

# Sistemi Intelligenti Stimatori e sistemi lineari - III

Alberto Borghese

Università degli Studi di Milano  
Laboratory of Applied Intelligent Systems (AIS-Lab)  
Dipartimento di Scienze dell'Informazione  
[borghese@di.unimi.it](mailto:borghese@di.unimi.it)





# Overview

Stima alla massima verosimiglianza di parametri di un modello


Sistemi lineari

Significato geometrico della stima

Relazione tra soluzione di un sistema lineare e stima alla massima verosimiglianza



# Modello



$$y = f(x | w)$$

$x$  – causa  $\Rightarrow$   $y$  – effetto (misurato)

Identification: determine  $\{w\}$  from  $\{x\}; \{y\}$  - *Supervised learning*


Control / Prediction: determine  $\{y\}$  from  $\{x\} \{w\}$

Inverse problem: determine  $\{x\}$  from  $\{y\} \{w\}$

# Esempio di Modello

$$y=f(x; w)$$

$$y = a x^2$$



**Identificazione:** determino i parametri  $w$  che fittano i punti campionati. La funzione  $f(x)$  varie forma con il parametro  $a$  in questo caso.

**Controllo:** Utilizzo il modello (a noto) per predire l'uscita,  $y_i$ , in funzione dell'ingresso  $x_i$ .

Nota: la funzione  $f$  è non lineare in  $x$ , ma il modello è lineare in  $a$ .

In generale, problemi multi input e multi output:  $\mathbf{x}$ ,  $\mathbf{y}$ ,  $\mathbf{w}$  vettori.



# Fitting di una retta



Vogliamo stimare i parametri di una retta:  $y = mx + q$ , con  $m$  e  $q$  incogniti:

$$X = \{m, q\}$$

Abbiamo a disposizione  $N$  misure effettuate:


$$Y = \{y_i ; x_i\}$$

Sappiamo che le  $y_i$  siano affette da rumore Gaussiano a media nulla. In pratica:

$$y_i = y_i + v_i \text{ dove } v_i \text{ è l'errore di misura.}$$

Possiamo anche scrivere che:

$y_i = y_{\text{true}} + G(\mu, \sigma^2)$  indica una distribuzione monodimensionale gaussiana a media  $\mu$  e varianza  $\sigma^2$ . Errore di misura:  $G(0, \sigma^2)$





# Estensione della stima a massima verosimiglianza



$y = f(x | w)$     misuro  $\{y_i\}$  in corrispondenza di  $\{x_i\}$

Avrò che:  $f(x_i | w) = y_{\text{true}} + v_i = y_i$

$$L(y | x, w) = \prod_i p(v_i) = \prod_i p(y_i - f(x_i; w)) = \prod_i \left( \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\left(\frac{1}{2}\left(\frac{y_i - f(x_i|w)}{\sigma}\right)^2\right)} \right)$$

$\sigma$  is equal for all samples  
 $(x_i; y_i)$  are the different samples



# Stima ai minimi quadrati e verosimiglianza per modello lineare



- Impostiamo il problema scrivendo la funzione di verosimiglianza e massimizzando tale funzione rispetto a  $m$  e  $q$ ...
- Scriviamo prima di tutto la densità di probabilità di ottenere  $y_i$  per ciascun dato:

$$p(x_i, y_i | m, q) = \frac{1}{\sqrt{2\pi\sigma}} \cdot \exp\left[-\frac{1}{2} \left(\frac{y_i - (mx_i + q)}{\sigma}\right)^2\right]$$

Dove  $m$  e  $q$  non sono note.



# Stima ai minimi quadrati e verosimiglianza



Sapendo che le misure sono indipendenti, possiamo scrivere la probabilità di ottenere le  $N$  misure  $\{y_i\}$ : funzione di verosimiglianza.

Scriviamo il logaritmo negativo della verosimiglianza:

$$\begin{aligned} f(y_1, y_2, \dots, y_N; m, b; x_1, x_2, \dots, x_N) &= -\sum_{i=1}^N \ln \left\{ \frac{1}{\sqrt{2\pi\sigma}} \cdot \exp \left[ -\frac{1}{2} \left( \frac{y_i - mx_i - b}{\sigma} \right)^2 \right] \right\} = \\ &= -\sum_{i=1}^N \ln \left( \frac{1}{\sqrt{2\pi\sigma}} \right) - \sum_{i=1}^N \left[ -\frac{1}{2} \left( \frac{y_i - mx_i - b}{\sigma} \right)^2 \right] = \\ &= -\sum_{i=1}^N \ln \left( \frac{1}{\sqrt{2\pi\sigma}} \right) + \frac{1}{2\sigma^2} \sum_{i=1}^N (y_i - mx_i - b)^2 \end{aligned}$$



