

Appunti sulla proprietà della mediana come stimatore della tendenza centrale di una popolazione

$$E(\widehat{Me}_i) = Me = \mu,$$

$$Var(\widehat{Me}) = \frac{1}{4nf(Me)^2},$$

dove $f(Me)$ è la funzione di densità della popolazione a livello della mediana (uguale a μ nelle distribuzioni simmetriche) e n è la grandezza del campione.

In pratica, la funzione di densità della popolazione a livello della mediana, $f(Me)$, non è nota; tuttavia se si può assumere come normale, abbiamo

$$\begin{aligned} f(Me = \mu; \mu; \sigma) &= \frac{1}{\sqrt{2\pi\sigma^2}} e^{\left\{ \frac{1}{2} \frac{(\mu - \mu)^2}{\sigma^2} \right\}} \\ &= \frac{1}{\sqrt{2\pi\sigma^2}} e^{\left\{ \frac{1}{2} \frac{0}{\sigma^2} \right\}} \\ &= \frac{1}{\sqrt{2\pi\sigma^2}} = \frac{1}{\sqrt{2\pi}} \times \frac{1}{\sqrt{\sigma^2}} \\ &= 0.3989423 \times \frac{1}{\sqrt{\sigma^2}} \\ &\approx 0.4 \times \frac{1}{\sqrt{\sigma^2}} \end{aligned}$$

Il valore di ordinata massima (dove $f(x)$ raggiunge il valore massimo) delle funzioni di densità di probabilità normali è quindi

$$0.4 \times \frac{1}{\sqrt{\sigma^2}}$$

che si semplifica a 0.4 nel caso della normale standard, dove $\sigma^2 = 1$.

- La varianza della distribuzione campionaria della mediana, secondo l'assunzione di normalità nella popolazione, diventa

$$\begin{aligned} \text{Var}(\widehat{Me}) &= \frac{1}{4n \left(0.4 \times 1/\sqrt{\sigma^2}\right)^2} = \frac{\sigma^2}{4n(0.4)^2} = \frac{1}{4(0.4)^2} \times \frac{\sigma^2}{n} \\ &= 1.5625 \frac{\sigma^2}{n} \\ &= 1.25^2 \sigma_{\bar{x}}^2 \end{aligned}$$

...Simulazione 1

- La formula precedente rivela che la mediana è meno efficiente della media quale operatore di tendenza centrale (ha una varianza campionaria 1.25^2 volte maggiore).
- Esaminiamo i risultati di una simulazione.
- Calcoliamo empiricamente la varianza della distribuzione campionaria di media e mediana di un campione casuale di $n = 200$ osservazioni, estratto (50000 volte) da una popolazione normale con media $\mu = 100$ e deviazione standard $\sigma = 36$.

```
rep <- 50000
n <- 200
DistrCampMedia <- rep(0, rep)
DistrCampMediana <- rep(0, rep)
for (i in 1:rep) {
  samp <- rnorm(n, mean=100, sd=36)
  DistrCampMedia[i] <- mean(samp)
  DistrCampMediana[i] <- median(samp)
}
```

I risultati confermano quello che ci aspettiamo:

```
var.media <- var(DistrCampMedia)*(n-1)/n
var.media
## 6.499387
```

```
36^2/200
## 6.48
```

la varianza della distribuzione campionaria della media è uguale al rapporto tra la varianza della popolazione e la numerosità del campione.

Vediamo ora cosa è successo per la mediana calcolata sui medesimi campioni.

```
var.mediana <- var(DistrCampMediana)*(n-1)/n
var.mediana
## 10.06176
```

```
1/(4* dnorm(0,0,1)^2) * 36^2/200
## 10.17876
```


Di quanto è più grande la deviazione standard della distribuzione campionaria della mediana della deviazione standard della distribuzione campionaria della media?

```
sqrt(var.mediana)/sqrt(var.media)
## [1] 1.24423
```

```
var.mediana/var.media
## [1] 1.548109
sqrt(1.548109)
## [1] 1.24423
```

Come vi ho mostrato, quando n è grande e la popolazione si assume essere normale, la varianza della distribuzione campionaria della mediana è

$$V(Me_i) = 1.25^2 \frac{\sigma^2}{n} \approx 10.17876$$



- La simulazione precedente rivela che la mediana è meno efficiente della media quale operatore di tendenza centrale (ha una varianza campionaria maggiore).