

LABORATORIO STATISTICO INFORMATICO

Pietro Millosovich

Corso di Laurea Triennale in Statistica e Informatica per
l'Azienda, la Finanza e l'Assicurazione
DEAMS, Università di Trieste

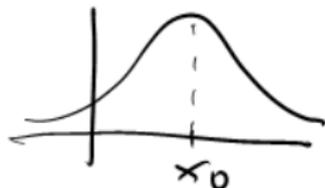
OTTIMIZZAZIONE

- Obiettivo: risolvere in \mathbf{R} problemi di massimizzazione/minimizzazione di una funzione
- Applicazioni
 - ▷ economia: max del profitto/utilità attesa
 - ▷ finanza matematica: selezione di portafoglio
 - ▷ fitting: adattamento di una funzione a un insieme di punti
 - ▷ risoluzione di un (sistema) di equazioni
 - ▷ Statistica inferenziale parametrica: massima verosimiglianza
 - ▷ ...

OTTIMIZZAZIONE

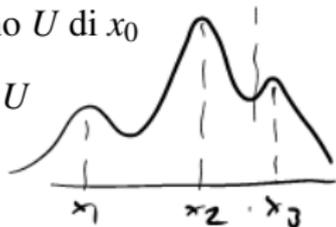
- Sia $f : D(\subset \mathbb{R}^n) \rightarrow \mathbb{R}$, con $D \neq \emptyset$
 - ▷ x_0 **punto di max (min) assoluto** se

$$f(x_0) \geq (\leq) f(x) \text{ per ogni } x \in D$$



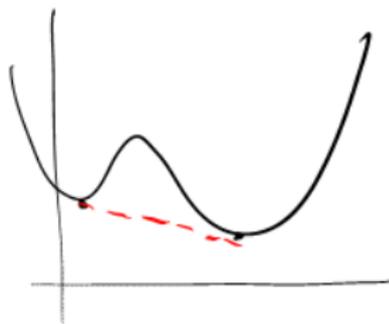
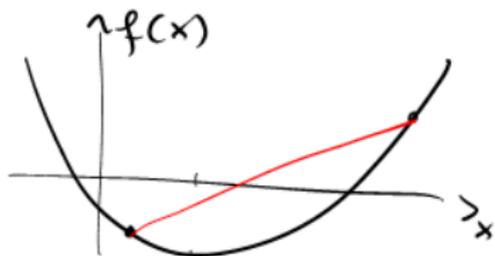
- ▷ x_0 **punto di max (min) relativo** se esiste un intorno U di x_0

$$f(x_0) \geq (\leq) f(x) \text{ per ogni } x \in D \cap U$$



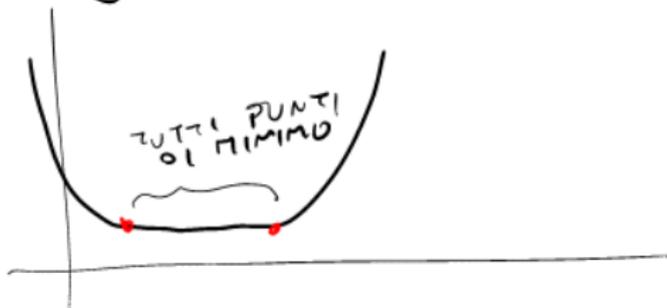
- Osservazioni:
 - ▷ Max/min relativi e/o assoluti possono non esistere o esistere (ma non essere unici)
 - ▷ x_0 max (min) assoluto $\Rightarrow x_0$ max (min) relativo; \Leftarrow vale se f concava (convessa)
 - ▷ Problema: trovare max (min) assoluto di una funzione non concava (convessa) con molti punti di max (min) relativi
 - ▷ **ottimizzazione vincolata:** $D = \{x \in \mathbb{R}^n : g(x) \leq 0, h(x) = 0\}$,
 - ▷ massimizzare f equivale a minimizzare $-f$

f CONVESSA



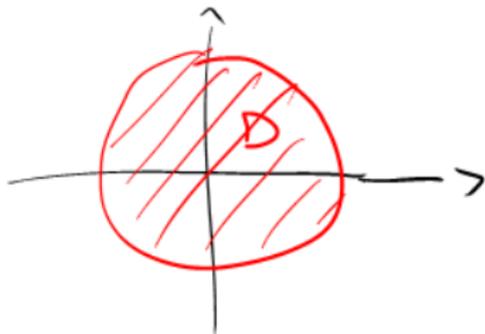
f STRETTAMENTE CONVESSA

\Rightarrow PUNTI DI MIN (SE ESISTONO)
SONO UNICI



ESEMPIO : OTTIMIZZAZIONE VINCOLATA

$$\begin{aligned} \min \quad & x - y \\ \text{s.t.} \quad & x^2 + y^2 \leq 1 \end{aligned}$$



