

# Probabilità e Processi Stocastici (455AA)

## Lezione 6

Dario Trevisan

12/10/2023

- Variabili aleatorie  $X = \{X = x\}_{x \in E}$

# Richiami

- Variabili aleatorie  $X = \{X = x\}_{x \in E}$
- Densità discreta/continua

# Richiami

- Variabili aleatorie  $X = \{X = x\}_{x \in E}$
- Densità discreta/continua
- Variabili composte  $g(X)$  e trasformazione delle densità

# Richiami

- Variabili aleatorie  $X = \{X = x\}_{x \in E}$
- Densità discreta/continua
- Variabili composte  $g(X)$  e trasformazione delle densità
- Variabili congiunte e marginali

# Richiami

- Variabili aleatorie  $X = \{X = x\}_{x \in E}$
- Densità discreta/continua
- Variabili composte  $g(X)$  e trasformazione delle densità
- Variabili congiunte e marginali
- Formula di Bayes

$$p(Y = y|X = x) \propto p(Y = y)L(Y = y; X = x)$$

# Richiami

- Variabili aleatorie  $X = \{X = x\}_{x \in E}$
- Densità discreta/continua
- Variabili composte  $g(X)$  e trasformazione delle densità
- Variabili congiunte e marginali
- Formula di Bayes

$$p(Y = y|X = x) \propto p(Y = y)L(Y = y; X = x)$$

- Indipendenza (anche per più di due variabili)

$$p(X = x|Y = y) = p(X = x)$$

# Section 1

## Reti bayesiane

# Reti Bayesiane

Presentiamo un metodo grafico per rappresentare le densità di variabili aleatorie (una specie di estensione dei diagrammi ad albero per variabili invece di eventi)

- Passo zero: si fissa un ordinamento tra le variabili (che corrisponde all'ordine in cui i sistemi di alternative vengono aggiunti nella costruzione del grafo ad albero):  $X_1, X_2, \dots, X_k$

Il diagramma è un grafo orientato su  $k$  nodi corrispondenti alle  $k$  variabili, viene costruito in  $k$  passi:

- nel primo passo si introduce solamente il nodo corrispondente alla variabile  $X_1$ ;

Il diagramma è un grafo orientato su  $k$  nodi corrispondenti alle  $k$  variabili, viene costruito in  $k$  passi:

- nel primo passo si introduce solamente il nodo corrispondente alla variabile  $X_1$ ;
- nel passo  $i$ -esimo, si introduce il nodo corrispondente alla variabile  $X_i$ , e si considera la densità di  $X_i$  condizionata a tutte le variabili inserite  $X_1, \dots, X_{i-1}$ ,

$$P(X_i = x_i | I, X_{i-1} = x_{i-1}, \dots, X_1 = x_1).$$

Il diagramma è un grafo orientato su  $k$  nodi corrispondenti alle  $k$  variabili, viene costruito in  $k$  passi:

- nel primo passo si introduce solamente il nodo corrispondente alla variabile  $X_1$ ;
- nel passo  $i$ -esimo, si introduce il nodo corrispondente alla variabile  $X_i$ , e si considera la densità di  $X_i$  condizionata a tutte le variabili inserite  $X_1, \dots, X_{i-1}$ ,

$$P(X_i = x_i | I, X_{i-1} = x_{i-1}, \dots, X_1 = x_1).$$

- si individua un sottoinsieme  $J \subseteq \{1, \dots, i-1\}$  tale che la densità dipenda solo dalle  $(X_j)_{j \in J}$ , ossia, per ogni  $x_1, \dots, x_i$ , valga

$$\begin{aligned} P(X_i = x_i | I, X_{i-1} = x_{i-1}, \dots, X_1 = x_1) \\ = P(X_i = x_i | I, X_j = x_j \text{ per ogni } j \in J). \end{aligned}$$

Il diagramma è un grafo orientato su  $k$  nodi corrispondenti alle  $k$  variabili, viene costruito in  $k$  passi:

- nel primo passo si introduce solamente il nodo corrispondente alla variabile  $X_1$ ;
- nel passo  $i$ -esimo, si introduce il nodo corrispondente alla variabile  $X_i$ , e si considera la densità di  $X_i$  condizionata a tutte le variabili inserite  $X_1, \dots, X_{i-1}$ ,

$$P(X_i = x_i | I, X_{i-1} = x_{i-1}, \dots, X_1 = x_1).$$

- si individua un sottoinsieme  $J \subseteq \{1, \dots, i-1\}$  tale che la densità dipenda solo dalle  $(X_j)_{j \in J}$ , ossia, per ogni  $x_1, \dots, x_i$ , valga

$$\begin{aligned} P(X_i = x_i | I, X_{i-1} = x_{i-1}, \dots, X_1 = x_1) \\ = P(X_i = x_i | I, X_j = x_j \text{ per ogni } j \in J). \end{aligned}$$

- si inseriscono gli archi orientati (freccie) da ciascun nodo corrispondente alle variabili  $X_j$ ,  $j \in J$ , verso il nodo corrispondente ad  $X_i$ .

Date  $k$  variabili aleatorie indipendenti  $X_1, \dots, X_k$ , l' algoritmo produce il diagramma:

- Si consideri una variabile aleatoria  $\Lambda$  tale che, condizionatamente ad essa, le variabili  $T_1, \dots, T_k$  sono indipendenti (un esempio concreto è  $\Lambda = \lambda$  individua il parametro delle variabili  $T_i$  che hanno legge esponenziale).

- Si consideri una variabile aleatoria  $\Lambda$  tale che, condizionatamente ad essa, le variabili  $T_1, \dots, T_k$  sono indipendenti (un esempio concreto è  $\Lambda = \lambda$  individua il parametro delle variabili  $T_i$  che hanno legge esponenziale).
- La densità congiunta ha la forma

$$P(\Lambda, T_1, T_2, T_3, T_4) = P(\Lambda)P(T_1|\Lambda)P(T_2|\Lambda)P(T_3|\Lambda)P(T_4|\Lambda).$$

