

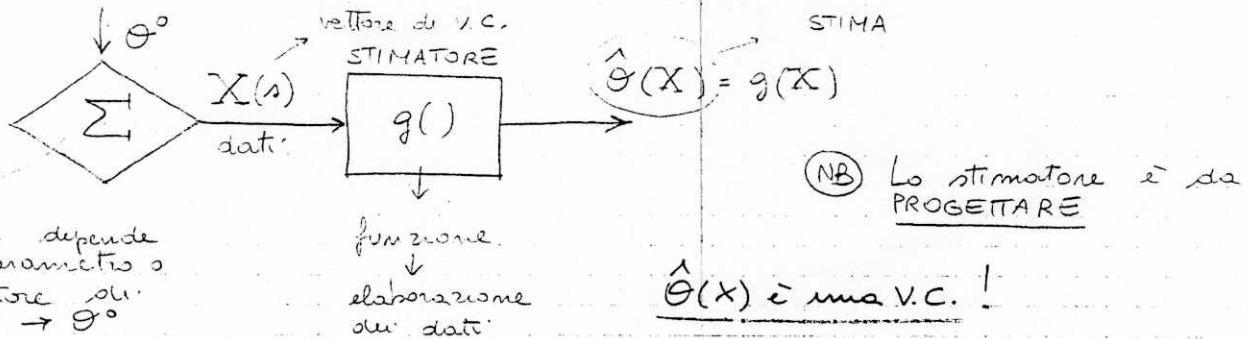
TEORIA DELLA STIMA

In alcuni casi le ddp sono note, ma nella maggior parte dei casi non lo sono e ho a disposizione solo dati sperimentali.

es Errore di minima: lo descrivo come una v.c. gaussiana X , ma non conosco $E[X]$ né $\text{Var}[X]$. Come stimare $E[X]$ e $\text{Var}[X]$?

es Stima di λ per eventi di Poisson

Il problema della stima può essere schematizzato come segue



esperimento casuale che dipende da un parametro o da un vettore parametrico θ^*

$$\text{es } X = \begin{bmatrix} 1 \\ 1 \\ 0 \\ 1 \\ 0 \\ 0 \\ 1 \end{bmatrix} \quad g() = \sum \frac{x_i}{N} \quad \hat{\theta} = \frac{\sum x_i}{N} = \text{probabilità di avere Testa}$$

Teste o croce \rightarrow

L'esperimento Σ è caratterizzato da una densità congiunta $f_X(x)$

Dato che il risultato di $g()$ è una v.c. non è detto che la stima sia sempre giusta.

es Stima di media (m) e deviazione standard (σ) di una v.c. gaussiana

$$\cdot \theta^* = \begin{bmatrix} \theta_1^* \\ \theta_2^* \end{bmatrix} = \begin{bmatrix} m \\ \sigma \end{bmatrix}$$

• Σ estrane N valori indipendenti della v.c. gaussiana

$$\cdot X = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_N \end{bmatrix} \quad f_X(x) = \frac{1}{\sqrt{(2\pi)^N (\theta_2^*)^N}} \cdot e^{-\frac{1}{2} \sum_{i=1}^N \left(\frac{x_i - \theta_1^*}{\theta_2^*} \right)^2}$$

la ddp è f_Z su θ^*

• $g(\cdot)$: posso stimare m con la media campionaria

$$\hat{\theta} = \begin{bmatrix} \hat{\theta}_1 \\ \hat{\theta}_2 \end{bmatrix} = \begin{bmatrix} g_1(x_1, x_2, \dots, x_N) \\ g_2(x_1, x_2, \dots, x_N) \end{bmatrix} = \begin{bmatrix} \frac{1}{N} \sum_{i=1}^N x_i \\ ? \end{bmatrix}, \quad \text{lo vedremo in seguito}$$

Stimatore abbastanza buono, anche obbedisce alla legge forte dei grandi numeri.

STIMA DEI MOMENTI DI UNA V.C.: MOMENTI CAMPIONARI

Consideriamo un esperimento casuale che fornisce N valori x_1, x_2, \dots, x_N

x_i iid con $f_{x_i}(x) = f_{x_j}(x) = f(x) \Rightarrow E[x_i] = m, \text{Var}[x_i] = \sigma^2, \text{etc.}$
 (ovviamente $f_x(x) = f_{x_1}(x_1) f_{x_2}(x_2) \dots f_{x_N}(x_N) = \prod_{i=1}^N f(x_i)$)

PROBLEMA: Stimare i momenti di X_i

Introduciamo una classe di possibili stimatori:

MOMENTO CAMPIONARIO DI ORDINE K:

$$M_k(X) := \frac{1}{N} \sum_{i=1}^N X_i^k \rightarrow \text{questo è una V.C.}$$

$$\underline{X} = \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_N \end{bmatrix}$$

$$(VS: m_k = \int_{-\infty}^{\infty} x^k f(x) dx)$$

questo è un calcolo

(NE) La media teorica e la media campionaria sono 2 cose MOLTO \neq !

MOMENTO CENTRALE CAMPIONARIO DI ORDINE K

$$S_k(X) := \frac{1}{N} \sum_{i=1}^N (X_i - M_1)^k$$

$$(VS: \mu_k := \int_{-\infty}^{\infty} (x - m_1)^k f(x) dx)$$

Essaminiamo le proprietà di alcuni momenti campionari

MEDIA CAMPIONARIA

$$M_1 := \frac{1}{N} \sum_{i=1}^N X_i$$

- $E[M_1] = m$ (media teorica o media d'insieme)

$$(E\left[\frac{1}{N} \sum_{i=1}^N X_i\right] = \frac{1}{N} E[\sum X_i] = \frac{Nm}{N})$$

$$\bullet \quad \underline{\text{Var}[M_1] = \frac{\sigma^2}{N}} \quad (\text{Var}\left[\frac{1}{N} \sum_{i=1}^N X_i\right] = \frac{1}{N^2} N \sigma^2 = \frac{\sigma^2}{N})$$

- f_{X_i} gaussiana $\Rightarrow M_1$ gaussiana (perché la somma di gaussiane è gaussiana)

- se le f_{X_i} non sono gaussiane per $N \rightarrow \infty \Rightarrow M_1 \rightarrow$ gaussiana per il teorema centrale del limite

\rightarrow Se ho abbastanza dati posso "prevedere" delle proprietà delle $X_i \rightarrow$ qui $N=10$ è suff.

$$\text{OSSERVAZIONE: } Z := \frac{M_1 - E[M_1]}{\sqrt{\text{Var}[M_1]}} = \frac{M_1 - m}{\sigma/\sqrt{N}} \Rightarrow M_1 = m + \frac{\sigma}{\sqrt{N}} \cdot Z \rightarrow \text{EPRORI}$$

(NB) La media d'insieme non è mai raggiungibile per esempio esistente.

Media campionaria = media teorica + componenti casuali

Termino di RUMORE

Z è un termine fisso \Rightarrow l'intensità del rumore dipende da σ e da $N \Rightarrow$ per N grande il rumore diminuisce $\Rightarrow 0$ per $N \rightarrow \infty$

Dai l'idea del principio fondamentale della legge dei grandi numeri

MOMENTO DI ORDINE 2 (VALORE QUADRATICO MEDIO CAMPIONARIO)

$$M_2 = \frac{1}{N} \sum_{i=1}^N X_i^2$$

$$\bullet \quad E[M_2] = m_2 = E[X_i^2] \quad (E\left[\frac{1}{N} \sum_{i=1}^N X_i^2\right] = \frac{1}{N} \sum E[X_i^2] = E[X_i^2])$$

PARENTESI: LA V.C. χ^2

Siano $Z_i, i=1 \dots N$ delle V.C. gaussiane standard ($E[Z_i] = 0, \text{Var}[Z_i] = 1$) indip.

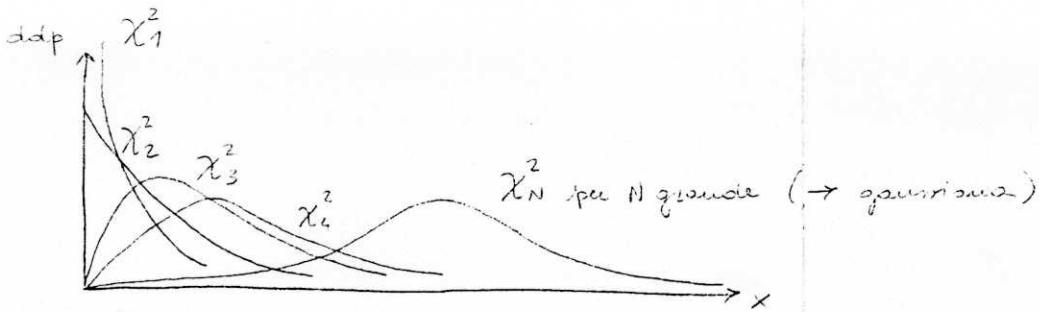
Allora costruisco una nuova V.C.:

$$\chi_N^2 := \sum_{i=1}^N Z_i^2$$

che prende il nome di "chi quadrato" a N gradi di libertà

3. una matrice diagonale di

$$V.C. \chi^2$$



Dove bis. cerca
una tabella
del χ^2 + valore
di N

- $E[\chi^2_N] = N$
- $\text{Var}[\chi^2_N] = 2N$
- per $N \rightarrow \infty$ $\frac{\chi^2_N - N}{\sqrt{2N}} \xrightarrow{} Z$ (gaussiana standard) (Per il Teo. Centrale del limite)

FINE PARENTESI

- se x_i gaussiane con $E[x_i] = 0$ si dimostra che

$$\frac{NM_2}{\sigma^2} = \chi^2_N$$

VARIANZA CAMPIONARIA NOTO IL VALOR MEDIO

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

se non conosciamo il valor medio giusto m usiamo la stima M_1

- $E[S_m^2] = \sigma^2 \left(E\left[\frac{1}{N} \sum (x_i - m)^2\right] - \frac{1}{N} \sum E(x_i - m)^2 = \frac{N\sigma^2}{N} \right)$

VARIANZA CAMPIONARIA

$$S^2 := S_2 := \frac{1}{N} \sum_{i=1}^N (x_i - M_1)^2$$

- $E[S^2] = \frac{N-1}{N} \sigma^2$ per dimostrarlo si usa:

PROPRIETA' : $(S^2 = M_2 - M_1^2)$ (infatti $S^2 = E[x^2] - m^2 = m_2 - m_1^2$)

$$\begin{aligned} \Rightarrow E[S^2] &= E[M_2] - E[M_1^2] = m_2 - (\text{Var}[M_1] + E[M_1]^2) \\ &= m_2 - \frac{\sigma^2}{N} - m^2 = (m_2 - m^2) - \frac{\sigma^2}{N} = \sigma^2 - \frac{\sigma^2}{N} \end{aligned}$$

cqd

(NB) la varianza della media campionaria \neq media della varianza campionaria

- TEOREMA (FISHER): Se x_i gaussiane iid, S^2 è una χ^2_{N-1} ed è indip da M_1

Più precisamente: $\frac{NS^2}{\sigma^2} = \sum_{i=1}^N \frac{(x_i - M_1)^2}{\sigma^2} = \chi^2_{N-1}$ $N-1$ e non N grado di libertà perché i x_i addizionali condizionano la pseudo-normalizzazione $M_1 \Rightarrow$ perdono 1 d.l.

- per $N \rightarrow \infty \Rightarrow S^2 \xrightarrow{} \text{(gaussiana e indip. da } M_1\text{)} \text{ anche se } f_{x_i} \text{ non è gauss.}$
- convergenza meno robusta della media campionaria $\Rightarrow N$ deve essere grande

PROPRIETA' DEGLI STIMATORI

NON POLARIZZAZIONE: $\hat{\theta}(x)$ è detto non polarizzato (corretto, non sesato, unbiased) se

$$E[\hat{\theta}(x)] = \theta^*$$

Esempio La media campionaria è uno stimatore consistente della media (legge dei grandi numeri).

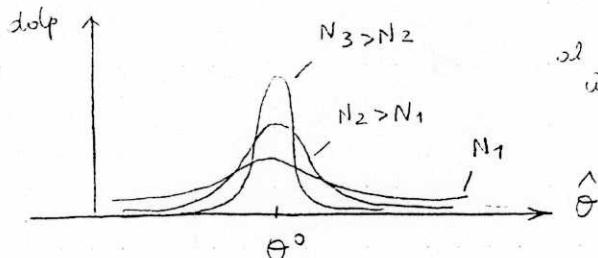
Cosa posso dire per M_2 ?

