

# Test non parametrici

Federico Plazzi

19 Novembre 2015

Cos'è un test non parametrico?

# Cos'è un test non parametrico?

## Idea di base

- ▶ **Distribuzione normale:** è governata solo dalla sua media e dalla sua deviazione standard, ossia da due *parametri*. Diciamo quindi che un test che si basa su una distribuzione normale è un test *parametrico*.

# Cos'è un test non parametrico?

## Idea di base

- ▶ **Distribuzione normale:** è governata solo dalla sua media e dalla sua deviazione standard, ossia da due *parametri*. Diciamo quindi che un test che si basa su una distribuzione normale è un test *parametrico*.
- ▶ Ad esempio, il test t è un test parametrico!

# Cos'è un test non parametrico?

## Idea di base

- ▶ **Distribuzione normale:** è governata solo dalla sua media e dalla sua deviazione standard, ossia da due *parametri*. Diciamo quindi che un test che si basa su una distribuzione normale è un test *parametrico*.
- ▶ Ad esempio, il test t è un test parametrico!
- ▶ **Ma cosa succede quando non possiamo sapere se la distribuzione della popolazione non è normale o non ne siamo sicuri?**

# Cos'è un test non parametrico?

## Idea di base

- ▶ **Distribuzione normale:** è governata solo dalla sua media e dalla sua deviazione standard, ossia da due *parametri*. Diciamo quindi che un test che si basa su una distribuzione normale è un test *parametrico*.
- ▶ Ad esempio, il test t è un test parametrico!
- ▶ **Ma cosa succede quando non possiamo sapere se la distribuzione della popolazione non è normale o non ne siamo sicuri?**
- ▶ Il test t ha anche altre ipotesi: che il campione od i campioni siano estratti a caso ed indipendentemente dalla popolazione e che le rilevazioni siano, o possano essere, continue (delle altezze o dei pesi, per esempio, non dei voti o dei “vero/falso”).

# Cos'è un test non parametrico?

## Idea di base

- ▶ **Distribuzione normale:** è governata solo dalla sua media e dalla sua deviazione standard, ossia da due *parametri*. Diciamo quindi che un test che si basa su una distribuzione normale è un test *parametrico*.
- ▶ Ad esempio, il test t è un test parametrico!
- ▶ **Ma cosa succede quando non possiamo sapere se la distribuzione della popolazione non è normale o non ne siamo sicuri?**
- ▶ Il test t ha anche altre ipotesi: che il campione od i campioni siano estratti a caso ed indipendentemente dalla popolazione e che le rilevazioni siano, o possano essere, continue (delle altezze o dei pesi, per esempio, non dei voti o dei “vero/falso”).
- ▶ **Se queste condizioni non ci sono, useremo un test non parametrico!**

# Wilcoxon signed-rank test



# Wilcoxon signed-rank test

## Quando si usa?

- ▶ Si usa per due campioni appaiati od autoappaiati (per esempio, “prima-dopo”):

# Wilcoxon signed-rank test

## Quando si usa?

- ▶ Si usa per due campioni appaiati od autoappaiati (per esempio, “prima-dopo”):
- ▶ si usa cioè quando voglio vedere se ci sono delle differenze significative tra due situazioni, individuo per individuo.

# Wilcoxon signed-rank test

## Quando si usa?

- ▶ Si usa per due campioni appaiati od autoappaiati (per esempio, “prima-dopo”):
- ▶ si usa cioè quando voglio vedere se ci sono delle differenze significative tra due situazioni, individuo per individuo.
- ▶ Se la distribuzione della popolazione da cui provengono i campioni è normale, possiamo usare un test  $t$  per due campioni appaiati:

# Wilcoxon signed-rank test

## Quando si usa?

- ▶ Si usa per due campioni appaiati od autoappaiati (per esempio, “prima-dopo”):
- ▶ si usa cioè quando voglio vedere se ci sono delle differenze significative tra due situazioni, individuo per individuo.
- ▶ Se la distribuzione della popolazione da cui provengono i campioni è normale, possiamo usare un test t per due campioni appaiati:
- ▶ usiamo cioè il test t per validare l'ipotesi nulla che le differenze individuo per individuo provengano da una popolazione con media = 0.

# Wilcoxon signed-rank test

## Quando si usa?

- ▶ Si usa per due campioni appaiati od autoappaiati (per esempio, “prima-dopo”):
- ▶ si usa cioè quando voglio vedere se ci sono delle differenze significative tra due situazioni, individuo per individuo.
- ▶ Se la distribuzione della popolazione da cui provengono i campioni è normale, possiamo usare un test t per due campioni appaiati:
- ▶ usiamo cioè il test t per validare l'ipotesi nulla che le differenze individuo per individuo provengano da una popolazione con media = 0.
- ▶ Se però non siamo sicuri della normalità della popolazione, usiamo il signed-rank test di Wilcoxon.

