat{es}(\bar{Y}_2 - \bar{Y}_1) = \sqrt{0.187 \left( \frac{1}{5} + \frac{1}{3} \right)} = \sqrt{0.0996} = 0.3155$$

## Intervallo di confidenza per la differenza tra le medie

### Popolazioni Normali indipendenti con varianze ignote ma uguali: Esempio

- Livello di confidenza:  $1 - \alpha = 0.99$

$$\alpha = 0.01 \implies t_{0.005,6} = 3.707$$

- Intervallo di confidenza

$$\begin{aligned} IC_{0.99}(\mu_2 - \mu_1) &= \\ &= \left[ 0.8 - 3.707 \cdot \sqrt{0.187 \left( \frac{1}{5} + \frac{1}{3} \right)}; 0.8 + 3.707 \cdot \sqrt{0.187 \left( \frac{1}{5} + \frac{1}{3} \right)} \right] = \\ &= [0.8 - 3.707 \cdot 0.3155; 0.8 + 3.707 \cdot 0.3155] = \\ &= [-1.970; 0.370] \end{aligned}$$

- Si noti che l'intervallo di confidenza contiene il valore zero, non escludendo quindi la possibilità che le due medie siano uguali al livello di confidenza del 99%

## Test per la differenza tra le medie

### Popolazioni Normali indipendenti con varianze ignote ma uguali

- Popolazioni:  $Y_1 \sim N(\mu_1, \sigma_1^2)$  versus  $Y_2 \sim N(\mu_2, \sigma_2^2)$  indipendenti,  $\sigma_1^2$  e  $\sigma_2^2$  ignote ma  $\sigma_1^2 = \sigma_2^2 \equiv \sigma^2$
- Ipotesi nulla:  $H_0 : \mu_1 = \mu_2$  ossia  $H_0 : \mu_D = 0$
- Campioni:  $(Y_{11}, \dots, Y_{1n_1})$  *i.i.d.*  $(Y_{21}, \dots, Y_{2n_2})$  *i.i.d.* indipendenti
- Statistica test

$$\bar{Y}_2 - \bar{Y}_1 \quad \mapsto \quad T = \frac{(\bar{Y}_2 - \bar{Y}_1) - 0}{\sqrt{\frac{S_p^2}{n_1} + \frac{S_p^2}{n_2}}} = \frac{\bar{Y}_2 - \bar{Y}_1}{\sqrt{S_p^2 \left( \frac{1}{n_1} + \frac{1}{n_2} \right)}}$$

- Sotto l'ipotesi nulla  $T \sim t_{n_1+n_2-2}$

## Test per la differenza tra le medie

### Popolazioni Normali indipendenti con varianze ignote ma uguali

- Livello di significatività del test =  $\alpha$
- Regione Critica (Regione di Rifiuto)

Ipotesi alternativa	Regione di Rifiuto
$H_a : \mu_2 \neq \mu_1$	$T \leq -t_{(n_1+n_2-2), \alpha/2}$ oppure $T \geq t_{(n_1+n_2-2), \alpha/2}$
$H_a : \mu_2 > \mu_1$	$T \geq t_{(n_1+n_2-2), \alpha}$
$H_a : \mu_2 < \mu_1$	$T \leq -t_{(n_1+n_2-2), \alpha}$

- P-valore: Sia  $t^{oss}$  il valore osservato della statistica test  $T$

Ipotesi alternativa	P-valore
$H_a : \mu_2 - \mu_1 \neq 0$	$P(T < - t_{oss}  \text{ oppure } T >  t_{oss} ; H_0)$ $= 2 \cdot (1 - P(T \leq  t_{oss} ; H_0))$
$H_a : \mu_2 - \mu_1 > 0$	$P(T \geq t_{oss}; H_0) = (1 - P(T \leq t_{oss}; H_0))$
$H_a : \mu_2 - \mu_1 < 0$	$P(T \leq t_{oss}; H_0)$

**Nota bene.** Il p-valore è calcolato usando la distribuzione t-Student con  $n_1 + n_2 - 2$  gdl (la distribuzione campionaria di  $T$  sotto  $H_0$ )

## Test per la differenza tra le medie

### Popolazioni Normali indipendenti con varianze ignote ma uguali: Esempio I

- Obiettivo: Confrontare il voto medio alla fine del primo anno di studenti di istituti professionali in classi in cui si sono adottati metodi di insegnamento standard (popolazione 1) e in classi in cui si sono adottati metodi di interattivi (popolazione 2)

Metodo di insegnamento standard	Metodo di insegnamento interattivo
6.6	6.5
6.2	7.2
5.7	6.7
6.1	
5.4	

- Ipotesi

$$H_0 : \mu_2 = \mu_1 \quad \text{vs} \quad H_a : \mu_2 \neq \mu_1 \iff H_0 : \mu_D = 0 \quad \text{vs} \quad H_a : \mu_D \neq 0$$

- Livello di significatività del test:  $\alpha = 0.01$
- Regione Critica (Regione di Rifiuto)

$$\alpha = 0.01 \implies t_{0.005,6} = 3.707 \implies RC_{0.01} = T \leq -3.707 \text{ oppure } T \geq 3.707$$

## Test per la differenza tra le medie

### Popolazioni Normali indipendenti con varianze ignote ma uguali: Esempio I

- Stima della differenza tra le medie

$$\bar{y}_2 - \bar{y}_1 = \frac{20.4}{3} - \frac{30}{5} = 6.8 - 6 = 0.8$$

- Stima della varianza

$$s_2^2 = \frac{0.86}{5-1} = 0.215 \quad \text{e} \quad s_1^2 = \frac{0.26}{3-1} = 0.13$$

Quindi

$$s_p^2 = \frac{4 \cdot 0.215 + 2 \cdot 0.13}{5 + 3 - 2} = \frac{0.86 + 0.26}{6} = \frac{1.12}{6} = 0.187$$

- Valore osservato della statistica test

$$t_{oss} = \frac{\bar{y}_2 - \bar{y}_1}{\sqrt{s_p^2 \left( \frac{1}{n_1} + \frac{1}{n_2} \right)}} = \frac{0.8}{\sqrt{0.187 \left( \frac{1}{5} + \frac{1}{3} \right)}} = \frac{0.8}{\sqrt{0.0996}} = \frac{0.8}{0.3155} = 2.535$$

- Decisione: Il valore osservato della statistica test NON appartiene alla regione di rifiuto:  $-t_{0.005,6} = -3.707 < t_{oss} = 2.535 < 3.707 = t_{0.005,6}$ . I dati NON mostrano evidenza contraria all'ipotesi nulla al livello di significatività del 1%
- $P$ -valore = 0.04435 ( $p$ -valore non estremamente piccolo)