$Y := X^2 \Rightarrow M_2$ è la media campionaria di $Y \Rightarrow$ per la legge dei grandi numeri M_2 converge a $E[Y] = E[X^2]$

Allora la consistenza si può estendere anche a M_3, M_4, \dots

Tutti i momenti campionari sono consistenti

- La CONSISTENZA è una proprietà fortemente desiderabile



Se cercate di N avere una delta di Dirac in θ^* \Rightarrow per $N \rightarrow \infty$ voglio avere certo (probabilità 1) di avere in θ^*

PROPRIETÀ: I momenti centrali campionari sono stimatori consistenti

ASINTOTICA NORMALITÀ: $\hat{\theta}(x)$ è asintoticamente normale se per

$N \rightarrow \infty$ converge in distribuzione ad una gaussiana

Esempio: I momenti campionari sono asint. normali perché sono medie di v.c. i.i.d. (di dimostrazione con $Y = X^k$) lo stesso vale per i momenti centrali campionari (di dimostrazione meno semplice)

DISGUAGLIANZA DI CRAMER - RAO (1945)

Considero uno stimatore non polarizzato ($E[\hat{\theta}] = \theta_0$) scalare. Allora, sotto condizioni di regolarità, vale

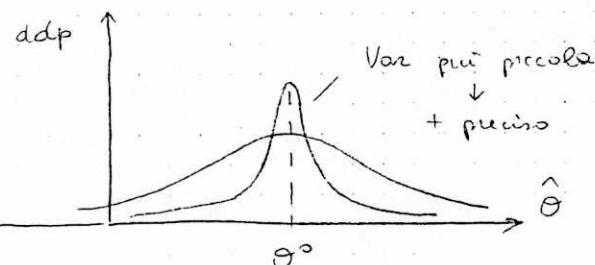
$$\text{Var}[\hat{\theta}] \geq \frac{1}{-E\left[\frac{\partial^2}{\partial \theta^2} \ln f_x^{(\theta)}(X)\right]_{\theta=\theta_0}}$$

per lo stimatore

NON polarizzato la varianza è SINONIMO di PRECISIONE

è una legge analoga nel caso polarizzato

è una v.c. che le confronta con i dati sperimentali



$\text{Var}[\hat{\theta}]$ misura la precisione

La diseguaglianza di Cramer-Rao mi dà un limite al di sotto del quale non posso + migliorare.

Interpretazione: qualunque stimatore io prendo, non riuscirà a portare la sua varianza al di sotto del limite di C.R.

Sono sicuro che se continuo uno stimatore che ha $\text{Var} = 2$ quella di CR è il migliore possibile

Le limiti 3 spiegherà dai dati sperimentali non posso "spremere" + di tanto

OSSERVAZIONI

- $S = -E\left[\frac{\partial^2}{\partial \theta^2} \ln f_x^{(\theta)}(X)\right]_{\theta=\theta_0}$ è detta quantità di informazione di Fisher

il modo in cui si calcola

È il inverso della

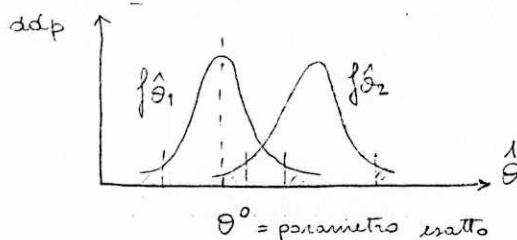
Esempi:

- M₁: non polarizzato (infatti $E[M_1] = m_1$)
- M₂: " " " (" $E[M_2] = m_2$)
- S²_m: " " " (" $E[S^2_m] = \sigma^2$)
- $\hat{\theta}$: polarizzato ($E[\hat{\theta}] = \frac{N-1}{N} \sigma^2$)

11-9-2001

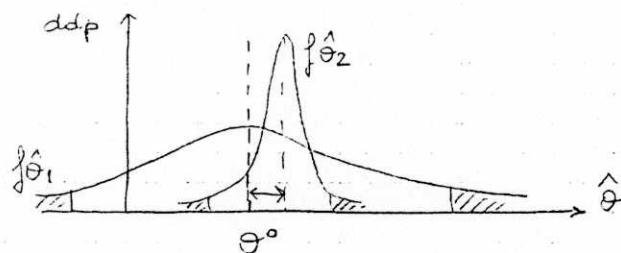
NON POLARIZZAZIONE

$$E[\hat{\theta}(x)] = \theta^*$$



Sul principio non può capitare che $\hat{\theta}_2$ sia + vicino a θ^* di $\hat{\theta}_1$ ma in generale dà una stima migliore $\hat{\theta}_1$

(NB) Gli stimatori sono V.C. \Rightarrow andrebbero scritti in maiuscolo $\hat{\theta}$



L'ideale sarebbe conoscere la differenza tra $E[\hat{\theta}_2]$ e θ^* , e, notare, centrare $\hat{\theta}_2$.

Idea: se poniamo "spostato" $\hat{\theta}_2$ in modo da eliminare bias

VARIANZA CAMPIONARIA CORRETTA

$$S_c^2 := \frac{N}{N-1} S^2 = \frac{1}{N-1} \sum_{i=1}^N (x_i - M_1)^2$$

Polarizzato?

$$E[S_c^2] = E\left[\frac{N}{N-1} S^2\right] = \frac{N}{N-1} E[S^2] = \frac{N}{N-1} \cdot \frac{N-1}{N} \sigma^2 = \sigma^2 \Rightarrow \text{NON POLARIZZATO}$$

(NB) Per centrarla abbiamo moltiplicato S^2 per una quantità $\left(\frac{N}{N-1}\right) > 1 \Rightarrow$

lo $E[S_c^2] = \left(\frac{N}{N-1}\right)^2 E[S^2]$ è + grande \rightarrow perdi la non polarizzazione

CONSISTENZA: $\hat{\theta}(x)$ è detto consistente se per $N \rightarrow \infty$, $\hat{\theta} \rightarrow \theta^*$ in probabilità

UNO STIMATORE che NON gode di questa proprietà è SOSPETTO

È un esempio non tanto interessante x la legge dei numeri n'

$\hat{\theta}_1$ è NON polarizzato o CENTRATO
perché il valore medio cade sul
parametro vero

$\hat{\theta}_2$ è polarizzato

In questa situazione è preferibile
 $\hat{\theta}_1$ perché dà errori + piccoli

Per lo stimatore $\hat{\theta}_1$ posso commettere anche errori consistenti mentre $\hat{\theta}_2$ è + vicino al valore vero.

Anche se polarizzato $\hat{\theta}_2$ potrebbe essere preferibile!!

(NB) Posso accettare un po' di polarizzazione se guadagno in errore.

Si potrebbe anche dividere per N
anche per N grande è la stessa cosa
dividendo per N-1 abbiamo centrato $\hat{\theta}$

• Estensione del concetto vettoriale

$S = \{S_{ij}\}$ Matrice di INFORMAZIONE di FISHER

$$S_{ij} := -E \left[\frac{\partial^2}{\partial \theta_i \partial \theta_j} \ln f_x^{(\theta)}(X) \Big|_{\theta=\theta^0} \right]$$

$$\rightarrow \text{Var}[\hat{\theta}] \geq S^{-1} \quad (\text{significa che } \text{Var}[\hat{\theta}] - S^{-1} \geq 0 \Rightarrow x^T A x \geq 0 \forall x)$$

cioè la differenza è semi-def. positiva

- Nel caso di $\hat{\theta}$ polarizzato NON ha senso dare un limite inferiore alla varianza

ES: Se pongo $\hat{\theta}(X) = 10$ ($\forall x$ stimatore che ignora i dati) $\text{Var}[\hat{\theta}(x)] = 0$
 \Rightarrow varianza nulla ma $\hat{\theta}$ è un pessimo stimatore

→ Come misurare la precisione di uno stimatore polarizzato?

Risposta: Valuto $E[(\hat{\theta} - \theta^0)^2]$ (non $E[\hat{\theta} - \theta^0] \approx 0$ perché potrei ottenere questo risultato compensando errori grandi ma > 0 con errori grandi ma < 0).

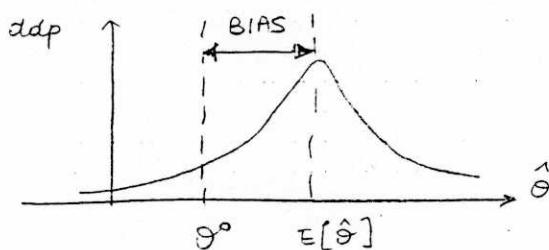
ERRORE QUADRATICO MEDIO

Si noti che $E[(\hat{\theta} - \theta^0)^2] = E[((\hat{\theta} - E[\hat{\theta}]) + (E[\hat{\theta}] - \theta^0))^2] =$

$$= \text{Var}[\hat{\theta}] + 2 \underbrace{E[\hat{\theta} - E[\hat{\theta}]]}_{= 0 \text{ deterministico}} \cdot (E[\hat{\theta}] - \theta^0) + (E[\hat{\theta}] - \theta^0)^2 =$$

$$= \text{Var}[\hat{\theta}] + (E[\hat{\theta}] - \theta^0)^2$$

BIAS → "scenatura" dello stimatore rispetto al valore vero
 Possiamo accettare una "scenatura" se guadagniamo abbondanza in varianza o viceversa.



Def: Uno stimatore non polarizzato $\hat{\theta}^m$ si dice a MINIMA VARIANZA se $\text{Var}[\hat{\theta}^m] \leq \text{Var}[\hat{\theta}]$, $\forall \hat{\theta}$ non polarizzato

($\hat{\theta}$ raggiunge il limite di C.R. $\Rightarrow \hat{\theta}$ è a MINIMA VARIANZA)

NON è garantito che ogni stimatore possa raggiungere il limite di C.R.
 \Rightarrow M.N. VAR < C.R. NON sono equivalenti

Esempio calcolare la quantità di info di Fisher per la stima della media di una v.c. gaussiana.

$$X = \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_N \end{bmatrix} \text{ con } X_i \text{ iid}$$

dato che faccio un esempio (sono tutti =)

$$\boxed{\text{NOTA}} \quad f_{X(x)} = f_{X_1}(x_1) \cdot f_{X_2}(x_2) \cdots \cdot f_{X_N}(x_N) = \prod_{i=1}^N f(x_i)$$

$$\Rightarrow -E\left[\frac{\partial^2}{\partial \theta^2} \ln f_x^{(\theta)}(X) \Big|_{\theta=\theta^0}\right] = -E\left[\frac{\partial^2}{\partial \theta^2} \sum_{i=1}^N \ln f^{(\theta)}(x_i) \Big|_{\theta=\theta^0}\right] =$$

$$= -\sum_{i=1}^N E\left[\frac{\partial^2}{\partial \theta^2} \ln f^{(\theta)}(x_i) \Big|_{\theta=\theta^0}\right]$$

$$\theta^0 = m \quad f^{(\theta)}(X_i) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2}\left(\frac{x_i-\theta}{\sigma}\right)^2} \quad \text{generale gaussiana}$$

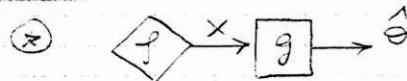
$$\ln f^{(\theta)}(x_i) = -\ln(\sqrt{2\pi}\sigma) - \frac{1}{2}\left(\frac{x_i-\theta}{\sigma}\right)^2$$

$$\frac{\partial}{\partial \theta} (\ln f^{(\theta)}(x_i)) = \frac{x_i-\theta}{\sigma^2} \quad \text{per la } \sum_{i=1}^N$$

$$\frac{\partial^2}{\partial \theta^2} (\ln f^{(\theta)}(x_i)) = -\frac{1}{\sigma^2} \Rightarrow S = \frac{N}{\sigma^2} \Rightarrow \text{Var}[\hat{\theta}] \geq \frac{\sigma^2}{N} = \text{Var}[M_1]$$

\Rightarrow la media campionaria è il miglior stimatore possibile poiché raggiunge il limite di C.R.

24-4-2001



θ = Momenti $\Rightarrow g$ = Momenti campionari
 $\theta = ? \Rightarrow g(\cdot) = ?$

CRITERI DI STIMA

CRITERIO DELLA MAX VEROSIMIGLIANZA (Maximum Likelihood, Lord Fisher '20)

Faccio riferimento alla formulazione generale del problema della Stima. (congiunta)

In particolare suppongo di conoscere $f_x^{(\theta)}(x)$

Qualche volta, si scrive $f_x(x|\theta) \rightarrow$ NON ha senso poiché θ non è una V.C.

