

## 7. Test d'ipotesi

Un tipico problema che ci si può trovare ad affrontare è il seguente:

Faccio una certa ipotesi (che indico con  $H_0$  e che chiamo **ipotesi nulla**). In base ai dati che ho a disposizione devo decidere se accettare o rifiutare la verità di questa ipotesi.

Si potranno verificare quattro situazioni alternative:

1. L'ipotesi è vera e l'accetto  $\rightarrow$  bene
2. L'ipotesi è vera ma in base ai dati la rifiuto  $\rightarrow$  in questo caso si dice che si commette **errore di prima specie**
3. L'ipotesi è falsa ma in base ai dati la accetto  $\rightarrow$  in questo caso si dice che si commette **errore di seconda specie**
4. L'ipotesi è falsa e la rifiuto  $\rightarrow$  bene

Per chiarirsi le idee vediamo prima un esempio.

**Esempio 7.0.2.** Ho una moneta. Voglio verificare se è bilanciata o meno. La lancio  $n$

volte. Pongo  $X_i = \begin{cases} 1 & \text{se all}'i\text{-esimo lancio esce testa,} \\ 0 & \text{se all}'i\text{-esimo lancio esce croce.} \end{cases}$ ,  $i = 1, \dots, n$ . Ho un campione

statistico bernoulliano di numerosità  $n$  e parametro  $p \in [0, 1]$  incognito, dove  $p$  è la probabilità che esca testa in un singolo lancio.

L'ipotesi nulla che dobbiamo testare è

$$H_0) \quad p = 0.5.$$

Facciamo dunque  $n$  lanci. Otteniamo  $k$  teste ed  $n - k$  croci:

$$x_1, x_2, \dots, x_n \quad \text{dove} \quad x_i = \begin{cases} 1 & \text{se all}'i\text{-esimo lancio esce testa,} \\ 0 & \text{se all}'i\text{-esimo lancio esce croce.} \end{cases}$$

$$\text{e dunque } \bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = \frac{k}{n}.$$

Stabilisco una distanza massima  $\varepsilon$  tra  $\bar{x}$  e 0.5 entro la quale accettare l'ipotesi  $p = 0.5$  e oltre la quale rifiutarla. Ovvero: accetto  $H_0$  se  $|\bar{x} - 0.5| < \varepsilon$  e la rifiuto se  $|\bar{x} - 0.5| \geq \varepsilon$ .

cioè se  $\left| \sum_{i=1}^n x_i - \frac{n}{2} \right| \geq n\varepsilon$ . Quanto vale la probabilità di commettere errore di prima specie, ovvero di rifiutarla quando esse invece è vera?

Commetto errore di prima specie con probabilità

$$\alpha := \mathbb{P} \left( \left| \sum_{i=1}^n X_i - \frac{n}{2} \right| \geq n\varepsilon \right).$$

Poiché le v.a.  $X_i$  sono indipendenti e seguono tutte la distribuzione di Bernoulli di parametro  $p$ , la v.a.  $Y := \sum_{i=1}^n X_i$  è una v.a. binomiale di parametri  $n$  e  $p$ . Se l'ipotesi  $H_0$  è vera, allora  $p = 0.5$  dunque:  $Y \sim B(n, 0.5)$  e

$$\alpha := \mathbb{P} \left( \left| Y - \frac{n}{2} \right| \geq n\varepsilon \right) = \mathbb{P} \left( Y \geq \frac{n}{2} + n\varepsilon \right) + \mathbb{P} \left( Y \leq \frac{n}{2} - n\varepsilon \right)$$

Vediamo alcuni casi

- $n = 50, \varepsilon = 0.1$

$$\alpha = \mathbb{P}(Y \geq 25 + 5) + \mathbb{P}(Y \leq 25 - 5) = 1 - F_Y(29) + F_Y(20).$$

```
> 1 - pbinom(c(29), size=50, prob=0.5, lower.tail=TRUE)
+ pbinom(c(20), size=50, prob=0.5, lower.tail=TRUE)
[1] 0.2026388
```

- $n = 100, \varepsilon = 0.1$

$$\alpha = \mathbb{P}(Y \geq 50 + 10) + \mathbb{P}(Y \leq 50 - 10) = 1 - F_Y(59) + F_Y(40).$$

```
> 1 - pbinom(c(59), size=100, prob=0.5, lower.tail=TRUE)
+ pbinom(c(40), size=100, prob=0.5, lower.tail=TRUE)
[1] 0.05688793
```

- $n = 200, \varepsilon = 0.1$

$$\alpha = \mathbb{P}(Y \geq 100 + 20) + \mathbb{P}(Y \leq 100 - 20) = 1 - F_Y(119) + F_Y(80).$$

```
> 1 - pbinom(c(119), size=200, prob=0.5, lower.tail=TRUE)
+ pbinom(c(80), size=200, prob=0.5, lower.tail=TRUE)
[1] 0.005685156
```

- $n = 300, \varepsilon = 0.1$

$$\alpha = \mathbb{P}(Y \geq 150 + 30) + \mathbb{P}(Y \leq 150 - 30) = 1 - F_Y(179) + F_Y(120).$$

```
> 1 - pbinom(c(179), size=300, prob=0.5, lower.tail=TRUE)
+ pbinom(c(120), size=300, prob=0.5, lower.tail=TRUE)
[1] 0.00063422
```

- $n = 50, \varepsilon = 0.05$

$$\alpha = \mathbb{P}(Y \geq 25 + 2.5) + \mathbb{P}(Y \leq 25 - 2.5) = 1 - F_Y(27) + F_Y(22).$$

```
> 1 - pbinom(c(27), size=50, prob=0.5, lower.tail=TRUE)
+ pbinom(c(22), size=50, prob=0.5, lower.tail=TRUE)
[1] 0.4798877
```

- $n = 100, \varepsilon = 0.05$

$$\alpha = \mathbb{P}(Y \geq 50 + 5) + \mathbb{P}(Y \leq 50 - 5) = 1 - F_Y(54) + F_Y(45).$$

```
> 1 - pbinom(c(54), size=100, prob=0.5, lower.tail=TRUE)
+ pbinom(c(45), size=100, prob=0.5, lower.tail=TRUE)
[1] 0.3682016
```

- $n = 200, \varepsilon = 0.05$

$$\alpha = \mathbb{P}(Y \geq 100 + 10) + \mathbb{P}(Y \leq 100 - 10) = 1 - F_Y(109) + F_Y(90).$$

```
> 1 - pbinom(c(109), size=200, prob=0.5, lower.tail=TRUE)
+ pbinom(c(90), size=200, prob=0.5, lower.tail=TRUE)
[1] 0.178964
```

- $n = 300, \varepsilon = 0.05$

$$\alpha = \mathbb{P}(Y \geq 150 + 15) + \mathbb{P}(Y \leq 150 - 15) = 1 - F_Y(164) + F_Y(135).$$

```
> 1 - pbinom(c(164), size=300, prob=0.5, lower.tail=TRUE)
+ pbinom(c(135), size=300, prob=0.5, lower.tail=TRUE)
[1] 0.0939037
```