# Stima ai minimi quadrati e verosimiglianza



- E massimizziamo  $L(\cdot)$  ponendo a zero le derivate prime rispetto a  $m$ :

$$\begin{aligned}\frac{\partial f(y_1, y_2, \dots, y_N; m, b; x_1, x_2, \dots, x_N)}{\partial m} &= \frac{\partial}{\partial m} \left[ -\sum_{i=1}^N \ln \left( \frac{1}{\sqrt{2\pi\sigma}} \right) + \frac{1}{2\sigma^2} \sum_{i=1}^N (y_i - m \cdot x_i - q)^2 \right] = \\ &= 0 + \frac{1}{2\sigma^2} \sum_{i=1}^N (y_i - m \cdot x_i - q) \cdot 2 \cdot (-x_i) = \\ &= \frac{1}{\sigma^2} \sum_{i=1}^N (y_i - m \cdot x_i - q) \cdot x_i = 0 \Rightarrow \sum_{i=1}^N (y_i - m \cdot x_i - q) \cdot x_i = 0 \Rightarrow \\ &\left[ \sum_{i=1}^N (y_i \cdot x_i) \right] - m \cdot \left[ \sum_{i=1}^N (x_i^2) \right] - q \cdot \left[ \sum_{i=1}^N (x_i) \right] = 0 \Rightarrow \\ &m \cdot \left[ \sum_{i=1}^N (x_i^2) \right] + q \cdot \left[ \sum_{i=1}^N (x_i) \right] = \left[ \sum_{i=1}^N (y_i \cdot x_i) \right] \quad 1^a \text{ equazione}\end{aligned}$$



# Stima ai minimi quadrati e verosimiglianza



... e a q:

$$\begin{aligned} &= 0 + \frac{1}{2\sigma^2} \sum_{i=1}^N (y_i - m \cdot x_i - q) \cdot 2 \cdot (-1) = \\ &= \frac{1}{\sigma^2} \sum_{i=1}^N (y_i - m \cdot x_i - q) = 0 \Rightarrow \sum_{i=1}^N (y_i - m \cdot x_i - q) = 0 \Rightarrow \\ &\left[ \sum_{i=1}^N (y_i) \right] - m \cdot \left[ \sum_{i=1}^N (x_i) \right] - q \cdot \left[ \sum_{i=1}^N (1) \right] = 0 \Rightarrow \\ &m \cdot \left[ \sum_{i=1}^N (x_i) \right] + q \cdot \left[ \sum_{i=1}^N (1) \right] = \left[ \sum_{i=1}^N (y_i) \right] \end{aligned}$$

2<sup>a</sup> equazione



# Stima massima verosimiglianza

$$\left[ \sum_{i=1}^N (x_i^2) \right] \cdot m + \left[ \sum_{i=1}^N (x_i) \right] \cdot q = \left[ \sum_{i=1}^N (y_i \cdot x_i) \right] \quad 1^\circ \text{ equazione}$$

$$\left[ \sum_{i=1}^N (x_i) \right] \cdot m + \left[ \sum_{i=1}^N (1) \right] \cdot q = \left[ \sum_{i=1}^N (y_i) \right] \quad 2^\circ \text{ equazione}$$

Le incognite,  $m$  e  $b$ , compaiono con esponente 1  $\Rightarrow$  equazioni lineari in  $m$  e  $q$   
Potrei risolvere per sostituzione



# Stima ai minimi quadrati e verosimiglianza




Per ogni punto, dovrebbe valere

$$y_i = mx_i + q.$$

Ma c'è l'errore di misura,

misuriamo in realtà  $y_i + v_i$ .

Cerchiamo i parametri  $m$  e  $q$   
che sono più verosimili.



Cosa vuol dire che sono più verosimili?  
Quanto sono più verosimili?



# Esempio

$$y = 2x + 1 \quad m = 2; q = 1$$

Misuro e ottengo:

- $x_1 = 1; y_1 = 2,8$
- $x_2 = 0; y_2 = 1,2$


Quanto varranno le stime di  $m$  e  $q$ ?