Per un dato valore \bar{x} , dato che \bar{x} è fissa, il parametro è θ

$L(\theta, \bar{x}) := f_x^{(\theta)}(\bar{x}) = f_x(\bar{x}|\theta) \rightarrow$ è detta VEROSIMIGLIANZA di θ sulla base dell'osservazione \bar{x}

Per V.C. discrete $L(\theta, \bar{x}) := P^{(\theta)}(X = \bar{x})$

prove di Bernoulli
(prob. di avere 4 successi)

Esempio : Moneta $P(\text{Testa}) = \theta$

Lanciando la moneta 4 volte ottengo 4 Teste $\Rightarrow L(\theta, \{T, T, T, T\}) = \theta^4$

{ Se la moneta è truccata $\epsilon \theta = 1 \Rightarrow L = 1$ → è come se avessi un voto alle mie hp
 " " " è onesta $\epsilon \theta = \frac{1}{2} \Rightarrow L = \frac{1}{16}$

→ Il valore $\theta = 1$ è più verosimile di $\theta = 0,5$

Se invece ottengo 2 Teste e 2 croci $\Rightarrow L(\theta, \{2T, 2C\}) = \binom{4}{2} \theta^2 (1-\theta)^2$

{ Se $\theta = 1 \Rightarrow L = 0$ → effettivamente NON posso pensare che la moneta abbia 2 Teste se è uscita croce

Se $\theta = 0,5 \Rightarrow L = 6 \cdot \frac{1}{16} = 0,375$

Se $\theta = 0,1 \Rightarrow L = 6 \cdot 0,01 \cdot 0,81 = 0,0486$

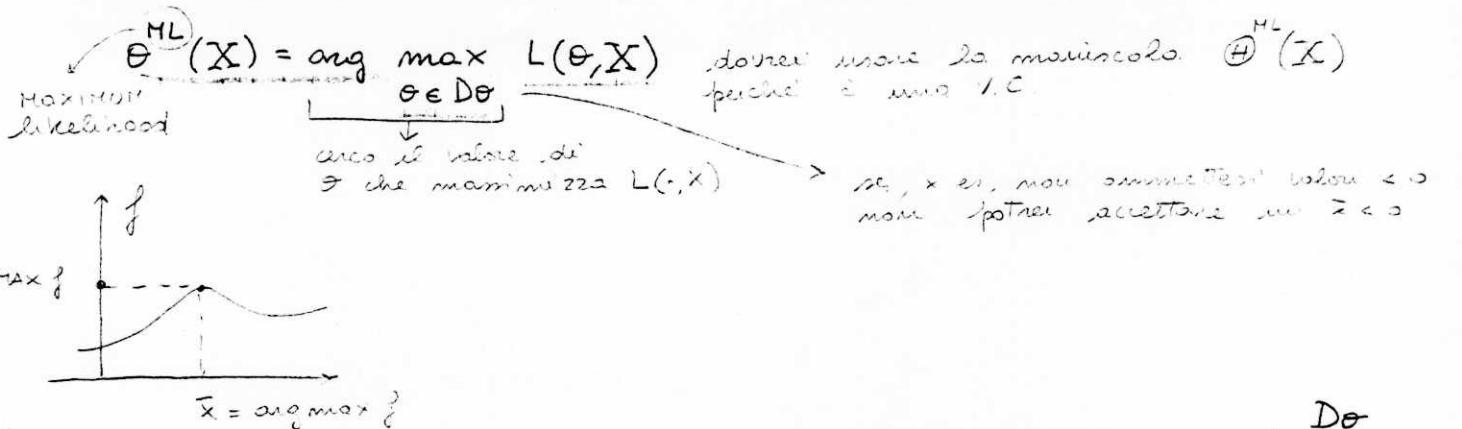
Il valore $\theta = 0,5$ è il + verosimile

NOTA : $L(\cdot, x)$ NON è una ddp poiché ciò che varia è θ , NON x

Pertanto, in generale, $\int L(\theta, x) d\theta \neq 1$ dove $D_\theta =$ insieme dei valori ammissibili di θ

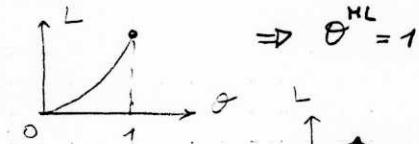
D_θ → per ho usato $\theta > 0$

perché potesse essere un intervallo aperto e perché questo sia più utile

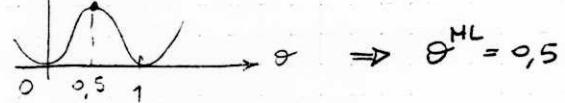
CRITERIO DELLA MAX VEROSIMIGLIANZA \rightarrow Scelta dei FREQUENTISTI

Esempio: Moneta, $k = \text{m}\circ\text{o di teste, } N \text{ lance. } L(\theta, k) = \binom{N}{k} \theta^k (1-\theta)^{N-k}$ $0 \leq \theta \leq 1$

$$\bar{k} = 4 \Rightarrow L(\theta, 4) = \theta^4$$



$$\bar{k} = 2 \Rightarrow L(\theta, 2) = 6\theta^2(1-\theta)^2$$



In generale, se ho k teste su N lanci $\Rightarrow \theta^{\text{ML}} = \frac{k}{N}$

NB [Spero è + comodo maximizzare $S = \ln L$ (S detto supporto o log-likelihood)
 $\theta^{\text{ML}}(X) = \arg \max_{\theta \in D\theta} \ln L(\theta, X)$

Uno dei vantaggi è che, se ho N campioni indipendenti,

$$S(\theta, X) = \ln L(\theta, X) = \ln \prod_{i=1}^N f_{X_i}^{(\theta)}(X_i) = \sum_{i=1}^N \ln f_{X_i}^{(\theta)}(X_i) = \sum_{i=1}^N S_i(\theta, X_i)$$

Maximizzare S o L è del tutto equivalente ai fini del risultato finale
 $(x_1 > x_2 \Leftrightarrow \ln x_1 > \ln x_2, x_1, x_2 \geq 0)$
 $L_1 > L_2 \quad S_1 > S_2$

Esempio: Dati N campioni indipendenti di una v.c. gaussiana, determinare lo stimatore congiunto ML di m e σ^2 .

$$\theta = \begin{bmatrix} m \\ \sigma^2 \end{bmatrix} = \begin{bmatrix} \theta_1 \\ \theta_2 \end{bmatrix}$$

$$S(\theta, X) = \ln \left(\frac{1}{\sqrt{(2\pi\sigma^2)^N}} e^{-\frac{\sum(X_i - m)^2}{2\sigma^2}} \right) =$$

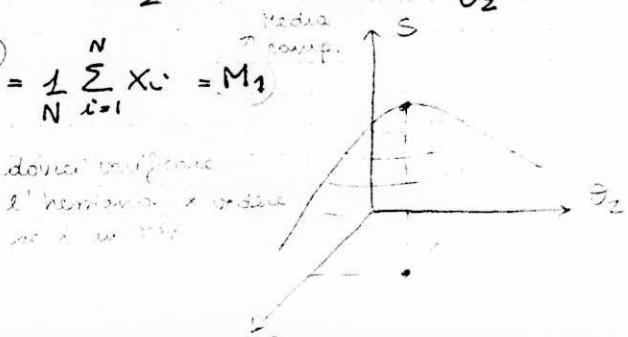
è ancora una v.c. perché non ho ancora fatto l'perimento

d.d.p. congiuntura dei dati sperimentali

$$= \ln \left(\frac{1}{\sqrt{(2\pi\sigma_2)^N}} e^{-\frac{1}{2} \frac{\sum(X_i - \theta_1)^2}{\theta_2}} \right) = -\ln \sqrt{(2\pi)^N} - \frac{N}{2} \ln \theta_2 - \frac{1}{2} \sum_{i=1}^N \frac{(X_i - \theta_1)^2}{\theta_2}$$

$$\frac{\partial S(\theta, X)}{\partial \theta_1} = 0 \Rightarrow \sum_{i=1}^N \frac{X_i - \theta_1}{\theta_2} = 0 \Rightarrow \theta_1^{\text{ML}} = \frac{1}{N} \sum_{i=1}^N X_i = M_1$$

dove verificare l'heriamo e vedere se è un min.



$$\frac{\partial S(\theta, x)}{\partial \theta_2} = 0 \Rightarrow -\frac{N}{2\theta_2^2} + \frac{1}{2} \sum_{i=1}^N \frac{(x_i - \theta_1)^2}{\theta_2^2} = 0 \Rightarrow \theta_2^{ML} = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - M_1)^2} = (S^2)$$

(si verifica che è un pto di max)

NB: S^2 è uno stimatore polarizzato, $E[S^2] \neq \sigma^2$

Esercizio: Siano noti N tempi di attesa W_i tra eventi di Poisson. Trovare lo stimatore ML di λ e di $m := E[W_i]$

$$\lambda = \frac{N}{\sum W_i}, \quad m = \frac{\sum W_i}{N}$$

PROPRIETÀ DEGLI STIMATORI ML

funzione

- Sotto ipotesi di regolarità, se $\eta = h(\theta)$ è un parametro funzione di θ (es: $\eta = \theta^3$) allora: $\eta^{ML} = h(\theta^{ML})$ (es: $\eta^{ML} = (\theta^{ML})^3$)
- Nell'esercizio sopra $m = E[W_i] = \frac{1}{\lambda} \Rightarrow m = \frac{1}{\lambda^{ML}}$ (se sono altre tecniche di stima per cui non vale questa proprietà).
- Sotto hp di regolarità θ^{ML} per campioni indipendenti e iid è uno stimatore asintoticamente:
 - consistente
 - non polarizzato
 - raggiunge il limite di C.R. \rightarrow tende a diventare imossibile
 - gausiano
- NON è un contraddizione con l'es: S^2 perché ciò è vero ASINTOTICAMENTE cioè x un gran n° di dati.
- limite del metodo: x pochi dati tutti questi vantaggi NON valgono

PREGIO: ML è una tecnica generale (può avere o no dipendenza da ddp)

DIFETTO: Presuppone la conoscenza di $f_x^{(0)}(x)$ (hp forte)

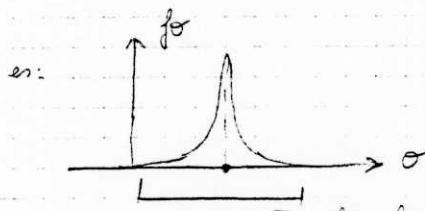
STIMA "A POSTERIORI" \rightarrow scuola BAYESIANA NON è una V.C.

Stima ML: θ è un parametro DETERMINISTICO ignoto

Stima a posteriori: descrivo θ come una V.C. \Rightarrow Teorema di Bayes

26-4-2001

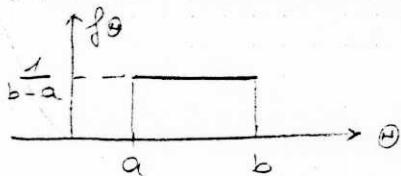
Idea: Trattare θ come una V.C.



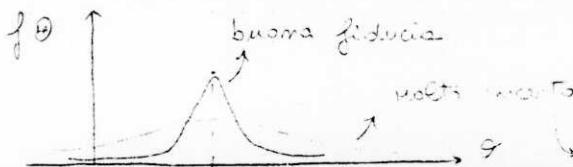
Esempio (come rappresentare le conoscenze a priori mediante ddp).

mi aspetto che la cost di quantizzazione universale sia in questo intervallo.

So che $a \leq \theta \leq b$ ma non ho motivi per preferire determinati valori.



Mi aspetto $\theta \approx \bar{\theta}$ con un po' di incertezza

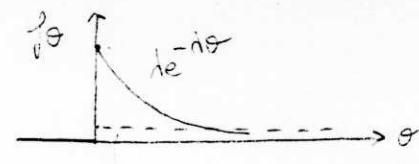


Se mi fiducia completamente
in quanto



mi NON ha +
scava importanza
nel punto stima

so che $\theta \geq 0$ e che valori troppo grandi sono improbabili

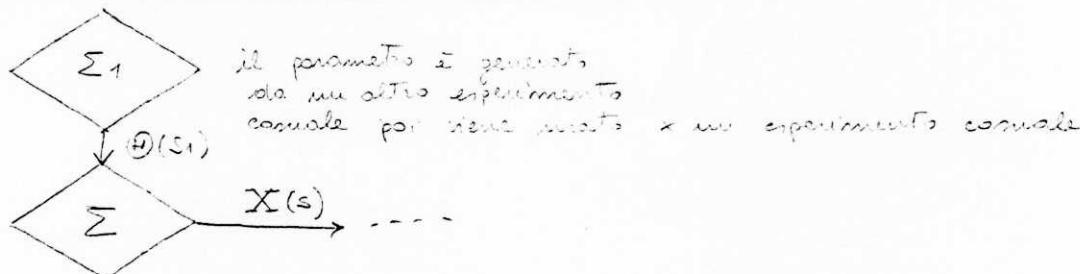


se conosco la media $\Rightarrow \lambda = \frac{1}{m}$

unico parametro dell'exp

caso di MAX Likelihood $\Rightarrow \lambda$ molto piccolo \Rightarrow a quasi nulla

SCHEMA MODIFICATO DEL PB DELLA STIMA



Σ_1 : sorgente casuale caratterizzata da $f_\Theta(\theta)$

Σ : sorgente casuale caratterizzata da $f_{X|\Theta}(x|\Theta=\theta)$

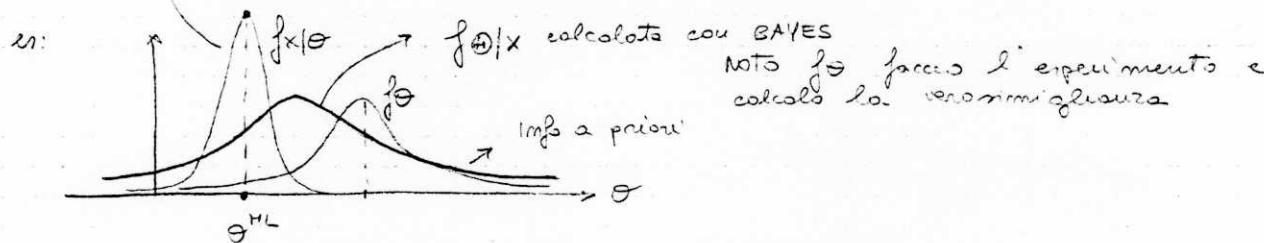
Note: se conosco f_Θ e $f_{X|\Theta}$, posso calcolare la ddp a posteriori condizionata alla vettore delle osservazioni

$$f_{\Theta|X}(\theta|X) = \frac{f_{X|\Theta}(X|\theta) f_\Theta(\theta)}{\int f_{X|\Theta}(X|\theta) f_\Theta(\theta) d\theta} \rightarrow \text{Tes della Prob. Tot}$$

↓
Densità a posteriori

NON dipende da X

evidenza sperimentale
il denominatore è una cost. di normalizzazione
 \Rightarrow si può calcolare imponendo che l'area sia unitaria (una volta muto il numeratore).



la ddp a posteriori è un compromesso tra informazioni a priori (f_Θ) e osservazioni ($f_{X|\Theta}$)

Esempio: In una scatola ci sono monete oneste (40%) e truccate (60%).