- $n = 400, \varepsilon = 0.05$


$$\alpha = \mathbb{P}(Y \geq 200 + 20) + \mathbb{P}(Y \leq 200 - 20) = 1 - F_Y(219) + F_Y(180).$$

```
> 1 - pbinom(c(219), size=400, prob=0.5, lower.tail=TRUE)
+ pbinom(c(180), size=400, prob=0.5, lower.tail=TRUE)
[1] 0.05104022
```

- $n = 500, \varepsilon = 0.05$

$$\alpha = \mathbb{P}(Y \geq 250 + 25) + \mathbb{P}(Y \leq 250 - 25) = 1 - F_Y(264) + F_Y(225).$$

```
> 1 - pbinom(c(264), size=500, prob=0.5, lower.tail=TRUE)
+ pbinom(c(225), size=500, prob=0.5, lower.tail=TRUE)
[1] 0.02832616
```

Figura 7.1:  $\beta(p)$ 

Solitamente si vuole controllare (nel senso di tenere bassa, inferiore a 0.1 o a 0.05) la probabilità  $\alpha$  di commettere errore di prima specie. Tale probabilità viene detta *livello di significatività* del test. Fissato il livello di significatività  $\alpha$ , la numerosità  $n$  e la soglia di tolleranza  $\varepsilon$  andranno scelti di conseguenza come visto negli esempi precedenti.

Inoltre, fissato  $\alpha$ , ci chiediamo quanto valga la probabilità di commettere errore di seconda specie, ovvero di accettare  $H_0$  quand'essa invece è falsa.

Se  $H_0$  è falsa, allora la probabilità di ottenere testa non è 0.5 ma assume un valore  $p \neq 0.5$  (ignoto) e dunque  $Y \sim B(n, p)$  e io accetto  $H_0$  con probabilità

$$\beta(p) := \mathbb{P}_p \left( \left| Y - \frac{n}{2} \right| < n\varepsilon \right) = \mathbb{P}_p \left( Y < \frac{n}{2} + n\varepsilon \right) - \mathbb{P}_p \left( Y \leq \frac{n}{2} - n\varepsilon \right)$$

Si calcola  $\beta(p)$  per vari valori di  $p$ . La funzione  $\beta(p)$  è detta **curva operativa caratteristica (OC)** mentre  $1 - \beta(p)$  cioè la probabilità di rifiutare  $H_0$  quand'essa in effetti è falsa e il parametro incognito vale  $p$ , è detta **potenza del test**.

**Esempio 7.0.3.** Consideriamo la solita moneta e stavolta vogliamo vedere se è più probabile ottenere testa che ottenere croce. Vogliamo cioè testare l'ipotesi nulla

$$H_0) \quad p \leq 0.5$$

Un test di questo tipo è detto *test unilaterale*.

Stabilisco una tolleranza massima  $\varepsilon$  entro la quale accettare l'ipotesi  $p \leq 0.5$  e oltre la quale rifiutarla. Ovvero: accetto  $H_0$  se  $\bar{x} < 0.5 + \varepsilon$  e la rifiuto se  $\bar{x} \geq 0.5 + \varepsilon$  cioè se  $\sum_{i=1}^n x_i \geq \frac{n}{2} + n\varepsilon$ . Quanto vale la probabilità di commettere errore di prima specie, ovvero di rifiutarla quando essa invece è vera?

Commetto errore di prima specie con probabilità

$$\alpha := \mathbb{P} \left( Y \geq \frac{n}{2} + n\varepsilon \right).$$

Se  $H_0$  è vera, allora  $Y \sim B(n, p)$  per qualche  $p \leq 0.5$ . Indico  $F_Y^p$  la sua funzione di ripartizione. Vediamo alcuni casi

- $n = 50, \varepsilon = 0.1$

$$\alpha = 1 - \mathbb{P}(Y < 25 + 5) = 1 - F_Y^p(29) \leq \sup_{p \in [0, 0.5]} \{1 - F_Y^p(29)\} = 1 - F_Y^{0.5}(29)$$

> 1 - pbinom(c(29), size=50, prob=0.5, lower.tail=TRUE)

- $n = 100, \varepsilon = 0.1$

$$\alpha = 1 - \mathbb{P}(Y < 50 + 10) = 1 - F_Y^p(59) \leq \sup_{p \in [0, 0.5]} \{1 - F_Y^p(59)\} = 1 - F_Y^{0.5}(59).$$

> 1 - pbinom(c(59), size=100, prob=0.5, lower.tail=TRUE)

[1] 0.02844397

- $n = 200, \varepsilon = 0.1$

$$\alpha = 1 - \mathbb{P}(Y < 100 + 20) = 1 - F_Y^p(119) \leq \sup_{p \in [0, 0.5]} \{1 - F_Y^p(119)\} = 1 - F_Y^{0.5}(119).$$

> 1 - pbinom(c(119), size=200, prob=0.5, lower.tail=TRUE)

[1] 0.002842578

- $n = 50, \varepsilon = 0.05$

$$\alpha = 1 - \mathbb{P}(Y < 25 + 2.5) = 1 - F_Y^p(27) \leq \sup_{p \in [0, 0.5]} \{1 - F_Y^p(27)\} = 1 - F_Y^{0.5}(27)$$

> 1 - pbinom(c(27), size=50, prob=0.5, lower.tail=TRUE)

[1] 0.2399438

- $n = 100, \varepsilon = 0.05$

$$\alpha = 1 - \mathbb{P}(Y < 50 + 5) = 1 - F_Y^p(54) \leq \sup_{p \in [0, 0.5]} \{1 - F_Y^p(54)\} = 1 - F_Y^{0.5}(54)$$

```
> 1 - pbinom(c(55), size=100, prob=0.5, lower.tail=TRUE)
[1] 0.1841008
```

- $n = 200, \varepsilon = 0.05$

$$\alpha = 1 - \mathbb{P}(Y < 100 + 10) = 1 - F_Y^p(109) \leq \sup_{p \in [0, 0.5]} \{1 - F_Y^p(109)\} = 1 - F_Y^{0.5}(109).$$

```
> 1 - pbinom(c(109), size=200, prob=0.5, lower.tail=TRUE)
[1] 0.08948202
```

- $n = 300, \varepsilon = 0.05$

$$\alpha = 1 - \mathbb{P}(Y < 150 + 15) = 1 - F_Y^p(164) \leq \sup_{p \in [0, 0.5]} \{1 - F_Y^p(164)\} = 1 - F_Y^{0.5}(145).$$

```
> 1 - pbinom(c(164), size=300, prob=0.5, lower.tail=TRUE)
[1] 0.04695185
```

In generale dunque un test d'ipotesi ha la seguente struttura:

1. Si ha un campione statistico  $X_1, X_2, \dots, X_n, X_i \sim \mathcal{D}(\theta)$ , dove  $\theta$  è un parametro reale.
2. Si formula un'ipotesi (che si chiama *ipotesi nulla* e si indica con  $H_0$ ), solitamente nella forma

$$H_0) \quad \theta \in \Theta_0$$

dove  $\Theta_0$  è un sottoinsieme di  $\mathbb{R}$ .