$$\left[ \sum_{i=1}^N (x_i^2) \right] \cdot m + \left[ \sum_{i=1}^N (x_i) \right] \cdot q = \left[ \sum_{i=1}^N (y_i \cdot x_i) \right]$$

$$\Rightarrow (1*1 + 0*0)m + (1 + 0)q = (1 * 2,8 + 0 * 1,2)$$

$$\left[ \sum_{i=1}^N (x_i) \right] \cdot m + \left[ \sum_{i=1}^N (1) \right] \cdot q = \left[ \sum_{i=1}^N (y_i) \right]$$

$$\Rightarrow (1 + 0) m_e + 2 q_e = (2,8 + 1,2)$$



$$m_e + q_e = 2,8 \quad m_e + 2q_e = 4 \quad \Rightarrow \text{per sottrazione} \quad q_e = 1,2; m_e = 1,6 \quad \text{NB } 2,8 = 1,6*1 + 1,2$$



# Overview



Stima alla massima verosimiglianza di parametri di un modello

## Sistemi lineari

Significato geometrico della stima

Relazione tra soluzione di un sistema lineare e stima alla massima verosimiglianza



# Sistema lineare



$$a_{11}x_1 + a_{12}x_2 + \dots + a_{1N}x_N = b_1$$

$$a_{21}x_1 + a_{22}x_2 + \dots + a_{2N}x_N = b_2$$

.....

$$a_{M1}x_1 + a_{M2}x_2 + \dots + a_{MN}x_N = b_M$$

{ $a_{ij}$ } – coefficienti in numero  $N \times M$

{ $x_j$ } – incognite,  $N$

{ $b_j$ } – termini noti,  $M$

I sistemi lineari sono interessanti perchè sono manipolabili con operazioni semplici (algebra delle matrici)

NB le  $x$  qui sono i parametri  $w$  del modello.

## Esempio:

$$3x_1 + 2x_2 + \dots + 4x_N = 5$$

$$4x_1 - 2x_2 + \dots + 0.5x_N = 3$$

.....

$$2x_1 + 3x_2 + \dots - 3x_N = -1$$

# Matrici

$$A = [a_{i,j}]$$

$$A^T = [a_{j,i}]$$

$$\alpha A = [\alpha a_{i,j}]$$

$$C = A + B = [a_{i,j} + b_{i,j}]$$

$$C = AB = [c_{i,j}] \text{ dove } [c_{i,j}] = \sum_{k=1}^n a_{i,k} b_{k,j}$$

Prodotto degli elementi di una riga per gli elementi di una colonna.

Se  $A (n \times m) \rightarrow B (m \times p) \rightarrow C (n \times p)$

$$A = \begin{bmatrix} 2 & 3 & 1 \\ 1 & -4 & 0 \end{bmatrix} \quad B = \begin{bmatrix} 1 & -1 \\ 1 & 3 \\ 2 & 0 \end{bmatrix} \quad \Rightarrow \quad C = \begin{bmatrix} 7 & 7 \\ -3 & -13 \end{bmatrix}$$

Se il numero di righe = numero di colonne, matrice quadrata



# Matrici (Proprietà)

La somma è associativa e commutativa  $(A + B) + C = A + (B + C)$ .

Il prodotto è associativo rispetto alla somma ma non gode della proprietà commutativa:

$$(A+B)C = AC + BC.$$

$$\mathbf{AB} \neq \mathbf{BA}$$

$$\mathbf{I} = [a_{i,j}] = \begin{cases} 1 & \text{per } i = j \\ 0 & \text{altrimenti} \end{cases} \quad \text{matrice identità}$$

$$\mathbf{AI} = \mathbf{A} = \mathbf{IA}$$

vettore come matrice colonna :  $\bar{\mathbf{u}}^T = \begin{bmatrix} u_x \\ u_y \\ u_z \end{bmatrix}$

prodotto vettore matrice :  $\bar{\mathbf{v}} = \bar{\mathbf{u}}^T \mathbf{M}$



# Matrice inversa

$$A^{-1}A = I$$

La matrice inversa è definita per una matrice quadrata

Esiste ed è unica se  $\det(A) \neq 0$

**Numero di condizionamento di una matrice (quadrata):**  
rapporto tra il valore singolare maggiore e minore (cf.  
Funzione cond in Matlab).

E' una misura di sensibilità della soluzione di un sistema  
lineare a variazioni nei dati.



# Rango di una matrice

Data una matrice  $A$  di ordine  $n$  ( $n \times n$ ),

una matrice  $A$   $n \times n$  ha rango  $m < n$  se e solo se  
esiste un suo minore di ordine  $m$  non nullo  
mentre sono nulli tutti i minori di ordine  $m + 1$ .

Una matrice  $A$   $n \times n$  ha rango  $n$  (rango pieno) se e solo se  
il suo determinante è diverso da 0

**Rango** di una matrice  $M \times N$  è la dimensione massima di tutte le matrici quadrate estraibili da  $A$  e con determinante non nullo. Il rango è massimo quando non è inferiore alla dimensione minima della matrice.