Per quelle truccate $P(\text{Testa}) = 0,8$. Estraggo una moneta a caso.

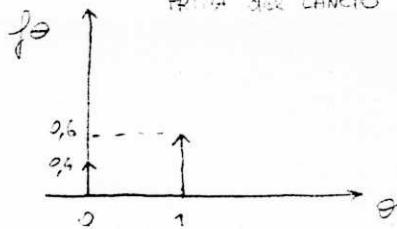
Qual è la prob. che sia truccata? Se dopo averla lanciata esce testa, quale è la prob. a posteriori che sia truccata?

$$\Theta = \begin{cases} 0 & (\text{onesta}) \\ 1 & (\text{truccata}) \end{cases} \quad P(\Theta=0) = 0,4 \quad P(\Theta=1) = 0,6$$

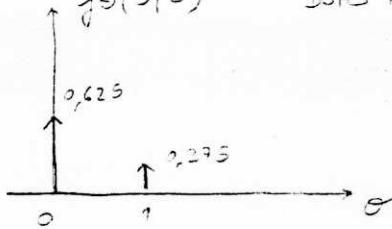
$$P(C|\Theta=0) = 0,5 \quad P(C|\Theta=1) = 0,2$$

$$P(\Theta=1|C) = \frac{P(C|\Theta=1) P(\Theta=1)}{P(C|\Theta=1) P(\Theta=1) + P(C|\Theta=0) P(\Theta=0)} = 0,375$$

FORMA DEL LANCIO

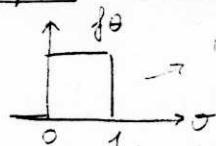


$f_\theta(\theta|C)$



DOPPO IL LANCIO (caso no spiegazione)

ESEMPIO: moneta. Voglio stimare $p = P(T)$



NON rappresenta nulla delle monete

Lancio la moneta

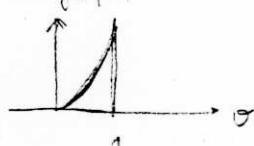
Testa

Croce

Testa

Croce

$f_{\theta|T}$



$f_{\theta|T}$

2

0.5 1

$f_{\theta|C}$

1

0.5 1

$f_{\theta|C}$

1

0.5 1

TERZO

$f_{\theta|CC\dots}$

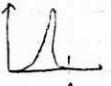


→ rappresenta tutto
ciò che so del pb.

$\frac{K}{N}$

$K = n^{\circ}$ Teste su N lanci

6T su 10 lanci è \neq da 600T su 1000 lanci \Rightarrow se N è molto grande si ottiene

Se punto hp che la moneta mi truccate  e però, comunque ottengo la ddp quale (2)

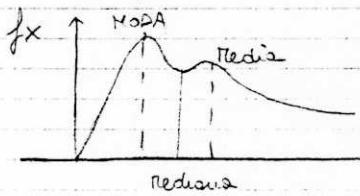
Solo se punto cioè $0 \rightarrow 1$ NON posso + correggere i miei pregiudizi

Come ottenere un pronostico dalla densità a posteriori? \rightarrow pronostico

PROBLEMA: Una volta che conosco $f_{\theta|x}(\theta|x)$ come scelgo $\hat{\theta}$?

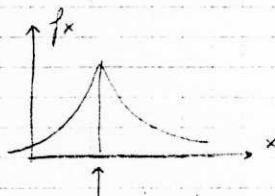
PARENTESI: STIMA DI UNA V.C. DI CUI È NOTA LA DDP

conosco $f_x(x)$. Dovendo fare una scelta (un pronostico, x es), cosa scelgo?

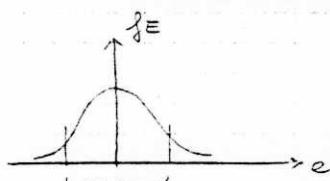


veniamo usate
Tutte e 3

\times posso scegliere
una prolunga. Ma
la prob. di essere rotta
rene un valore è \emptyset
 \Rightarrow meglio usare l'euore (che è una v.c.)



CRITERIO INTERESSANTE:



$$\min_{\hat{\theta}} E[(X - \hat{\theta})^2] \quad e := X - \hat{\theta}$$

\downarrow valore quadratico medio dell'euore

\downarrow piccolo solo se la densità è rinchiusa
intorno all'origine

euore in 1° piccolo \Rightarrow prob. elevate
che è cada in un intervallo piccolo

(minimizza l'euore quadratico medio)

TEOREMA: $E[(X - \hat{\theta})^2]$ è minimo per $\hat{\theta} = E[X]$

Dimostrazione: $J = E[(X - \hat{\theta})^2] = \int_{-\infty}^{+\infty} (X - \hat{\theta})^2 f_X(x) dx$

$$\frac{\partial J}{\partial \hat{x}} = 0 \Rightarrow \int_{-\infty}^{+\infty} (x - \hat{x}) f_x(x) dx = 0 \Rightarrow \hat{x} = \int_{-\infty}^{\infty} x f_x(x) dx = E[X]$$

$$\frac{\partial^2 J}{\partial \hat{x}^2} = \int_{-\infty}^{+\infty} f_x(x) dx = 1 > 0 \quad \text{evid}$$

E se voglio minimizzare $E[(X - \hat{x})^2] = ? \Rightarrow \hat{x} = \underline{\text{mediana}}$

c'è una certa preferenza per il valore medio (che il risultato è più facilmente divisibile)

STIMA DI UNA V.C. IN FUNZIONE DI UN'ALTRA V.C.

X, Y v.c. congiunte con $f_{XY}(x,y)$ nota \rightarrow Se non convergono la d.d.p. congiunta e si stima

PROBLEMA: Trovare $\hat{X}(Y)$ che stima X in base alla sola misura di Y

Suppongo di conoscere $f_{X|Y}$. Ragiono per $Y=y$

TEOREMA: $E[(X - \hat{X}(y))^2 | Y=y]$ è minimo per $\hat{X}^{\text{MS}}(y) = E[X | Y=y]$

MS: Mean Square

STIMATORE IN MEDIA QUADRATICA

Vd. fotocopie

bisogna
conoscere la d.d.p.
condizionata
(eventualmente la stima)

STIMA DI UNA V.C. IN FUNZIONE DI UN'ALTRA V.C.

trovare $\hat{X}(Y)$ con X, Y v.c. congiunte

(è conosciuto peso, voglio indovinare altezza)

\Rightarrow cerca criterio che dico
è metodo migliore

Criterio: voglio che errore che commetto sia piccolo
perimetro

Si vede che:

$$E[(X - \hat{X}(y))^2 | Y=y] \text{ è minimo per } \hat{X}^{\text{MS}}(y) = E[X|Y=y]$$

(stessa cosa che abbiamo visto per la angola v.c. \Rightarrow ecco il valore med
(Trovo che questo è il miglior stimatore possibile))

Questo che abbiamo visto è il Problema di stima in media quadratica - Least Square estimation.

oss:

- Se X e Y sono indip. (voto am. e altezza) $\Rightarrow E[X|Y=y] = E[X]$
(perché se le 2 var. sono indip \Rightarrow la ddp di $x|y$ è uguale alla
ddp di $x \Rightarrow$ anche valore medio) \Rightarrow miglior stimatore che posso rendere è
il miglio il valore medio
- $E[(X - \hat{X}(y))^2 | Y=y] = E[(X - E[X])^2] = \text{Var}[X]$
- Se X e Y sono congiuntam. gaussiane (anche vettoriali: cioè X e Y po
sono essere rett \Rightarrow posso cercare di indovinare voto di geom da quello
di am1 e am2 \Rightarrow devo considerare ddp congiunte e stimatore mug
a resto il voto atteso condizionato).

$$\rightarrow E[X|Y=y] = E[X] + V_{xy} V_y^{-1} (y - E[Y])$$

$$\left(\begin{array}{c} \text{Vare} \\ \text{am1} \\ \text{am2} \end{array} \right) \left[\begin{array}{c} X \\ Y \end{array} \right] = \left[\begin{array}{cc} V_x & V_{xy} \\ V_{yx} & V_y \end{array} \right]$$

fisi
geom

Espressione dello stimatore, errore quadr. medio:

$$E[(X - E[X|Y=y])(X - E[X|Y=y])^T] =$$

$$\boxed{} \quad \boxed{}$$

$$= V_x - V_{xy} V_y^{-1} V_{xy}^T$$

Ma cosa succede?

$$E[X|Y=y] = E[X] + \frac{6x}{6y} (Y - E[Y]) \quad *$$

Nel caso della gauss. è semplice:

$$\frac{E[X|Y=y] - E[X]}{6x} = \frac{\text{valore atteso}}{\text{a priori}} \frac{Y - E[Y]}{6y}$$

pseudo normalizzata
della mia previsione

L'errore quadrat medio che a commette è:

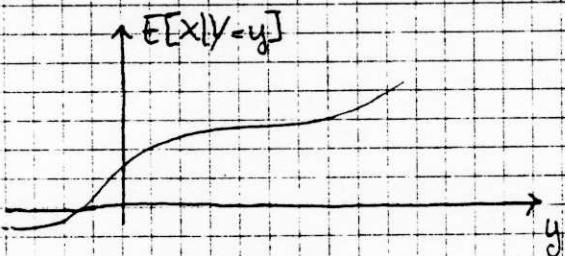
$$\rightarrow E[(X - E[X|Y=y])^2 | Y=y] = 6_x^2 (1 - x^2)$$

se trovo 2 var. fortemente correlate fra loro ($r \approx \pm 1$) \Rightarrow se solo
trovo l'errore quadrat medio sarebbe molto piccolo (anz condizionato da
di addens. su origine) \rightarrow quando uso questo stimatore me ne accorgo, lo smaschero.

Nel caso gaussiano lo stimatore \hat{x}_S è una funzione lineare delle osservazioni.

(Nella * l'unica var. è Y , tutti altri sono n.i. \Rightarrow devo considerare solo
 Y e conoscere $E[X|Y=y]$)

In generale, $E[X|Y=y]$ è una funzione non lineare di y .



Soltanto nel caso gaussiano, l'errore quadratico medio non dipende da y . $E = 6_x^2 (1 - x^2)$ conosco già le proprietà ↑
 \Rightarrow errore quadrat medio nel caso gauss. non dipende dai dati \Rightarrow posso uscire
fisarlo puro di vedere se lo stimatore funziona.

So solo che \hat{x}_S è lo stimatore migliore, però è costoso.

C'è qualcosa di + veloce anche se non migliore?

se è grande
piccolo

STIMATORE \hat{x}_S LINEARE

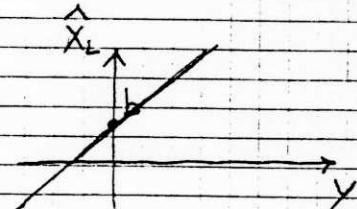
Caso non gaussiano: avevo una soluzione subottima per non dovere
ricostruire $E[X|Y=y]$ (funt. non lineare di y).

Ossia . Restringo l'attenzione alla classe degli STIMATORI LINEARI (che hanno pochi parametri e facili da calcolare).

Ricercata: Considero la classe degli stimatori lineari ($\hat{X}_L(Y) = aY + b$) (vale anche nel caso di X e Y vettori $\Rightarrow a$ e b matrici).

Trovare a e b che minimizzano:

$$J = E[(X - \hat{X}_L(Y))^2] = E[(X - aY - b)^2]$$



← è ciò che sto cercando!

(faccio derivata rispetto alle a e b , imposto = 0 e risolvo due sistemi \Rightarrow)

Soluzione : $\hat{X}_L(Y) = E[X] + V_{xy} V_y^{-1} (Y - E[Y])$

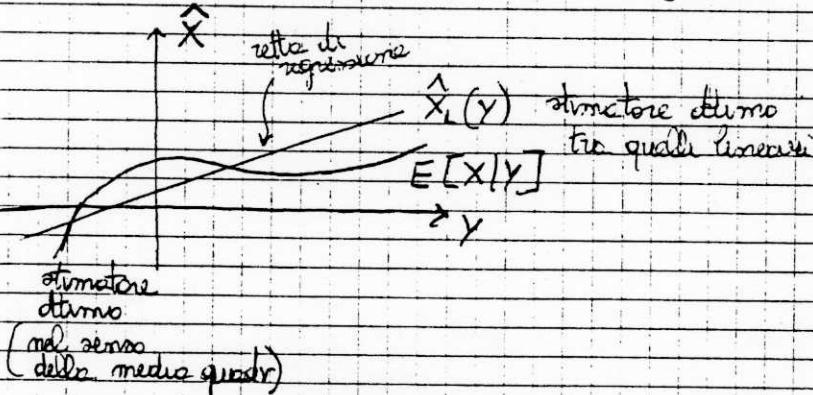
stimatore $\rightarrow E[(X - \hat{X}(Y))(X - \hat{X}(Y))^T] = V_x - V_{xy} V_y^{-1} V_{xy}^T$

(è la stessa formula trovata per gauss., ma si adatta ovunque per le diverse).