3. Si formula una regola di decisione per l'accettazione o il rifiuto di  $H_0$ . La regola di decisione è di questo tipo: si sceglie una statistica che fornisce una stima del parametro  $\theta$  e un sottoinsieme  $A \subset \mathbb{R}$ , detto *regione di accettazione*. Dopodiché
  - se  $Y \in A$ , allora si accetta  $H_0$ ;
  - se  $Y \notin A$ , allora si rifiuta  $H_0$ .

L'insieme  $A^c := \mathbb{R} \setminus A$  è detto *regione di rifiuto*.

Come già detto, è solitamente richiesto di *limitare* la probabilità di commettere errore di prima specie, cioè di limitare la probabilità di rifiutare l'ipotesi nulla quando essa è vera. Vediamo come questo sia possibile nel caso di campioni gaussiani.

## 7.1. Test d'ipotesi per la media di campioni gaussiani

### 7.1.1. Campione gaussiano di cui è nota la varianza

#### Test bilaterale

Sia  $X_1, X_2, \dots, X_n$  un campione gaussiano di media  $\mu$  incognita e varianza  $\sigma^2$  nota. Vogliamo testare l'ipotesi nulla

$$H_0) \quad \mu = \mu_0.$$

$H_0$  è vera se e solo se  $\mathbb{E}[\bar{X}] = \mu_0$  dunque accetto l'ipotesi nulla  $H_0$  se la media campionaria si discosta da  $\mu_0$  per meno di un valore soglia  $\varepsilon$  ovvero se  $|\bar{x} - \mu_0| < \varepsilon$  e la rifiuto altrimenti.

Il livello di di significatività (cioè la probabilità di commettere un errore di prima specie) è allora

$$\alpha = \mathbb{P}_{\mu_0} (|\bar{X} - \mu_0| \geq \varepsilon)$$

dove il pedice  $\mu_0$  indica che  $H_0$  è vera, cioè che  $\mu = \mu_0$ .

Se  $H_0$  è vera,  $\bar{X} \sim \mathcal{N}\left(\mu_0, \frac{\sigma^2}{n}\right)$  e  $Z := \frac{\bar{X} - \mu_0}{\frac{\sigma}{\sqrt{n}}} \sim \mathcal{N}(0, 1)$ . Dunque

$$\begin{aligned} \alpha &= \mathbb{P}_{\mu_0} (|\bar{X} - \mu_0| \geq \varepsilon) = \mathbb{P}_{\mu_0} \left( \frac{|\bar{X} - \mu_0|}{\frac{\sigma}{\sqrt{n}}} \geq \frac{\varepsilon}{\frac{\sigma}{\sqrt{n}}} \right) = \mathbb{P} \left( |Z| \geq \frac{\varepsilon\sqrt{n}}{\sigma} \right) \\ &= \mathbb{P} \left( Z \geq \frac{\varepsilon\sqrt{n}}{\sigma} \right) + \mathbb{P} \left( Z \leq -\frac{\varepsilon\sqrt{n}}{\sigma} \right) = 1 - \Phi \left( \frac{\varepsilon\sqrt{n}}{\sigma} \right) + \Phi \left( -\frac{\varepsilon\sqrt{n}}{\sigma} \right) \\ &= 2 \left( 1 - \Phi \left( \frac{\varepsilon\sqrt{n}}{\sigma} \right) \right) \end{aligned}$$

Se voglio fissare a priori  $\alpha$ , deve essere allora  $\Phi \left( \frac{\varepsilon\sqrt{n}}{\sigma} \right) = 1 - \frac{\alpha}{2}$  cioè deve essere  $\frac{\varepsilon\sqrt{n}}{\sigma} = z_{1-\frac{\alpha}{2}}$  e dunque devo scegliere

$$\varepsilon = \frac{\sigma}{\sqrt{n}} z_{1-\frac{\alpha}{2}}.$$

Presi i dati  $x_1, x_2, \dots, x_n$ , sia dunque  $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$  la loro media. Accetto  $H_0$  se

$$|\bar{x} - \mu_0| < \frac{\sigma}{\sqrt{n}} z_{1-\frac{\alpha}{2}}$$

e la rifiuto altrimenti.

**Test unilaterale**

Sia  $X_1, X_2, \dots, X_n$  un campione gaussiano di media  $\mu$  incognita e varianza  $\sigma^2$  nota. Vogliamo testare l'ipotesi nulla

$$H_0) \quad \mu \leq \mu_0.$$

Accetto l'ipotesi nulla  $H_0$  se la media campionaria è inferiore a  $\mu_0 + \varepsilon$  cioè se  $\bar{x} < \mu_0 + \varepsilon$ .

La probabilità di commettere un errore di prima specie è allora

$$\mathbb{P}_{\mu \leq \mu_0} (\bar{X} \geq \mu_0 + \varepsilon).$$

dove il pedice indica che la media del campione è  $\mu \leq \mu_0$ .

Poiché  $\bar{X} \sim \mathcal{N}\left(\mu, \frac{\sigma^2}{n}\right)$  e  $Z := \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \sim \mathcal{N}(0, 1)$ , si ha

$$\begin{aligned} \mathbb{P}_{\mu \leq \mu_0} (\bar{X} \geq \mu_0 + \varepsilon) &= \mathbb{P}_{\mu \leq \mu_0} \left( \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \geq \frac{\mu_0 - \mu + \varepsilon}{\frac{\sigma}{\sqrt{n}}} \right) = \mathbb{P} \left( Z \geq \frac{(\mu_0 - \mu + \varepsilon)\sqrt{n}}{\sigma} \right) \\ &= 1 - \mathbb{P} \left( Z \leq \frac{(\mu_0 - \mu + \varepsilon)\sqrt{n}}{\sigma} \right) = 1 - \Phi \left( \frac{(\mu_0 - \mu + \varepsilon)\sqrt{n}}{\sigma} \right) \leq 1 - \Phi \left( \frac{\varepsilon\sqrt{n}}{\sigma} \right). \end{aligned}$$

Se voglio limitare superiormente  $\mathbb{P}_{\mu \leq \mu_0} (\bar{X} > \mu_0 + \varepsilon)$ , cioè se voglio

$$\mathbb{P}_{\mu \leq \mu_0} (\bar{X} > \mu_0 + \varepsilon) \leq \alpha \quad \forall \mu \leq \mu_0$$

scelgo  $\varepsilon$  in modo da avere  $1 - \Phi \left( \frac{\varepsilon\sqrt{n}}{\sigma} \right) = \alpha$  cioè  $\frac{\varepsilon\sqrt{n}}{\sigma} = z_{1-\alpha}$  e dunque scelgo

$$\varepsilon = \frac{\sigma}{\sqrt{n}} z_{1-\alpha}.$$

Presi i dati  $x_1, x_2, \dots, x_n$ , sia dunque  $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$  la loro media. Accetto  $H_0$  se

$$\bar{x} < \mu_0 + \frac{\sigma}{\sqrt{n}} z_{1-\alpha}$$

e la rifiuto altrimenti.

**Test unilaterale**

Sia  $X_1, X_2, \dots, X_n$  un campione gaussiano di media  $\mu$  incognita e varianza  $\sigma^2$  nota. Vogliamo testare l'ipotesi nulla

$$H_0) \quad \mu \geq \mu_0.$$

Accetto l'ipotesi nulla  $H_0$  se la media campionaria è superiore a  $\mu_0 - \varepsilon$  cioè se  $\bar{x} > \mu_0 - \varepsilon$ .