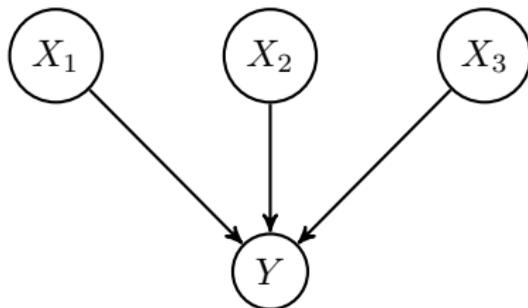
- Si consideri una variabile aleatoria  $\Lambda$  tale che, condizionatamente ad essa, le variabili  $T_1, \dots, T_k$  sono indipendenti (un esempio concreto è  $\Lambda = \lambda$  individua il parametro delle variabili  $T_i$  che hanno legge esponenziale).
- La densità congiunta ha la forma

$$P(\Lambda, T_1, T_2, T_3, T_4) = P(\Lambda)P(T_1|\Lambda)P(T_2|\Lambda)P(T_3|\Lambda)P(T_4|\Lambda).$$

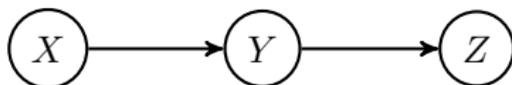
- La rete bayesiana costruita inserendo prima la variabile  $\Lambda$  e poi le rimanenti è la seguente:



Si considerino  $k$  variabili  $X_1, \dots, X_k$  indipendenti tra loro (rispetto all'informazione iniziale) e sia  $Y = g(X_1, \dots, X_k)$  (ad esempio  $Y = X_1 + \dots + X_k$  nel caso di variabili a valori in  $\mathbb{R}$ ). La rete bayesiana è rappresentata in figura.



Si consideri la rete bayesiana rappresentata in figura. Condizionando rispetto ad  $Y$ , si ottiene che  $X$  e  $Z$  sono indipendenti. Questo è un semplice esempio di *catena di Markov*.



## Section 2

# Cenni ai metodi numerici

# Dalla teoria alla pratica

- In teoria abbiamo tutti gli strumenti per affrontare problemi concreti:

# Dalla teoria alla pratica

- In teoria abbiamo tutti gli strumenti per affrontare problemi concreti:
  - a. Si definisce un *modello* con parametri  $\Theta$  e quantità osservabili  $X$  (una opportuna rete bayesiana)

# Dalla teoria alla pratica

- In teoria abbiamo tutti gli strumenti per affrontare problemi concreti:
  - a. Si definisce un *modello* con parametri  $\Theta$  e quantità osservabili  $X$  (una opportuna rete bayesiana)
  - b. Si stabiliscono probabilità *a priori* per  $\Theta$  (ad es. uniformi) e *verosimiglianza*  $L(\Theta = \theta; X = x) = P(X = x | \Theta = \theta)$

# Dalla teoria alla pratica

- In teoria abbiamo tutti gli strumenti per affrontare problemi concreti:
  - a. Si definisce un *modello* con parametri  $\Theta$  e quantità osservabili  $X$  (una opportuna rete bayesiana)
  - b. Si stabiliscono probabilità *a priori* per  $\Theta$  (ad es. uniformi) e *verosimiglianza*  $L(\Theta = \theta; X = x) = P(X = x | \Theta = \theta)$
  - c. Si aggiorna il modello incorporando i dati *osservati* (Bayes)

# Dalla teoria alla pratica

- In teoria abbiamo tutti gli strumenti per affrontare problemi concreti:
  - Si definisce un *modello* con parametri  $\Theta$  e quantità osservabili  $X$  (una opportuna rete bayesiana)
  - Si stabiliscono probabilità *a priori* per  $\Theta$  (ad es. uniformi) e *verosimiglianza*  $L(\Theta = \theta; X = x) = P(X = x | \Theta = \theta)$
  - Si aggiorna il modello incorporando i dati *osservati* (Bayes)
  - Si stimano i parametri  $\Theta$  (ad es. mediante MAP o MLE)

# Dalla teoria alla pratica

- In teoria abbiamo tutti gli strumenti per affrontare problemi concreti:
  - a. Si definisce un *modello* con parametri  $\Theta$  e quantità osservabili  $X$  (una opportuna rete bayesiana)
  - b. Si stabiliscono probabilità *a priori* per  $\Theta$  (ad es. uniformi) e *verosimiglianza*  $L(\Theta = \theta; X = x) = P(X = x | \Theta = \theta)$
  - c. Si aggiorna il modello incorporando i dati *osservati* (Bayes)
  - d. Si stimano i parametri  $\Theta$  (ad es. mediante MAP o MLE)
  - e. Si fanno *previsioni* su eventuali variabili non osservate usando

# Dalla teoria alla pratica

- In teoria abbiamo tutti gli strumenti per affrontare problemi concreti:
  - Si definisce un *modello* con parametri  $\Theta$  e quantità osservabili  $X$  (una opportuna rete bayesiana)
  - Si stabiliscono probabilità *a priori* per  $\Theta$  (ad es. uniformi) e *verosimiglianza*  $L(\Theta = \theta; X = x) = P(X = x | \Theta = \theta)$
  - Si aggiorna il modello incorporando i dati *osservati* (Bayes)
  - Si stimano i parametri  $\Theta$  (ad es. mediante MAP o MLE)
  - Si fanno *previsioni* su eventuali variabili non osservate usando
- Il problema è che nella pratica la numerosità sia dei dati osservati sia dei parametri è elevata e questo si richiede di calcolare densità di probabilità su spazi di *dimensione elevata*, che diventa impraticabile analiticamente.

## Densità coniugate

Per certe funzioni di verosimiglianza, si possono introdurre delle densità a priori (*coniugate*) particolarmente convenienti perché la densità a posteriori è nella stessa classe.

- In  $n$  esperimenti indipendenti, ciascuno con probabilità di successo  $Y = y$ , il numero  $X$  di successi ha una densità binomiale

$$L(Y = y; X = k) = P(X = k | Y = y) = \binom{n}{k} y^k (1 - y)^{n-k}.$$

## Densità coniugate

Per certe funzioni di verosimiglianza, si possono introdurre delle densità a priori (*coniugate*) particolarmente convenienti perché la densità a posteriori è nella stessa classe.

- In  $n$  esperimenti indipendenti, ciascuno con probabilità di successo  $Y = y$ , il numero  $X$  di successi ha una densità binomiale

$$L(Y = y; X = k) = P(X = k | Y = y) = \binom{n}{k} y^k (1 - y)^{n-k}.$$

- Se la densità di  $Y$  a priori è *Beta* di parametri  $\alpha, \beta > 0$ , ossia

$$p(Y = y) \propto y^{\alpha-1} (1 - y)^{\beta-1},$$

allora la densità a posteriori avendo osservato  $X = k$  successi è ancora Beta:

$$p(Y = y | X = k) \propto y^{\alpha+k-1} (1 - y)^{\beta+n-k-1}.$$

# Problema

Una routine probabilistica fornisce l'output desiderato con probabilità  $p \in [0, 1]$  non nota. Ogni applicazione dell'algoritmo produce esiti tra di loro indipendenti. Si modella inizialmente  $p$  come una variabile uniforme su  $[0, 1]$ .