## Test per la differenza tra le medie

### Popolazioni Normali indipendenti con varianze ignote ma uguali: Esempio II

- Obiettivo: Valutare se un nuovo farmaco contro l'ipertensione riduce la pressione sanguigna
- Popolazione 1 = Soggetti ipertesi a cui è somministrato il farmaco standard
- Popolazione 2 = Soggetti ipertesi a cui è somministrato il nuovo farmaco

$$H_0 : \mu_2 = \mu_1 \quad \text{vs} \quad H_a : \mu_2 < \mu_1 \iff H_0 : \mu_D = 0 \quad \text{vs} \quad H_a : \mu_D < 0$$

- Dimensioni campionarie:  $n_1 = 12$  e  $n_2 = 10$
- Livello di significatività del test:  $\alpha = 0.05$
- Regione Critica (Regione di Rifiuto)

$$\alpha = 0.05 \implies t_{0.05, 10+12-2} = t_{0.05, 20} = 1.72 \implies RC_{0.05} = T \leq -1.72$$

## Test per la differenza tra le medie

### Popolazioni Normali indipendenti con varianze ignote ma uguali: Esempio II

$u_{i1}$	$y_{i1}$	$(y_{i1} - \bar{y}_1)^2$	$u_{i2}$	$y_{i2}$	$(y_{i2} - \bar{y}_2)^2$
1	178	240.25	1	117	605.16
2	153	90.25	2	166	595.36
3	186	552.25	3	118	556.96
4	118	1980.25	4	168	696.96
5	178	240.25	5	153	129.96
6	174	132.25	6	115	707.56
7	162	0.25	7	140	2.56
8	175	156.25	8	150	70.56
9	158	20.25	9	133	73.96
10	178	240.25	10	156	207.36
11	133	870.25			
12	157	30.25			

$$\bar{y}_1 = \frac{1950}{12} = 162.5$$

$$s_1^2 = \frac{4553}{12 - 1} = 413.91$$

$$\bar{y}_2 = \frac{1416}{10} = 141.6$$

$$s_2^2 = \frac{3646.4}{10 - 1} = 405.16$$

## Test per la differenza tra le medie

### Popolazioni Normali indipendenti con varianze ignote ma uguali: Esempio II

- Stima pooled della varianza

$$\begin{aligned}s_p^2 &= \frac{11 \cdot 413.91 + 9 \cdot 405.16}{10 + 12 - 2} \\ &= \frac{4553 + 3646.4}{20} = \frac{8199.4}{20} = 409.97\end{aligned}$$

- Valore osservato della statistica test

$$\begin{aligned}t_{oss} &= \frac{\bar{y}_2 - \bar{y}_1}{\sqrt{s_p^2 \left( \frac{1}{n_1} + \frac{1}{n_2} \right)}} = \frac{141.6 - 162.5}{\sqrt{409.97 \left( \frac{1}{10} + \frac{1}{12} \right)}} \\ &= \frac{-20.9}{\sqrt{75.16}} = \frac{-20.9}{8.67} = -2.41\end{aligned}$$

- Decisione: Il valore osservato della statistica test appartiene alla regione di rifiuto:  $t_{oss} = -2.41 < -1.72 = -t_{0.05,20} \implies$  I dati mostrano evidenza contraria all'ipotesi nulla al livello di significatività del 5%
- $P$ -valore = 0.01283 ( $p$ -valore piccolo ma non estremamente piccolo)

## Inferenza per la differenza tra le medie

### Popolazioni Normali indipendenti con varianze non note

- Popolazioni:  $Y_1 \sim N(\mu_1, \sigma_1^2)$  versus  $Y_2 \sim N(\mu_2, \sigma_2^2)$  indipendenti,  $\sigma_1^2$  e  $\sigma_2^2$  ignote
- Campioni casuali indipendenti:

$(Y_{11}, \dots, Y_{n_1})$  *i.i.d.*  $(Y_{12}, \dots, Y_{n_2})$  *i.i.d.* indipendenti

- Stimatore della differenza tra le medie:  $\bar{Y}_2 - \bar{Y}_1$
- Distribuzione campionaria:  $\bar{Y}_2 - \bar{Y}_1 \sim N\left(\mu_2 - \mu_1; \frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}\right)$
- Stimatori delle varianze

$$S_1^2 = \frac{1}{n_1 - 1} \sum_{i=1}^{n_1} (Y_{i1} - \bar{Y}_1)^2 \quad e \quad S_2^2 = \frac{1}{n_2 - 1} \sum_{i=1}^{n_2} (Y_{i2} - \bar{Y}_2)^2$$

- Statistica

$$\frac{(\bar{Y}_2 - \bar{Y}_1) - (\mu_2 - \mu_1)}{\sqrt{\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}}}$$

## Inferenza per la differenza tra le medie

### Popolazioni Normali indipendenti con varianze non note

- Distribuzione campionaria della statistica

$$\frac{(\bar{Y}_2 - \bar{Y}_1) - (\mu_2 - \mu_1)}{\sqrt{\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}}} \sim t_{gdl}$$

- I *gdl* dipendono dalle stime delle deviazioni standard  $s_1^2$  e  $s_2^2$  e dalle numerosità campionarie  $n_1$  e  $n_2$ 
  - ✓ Approssimazione Welch-Satterthwaite (complessa)
  - ✓ Se  $s_1^2 = s_2^2$  e  $n_1 = n_2$  allora  $gdl = n_1 + n_2 - 2$
  - ✓  $\min\{(n_1 - 1), (n_2 - 1)\} \leq gdl \leq (n_1 + n_2 - 2)$
- Se  $n_1$  e  $n_2$  sono sufficientemente grandi (almeno 30 ciascuno):

$$\frac{(\bar{Y}_2 - \bar{Y}_1) - (\mu_2 - \mu_1)}{\sqrt{\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}}} \sim t_{gdl} \approx N(0, 1)$$

## Intervallo di confidenza per la differenza tra le medie Popolazioni Normali indipendenti con varianze non note

Intervallo di confidenza (approssimato) al livello di confidenza  $1 - \alpha$

$$IC_{1-\alpha}(\mu_2 - \mu_1) \approx \left[ (\bar{y}_2 - \bar{y}_1) - z_{\alpha/2} \sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}; (\bar{y}_2 - \bar{y}_1) + z_{\alpha/2} \sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}} \right]$$

