

Probabilità e Processi Stocastici (455AA)

Lezione 9

Dario Trevisan

21/10/2024

Section 1

Covarianza

Richiami

- *Varianza* $\text{Var}(X) = \mathbb{E}[(X - \mathbb{E}[X])^2] = \mathbb{E}[X^2] - \mathbb{E}[X]^2$

$$P(|X - \mathbb{E}[X]| \leq k\sigma_X) \geq 1 - \frac{1}{k^2}$$

Richiami

- *Varianza* $\text{Var}(X) = \mathbb{E}[(X - \mathbb{E}[X])^2] = \mathbb{E}[X^2] - \mathbb{E}[X]^2$
- *Deviazione standard* $\sigma_X = \sqrt{\text{Var}(X)}$


$$P(|X - \mathbb{E}[X]| \leq k\sigma_X) \geq 1 - \frac{1}{k^2}$$

Richiami

- *Varianza* $\text{Var}(X) = \mathbb{E}[(X - \mathbb{E}[X])^2] = \mathbb{E}[X^2] - \mathbb{E}[X]^2$
- *Deviazione standard* $\sigma_X = \sqrt{\text{Var}(X)}$
- Diseguaglianza di Chebychev

$$P(|X - \mathbb{E}[X]| \leq k\sigma_X) \geq 1 - \frac{1}{k^2}$$

Richiami



- *Varianza* $\text{Var}(X) = \mathbb{E}[(X - \mathbb{E}[X])^2] = \mathbb{E}[X^2] - \mathbb{E}[X]^2 \geq 0$
- *Deviazione standard* $\sigma_X = \sqrt{\text{Var}(X)}$
- Diseguaglianza di Chebychev

$$P(|X - \mathbb{E}[X]| \leq k\sigma_X) \geq 1 - \frac{1}{k^2}$$

- *Covarianza*

$$\text{Cov}(X, Y) = \mathbb{E}[(X - \mathbb{E}[X])(Y - \mathbb{E}[Y])] = \underbrace{\mathbb{E}[XY] - \mathbb{E}[X]\mathbb{E}[Y]} \in \mathbb{R}$$

- Esempio $\theta \in [0, 2\pi]$ $X = \cos\theta$ $Y = \sin\theta$ \uparrow

Matrice delle covarianze

Dato un vettore aleatorio $X = (X_1, \dots, X_d) \in \mathbb{R}^d$, si definisce la matrice delle covarianze di X la matrice di numeri reali $\Sigma_X \in \mathbb{R}^{d \times d}$

$$(\Sigma_X)_{i,j} = \text{Cov}(X_i, X_j) = \mathbb{E}[X_i X_j] - \mathbb{E}[X_i] \mathbb{E}[X_j] \quad \text{per } i, j \in \{1, \dots, d\}.$$

- Notazioni alternative: $\text{Var}(X)$, K_{XX} o Q_X .

Proprietà

- La matrice delle covarianze è simmetrica $\Sigma_X = \Sigma_X^T$, dove T indica l'operazione di trasposizione.

$$\begin{pmatrix} \dots & \dots & (\Sigma_X)_{j,i} \\ \dots & \dots & \dots \\ (\Sigma_X)_{i,j} & \dots & \dots \end{pmatrix}$$

$$\begin{pmatrix} 1 & 2 & 4 \\ 2 & 3 & 5 \\ 4 & 5 & -6 \end{pmatrix}$$

Proprietà

- La matrice delle covarianze è simmetrica $\Sigma_X = \Sigma_X^T$, dove T indica l'operazione di trasposizione.
- (trasformazioni affini) Sia $X \in \mathbb{R}^d$ e

$$Y = AX + b \quad \text{ossia} \quad \boxed{Y_i = \sum_{j=1}^d A_{ij} X_j + b_i,}$$

dove $A \in \mathbb{R}^{k \times d}$ è una matrice e $b \in \mathbb{R}^k$ è un vettore (costanti). Vale

$$\mathbb{R}^{k \times k} \ni \Sigma_{AX+b} = A \Sigma_X A^T. \quad (A \Sigma_X A^T)_{i' i'}$$

$$\begin{aligned} \text{Cov}(Y_{i'}, Y_{i'}) &= \text{Cov}\left(\sum_j A_{ij'} X_j + b_{i'}, \sum_{j'} A_{i'j'} X_{j'} + b_{i'}\right) = \text{Cov}\left(\sum_j A_{ij'} X_j, \sum_{j'} A_{i'j'} X_{j'}\right) \\ &= \sum_{j, j'} A_{ij'} A_{i'j'} \text{Cov}(X_j, X_{j'}) = \sum_{j, j'} A_{ij'} (\Sigma_X)_{j j'} A_{i'j'} \end{aligned}$$

Proprietà

- La matrice delle covarianze è simmetrica $\Sigma_X = \Sigma_X^T$, dove T indica l'operazione di trasposizione.
- (trasformazioni affini) Sia $X \in \mathbb{R}^d$ e

$$Y = AX + b \quad \text{ossia} \quad Y_i = \sum_{j=1}^d A_{ij} X_j + b_i,$$

dove $A \in \mathbb{R}^{k \times d}$ è una matrice e $b \in \mathbb{R}^k$ è un vettore (costanti). Vale

$$\Sigma_{AX+b} = A \Sigma_X A^T.$$

- In particolare, se $k = 1$ e $A = v^T$, con $v \in \mathbb{R}^d$, si ottiene che

$$\text{Var}(v \cdot X) = \Sigma_{v \cdot X} = v^T \Sigma_X v \geq 0$$

ossia Σ_X è (semi-)definita positiva.