Caso scalare :

$$\hat{X}_L(Y) = m_x + \frac{\rho}{6x} (Y - m_y)$$

$$\rightarrow E[(X - \hat{X}(Y))^2] = 6x^2 (1 - \rho^2)$$



↪ faccio meglio ad usarelo, ma + difficile!

STIMATORI OTTIMI E STIMATORI LINEARI:

Lo stimatore che nel caso gaussiano è ottimo in assoluto, nel caso non gaussiano risulta ottimo limitatamente alla classe degli stimatori lineari.

(\Rightarrow 2 strade diverse per trovare stimatore: o ipotesi gaussiana, per dover dimostrarla in qualche modo, non solo da histogrammi; oppure sono + prudente e cerco uno stim. lineare e così trovo perci uno

stimatore che potrebbe non essere il migliore di tutti).

Torniamo allo stima a posteriori. Supponiamo di avere calcolato:

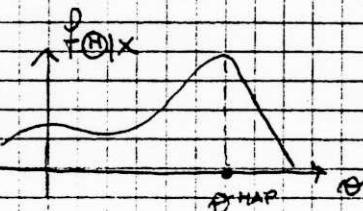
$$f_{\Theta|X}(\theta|x) \quad . \quad \text{Come generare } \hat{\theta}?$$

↑
parametri
misurati osservazioni

(Ci sono \neq alternative)

1^a strada: STIMA MAP (Maximum A Posteriori)

$$\hat{\theta}^{\text{MAP}}(x) = \arg \max_{\theta} f_{\Theta|X}(\theta|x)$$



as $\hat{\theta}^{\text{MAP}}$ è il modo della ddp a posteriori come momento

Commenti:

- Dato che (per il teo. di Bayes)

$$f_{\Theta|X}(\theta|x) = \underbrace{f_{X|\Theta}(x|\theta)}_{\sim \dots} f_{\Theta}(\theta)$$

\leftarrow non dipende da θ

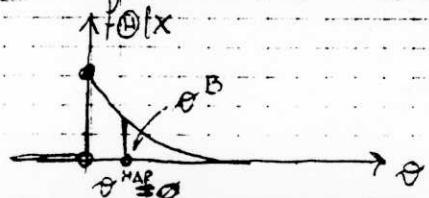
$$\Rightarrow \hat{\theta}^{\text{MAP}} = \arg \max_{\theta} \{ f_{X|\Theta}(x|\theta) f_{\Theta}(\theta) \}$$

Assomiglia molto alla stima ML (infatti senza Θ , sarebbe la retta di quantile). La formula è identica alla stima ML se f_{Θ} è uniforme (cioè se è cost).

Per calcolare max \Rightarrow devo cercare punti di stazionarietà \Rightarrow meglio usare LOGARITMO da max.

- Le tecniche numeriche sono analoghe a quelle già viste per la stima ML.

- Limite: in certi casi la moda è poco significativa



sopra ddp a punti di tipo espon. $\Rightarrow \hat{\theta}^{\text{MAP}} \rightarrow \infty$

è inf. ovunque x c'è 100% di probab.
che sia > di $\hat{\theta}^{\text{MAP}}$ la probab..

2^a strada:

STIMA DI BAYES

$$\hat{\theta}^B(X) = E[\Theta|X] \quad (\text{è lo stimatore in medias quadr.)}$$

($\hat{\theta}^B$: stima migliore in quel caso)

Commenti:

/ per gauss $E[X] = \text{con} \ \mu_{\Theta}$

- Se Θ e X sono cond. gaussiane,

$$\hat{\theta}^B(X) = \hat{\theta}^{\text{MAP}}(X) = E[\Theta] + V_{\Theta X} V_X^{-1} (X - E[X])$$

$$\left(\text{Var} \begin{bmatrix} X \\ \Theta \end{bmatrix} \right) = \begin{bmatrix} V_X & V_{X\Theta} \\ V_{\Theta X}^T & V_{\Theta} \end{bmatrix}$$

- Negli altri casi è vero trovare formule esplicite.

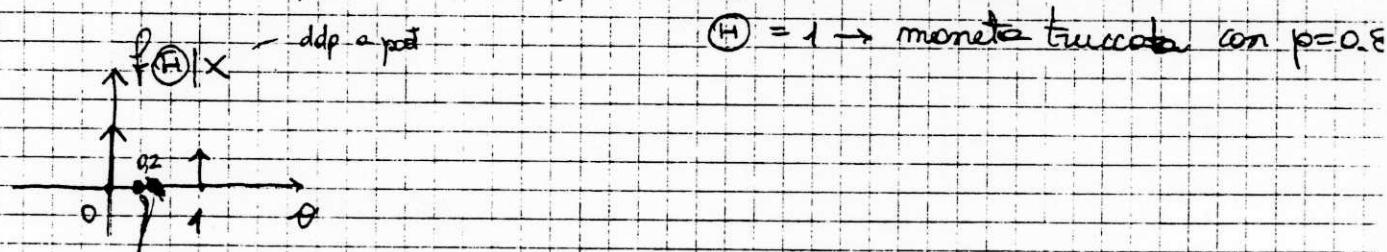
quando var. non sono cond. gauss.

[\Rightarrow questo spiega successo della stima MAP x' più semplice che calcola l' \int , che richiede stima di B . (se ho ddp ricavo $E[\cdot]$ con integr. \Rightarrow difficile da calcolare se ddp è brutta)]

Però ci sono tecniche di simulazione stocastica. (riduzione generazione di n° casuali).

- Punto debole: in certi casi non ho vero prendere la media

(ESEMPIO: supp. di avere param. $\Theta = 0 \rightarrow$ moneta onesta



media di 2 articelle = 0.2 ma non ha senso, se moneta può avere σ od 1.

3^a strada: STIMA HS LINEARE

$$\hat{\theta}^{\text{HS}}(X) = E[\Theta] + V_{\Theta X} V_X^{-1} (X - E[X])$$

Commenti:

- Se Θ ed X sono condizionati gaussiane, $\hat{\theta}^{\text{HS}}$ coincide con $\hat{\theta}^B$ e $\hat{\theta}^{\text{MAP}}$ (nel caso gaussiano, tutti gli estimatori sono equivalenti).

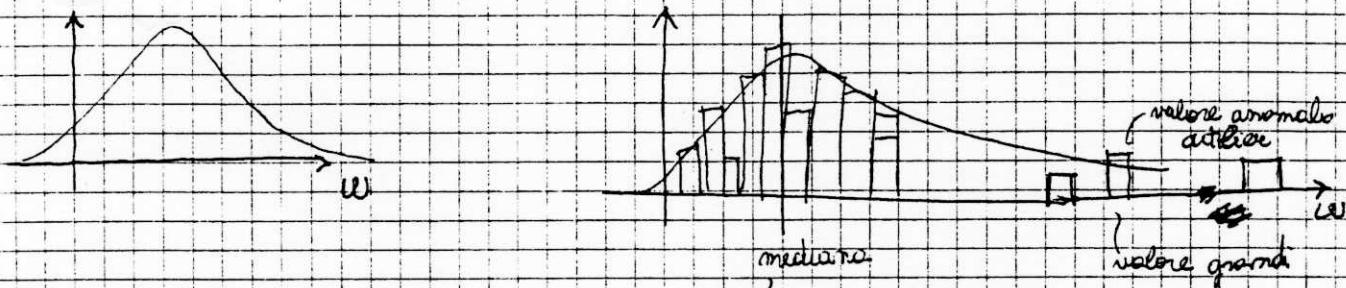
si può anche porsi $\hat{\theta} = \text{mediana}(f_{\theta} \mid x)$

(non ha un nome particolare questo stimatore)

Se ho var con gauss $\Rightarrow \hat{\theta} = \bar{x}^M = \bar{x}^B = \bar{x}^{MAP}$

Hanno in Matlab calcolato lo mediana

Può avere dei vantaggi rispetto alla stimatrice con media x se c'è un solo
molto alto \Rightarrow media scossa, mentre mediana no.



anche se aggiungo valore \square estremo
mediana regge il 50% da una parte e
il 50% dall'altra \Rightarrow + robusta ad inservimenti
di valori estremi.

STIMA A POSTERIORI: COMMENTI CONCLUSIVI

- Quando usarla:

1) $x \mid \theta$ è una v.c. ($\underline{\text{es.}}$ catola con monete oneste e truccate)

2) Stima sequenziale (dati che arrivano a spazi di tempo
consecutivamente ma ad intervalli: all'inizio ho insieme
di dati e costituisco mia stima, poi arrivano altri dati \Rightarrow devo
ricostruire stima. Posso procedere in 2 mode: o metto insieme
tutti i dati e costituisco valor atteso; oppure propongo
l'info usando la prima stima come stima a priori ed elaboro
solo ultimo insieme di dati usandoli come stima a posteriori
 \Rightarrow non rischio che n° di dati esploda con questa 2^a strada).

3) Non far per rappresentare le mie conoscenze e priori
($\underline{\text{es.}}$ conoscenze di un esperto).

- Vantaggi: più generale di ML

possibilità di trattare situazioni con pochi dati (avc).

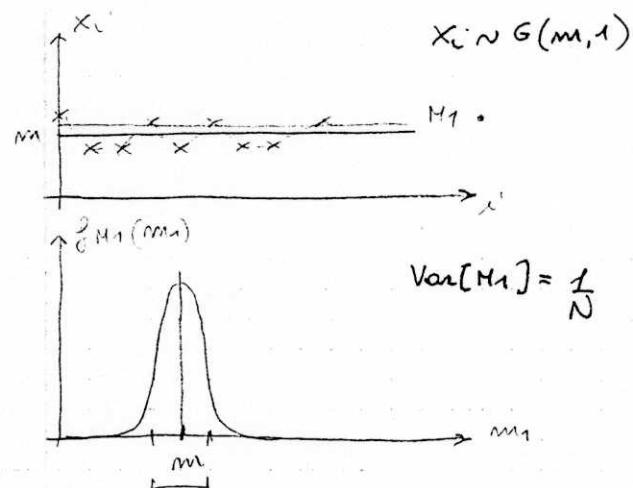
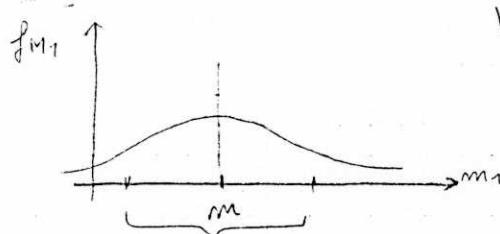
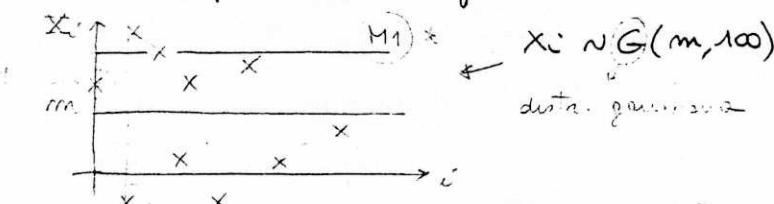
- Svantaggi: ipotesi forti (andre di + di quelle di ML: dovrò
conoscere generalizz. casuale). : problema della scelta del
"prior" f_{θ} . (non è facile trasmettere in info a priori)

INTERVALLI DI CONFIDENZA

Formare delle stime senza indicarne la precisione può essere del tutto fuorviante.

Esempio: X_i iid $i=1 \dots N$ $E[X_i] = m$ Considero come stimatore M_1

(media campionaria) N fisso

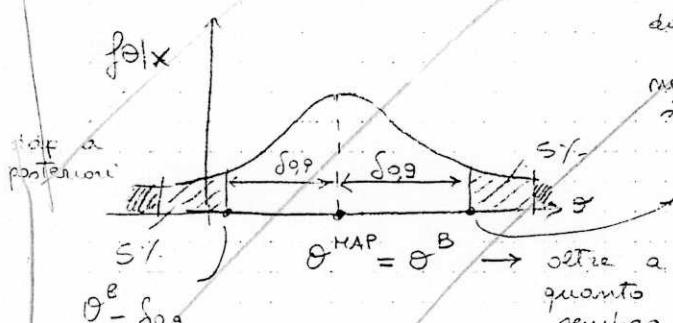


* M_1 potrebbe anche cadere lì perché la media camp. puo' varire in un intervallo ampio

* M_1 puo' stare poco \rightarrow intervallo stretto

In questo caso NON posso fidarmi!

Dovrò sempre fornire il riferimento (\rightarrow intervalli di confidenza) prima di fornire un n .

