

Indici di posizione e dispersione per distribuzioni di variabili aleatorie

12 maggio 2017

Consideriamo i principali indici statistici che caratterizzano una distribuzione: indici di posizione, che forniscono informazioni del valore attorno al quale si posizionano i dati; b) indici di dispersione, che forniscono informazioni su quanto i dati si disperdano intorno ad un valore centrale

1 Indici di posizione

Aiutano a localizzare la distribuzione, ovvero individuare attorno a quale valore si concentra la distribuzione stessa. Sono espressi nella stessa unità di misura della V.A.

1.1 Moda

Data una distribuzione discreta $p_X(x)$ o continua $f_X(x)$, di una V.A. X la **moda** è il valore $X = x$ per cui la distribuzione è massima. Formalmente (caso continuo)

$$x_{moda} = \arg \max_x [f_X(x)].$$

Una distribuzione è detta *unimodale* se è presente un solo valore di massimo *multimodale* se sono presenti più massimi. In quest'ultimo caso ciascun di essi si chiama valore modale.

1.2 Mediana

Data una distribuzione della V.A. X , la **mediana** è il valore $X = x_{mediana}$ che taglia in due parti equivalenti la distribuzione.

Formalmente:

$$\begin{aligned} P_X(\{X \leq x\}) &= P_X(\{X > x\}) \\ F_X(x) &= 1 - F_X(x) \\ F_X(x) &= \frac{1}{2} \end{aligned}$$

1.3 Media

Data una distribuzione X , la **media** è visualizzabile come il *baricentro* della distribuzione. Formalmente, viene indicata come **valore atteso** oppure **speranza matematica** e si indica $\langle x \rangle$, $E[X]$ (dove E sta per "expectation" ovvero speranza matematica), \bar{X} oppure μ_X .




Figura 1: In alto, un esempio di distribuzione unimodale; in basso, un esempio di distribuzione multimodale

Si noti che, in una distribuzione simmetrica, la moda e la mediana coincidono

Nel caso discreto,

$$\begin{aligned} E[X] &= \sum x \cdot P_X(\{X = x\}) \\ &= \sum x \cdot p_X(x), \end{aligned}$$

dove la sommatoria é indicizzata da tutti i valori discreti che puó assumere la V.A. X .

Nel caso in cui X sia una V.A. continua, la sommatoria é sostituita da un integrale:

$$E[X] = \int_{-\infty}^{+\infty} x \cdot f_X(x) dx$$

La speranza matematica gode della proprietá di linearitá.

Prop. 1.1 Se X é una variabile aleatoria degenere ovvero $X = \beta$ dove $\beta \in \mathbb{R}$ é una costante allora

$$E[\beta] = \beta$$

Dimostrazione

$$\begin{aligned} E[\beta] &= \int_{-\infty}^{+\infty} \beta \cdot f_X(x) dx \\ &= \beta \cdot \int_{-\infty}^{+\infty} f_X(x) dx \\ &= \beta \end{aligned}$$

Prop. 1.2 Dato $\alpha \in \mathbb{R}$

$$E[\alpha X] = \alpha \cdot E[X]$$

Dimostrazione

$$\begin{aligned} E[\alpha X] &= \int_{-\infty}^{+\infty} \alpha \cdot x \cdot f_X(x) dx \\ &= \alpha \cdot \int_{-\infty}^{+\infty} x \cdot f_X(x) dx \\ &= \alpha \cdot E[X]. \end{aligned}$$

Prop. 1.3 (Linearitá) Dati $\alpha, \beta \in \mathbb{R}$

$$E[\alpha X + \beta] = \alpha \cdot E[X] + \beta$$

Dimostrazione

$$\begin{aligned}
 E[\alpha X + \beta] &= \int_{-\infty}^{+\infty} (\alpha \cdot x + \beta) \cdot f_X(x) dx \\
 &= \alpha \cdot \int_{-\infty}^{+\infty} x \cdot f_X(x) dx + \beta \cdot \int_{-\infty}^{+\infty} f_X(x) dx \\
 &= \alpha \cdot E[X] + \beta.
 \end{aligned}$$