# La procedura

## La procedura

1. Calcolo tutte le differenze  $\Delta_{AB}$  tra campione A e campione B, individuo per individuo.

## La procedura

1. Calcolo tutte le differenze  $\Delta_{AB}$  tra campione A e campione B, individuo per individuo.
2. Passo al valore assoluto ( $|\Delta_{AB}|$ ).



## La procedura

1. Calcolo tutte le differenze  $\Delta_{AB}$  tra campione A e campione B, individuo per individuo.
2. Passo al valore assoluto ( $|\Delta_{AB}|$ ).
3. Assegno ad ogni differenza in valore assoluto il suo rango (*rank*)  $r_{\Delta_{AB}}$ , partendo dalla più piccola (escludendo gli zeri e mediando per i pareggi).

## La procedura

1. Calcolo tutte le differenze  $\Delta_{AB}$  tra campione A e campione B, individuo per individuo.
2. Passo al valore assoluto ( $|\Delta_{AB}|$ ).
3. Assegno ad ogni differenza in valore assoluto il suo rango (*rank*)  $r_{\Delta_{AB}}$ , partendo dalla più piccola (escludendo gli zeri e mediando per i pareggi).
4. Associao ad ogni rango il segno della differenza originale (*signed-rank*).

## La procedura

1. Calcolo tutte le differenze  $\Delta_{AB}$  tra campione A e campione B, individuo per individuo.
2. Passo al valore assoluto ( $|\Delta_{AB}|$ ).
3. Assegno ad ogni differenza in valore assoluto il suo rango (*rank*)  $r_{\Delta_{AB}}$ , partendo dalla più piccola (escludendo gli zeri e mediando per i pareggi).
4. Associo ad ogni rango il segno della differenza originale (*signed-rank*).
5. Sommo i ranghi con i loro segni:

## La procedura

1. Calcolo tutte le differenze  $\Delta_{AB}$  tra campione A e campione B, individuo per individuo.
2. Passo al valore assoluto ( $|\Delta_{AB}|$ ).
3. Assegno ad ogni differenza in valore assoluto il suo rango (*rank*)  $r_{\Delta_{AB}}$ , partendo dalla più piccola (escludendo gli zeri e mediando per i pareggi).
4. Associao ad ogni rango il segno della differenza originale (*signed-rank*).
5. Sommo i ranghi con i loro segni:

$$W = \sum_{i=1}^N r_{i\Delta_{AB}} \quad (1)$$

dove  $r_{i\Delta_{AB}}$  è il rango con segno della differenza misurata per l' $i$ -esimo individuo tra campione A e campione B ed  $N$  è la dimensione dei campioni.

Il test

## Il test

Solito trucco...

- ▶ Ancora una volta,  $W$  si distribuisce in modo normale!

# Il test

## Solito trucco...

- ▶ Ancora una volta,  $W$  si distribuisce in modo normale!
- ▶ Ancora una volta, quindi, possiamo usare  $Z$  per vedere dove sta il nostro  $W$  nella normale di tutti i  $W$ ...

# Il test

Solito trucco...

- ▶ Ancora una volta,  $W$  si distribuisce in modo normale!
- ▶ Ancora una volta, quindi, possiamo usare  $Z$  per vedere dove sta il nostro  $W$  nella normale di tutti i  $W$ ...
- ▶

$$\mu_W = 0 \quad (2)$$



## Il test

### Solito trucco...

- ▶ Ancora una volta,  $W$  si distribuisce in modo normale!
- ▶ Ancora una volta, quindi, possiamo usare  $Z$  per vedere dove sta il nostro  $W$  nella normale di tutti i  $W$ ...



$$\mu_W = 0 \quad (2)$$



$$\sigma_W = \sqrt{\frac{N \cdot (N + 1) \cdot (2N + 1)}{6}} \quad (3)$$

## Il test

Solito trucco...

- ▶ Ancora una volta,  $W$  si distribuisce in modo normale!
- ▶ Ancora una volta, quindi, possiamo usare  $Z$  per vedere dove sta il nostro  $W$  nella normale di tutti i  $W$ ...



$$\mu_W = 0 \quad (2)$$



$$\sigma_W = \sqrt{\frac{N \cdot (N + 1) \cdot (2N + 1)}{6}} \quad (3)$$



$$Z = \frac{(W - \mu_W) \pm 0.5}{\sigma_W} = \frac{W \pm 0.5}{\sqrt{\frac{N \cdot (N + 1) \cdot (2N + 1)}{6}}} \quad (4)$$