**Nota bene.** L'approssimazione è adeguata se  $n_1$  e  $n_2$  sono sufficientemente grandi

# Test per la differenza tra le medie

## Popolazioni Normali indipendenti con varianze non note

- Popolazioni:  $Y_1 \sim N(\mu_1, \sigma_1^2)$  versus  $Y_2 \sim N(\mu_2, \sigma_2^2)$  indipendenti,  $\sigma_1^2$  e  $\sigma_2^2$  ignote
- Campioni casuali indipendenti:

$(Y_{11}, \dots, Y_{n_1})$  *i.i.d.*    $(Y_{12}, \dots, Y_{n_2})$  *i.i.d.*   indipendenti

- Stimatore della differenza tra le medie:  $\bar{Y}_2 - \bar{Y}_1$
- Stimatori delle varianze

$$S_1^2 = \frac{1}{n_1 - 1} \sum_{i=1}^{n_1} (Y_{i1} - \bar{Y}_1)^2 \quad e \quad S_2^2 = \frac{1}{n_2 - 1} \sum_{i=1}^{n_2} (Y_{i2} - \bar{Y}_2)^2$$

- Statistica test e sua distribuzione campionaria sotto  $H_0 : \mu_2 - \mu_1 = 0$

$$Z = \frac{(\bar{Y}_2 - \bar{Y}_1) - 0}{\sqrt{\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}}} \sim t_{gdl} \text{ sotto l'ipotesi nulla}$$

con *gdl* difficili da calcolare

## Test per la differenza tra le medie

### Popolazioni Normali indipendenti con varianze non note

- Se  $n_1$  e  $n_2$  sono sufficientemente grandi, sotto l'ipotesi nulla,  
 $H_0 : \mu_2 - \mu_1 = 0$

$$Z = \frac{(\bar{Y}_2 - \bar{Y}_1) - 0}{\sqrt{\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}}} \sim t_{gdl} \approx N(0, 1)$$

**Nota bene.** L'approssimazione è adeguata se  $n_1$  e  $n_2$  sono sufficientemente grandi

## Test per la differenza tra le medie

### Popolazioni Normali indipendenti con varianze non note

- Livello di significatività del test =  $\alpha$
- Regione di rifiuto (Approssimata)

Ipotesi alternativa	Regione di Rifiuto
$H_a : \mu_2 \neq \mu_1$	$Z \leq -z_{\alpha/2}$ oppure $Z \geq z_{\alpha/2}$
$H_a : \mu_2 > \mu_1$	$Z \geq z_{\alpha}$
$H_a : \mu_2 < \mu_1$	$Z \leq -z_{\alpha}$

- P-valore (approssimato): Sia  $z^{\text{oss}}$  il valore osservato della statistica test  $Z$

Ipotesi alternativa	P-valore
$H_a : \mu_2 - \mu_1 \neq 0$	$P(Z < - z_{\text{oss}}  \text{ oppure } Z >  z_{\text{oss}} ; H_0)$ $= 2 \cdot (1 - P(Z \leq  z_{\text{oss}} ; H_0))$
$H_a : \mu_2 - \mu_1 > 0$	$P(Z \geq z_{\text{oss}}; H_0) = (1 - P(Z \leq z_{\text{oss}}; H_0))$
$H_a : \mu_2 - \mu_1 < 0$	$P(Z \leq z_{\text{oss}}; H_0)$

**Nota bene.** Il p-valore è calcolato usando la distribuzione Normale standard (la distribuzione campionaria approssimata di  $Z$  sotto  $H_0$ )

## Inferenza per la differenza tra le medie

### Popolazioni qualsiasi indipendenti – Campioni di grandi dimensioni

- Popolazioni:

$$Y_1 : \mathbb{E}(Y_1) = \mu_1; \text{var}(Y_1) = \sigma_1^2 \quad \text{versus} \quad Y_2 : \mathbb{E}(Y_2) = \mu_2; \text{var}(Y_2) = \sigma_2^2$$

$Y_1$  e  $Y_2$  indipendenti,  $\sigma_1^2$  e  $\sigma_2^2$  ignote

- Campioni casuali indipendenti:

$(Y_{11}, \dots, Y_{n_{11}})$  *i.i.d.*    $(Y_{12}, \dots, Y_{n_{22}})$  *i.i.d.*   indipendenti

- Stimatore della differenza tra le medie:  $\bar{Y}_2 - \bar{Y}_1$
- Stimatori delle varianze

$$S_1^2 = \frac{1}{n_1 - 1} \sum_{i=1}^{n_1} (Y_{i1} - \bar{Y}_1)^2 \quad \text{e} \quad S_2^2 = \frac{1}{n_2 - 1} \sum_{i=1}^{n_2} (Y_{i2} - \bar{Y}_2)^2$$

## Inferenza per la differenza tra le medie

### Popolazioni qualsiasi indipendenti – Campioni di grandi dimensioni

- Statistica

$$\frac{(\bar{Y}_2 - \bar{Y}_1) - (\mu_2 - \mu_1)}{\sqrt{\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}}}$$

- Distribuzione campionaria (approssimata) della statistica. Se  $n_1$  e  $n_2$  sono sufficientemente grandi:

$$\frac{(\bar{Y}_2 - \bar{Y}_1) - (\mu_2 - \mu_1)}{\sqrt{\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}}} \approx N(0, 1)$$

## Intervallo di confidenza per la differenza tra le medie

### Popolazioni qualsiasi indipendenti – Campioni di grandi dimensioni

Intervallo di confidenza (approssimato) al livello di confidenza  $1 - \alpha$

$$IC_{1-\alpha}(\mu_2 - \mu_1) \approx \left[ (\bar{y}_2 - \bar{y}_1) - z_{\alpha/2} \sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}; (\bar{y}_2 - \bar{y}_1) + z_{\alpha/2} \sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}} \right]$$

**Nota bene.** L'approssimazione è adeguata se  $n_1$  e  $n_2$  sono sufficientemente grandi

## Intervallo di confidenza per la differenza tra le medie

Popolazioni qualsiasi indipendenti – Campioni di grandi dimensioni: Esempio

- Obiettivo: Confrontare il livello di dolore (misurato attraverso la scala visuo-analogica del dolore) a 4 ore dalla fine dell'operazione tra due gruppi di pazienti sottoposti a un'operazione chirurgica all'addome: pazienti trattati preliminarmente con morfina e pazienti trattati preliminarmente con un placebo
- Sintesi dei dati campionari:

Gruppo placebo:  $n_1 = 200$   $\bar{y}_1 = 45.4$   $s_1^2 = 333.2$

Gruppo morfina:  $n_2 = 120$   $\bar{y}_2 = 28.0$   $s_2^2 = 162.7$

- Intervallo di confidenza al livello di confidenza  $1 - \alpha = 0.95$  (approssimato)

$$\begin{aligned} IC_{0.95}(\mu_2 - \mu_1) &\approx \left[ -17.4 - 1.96\sqrt{\frac{333.2}{200} + \frac{162.7}{120}}; -17.4 + 1.96\sqrt{\frac{333.2}{200} + \frac{162.7}{120}} \right] \\ &= [-20.81; -13.99] \end{aligned}$$

## Test per la differenza tra le medie

### Popolazioni qualsiasi indipendenti – Campioni di grandi dimensioni

- Popolazioni:

$$Y_1 : \mathbb{E}(Y_1) = \mu_1; \text{var}(Y_1) = \sigma_1^2 \quad \text{versus} \quad Y_2 : \mathbb{E}(Y_2) = \mu_2; \text{var}(Y_2) = \sigma_2^2$$

$Y_1$  e  $Y_2$  indipendenti,  $\sigma_1^2$  e  $\sigma_2^2$  ignote

- Se  $n_1$  e  $n_2$  sono sufficientemente grandi, sotto l'ipotesi nulla,

$$Z = \frac{(\bar{Y}_2 - \bar{Y}_1) - 0}{\sqrt{\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}}} \approx N(0, 1)$$

## Test per la differenza tra le medie

### Popolazioni qualsiasi indipendenti – Campioni di grandi dimensioni

- Livello di significatività del test =  $\alpha$
- Regione Rifiuto (Approssimata)

Ipotesi alternativa	Regione di Rifiuto
$H_a : \mu_2 \neq \mu_1$	$Z \leq -z_{\alpha/2}$ oppure $Z \geq z_{\alpha/2}$
$H_a : \mu_2 > \mu_1$	$Z \geq z_{\alpha}$
$H_a : \mu_2 < \mu_1$	$Z \leq -z_{\alpha}$

- P-valore (approssimato): Sia  $z^{oss}$  il valore osservato della statistica test  $Z$

Ipotesi alternativa	P-valore
$H_a : \mu_2 - \mu_1 \neq 0$	$P(Z < - z_{oss}  \text{ oppure } Z >  z_{oss} ; H_0)$ $= 2 \cdot (1 - P(Z \leq  z_{oss} ; H_0))$
$H_a : \mu_2 - \mu_1 > 0$	$P(Z \geq z_{oss}; H_0) = (1 - P(Z \leq z_{oss}; H_0))$
$H_a : \mu_2 - \mu_1 < 0$	$P(Z \leq z_{oss}; H_0)$

**Nota bene.** Il p-valore è calcolato usando la distribuzione Normale standard (la distribuzione campionaria approssimata di  $Z$  sotto  $H_0$ )

## Test per la differenza tra le medie

### Popolazioni qualsiasi indipendenti – Campioni di grandi dimensioni: Esempio

- Obiettivo: Confrontare il livello di dolore (misurato attraverso la scala visuo-analogica del dolore) a 4 ore dalla fine dell'operazione tra due gruppi di pazienti sottoposti a un'operazione chirurgica all'addome: pazienti trattati preliminarmente con morfina e pazienti trattati preliminarmente con un placebo

$$H_0 : \mu_2 = \mu_1 \quad vs \quad H_a : \mu_2 \neq \mu_1 \iff H_0 : \mu_D = 0 \quad vs \quad H_a : \mu_D \neq 0$$

- Sintesi dei dati campionari:

$$\text{Gruppo placebo: } n_1 = 200 \quad \bar{y}_1 = 45.4 \quad s_1^2 = 333.2$$

$$\text{Gruppo morfina: } n_2 = 120 \quad \bar{y}_2 = 28.0 \quad s_2^2 = 162.7$$

- Livello di significatività del test:  $\alpha = 0.05$

- Regione di rifiuto (Approssimata):

$$\alpha = 0.05 \implies \alpha/2 = 0.025 \implies z_{\alpha/2} = 1.96. \text{ Quindi}$$

$$RC_{0.05} = Z \leq -1.96 \quad \text{oppure} \quad Z \geq 1.96$$

## Test per la differenza tra le medie

### Popolazioni qualsiasi indipendenti – Campioni di grandi dimensioni: Esempio

- Valore osservato della statistica test

$$\begin{aligned} z_{oss} &= \frac{\bar{y}_2 - \bar{y}_1}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}} = \frac{28 - 45.4}{\sqrt{\frac{333.2}{200} + \frac{162.7}{120}}} \\ &= \frac{-17.4}{\sqrt{1.666 + 1.356}} = \frac{-17.4}{\sqrt{3.022}} = \frac{-17.4}{1.738} = -10.01 \end{aligned}$$

- Decisione: Il valore osservato della statistica test appartiene alla regione di rifiuto:  $z_{oss} = -10.01 < -1.96 = -z_{0.025} \implies$  I dati mostrano evidenza contraria all'ipotesi nulla al livello di significatività del 5%
- $P$ -valore (approssimato)

$$p = 2 \cdot [1 - P(Z \leq |-10.01|; H_0)] = 0.000$$

( $p$ -valore piccolo)

## Corrispondenza tra intervalli di confidenza e test bilaterali per la media di una variabile quantitativa

- $IC_{1-\alpha}(\mu_2 - \mu_1)$ : Intervallo di confidenza al livello di confidenza  $1 - \alpha$
- Test bilaterale:

$$H_0 : \mu_2 = \mu_1 \quad \text{vs} \quad H_a : \mu_2 \neq \mu_1 \iff H_0 : \mu_D = 0 \quad \text{vs} \quad H_a : \mu_D \neq 0$$

✓  $RC_\alpha$ : Regione di rifiuto al livello di significatività  $\alpha$

- L'intervallo di confidenza al livello di confidenza  $1 - \alpha$  *contiene il valore zero*  $\iff$  I dati *non mostrano* evidenza contro  $H_0$  al livello di significatività  $\alpha$
- L'intervallo di confidenza al livello di confidenza  $1 - \alpha$  *non contiene il valore zero*  $\iff$  I dati *mostrano* evidenza contro  $H_0$  al livello di significatività  $\alpha$

## Corrispondenza tra intervalli di confidenza e test bilaterali

### Popolazioni Normali indipendenti con varianze note: Esempio

- Obiettivo: Confrontare il peso medio (in grammi) di neonati nati da madri non fumatrici (popolazione 1) il peso medio (in grammi) di neonati nati da madri fumatrici (popolazione 2)
- Varianze note:  $\sigma_1^2 = \sigma_{\bar{F}}^2 = 50850$  e  $\sigma_2^2 = \sigma_{\bar{F}}^2 = 60025$
- Sintesi dei dati campionari:

Madre fumatrice:	$n_F = 120$	$\bar{y}_F = 2150$
Madre non fumatrice:	$n_R = 100$	$\bar{y}_R = 3375$

quindi  $\bar{y}_F - \bar{y}_{\bar{F}} = -1225$  e  $es(\bar{Y}_F - \bar{Y}_{\bar{F}}) = 32$

- Intervallo di confidenza al livello di confidenza  $1 - \alpha = 0.95$

$$IC_{0.95}(\mu_F - \mu_{\bar{F}}) = [-1287.719; -1162.281]$$

- Verifica delle ipotesi  $H_0 : \mu_F = \mu_{\bar{F}}$  vs  $H_a : \mu_F \neq \mu_{\bar{F}}$  al livello  $\alpha = 0.05$ :

$$z_{oss} = -38.28 \in RC_{0.05} = Z \leq -1.96 \text{ oppure } Z \geq 1.96$$

- L'intervallo di confidenza NON contiene lo zero: i dati mostrano evidenza contraria alla possibilità che la differenza tra le due medie sia nulla  $\iff$  Il test porta a rifiutare  $H_0$  al livello di significatività del 5%

## Corrispondenza tra intervalli di confidenza e test bilaterali

### Popolazioni Normali indipendenti con varianze ignote ma uguali: Esempio

- Obiettivo: Confrontare il voto medio alla fine del primo anno di studenti di istituti professionali in classi in cui si sono adottati metodi di insegnamento standard (popolazione 1) e in classi in cui si sono adottati metodi di interattivi (popolazione 2)
- Sintesi dei dati campionari:

$$\begin{array}{lll} n_1 = 5 & n_2 = 3 & \\ \bar{y}_1 = 6.0 & \bar{y}_2 = 6.8 & \bar{y}_2 - \bar{y}_1 = 0.8 \\ s_1^2 = 0.215 & s_2^2 = 0.13 & s_p^2 = 0.187 \end{array}$$

- Intervallo di confidenza al livello di confidenza  $1 - \alpha = 0.99$

$$IC_{0.99}(\mu_2 - \mu_1) = [-1.970; 0.370]$$

- Verifica delle ipotesi  $H_0 : \mu_2 = \mu_1$  vs  $H_a : \mu_2 \neq \mu_1$  al livello  $\alpha = 0.01$ :

$$T_{oss} = 2.535 \notin RC_{0.01} = T \leq -3.707 \text{ oppure } T \geq 3.707$$

- L'intervallo di confidenza contiene lo zero: i dati non mostrano evidenza contraria alla possibilità che la differenza tra le due medie sia nulla. Coerentemente non si rifiuta  $H_0$  al livello di significatività del 5%

## Corrispondenza tra intervalli di confidenza e test bilaterali

### Popolazioni qualsiasi indipendenti – Campioni di grandi dimensioni: Esempio

- Obiettivo: Confrontare il livello di dolore (misurato attraverso la scala visuo-analogica del dolore) a 4 ore dalla fine dell'operazione tra due gruppi di pazienti sottoposti a un'operazione chirurgica all'addome: pazienti trattati preliminarmente con morfina e pazienti trattati preliminarmente con un placebo
- Sintesi dei dati campionari:

$$\text{Gruppo placebo: } n_1 = 200 \quad \bar{y}_1 = 45.4 \quad s_1^2 = 333.2$$

$$\text{Gruppo morfina: } n_2 = 120 \quad \bar{y}_2 = 28.0 \quad s_2^2 = 162.7$$

- Intervallo di confidenza al livello di confidenza  $1 - \alpha = 0.95$  (approssimato)

$$IC_{0.95}(\mu_2 - \mu_1) \approx [-20.81; -13.99]$$

- Verifica delle ipotesi  $H_0 : \mu_2 = \mu_1$  vs  $H_a : \mu_2 \neq \mu_1$  al livello  $\alpha = 0.05$ :

$$z_{oss} = -10.01 \in RC_{0.05} = Z \leq -1.96 \text{ oppure } Z \geq 1.96$$

- L'intervallo di confidenza NON contiene lo zero: i dati mostrano evidenza contraria alla possibilità che la differenza tra le due medie sia nulla. Coerentemente si rifiuta  $H_0$  al livello di significatività del 5%

# Inferenza per la differenza tra le medie

## Popolazioni Normali dipendenti (dati appaiati)

- Studi longitudinali → Misure Ripetute → Dati appaiati
- Una popolazione in due tempi successivi:

$$Y_1 \sim N(\mu_1, \sigma_1^2) \quad \text{versus} \quad Y_2 \sim N(\mu_2, \sigma_2^2)$$

- Campioni casuali:  $(Y_{11}, \dots, Y_{n1})$  *i.i.d.* e  $(Y_{12}, \dots, Y_{n2})$  *i.i.d.*
- $Y_{i1}$  e  $Y_{i2}$ : misure sulla stessa unità in tempi successivi (prima e dopo un trattamento)
- $Y_{iD} = Y_{i2} - Y_{i1} \implies Y_{1D}, \dots, Y_{iD}, \dots, Y_{nD}$  *i.i.d.* da  $Y_D \sim N(\mu_D, \sigma_D^2)$
- Si suppone che le varianze  $\sigma_1^2$  e  $\sigma_2^2$  (e quindi  $\sigma_D^2$ ) siano non note

# Inferenza per la differenza tra le medie

## Popolazioni Normali dipendenti (dati appaiati)

- Stimatore della differenza tra le medie

$$\bar{Y}_D = \frac{1}{n} \sum_{i=1}^n Y_{iD}$$

- Distribuzione campionaria della statistica  $\bar{Y}_D$

$$\bar{Y}_D \sim N\left(\mu_D, \frac{\sigma_D^2}{n}\right)$$

# Inferenza per la differenza tra le medie

## Popolazioni Normali dipendenti (dati appaiati)

- Stimatore della varianza delle differenze

$$S_D = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (Y_{iD} - \bar{Y}_D)^2}$$

- Statistica  $T$  e sua distribuzione campionaria

$$T = \frac{\bar{Y}_D - \mu_D}{S_D/\sqrt{n}} \sim t_{n-1}$$

## Intervallo di confidenza per la differenza tra le medie Popolazioni Normali dipendenti (dati appaiati)

Intervallo di confidenza al livello di confidenza  $1 - \alpha$

$$IC_{1-\alpha}(\mu_D) = \left[ \bar{y}_D - t_{(n-1),\alpha/2} \sqrt{\frac{S_D^2}{n}}; \bar{y}_D + t_{(n-1),\alpha/2} \sqrt{\frac{S_D^2}{n}} \right]$$