Esempio : STIMA A POSTERIORI

adp unimodale, simmetrica
non ho pb a scegliere la stima

$$\delta^B + \delta_{0.9}$$

$\theta^{MAP} = \theta^B \rightarrow$ oltre a questo m° bisogna dire quanto ci si può fidare (e sembra che NON ci si possa fidare).

Per trovare la larghezza $\delta_{0.9}$ fuori 2 code (curvatura del 5%) \rightarrow c'è solo il 10% di prob di cadere fuori dall'intervallo $[\theta - \delta_{0.9}, \theta + \delta_{0.9}]$.

Cerco un valore $\delta_{0.9}$ tale che la prob. $P(\theta - \delta_{0.9} \leq \theta \leq \theta + \delta_{0.9}) = 0.9$

Ho il 90% di prob che $\theta \in I_{0.9} := [\theta - \delta_{0.9}, \theta + \delta_{0.9}]$, potrei usare anche 0.95 o qualcosa di più.

Intervallo Bayesiano (di confidenza) al 90%.

$\gamma = 0.9$ è il LIVELLO DI CONFIDENZA

Se voglio risparmiare meno devo allargare l'intervallo (di solito in misura infinita al 91% \rightarrow 1 prob su 20 di sbaglio).

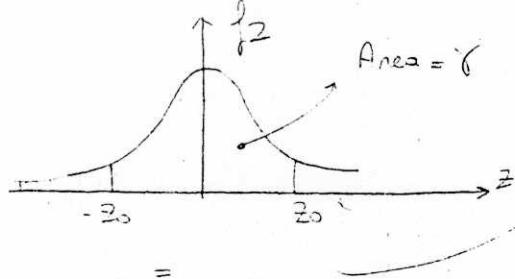
Come fare se non uso la stima a posteriori?

Esempio: Sia $\hat{\theta}$ uno stimatore gaussiano non polarizzato ($E[\hat{\theta}] = \theta$) avente varianza $\sigma_{\hat{\theta}}^2 := \text{Var}[\hat{\theta}]$ NOTA. Trovare I_γ per γ fissato

È una IC. Supp. dati sufficienti. Supp. valori estremi - valori medi

Idea: Standardizzazione $Z_1 = \frac{\hat{\theta} - \theta}{\sigma_{\hat{\theta}}} \sim N(0,1)$ (gauss. standard)

cerco nelle Tabelle Z_0 t.c. $P(-Z_0 \leq Z_1 \leq Z_0) = \gamma \Rightarrow P(|Z_1| \leq Z_0) = \gamma$



$$F_2(Z_0) - F_2(-Z_0) = \gamma =$$

area 1/2

$$= F_2(Z_0) - (1 - F_2(Z_0)) =$$

$$= 2F_2(Z_0) - 1 = \gamma$$

$$\Rightarrow F_2(Z_0) = \frac{1+\gamma}{2} = 0,5 + \frac{\gamma}{2}$$

$$\Rightarrow P\left(\left|\frac{\hat{\theta} - \theta}{\sigma_{\hat{\theta}}}\right| \leq Z_0\right) = \gamma \Rightarrow P\left(\left|\frac{\hat{\theta} - \theta}{\sigma_{\hat{\theta}}}\right| \leq Z_0 \sigma_{\hat{\theta}}\right) = \gamma \Rightarrow$$

$$P\left(\hat{\theta} - Z_0 \sigma_{\hat{\theta}} \leq \theta \leq \hat{\theta} + Z_0 \sigma_{\hat{\theta}}\right) = \gamma$$

$$I\gamma = [\hat{\theta} - Z_0 \sigma_{\hat{\theta}}, \hat{\theta} + Z_0 \sigma_{\hat{\theta}}]$$

In pratica se $\theta = 7,3$, $Z_0 \sigma_{\hat{\theta}} = 0,4 \rightarrow \theta = 7,3 \pm 0,4$ ($\rho = 0,95$)

le Bayesiano dice che tutto noi è un imbroglio
perché $\hat{\theta}$ non è una v.c. perché $\hat{\theta}$ è in natura
 \rightarrow se raccolgo dati diventa una v.c.

livello di prob.

↳ se non è specificato mi mette 95%.

INBROGLIO: dire che $\theta \in I\gamma$ significa una volta raccolto i dati $\hat{\theta}$ è un
numero e non una v.c. $\Rightarrow \theta \in I\gamma \circ \theta \notin I\gamma$ MA NON ha
senso parlare di probabilità

E' DIVERSO se parlo di prob. SOGGETTIVA

SIFESA SUL FICHERAANO: γ è il n° di volte che ci saremo se nella mia vita
ripete il "successo" + volte $\Rightarrow \gamma = \%$ di volte che
ho ragione secondo questa regola

Esempio: X_i iid, $\text{Var}[x_i] = \sigma^2$, σ^2 NOTA, N "grande". Trovare $I\gamma$ per

M_1 . Parametro da cui ho $\hat{\theta} = m$

TEOREMA CENTRALE DEL LIMITE

$$\hat{\theta} = M_1 \quad \sigma_{\hat{\theta}} = \sqrt{\frac{\sigma^2}{N}} = \frac{\sigma}{\sqrt{N}} \quad N \text{ "grande"} \Rightarrow M_1 \sim N(m, \frac{\sigma^2}{N})$$

solo nodosamente tutte le HP del caso precedente

In virtù del caso precedente: $I\gamma = [M_1 - Z_0 \cdot \frac{\sigma}{\sqrt{N}}, M_1 + Z_0 \cdot \frac{\sigma}{\sqrt{N}}]$

SE: $\frac{\sigma}{\sqrt{N}}$ è anche detto STANDARD ERROR

$$SD = \sigma \quad SE = \frac{\sigma}{\sqrt{N}}$$

↓ dev. std della media

Possibili PROBLEMI:

(a) noti $N=100$ e $\gamma = 0,9$, trovare $I\gamma$

(b) noti $N=100$ e $I\gamma = [M_1 - \delta, M_1 + \delta]$ Trovare γ (con che prob. posso garantire
di non essere compreso nell'intervallo $[M_1 - \delta, M_1 + \delta]$?)

(c) noti $\gamma = 0,95$ e $I\gamma = [M_1 - \delta, M_1 + \delta]$ Trovare N (ex: ISTAT Demoscopia)

↳ Quale N serve x avere scarsi con prob γ di cadere dentro $I\gamma$

(d) $\frac{1+\gamma}{2} = \frac{1,9}{2} = 0,95$ Sulle Tabelle trovo che $F_2(Z_0) = 0,95$ per

$$Z_0 = 1,645 \Rightarrow I\gamma = \left[M_1 - \frac{1,645 \sigma}{\sqrt{10}}, M_1 + \frac{1,645 \sigma}{\sqrt{10}}\right]$$

$$(b) \text{ Ipotizziamo che } \delta = \frac{\epsilon}{10} \rightarrow \frac{2\delta\gamma}{\sqrt{N}} = \delta = \frac{\epsilon}{10} \rightarrow z_0 = \frac{\sqrt{N}}{10} = 1$$

$$F_2(z_0) = 0,8413 \text{ (dalla Tabella con } z_0 = 1)$$

$$= \frac{1+\gamma}{2} \Rightarrow \gamma = 0,6826 \rightarrow \text{prob del } 68\% \text{ di commettere un errore} \leq \frac{\epsilon}{10}$$

$$(c) \text{ Suppongo } \delta = \frac{\epsilon}{10} \quad F_2(z_0) = \frac{1+\gamma}{2} = \frac{1+0,95}{2} = 0,975 \text{ per } z_0 = 1,96$$

$$\frac{2\delta\gamma}{\sqrt{N}} = \delta = \frac{\epsilon}{10} \Rightarrow N = 100 \cdot (1,96)^2 = 384,16$$

NOTA: $\sqrt{N} = \frac{2\delta\gamma}{\delta} \rightarrow N = \left(\frac{2\delta\gamma}{\delta}\right)^2$ per stimazione la formula (b) doppia e quadruplicare i dati (N)!

\Rightarrow la precisione COSTA! NON è tanto facile guadagnare

Se il n° di osservazioni è piccolo ci solleviamo solo se sono distribuite gaussianamente \Rightarrow media camp. gaussiana vs NO

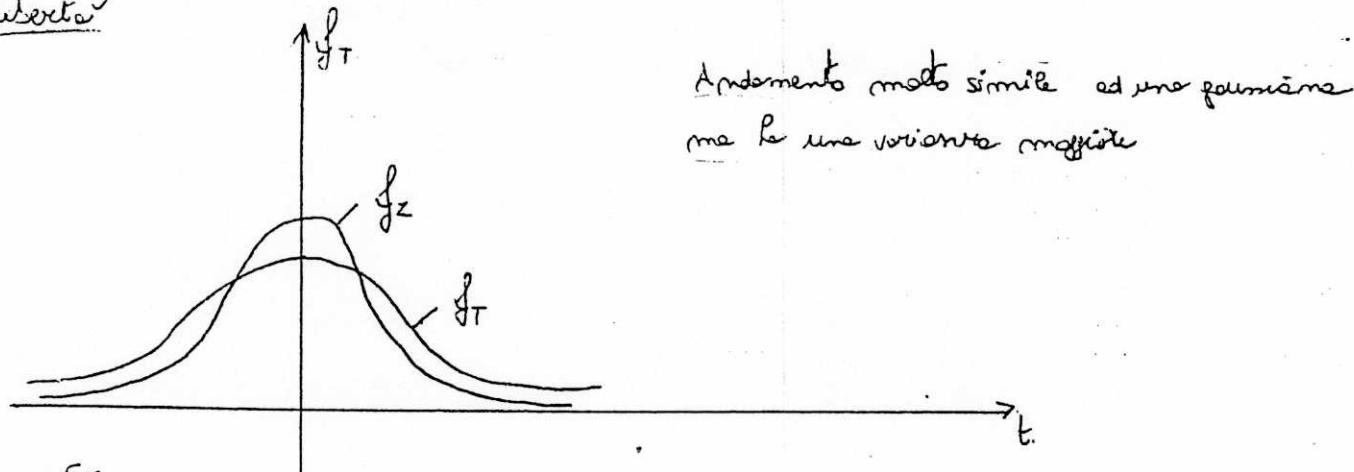
ESEMPIO: X_i i.i.d. gaussiane, σ^2 non nota.

trovare I_g per H_1

PARENTESI da t di Student

da v.c. $T_N := \frac{Z}{\sqrt{\sum_{i=1}^N Z_i^2}} = \frac{Z}{\sqrt{\chi_N^2}}$

dove Z e Z_i sono v.c. i.i.d. $\sim G(0, 1)$ è detto t di Student a N gradi di libertà



Andamento molto simile ad una gaussiana ma la varianza maggiore

Proprietà:

- Simmetrico
- $E[T_N] = 0$
- $\text{Var}[T_N] = \frac{N}{N-2}$
- Per $N \rightarrow \infty$, risulta che $T_N \xrightarrow{\text{in distribuzione}} G(0, 1)$ (mtw per il Teorema centrale del limite)

FINE PARENTESI

Si vede che:

$$\frac{H_1 - m}{S_c / \sqrt{N}} = \frac{H_1 - m}{S} \sqrt{N-1} = \frac{H_1 - m}{\sqrt{N-1}} \xrightarrow{\text{per il Teo del CLT}} \text{distribuzione normale standardizzata}$$

$$S_c^2 = \frac{1}{N-1} \sum_{i=1}^N (X_i - H_1)^2$$

$$S^2 = \frac{1}{N} \sum_{i=1}^N (X_i - H_1)^2 = \frac{N-1}{N} S_c^2$$

$$S_c = \sqrt{\frac{N}{N-1}} S$$

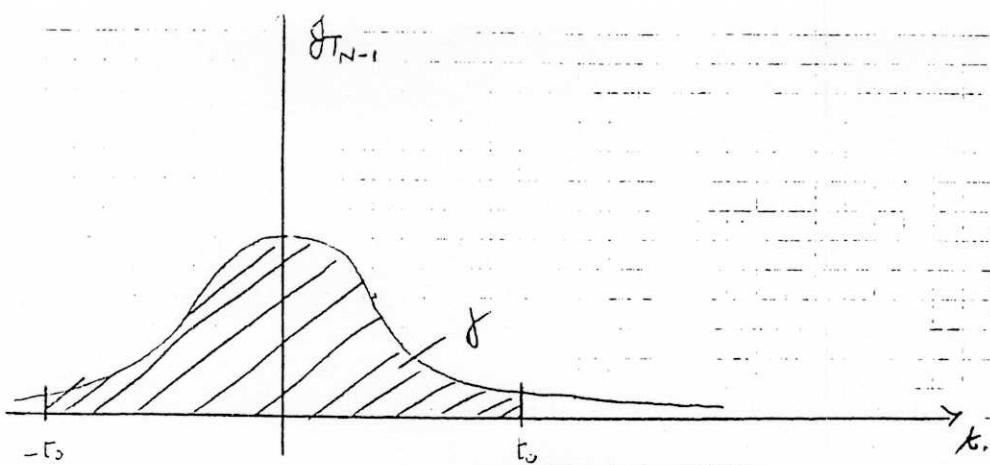
$$\text{NB } S_c^2 = \frac{N}{N-1} S^2 \text{ è la}$$