- Dopo aver effettuato 100 esperimenti, avendo osservato che l'output è corretto su 60 di questi, scrivere la densità a posteriori per  $p$  e riconoscere una densità beta. Determinare la stima di massimo a posteriori.

# Problema

Una routine probabilistica fornisce l'output desiderato con probabilità  $p \in [0, 1]$  non nota. Ogni applicazione dell'algoritmo produce esiti tra di loro indipendenti. Si modella inizialmente  $p$  come una variabile uniforme su  $[0, 1]$ .

- Dopo aver effettuato 100 esperimenti, avendo osservato che l'output è corretto su 60 di questi, scrivere la densità a posteriori per  $p$  e riconoscere una densità beta. Determinare la stima di massimo a posteriori.
- Come cambia la risposta se invece si effettuano 1000 esperimenti e si osserva un output corretto su 600 di questi?

# Tecniche numeriche

Le densità coniugate non risolvono completamente il problema, in particolare se la numerosità delle osservazioni è molto grande.

Si ricorre a metodi numerici. Due approcci fondamentali:

- Approssimare tutta la densità a posteriori di  $Y$

# Tecniche numeriche

Le densità coniugate non risolvono completamente il problema, in particolare se la numerosità delle osservazioni è molto grande.

Si ricorre a metodi numerici. Due approcci fondamentali:

- Approssimare tutta la densità a posteriori di  $Y$
- Determinare solamente la stima di massima verosimiglianza  $y_{\text{MAP}}$

# Integrazione numerica

Nel primo caso il problema è quindi di approssimare numericamente un integrale

$$P(Y \in U|I) = \int_U p(Y = y|I)dy.$$

- Negli esempi seguiamo un approccio elementare: calcolare  $p(Y = y|I)$  su una griglia

# Integrazione numerica

Nel primo caso il problema è quindi di approssimare numericamente un integrale

$$P(Y \in U|I) = \int_U p(Y = y|I) dy.$$

- Negli esempi seguiamo un approccio elementare: calcolare  $p(Y = y|I)$  su una griglia
- Problema: se  $Y$  è a valori in  $[0, 1]^d \subseteq \mathbb{R}^d$  e il passo è  $\delta y$ , si devono calcolare circa

$$\frac{1}{\delta^d}$$

valori (e  $d$  è molto grande).

# Integrazione numerica

Nel primo caso il problema è quindi di approssimare numericamente un integrale

$$P(Y \in U|I) = \int_U p(Y = y|I)dy.$$

- Negli esempi seguiamo un approccio elementare: calcolare  $p(Y = y|I)$  su una griglia
- Problema: se  $Y$  è a valori in  $[0, 1]^d \subseteq \mathbb{R}^d$  e il passo è  $\delta y$ , si devono calcolare circa

$$\frac{1}{\delta^d}$$

valori (e  $d$  è molto grande).

- Approcci alternativi cercano di ottimizzare la scelta dei punti, anche mediante scelte (pseudo)-*casuali* (metodi Monte Carlo).

# Metodi di ottimizzazione

Nel secondo caso il problema è di determinare il punto di massimo di una funzione

$$y_{\text{MLE}} = \arg \max \{L(Y = y; X = x)\}.$$

- Il problema generale è studiatissimo e vi sono molteplici algoritmi (Newton, ascesa gradiente. . .)

# Metodi di ottimizzazione

Nel secondo caso il problema è di determinare il punto di massimo di una funzione

$$y_{\text{MLE}} = \arg \max \{L(Y = y; X = x)\}.$$

- Il problema generale è studiatissimo e vi sono molteplici algoritmi (Newton, ascesa gradiente. . .)
- In R le funzioni `nlm()` e `optim()` permettono di applicare i principali.

# Metodi di ottimizzazione

Nel secondo caso il problema è di determinare il punto di massimo di una funzione

$$y_{\text{MLE}} = \arg \max \{L(Y = y; X = x)\}.$$

- Il problema generale è studiatissimo e vi sono molteplici algoritmi (Newton, ascesa gradiente. . .)
- In R le funzioni `nlm()` e `optim()` permettono di applicare i principali.
- Se la numerosità delle osservazioni  $X$  è troppo elevata, si ricorre a metodi probabilistici.

# Metodi di ottimizzazione

Nel secondo caso il problema è di determinare il punto di massimo di una funzione

$$y_{\text{MLE}} = \arg \max \{L(Y = y; X = x)\}.$$

- Il problema generale è studiatissimo e vi sono molteplici algoritmi (Newton, ascesa gradiente. . .)
- In R le funzioni `nlm()` e `optim()` permettono di applicare i principali.
- Se la numerosità delle osservazioni  $X$  è troppo elevata, si ricorre a metodi probabilistici.
- A volte  $Y = (Y_{\text{par}}, Y_{\text{hid}})$  e si richiede di massimizzare solo la verosimiglianza di  $Y_{\text{par}}$ . Necessità di ricorrere a metodi “misti” (ad esempio Expectation-Maximization).

# Problema

Il numero di clienti che entrano in un negozio in un dato giorno è rappresentato da una variabile con densità Poisson di parametro  $\Lambda > 0$  (inizialmente non noto). Si vuole stimare  $\lambda$  osservando gli ingressi in tre giorni consecutivi. Si suppone che a giorni diversi corrispondano numeri di ingressi indipendenti tra loro.

- Supponendo di avere osservato in sequenza  $X_1 = 4$ ,  $X_2 = 5$  e 3 ingressi nei tre giorni, fornire una stima di massima verosimiglianza per  $\lambda$ .

# Problema

Il numero di clienti che entrano in un negozio in un dato giorno è rappresentato da una variabile con densità Poisson di parametro  $\Lambda > 0$  (inizialmente non noto). Si vuole stimare  $\lambda$  osservando gli ingressi in tre giorni consecutivi. Si suppone che a giorni diversi corrispondano numeri di ingressi indipendenti tra loro.

- Supponendo di avere osservato in sequenza  $X_1 = 4$ ,  $X_2 = 5$  e 3 ingressi nei tre giorni, fornire una stima di massima verosimiglianza per  $\lambda$ .
- Supponendo che  $\Lambda$  sia a priori distribuito come una variabile esponenziale di parametro 1, avendo osservato la stessa sequenza 4, 5, 3 di ingressi, fornire la densità a posteriori e la stima di massimo a posteriori.