Si noti che la proprietà di linearità (1.3) ci dice che se definiamo una nuova VA Y come funzione lineare di X

$$Y = \alpha X + \beta$$

allora il valore atteso di Y , cioè $E[Y]$, è funzione lineare di $E[X]$

$$E[Y] = \alpha E[X] + \beta$$

2 Esempi con distribuzioni notevoli**2.1 Distribuzione Uniforme**

Consideriamo la distribuzione uniforme $Unif(a, b)$ la cui CDF è (cfr., Fig. 3):

$$F_X(x) = \frac{x - a}{b - a}.$$

La mediana in si calcola come il valore $X = x$ tale che $F_X(x) = \frac{1}{2}$; pertanto:

$$\begin{aligned}
 \frac{x - a}{b - a} &= \frac{1}{2} \\
 x - a &= \frac{b - a}{2} \\
 x &= \frac{b - a}{2} + a \\
 x_{mediana} &= \frac{b + a}{2}.
 \end{aligned}$$

Per quanto riguarda il valore atteso:




Figura 3: Funzione di ripartizione (CDF) della distribuzione uniforme $Unif(a, b)$

$$\begin{aligned}
E[X] &= \int_{-\infty}^{+\infty} x \cdot f_X(x) dx \\
&= \int_a^b x \cdot \frac{1}{b-a} dx \\
&= \frac{1}{b-a} \cdot \left[\frac{1}{2} \cdot x^2 \right]_a^b \\
&= \frac{1}{2(b-a)} \cdot (b^2 - a^2) \\
&= \frac{1}{2} \cdot \frac{(b-a)(b+a)}{b-a} \\
&= \frac{b+a}{2}.
\end{aligned}$$

2.2 Distribuzione Bernoulliana

Nel caso della distribuzione Bernoulliana

$$\text{Bern}(p) = p^x \cdot q^{1-x},$$

il valore medio si calcola utilizzando la sommatoria con x che può assumere solo due valori: 0 e 1.

$$\begin{aligned}
E[X] &= \sum_{x=0,1} x \cdot P_X(x) \\
&= \sum_{x=0,1} x \cdot p_X(x) \\
&= 0 \cdot p^0 \cdot q^1 + 1 \cdot p^1 \cdot q^0 \\
&= p
\end{aligned}$$

3 Limiti degli indicatori di posizione

In alcune distribuzioni particolari, alcuni indicatori di posizione non sono definiti ad eccezione della mediana: essa é sempre definita in qualunque distribuzione sia discreta che continua.

La moda non é sempre definita nelle distribuzioni continue, infatti nel caso in cui esista un intervallo di valori alla medesima frequenza massima, il valore modale non é definito. Un caso palese é rappresentato dalla distribuzione uniforme

Anche la media non é sempre definita: in alcuni casi l'integrale può assumere valore divergente. Un esempio é fornito dalla densità

$$f_X(x) = \frac{1}{x^2}:$$

$$\begin{aligned} E[X] &= \int_{-\infty}^{+\infty} x \cdot \frac{1}{x^2} dx \\ &= \int_{-\infty}^{+\infty} \frac{1}{x} dx \\ &= [\ln |x|]_{-\infty}^{+\infty} = \infty. \end{aligned}$$

4 Indici di dispersione o ampiezza

4.1 Quartile

Il quartile si può considerare un'estensione della mediana: esso ripartisce la distribuzione in quattro parti equivalenti.

I quartili vengono indicati nel seguente modo: $q_{\frac{1}{4}}$ (primo quartile), $q_{\frac{2}{4}}$ (secondo quartile, ovvero $q_{\frac{1}{2}}$ che corrisponde alla mediana), $q_{\frac{3}{4}}$ (terzo quartile).

La quantità

$$\Delta = q_{\frac{3}{4}} - q_{\frac{1}{4}}$$

é detta *scarto o intervallo interquartile*

Distribuzione uniforme Considerando ancora una VA distribuita uniformemente $X \sim Unif(a, b)$ con CDF

$$F_X(x) = \frac{x - a}{b - a},$$

i quartili si calcolano nel seguente modo.