La probabilità di commettere un errore di prima specie è allora

$$\mathbb{P}_{\mu \geq \mu_0} (\bar{X} \leq \mu_0 - \varepsilon).$$



Poiché  $\bar{X} \sim \mathcal{N}\left(\mu, \frac{\sigma^2}{n}\right)$ , e  $Z := \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \sim \mathcal{N}(0, 1)$ , si ha

$$\begin{aligned} \mathbb{P}_{\mu \geq \mu_0}(\bar{X} \leq \mu_0 - \varepsilon) &= \mathbb{P}_{\mu \geq \mu_0}\left(\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \leq \frac{\mu_0 - \mu - \varepsilon}{\frac{\sigma}{\sqrt{n}}}\right) = \mathbb{P}\left(Z \leq \frac{(\mu_0 - \mu - \varepsilon)\sqrt{n}}{\sigma}\right) \\ &= \Phi\left(\frac{(\mu_0 - \mu - \varepsilon)\sqrt{n}}{\sigma}\right) \leq \Phi\left(\frac{-\varepsilon\sqrt{n}}{\sigma}\right) = 1 - \Phi\left(\frac{\varepsilon\sqrt{n}}{\sigma}\right). \end{aligned}$$

Se voglio limitare superiormente  $\mathbb{P}_{\mu \geq \mu_0}(\bar{X} \leq \mu_0 - \varepsilon)$  cioè se voglio

$$\mathbb{P}_{\mu \geq \mu_0}(\bar{X} \leq \mu_0 - \varepsilon) \leq \alpha \quad \forall \mu \geq \mu_0$$

scelgo  $\varepsilon$  in modo da avere  $\Phi\left(\frac{\varepsilon\sqrt{n}}{\sigma}\right) = 1 - \alpha$  cioè  $\frac{\varepsilon\sqrt{n}}{\sigma} = z_{1-\alpha}$  e dunque scelgo

$$\varepsilon = \frac{\sigma}{\sqrt{n}} z_{1-\alpha}.$$

Presi i dati  $x_1, x_2, \dots, x_n$ , sia dunque  $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$  la loro media. Accetto  $H_0$  se

$$\bar{x} > \mu_0 - \frac{\sigma}{\sqrt{n}} z_{1-\alpha}$$

e la rifiuto altrimenti.

### 7.1.2. Campione gaussiano di cui non è nota la varianza

#### Test bilaterale

Sia  $X_1, X_2, \dots, X_n$  un campione gaussiano di media  $\mu$  e varianza  $\sigma^2$  entrambe ignote. Vogliamo testare l'ipotesi nulla

$$H_0) \quad \mu = \mu_0.$$

Sappiamo che, se  $\mu = \mu_0$ , allora  $T := \frac{(\bar{X} - \mu_0)\sqrt{n}}{S} \sim t(n-1)$ .

Inoltre  $H_0$  è vera se e solo se  $\mathbb{E}[\bar{X}] = \mu_0$  ovvero, per l'indipendenza di  $\bar{X}$  e  $S^2$ , se e solo se  $\mathbb{E}[T] = 0$ . Dunque accetto l'ipotesi nulla  $H_0$  se  $|T| \leq \varepsilon$ .

Il livello di di significatività (cioè la probabilità di commettere un errore di prima specie) è allora

$$\alpha = \mathbb{P}(|T| \geq \varepsilon).$$

Si ha quindi

$$\begin{aligned} \alpha &= \mathbb{P}(|T| \geq \varepsilon) = \mathbb{P}(T \geq \varepsilon) + \mathbb{P}(T \leq -\varepsilon) \\ &= 1 - F_T(\varepsilon) + F_T(-\varepsilon) = 2(1 - F_T(\varepsilon)) \end{aligned}$$

Se voglio fissare a priori  $\alpha$ , deve essere allora  $F_T(\varepsilon) = 1 - \frac{\alpha}{2}$  dunque devo scegliere

$$\varepsilon = t_{n-1, 1-\frac{\alpha}{2}}.$$

Presi i dati  $x_1, x_2, \dots, x_n$ , sia dunque  $t = \frac{(\bar{x} - \mu_0)\sqrt{n}}{\sqrt{s^2}}$  (dove  $\bar{x}$  e  $s$  indicano la media e la deviazione campionaria del campione, rispettivamente). Accetto  $H_0$  se

$$|t| \leq t_{n-1, 1-\frac{\alpha}{2}}$$

e la rifiuto altrimenti, ovvero accetto  $H_0$  se

$$\mu_0 - \frac{t_{n-1, 1-\frac{\alpha}{2}} s}{\sqrt{n}} \leq \bar{x} \leq \mu_0 + \frac{t_{n-1, 1-\frac{\alpha}{2}} s}{\sqrt{n}}$$

e la rifiuto altrimenti.

### Test unilaterale

Sia  $X_1, X_2, \dots, X_n$  un campione gaussiano di media  $\mu$  e varianza  $\sigma^2$  entrambe incognite. Vogliamo testare l'ipotesi nulla

$$H_0) \quad \mu \leq \mu_0.$$

Diamo la seguente regola di accettazione: accettiamo  $H_0$  se  $\frac{(\bar{X} - \mu_0)\sqrt{n}}{S} \leq \varepsilon$ .

La probabilità di commettere un errore di prima specie è allora

$$\mathbb{P}_{\mu \leq \mu_0} \left( \frac{(\bar{X} - \mu_0)\sqrt{n}}{S} > \varepsilon \right).$$

Se  $H_0$  è vera, allora  $\mu \leq \mu_0$  e dunque

$$\frac{(\bar{X} - \mu_0)\sqrt{n}}{S} \leq \frac{(\bar{X} - \mu)\sqrt{n}}{S} =: T \sim t(n-1).$$

Di conseguenza

$$\left\{ \frac{(\bar{X} - \mu_0)\sqrt{n}}{S} > \varepsilon \right\} \subset \left\{ \frac{(\bar{X} - \mu)\sqrt{n}}{S} > \varepsilon \right\}$$

Dunque, per ogni  $\mu \leq \mu_0$  si ha

$$\mathbb{P}_{\mu \leq \mu_0} \left( \frac{(\bar{X} - \mu_0)\sqrt{n}}{S} > \varepsilon \right) \leq \mathbb{P}_{\mu \leq \mu_0} \left( \frac{(\bar{X} - \mu)\sqrt{n}}{S} > \varepsilon \right) = \mathbb{P}(T > \varepsilon) = 1 - F_T(\varepsilon)$$

Se vogliamo stabilire il livello di significatività  $\alpha$  dovremmo scegliere  $\varepsilon$  in modo che

$$1 - F_T(\varepsilon) = \alpha$$

cioè  $\varepsilon = t_{n-1,1-\alpha}$ .