Dimostrazione

Altra dimostrazione della formula $\Sigma_{AX} = A \Sigma_X A^T$

$$(X - \mathbb{E}[X]) \in \mathbb{R}^d \quad \Sigma_X = \mathbb{E} \left[\underbrace{(X - \mathbb{E}[X]) (X - \mathbb{E}[X])^T}_{d \times d} \right]$$

$$Y = AX \quad \mathbb{E}[Y] = \mathbb{E}[AX] = A \mathbb{E}[X]$$

$$\begin{aligned} \Sigma_Y &= \mathbb{E} \left[(Y - \mathbb{E}[Y]) (Y - \mathbb{E}[Y])^T \right] \\ &= \mathbb{E} \left[A (X - \mathbb{E}[X]) \cdot (X - \mathbb{E}[X])^T A^T \right] \\ &= A \Sigma_X A^T \end{aligned}$$

Conseguenze: il coefficiente di correlazione

- Nel caso $d = 2$, scrivendo (X, Y) per la variabile congiunta di due variabili reali X, Y , la matrice delle covarianze è esplicitamente

$$\Sigma_{(X,Y)} = \begin{pmatrix} \text{Var}(X) & \text{Cov}(X, Y) \\ \text{Cov}(X, Y) & \text{Var}(Y) \end{pmatrix}.$$

Conseguenze: il coefficiente di correlazione

- Nel caso $d = 2$, scrivendo (X, Y) per la variabile congiunta di due variabili reali X, Y , la matrice delle covarianze è esplicitamente

$$\Sigma_{(X,Y)} = \begin{pmatrix} \text{Var}(X) & \text{Cov}(X, Y) \\ \text{Cov}(X, Y) & \text{Var}(Y) \end{pmatrix}.$$

- Essendo semidefinita positiva, il suo determinante è positivo (o nullo):

$$\det(\Sigma_{(X,Y)}) = \text{Var}(X) \text{Var}(Y) - (\text{Cov}(X, Y))^2 \geq 0,$$

$$\left| \frac{\text{Cov}(X,Y)}{\sigma_X \sigma_Y} \right| \leq \frac{\sqrt{\text{Var}(X) \text{Var}(Y)}}{\sigma_X \sigma_Y} = 1$$

$$\rho = \frac{\text{Cov}(X,Y)}{\sigma_X \sigma_Y} \in [-1, 1]$$

Conseguenze: il coefficiente di correlazione

- Nel caso $d = 2$, scrivendo (X, Y) per la variabile congiunta di due variabili reali X, Y , la matrice delle covarianze è esplicitamente

$$\Sigma_{(X,Y)} = \begin{pmatrix} \text{Var}(X) & \text{Cov}(X, Y) \\ \text{Cov}(X, Y) & \text{Var}(Y) \end{pmatrix}.$$

- Essendo semidefinita positiva, il suo determinante è positivo (o nullo):

$$\det(\Sigma_{(X,Y)}) = \text{Var}(X) \text{Var}(Y) - (\text{Cov}(X, Y))^2 \geq 0,$$

- ossia, dopo alcune operazioni elementari

$$\rho_{XY} := \frac{\text{Cov}(X, Y)}{\sigma_X \sigma_Y} \in [-1, 1].$$

Conseguenze: il coefficiente di correlazione

- Nel caso $d = 2$, scrivendo (X, Y) per la variabile congiunta di due variabili reali X, Y , la matrice delle covarianze è esplicitamente

$$\Sigma_{(X,Y)} = \begin{pmatrix} \text{Var}(X) & \text{Cov}(X, Y) \\ \text{Cov}(X, Y) & \text{Var}(Y) \end{pmatrix}.$$

- Essendo semidefinita positiva, il suo determinante è positivo (o nullo):

$$\det(\Sigma_{(X,Y)}) = \text{Var}(X) \text{Var}(Y) - (\text{Cov}(X, Y))^2 \geq 0,$$

- ossia, dopo alcune operazioni elementari

$$\rho_{XY} := \frac{\text{Cov}(X, Y)}{\sigma_X \sigma_Y} \in [-1, 1].$$

$\exists \in \{-1, 1\}$ se
 esiste λ se
 $Y = \lambda X + d$

- ρ_{XY} è il *coefficiente di correlazione* (o indice di correlazione di Pearson).

Standardizzazione nel caso vettoriale

Il teorema spettrale permette di decomporre

$$\Sigma_X = U^T D U,$$

dove $U \in \mathbb{R}^{d \times d}$, è ortogonale $U^T U = Id$ e D è diagonale (gli autovalori di Σ_X).

- La trasformazione UX , corrisponde ad un cambio di coordinate e trasforma la covarianza

$$\Sigma_{UX} = U \Sigma_X U^T = D$$

ossia le componenti di UX sono a due a due non correlate.

- Se D è invertibile si può definire una *standardizzazione* di X

$$\hat{X} = \sqrt{D}^{-1} U(X - \mathbb{E}[X])$$

dove \sqrt{D} è la matrice diagonale con entrate date dalla radice quadrata di quelle di D .

- Se D è invertibile si può definire una *standardizzazione* di X

$$\hat{X} = \sqrt{D}^{-1} U(X - \mathbb{E}[X])$$

dove \sqrt{D} è la matrice diagonale con entrate date dalla radice quadrata di quelle di D .

- Usando le proprietà del vettore delle medie e della varianza, si ha

$$\mathbb{E}[\hat{X}] = 0 \in \mathbb{R}^d \quad \text{e} \quad \Sigma_{\hat{X}} = Id.$$

(supponendo $D \succ 0$)

Problema

Un'urna contiene N palline di cui R rosse e $B = N - R$ blu. Si effettuano $n \leq N$ estrazioni senza rimpiazzo e si pone $X_i \in \{0, 1\}$ la variabile indicatrice dell'evento "l'esito della estrazione i è una pallina rossa".

- 1 Calcolare il coefficiente di correlazione tra X_1 e X_2 . Sono indipendenti?
- 2 Calcolare la matrice delle covarianze del vettore $(X_i)_{i=1}^n$.
- 3 Calcolare valor medio e varianza del numero totale Y di palline rosse estratte nelle n estrazioni.
- 4 La variabile Y è positivamente, negativamente o non correlata con X_1 ?

$$\text{Cov}(Y, X_1) = \text{Cov}\left(\sum_{i=1}^n X_i, X_1\right) = \sum_{i=1}^n \text{Cov}(X_i, X_1) = \frac{R}{N} \frac{B}{N} - \frac{(n-1)}{N-1} \frac{R}{N} \frac{B}{N} = \frac{RB}{N^2} \left(1 - \frac{n-1}{N}\right)$$

