
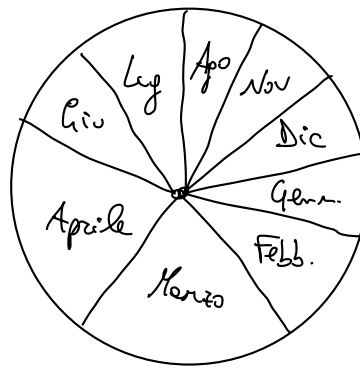





# Diagramma a torta



Supponiamo di avere dati quantitativi (es altezze, giorno di nascita, --)



Normale

"curva a campana"


Def Dato un campione  $x = \{x_1, \dots, x_N\}$  di  $N$  dati, si chiama MEDIA di  $x$ , il numero

$$\bar{x} := \frac{1}{N} \sum_{i=1}^N x_i = \frac{1}{N} (x_1 + x_2 + \dots + x_N)$$

OSS  $\min_{a \in \mathbb{R}} \sum_{i=1}^N (x_i - a)^2 = \sum_{i=1}^N (x_i - \bar{x})^2$

ES  $x = \{ 25, 24, 28, 30, 26, 24, 26, 30, 24, 26 \}$

$N = 10$



$\bar{x} = \frac{1}{10} \sum_{i=1}^N x_i = 26,3$

$x = \{ 24, 24, 29, 31, 25, 24, 27, 29, 24, 26 \}$  ,  $\bar{x} = 26,3$

$x = \{ 23, 23, 31, 31, 24, 23, 28, 31, 23, 26 \}$  ,  $\bar{x} = 26,3$

Def Dato un campione  $x = \{ x_1, \dots, x_N \}$  con media  $\bar{x}$ , si chiama **VARIANZA** (empirica) di  $x$  il numero

$$var_x(x) := \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2$$

Si chiama **SCARTO QUADRATICO MEDIO** di  $x$  (o **DEVIATIONE STANDARD** di  $x$ ) la quantità

$$\sigma(x) := \sqrt{var(x)}$$

ES  $x = \{ 25, 24, 28, 30, 26, 24, 26, 30, 24, 26 \}$   
 $x = \{ 24, 24, 29, 31, 25, 24, 27, 29, 24, 26 \}$   
 $x = \{ 23, 23, 31, 31, 24, 23, 28, 31, 23, 26 \}$  }  $\bar{x} = 26,3$

$var(x) = \begin{cases} 4,81 & \text{---} \\ 6,01 & \text{---} \\ 11,81 & \text{---} \end{cases}$        $\sigma(x) = \begin{cases} 2,19 & \text{---} \\ 2,45 & \text{---} \\ 3,44 & \text{---} \end{cases}$

OSS

$$\begin{aligned} \text{var}(x) &= \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2 = \frac{1}{N} \sum_{i=1}^N (x_i^2 - 2x_i\bar{x} + \bar{x}^2) = \\ &= \frac{1}{N} \sum_{i=1}^N x_i^2 - \underbrace{\frac{2}{N} \sum_{i=1}^N x_i \bar{x}}_{\frac{2\bar{x}}{N} \sum_{i=1}^N x_i} + \underbrace{\frac{1}{N} \sum_{i=1}^N \bar{x}^2}_{\frac{1}{N} \cdot N \bar{x}^2} = \\ &= \frac{1}{N} \sum_{i=1}^N x_i^2 - \bar{x}^2 \end{aligned}$$

Prop (Disuguaglianza di Chebyshev) Dato  $x = \{x_1, \dots, x_N\}$  con media  $\bar{x}$  e varianza  $\text{var}(x)$ , vale che per ogni  $d > 0$

$$\frac{\# \left\{ i / |x_i - \bar{x}| > d \right\}}{N} \leq \frac{\text{var}(x)}{d^2}$$

(equivalentemente  $\frac{\# \left\{ i / |x_i - \bar{x}| \leq d \right\}}{N} \geq 1 - \frac{\text{var}(x)}{d^2}$ )

OSS  $d = \alpha \cdot \sigma(x)$ ,  $\alpha > 0$ ,  $\sigma(x) = \sqrt{\text{var}(x)}$

$$\frac{\# \left\{ i / |x_i - \bar{x}| \leq \alpha \sigma(x) \right\}}{N} \geq 1 - \frac{\text{var}(x)}{\alpha^2 (\sigma(x))^2} = 1 - \frac{1}{\alpha^2}$$

ES  $\alpha = 3$ , Almeno 89% dei dati è a distanza  $\leq 3\sigma$  da  $\bar{x}$ .

OSS Per la distribuzione normale vale che:

almeno il 68% dei dati è a distanza  $\leq \sigma$  da  $\bar{x}$

" " 95% " " " "  $\leq 2\sigma$  "


" " 99,7% " " " " " ≤ 3σ "

- Funzione di ripartizione  $F(t)$ ,  $t \in \mathbb{R}$ ,  $F: \mathbb{R} \rightarrow \mathbb{R}$   
 $\text{Im} F = [0, 1]$ .

Dato  $x = \{x_1, \dots, x_N\}$ ,

$$F(t) := \frac{\#\{i / x_i \leq t\}}{N}$$

ES  $x = \{25, 24, 28, 30, 26, 24, 26, 30, 24, 26\}$



$$F(24) = \frac{1}{10} \#\{i / x_i \leq 24\} = \frac{3}{10}$$

Def Dato  $k \in (0, 100)$ , si chiama  $k$ -SIMO PERCENTILE di  $x = \{x_1, \dots, x_N\}$  il valore  $t_k \in \mathbb{R}$  per cui:


- almeno  $\frac{k}{100} \cdot N$  dati sono  $\leq t_k$
- almeno  $(1 - \frac{k}{100})N$  dati sono  $\geq t_k$ .

Se  $k = 25$ , il numero  $t_{25}$  si chiama primo quartile

"  $k = 50$ , " "  $t_{50}$  " mediana

"  $k = 75$ , " "  $t_{75}$  " terzo quartile

ES



La mediana è 26 (infatti ho 7 stati su 10 che sono  $\leq 26$  e ho 6 stati su 10 che sono  $\geq 26$ )

Il 40-esimo percentile è 25,5 (infatti ho 4 stati su 10 che sono  $\leq 25,5$  e ho 6 stati su 10 che sono  $\geq 25,5$ )

Il primo quartile è 24, il terzo quartile è 28.