Presi i dati  $x_1, x_2, \dots, x_n$ , sia dunque  $t_0 = \frac{(\bar{x} - \mu_0)\sqrt{n}}{s}$ . Accetto  $H_0$  se

$$t_0 \leq t_{n-1,1-\alpha}$$

ovvero se

$$\bar{x} \leq \mu_0 + \frac{t_{n-1,1-\alpha} s}{\sqrt{n}}$$

e la rifiuto altrimenti.

### Test unilaterale

Sia  $X_1, X_2, \dots, X_n$  un campione gaussiano di media  $\mu$  e varianza  $\sigma^2$  entrambe incognite. Vogliamo testare l'ipotesi nulla

$$H_0) \quad \mu \geq \mu_0.$$

Diamo la seguente regola di accettazione: accettiamo  $H_0$  se  $\frac{(\bar{X} - \mu_0)\sqrt{n}}{S} \geq -\varepsilon$ .

La probabilità di commettere un errore di prima specie è allora

$$\mathbb{P}_{\mu \geq \mu_0} \left( \frac{(\bar{X} - \mu_0)\sqrt{n}}{S} < -\varepsilon \right).$$

Se  $H_0$  è vera, allora  $\mu \geq \mu_0$  e dunque

$$\frac{(\bar{X} - \mu_0)\sqrt{n}}{S} \geq \frac{(\bar{X} - \mu)\sqrt{n}}{S} =: T \sim t(n-1).$$

Di conseguenza

$$\left\{ \frac{(\bar{X} - \mu_0)\sqrt{n}}{S} < -\varepsilon \right\} \subset \left\{ \frac{(\bar{X} - \mu)\sqrt{n}}{S} < -\varepsilon \right\}$$

Dunque

$$\mathbb{P}_{\mu \geq \mu_0} \left( \frac{(\bar{X} - \mu_0)\sqrt{n}}{S} < -\varepsilon \right) \leq \mathbb{P}_{\mu \geq \mu_0} \left( \frac{(\bar{X} - \mu)\sqrt{n}}{S} < -\varepsilon \right) \quad \forall \mu \geq \mu_0$$

e quindi, per ogni  $\mu \geq \mu_0$  si ha

$$\begin{aligned} \mathbb{P}_{\mu \geq \mu_0} \left( \frac{(\bar{X} - \mu_0)\sqrt{n}}{S} < -\varepsilon \right) &= \mathbb{P}_{\mu \geq \mu_0} \left( \frac{(\bar{X} - \mu)\sqrt{n}}{S} < -\varepsilon \right) \\ &= \mathbb{P}(T < -\varepsilon) = F_T(-\varepsilon) = 1 - F_T(\varepsilon). \end{aligned}$$

Se vogliamo stabilire il livello di significatività  $\alpha$  dovremmo scegliere  $\varepsilon$  in modo che

$$1 - F_T(\varepsilon) = \alpha$$

cioè  $\varepsilon = t_{n-1,1-\alpha}$ .

Presi i dati  $x_1, x_2, \dots, x_n$ , sia dunque  $t_0 = \frac{(\bar{x} - \mu_0)\sqrt{n}}{s}$ . Accetto  $H_0$  se

$$t_0 \geq -t_{n-1, 1-\alpha}$$

e la rifiuto altrimenti, ovvero accetto  $H_0$  se

$$\bar{x} \geq \mu_0 - \frac{t_{n-1, 1-\alpha} s}{\sqrt{n}}$$

e la rifiuto altrimenti.

## 7.2. Test d'ipotesi per l'uguaglianza di medie di campioni gaussiani

Supponiamo di avere due campioni, entrambi gaussiani

$$\begin{aligned} X: X_1, X_2, \dots, X_n & \quad X_i \sim \mathcal{N}(\mu_X, \sigma_X^2), \\ Y: Y_1, Y_2, \dots, Y_k & \quad Y_j \sim \mathcal{N}(\mu_Y, \sigma_Y^2). \end{aligned}$$

Vogliamo testare l'ipotesi

$$H_0) \quad \mu_X = \mu_Y$$

Osserviamo che  $\mu_X = \mu_Y$  se e solo se  $\mathbb{E}[\bar{X} - \bar{Y}] = 0$ .

Per limitare la probabilità di commettere errore di prima specie, distinguiamo tre diversi casi

### 7.2.1. Primo caso: le varianze $\sigma_X^2$ e $\sigma_Y^2$ sono note

Considero la v.a.  $W := \bar{X} - \bar{Y}$ . Per le proprietà dei campioni gaussiani

$$W \sim \mathcal{N}\left(\mu_X - \mu_Y, \frac{\sigma_X^2}{n} + \frac{\sigma_Y^2}{k}\right).$$

Dunque  $H_0$  è vera se e solo se  $W \sim \mathcal{N}\left(0, \frac{\sigma_X^2}{n} + \frac{\sigma_Y^2}{k}\right)$ . Dunque stabilisco il seguente criterio di accettazione:

$$\text{Accetto } H_0 \text{ se e solo se } |w| = |\bar{x} - \bar{y}| < \varepsilon.$$

La probabilità di commettere errore di prima specie vale allora

$$\alpha = \mathbb{P}_{\mu_X = \mu_Y}(|W| \geq \varepsilon) = \mathbb{P}_{\mu_X = \mu_Y} \left( \frac{|W|}{\sqrt{\frac{\sigma_X^2}{n} + \frac{\sigma_Y^2}{k}}} \geq \frac{\varepsilon}{\sqrt{\frac{\sigma_X^2}{n} + \frac{\sigma_Y^2}{k}}} \right)$$

D'altra parte, se  $H_0$  è vera, allora  $Z := \frac{W}{\sqrt{\frac{\sigma_X^2}{n} + \frac{\sigma_Y^2}{k}}} \sim \mathcal{N}(0, 1)$ , e dunque dovremo

scegliere  $\frac{\varepsilon}{\sqrt{\frac{\sigma_X^2}{n} + \frac{\sigma_Y^2}{k}}} = z_{1-\frac{\alpha}{2}}$  ovvero

$$\varepsilon = z_{1-\frac{\alpha}{2}} \sqrt{\frac{\sigma_X^2}{n} + \frac{\sigma_Y^2}{k}}.$$

Dunque accettiamo l'ipotesi  $H_0$  se

$$|\bar{x} - \bar{y}| < z_{1-\frac{\alpha}{2}} \sqrt{\frac{\sigma_X^2}{n} + \frac{\sigma_Y^2}{k}}$$

e la rifiutiamo altrimenti.

**Osservazione 7.2.1.** Se  $\sigma_X^2 = \sigma_Y^2 = \sigma_0^2$  e  $k = n$ , allora  $\varepsilon = z_{1-\frac{\alpha}{2}} \sigma_0 \sqrt{\frac{2}{n}}$ .