SOLUZIONI \rightarrow MOLTIPLICATORI
DI LAGRANGE
(VINCOLI DI UGUAGLIANZA)

KHUN-TUCKER
(VINCOLI DI UGUAGLIANZA
E DISUGUAGLIANZA)

ESEMPLO

$$f(x) = \begin{cases} e^{-\frac{1}{|x-1|}} & -1 < x < 4, x \neq 1 \\ 0 & x = 1 \\ 10 & \text{ALTRIMENTI} \end{cases}$$

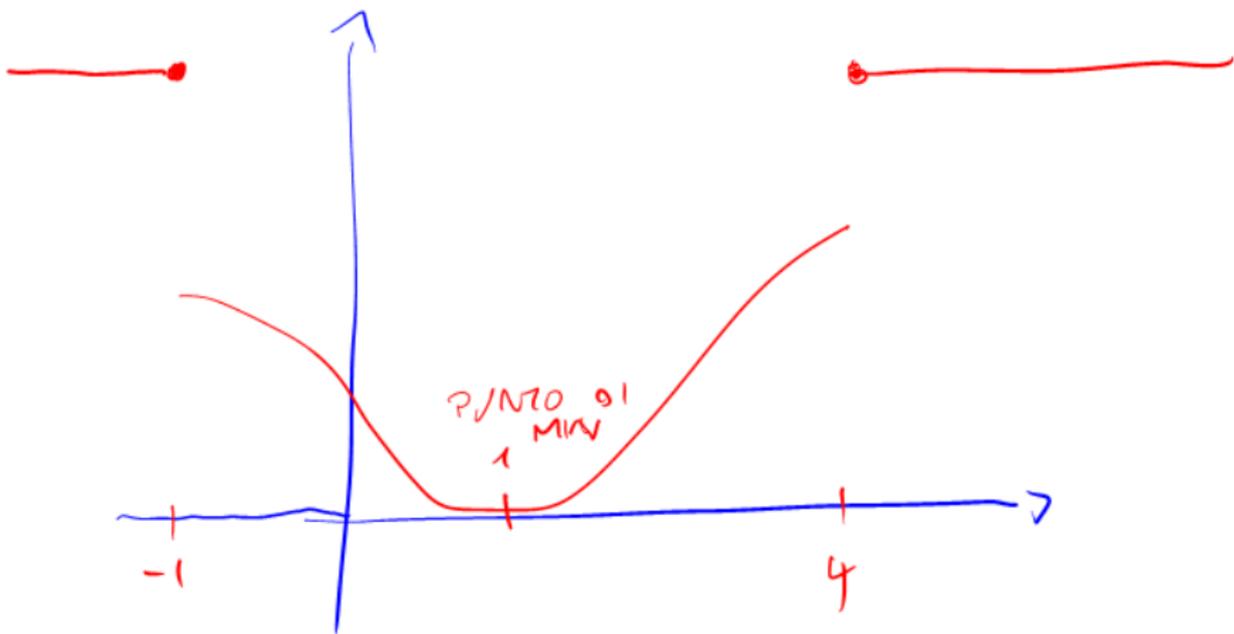
$$\lim_{x \rightarrow 1} f(x) = 0 = f(1) \Rightarrow f \text{ CONTINUA IN } 1$$

$$\lim_{x \rightarrow -1} f(x) < 10, \quad \lim_{x \rightarrow 4} f(x) < 10 \Rightarrow f \text{ DISCONTINUA IN } -1, 4$$

$$f'(x) = \begin{cases} e^{-\frac{1}{x-1}} \frac{1}{(x-1)^2} & x > 1 \\ -e^{\frac{1}{x-1}} \frac{1}{(x-1)^2} & x < 1 \end{cases}$$

$$f'(x) \approx 0 \text{ PER } x \text{ VICINO A } 1 \\ \Rightarrow f \text{ "PIATTA" VICINO A } x=1$$