## Il test

### Solito trucco...

- ▶ Ancora una volta,  $W$  si distribuisce in modo normale!
- ▶ Ancora una volta, quindi, possiamo usare  $Z$  per vedere dove sta il nostro  $W$  nella normale di tutti i  $W$ ...



$$\mu_W = 0 \quad (2)$$



$$\sigma_W = \sqrt{\frac{N \cdot (N + 1) \cdot (2N + 1)}{6}} \quad (3)$$



$$z = \frac{(W - \mu_W) \pm 0.5}{\sigma_W} = \frac{W \pm 0.5}{\sqrt{\frac{N \cdot (N + 1) \cdot (2N + 1)}{6}}} \quad (4)$$

- ▶  $\pm 0.5$  è una “correzione di continuità” e prende il segno meno se  $(W - \mu_W) = W > 0$  e viceversa.

# Test di Mann e Whitney

a.k.a. Wilcoxon rank-sum test

# Test di Mann e Whitney

a.k.a. Wilcoxon rank-sum test

Quando si usa?

- ▶ Si usa per due campioni indipendenti:

# Test di Mann e Whitney

a.k.a. Wilcoxon rank-sum test

## Quando si usa?

- ▶ Si usa per due campioni indipendenti:
- ▶ si usa cioè quando voglio vedere se ci sono delle differenze significative tra due campioni.

# Test di Mann e Whitney

a.k.a. Wilcoxon rank-sum test

## Quando si usa?

- ▶ Si usa per due campioni indipendenti:
- ▶ si usa cioè quando voglio vedere se ci sono delle differenze significative tra due campioni.
- ▶ Se la distribuzione della popolazione da cui provengono i campioni è normale, possiamo usare un test t per due campioni indipendenti:

# Test di Mann e Whitney

a.k.a. Wilcoxon rank-sum test

## Quando si usa?

- ▶ Si usa per due campioni indipendenti:
- ▶ si usa cioè quando voglio vedere se ci sono delle differenze significative tra due campioni.
- ▶ Se la distribuzione della popolazione da cui provengono i campioni è normale, possiamo usare un test t per due campioni indipendenti:
- ▶ usiamo cioè il test t per validare l'ipotesi nulla che le medie dei due campioni siano identiche.



# Test di Mann e Whitney

a.k.a. Wilcoxon rank-sum test

## Quando si usa?

- ▶ Si usa per due campioni indipendenti:
- ▶ si usa cioè quando voglio vedere se ci sono delle differenze significative tra due campioni.
- ▶ Se la distribuzione della popolazione da cui provengono i campioni è normale, possiamo usare un test t per due campioni indipendenti:
- ▶ usiamo cioè il test t per validare l'ipotesi nulla che le medie dei due campioni siano identiche.
- ▶ Se però non siamo sicuri della normalità della popolazione, usiamo il test di Mann e Whitney.

# La procedura

# La procedura

1. Metto tutte le osservazioni insieme in un unico campione.

# La procedura

1. Metto tutte le osservazioni insieme in un unico campione.
2. Assegno ad ogni osservazione il suo rango  $r$ , partendo dalla più piccola (mediando per i pareggi).

## La procedura

1. Metto tutte le osservazioni insieme in un unico campione.
2. Assegno ad ogni osservazione il suo rango  $r$ , partendo dalla più piccola (mediando per i pareggi).
3. Ridivido i ranghi nei due campioni originali A e B.

## La procedura

1. Metto tutte le osservazioni insieme in un unico campione.
2. Assegno ad ogni osservazione il suo rango  $r$ , partendo dalla più piccola (mediando per i pareggi).
3. Ridivido i ranghi nei due campioni originali A e B.
4. Sommo i ranghi di ogni campione:

## La procedura

1. Metto tutte le osservazioni insieme in un unico campione.
2. Assegno ad ogni osservazione il suo rango  $r$ , partendo dalla più piccola (mediando per i pareggi).
3. Ridivido i ranghi nei due campioni originali A e B.
4. Sommo i ranghi di ogni campione:

$$T_A = \sum_{i=1}^{N_A} r_i \quad (5)$$

$$T_B = \sum_{j=1}^{N_B} r_j \quad (6)$$

dove  $r_i$  è il rango dell' $i$ -esima osservazione del campione A,  $N_A$  è la dimensione del campione A,  $r_j$  è il rango della  $j$ -esima osservazione del campione B ed  $N_B$  è la dimensione del campione B.

Il test



## Il test

Cosa ci aspettiamo da  $T_A$  e  $T_B$ ?

## Il test

Cosa ci aspettiamo da  $T_A$  e  $T_B$ ?

- ▶ La somma di  $N$  ranghi è data da

$$T = \sum_{i=1}^N r_i = \frac{N \cdot (N + 1)}{2} \quad (7)$$

## Il test

Cosa ci aspettiamo da  $T_A$  e  $T_B$ ?