• X_1, X_2 variabili Bernoulli $\text{Cov}(X_1, X_2) = P(R_1 \cap R_2) - P(R_1)P(R_2)$
Negativamente correlate

$$\text{Var}(X_1) = P(R_1)(1 - P(R_1)) \\ = \frac{R}{N} \cdot \frac{B}{N}$$

$$\text{Var}(X_2) = \text{Var}(X_1) = \frac{R}{N} \cdot \frac{B}{N}$$

$$\rho_{X_1 X_2} = - \frac{\frac{R \cdot B}{N \cdot N} \cdot \frac{1}{N-1}}{\frac{R \cdot B}{N \cdot N}} = - \frac{1}{N-1} < 0$$

$(N \geq 2)$ $\rho \rightarrow 0$
 se $N \rightarrow \infty$

• OSS $P(X_i = 1 \mid X_j = 1) = \frac{R-1}{N-1} \quad \forall i \neq j$
 $P(X_j = 1) = \frac{R}{N}$

$$\begin{aligned} &= \frac{R}{N} \cdot \frac{R-1}{N-1} - \frac{R}{N} \cdot \frac{B}{N} \\ &= \frac{R}{N} \frac{(R-1) \cdot N - (N-1) \cdot B}{N(N-1)} \\ &= \frac{R}{N} \frac{R-N}{N(N-1)} \\ &= - \frac{R \cdot B}{N \cdot N(N-1)} \end{aligned}$$

$$Y = X_1 + X_2 + \dots + X_n$$

$$\underline{\underline{n \leq N}}$$

$$\begin{aligned} E[Y] &= E[X_1] + \dots + E[X_n] \\ &= n \cdot \frac{R}{N} \end{aligned}$$

$$\text{Var}(Y) < n \frac{R}{N} \left(1 - \frac{R}{N}\right) \leftarrow \text{caso con rimpiazzo}$$

$$\text{Cov}\left(\sum_{i=1}^n X_i, \sum_{j=1}^n X_j\right) = \sum_{i,j=1}^n \text{Cov}(X_i, X_j)$$

$$\begin{aligned} &= \sum_{i=1}^n \sum_{j=1}^n \frac{R}{N} \frac{B}{N} - \sum_{i \neq j} \frac{R}{N} \frac{B}{N} \frac{1}{N-1} \\ &= n \frac{R}{N} \left(1 - \frac{R}{N}\right) - (n^2 - n) \frac{R}{N} \frac{B}{N} \frac{1}{N-1} \end{aligned}$$

Problema



La durata della batteria di un drone è rappresentata tramite una variabile aleatoria T avente densità esponenziale di un parametro Λ , non del tutto noto e quindi rappresentato tramite una variabile aleatoria, anch'essa esponenziale, di parametro 1.

- 1 Dire se le variabili (Λ, T) sono tra loro indipendenti. *No*
- 2 Calcolare il coefficiente di correlazione tra Λ e T .
- 3 Si osserva che $T \geq 1$. Come cambia la densità di T ? e di Λ ? e il coefficiente di correlazione?

$$\Rightarrow \text{usare la densità } p(\Lambda = \lambda, T = t \mid T \geq 1) \propto \begin{cases} 0 & \text{se } t < 1 \\ e^{-\lambda} \lambda e^{-\lambda t} & \text{se } t \geq 1 \end{cases}$$

• Dal testo segue che $p(T=t | \Lambda=\lambda) = \lambda e^{-\lambda t}$ e z_0

T non è indipendente da λ ↗ dipende da λ

Se fossero indipendenti $p(T=t | \Lambda=\lambda) = p(T=t)$

• $Cov(T, \Lambda) = E[T\Lambda] - E[T]E[\Lambda]$ ↗ non dipende da λ

$$E[T\Lambda] = \int_0^{+\infty} E[T\Lambda | \Lambda=\lambda] p(\Lambda=\lambda) d\lambda = \int_0^{+\infty} \lambda \underbrace{E[T | \Lambda=\lambda]}_{\frac{1}{\lambda}} e^{-\lambda} d\lambda$$

↑ disintegrazione $\Lambda=\lambda$

$$= \int_0^{+\infty} \lambda \cdot \frac{1}{\lambda} e^{-\lambda} d\lambda = \int_0^{+\infty} e^{-\lambda} d\lambda = 1$$

Se $T \geq 1$ come cambiano le risposte?

debbono calcolare $P(T=t, \Lambda=\lambda | T \geq 1) =$

$$= P(\underbrace{\Lambda=\lambda}_{\text{evento}} | T \geq 1) \cdot P(T=t | \underbrace{T \geq 1, \Lambda=\lambda}_{\text{evento}})$$

$$= \frac{P(T \geq 1 | \Lambda=\lambda) P(\Lambda=\lambda)}{P(T \geq 1)} \cdot \frac{\lambda e^{-\lambda t}}{P(T \geq 1 | \Lambda=\lambda)} \quad \text{se } t \geq 1$$

Se X ha densità $p(X=x)$ e osserviamo $X \in U$

allora X condizionato a $X \in U$ ha densità

$$p(X=x) = \begin{cases} 0 & \text{se } x \notin U \\ p(X=x)/P(X \in U) & \text{se } x \in U \end{cases}$$

Section 2

Momenti

Approssimazione della legge tramite polinomi

Supponiamo di dover approssimare $\mathbb{E}[g(X)]$, dove $g : \mathbb{R} \rightarrow \mathbb{R}$ è una funzione regolare.

- Consideriamo uno sviluppo di Taylor per g

$$g(x) \sim a_0 + a_1x + a_2x^2 + \dots + a_kx^k$$

dove $a_j \in \mathbb{R}$ sono costanti, e per la linearità del valor medio

$$\mathbb{E}[g(X)] \sim a_0 + a_1\mathbb{E}[X] + a_2\mathbb{E}[X^2] + \dots + a_k\mathbb{E}[X^k].$$

Approssimazione della legge tramite polinomi

Supponiamo di dover approssimare $\mathbb{E}[g(X)]$, dove $g: \mathbb{R} \rightarrow \mathbb{R}$ è una funzione regolare.

- Consideriamo uno sviluppo di Taylor per g

$$g(x) \sim a_0 + a_1x + a_2x^2 + \dots + a_kx^k$$

dove $a_i \in \mathbb{R}$ sono costanti, e per la linearità del valor medio

$$\mathbb{E}[g(X)] \sim a_0 + a_1\mathbb{E}[X] + a_2\mathbb{E}[X^2] + \dots + a_k\mathbb{E}[X^k].$$

- Problemi:

Approssimazione della legge tramite polinomi

Supponiamo di dover approssimare $\mathbb{E}[g(X)]$, dove $g: \mathbb{R} \rightarrow \mathbb{R}$ è una funzione regolare.