## Intervallo di confidenza per la differenza tra le medie Popolazioni Normali dipendenti (dati appaiati): Esempio

- Pressione sanguigna per soggetti ipertesi prima e dopo un trattamento farmacologico
- Campione casuale di 5 soggetti prima e dopo il trattamento
- Osservazioni campionarie

$u_i$	$y_{i1}$	$y_{i2}$	$y_{iD}$
1	177	136	-41
2	177	140	-37
3	166	139	-27
4	169	141	-28
5	169	141	-28

$$\bar{y}_D = \frac{161}{5} = -32.2$$

$$s_D^2 = \frac{5347 - 5 \cdot (-32.2)^2}{5 - 1} = 40.7$$

- Intervallo di confidenza al livello di confidenza  $1 - \alpha = 0.95$

$$\begin{aligned} IC_{0.95}(\mu_D) &= \left[ -32.2 - 2.78 \cdot \sqrt{\frac{40.7}{5}}; -32.2 + 2.78 \cdot \sqrt{\frac{40.7}{5}} \right] \\ &= [-40.12; -24.28] \end{aligned}$$

## Test per la differenza tra le medie

### Popolazioni Normali dipendenti (dati appaiati)

- Una popolazione in due tempi successivi:

$$Y_1 \sim N(\mu_1, \sigma_1^2) \quad \text{versus} \quad Y_2 \sim N(\mu_2, \sigma_2^2)$$

- Campioni casuali:  $(Y_{11}, \dots, Y_{n1})$  *i.i.d.* e  $(Y_{12}, \dots, Y_{n2})$  *i.i.d.*
- $Y_{i1}$  e  $Y_{i2}$ : misure sulla stessa unità in tempi successivi (prima e dopo un trattamento)
- $Y_{iD} = Y_{i2} - Y_{i1} \implies Y_{1D}, \dots, Y_{iD}, \dots, Y_{nD}$  *i.i.d.* da  $Y_D \sim N(\mu_D, \sigma_D^2)$
- Si suppone che le varianze  $\sigma_1^2$  e  $\sigma_2^2$  (e quindi  $\sigma_D^2$ ) siano non note
- Test per la media di una popolazione normale con varianza ignota
- Ipotesi

$$H_0: \mu_D = 0 \quad \text{vs} \quad H_a: \mu_D \neq 0$$

$$H_0: \mu_D = 0 \quad \text{vs} \quad H_a: \mu_D > 0$$

$$H_0: \mu_D = 0 \quad \text{vs} \quad H_a: \mu_D < 0$$

# Test per la differenza tra le medie

## Popolazioni Normali dipendenti (dati appaiati)

- Statistica test

$$T = \frac{\bar{Y}_D - 0}{S_D / \sqrt{n}}$$

- Sotto l'ipotesi nulla  $T \sim t_{n-1}$
- Regione rifiuto al livello di significatività  $\alpha$

Ipotesi alternativa	Regione di Rifiuto
$H_a : \mu_D \neq 0$	$T \leq -t_{(n-1), \alpha/2}$ oppure $T \geq t_{(n-1), \alpha/2}$
$H_a : \mu_D > 0$	$T \geq t_{(n-1), \alpha}$
$H_a : \mu_D < 0$	$T \leq -t_{(n-1), \alpha}$

- P-valore: Sia  $t^{\text{oss}}$  il valore osservato della statistica test  $T$

Ipotesi alternativa	P-valore
$H_a : \mu_D \neq 0$	$P(T < - t_{\text{oss}}  \text{ oppure } T >  t_{\text{oss}} ; H_0)$
$H_a : \mu_D > 0$	$P(T \geq t_{\text{oss}}; H_0) = (1 - P(T \leq t_{\text{oss}}; H_0))$
$H_a : \mu_D < 0$	$P(T \leq t_{\text{oss}}; H_0)$

**Nota bene.** Il p-valore è calcolato usando la distribuzione t-Student con  $n - 1$  gdl (la distribuzione campionaria di  $T$  sotto  $H_0$ )

## Test per la differenza tra le medie

### Popolazioni Normali dipendenti (dati appaiati): Esempio

- Pressione sanguigna per soggetti ipertesi prima e dopo un trattamento farmacologico
- Campione casuale di 5 soggetti prima e dopo il trattamento

$$\bar{y}_D = \frac{-161}{5} = -32.2 \quad s_D^2 = \frac{5347 - 5 \cdot (-32.2)^2}{5 - 1} = 40.7$$

- Sistema di ipotesi

$$H_0 : \mu_D = 0 \quad \text{versus} \quad H_a : \mu_D \neq 0$$

- Livello di significatività:  $\alpha = 0.05$

$$\alpha = 0.05 \implies \alpha/2 = 0.025 \implies t_{(n-1),0.025} = t_{4,0.025} = 2.78$$

- Regione rifiuto al livello di significatività  $\alpha$

$$T \leq -2.78 \quad \text{oppure} \quad T \geq 2.78$$

## Test per la differenza tra le medie

### Popolazioni Normali dipendenti (dati appaiati): Esempio

- Valore osservato della statistica test

$$t_{oss} = \frac{-32.2}{\sqrt{\frac{40.7}{5}}} = \frac{-32.2}{\sqrt{8.14}} = \frac{-32.2}{2.85} = -11.29$$

- Decisione: Il valore osservato della statistica test appartiene alla regione di rifiuto:  $t_{oss} = -11.29 < -2.78 = -t_{4,0.025} \implies$  I dati mostrano evidenza contraria all'ipotesi nulla al livello di significatività del 5%
- $P$ -valore = 0.0003512 ( $p$ -valore piccolo)
- Corrispondenza tra intervalli di confidenza e test bilaterali per la differenza tra medie con campioni dipendenti:
  - ✓ L'intervallo di di confidenza al livello di confidenza  $1 - \alpha = 0.95$  *non contiene il valore zero* ma solo valori negativi
  - ✓ Coerentemente i dati *mostrano* evidenza contro  $H_0$  al livello di significatività  $\alpha = 0.05$

# Inferenza per la differenza tra proporzioni

- Variabile di interesse:  $Y$  (variabile binaria)
- Popolazioni:  $Y_1 \sim \text{Ber}(\pi_1)$  versus  $Y_2 \sim \text{Ber}(\pi_2)$  indipendenti
- Obiettivo: Valutare se  $\pi_1 = \pi_2 \iff \pi_D \equiv \pi_2 - \pi_1 = 0$
- Campioni casuali indipendenti:

$(Y_{11}, \dots, Y_{n_1})$  *i.i.d.*  $(Y_{12}, \dots, Y_{n_2})$  *i.i.d.* indipendenti

- Proporzioni campionarie:  $\hat{\pi}_1 = \bar{Y}_1 = \frac{1}{n_1} \sum_{i=1}^{n_1} Y_{i1}$  e  $\hat{\pi}_2 = \bar{Y}_2 = \frac{1}{n_2} \sum_{i=1}^{n_2} Y_{i2}$
- Stimatore per la differenza tra proporzioni:  $\hat{\pi}_2 - \hat{\pi}_1 = \bar{Y}_2 - \bar{Y}_1$
- Distribuzioni campionarie: Se  $n_1$  e  $n_2$  sono sufficientemente grandi

$$\hat{\pi}_1 = \bar{Y}_1 \approx N\left(\pi_1, \frac{\pi_1(1-\pi_1)}{n_1}\right) \quad \text{e} \quad \hat{\pi}_2 = \bar{Y}_2 \approx N\left(\pi_2, \frac{\pi_2(1-\pi_2)}{n_2}\right)$$

Sotto l'ipotesi di indipendenza (per  $n_1$  e  $n_2$  sufficientemente grandi)

$$\hat{\pi}_2 - \hat{\pi}_1 \approx N\left(\pi_2 - \pi_1, \frac{\pi_1(1-\pi_1)}{n_1} + \frac{\pi_2(1-\pi_2)}{n_2}\right)$$

## Intervallo di confidenza per la differenza tra proporzioni Campioni di grandi dimensioni

Intervallo di confidenza al livello di confidenza  $1 - \alpha$

$$IC_{1-\alpha}(\pi_2 - \pi_1) \approx \left[ (\hat{\pi}_2 - \hat{\pi}_1) - z_{\alpha/2} \sqrt{\frac{\hat{\pi}_1(1 - \hat{\pi}_1)}{n_1} + \frac{\hat{\pi}_2(1 - \hat{\pi}_2)}{n_2}}; \right. \\ \left. (\hat{\pi}_2 - \hat{\pi}_1) + z_{\alpha/2} \sqrt{\frac{\hat{\pi}_1(1 - \hat{\pi}_1)}{n_1} + \frac{\hat{\pi}_2(1 - \hat{\pi}_2)}{n_2}} \right]$$

## Intervallo di confidenza per la differenza tra proporzioni

### Campioni di grandi dimensioni: Esempio

- Obiettivo: Confrontare il tasso di occupazione di giovani svantaggiati che hanno seguito un corso di formazione professionale ( $\pi_2$ ) con il tasso di occupazione di giovani svantaggiati che non hanno seguito un corso di formazione professionale ( $\pi_1$ )
- Osservazioni campionarie

Corso di formazione	Numerosità campionaria	Numero occupati	Proporzione campionaria
No	$n_1 = 80$	60	$\hat{\pi}_1 = \frac{60}{80} = 0.75$
Si	$n_2 = 120$	93	$\hat{\pi}_2 = \frac{93}{120} = 0.775$

## Intervallo di confidenza per la differenza tra proporzioni

### Campioni di grandi dimensioni: Esempio

- Stima della differenza tra proporzioni  $\hat{\pi}_2 - \hat{\pi}_1 = 0.775 - 0.75 = 0.025$
- Stima dell'errore standard dello stimatore differenza tra proporzioni

$$\begin{aligned} & \sqrt{\frac{\hat{\pi}_1(1 - \hat{\pi}_1)}{n_1} + \frac{\hat{\pi}_2(1 - \hat{\pi}_2)}{n_2}} = \\ & \sqrt{\frac{0.75 \cdot (1 - 0.75)}{80} + \frac{0.775 \cdot (1 - 0.775)}{120}} = \\ & \sqrt{\frac{0.1875}{80} + \frac{0.1744}{120}} = \sqrt{0.0023 + 0.0015} = \sqrt{0.0038} = 0.0616 \end{aligned}$$

- Intervallo di confidenza al livello di confidenza  $1 - \alpha = 0.97$

$$\begin{aligned} IC_{0.97}(\pi_2 - \pi_1) & \approx [0.025 - 2.17 \cdot 0.0616; 0.025 + 2.17 \cdot 0.0616] \\ & = [-0.1087; 0.1587] \end{aligned}$$

## Test per la differenza tra proporzioni Campioni di grandi dimensioni

- Parametro di interesse  $\pi_D \equiv \pi_2 - \pi_1$
- Ipotesi nulla e ipotesi alternativa

$$\begin{array}{llll} H_0 : \pi_2 = \pi_1 & \text{vs} & H_a : \pi_2 \neq \pi_1 & H_0 : \pi_D = 0 & \text{vs} & H_a : \pi_D \neq 0 \\ H_0 : \pi_2 = \pi_1 & \text{vs} & H_a : \pi_2 > \pi_1 & \iff & H_0 : \pi_D = 0 & \text{vs} & H_a : \pi_D > 0 \\ H_0 : \pi_2 = \pi_1 & \text{vs} & H_a : \pi_2 < \pi_1 & & H_0 : \pi_D = 0 & \text{vs} & H_a : \pi_D < 0 \end{array}$$

- Sotto l'ipotesi nulla  $\pi_1 = \pi_2 \equiv \pi \implies$  Sotto  $H_0$  le due popolazioni hanno stessa varianza  $\pi(1 - \pi)$
- Stimatore congiunto (pooled) della proporzione

$$\hat{\pi} = \bar{Y}_p = \frac{1}{n_1 + n_2} \left( \sum_{i=1}^{n_1} Y_{i1} + \sum_{i=1}^{n_2} Y_{i2} \right) = \frac{n_1 \bar{Y}_1 + n_2 \bar{Y}_2}{n_1 + n_2} = \frac{n_1 \hat{\pi}_1 + n_2 \hat{\pi}_2}{n_1 + n_2}$$

## Test per la differenza tra proporzioni Campioni di grandi dimensioni

- Statistica test

$$Z = \frac{(\bar{Y}_2 - \bar{Y}_1) - 0}{\sqrt{\bar{Y}_p(1 - \bar{Y}_p) \left( \frac{1}{n_1} + \frac{1}{n_2} \right)}} = \frac{(\hat{\pi}_2 - \hat{\pi}_1) - 0}{\sqrt{\hat{\pi}(1 - \hat{\pi}) \left( \frac{1}{n_1} + \frac{1}{n_2} \right)}}$$