ESEMPLO



SELEZIONE DI PORTAFOGLIO

- Problema come ripartire l'investimento tra attività rischiose (e non rischiose)?
- Siano R_1, \dots, R_n i rendimenti (semplici) aleatori di n attività rischiose
 - ▷ $E[R_i] = \mu_i$ rendimento atteso, $\sigma_{i,j} = \text{COV}[R_i, R_j]$ covarianza tra rendimenti, $i, j = 1, \dots, n$
 - ▷ μ vettore dei rendimenti attesi, Σ matrice varianza-covarianza

$$\begin{bmatrix} R_1 \\ \vdots \\ R_n \end{bmatrix}$$

$$\mu = \begin{bmatrix} \mu_1 \\ \vdots \\ \mu_n \end{bmatrix}, \quad \Sigma = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \dots & \sigma_{1n} \\ \vdots & \vdots & \dots, \dots & \\ \sigma_{n1} & \sigma_{n2} & \dots & \sigma_{nn} \end{bmatrix}$$

... SELEZIONE DI PORTAFOGLIO

$$\begin{array}{c} x_1 \rightarrow R_1 \\ \vdots \\ x_n \rightarrow R_n \end{array}$$

- Obiettivo: ripartire la ricchezza fra le attività rischiose in maniera ottimale (secondo un certo criterio)
 - ▷ x_i = percentuale di ricchezza investita nell'attività i
 - ▷ $1 - \sum_{i=1}^n x_i$ = percentuale di ricchezza investita nell'attività priva di rischio, con rendimento certo r

$$1 - \sum x_i \rightarrow r$$

- **rendimento di portafoglio** $R_P = \sum_{i=1}^n x_i R_i + (1 - \sum_{i=1}^n x_i)r$
- **media e varianza** del rendimento di portafoglio:

$T = \text{TRASPOSTA}$

$$\begin{aligned} E[R_P] &= x^T \mu + (1 - x^T \mathbf{1})r \\ \text{VAR}[R_P] &= x^T \Sigma x \end{aligned}$$

dove $\mathbf{1}^T = [1, \dots, 1]$

... SELEZIONE DI PORTAFOGLIO

- Modello Media-Varianza di Markowitz (1952): fissato il rendimento atteso \bar{E} , scegliere il portafoglio con varianza (rischio?) minima

$$\min_{x \in \mathbb{R}^n} \text{VAR}[R_P], \quad E[R_P] = \bar{E}$$

cioè

$$\min_{x \in \mathbb{R}^n} x^T \Sigma x, \quad x^T \mu + (1 - x^T \mathbf{1})r = \bar{E}$$

problema di ottimizzazione **quadratica**

(FUNZIONE QUADRATICA
VINCOLI LINEARI)

- al variare di $\bar{E} \geq r$ si descrive la **frontiera efficiente** dei portafogli ottimi
- possibili vincoli aggiuntivi:
 - ▷ $x_i \geq 0$: no vendita allo scoperto dell'attività i
 - ▷ $\sum_{i=1}^n x_i \leq 1$: non ci si può indebitare
 - ▷ $\sum_{i=1}^n x_i = 1$: non c'è attività priva di rischio