- Consideriamo uno sviluppo di Taylor per g

$$g(x) \sim a_0 + a_1x + a_2x^2 + \dots + a_kx^k$$

dove $a_i \in \mathbb{R}$ sono costanti, e per la linearità del valor medio

$$\mathbb{E}[g(X)] \sim a_0 + a_1\mathbb{E}[X] + a_2\mathbb{E}[X^2] + \dots + a_k\mathbb{E}[X^k].$$

- Problemi:
 - 1 determinare un polinomio approssimante per g

Approssimazione della legge tramite polinomi

Supponiamo di dover approssimare $\mathbb{E}[g(X)]$, dove $g: \mathbb{R} \rightarrow \mathbb{R}$ è una funzione regolare.

- Consideriamo uno sviluppo di Taylor per g

$$g(x) \sim a_0 + a_1x + a_2x^2 + \dots + a_kx^k$$

dove $a_i \in \mathbb{R}$ sono costanti, e per la linearità del valor medio

$$\mathbb{E}[g(X)] \sim a_0 + a_1\mathbb{E}[X] + a_2\mathbb{E}[X^2] + \dots + a_k\mathbb{E}[X^k].$$

- Problemi:

- 1 determinare un polinomio approssimante per g
- 2 calcolare i valor medi $\mathbb{E}[X]$, $\mathbb{E}[X^2]$, \dots , $\mathbb{E}[X^k]$

I momenti

Sia $X \in \mathbb{R}$ una variabile aleatoria. Per ogni $k \in \mathbb{N}$, si dice **momento di ordine k** (o momento k -esimo) di X la quantità

$$\mathbb{E} [X^k],$$

se è ben definita (ricordiamo che si richiede che la serie o l'integrale che definisce $\mathbb{E} [X^k]$ debba convergere).

- se X ha densità (discreta o continua) vale

$$\mathbb{E} [X^k] = \begin{cases} \sum_{x \in \mathbb{R}} x^k P(X = x) & \text{se } X \text{ ha densità discreta,} \\ \int_{x \in \mathbb{R}} x^k p(X = x) dx & \text{se } X \text{ ha densità continua.} \end{cases}$$

Momento secondo e varianza, terzo

- La varianza è scrivibile come combinazione del momento secondo e dal momento primo:

$$\mathbb{E}[X^2] = \text{Var}(X) + (\mathbb{E}[X])^2,$$
$$\text{Var}(X) = \mathbb{E}[X^2] - (\mathbb{E}[X])^2$$


Momento secondo e varianza, terzo

- La varianza è scrivibile come combinazione del momento secondo e dal momento primo:

$$\mathbb{E}[X^2] = \text{Var}(X) + (\mathbb{E}[X])^2,$$

- Per gli ordini successivi si considerano anche i momenti della variabile standardizzata

$$X' = (X - \mathbb{E}[X]) / \sigma_X.$$



Momento secondo e varianza, terzo

- La varianza è scrivibile come combinazione del momento secondo e dal momento primo:

$$\mathbb{E} [X^2] = \text{Var} (X) + (\mathbb{E} [X])^2,$$

- Per gli ordini successivi si considerano anche i momenti della variabile standardizzata

$$X' = (X - \mathbb{E} [X]) / \sigma_X.$$

- il suo momento terzo è detto **skewness** di X (e indica eventuale asimmetria della densità rispetto alla media)

Momento secondo e varianza, terzo

- La varianza è scrivibile come combinazione del momento secondo e dal momento primo:

$$\mathbb{E} [X^2] = \text{Var} (X) + (\mathbb{E} [X])^2,$$

- Per gli ordini successivi si considerano anche i momenti della variabile standardizzata

$$X' = (X - \mathbb{E} [X]) / \sigma_X.$$

- il suo momento terzo è detto **skewness** di X (e indica eventuale asimmetria della densità rispetto alla media)
- il momento quarto è detto **kurtosi**.

La funzione generatrice dei momenti

Data $X \in \mathbb{R}$ una variabile aleatoria reale, si definisce la sua **funzione generatrice dei momenti** (in inglese *moment generating function*, **MGF**) la funzione $\text{MGF}_X : \mathbb{R} \rightarrow [0, \infty]$, che associa

$$t \mapsto \text{MGF}_X(t) = \mathbb{E} \left[e^{tX} \right].$$

- Per ciascun $t \in \mathbb{R}$, il valor medio si calcola quindi come

$$\text{MGF}_X(t) = \begin{cases} \sum_{x \in \mathbb{R}} e^{tx} P(X = x) & \text{se } X \text{ ha densità discreta,} \\ \int_{x \in \mathbb{R}} e^{tx} p(X = x) dx & \text{se } X \text{ ha densità continua.} \end{cases}$$

La funzione generatrice dei momenti

Data $X \in \mathbb{R}$ una variabile aleatoria reale, si definisce la sua **funzione generatrice dei momenti** (in inglese *moment generating function*, **MGF**) la funzione $\text{MGF}_X : \mathbb{R} \rightarrow [0, \infty]$, che associa

$$t \mapsto \text{MGF}_X(t) = \mathbb{E} \left[e^{tX} \right].$$

- Per ciascun $t \in \mathbb{R}$, il valor medio si calcola quindi come

$$\text{MGF}_X(t) = \begin{cases} \sum_{x \in \mathbb{R}} e^{tx} P(X = x) & \text{se } X \text{ ha densità discreta,} \\ \int_{x \in \mathbb{R}} e^{tx} p(X = x) dx & \text{se } X \text{ ha densità continua.} \end{cases}$$

- Se per qualche $t \in \mathbb{R}$ l'integrale o la serie che definiscono il valor medio di $\mathbb{E} \left[e^{tX} \right]$ non convergono, si pone $\text{MGF}_X(t) = \infty$.