Per il primo quartile:

$$x_{\frac{1}{4}} = a + \frac{b - a}{4}$$

Per il secondo quartile:

$$x_{\frac{1}{2}} = a + \frac{b - a}{2}$$

Per il terzo quartile:

$$x_{\frac{3}{4}} = a + \frac{3(b - a)}{4}$$

4.2 Percentile

I quartili si ottengono dividendo in quattro parti la distribuzione. Possiamo utilizzare una partizione piú fine, definendo i percentili. Il percentile ripartisce la distribuzione in cento parti equivalenti.




Figura 4: Rappresentazione grafica dei quartili




Figura 5: Quartili della distribuzione uniforme.

Definizione 4.1 Sia $0 < p < 100$. Il *percentile di ordine p* di una distribuzione (o p -mo percentile, se p è intero) è il valore di x che delimita il primo $p\%$ dei dati dai rimanenti.

Notiamo che, per esempio, $F_X(q_1) = \frac{1}{4} = 0.25$: dunque, il primo quartile corrisponde al 25-mo percentile. Analogamente, il secondo e il terzo corrispondono al 50-mo e al 75-mo

4.3 Quantile

Quartili e percentili sono casi particolari del quantile.

Definizione 4.2 Data X V.A. e un valore α definito $0 < \alpha < 1$, il *quantile di ordine α* è il più piccolo valore x_α tale che:

$$P(X \leq x_\alpha) = F_X(x_\alpha) \geq \alpha$$

Nel caso continuo $F_X(x_\alpha) = \alpha$.

Si noti che la disuguaglianza \geq è necessaria per contemplare anche il caso di VA discrete dove $F_X(x_\alpha)$ potrebbe non coincidere con α

Esempio 4.3 Data la densità

$$f_X(x) = \frac{3x^2}{4^3} e^{-\left(\frac{x}{4}\right)^3}$$

con $x \in (0, \infty)$ determinare l'intervallo I tale che la probabilità di X sia compresa tra 0.3 e 0.9.

Soluzione.

Calcoliamo la CDF.

$$F_X(x) = \int_0^x \frac{3t^2}{4^3} e^{-\left(\frac{t}{4}\right)^3} dt$$

Notiamo che:

$$\frac{3t^2}{4^3} e^{-\left(\frac{t}{4}\right)^3} = -\frac{d}{dt} \left[e^{-\left(\frac{t}{4}\right)^3} \right],$$

pertanto

$$\begin{aligned} F_X(x) &= \int_0^x \frac{3t^2}{4^3} e^{-\left(\frac{t}{4}\right)^3} dt \\ &= -\int_0^x \frac{d}{dt} \left[e^{-\left(\frac{t}{4}\right)^3} \right] dt \\ &= \left[-e^{-\left(\frac{t}{4}\right)^3} \right]_0^x \\ &= 1 - e^{-\left(\frac{x}{4}\right)^3} \end{aligned}$$

Troviamo l'estremo inferiore ponendo

$$F_X(x_{0.3}) = 1 - e^{-\left(\frac{x}{4}\right)^3} = 0.3,$$




Figura 6: Rappresentazione grafica dei percentili.

ovvero

$$e^{-\left(\frac{x}{4}\right)^3} = 0.7,$$

da cui prendendo il logaritmo di entrambi i termini

$$-\left(\frac{x}{4}\right)^3 = \ln 0.7 = -0.356$$

si ottiene $x_{0,3} \approx 2.84$.

Ripetendo gli stessi conti per $F_X(x_{0,9}) = 0.9$, si ha che $x_{0,9} = 5.28$.