# Problema

Il numero di clienti che entrano in un negozio in un dato giorno è rappresentato da una variabile con densità Poisson di parametro  $\Lambda > 0$  (inizialmente non noto). Si vuole stimare  $\lambda$  osservando gli ingressi in tre giorni consecutivi. Si suppone che a giorni diversi corrispondano numeri di ingressi indipendenti tra loro.

- Supponendo di avere osservato in sequenza  $X_1 = 4$ ,  $X_2 = 5$  e 3 ingressi nei tre giorni, fornire una stima di massima verosimiglianza per  $\lambda$ .
- Supponendo che  $\Lambda$  sia a priori distribuito come una variabile esponenziale di parametro 1, avendo osservato la stessa sequenza 4, 5, 3 di ingressi, fornire la densità a posteriori e la stima di massimo a posteriori.
- Come cambiano le risposte se invece si osservano in sequenza  $X_1 \leq 4$ ,  $X_2 \leq 5$  e  $X_3 \leq 3$  ingressi?





## Section 3

# Indicatori caratteristici

# Come riassumere la legge di una variabile?

Indicatori di *posizione*, di *dispersione* e di *correlazione*.

- Funzione di ripartizione (CDF), funzione di sopravvivenza

# Come riassumere la legge di una variabile?

Indicatori di *posizione*, di *dispersione* e di *correlazione*.

- Funzione di ripartizione (CDF), funzione di sopravvivenza
- Funzione quantile, mediana (quartili, decili, ecc.)

# Come riassumere la legge di una variabile?

Indicatori di *posizione*, di *dispersione* e di *correlazione*.

- Funzione di ripartizione (CDF), funzione di sopravvivenza
- Funzione quantile, mediana (quartili, decili, ecc.)
- Valor medio

# Come riassumere la legge di una variabile?

Indicatori di *posizione*, di *dispersione* e di *correlazione*.

- Funzione di ripartizione (CDF), funzione di sopravvivenza
- Funzione quantile, mediana (quartili, decili, ecc.)
- Valor medio
- Varianza e deviazione standard

# Come riassumere la legge di una variabile?

Indicatori di *posizione*, di *dispersione* e di *correlazione*.

- Funzione di ripartizione (CDF), funzione di sopravvivenza
- Funzione quantile, mediana (quartili, decili, ecc.)
- Valor medio
- Varianza e deviazione standard
- Covarianza e correlazione.

# Come riassumere la legge di una variabile?

Indicatori di *posizione*, di *dispersione* e di *correlazione*.

- Funzione di ripartizione (CDF), funzione di sopravvivenza
- Funzione quantile, mediana (quartili, decili, ecc.)
- Valor medio
- Varianza e deviazione standard
- Covarianza e correlazione.
- Momenti e funzione generatrice dei momenti

# Come riassumere la legge di una variabile?

Indicatori di *posizione*, di *dispersione* e di *correlazione*.

- Funzione di ripartizione (CDF), funzione di sopravvivenza
- Funzione quantile, mediana (quartili, decili, ecc.)
- Valor medio
- Varianza e deviazione standard
- Covarianza e correlazione.
- Momenti e funzione generatrice dei momenti
- Funzione caratteristica

# Come riassumere la legge di una variabile?

Indicatori di *posizione*, di *dispersione* e di *correlazione*.

- Funzione di ripartizione (CDF), funzione di sopravvivenza
- Funzione quantile, mediana (quartili, decili, ecc.)
- Valor medio
- Varianza e deviazione standard
- Covarianza e correlazione.
- Momenti e funzione generatrice dei momenti
- Funzione caratteristica
- Cenni all'entropia

## Funzione di ripartizione e di sopravvivenza

Data  $X$  a valori in  $\mathbb{R}$ , si è spesso interessati a conoscere la probabilità che  $X$  assuma valori “grandi”.

- Esempio: la quantità di denaro che un investitore potrebbe guadagnare (se positiva) o perdere (se negativa) in una fissata data futura, a seconda dell'andamento del mercato

Definiamo

# Funzione di ripartizione e di sopravvivenza

Data  $X$  a valori in  $\mathbb{R}$ , si è spesso interessati a conoscere la probabilità che  $X$  assuma valori “grandi”.

- Esempio: la quantità di denaro che un investitore potrebbe guadagnare (se positiva) o perdere (se negativa) in una fissata data futura, a seconda dell'andamento del mercato

Definiamo

- 1 la **funzione di ripartizione** (o funzione cumulativa, in inglese *cumulative distribution function*, CDF,) di  $X$

$$\mathbb{R} \ni x \mapsto \text{CDF}_X(x) = P(X \leq x).$$

# Funzione di ripartizione e di sopravvivenza

Data  $X$  a valori in  $\mathbb{R}$ , si è spesso interessati a conoscere la probabilità che  $X$  assuma valori “grandi”.

- Esempio: la quantità di denaro che un investitore potrebbe guadagnare (se positiva) o perdere (se negativa) in una fissata data futura, a seconda dell'andamento del mercato

Definiamo

- 1 la **funzione di ripartizione** (o funzione cumulativa, in inglese *cumulative distribution function*, CDF,) di  $X$

$$\mathbb{R} \ni x \mapsto \text{CDF}_X(x) = P(X \leq x).$$

- 2 la **funzione di sopravvivenza** (in inglese *survival function*) di  $X$ ,

$$\mathbb{R} \ni x \mapsto \text{SUR}_X(x) = P(X > x).$$

## Come calcolarle

- Essendo  $\{X \leq x\}$  e  $\{X > x\}$  un sistema di alternative,  
$$\text{CDF}_X(x) + \text{SUR}_X(x) = 1.$$

## Come calcolarle

- Essendo  $\{X \leq x\}$  e  $\{X > x\}$  un sistema di alternative,

$$\text{CDF}_X(x) + \text{SUR}_X(x) = 1.$$

- Se la densità (discreta o continua) di  $X$  è nota, siccome  $P(X \leq x) = P(X \in (-\infty, x])$ , si trova

$$\text{CDF}_X(x) = \begin{cases} \sum_{z \leq x} P(X = z) & \text{se } X \text{ ha densità discreta,} \\ \int_{-\infty}^x f(z) dz & \text{se } X \text{ ha densità continua.} \end{cases}$$

## Come calcolarle

- Essendo  $\{X \leq x\}$  e  $\{X > x\}$  un sistema di alternative,

$$\text{CDF}_X(x) + \text{SUR}_X(x) = 1.$$

- Se la densità (discreta o continua) di  $X$  è nota, siccome  $P(X \leq x) = P(X \in (-\infty, x])$ , si trova

$$\text{CDF}_X(x) = \begin{cases} \sum_{z \leq x} P(X = z) & \text{se } X \text{ ha densità discreta,} \\ \int_{-\infty}^x f(z) dz & \text{se } X \text{ ha densità continua.} \end{cases}$$

- Possiamo quindi interpretare (almeno nel caso continuo) la  $\text{CDF}_X(x)$  come l'area del sottografico della densità da  $-\infty$  fino ad  $x$ .