• $f(x)$ trasformata di Laplace

$$\int_{-\infty}^{+\infty} e^{tx} f(x) dx$$

La funzione generatrice dei momenti

Data $X \in \mathbb{R}$ una variabile aleatoria reale, si definisce la sua **funzione generatrice dei momenti** (in inglese *moment generating function*, **MGF**) la funzione $\text{MGF}_X : \mathbb{R} \rightarrow [0, \infty]$, che associa

$$t \mapsto \text{MGF}_X(t) = \mathbb{E} \left[e^{tX} \right].$$

- Per ciascun $t \in \mathbb{R}$, il valor medio si calcola quindi come

$$\text{MGF}_X(t) = \begin{cases} \sum_{x \in \mathbb{R}} e^{tx} P(X = x) & \text{se } X \text{ ha densità discreta,} \\ \int_{x \in \mathbb{R}} e^{tx} p(X = x) dx & \text{se } X \text{ ha densità continua.} \end{cases}$$

- Se per qualche $t \in \mathbb{R}$ l'integrale o la serie che definiscono il valor medio di $\mathbb{E} \left[e^{tX} \right]$ non convergono, si pone $\text{MGF}_X(t) = \infty$.
- Per $t = 0$,

$$\text{MGF}_X(0) = \mathbb{E} \left[e^{0 \cdot X} \right] = \mathbb{E} [1] = 1.$$

Esempi

$$p(X=x) = \begin{cases} \lambda e^{-\lambda x} & x \geq 0 \\ 0 & x < 0 \end{cases}$$

$$M_{GF_X}(t) = \int_{-\infty}^{+\infty} e^{tx} p(X=x) dx = \int_0^{+\infty} \underbrace{e^{tx}} \lambda \underbrace{e^{-\lambda x}} dx$$

Sia $X \in \mathbb{R}$ con densità continua esponenziale di parametro $\lambda > 0$. Allora

$$\lambda \int_{-\frac{t-\lambda}{\lambda}}^{+\infty} e^{x(t-\lambda)} dx = \begin{cases} +\infty & \text{se } t \geq \lambda \\ \frac{\lambda}{\lambda-t} & \text{se } t < \lambda \end{cases}$$

Esempi discreti

$$\text{Binomiale}(n, p)(k) = \binom{n}{k} p^k (1-p)^{n-k} \quad k \in \{0, 1, \dots, n\}$$

$$\text{PGF}(t) = \sum_{k=0}^n e^{tk} \binom{n}{k} p^k (1-p)^{n-k} = \sum_{k=0}^n \binom{n}{k} (e^t p)^k (1-p)^{n-k}$$

$$\begin{cases} x = e^t p \\ y = 1-p \\ \sum \binom{n}{k} x^k y^{n-k} = (x+y)^n \end{cases} = (e^t p + (1-p))^n$$

Se $n=1$ Binomiale(1, p) = Bernoulli(p) \Rightarrow PGF(t) = $1-p + e^t p$

Proprietà della MGF

Siano $X, Y \in \mathbb{R}$ variabili aleatorie e $a, b \in \mathbb{R}$ costanti. Allora

$$\textcircled{1} \text{MGF}_{aX+b}(t) = e^{tb} \text{MGF}_X(at)$$

$$\begin{array}{c} | \\ \mathbb{E}[\exp((aX+b)t)] = \mathbb{E}[\exp(bt) \exp((at)X)] \end{array}$$

Proprietà della MGF

Siano $X, Y \in \mathbb{R}$ variabili aleatorie e $a, b \in \mathbb{R}$ costanti. Allora

- 1 MGF $_{aX+b}(t) = e^{tb} \text{MGF}_X(at)$
- 2 Se X, Y sono indipendenti, allora $\text{MGF}_{X+Y}(t) = \text{MGF}_X(t) \text{MGF}_Y(t)$.

$$E[\exp((X+Y)t)] = E[\underbrace{\exp(Xt)}_{h(X)} \underbrace{\exp(Yt)}_{g(Y)}] = E[\exp(Xt)] \cdot E[\exp(Yt)]$$

Dimostrazione

Dalla MGF ai momenti

Sia $X \in \mathbb{R}$ tale che $\text{MGF}_X(t) < \infty$ per ogni $t \in (-\varepsilon, \varepsilon)$, per qualche $\varepsilon > 0$. Allora, per ogni $k \in \mathbb{N}$, X ha momento di ordine k ben definito e vale

$$\frac{d^k}{d^k t} \text{MGF}_X(0) = \mathbb{E} [X^k].$$

- Per calcolare il momento di ordine k è quindi sufficiente derivare k volte la $\text{MGF}_X(t)$ e successivamente porre $t = 0$.

Dimostrazione (cenno)

$$\mathbb{E}[e^{tX}] = \mathbb{E}\left[\sum_{k=0}^{+\infty} \frac{(tX)^k}{k!}\right] = \sum_{k=0}^{+\infty} \frac{\mathbb{E}[(tX)^k]}{k!}$$

$$\boxed{\text{MGF}_X(t) = \sum_{k=0}^{+\infty} \frac{t^k}{k!} \mathbb{E}[X^k]}$$

↓ Coeff. dello sviluppo Taylor intorno

$$\begin{aligned} \left. \frac{d}{dt} \mathbb{E}[e^{tX}] \right|_{t=0} &= \lim_{h \rightarrow 0} \frac{\mathbb{E}[e^{(t+h)X}] - \mathbb{E}[e^{tX}]}{h} \\ &= \lim_{h \rightarrow 0} \mathbb{E}\left[\frac{e^{(t+h)X} - e^{tX}}{h}\right] = \mathbb{E}\left[\left. \frac{d}{dt} e^{tX} \right|_{t=0}\right] = \mathbb{E}[X] \end{aligned}$$

Il caso vettoriale

Si può estendere il concetto di momento a variabili vettoriali $X \in \mathbb{R}^d$, considerando prodotti delle marginali.

- Il momento primo corrisponde al vettore dei valor medi,

$$\left(\mathbb{E}[X_i] \right)_{i=1, \dots, d}$$

Il caso vettoriale

Si può estendere il concetto di momento a variabili vettoriali $X \in \mathbb{R}^d$, considerando prodotti delle marginali.

- Il momento primo corrisponde al vettore dei valor medi,
- il vettore secondo alla collezione

$$\mathbb{E}[X_i X_j] \quad \text{per } i, j \in \{1, \dots, d\} \text{ (anche } i = j)$$

Il caso vettoriale

Si può estendere il concetto di momento a variabili vettoriali $X \in \mathbb{R}^d$, considerando prodotti delle marginali.