- Sotto l'ipotesi nulla, per  $n_1$  e  $n_2$  sufficientemente grandi,

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

## Test per la differenza tra proporzioni Campioni di grandi dimensioni

- Livello di significatività del test =  $\alpha$
- Regione di rifiuto (Approssimata)

Ipotesi alternativa	Regione di Rifiuto
$H_a : \pi_2 \neq \pi_1$	$Z \leq -z_{\alpha/2}$ oppure $Z \geq z_{\alpha/2}$
$H_a : \pi_2 > \pi_1$	$Z \geq z_{\alpha}$
$H_a : \pi_2 < \pi_1$	$Z \leq -z_{\alpha}$

- P-valore (approssimato): Sia  $z^{oss}$  il valore osservato della statistica test  $Z$

Ipotesi alternativa	P-valore
$H_a : \pi_2 - \pi_1 \neq 0$	$P(Z < - z_{oss}  \text{ oppure } Z >  z_{oss} ; H_0)$ $= 2 \cdot (1 - P(Z \leq  z_{oss} ; H_0))$
$H_a : \pi_2 - \pi_1 > 0$	$P(Z \geq z_{oss}; H_0) = (1 - P(Z \leq z_{oss}; H_0))$
$H_a : \pi_2 - \pi_1 < 0$	$P(Z \leq z_{oss}; H_0)$

**Nota bene.** Il p-valore è calcolato usando la distribuzione Normale standard (la distribuzione campionaria approssimata di  $Z$  sotto  $H_0$ )

## Test per la differenza tra proporzioni

### Campioni di grandi dimensioni: Esempio I

- Obiettivo: Confrontare il tasso di occupazione di giovani svantaggiati che hanno seguito un corso di formazione professionale ( $\pi_2$ ) con il tasso di occupazione di giovani svantaggiati che non hanno seguito un corso di formazione professionale ( $\pi_1$ )

$$H_0 : \pi_2 = \pi_1 \quad \text{vs} \quad H_a : \pi_2 \neq \pi_1 \iff H_0 : \pi_D = 0 \quad \text{vs} \quad H_a : \pi_D \neq 0$$

- Osservazioni campionarie

Corso di formazione	Numerosità campionaria	Numero occupati	Proporzione campionaria
No	$n_1 = 80$	60	$\hat{\pi}_1 = \frac{60}{80} = 0.75$
Si	$n_2 = 120$	93	$\hat{\pi}_2 = \frac{93}{120} = 0.775$

## Test per la differenza tra proporzioni

### Campioni di grandi dimensioni: Esempio I

- Stima pooled della proporzione

$$\hat{\pi} = \frac{80 \cdot 0.75 + 120 \cdot 0.775}{80 + 120} = \frac{60 + 93}{80 + 120} = \frac{153}{200} = 0.765$$

- Livello di significatività:  $\alpha = 0.03 \Rightarrow \alpha/2 = 0.015 \Rightarrow z_{0.015} = 2.17$
- Regione rifiuto:  $RC_{0.03} = Z \leq -2.17$  oppure  $Z \geq 2.17$
- Valore osservato della statistica test

$$\begin{aligned} z_{oss} &= \frac{(\hat{\pi}_2 - \hat{\pi}_1) - 0}{\sqrt{\hat{\pi}(1 - \hat{\pi}) \left( \frac{1}{n_1} + \frac{1}{n_2} \right)}} = \frac{0.775 - 0.75}{\sqrt{0.765 \cdot (1 - 0.765) \left( \frac{1}{80} + \frac{1}{120} \right)}} \\ &= \frac{0.025}{\sqrt{0.1798(0.0125 + 0.0083)}} = \frac{0.025}{\sqrt{0.0037}} = \frac{0.025}{0.0612} = 0.4085 \end{aligned}$$

- Decisione: Il valore osservato della statistica test NON appartiene alla regione di rifiuto:  $-z_{0.015} = -2.17 < z_{oss} = 0.4085 < 2.17 = z_{0.015}$ . I dati NON mostrano evidenza contraria all'ipotesi nulla al livello di significatività del 3%
- $P$ -valore (approssimato) =  $2 \cdot [1 - P(Z \leq |0.4085|; H_0)] = 0.6829$  ( $p$ -valore grande)

## Test per la differenza tra proporzioni

### Campioni di grandi dimensioni: Esempio II

- Obiettivo: Confrontare la proporzione di abbandoni tra matricole con e senza borsa di studio in un certo ateneo

$$H_0 : \pi_2 = \pi_1 \quad \text{vs} \quad H_a : \pi_2 > \pi_1 \iff H_0 : \pi_D = 0 \quad \text{vs} \quad H_a : \pi_D < 0$$

- Osservazioni campionarie

Borsa di Studio	Numerosità campionaria	Numero di abbandoni	Proporzione campionaria
No	$n_1 = 800$	200	$\hat{\pi}_1 = \frac{200}{800} = 0.250$
Si	$n_2 = 400$	70	$\hat{\pi}_2 = \frac{70}{400} = 0.175$

## Test per la differenza tra proporzioni

### Campioni di grandi dimensioni: Esempio II

- Stima pooled della proporzione

$$\hat{\pi} = \frac{800 \cdot 0.25 + 400 \cdot 0.175}{800 + 400} = \frac{200 + 70}{1200} = \frac{270}{1200} = 0.225$$

- Livello di significatività:  $\alpha = 0.05 \Rightarrow z_{0.05} = 1.645$
- Regione rifiuto:  $RC_{0.05} = Z \leq -1.645$
- Valore osservato della statistica test

$$\begin{aligned} z_{oss} &= \frac{(\hat{\pi}_2 - \hat{\pi}_1) - 0}{\sqrt{\hat{\pi}(1 - \hat{\pi})\left(\frac{1}{n_1} + \frac{1}{n_2}\right)}} = \frac{0.175 - 0.25}{\sqrt{0.225 \cdot (1 - 0.225)\left(\frac{1}{800} + \frac{1}{400}\right)}} \\ &= \frac{-0.075}{\sqrt{0.1744(0.00125 + 0.0025)}} = \frac{-0.075}{\sqrt{0.0006}} = \frac{0.075}{0.0256} = -2.933 \end{aligned}$$

- Decisione: Il valore osservato della statistica test appartiene alla regione di rifiuto:  $z_{oss} = -2.933 \leq -1.645 = -z_{0.05} \implies$  I dati mostrano evidenza contraria all'ipotesi nulla al livello di significatività del 5%
- $P$ -valore (approssimato) =  $P(Z \leq -2.933; H_0) = 0.00168$  ( $p$ -valore piccolo)