## Come calcolarle

- Essendo  $\{X \leq x\}$  e  $\{X > x\}$  un sistema di alternative,

$$\text{CDF}_X(x) + \text{SUR}_X(x) = 1.$$

- Se la densità (discreta o continua) di  $X$  è nota, siccome  $P(X \leq x) = P(X \in (-\infty, x])$ , si trova

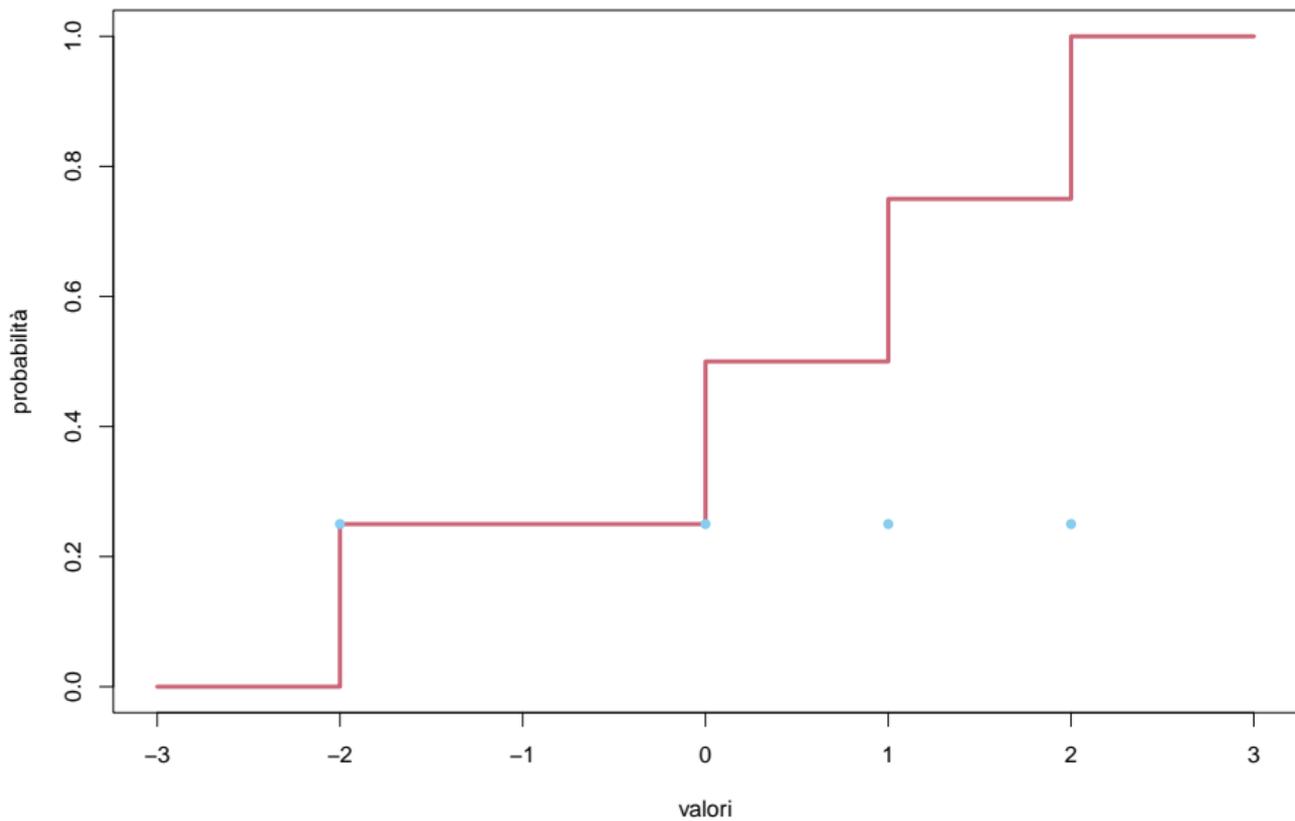
$$\text{CDF}_X(x) = \begin{cases} \sum_{z \leq x} P(X = z) & \text{se } X \text{ ha densità discreta,} \\ \int_{-\infty}^x f(z) dz & \text{se } X \text{ ha densità continua.} \end{cases}$$

- Possiamo quindi interpretare (almeno nel caso continuo) la  $\text{CDF}_X(x)$  come l'area del sottografico della densità da  $-\infty$  fino ad  $x$ .
- Per la funzione di sopravvivenza,

$$\text{SUR}_X(x) = \begin{cases} \sum_{z > x} P(X = z) & \text{se } X \text{ ha densità discreta,} \\ \int_x^{+\infty} f(z) dz & \text{se } X \text{ ha densità continua,} \end{cases}$$