- Il momento primo corrisponde al vettore dei valor medi,
- il vettore secondo alla collezione

$$\mathbb{E}[X_i X_j] \quad \text{per } i, j \in \{1, \dots, d\} \text{ (anche } i = j)$$

- il momento terzo

$$\mathbb{E}[X_i X_j X_k] \quad \text{per } i, j, k \in \{1, \dots, d\}.$$

Il caso vettoriale

Si può estendere il concetto di momento a variabili vettoriali $X \in \mathbb{R}^d$, considerando prodotti delle marginali.

- Il momento primo corrisponde al vettore dei valor medi,
- il vettore secondo alla collezione

$$\mathbb{E}[X_i X_j] \quad \text{per } i, j \in \{1, \dots, d\} \text{ (anche } i = j)$$

- il momento terzo

$$\mathbb{E}[X_i X_j X_k] \quad \text{per } i, j, k \in \{1, \dots, d\}.$$

- La MGF di X vettoriale è funzione di $t = (t_1, t_2, \dots, t_d) \in \mathbb{R}^d$,

$$\text{MGF}_X(t) = \mathbb{E} \left[\exp \left(\sum_{i=1}^d t_i X_i \right) \right] = \mathbb{E} \left[\exp(t \cdot X) \right]$$

$$\bullet \text{MGF}_{AX+b}(t) = e^{t \cdot b} \text{MGF}_X(A^T t)$$

$$t \cdot (AX) = t^T A X = (A^T t)^T X$$

$$\bullet \text{MGF}_{X+Y}(t) = \text{MGF}_X(t) \text{MGF}_Y(t) \quad \text{se } X, Y \text{ indep}$$

$$\bullet \mathbb{E}[X_1^{d_1} X_2^{d_2} \dots X_d^{d_d}] = \frac{\partial^{d_1 + \dots + d_d}}{(\partial t_1)^{d_1} (\partial t_2)^{d_2} \dots (\partial t_d)^{d_d}} \text{MGF}(t) \Big|_{t=0}$$

$$\bullet \mathbb{E}[X_1 X_2] = \frac{\partial^2}{\partial t_1 \partial t_2} \text{MGF}_X(t) \Big|_{t_1=t_2=0}$$

Section 3

Richiami sulla trasformata di Fourier

Caso finito

Fissano $n \in \mathbb{N}$, si consideri un segnale definito (o misurato) su un intervallo discreto di n valori

$$g : \{0, 1, \dots, (n-1)\} \rightarrow \mathbb{C}, \quad t \mapsto g(t).$$

Si definisce la sua *trasformata di Fourier* come la funzione

$$\frac{2\pi\xi}{n} = \omega$$

$$\hat{g} : \{0, 1, \dots, (n-1)\} \rightarrow \mathbb{C}, \quad \xi \mapsto \hat{g}(\xi) := \sum_{t=0}^{n-1} g(t) e^{-2\pi i t \xi / n}.$$

- Il dominio della g può essere pensato come un insieme di tempi

Caso finito

Fissano $n \in \mathbb{N}$, si consideri un *segnale* definito (o misurato) su un intervallo discreto di n valori

$$g : \{0, 1, \dots, (n-1)\} \rightarrow \mathbb{C}, \quad t \mapsto g(t).$$

Si definisce la sua *trasformata di Fourier* come la funzione

$$\hat{g} : \{0, 1, \dots, (n-1)\} \rightarrow \mathbb{C}, \quad \xi \mapsto \hat{g}(\xi) := \sum_{t=0}^{n-1} g(t) e^{-2\pi i t \xi / n}.$$

- Il dominio della g può essere pensato come un insieme di tempi
- il dominio di \hat{g} come *frequenze* ξ (precisamente, le frequenze sarebbero ξ/n , mentre le frequenze angolari $2\pi\xi/n$)

Notazione matriciale

Interpretiamo $g = (g(t))_{t=0}^{n-1}$ e $(\hat{g}(\xi))_{\xi=0}^{n-1}$ come vettori in \mathbb{C}^n : allora $\hat{g} = Fg$, dove $F \in \mathbb{C}^{n \times n}$

$$F_{\xi t} = e^{-2\pi i t \xi / n}.$$

La matrice F è unitaria, ossia l'inversa di F è la sua trasposta coniugata (a meno di una costante $1/n$). Per $s, t \in \{0, 1, \dots, n-1\}$,

$$(\bar{F}^T F)_{st} = \sum_{\xi=0}^{n-1} \underbrace{e^{2\pi i s \xi / n}}_{\bar{F}_{s\xi}^T} e^{-2\pi i t \xi / n} = \begin{cases} n & \text{se } s = t \\ 0 & \text{altrimenti.} \end{cases}$$

Per dimostrarlo basta ricordare la somma geometrica

$\sum_{j=0}^{k-1} z^j = (z^k - 1)/(z - 1)$ e il fatto che $e^{2\pi i} = 1$.

$$z = e^{2\pi i (s-t)}$$

Formula di inversione

Come prima conseguenza otteniamo la formula di inversione

$$g = \frac{1}{n} \bar{F}^t F g,$$

che esplicitamente diventa

$$g(t) = \frac{1}{n} \sum_{\xi=0}^{n-1} \hat{g}(\xi) e^{2\pi i \xi t/n}.$$

Identità dell'energia

$$\sum_{\xi \rightarrow \infty}^{n-1} |\hat{g}(\xi)|^2 = n \sum_{s=0}^{n-1} |g(s)|^2$$

Una seconda conseguenza è il fatto che la norma (Euclidea) del vettore g coincide (a meno di un fattore $1/n$) con quella del vettore \hat{g} , perché

$$|\hat{g}|^2 = \bar{F}g^T Fg = \bar{g}^T \bar{F}^T Fg = n\bar{g}^T g = n|g|^2.$$

- La norma $|g|^2$ può essere interpretata come una *energia* del segnale g , di conseguenza l'identità sopra mostra che la stessa energia può essere ottenuta sommando le energie associate alle singole frequenze, ossia $|\hat{g}(\xi)|^2$ (e dividendo per n).

Calcolo mediante R della trasformata di Fourier

- Tutte le trasformate di Fourier che si calcolano numericamente sono ridotte al caso di tempi finiti.