In definitiva, l'intervallo

$$I = [2.84, 5.28]$$

é quello per cui

$$P(2.84 \leq X \leq 5.28) = 0.9 - 0.3 = 0.6$$

5 Indici di dispersione intorno alla media

Sia X una VA (discreta o continua), con valor medio

$$\langle X \rangle = E[X] = \begin{cases} \sum_x x \cdot p_X(x) & \text{se } X \text{ discreta,} \\ \int x \cdot f_X(x) dx & \text{se } X \text{ continua.} \end{cases} \quad (1)$$

Possiamo calcolare il valor medio di una funzione $g(X)$ definita sulla V.A. X :

$$\langle g(X) \rangle = E[g(X)] = \begin{cases} \sum_x g(x) \cdot p_X(x) & \text{se } X \text{ discreta,} \\ \int g(x) \cdot f_X(x) dx & \text{se } X \text{ continua.} \end{cases} \quad (2)$$

Definiamo una $g(X)$ come la funzione potenza r -ma di X , ovvero $g(X) = X^r$, che prende il nome di **momento di ordine r** , dunque:

$$\langle X^r \rangle = E[X^r] = \begin{cases} \sum_x x^r \cdot p_X(x) & \text{se } X \text{ discreta,} \\ \int x^r \cdot f_X(x) dx & \text{se } X \text{ continua.} \end{cases} \quad (3)$$

Di particolare interesse é il **momento di ordine 2**, del quale vedremo il suo utilizzo piú avanti.

$$\langle X^2 \rangle = E[X^2] = \begin{cases} \sum_x x^2 \cdot p_X(x) & \text{se } X \text{ discreta,} \\ \int x^2 \cdot f_X(x) dx & \text{se } X \text{ continua.} \end{cases} \quad (4)$$

La **varianza** é un indice di **ampiezza** che identifica la **dispersione** di una VA rispetto al Valor Medio.

$$\sigma_X^2 = \text{var}(X) = \langle (X - E[X])^2 \rangle = E[(X - E[X])^2] = \begin{cases} \sum_x (x - \langle X \rangle)^2 \cdot p_X(x) & \text{se } X \text{ discreta,} \\ \int (x - \langle X \rangle)^2 \cdot f_X(x) dx & \text{se } X \text{ continua.} \end{cases} \quad (5)$$

La **deviazione standard** é definita come la radice quadrata della varianza, ed é anche nota come **scarto quadratico medio**.

$$\sigma_X = \sqrt{\sigma_X^2} = \sqrt{\text{var}(X)} \quad (6)$$

Nel misure sperimentali é utilizzata per identificare la precisione di una misura a fronte di numerose misurazioni:

$$\langle X \rangle \pm \sigma_X$$

Il raggio di un cilindro meccanico é di 172.0mm ± 0.1mm

Un modo alternativo per calcolare la varianza é fornito dal seguente.

Lemma 5.1 *La varianza di una V.A. equivale alla differenza fra il suo momento di ordine 2 e il quadrato della suo valore atteso:*

$$\sigma_X^2 = E[(X - E[X])^2] = E[X^2] - E[X]^2 \quad (7)$$

Dimostrazione

$$\begin{aligned} E[(X - E[X])^2] &= \int (x - E[X])^2 \cdot f_X(x) dx = \\ &= \int (x^2 - 2x \cdot E[X] + E[X]^2) \cdot f_X(x) dx = \\ &= \underbrace{\int x^2 \cdot f_X(x) dx}_{E[X^2]} - 2E[X] \underbrace{\int x \cdot f_X(x) dx}_{E[X]} + E[X]^2 \underbrace{\int f_X(x) dx}_1 = \\ &= E[X^2] - 2E[X]E[X] + E[X]^2 \cdot 1 = \\ &= E[X^2] - E[X]^2. \end{aligned}$$

6 Varianza e Deviazione Standard delle Variabili Aleatorie notevoli

Vedremo ora il calcolo di questi indici di ampiezza per due distribuzioni notevoli: la Bernoulliana e l'Uniforme.