FITTING DI UNA CURVA

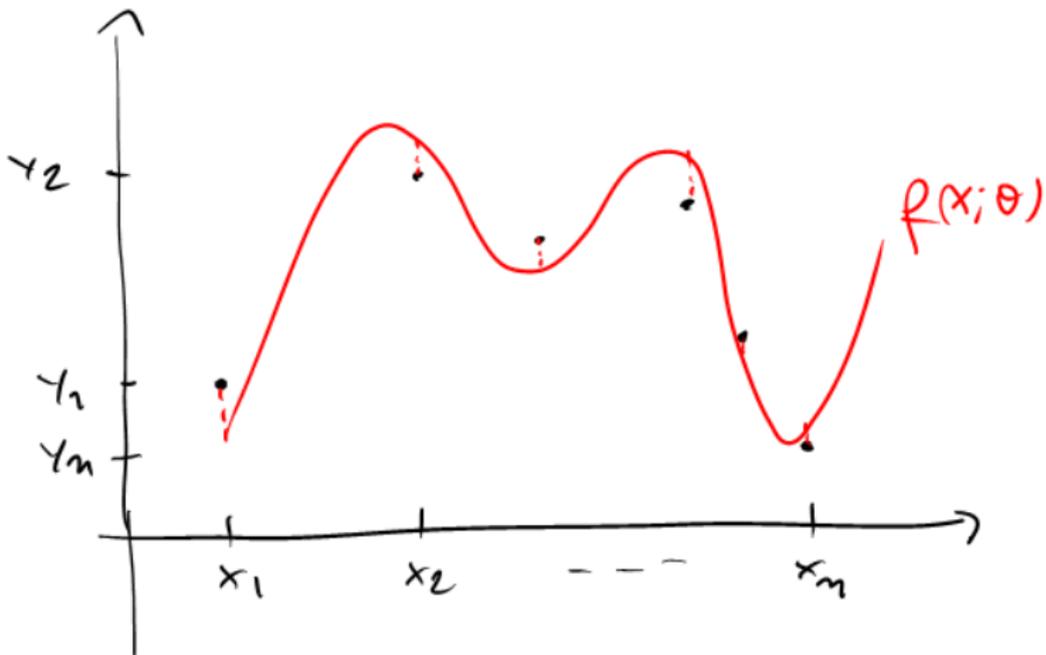
- Dati $(x_i, y_i) \in \mathbb{R}^{h+1}$, per $i = 1, \dots, k$, trovare una funzione $f : \mathbb{R}^h \rightarrow \mathbb{R}$ tale che $f(x_i)$ sia “vicino” a y_i , per ogni $i \rightsquigarrow$
perequazione, interpolazione, estrapolazione
- la funzione f viene scelta in una **famiglia parametrica**:
 $f(x) \equiv f(x; \theta)$ con $\theta \in \Theta \subset \mathbb{R}^n$
- misurando la “vicinanza” con la distanza Euclidea, il problema è

$$\min_{\theta \in \Theta} \sum_{i=1}^h (y_i - f(x_i; \theta))^2 \quad \text{o} \quad \min_{\theta \in \Theta} \sum_{i=1}^h w_i (y_i - f(x_i; \theta))^2$$

dove w_i sono pesi

- ▷ $f(x_i; \theta) = \sum_{i=1}^k \theta_i x_i \rightsquigarrow$ regressione lineare
- ▷ funzioni non lineari (in θ)
- ▷ splines polinomiali o di altro tipo
- ▷ ...

FITTING DI UNA CURVA



... FITTING DI UNA CURVA

- Esempio 1: fitting della curva dei tassi - **Modello di Nelson-Siegel**

▷ $f(0, t)$ tasso forward istantaneo;

$$f(0, t) = \beta_0 + \beta_1 e^{-t/a} + \beta_2 \frac{t}{a} e^{-t/a}$$

con $\theta^T = [\beta_0, \beta_1, \beta_2, a] \in \mathbb{R}^3 \times \mathbb{R}_+$

- ▷ Dati \hat{P}_i prezzi di mercato di h obbligazioni (con o senza cedola) e $P_i^{NS}(\theta)$ i corrispondenti prezzi teorici secondo Nelson-Siegel, $i = 1, \dots, h$, si risolve il problema

$$\min_{\theta \in \Theta} \sum_{i=1}^h w_i (\hat{P}_i - P_i^{NS}(\theta))^2$$

- altri modelli (Svensson), strumenti, ...

FATTORE
DI
SCONTO

$$-\int_0^t f(0, u) du$$

$$v(0, t) = e$$

... FITTING DI UNA CURVA

- Esempio 2: smoothing di tassi di mortalità grezzi - **modello di Heligman-Pollard**

▷ q_x/p_x "odds ratio"; il modello è

$$\frac{q_x}{p_x} = A^{(x+B)^C} + De^{-E(\log x - \log F)^2} + GH^x,$$

con $\theta^T = [A, B, C, D, E, F, G, H] \in \Theta = \mathbb{R}_+^8$

- ▷ i tre termini riflettono le tre componenti della mortalità
- ▷ Dati i tassi grezzi $\hat{q}_x = \frac{D_x}{E_x}$, $x = 0, 1, \dots$ probabilità annua di morte a età x (D_x decessi, E_x esposti al rischio), e q_x^{HP} la corrispondente probabilità secondo Heligman-Pollard, $x = 0, 1, \dots$, si risolve il problema

$$\min_{\theta \in \Theta} \sum_x w_x (\hat{q}_x - \hat{q}_x^{HP})^2$$

- altri modelli (Gompertz, Makeham, Thiele, ...)