Calcolo mediante R della trasformata di Fourier

- Tutte le trasformate di Fourier che si calcolano numericamente sono ridotte al caso di tempi finiti.
- Per questo vi sono algoritmi particolarmente veloci, che in R si possono usare mediante la funzione `fft()`.

$$\hat{g} = \text{fft}(g)$$






Figure 1: esempio di un segnale finito (onda quadra) e della sua trasformata di Fourier

Possiamo anche verificare la formula di inversione, usando l'opzione `inverse = TRUE` nella stessa funzione `fft()`. Bisogna tuttavia ricordare il fattore n .



Caso discreto

Supponiamo ora di osservare un segnale definito su un tempo infinito discreto $g : \mathbb{Z} \rightarrow \mathbb{C}$ (è una situazione ideale ovviamente).

- L'analogia trasformazione stavolta definisce la trasformata di Fourier a tempi discreti

$$\hat{g} : [0, 1] \rightarrow \mathbb{C}, \quad \xi \mapsto \hat{g}(\xi) := \sum_{t \in \mathbb{Z}} g(t) e^{2\pi i t \xi},$$

purché la serie converga, ad esempio se

$$\left(\sum_{t \in \mathbb{Z}} |g(t)| < \infty. \right)$$

Caso discreto

Supponiamo ora di osservare un segnale definito su un tempo infinito discreto $g : \mathbb{Z} \rightarrow \mathbb{C}$ (è una situazione ideale ovviamente).

- L'analogia trasformazione stavolta definisce la trasformata di Fourier a tempi discreti

$$\hat{g} : [0, 1] \rightarrow \mathbb{C}, \quad \xi \mapsto \hat{g}(\xi) := \sum_{t \in \mathbb{Z}} g(t) e^{2\pi i t \xi},$$

purché la serie converga, ad esempio se

$$\sum_{t \in \mathbb{Z}} |g(t)| < \infty.$$

- Per passare dal finito al discreto l'idea è di cambiare la variabile frequenza nel caso discreto, ossia di passare da ξ a ξ/n , in modo che il dominio sia l'intervallo discreto $\{0, 1/n, 2/n, \dots, (n-1)/n\}$. In questo modo, per $n \rightarrow \infty$ si ottiene una funzione definita sull'intervallo continuo di frequenze $[0, 1]$.

Anche senza ricorrere al limite dal caso finito, si hanno la formula di inversione

$$g(t) = \int_0^1 \hat{g}(\xi) e^{2\pi i t \xi} d\xi,$$

e l'identità dell'energia

$$\sum_{t \in \mathbb{Z}} |g(t)|^2 = \int_0^1 |\hat{g}(\xi)|^2 d\xi.$$

- Il punto chiave è la relazione di ortogonalità

$$\int_0^1 e^{2\pi i s \xi} e^{-2\pi i t \xi} d\xi = \begin{cases} 1 & \text{se } s = t, \\ 0 & \text{altrimenti,} \end{cases}$$

che si dimostra ad esempio integrando per parti. Le due relazioni sopra seguono ripercorrendo la dimostrazione del caso finito sfruttando questa ortogonalità.

Operatore ritardo (lag) e trasformata

Definiamo l'operatore di *ritardo* L (in inglese *lag*), che trasforma g nel segnale

$$t \mapsto (Lg)(t) = g(t - 1),$$

allora

$$\widehat{Lg}(\xi) = \sum_{t \in \mathbb{Z}} g(t - 1) e^{-2\pi i t \xi} = e^{-2\pi i \xi} \widehat{g}(\xi).$$

In termini fisici, la traslazione (o ritardo) fa acquisire una fase alla trasformata.

- Iterando l'operazione, la fase si accumula: posta $L^s g(t) = g(t - s)$, ossia L applicata s -volte a g , si ha

$$\widehat{L^s g}(\xi) = e^{-2\pi i s \xi} \widehat{g}(\xi).$$

Convoluzione e trasformata

- Quando si interpreta g come un segnale, la *convoluzione* di g con un “filtro” $f : \mathbb{Z} \rightarrow \mathbb{C}$ è una operazione naturale:

$$(g * f)(t) = \sum_{s \in \mathbb{Z}} g(t - s)f(s).$$

Passando alla trasformata di Fourier, possiamo scrivere

$$\begin{aligned}
 \widehat{g * f}(\xi) &= \sum_{s \in \mathbb{Z}} \widehat{g(\cdot - s)} f(s)(\xi) \\
 &= \sum_{s \in \mathbb{Z}} \widehat{g(\cdot - s)}(\xi) f(s) \\
 &= \sum_{s \in \mathbb{Z}} L^s \widehat{g}(\xi) f(s) \\
 &= \sum_{s \in \mathbb{Z}} e^{-2\pi i s} \widehat{g}(\xi) f(s) \\
 &= \widehat{g}(\xi) \sum_{s \in \mathbb{Z}} e^{-2\pi i s} f(s) = \widehat{g}(\xi) \widehat{f}(\xi).
 \end{aligned}$$

- Nelle frequenze la convoluzione con un f diventa il prodotto con \widehat{f} .

Passando alla trasformata di Fourier, possiamo scrivere

$$\begin{aligned}
 \widehat{g * f}(\xi) &= \sum_{s \in \mathbb{Z}} \widehat{g(\cdot - s)} f(s)(\xi) \\
 &= \sum_{s \in \mathbb{Z}} \widehat{g(\cdot - s)}(\xi) f(s) \\
 &= \sum_{s \in \mathbb{Z}} L^s \widehat{g}(\xi) f(s) \\
 &= \sum_{s \in \mathbb{Z}} e^{-2\pi i s} \widehat{g}(\xi) f(s) \\
 &= \widehat{g}(\xi) \sum_{s \in \mathbb{Z}} e^{-2\pi i s} f(s) = \widehat{g}(\xi) \widehat{f}(\xi).
 \end{aligned}$$

- Nelle frequenze la convoluzione con un f diventa il prodotto con \widehat{f} .
- Identità dell'energia:

$$\sum_{t \in \mathbb{Z}} |g * f|^2(t) = \int_0^1 |\widehat{g}|^2(\xi) |\widehat{f}|^2(\xi) d\xi.$$