- ▶ La somma di  $N$  ranghi è data da

$$T = \sum_{i=1}^N r_i = \frac{N \cdot (N + 1)}{2} \quad (7)$$

- ▶ Il rango medio, perciò, è

$$\mu_r = \frac{T}{N} = \frac{N \cdot (N + 1)}{2} \cdot \frac{1}{N} = \frac{N + 1}{2} \quad (8)$$

## Il test

Cosa ci aspettiamo da  $T_A$  e  $T_B$ ?

- ▶ La somma di  $N$  ranghi è data da

$$T = \sum_{i=1}^N r_i = \frac{N \cdot (N + 1)}{2} \quad (7)$$

- ▶ Il rango medio, perciò, è

$$\mu_r = \frac{T}{N} = \frac{N \cdot (N + 1)}{2} \cdot \frac{1}{N} = \frac{N + 1}{2} \quad (8)$$

- ▶ Ci aspettiamo quindi che

$$\overline{T}_A = \frac{N + 1}{2} \cdot N_A \quad (9)$$

$$\overline{T}_B = \frac{N + 1}{2} \cdot N_B \quad (10)$$

ll test

## Il test

Solito trucco...

- ▶ Tanto per cambiare,  $T_A$  e  $T_B$  si distribuiscono normalmente intorno alle loro medie  $\bar{T}_A$  e  $\bar{T}_B$ ...

## Il test

Solito trucco...

- ▶ Tanto per cambiare,  $T_A$  e  $T_B$  si distribuiscono normalmente intorno alle loro medie  $\bar{T}_A$  e  $\bar{T}_B$ ...
- ▶ Ancora una volta, quindi, possiamo usare  $Z$ ...

## Il test

Solito trucco...

- ▶ Tanto per cambiare,  $T_A$  e  $T_B$  si distribuiscono normalmente intorno alle loro medie  $\bar{T}_A$  e  $\bar{T}_B$ ...
- ▶ Ancora una volta, quindi, possiamo usare  $Z$ ...
- ▶

$$\sigma_T = \sqrt{\frac{N_A \cdot N_B \cdot (N + 1)}{12}} \quad (11)$$



## Il test

### Solito trucco...

- ▶ Tanto per cambiare,  $T_A$  e  $T_B$  si distribuiscono normalmente intorno alle loro medie  $\bar{T}_A$  e  $\bar{T}_B$ ...
- ▶ Ancora una volta, quindi, possiamo usare  $Z$ ...

$$\sigma_T = \sqrt{\frac{N_A \cdot N_B \cdot (N + 1)}{12}} \quad (11)$$

$$z = \frac{(T - \bar{T}) \pm 0.5}{\sigma_T} = \frac{(T - \bar{T}) \pm 0.5}{\sqrt{\frac{N_A \cdot N_B \cdot (N + 1)}{12}}} \quad (12)$$

## Il test

### Solito trucco...

- ▶ Tanto per cambiare,  $T_A$  e  $T_B$  si distribuiscono normalmente intorno alle loro medie  $\bar{T}_A$  e  $\bar{T}_B$ ...
- ▶ Ancora una volta, quindi, possiamo usare  $Z$ ...

$$\sigma_T = \sqrt{\frac{N_A \cdot N_B \cdot (N + 1)}{12}} \quad (11)$$

$$z = \frac{(T - \bar{T}) \pm 0.5}{\sigma_T} = \frac{(T - \bar{T}) \pm 0.5}{\sqrt{\frac{N_A \cdot N_B \cdot (N + 1)}{12}}} \quad (12)$$

- ▶  $\pm 0.5$  è la “correzione di continuità” e prende sempre il segno meno se  $(T - \bar{T}) > 0$  e viceversa.

## Il test

### Solito trucco...

- ▶ Tanto per cambiare,  $T_A$  e  $T_B$  si distribuiscono normalmente intorno alle loro medie  $\bar{T}_A$  e  $\bar{T}_B$ ...
- ▶ Ancora una volta, quindi, possiamo usare  $Z$ ...

$$\sigma_T = \sqrt{\frac{N_A \cdot N_B \cdot (N + 1)}{12}} \quad (11)$$

$$z = \frac{(T - \bar{T}) \pm 0.5}{\sigma_T} = \frac{(T - \bar{T}) \pm 0.5}{\sqrt{\frac{N_A \cdot N_B \cdot (N + 1)}{12}}} \quad (12)$$

- ▶  $\pm 0.5$  è la “correzione di continuità” e prende sempre il segno meno se  $(T - \bar{T}) > 0$  e viceversa.
- ▶ Il risultato non cambia se considero il campione A od il campione B, perché risultano speculari! Naturalmente, però, dobbiamo sapere in che direzione stiamo effettuando il test...