MORTALITÀ
ACCIDENTALE

INFANTILE

ETÀ ADULTA



(SISTEMA DI) EQUAZIONI

- La risoluzione di **un'equazione** o un **sistema di equazioni** si può impostare come problema di ottimizzazione

▷ $f : D(\subset \mathbb{R}) \rightarrow \mathbb{R}$. Le soluzioni di

$$f(x) = 0, x \in D$$

sono i punti di minimo di

$$\min_{x \in D} f(x)^2$$

▷ $f : D(\subset \mathbb{R}^n) \rightarrow \mathbb{R}^n$, cioè $f^T = [f_1, \dots, f_n]$ è una funzione vettoriale. Le soluzioni di

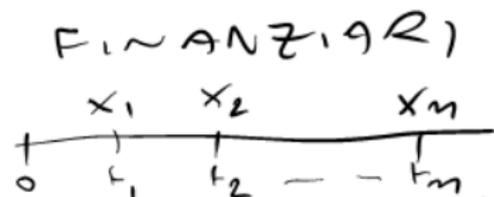
$$\begin{cases} f_1(x) = 0 \\ \vdots \\ f_n(x) = 0, \end{cases} \quad x \in D$$

sono i punti di minimo di

$$\min_{x \in D} (f_1(x)^2 + \dots + f_n(x)^2)$$

ESEMPIO: TIR DI UNA OPERAZIONE FINANZIARIA

x_1, \dots, x_n FLUSSI FINANZIARI
in t_1, t_2, \dots, t_n



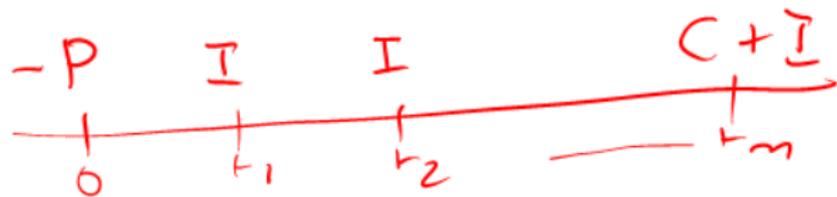
\hat{i}^* TASSO INTERNO DI RENDIMENTO (TIR)

$$\sum_{i=1}^n x_i (1+i)^{-t_i} = 0$$

$VAN(\hat{i})$

ESEMPIO: TIR

CASO PARTICOLARE: COUPON BOND

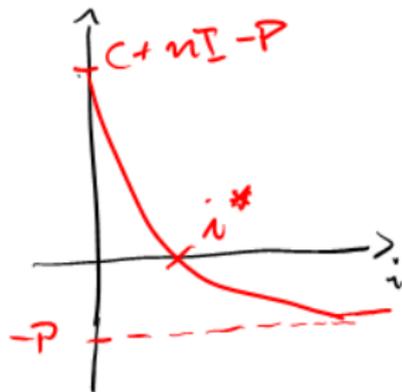


$$t_i - t_{i-1} = \Delta \text{ (costante)}$$

P = PREZZO DI ACQUISTO

I = cedola

C = VALORE NOMINALE



Se $P < C+nI \Rightarrow$ TIR ESISTE UNICO

$$VAN(i) = -P + I \sum_{i=1}^n (1+i)^{-i\Delta} + C(1+i)^{-n\Delta}$$

CONDIZIONI DI OTTIMALITÀ

- $f : D(\subset \mathbb{R}^n) \rightarrow \mathbb{R}$ e x_0 interno a D
 - ▷ **Gradiente** di f in x_0 : vettore delle derivate parziali di f (se esistono in x_0)

$$\nabla f(x_0) = \begin{bmatrix} \frac{\partial f}{\partial x_1}(x_0) \\ \vdots \\ \frac{\partial f}{\partial x_n}(x_0) \end{bmatrix}$$

- ▷ **Hessiano** di f in x_0 : matrice delle derivate parziali seconde di f (se esistono in x_0)

$$H_f(x_0) = \begin{bmatrix} \frac{\partial^2 f}{\partial x_1^2}(x_0) & \frac{\partial^2 f}{\partial x_1 \partial x_2}(x_0) & \cdots & \frac{\partial^2 f}{\partial x_1 \partial x_n}(x_0) \\ \vdots & \vdots & \cdots & \vdots \\ \frac{\partial^2 f}{\partial x_1 \partial x_n}(x_0) & \frac{\partial^2 f}{\partial x_2 \partial x_n}(x_0) & \cdots & \frac{\partial^2 f}{\partial x_n^2}(x_0) \end{bmatrix}$$