Caso continuo

Pasando da tempi da discreti a continui, si trova che per un segnale

$$g : \mathbb{R} \rightarrow \mathbb{C}$$

la trasformata è definita come

$$\hat{g} : \mathbb{R} \rightarrow \mathbb{C}, \quad \hat{g}(\xi) := \int_{-\infty}^{\infty} g(t) e^{-2\pi i t \xi} dt,$$

- purché l'integrale converga, ad esempio se

$$\int_{-\infty}^{\infty} |g(t)| dt < \infty.$$

Caso continuo

Pasando da tempi da discreti a continui, si trova che per un segnale

$$g : \mathbb{R} \rightarrow \mathbb{C}$$

la trasformata è definita come

$$\hat{g} : \mathbb{R} \rightarrow \mathbb{C}, \quad \hat{g}(\xi) := \int_{-\infty}^{\infty} g(t) e^{-2\pi i t \xi} dt,$$

- purché l'integrale converga, ad esempio se

$$\int_{-\infty}^{\infty} |g(t)| dt < \infty.$$

- Si può anche usare come variabile della trasformata la frequenza angolare $\omega = 2\pi\xi$

- Formula di inversione

$$g(t) = \int_{-\infty}^{\infty} \hat{g}(\xi) e^{2\pi i t \xi} d\xi,$$

(purché l'integrale abbia senso)

- Formula di inversione

$$g(t) = \int_{-\infty}^{\infty} \hat{g}(\xi) e^{2\pi i t \xi} d\xi,$$

(purché l'integrale abbia senso)

- Identità dell'energia

$$\int_{-\infty}^{\infty} |g(t)|^2 dt = \int_{-\infty}^{\infty} |\hat{g}(\xi)|^2 d\xi.$$

- Convoluzione con $f : \mathbb{R} \rightarrow \mathbb{C}$,

$$g * f(t) = \int_{-\infty}^{\infty} g(t-s)f(s)ds,$$

e nella base delle frequenze l'operazione si riduce ad un prodotto:

$$\widehat{g * f}(\xi) = \hat{g}(\xi)\hat{f}(\xi).$$

DSS Se X e Y sono continue e indipendenti $X+Y=Z$ ha densità data dalla convoluzione delle P_X, P_Y

$$P(X+Y=Z) = \int_{\mathbb{R}} P(Y=Z-x \mid X=x) P(X=x) dx$$

↑ eliminato per indep.

Entropia di una densità uniforme

- caso discreto

$$H(X \text{ uniforme su } n \text{ valori}) = - \sum_{i=1}^n \log\left(\frac{1}{n}\right) \frac{1}{n} = \log(n),$$

Entropia di una densità uniforme

- caso discreto

$$H(X \text{ uniforme su } n \text{ valori}) = - \sum_{i=1}^n \log\left(\frac{1}{n}\right) \frac{1}{n} = \log(n),$$

- caso continuo

$$\begin{aligned} H(X \text{ uniforme continua su } [a, b]) &= - \int_a^b \log\left(\frac{1}{b-a}\right) \frac{1}{b-a} dx \\ &= \log(b-a). \end{aligned}$$

Entropia di una densità uniforme

- caso discreto

$$H(X \text{ uniforme su } n \text{ valori}) = - \sum_{i=1}^n \log\left(\frac{1}{n}\right) \frac{1}{n} = \log(n),$$

- caso continuo

$$\begin{aligned} H(X \text{ uniforme continua su } [a, b]) &= - \int_a^b \log\left(\frac{1}{b-a}\right) \frac{1}{b-a} dx \\ &= \log(b-a). \end{aligned}$$

- In particolare, più grande è tale insieme, maggiore è l'entropia (c'è meno informazione).

Il principio di massima entropia

L'entropia ha un ruolo importante nel determinare densità (discrete o continue) per variabili aleatorie X .

- Si estende il principio di Laplace (per la probabilità uniforme) al **principio di massima entropia**.

Il principio di massima entropia

L'entropia ha un ruolo importante nel determinare densità (discrete o continue) per variabili aleatorie X .

- Si estende il principio di Laplace (per la probabilità uniforme) al **principio di massima entropia**.
- Qualora l'informazione disponibile permetta solo di indentificare una classe \mathcal{D} di densità ammissibili, allora *si sceglierà la densità per cui $H(X)$ sia massima tra quelle in \mathcal{D} .*

Il principio di massima entropia

L'entropia ha un ruolo importante nel determinare densità (discrete o continue) per variabili aleatorie X .

- Si estende il principio di Laplace (per la probabilità uniforme) al **principio di massima entropia**.
- Qualora l'informazione disponibile permetta solo di indentificare una classe \mathcal{D} di densità ammissibili, allora *si sceglierà la densità per cui $H(X)$ sia massima tra quelle in \mathcal{D}* .
- Molte densità notevoli sono di **massima entropia** in una opportuna classe, che ne giustifica l'uso nella pratica.

Esempi

- La densità uniforme (discreta) su un insieme E con n elementi massimizza l'entropia tra tutte le densità discrete su E .

Esempi

- La densità uniforme (discreta) su un insieme E con n elementi massimizza l'entropia tra tutte le densità discrete su E .
- La densità uniforme continua su $E = [a, b]$ massimizza l'entropia tra le densità continue nulle fuori da $[a, b]$.

- La densità esponenziale di parametro $\lambda = 1/m$ massimizza l'entropia tra le densità continue $p(X = x)$ nulle fuori da $[0, \infty)$ e di valor medio fissato

$$\int_0^{\infty} xp(X = x)dx = m.$$

- La densità esponenziale di parametro $\lambda = 1/m$ massimizza l'entropia tra le densità continue $p(X = x)$ nulle fuori da $[0, \infty)$ e di valor medio fissato

$$\int_0^{\infty} xp(X = x)dx = m.$$

- Tra le densità discrete a valori in \mathbb{N} con valor medio m , l'entropia è massima per una variabile con densità **geometrica**, ossia

$$P(X = k) \propto (1 - p)^k$$

Si calcola che

$$\mathbb{E}[X] = \frac{1 - p}{p},$$

da cui $p = 1/(m + 1)$ e quindi si può anche scrivere

$$P(X = k) = \frac{1}{m + 1} \left(\frac{m}{m + 1} \right)^k.$$