## Esempio nel caso discreto:

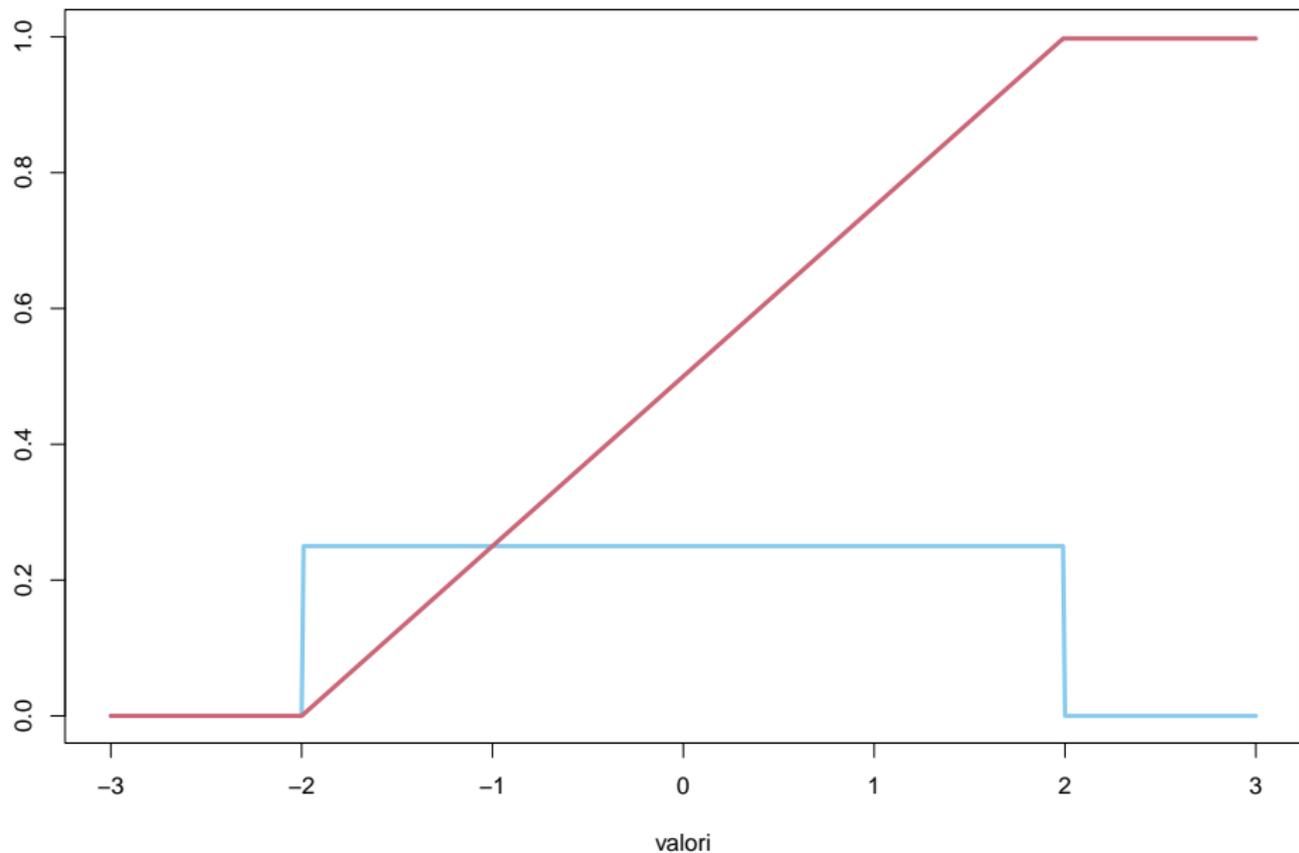
- Sia  $X$  uniforme discreta sui valori  $E = \{-2, 1, 0, 2\}$ .



## Esempio nel caso continuo

Si consideri una variabile aleatoria  $X$  avente densità uniforme continua nell'intervallo  $[-2, 2]$ , ossia per  $x \in [-2, 2]$ ,

$$p(X = x) = 1/4.$$



# Proprietà

- 1 vale  $\text{CDF}_X(x) \in [0, 1]$ , essendo una probabilità.

# Proprietà

- 1 vale  $\text{CDF}_X(x) \in [0, 1]$ , essendo una probabilità.
- 2 la funzione  $x \mapsto \text{CDF}_X(x)$  è crescente (ma non strettamente): se  $x < z$ , per la monotonia della probabilità,

$$\text{CDF}_X(x) \leq \text{CDF}_X(z)$$

# Proprietà

- 1 vale  $\text{CDF}_X(x) \in [0, 1]$ , essendo una probabilità.
- 2 la funzione  $x \mapsto \text{CDF}_X(x)$  è crescente (ma non strettamente): se  $x < z$ , per la monotonia della probabilità,

$$\text{CDF}_X(x) \leq \text{CDF}_X(z)$$

- 3 vale  $\text{CDF}_X(-\infty) = 0$  e  $\text{CDF}_X(+\infty) = 1$  (nel senso di limiti opportuni):

# Proprietà

- 1 vale  $CDF_X(x) \in [0, 1]$ , essendo una probabilità.
- 2 la funzione  $x \mapsto CDF_X(x)$  è crescente (ma non strettamente): se  $x < z$ , per la monotonia della probabilità,

$$CDF_X(x) \leq CDF_X(z)$$

- 3 vale  $CDF_X(-\infty) = 0$  e  $CDF_X(+\infty) = 1$  (nel senso di limiti opportuni):
- 4 Nel caso di densità discreta, la  $CDF_X$  è una funzione costante a tratti, mentre nel caso di variabili con densità continua, la  $CDF_X$  è una funzione continua.

# Proprietà

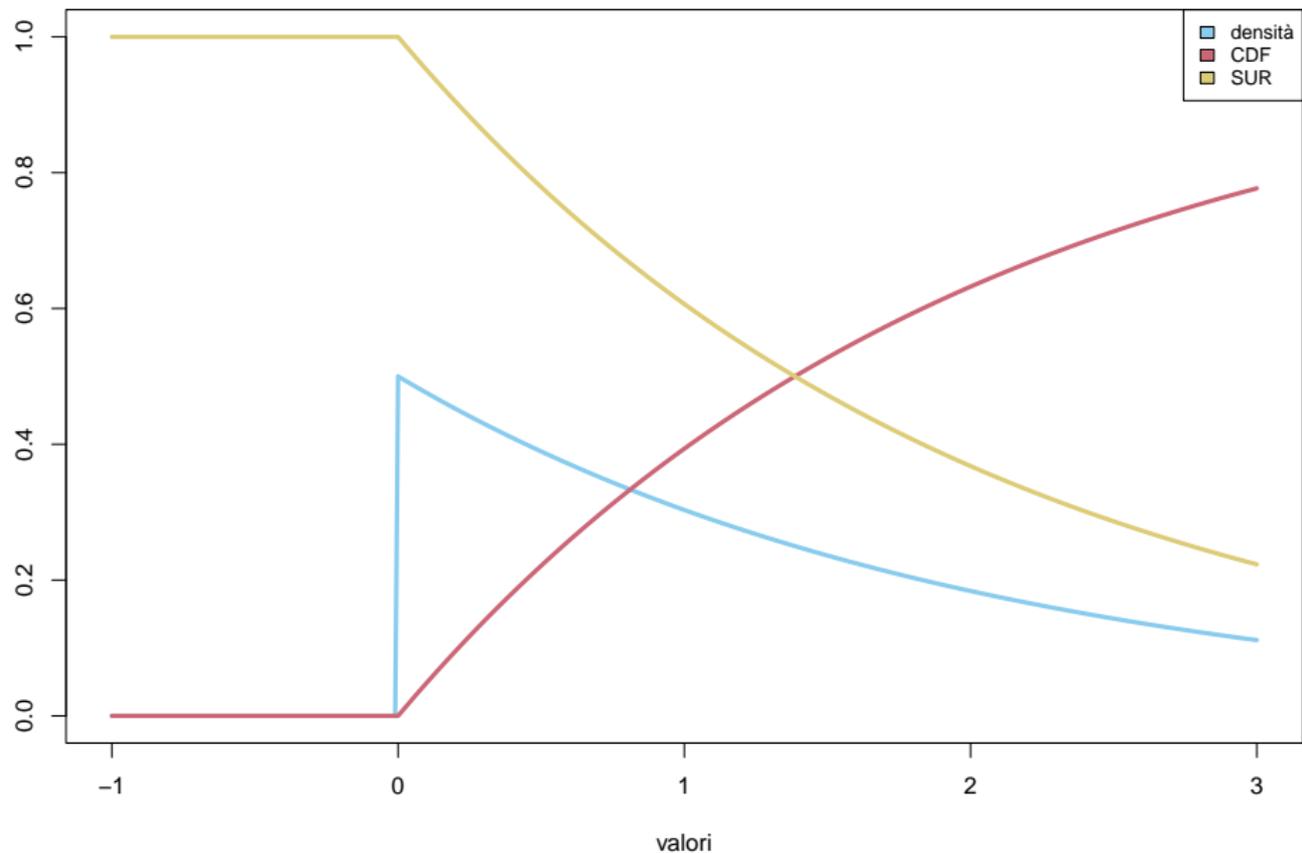
- 1 vale  $CDF_X(x) \in [0, 1]$ , essendo una probabilità.
- 2 la funzione  $x \mapsto CDF_X(x)$  è crescente (ma non strettamente): se  $x < z$ , per la monotonia della probabilità,