**7.2.2. Secondo caso: le varianze  $\sigma_X^2$  e  $\sigma_Y^2$  sono ignote ma uguali**

Consideriamo le due varianze campionarie

$$S_X^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2, \quad S_Y^2 = \frac{1}{k-1} \sum_{j=1}^k (Y_j - \bar{Y})^2.$$

Sia  $\sigma^2$  il comune valore di  $\sigma_X^2$  e  $\sigma_Y^2$ . Sappiamo che

$$V_X := \frac{(n-1)S_X^2}{\sigma^2} \sim \chi_{n-1}^2, \quad V_Y := \frac{(k-1)S_Y^2}{\sigma^2} \sim \chi_{k-1}^2$$

dunque, per la Proprietà 5.3.2,  $V_X + V_Y \sim \chi_{n-1+k-1}^2 = \chi_{n+k-2}^2$

D'altra parte

$$V_X + V_Y = \frac{(n-1)S_X^2 + (k-1)S_Y^2}{\sigma^2} = \frac{n+k-2}{\sigma^2} \frac{(n-1)S_X^2 + (k-1)S_Y^2}{n+k-2}.$$

Consideriamo la statistica:

$$\bar{S}^2 := \frac{(n-1)S_X^2 + (k-1)S_Y^2}{n+k-2}.$$

Si ha

$$V_X + V_Y = \frac{(n+k-2)\bar{S}^2}{\sigma^2}. \tag{7.1}$$

Inoltre  $\bar{X} - \bar{Y} \sim \mathcal{N}\left(\mu_X - \mu_Y, \sigma^2 \left(\frac{1}{n} + \frac{1}{k}\right)\right)$ , quindi

$$Z := \frac{\bar{X} - \bar{Y}}{\sigma \sqrt{\frac{1}{n} + \frac{1}{k}}} \sim \mathcal{N}(0, 1) \quad \text{se e solo se} \quad \mu_X = \mu_Y.$$

Sia

$$T := \frac{Z\sqrt{n+k-2}}{\sqrt{V_X + V_Y}}.$$

Poiché i due campioni sono gaussiani e indipendenti le v.a.  $\bar{X}$ ,  $S_X^2$ ,  $\bar{Y}$  e  $S_Y^2$  sono indipendenti, quindi  $Z$  e  $\bar{S}^2$  sono indipendenti, quindi  $\mathbb{E}[\bar{X} - \bar{Y}] = 0$  se e solo se  $\mathbb{E}[T] = 0$ . Come criterio di accettazione per l'ipotesi nulla  $H_0$  scelgo dunque  $|t| < \varepsilon$ .

Inoltre, se  $\mathbb{E}[\bar{X} - \bar{Y}] = 0$ , allora per il Teorema 5.3.5

$$T \sim t(n+k-2).$$

Sostituendo l'espressione per  $Z$  e quella per  $V_X + V_Y$  data nell'equazione (7.1) si ha

$$T = \frac{\bar{X}}{\bar{S} \sqrt{\frac{1}{n} + \frac{1}{k}}} \sim t(n+k-2)$$

Osserviamo anche che

$$\mathbb{E}[\bar{S}^2] = \frac{(n-1)\mathbb{E}[S_X^2] + (k-1)\mathbb{E}[S_Y^2]}{n+k-2} = \frac{(n-1)\sigma^2 + (k-1)\sigma^2}{n+k-2} = \sigma^2$$

e dunque possiamo usare  $\bar{S}^2$  per stimare la varianza  $\sigma^2$ .

La probabilità di commettere errore di prima specie è allora

$$\alpha = \mathbb{P}(|T| \geq \varepsilon)$$

Fissato il livello di significatività  $\alpha$ , devo dunque scegliere  $\varepsilon = t_{n+k-2, 1-\frac{\alpha}{2}}$ .

Siano  $x: x_1, x_2, \dots, x_n$  e  $y: y_1, y_2, \dots, y_k$  i dati,  $\bar{x}$  e  $\bar{y}$  le rispettive medie,  $s_x^2$  e  $s_y^2$  le rispettive varianze e sia  $\bar{s}^2 := \frac{(n-1)s_x^2 + (k-1)s_y^2}{n+k-2}$ : accetto l'ipotesi nulla se

$$\frac{|\bar{x} - \bar{y}|}{\bar{s} \sqrt{\frac{1}{n} + \frac{1}{k}}} < t_{n+k-2, 1-\frac{\alpha}{2}},$$

cioè se

$$|\bar{x} - \bar{y}| < t_{n+k-2, 1-\frac{\alpha}{2}} \bar{s} \sqrt{\frac{1}{n} + \frac{1}{k}}$$

e la rifiuto altrimenti.

### 7.2.3. Terzo caso: le varianze $\sigma_X^2$ e $\sigma_Y^2$ sono ignote e diverse

Si può dimostrare che se  $n$  e  $k$  sono sufficientemente grandi e se  $H_0$  è vera, allora la distribuzione della statistica

$$\frac{\bar{X} - \bar{Y}}{\sqrt{\frac{S_X^2}{n} + \frac{S_Y^2}{k}}}$$

è *approssimativamente* gaussiana standard. Dunque, per ottenere approssimativamente un livello di significatività  $\alpha$  si accetta l'ipotesi nulla  $H_0) \quad \mu_X = \mu_Y$  quando

$$\frac{|\bar{x} - \bar{y}|}{\sqrt{\frac{s_X^2}{n} + \frac{s_Y^2}{k}}} < z_{1-\frac{\alpha}{2}}$$

e la si rifiuta altrimenti.

Il problema di individuare un test che dia un livello di significatività  $\alpha$  prescritto è ancora un problema aperto ed è noto come *problema di Behrens-Fisher*.

## 7.3. Test d'ipotesi per la varianza di campioni gaussiani

### Test bilaterale

Sia  $X_1, X_2, \dots, X_n$  un campione gaussiano di media  $\mu$  (nota o incognita) e varianza  $\sigma^2$  incognita. Vogliamo testare l'ipotesi nulla

$$H_0) \quad \sigma^2 = \sigma_0^2.$$

$H_0$  è vera se e solo se  $\mathbb{E}[S^2] = \sigma_0^2$  se e solo se  $\mathbb{E}\left[\frac{S^2}{\sigma_0^2}\right] = 1$ .

Sappiamo che la v.a.  $V := \frac{(n-1)S^2}{\sigma^2} \sim \chi_{n-1}^2$ .

Dunque accetto  $H_0$  se  $1 - \varepsilon_1 < \frac{s^2}{\sigma_0^2} < 1 + \varepsilon_2$ ,  $\varepsilon_1, \varepsilon_2$  positivi, cioè se e solo se

$$(n-1)(1 - \varepsilon_1) < \frac{(n-1)s^2}{\sigma^2} < (n-1)(1 + \varepsilon_2).$$

Devo scegliere  $\varepsilon_1$  e  $\varepsilon_2$  in modo da ottenere il livello di significatività  $\alpha$  desiderato:

$$\begin{aligned} \alpha &= \mathbb{P}\left(\frac{S^2}{\sigma_0^2} > 1 + \varepsilon_2\right) + \mathbb{P}\left(\frac{S^2}{\sigma_0^2} < 1 - \varepsilon_1\right) \\ &= \mathbb{P}\left(\frac{(n-1)S^2}{\sigma_0^2} > (n-1)(1 + \varepsilon_2)\right) + \mathbb{P}\left(\frac{(n-1)S^2}{\sigma_0^2} < (n-1)(1 - \varepsilon_1)\right). \end{aligned}$$