6.1 Varianza e deviazione standard di una VA Bernoulliana

$$\begin{aligned}
\sigma_{X \sim \text{Bern}(p)}^2 &= E[X^2] - E[X]^2 = \\
&= \sum_{x=0,1} x^2 \cdot p_{X \sim \text{Bern}(p)}(x) - p^2 = \\
&= \sum_{x=0,1} x^2 \cdot p^x \cdot q^{1-x} - p^2 = \\
&= p - p^2 = p \cdot (1 - p) = p \cdot q
\end{aligned} \tag{8}$$

$$\sigma_{X \sim \text{Bern}(p)} = \sqrt{p \cdot q}$$

6.2 Varianza e deviazione standard di una VA Uniforme

$$\begin{aligned}
\sigma_{X \sim \text{Unif}(a,b)}^2 &= E[X^2] - E[X]^2 = \\
&= \int_a^b x^2 \cdot f_{X \sim \text{Unif}(a,b)}(x) dx - \left(\frac{a+b}{2}\right)^2 = \\
&= \int_a^b \frac{x^2}{b-a} dx - \frac{(a+b)^2}{4} = \\
&= \frac{1}{b-a} \int_a^b x^2 dx - \frac{(a+b)^2}{4} = \\
&= \frac{1}{b-a} \left[\frac{x^3}{3} \right]_a^b - \frac{(a+b)^2}{4} = \\
&= \frac{b^3 - a^3}{3(b-a)} - \frac{(a+b)^2}{4} = \\
&= \frac{4(b^3 - a^3) - 3(b-a)(a+b)^2}{12(b-a)} = \\
&= \frac{(b-a)[4(b^2 + ab + a^2) - 3(a^2 + 2ab + b^2)]}{12(b-a)} = \\
&= \frac{4b^2 + 4ab + 4a^2 - 3a^2 - 6ab - 3b^2}{12} = \\
&= \frac{b^2 - 2ab + a^2}{12} = \\
&= \frac{(b-a)^2}{12}
\end{aligned} \tag{9}$$

$$\sigma_{X \sim \text{Unif}(a,b)} = \sqrt{\frac{(b-a)^2}{12}} = \frac{\sqrt{3}}{6} \cdot (b-a)$$

7 Disuguaglianza di Chebychev

Possiamo fornire un legame preciso fra varianza e deviazioni di X dal valore atteso $E[X]$ mediante la disuguaglianza di Chebychev




Figura 7: Rappresentazione della disuguaglianza di Chebychev. Si noti che, per costruzione, prendendo un valore x che cade nelle code $|x - \mu| \geq k\sigma$, ovvero la sua distanza da μ è $(x - \mu)^2 \geq k^2\sigma^2$

Teorema 7.1 Sia X una VA, con $E[X] = \mu$ e $\text{var}(X) = \sigma^2$, allora $\forall k \in \mathbb{R} > 0$ vale la seguente:

$$P_X(|X - \mu| \geq k\sigma) \leq \frac{1}{k^2} \quad (10)$$

o anche:

$$P_X(|X - \mu| < k\sigma) \geq 1 - \frac{1}{k^2}.$$

Dimostrazione

a) $0 < k < 1$.

Se $0 < k < 1$ abbiamo

$$P_X(|X - \mu| \geq k\sigma) \leq 1 < \frac{1}{k^2}$$

che é sempre valida per l'assioma di normalizzazione.

b) $k \geq 1$

Si consideri la Figura 7 e la disuguaglianza $(x - \mu)^2 \geq k^2\sigma^2$. Per definizione di varianza e per l'ipotesi $\text{var}(X) = \sigma^2$:

$$\begin{aligned} \sigma^2 &= \int_{-\infty}^{+\infty} (x - \mu)^2 \cdot f(x) dx = \\ &= \int_{-\infty}^{\mu - k\sigma} (x - \mu)^2 \cdot f(x) dx + \int_{\mu - k\sigma}^{\mu + k\sigma} (x - \mu)^2 \cdot f(x) dx + \int_{\mu + k\sigma}^{+\infty} (x - \mu)^2 \cdot f(x) dx \geq \\ &\geq k^2\sigma^2 \int_{-\infty}^{\mu - k\sigma} f(x) dx + \int_{\mu - k\sigma}^{\mu + k\sigma} (x - \mu)^2 f(x) dx + k^2\sigma^2 \int_{\mu + k\sigma}^{+\infty} f(x) dx \geq \\ &\geq k^2\sigma^2 \left(\underbrace{\int_{-\infty}^{\mu - k\sigma} f(x) dx}_{P_X(X \leq \mu - k\sigma)} + \underbrace{\int_{\mu + k\sigma}^{+\infty} f(x) dx}_{P_X(X \geq \mu + k\sigma)} \right) \end{aligned}$$