Varianza campionaria corretta

$$t = \frac{Z}{\sqrt{\chi_{N-1}^2}} \sqrt{N-1} = T_{N-1}$$

NOTA: ricordiamo che H_1 e S^2 sono indipendenti

1) Trovare t.c. $P(|T_{N-1}| \leq t_0) = \gamma$



$$P(-t_0 \leq T_{N-1} \leq t_0) = \gamma$$

t_0 : raccolto delle Tabelle delle t di Student.

$$P\left(-t_0 \leq \frac{M_1 - m}{\frac{s_c}{\sqrt{N}}} \leq t_0\right) = \gamma$$

$$P\left(M_1 - t_0 \frac{s_c}{\sqrt{N}} \leq m \leq M_1 + t_0 \frac{s_c}{\sqrt{N}}\right) = \gamma$$

$$I_\gamma = \left[M_1 - t_0 \frac{s_c}{\sqrt{N}}, M_1 + t_0 \frac{s_c}{\sqrt{N}} \right]$$

$$\left(I_\gamma = \left[M_1 - Z_0 \frac{\sigma}{\sqrt{N}}, M_1 + Z_0 \frac{\sigma}{\sqrt{N}} \right], \text{ nel caso in cui } \sigma = \sigma \right)$$

$$\text{e } \gamma = 0.95$$

$$Z_0 = 1.96$$

TABELLA prendo la colonna corrispondente a $1-\gamma = 0.05$

t_0 dipende da N

$$N = 5 \Rightarrow D = N-1 = 4 \Rightarrow t_0 = 2.776$$

$$N = 10 \Rightarrow D = N-1 = 9 \Rightarrow t_0 = 2.262$$

$$N = 30 \Rightarrow D = 29 \Rightarrow t_0 = 2.045$$

Si noti che t_0 è sempre maggiore di Z_0

$$t_0 - Z_0 \rightarrow 0 \text{ per } N \rightarrow \infty$$

(per N "grande" posso usare Z_0 al posto di T_{N-1}).

ESEMPIO: SONDAGGIO ELETTORALE

- Quanto deve essere numeroso il campione?
- La numerosità in che modo dipende del numero di elettori?
- In un sistema uninominale le cose sono più facili o più difficili.

100.000 elettori di cui X votano per CS

$$\text{Infatti: prove di Bernoulli con } p = \frac{X}{100.000}$$

Problema: Sintesi p a partire dai risultati di N prove di Bernoulli

Soluzione: Usa la frequenza relativa.

$$\hat{p} = \frac{K}{N} \quad \text{con } K: \text{n. di successi.}$$

Intervallo di confidenza? (al 95%)

$$P(S_N = K) = \binom{N}{K} p^K (1-p)^{N-K} \quad (\text{Binomiale})$$

$\begin{matrix} \text{n. di successi} \\ \text{in } N \text{ prove} \end{matrix}$

$$E[S_N] = Np$$

$$\text{Var}[S_N] = Np(1-p)$$

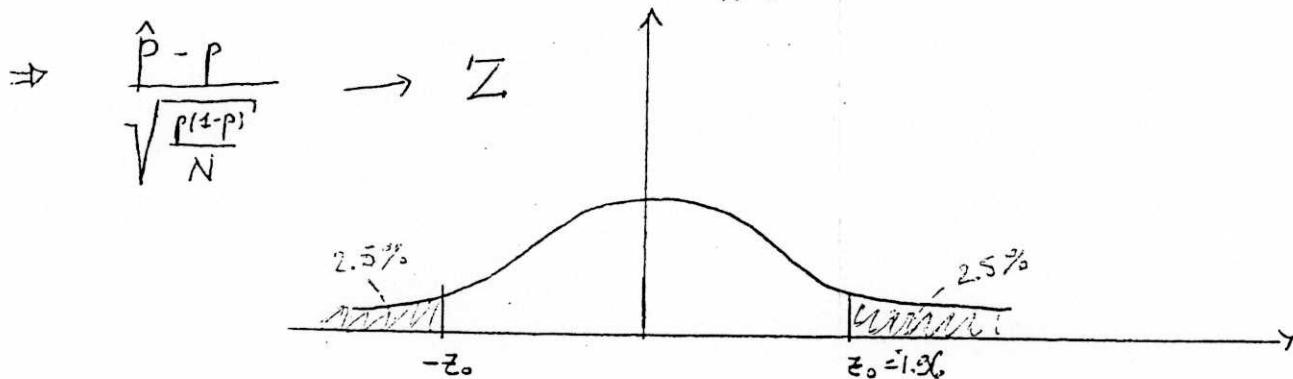
$$\hat{p} := \frac{S_N}{N} \Rightarrow E[\hat{p}] = p \quad (\text{sistema non polarizzato})$$

$$\text{Var}[\hat{p}] = \frac{p(1-p)}{N}$$

$$\text{Var}[\hat{p}] = \text{Var}\left[\frac{S_N}{N}\right] = \frac{1}{N^2} \text{Var}[S_N] = \frac{p(1-p)}{N}$$

in distribuzione

Per il Teorema centrale del limite, $S_N \xrightarrow[N \rightarrow \infty]{\text{distribuzione}} \text{gaussiana}$



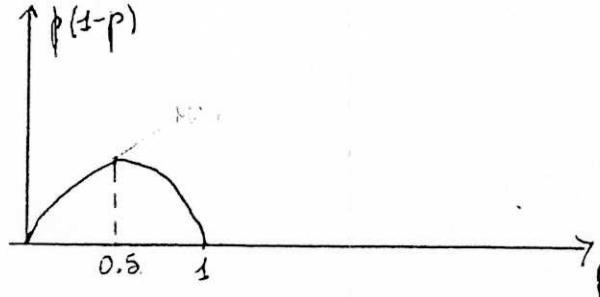
Per N grande, nel 95% dei casi:

$$Z \cong \left| (\hat{p} - p) \frac{\sqrt{N}}{\sqrt{p(1-p)}} \right| < 1.96 \quad \text{avendo}$$

$$|\hat{p} - p| \leq \frac{1.96 \sqrt{p(1-p)}}{\sqrt{N}}$$

depende de p (incognita)

OSSERVAZIONE



Caso peggiore
(intervallo più lungo)
per $p = 0.5$

$$|p - \hat{p}| \leq \frac{1.96 \sqrt{p(1-p)}}{\sqrt{N}}$$

$$< \frac{2 \sqrt{0.5^2}}{\sqrt{N}}$$

nel 95% dei casi

$$|p - \hat{p}| \leq \frac{1}{\sqrt{N}}$$

+ questo deve essere numeroso e
completo

↳ le più elevate coste

Per avere un errore < 1% $\Rightarrow N \geq 10.000$

(nel 5% dei casi puo' ancora andare male)

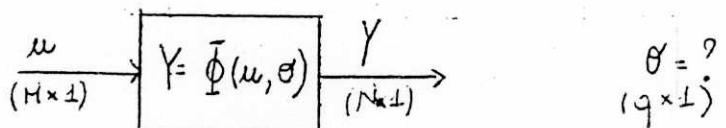
$f = 0.35$	errore %
$N = 150$	$\pm 8\%$
$N = 200$	$\pm 7\%$
$N = 625$	$\pm 6\%$
$N = 2500$	$\pm 2\%$
$N = 10.000$	$\pm 1\%$

- La numerosità del corpo elettorale non ha influenza sulla precisione (Pizzighettone = USA)
- Sistema maggioritario: si vuole un sondaggio per ogni collegio
Se si vuole precisione i costi aumentano rispetto al proporzionale

IDENTIFICAZIONE DI MODELLI (STATICI)

10 Reggio 2001

non dinamici



3 insiemi di variabili: u , Y , θ .

Y : variabili dipendenti, variabili misurate che voglio spiegare. (effetti)

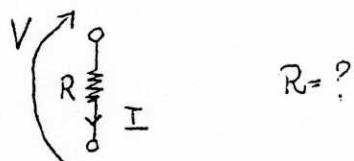
u : variabili indipendenti; variabili misurate oppure mette fuori (cause) mediante le quali voglio spiegare gli effetti.

$\Phi(\cdot, \cdot)$ è il modello matematico che lega u e Y .

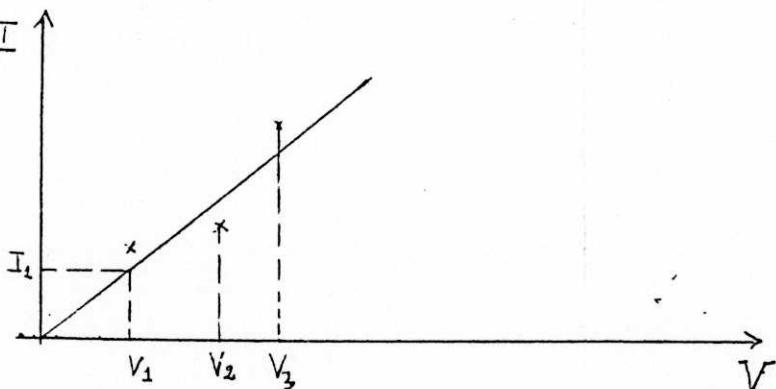
θ : parametri incogniti del modello

ESEMPIO:

$$I = \frac{V}{R}$$



Impongo diversi valori di tensione V ($V = V_1, V = V_2, \dots, V = V_N$) e misuro I ($I = I_1, I = I_2, \dots, I = I_N$)



da retta non si verifica nella realtà:

- Tensioni di misura

- la relazione tra V e I è lineare solo in un resistore ideale

Effetti

$$Y = \begin{bmatrix} I_1 \\ I_2 \\ \vdots \\ I_N \end{bmatrix}$$

Cause

$$u = \begin{bmatrix} V_1 \\ V_2 \\ \vdots \\ V_N \end{bmatrix}$$

Parametro incognito

$$\theta = \frac{1}{R}$$

$$\underbrace{\Phi(u, \theta)}_{\text{modello lineare nel parametro } \theta} = u \theta$$

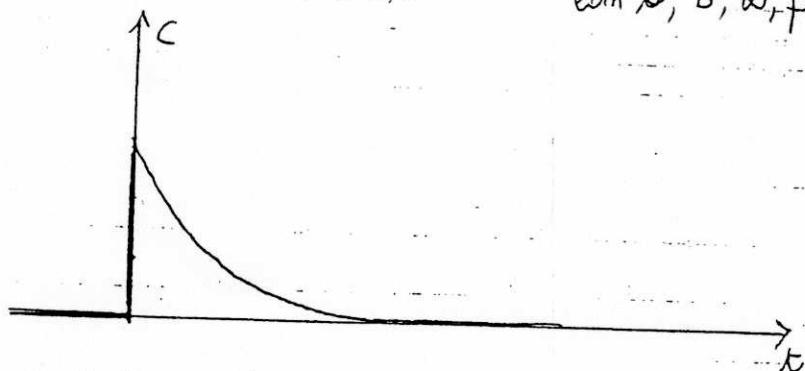
modello lineare nel parametro θ .

Ora R

$$\Rightarrow \underbrace{\Phi(u, \theta)}_{\text{modello non lineare ma pur sempre } \theta} = \frac{1}{\theta} u$$

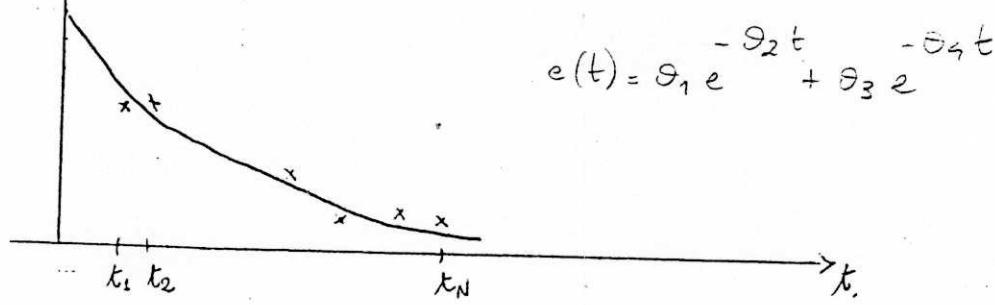
ESERCIZIO: Supponiamo di sapere che la concentrazione plasmatica di un farmaco dopo una iniezione evole secondo la legge:

$$C(t) = ae^{-\alpha t} + be^{-\beta t} \quad \text{con } a, b, \alpha, \beta \text{ dati}$$