Una possibile scelta è allora

$$\begin{aligned} \mathbb{P}\left(\frac{(n-1)S^2}{\sigma_0^2} > (n-1)(1+\varepsilon_2)\right) &= \frac{\alpha}{2} & \text{cioè} & \quad (n-1)(1+\varepsilon_2) = \chi_{n-1, 1-\frac{\alpha}{2}}^2 \\ \mathbb{P}\left(\frac{(n-1)S^2}{\sigma_0^2} < (n-1)(1-\varepsilon_1)\right) &= \frac{\alpha}{2} & \text{cioè} & \quad (n-1)(1-\varepsilon_1) = \chi_{n-1, \frac{\alpha}{2}}^2. \end{aligned}$$

Dunque accetto  $H_0$  se

$$\chi_{n-1, \frac{\alpha}{2}}^2 < \frac{(n-1)s^2}{\sigma_0^2} < \chi_{n-1, 1-\frac{\alpha}{2}}^2$$

cioè se

$$\frac{\sigma_0^2}{n-1} \chi_{n-1, \frac{\alpha}{2}}^2 < s^2 < \frac{\sigma_0^2}{n-1} \chi_{n-1, 1-\frac{\alpha}{2}}^2$$

e la rifiuto altrimenti.

### Test unilaterale

Sia  $X_1, X_2, \dots, X_n$  un campione gaussiano di media  $\mu$  (nota o incognita) e varianza  $\sigma^2$  incognita. Vogliamo testare l'ipotesi nulla

$$H_0) \quad \sigma^2 \leq \sigma_0^2.$$

Accetto l'ipotesi nulla se  $\frac{s^2}{\sigma_0^2} \leq 1 + \varepsilon$ .

Se la varianza è  $\sigma^2 \leq \sigma_0^2$ , allora  $V := \frac{(n-1)S^2}{\sigma^2} \sim \chi_{n-1}^2$  e la probabilità di commettere errore di prima specie è

$$\begin{aligned} \mathbb{P}_{\sigma^2 \leq \sigma_0^2} \left( \frac{S^2}{\sigma_0^2} > 1 + \varepsilon \right) &= \mathbb{P}_{\sigma^2 \leq \sigma_0^2} \left( \frac{(n-1)S^2}{\sigma^2} > \frac{\sigma_0^2}{\sigma^2} (n-1)(1+\varepsilon) \right) \\ &= \mathbb{P} \left( V > \frac{\sigma_0^2}{\sigma^2} (n-1)(1+\varepsilon) \right) = 1 - F_V \left( \frac{\sigma_0^2}{\sigma^2} (n-1)(1+\varepsilon) \right) \\ &\leq 1 - F_V((n-1)(1+\varepsilon)). \end{aligned}$$

Posso allora limitare superiormente con  $\alpha$  la probabilità di commettere errore di prima specie imponendo

$$1 - F_V((n-1)(1+\varepsilon)) = \alpha$$

cioè scegliendo  $\varepsilon$  in modo che

$$(n-1)(1+\varepsilon) = \chi_{n-1, 1-\alpha}^2.$$

Dunque accetto l'ipotesi nulla  $H_0$  se

$$\frac{(n-1)s^2}{\sigma_0^2} < \chi_{n-1, 1-\alpha}^2$$

cioè se

$$s^2 < \frac{\sigma_0^2}{n-1} \chi_{n-1, 1-\alpha}^2$$

e la rifiuto altrimenti.



### Test unilaterale

Sia  $X_1, X_2, \dots, X_n$  un campione gaussiano di media  $\mu$  (nota o incognita) e varianza  $\sigma^2$  incognita. Vogliamo testare l'ipotesi nulla

$$H_0) \quad \sigma^2 \geq \sigma_0^2.$$

Accetto l'ipotesi nulla se  $\frac{s^2}{\sigma_0^2} \geq 1 - \varepsilon$ .

Se la varianza è  $\sigma^2 \geq \sigma_0^2$ , allora  $V := \frac{(n-1)S^2}{\sigma^2} \sim \chi_{n-1}^2$  la probabilità di commettere errore di prima specie è allora

$$\begin{aligned} \mathbb{P}_{\sigma^2} \left( \frac{S^2}{\sigma_0^2} < 1 - \varepsilon \right) &= \mathbb{P}_{\sigma^2} \left( \frac{(n-1)S^2}{\sigma^2} < \frac{\sigma_0^2}{\sigma^2} (n-1)(1 - \varepsilon) \right) \\ &= F_V \left( \frac{\sigma_0^2}{\sigma^2} (n-1)(1 - \varepsilon) \right) \leq F_V((n-1)(1 - \varepsilon)). \end{aligned}$$

Posso allora limitare superiormente con  $\alpha$  la probabilità di commettere errore di prima specie imponendo

$$F_V((n-1)(1 - \varepsilon)) = \alpha$$

cioè scegliendo  $\varepsilon$  in modo che

$$(n-1)(1 - \varepsilon) = \chi_{n-1, \alpha}^2.$$

Dunque accetto l'ipotesi nulla  $H_0$  se

$$\frac{(n-1)s^2}{\sigma_0^2} > \chi_{n-1, \alpha}^2$$

cioè se

$$s^2 > \frac{\sigma_0^2}{n-1} \chi_{n-1, \alpha}^2$$

e la rifiuto altrimenti.

### 7.4. Test d'ipotesi per la media di campioni bernoulliani

Abbiamo già trattato questo argomento nell' esempio introduttivo.

#### Test bilaterale

Sia  $X_1, X_2, \dots, X_n$  è un campione di Bernoulli di parametro  $p$  incognito. Sappiamo che  $\mathbb{E}[X_i] = p$  e che, vedi (5.1)

$$\mathbb{P}(|\bar{X} - p| > t) \leq \frac{1}{4nt^2} \quad \forall t > 0.$$

dunque usiamo  $\bar{x}$  come stima di  $p$ .

Testiamo l'ipotesi nulla

$$H_0) \quad p = p_0.$$

Stabiliamo il criterio di accettazione: accetto  $H_0$  se  $\bar{x} - p_0 < \varepsilon$  e la rifiuto altrimenti.

Se  $H_0$  è vera, allora la v.a.  $Y := \sum_{i=1}^n X_i$  segue la distribuzione  $B(n, p_0)$  di cui conosciamo la distribuzione. La probabilità di commettere errore di prima specie è quindi

$$\begin{aligned} \alpha &= \mathbb{P}_{p=p_0} (|\bar{X} - p_0| < \varepsilon) = \mathbb{P}_{p=p_0} (|Y - np_0| < n\varepsilon) \\ &= \mathbb{P}(Y < n(p_0 + \varepsilon)) - \mathbb{P}(Y \leq n(p_0 - \varepsilon)). \end{aligned}$$

### Test unilaterale

Testiamo l'ipotesi nulla

$$H_0) \quad p \leq p_0.$$

Stabiliamo il criterio di accettazione: accetto  $H_0$  se  $\bar{x} < p_0 + \varepsilon$  e la rifiuto altrimenti.