$$CDF_X(x) \leq CDF_X(z)$$

- 3 vale  $CDF_X(-\infty) = 0$  e  $CDF_X(+\infty) = 1$  (nel senso di limiti opportuni):
- 4 Nel caso di densità discreta, la  $CDF_X$  è una funzione costante a tratti, mentre nel caso di variabili con densità continua, la  $CDF_X$  è una funzione continua.
- 5 Per la funzione SUR, valgono proprietà analoghe: la funzione è decrescente e vale  $SUR_X(-\infty) = 1$  mentre  $SUR_X(+\infty) = 0$ .

## Un ulteriore esempio

Si consideri una variabile aleatoria  $X$  con densità esponenziale di parametro  $\lambda > 0$ .

Figura 2: densità, CDF e SUR di una variabile  $X$  con densità esponenziale di

## Dalla CDF alla densità

- Nel caso discreto, la densità è non nulla solo nei valori  $x \in \mathbb{R}$  in cui la  $CDF_X(x)$  ha un salto, e il valore della densità in quel punto è proprio *l'ampiezza del salto*.

## Dalla CDF alla densità

- Nel caso discreto, la densità è non nulla solo nei valori  $x \in \mathbb{R}$  in cui la  $CDF_X(x)$  ha un salto, e il valore della densità in quel punto è proprio *l'ampiezza del salto*.
- Nel caso di densità continua, per invertire la formula

$$\int_{-\infty}^x p(X = z) dz = CDF_X(x)$$

è sufficiente applicare il teorema fondamentale del calcolo integrale, e quindi derivare la  $CDF_X$ :

$$\frac{d}{dx} CDF_X(x) = p(X = x).$$

(nei punti in cui  $CDF_X$  è derivabile)

## Dalla CDF alla densità

- Nel caso discreto, la densità è non nulla solo nei valori  $x \in \mathbb{R}$  in cui la  $CDF_X(x)$  ha un salto, e il valore della densità in quel punto è proprio *l'ampiezza del salto*.

- Nel caso di densità continua, per invertire la formula

$$\int_{-\infty}^x p(X = z) dz = CDF_X(x)$$

è sufficiente applicare il teorema fondamentale del calcolo integrale, e quindi derivare la  $CDF_X$ :

$$\frac{d}{dx} CDF_X(x) = p(X = x).$$

(nei punti in cui  $CDF_X$  è derivabile)

- Per la  $SUR_X$ , è sufficiente cambiare di segno alle quantità: nel caso continuo, si ottiene

$$-\frac{d}{dx} SUR_X(x) = f(x).$$

# Mediana

- La *mediana* di  $X$  è definita come un valore  $\bar{x} \in \mathbb{R}$ , se esiste, tale che

$$\text{CDF}_X(\bar{x}) = \frac{1}{2}.$$

# Mediana

- La *mediana* di  $X$  è definita come un valore  $\bar{x} \in \mathbb{R}$ , se esiste, tale che

$$\text{CDF}_X(\bar{x}) = \frac{1}{2}.$$

- Significa che

$$P(X \leq \bar{x}) = P(X > \bar{x}) = \frac{1}{2},$$

ossia  $\bar{x}$  è scelta in modo che le due alternative  $\{X \leq \bar{x}\}$  e  $\{X > \bar{x}\}$  abbiano la stessa probabilità.

# Mediana

- La *mediana* di  $X$  è definita come un valore  $\bar{x} \in \mathbb{R}$ , se esiste, tale che

$$\text{CDF}_X(\bar{x}) = \frac{1}{2}.$$

- Significa che

$$P(X \leq \bar{x}) = P(X > \bar{x}) = \frac{1}{2},$$

ossia  $\bar{x}$  è scelta in modo che le due alternative  $\{X \leq \bar{x}\}$  e  $\{X > \bar{x}\}$  abbiano la stessa probabilità.

- La mediana è quindi un indicatore di “centralità” per  $X$ , alternativo alla moda.

## Esempi

- se la densità di  $X$  è uniforme (diciamo su un insieme  $E$  con un numero pari di valori), significa che metà dei valori possibili di  $X$  sono  $\leq \bar{x}$ , mentre i rimanenti sono  $> \bar{x}$ . In questo caso invece una moda è uno qualsiasi dei valori di  $E$ .