$$\Rightarrow \sigma^2 \geq k^2\sigma^2 \cdot P_X(|X - \mu| \geq k\sigma)$$

$$\Rightarrow \frac{1}{k^2} \geq P_X(|X - \mu| \geq k\sigma)$$

Questa é una relazione del tutto generale, dimostrabile anche nel caso discreto: l'unica condizione é l'esistenza di media e varianza finite. La disuguaglianza ci dice che la probabilitá che X ha di deviare di $k\sigma$ dal suo valore atteso tende rapidamente a 0 per $k \rightarrow \infty$.

In pratica ci dice che negli intervalli centrati sulla media e ampi 2σ e 3σ sono compresi rispettivamente *almeno* il 75% e il 90% della probabilitá totale. Una Tabella precisa che indica, al variare di k , la percentuale di probabilitá totale intorno alla media e nelle code destra e sinistra é riportata in Figura 8.

La disuguaglianza dá luogo alla **legge 3σ generalizzata**, che con-

Legge 3σ generalizzata

siste nel ritenere trascurabili *per qualunque distribuzione statistica*, le probabilità di avere valori fuori dall'intervallo

$$[\mu - 3\sigma, \mu + 3\sigma]$$

k	Min. % within k standard deviations of mean	Max. % beyond k standard deviations from mean
1	0%	100%
$\sqrt{2}$	50%	50%
1.5	55.56%	44.44%
2	75%	25%
3	88.8889%	11.1111%
4	93.75%	6.25%
5	96%	4%
6	97.2222%	2.7778%
7	97.9592%	2.0408%
8	98.4375%	1.5625%
9	98.7654%	1.2346%
10	99%	1%

Figura 8: Percentuale di probabilità totale nell'intorno $k\sigma$ della media e nelle code destra e sinistra

Esempio 7.2 Il numero di pezzi prodotti da una fabbrica durante una settimana è una VA di media $\mu = 50$ e di varianza pari a $\sigma^2 = 25$. Cosa si può dire sulla probabilità che la produzione sia compresa fra i 40 e 60 pezzi?

Soluzione. Possiamo ragionare in due modi. Poiché $\sigma^2 = 25$ allora $\sigma = 5$; ovvero, la produzione è caratterizzabile come di

$$50 \pm 5$$

pezzi a settimana. Affinché sia compresa fra i 40 e 60 pezzi occorre che

$$50 \pm 2\sigma$$

da cui $k = 2$. Applicando Chebychev, nella forma $P_X(|X - \mu| \leq k\sigma) \geq 1 - \frac{1}{k^2}$ si ha che

$$P_X(40 \leq X \leq 60) = P_X(|X - 50| \leq 10) \geq 1 - \frac{1}{4} = \frac{3}{4}$$

Guardando la tabella di Figura 8, la probabilità che la produzione sia compresa fra i 40 e 60 pezzi è almeno del 75%.

Oppure, ponendo $r = k\sigma$ in Chebychev, la riscrivo come

$$P_X(|X - \mu| \geq k\sigma) \leq \frac{1}{k^2} = P_X(|X - \mu| \geq r) \leq \frac{\sigma^2}{r^2}$$

da cui direttamente:

$$P_X(|X - \mu| \geq r) \leq \frac{\sigma^2}{r^2} = P_X(|X - 50| \geq 10) \leq \frac{25}{10^2} = \frac{1}{4}$$

Dunque $P_X(40 \leq X \leq 60) = 1 - \frac{1}{4}$.

Si noti ancora una volta che il risultato è stato ottenuto senza avere identificato un modello probabilistico preciso per la distribuzione $P_X(X = x)$