Se  $H_0$  è vera, allora la v.a.  $Y := \sum_{i=1}^n X_i$  segue la distribuzione  $B(n, p)$  per qualche  $p \leq p_0$ . La probabilità di commettere errore di prima specie è quindi

$$\begin{aligned} \mathbb{P}_{p \leq p_0} (\bar{X} \geq p_0 + \varepsilon) &= \mathbb{P}_{p \leq p_0} (Y \geq n(p_0 + \varepsilon)) \\ &\leq \mathbb{P}_{p_0} (Y \geq n(p_0 + \varepsilon)). \end{aligned}$$

Per limitare superiormente il livello di significatività  $\alpha$  scelgo dunque  $\varepsilon$  in modo che  $\mathbb{P}_{p_0} (Y \geq n(p_0 + \varepsilon)) \leq \alpha$ .

### Test unilaterale

Testiamo l'ipotesi nulla

$$H_0) \quad p \geq p_0.$$

Stabiliamo il criterio di accettazione: accetto  $H_0$  se  $\bar{x} > p_0 - \varepsilon$  e la rifiuto altrimenti.

Se  $H_0$  è vera, allora la v.a.  $Y := \sum_{i=1}^n X_i$  segue la distribuzione  $B(n, p)$  per qualche  $p \geq p_0$ . La probabilità di commettere errore di prima specie è quindi

$$\begin{aligned} \mathbb{P}_{p \geq p_0} (\bar{X} \leq p_0 - \varepsilon) &= \mathbb{P}_{p \geq p_0} (Y \leq n(p_0 - \varepsilon)) \\ &\leq \mathbb{P}_{p_0} (Y \leq n(p_0 - \varepsilon)). \end{aligned}$$

Per limitare superiormente il livello di significatività  $\alpha$  scelgo dunque  $\varepsilon$  in modo che  $\mathbb{P}_{p_0} (Y \leq n(p_0 - \varepsilon)) \leq \alpha$ .

### 7.5. Test del $\chi^2$

Sia  $X_1, X_2, \dots, X_n$  un campione statistico. Supponiamo che le v.a. del campione siano discrete a valori  $y_1, y_2, \dots, y_k$ . Consideriamo le densità di probabilità

$$p_j := \mathbb{P}(X_i = y_j), \quad j = 1, \dots, k.$$

Vogliamo testare l'ipotesi nulla

$$H_0 \quad p_j = p_j^0 \quad \forall j = 1, \dots, k.$$

Per ogni  $j = 1, \dots, k$  considero le *frequenze campionarie*

$$N_j(\omega) = \#\{i \in \{1, \dots, n\} : X_i(\omega) = y_j\} \quad j = 1, \dots, k$$

e le *frequenze campionarie relative*

$$F_j := \frac{N_j}{n}, \quad j = 1, \dots, k.$$

Sicuramente  $N_j \sim B(n, p_j)$ , quindi  $\mathbb{E}[N_j] = np_j$  e  $\mathbb{E}[F_j] = p_j$ .

In particolare  $H_0$  è vera se e solo se  $\mathbb{E}[N_j] = np_j^0 \quad \forall j = 1, \dots, k$ , dunque un criterio di accettazione potrebbe essere quello di accettare  $H_0$  se e solo se  $|n_j - np_j^0| < \varepsilon \quad \forall j = 1, \dots, k$ .

Questo criterio però non ci permette di calcolare la probabilità di errore di prima specie. Vale però il seguente risultato:

**Teorema 7.5.1** (di Pearson). *Se  $N_j \sim B(n, p_j)$ , allora la funzione di ripartizione della v.a.*

$$T_n := \sum_{j=1}^k \frac{(N_j - np_j)^2}{np_j}$$

*converge, per  $n \rightarrow \infty$ , alla funzione di ripartizione associata alla distribuzione  $\chi_{k-1}^2$ .*

**Osservazione 7.5.1.** Nelle applicazioni l'approssimazione è considerata accettabile se  $np_j \geq 5 \quad \forall j = 1, \dots, k$ .

Formuliamo allora il seguente criterio di accettazione:

$$\text{accetto l'ipotesi nulla } H_0 \text{ se e solo se } t_n := \sum_{j=1}^k \frac{(n_j - np_j^0)^2}{np_j^0} < \varepsilon.$$

La probabilità di commettere errore di prima specie è allora

$$\alpha := \mathbb{P}(T_n \geq \varepsilon) \simeq 1 - F_{\chi_{k-1}^2}(\varepsilon).$$

Scelgo dunque  $\varepsilon$  tale che  $F_{\chi_{k-1}^2}(\varepsilon) = 1 - \alpha$ , cioè  $\varepsilon = \chi_{k-1, 1-\alpha}^2$ .

**Osservazione 7.5.2.** Il test si può applicare anche nel caso in cui  $y_1, y_2, \dots, y_k$  siano sostituiti da classi di modalità  $I_1, I_2, \dots, I_k$ .

**7.5.1. Test di normalità**

Supponiamo di aver un campione  $X_1, X_2, \dots, X_n$ . Vogliamo testare l'ipotesi

$$H_0) \quad \text{Il campione è normale}$$

Si può procedere nel seguente modo:

1. stimiamo  $\mu$  e  $\sigma^2$  rispettivamente con  $\bar{x}$  e  $s^2$ ;
2. standardizziamo i dati ponendo  $z_i := \frac{x_i - \mu}{\sigma}$ . Se il campione segue la distribuzione  $\mathcal{N}(\mu, \sigma^2)$ , allora  $Z_i \sim \mathcal{N}(0, 1)$ ;
3. suddividiamo la retta reale in intervalli  $I_1, I_2, \dots, I_k$  (simmetrici rispetto all'origine), ivi comprese due semirette simmetriche  $[a, +\infty)$  e  $(-\infty, -a]$ ;
4. contiamo  $n_j := \#\{i \in \{1, \dots, n\} : z_i \in I_j\}$ ;
5. calcoliamo  $p_j^0 := \mathbb{P}(Z_i \in I_j)$ ;
6. consideriamo la v.a.  $T_n := \sum_{j=1}^k \frac{(N_j - np_j^0)^2}{np_j^0}$ . Si può dimostrare che per  $n \rightarrow \infty$  la funzione di ripartizione di  $T_n$  converge alla funzione di ripartizione associata alla distribuzione  $\chi_{n-2-1}^2$ , dove il  $-2$  è dovuto al fatto che abbiamo sostituito i due parametri  $\mu$  e  $\sigma^2$  con le loro stime provenienti dai dati  $\bar{x}$  e  $s^2$ ;
7. accettiamo l'ipotesi nulla se  $t_n < \varepsilon$ . Se imponiamo un livello di significatività  $\alpha$ , sceglieremo allora  $\varepsilon = \chi_{n-3, 1-\alpha}^2$ .

## Bibliografia

- [1] Luigi Barletti. Appunti del corso applicazioni di matematiche e statistica, a.a. 2007–08.
- [2] Fabio Frascati. *Formulario di Statistica con R*. <http://cran.r-project.org/doc/contrib/Frascati-FormularioStatisticaR.pdf>, 2008.
- [3] Antonia Morpoulou and Kyriaki Polikreti. Principal component analysis in monument conservation: Three application examples. *Journal of Cultural Heritage*, 10:73–81, 2009.
- [4] John Verzani. *simpleR*. <http://cran.r-project.org/doc/contrib/Verzani-SimpleR.pdf>, 2001.