## Esempi

- se la densità di  $X$  è uniforme (diciamo su un insieme  $E$  con un numero pari di valori), significa che metà dei valori possibili di  $X$  sono  $\leq \bar{x}$ , mentre i rimanenti sono  $> \bar{x}$ . In questo caso invece una moda è uno qualsiasi dei valori di  $E$ .
- Sia  $X$  uniforme su

$$E = \{0, 0.1, 0.15, 0.3, 0.4, 0.7, 0.73, 0.9, 0.95, 1.1\}$$

Una mediana per  $X$  è  $\bar{x} = 0.4$ , ma anche un qualsiasi valore compreso tra 0.4 e 0.7 (escluso)

## Esempi

- se la densità di  $X$  è uniforme (diciamo su un insieme  $E$  con un numero pari di valori), significa che metà dei valori possibili di  $X$  sono  $\leq \bar{x}$ , mentre i rimanenti sono  $> \bar{x}$ . In questo caso invece una moda è uno qualsiasi dei valori di  $E$ .
- Sia  $X$  uniforme su

$$E = \{0, 0.1, 0.15, 0.3, 0.4, 0.7, 0.73, 0.9, 0.95, 1.1\}$$

Una mediana per  $X$  è  $\bar{x} = 0.4$ , ma anche un qualsiasi valore compreso tra 0.4 e 0.7 (escluso)

- Nel caso di una variabile esponenziale di parametro  $\lambda$ ,

$$1 - e^{-\lambda \bar{x}} = \frac{1}{2} \quad \Leftrightarrow \quad \lambda \bar{x} = \log(2),$$

ossia

$$\bar{x} = \frac{\log(2)}{\lambda}.$$

## Funzione quantile

Problemi della mediana (così definita) - non necessariamente la mediana esiste sempre - non è unicamente determinata - non è facile calcolarla

Per risolvere i primi due, si introduce una inversa generalizzata  $CDF_X$ , detta funzione *quantile* di  $X$

$$q_X : (0, 1) \rightarrow \mathbb{R}$$

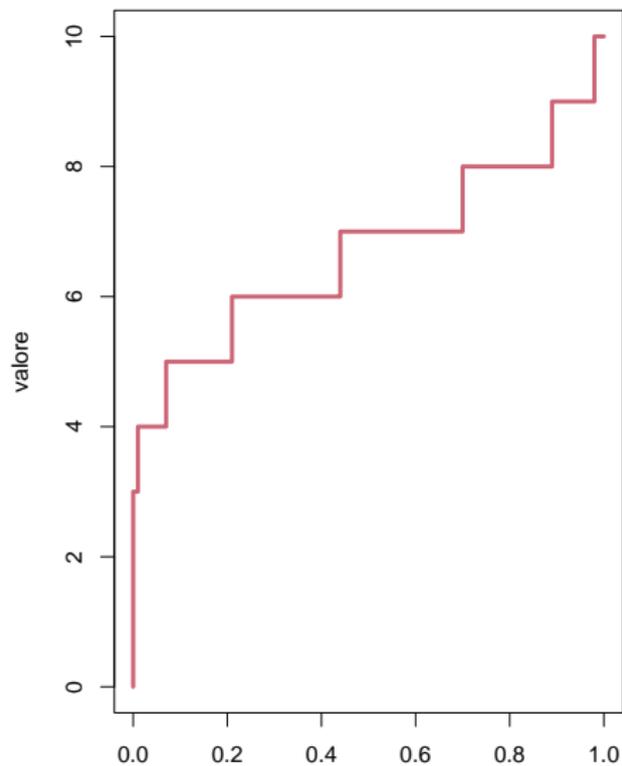
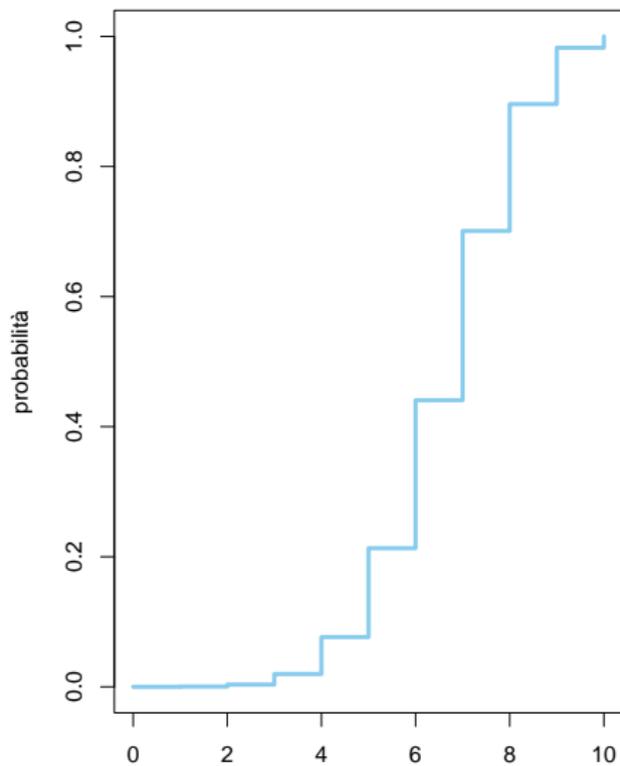
che ad ogni *livello*  $\alpha \in (0, 1)$  associa

$$q_X(\alpha) = \min \{x \in \mathbb{R} : CDF_X(x) \geq \alpha\}.$$

- se  $X$  ha densità continua, allora

$$CDF_X(q_X(\alpha)) = \alpha.$$

# Un esempio discreto



# Mediana, quartili, decili ecc.

Si definiscono quindi

- la mediana di  $X$  come il valore  $\bar{x} = q_X(1/2)$ .

# Mediana, quartili, decili ecc.

Si definiscono quindi

- la mediana di  $X$  come il valore  $\bar{x} = q_X(1/2)$ .
- i *quartili*,  $q_X(\alpha)$  corrispondenti ad  $\alpha \in \{1/4, 2/4, 3/4\}$  (detti il primo, secondo e terzo quartile),

# Mediana, quartili, decili ecc.

Si definiscono quindi

- la mediana di  $X$  come il valore  $\bar{x} = q_X(1/2)$ .
- i *quartili*,  $q_X(\alpha)$  corrispondenti ad  $\alpha \in \{1/4, 2/4, 3/4\}$  (detti il primo, secondo e terzo quartile),
- i *decili*  $q_X(\alpha)$  per  $\alpha = k/10$ ,

# Mediana, quartili, decili ecc.

Si definiscono quindi

- la mediana di  $X$  come il valore  $\bar{x} = q_X(1/2)$ .
- i *quartili*,  $q_X(\alpha)$  corrispondenti ad  $\alpha \in \{1/4, 2/4, 3/4\}$  (detti il primo, secondo e terzo quartile),
- i *decili*  $q_X(\alpha)$  per  $\alpha = k/10$ ,
- i *percentili*  $q_X(\alpha)$  per  $\alpha = k/100$