CONDIZIONI DI OTTIMALITÀ

- **Condizioni necessarie** per punti ottimo: se x_0 interno a D è max/min relativo allora
 - ▷ primo ordine: $\nabla f(x_0) = 0$
 - ▷ secondo ordine: $H_f(x_0)$ è semi-definita negativa/positiva

$$x^T H_f(x_0) x \leq / \geq 0 \text{ per ogni } x \in \mathbb{R}^n$$

- **Condizioni sufficienti** per punti ottimo: se x_0 interno a D e
 - ▷ primo ordine: $\nabla f(x_0) = 0$
 - ▷ secondo ordine: $H_f(x_0)$ è definita negativa/positiva

$$x^T H_f(x_0) x < / > 0 \text{ per ogni } x \in \mathbb{R}^n - \{0\}$$

allora x_0 è max/min relativo

ALGORITMI PER L'OTTIMIZZAZIONE

- Molti algoritmi cercano di risolvere il sistema di equazioni

$$\nabla f(x) = 0 \Leftrightarrow \begin{cases} \frac{\partial f}{\partial x_1}(x) = 0 \\ \vdots \\ \frac{\partial f}{\partial x_n}(x) = 0 \end{cases}$$

- Metodi **basati sul gradiente** \rightsquigarrow approssimano ∇f per individuare la direzione di massima ascesa/discesa
- altri metodi usano solo la funzione valutata in certi punti \rightsquigarrow funzioni **non differenziabili**
- alcuni metodi richiedono di indicare limitazioni **inferiori e superiori** per ognuna delle variabili

... ALGORITMI PER L'OTTIMIZZAZIONE

- Gli algoritmi iterativi si basano su un

INIZIO punto iniziale $y_0 \in D$ (in input)

ITERAZIONE dato $y_n \in D$, l'algoritmo genera

$$y_{n+1} = T_n(y_n) \in D$$

che “migliora” il punto precedente ($f(y_{n+1}) < f(y_n)$ per un problema di minimo)

ARRESTO quando una data condizione è verificata

- Condizione di arresto:

- ▷ incremento relativo/assoluto rispetto al punto precedente inferiore a un dato valore
- ▷ numero di iterazioni
- ▷ ...

- l'algoritmo può convergere o no, o convergere a un max/min locale

ESEMPIO: ROSENBERG "GARANNA" FUNCTION

$$f(x, y) = 100(x_2 - x_1^2)^2 + (1 - x_1)^2$$

$$f: \mathbb{R}^2 \rightarrow \mathbb{R}$$

$$\text{OSS: } f(x, y) \geq 0 \quad \forall (x, y)$$

$$f(x, y) = 0 \Leftrightarrow \begin{cases} 1 - x_1 = 0 \\ x_2 = x_1^2 \end{cases} \quad \begin{cases} x_1 = 1 \\ x_2 = 1 \end{cases}$$

(1, 1) PUNTO DI MINIMO ASSOLUTO

$$\text{GRADIENTE: } \nabla f(x, y) = \begin{bmatrix} -400 \cdot x_1 \cdot (x_2 - x_1^2) \\ -2(1 - x_1) \\ 200(x_2 - x_1^2) \end{bmatrix}$$

STATISTICA INFERENZIALE PARAMETRICA

- X v.a., continua o discreta (o mistura): ammontare dei sinistri, numeri di sinistri, frequenze, ...
 - ▷ si osservano X_1, \dots, X_n **indipendenti e identicamente distribuite** (iid) con la stessa distribuzione di $X \rightsquigarrow$ **campione aleatorio** di dimensione n
 - ▷ si sceglie una **famiglia parametrica** $F_X(x; \theta)$: densità $f_X(x; \theta)$ se X è continua, massa $p_X(x; \theta)$ se X discreta
 - ▷

$$\theta = \begin{bmatrix} \theta_1 \\ \vdots \\ \theta_d \end{bmatrix} \in \Theta$$

è il **(vettore) di parametri**, $\Theta \subset \mathbb{R}^d$ è lo **spazio dei parametri**

- ▷ Esempio: $X \sim \text{Gamma}(\alpha, \lambda)$, $\theta = \begin{bmatrix} \alpha \\ \lambda \end{bmatrix}$ e
 $\Theta = \{(\alpha, \lambda) \mid \alpha > 0, \lambda > 0\}$