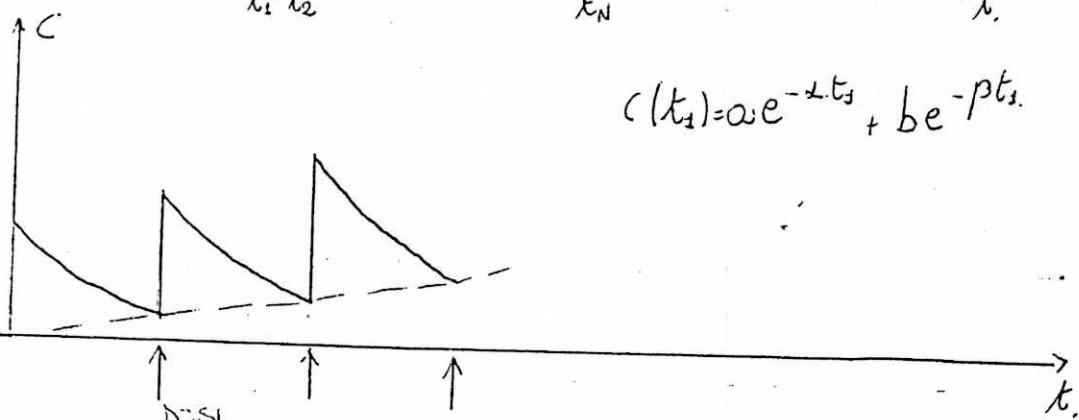


Effettua dei prelievi ai tempi t_1, \dots, t_N

\times punti ottenuti sperimentalmente.



$$c(t) = \theta_1 e^{-\theta_2 t} + \theta_3 e^{-\theta_4 t}$$



$$c(t_i) = a e^{-\alpha t_i} + b e^{-\beta t_i}$$

$$\mathbf{y} = \begin{bmatrix} c(t_1) \\ c(t_2) \\ \vdots \\ c(t_N) \end{bmatrix}$$

$$\mathbf{u} = \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_N \end{bmatrix} = \begin{bmatrix} t_1 \\ t_2 \\ \vdots \\ t_N \end{bmatrix}$$

$$\boldsymbol{\theta} = \begin{bmatrix} \alpha \\ \beta \\ a \\ b \end{bmatrix} \rightarrow \begin{bmatrix} \theta_1 \\ \theta_2 \\ \theta_3 \\ \theta_4 \end{bmatrix}$$

$$\phi(u, \theta) = \begin{bmatrix} \theta_1 e^{-\theta_2 u_1} + \theta_3 e^{-\theta_4 u_1} \\ \vdots \\ \theta_1 e^{-\theta_2 u_N} + \theta_3 e^{-\theta_4 u_N} \end{bmatrix}$$

modello non lineare

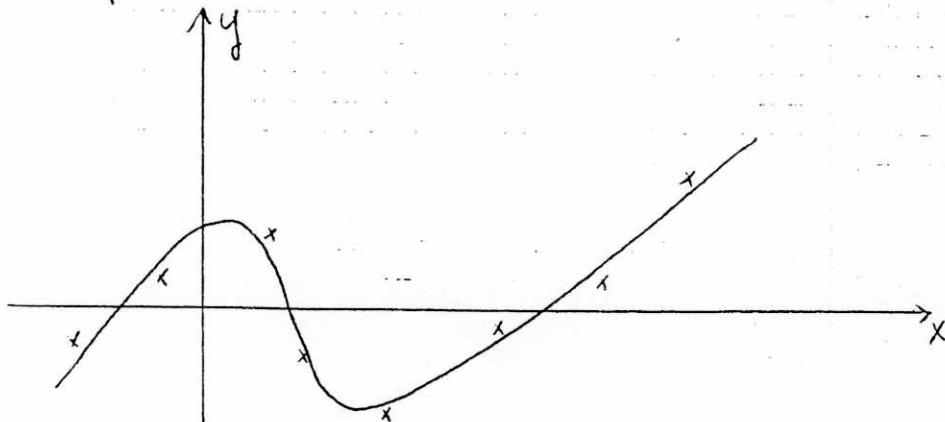
ma puoi

(θ_1, θ_3 crescono linearmente

mentre θ_2, θ_4 sono esponentiali)

ESEMPIO : Voglio interpolare (approssimare) delle coppie di punti (x_i, y_i) con una curva

$$(y = \theta_0 + \theta_1 x + \theta_2 x^2 + \theta_3 x^3)$$



$$Y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_N \end{bmatrix} \quad M = \begin{bmatrix} x_1 & x_2 & \dots & x_N \\ x_1^2 & x_2^2 & \dots & x_N^2 \\ \vdots & \vdots & \ddots & \vdots \\ x_1^3 & x_2^3 & \dots & x_N^3 \end{bmatrix} = \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_N \end{bmatrix} \quad \theta = \begin{bmatrix} \theta_0 \\ \theta_1 \\ \theta_2 \\ \theta_3 \end{bmatrix} = \begin{bmatrix} \theta_1 \\ \theta_2 \\ \theta_3 \\ \theta_4 \end{bmatrix}$$

$$\phi(u, \theta) =$$

$$y_i = \theta_0 + \theta_1 x_i + \theta_2 x_i^2 + \theta_3 x_i^3$$

$$\phi(u, \theta) = \begin{bmatrix} \theta_0 + \theta_1 u_1 + \theta_2 u_1^2 + \theta_3 u_1^3 \\ \vdots \\ \theta_0 + \theta_1 u_N + \theta_2 u_N^2 + \theta_3 u_N^3 \end{bmatrix} = \begin{bmatrix} 1 & u_1 & u_1^2 & u_1^3 \\ \vdots & \vdots & \vdots & \vdots \\ 1 & u_N & u_N^2 & u_N^3 \end{bmatrix} \begin{bmatrix} \theta_0 \\ \theta_1 \\ \theta_2 \\ \theta_3 \end{bmatrix}$$

matrice lineare
matrice parametri

$$\underbrace{\phi(u)}_{\tilde{\phi}(u)} \quad \underbrace{\theta}_{\tilde{\theta}}$$

ESEMPIO : regressione lineare

Dipendenza delle misure di $Q+1$ variabili $y(t), u_1(t), \dots, u_Q(t)$ per $t=1, \dots, N$, voglio spiegare y mediante una funzione lineare delle u_j

$$\underline{y(t) = \theta_1 u_1 + \theta_2 u_2 + \dots + \theta_Q u_Q}$$

Regressione lineare della variabile y sulle variabili u_j

$$Y = \begin{bmatrix} y(1) \\ y(2) \\ \vdots \\ y(N) \end{bmatrix} \quad u = \begin{bmatrix} u_1(1) \\ u_1(2) \\ \vdots \\ u_1(N) \\ u_2(1) \\ u_2(2) \\ \vdots \\ u_2(N) \\ \vdots \\ u_Q(1) \\ u_Q(2) \\ \vdots \\ u_Q(N) \end{bmatrix} \quad \theta = \begin{bmatrix} \theta_1 \\ \vdots \\ \theta_Q \end{bmatrix}$$

$$\tilde{\Phi}(w, \theta) = \tilde{\Phi}(w) \circ$$

$$\tilde{\Phi}(w) = \begin{bmatrix} w_1(1) & w_2(1) & \dots & w_q(1) \\ w_1(N) & w_2(N) & \dots & w_q(N) \end{bmatrix}$$

Def: Un modello è lineare nei parametri se

$\tilde{\Phi} = \tilde{\Phi}(w)$ è detta matrice di sensitività

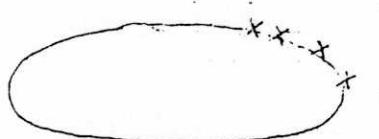
minimi quadrati (LEAST SQUARES (LS))

Cenni storici:

Gauss (1777-1855)

LS nel 1735.

Il 1° gennaio 1800 viene scoperto un asteroide: Ceres.



Da poche misure Gauss cerca di ricostruire l'orbita
↳ con i minimi quadrati e ci arriva.

Nel 1801 divenne direttore dell'Osservatorio di Göttingen.

Nel 1809: "Teoria del moto dei corpi celesti"

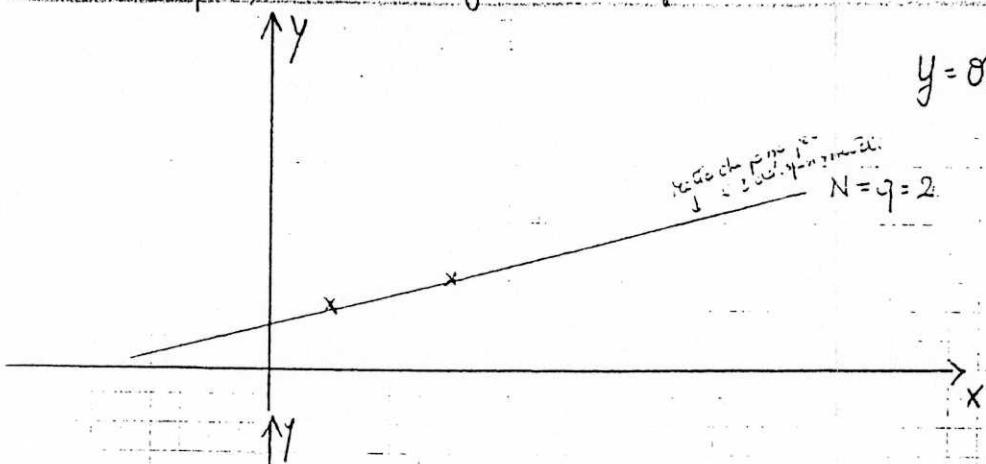
(Boyer)

Fine dei cenni storici.

Dopo un po':

$$q \leq N \quad \begin{array}{l} \text{n. di equazioni} \\ \text{disponibili} \\ \text{n. di incognite} \\ \text{determinata} \end{array}$$

Per $N > q$, sarà in genere impossibile trovare θ tali che $y = \tilde{\Phi}\theta$.



$$y = \theta_1 + \theta_2 x$$

$$\text{y = } \theta_1 + \theta_2 x \quad N=2 \quad q=2$$

$$N=3 > q=2$$

È un modello che spiega perfettamente i dati:

- È un po' di misura
- nello reale le forme non sono perfettamente lineari

retta tale per cui gli errori siano piccoli

Volevo, mi accorgono che l'errore

$$\varepsilon := Y - \Phi \theta$$

è piccolo

Per esempio posso dire che

$$\sum_{i=1}^N \varepsilon_i^2 = \|\varepsilon\|^2 = (Y - \Phi \theta)^T (Y - \Phi \theta)$$

sia piccolo

Teorema: Si supponga che $\text{rank}[\Phi] = q$

(m° di colonne Φ linearmente indipendenti è uguale a q)

Allora,

$$J(\theta) := \|\varepsilon\|^2$$

ha un minimo globale in corrispondenza di

$$\theta^{LS} = (\Phi^T \Phi)^{-1} \Phi^T Y$$

Dim:

PARENTESI: funzioni matriciali

$$x = \begin{bmatrix} x_1 \\ \vdots \\ x_N \end{bmatrix}$$

$$f(x): \mathbb{R}^n \xrightarrow{1 \times 1} \mathbb{R}$$

$$\frac{df}{dx} := \left[\frac{\partial f}{\partial x_1} \quad \frac{\partial f}{\partial x_2} \quad \cdots \quad \frac{\partial f}{\partial x_n} \right]$$

$$f(x) = \begin{bmatrix} f_1(x) \\ f_2(x) \\ \vdots \\ f_m(x) \end{bmatrix} \quad (1 \times m)$$

$$\frac{df}{dx} := \begin{bmatrix} \frac{\partial f_1}{\partial x} \\ \frac{\partial f_2}{\partial x} \\ \vdots \\ \frac{\partial f_m}{\partial x} \end{bmatrix} = \begin{bmatrix} \frac{\partial f_1}{\partial x_1} & \frac{\partial f_1}{\partial x_m} \\ \vdots & \vdots \\ \frac{\partial f_m}{\partial x_1} & \frac{\partial f_m}{\partial x_m} \end{bmatrix}$$

$$\bullet \frac{d}{dx} x = I_m$$

$$\bullet f(x), g(x) \in \mathbb{R}^{m \times 1}$$

$$\frac{d}{dx} \underbrace{(g(x)^T f(x))}_{\text{scalar}} = f(x)^T \frac{d}{dx} g(x) + g(x)^T \frac{d}{dx} f(x)$$

$$\bullet \frac{d}{dx} (f(x)^T f(x)) = 2 f(x)^T \frac{d}{dx} f(x)$$

$$\bullet \frac{d}{dx} (A x) \underset{(m \times n)(n \times 1)}{=} A$$

$$\bullet A = A^T \quad , \quad \frac{d}{dx} (x^T A x) = \underbrace{x^T A + A^T x}_{1 \times 1} = 2x^T A$$

(m x m)

$$\left[\frac{\frac{d^2 f(x)}{dx^2}}{ij} \right] := \left[\frac{\frac{\partial^2 f}{\partial x_i \partial x_j}}{} \right]$$

$f(x): \mathbb{R}^m \rightarrow \mathbb{R}^1$

$$\frac{d^2 f}{dx^2} \in \mathbb{R}^{m \times m}$$

$$\bullet \frac{d^2(x^T A x)}{dx^2} = 2A$$

Sviluppo di Taylor.

$$f(x) = f(x_0) + \left. \frac{df(x)}{dx} \right|_{x=x_0} (x - x_0) + \frac{1}{2} \left. (x - x_0)^T \frac{d^2 f(x)}{dx^2} \right|_{x=x_0} (x - x_0) + \dots$$

Def: D è detto NADE

se $\boxed{D = A^T A}$

Proprietà

$$\boxed{D = D^T \geq 0}$$

Infatti, $x^T D x = x^T A^T A x = \|Ax\|^2 \geq 0 \quad \forall x$.