... STIMATORI

- Statistiche e stimatori
 - ▷ **Statistica**: una funzione $T = T(X_1, \dots, X_n)$; **stimatore** di θ : ogni statistica tale che T prende valori in Θ
 - ▷ Esempio: $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ **media campionaria**, uno stimatore di $E[X]$; $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$ **varianza campionaria**, uno stimatore di $\text{VAR}[X]$

- ricordiamo che:

- ▷ **prima di osservare** il campione aleatorio,

$$X_1, \dots, X_n \text{ e ogni statistica } T = T(X_1, \dots, X_n)$$

sono **variabili aleatorie**

- ▷ dopo che l'osservazione ha avuto luogo,

$$X_1 = x_1, \dots, X_n = x_n \text{ e } T(x_1, \dots, x_n) = t$$

sono numeri; $T = t$ **stima** t di θ

- Come trovare degli stimatori di θ ?

METODO DEI MOMENTI

- uguagliare momenti **empirici** a momenti della **popolazione** \rightsquigarrow risolvere per il parametro θ
 - ▷ momenti empirici: $m_k = \frac{1}{n} \sum_{i=1}^n X_i^k$ for $k = 1, 2, \dots$ \rightsquigarrow statistica
 - ▷ momenti della popolazione: $\mu_k = E[X^k]$ per $k = 1, 2, \dots$ \rightsquigarrow funzione del parametro θ , $\mu_k \equiv \mu_k(\theta)$
 - ▷ se ci sono d parametri da trovare, $\theta^T = [\theta_1, \dots, \theta_d]$, si uguagliano i primi d momenti empirici con i corrispondenti momenti della popolazione:

$$\begin{cases} \mu_1(\theta_1, \dots, \theta_d) = m_1 \\ \mu_2(\theta_1, \dots, \theta_d) = m_2 \\ \dots \\ \mu_d(\theta_1, \dots, \theta_d) = m_d \end{cases}$$

- \rightsquigarrow sistema di d equazioni in d incognite
- ▷ risolvendo il sistema si arriva a uno stimatore $\hat{\theta}^T = [\hat{\theta}_1, \dots, \hat{\theta}_d]$ dipendente dai termini noti m_1, \dots, m_d

ESSEMPIO: GAMMA (α, λ)

$$f(x; \alpha, \lambda) = \frac{\lambda^\alpha}{\Gamma(\alpha)} x^{\alpha-1} e^{-\lambda x}$$

$$E(X) = \frac{\alpha}{\lambda}$$

$$\text{VAR}(X) = \frac{\alpha}{\lambda^2} \quad E(X^2) = \frac{\alpha}{\lambda^2} + \frac{\alpha^2}{\lambda^2} = \frac{\alpha(\alpha+1)}{\lambda^2}$$

METODO DEI MOMENTI

$$\left\{ \begin{array}{l} \frac{\alpha}{\lambda} = m_1 \\ \alpha(\alpha+1) = m_2 \end{array} \right.$$

$$\alpha = \lambda m_1$$

$$\frac{\lambda m_1 (\lambda m_1 + 1)}{\lambda^2} = m_2 \Rightarrow m_1 + \frac{1}{\lambda} = \frac{m_2}{m_1}$$

$$\Rightarrow \frac{1}{\lambda} = \frac{m_2}{m_1} - m_1 = \frac{m_2 - m_1^2}{m_1}$$

$$\Rightarrow \hat{\lambda} = \frac{m_1}{m_2 - m_1^2} \quad \hat{\alpha} = \frac{m_1^2}{m_2 - m_1^2}$$

METODO DEI QUANTILI

- Uguagliare quantili **empirici** a quelli della **popolazione**
 - ▷ quantili empirici: **statistica d'ordine** di x_1, \dots, x_n

$$x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}$$

per $0 < p < 1$, il p -esimo quantile empirico è la statistica

$$\widehat{x}_p = (1 - w)x_{(j)} + wx_{(j+1)}$$

dove $j = \lfloor np \rfloor =$ parte intera di np e $0 \leq w \leq 1$; scelta classica:
 $w = np - j =$ parte frazionaria di np

- ▷ quantile della popolazione: per $0 < p < 1$ è definito come

$$x_p = F_X^{-1}(p) = \inf\{x \in \mathbb{R} : F_X(x) \geq p\}$$

↪ una funzione del parametro θ , $F_X^{-1}(p) \equiv F_X^{-1}(p; \theta)$; se F_X crescente allora F_X^{-1} è l'inversa di F_X e $F_X(x_p) = p$ definisce il quantile

... METODO DEI QUANTILI

- Uguagliare quantili empirici a quelli della popolazione
 - ▷ i quantili più importanti corrispondono a $p = 0.5$ (mediana), $p = 0.25$ (primo quartile), $p = 0.75$ (terzo quartile)
 - ▷ si scelgono d quantili corrispondenti a $p_1 < p_2 < \dots < p_d$ poi si uguagliano i quantili della popolazione ai corrispondenti quantili empirici

$$\begin{cases} F_X^{-1}(p_1; \theta_1, \dots, \theta_d) = \hat{x}_{p_1} \\ F_X^{-1}(p_2; \theta_1, \dots, \theta_d) = \hat{x}_{p_2} \\ \dots \\ F_X^{-1}(p_d; \theta_1, \dots, \theta_d) = \hat{x}_{p_d} \end{cases}$$

↪ un sistema di d equazioni in d incognite

- ▷ risolvendo il sistema si arriva a uno stimatore $\hat{\theta}^T = [\hat{\theta}_1, \dots, \hat{\theta}_d]$ dipendente dal termine noto $\hat{x}_{p_1}, \dots, \hat{x}_{p_d}$
- ▷ se F_X è crescente allora le equazioni del sistema possono essere scritte come

$$F_X(\hat{x}_{p_j}; \theta) = p_j, j = 1, \dots, d$$

METODO DELLA MASSIMA VEROSIMIGLIANZA

- Idea: scegliere i parametri in modo che la **verosimiglianza** (\equiv probabilità) di **ottenere i valori effettivamente osservati è massima**

- ▷ X è continua con densità f_X : la verosimiglianza = densità congiunta di X_1, \dots, X_n (iid!) in funzione di θ :

$$L(\theta) \equiv L(\theta; x_1, \dots, x_n) = f_{X_1, \dots, X_n}(x_1, \dots, x_n; \theta) = \prod_{i=1}^n f_X(x_i; \theta)$$

si vuole risolvere $\max_{\theta \in \Theta} L(\theta) \rightsquigarrow$ difficile

- ▷ è **equivalente e più semplice** massimizzare il logaritmo della verosimiglianza

$$\ell(\theta) = \log L(\theta) = \sum_{i=1}^n \log f_X(x_i; \theta)$$

cioè risolvere

$$\max_{\theta \in \Theta} \ell(\theta)$$

- ▷ quando X è discreta con f_X sostituita da p_X

CONFRONTO TRA I METODI DI STIMA

- il metodo dei momenti e dei quantili sono più semplici da implementare rispetto a max verosimiglianza
 - ▷ max verosimiglianza può essere complicato analiticamente quando più di un parametro è coinvolto
 - ▷ tuttavia, i computer moderni possono risolvere problemi di max verosimiglianza anche in spazi di parametri di dimensione elevata
- i metodi dei momenti e dei quantili non usano tutta l'informazione contenuta nel campione, a differenza di max verosimiglianza
- max verosimiglianza è un metodo **più robusto** e gode di proprietà **asintotiche (campioni elevati)**:
 - ▷ non distorto
 - ▷ consistente: lo stimatore “si avvicina” al (vero) parametro della popolazione
 - ▷ distribuzione normale \rightsquigarrow intervalli di confidenza
 - ▷ ha varianza minima \rightsquigarrow miglior stimatore tra quelli non distorti

CONFRONTO TRA MODELLI STIMATI

- Avendo stimato diverse distribuzioni parametriche su un dato campione tramite **max verosimiglianza**, come si può scegliere quella migliore?
- **Criteri di informazione**: se n è il numero di osservazioni (dimensione campionaria), P è una distribuzione (modello) con d_P parametri e max verosimiglianza $\hat{\ell}_P$

▷ **Criterio di Informazione di Akaike**

$$\text{AIC}(P) = 2d_P - 2\hat{\ell}_P$$

▷ **Criterio di Informazione di Bayes**

$$\text{BIC}(P) = d_P \log n - 2\hat{\ell}_P$$

▷ Idea: trade-off tra **bontà di adattamento** e **parsimonia** \rightsquigarrow BIC penalizza più per il numero di parametri

- Si sceglie il modello con criterio di informazione più basso