# Altre proprietà delle matrici

$$\det(AB) = \det(A) \det(B)$$

$$\det(\text{diag}(W)) = \prod_k w_{k,k}$$

$$(A^T)^{-1} = (A^{-1})^T$$

$$(A B C)^T = C^T B^T A^T$$

Una matrice  $U$ , si dice ortogonale se  $U^T U = \text{diag}(W)$ .

Una matrice  $U$ , si dice ortonormale se  $U^T U = I \rightarrow U^{-1} = U^T$

## Condizione di ortonormalità:

Il determinante è  $= 1$ .

La somma dei prodotti di due righe o di due colonne è  $= 0$ .

La somma dei quadrati degli elementi su righe e colonne  $= 1$


Esempio notevole: **matrice di rotazione (cambio di sistema di riferimento)**.



# Esempio

$$y = x + 2$$

$$y = -3x + 1$$



$$1 x_1 - 1 x_2 = -2$$

$$-3 x_1 - 1 x_2 = -1$$

$$y = x_2$$

$$x = x_1$$

Risolvero per sostituzione:  $x_1 = -2 + x_2$ .

$$-3(-2 + x_2) - x_2 = -1 \quad \rightarrow \quad x_2 = 7/4$$

$$x_1 - 1/4 = 2 \quad \rightarrow \quad x_1 = -1/4$$



# Sistema lineare



$$a_{11}x_1 + a_{12}x_2 + \dots + a_{1N}x_N = b_1$$

$$a_{21}x_1 + a_{22}x_2 + \dots + a_{2N}x_N = b_2$$

.....


$$a_{M1}x_1 + a_{M2}x_2 + \dots + a_{MN}x_N = b_M$$

**Esempio:**

$$3x_1 + 2x_2 + \dots + 4x_N = 5$$

$$4x_1 - 2x_2 + \dots + 0.5x_N = 3$$

.....

$$2x_1 + 3x_2 + \dots - 3x_N = -1$$




# Sistema quadrato (N x N)



$$a_{11}x_1 + a_{12}x_2 + \dots a_{1N}x_N = b_1$$

$$a_{21}x_1 + a_{22}x_2 + \dots a_{2N}x_N = b_2$$

.....

$$a_{N1}x_1 + a_{N2}x_2 + \dots a_{NN}x_N = b_N$$

Ammette 1, nessuna o  $\infty$  soluzioni

A è N x N quadrata

$$\mathbf{A} \mathbf{x} = \mathbf{b}$$

$$\mathbf{A}^{-1}\mathbf{A}\mathbf{x} = \mathbf{A}^{-1}\mathbf{b}$$

$\mathbf{x} = \mathbf{A}^{-1} \mathbf{b}$  se  $\mathbf{A}^{-1}$  esiste, 1 soluzione.

altrimenti, nessuna (rette parallele)

o

$\infty$  soluzioni (rette coincidenti).

## Esempio:

$$3x_1 + 2x_2 + \dots 4x_N = 5$$

$$4x_1 - 2x_2 + \dots 0.5x_N = 3$$

.....

$$2x_1 + 3x_2 + \dots -3x_N = -1$$



# Soluzione dei sistemi lineari

Scrivo il sistema lineare:  $Ax = b$

$$y = x + 2$$

$$y = -3x + 1$$

$$A = \begin{bmatrix} 1 & -1 \\ -3 & -1 \end{bmatrix} \quad b = \begin{bmatrix} -2 \\ -1 \end{bmatrix}$$

$$1 x_1 - 1 x_2 = -2$$

$$-3 x_1 - 1 x_2 = -1$$

$X$  è una soluzione se soddisfa **tutte** le equazioni del sistema stesso.

Soluzioni:

!  $\exists$  Soluzione (sistema impossibile)

$\exists$  Soluzione (sistema possibile)

1 soluzione (sistema determinato)

> 1 soluzione ( $\infty^k$  soluzioni – sistema indeterminato).



# Soluzione di sistemi lineari quadrati

$$x = A^{-1} b$$

Condizione di esistenza dell'inversa è  $\det(A) \neq 0$

Il sistema ammette 1 ed 1 sola soluzione se  $\det(A) \neq 0$


Altrimenti: nessuna o infinite soluzioni



# Esempio

$$y = x + 2$$

$$y = -3x + 1$$



$$1 x_1 - 1 x_2 = -2$$

$$-3 x_1 - 1 x_2 = -1$$

$$x_1 = x$$

$$x_2 = y$$

$$A = \begin{bmatrix} 1 & -1 \\ -3 & -1 \end{bmatrix} \quad b = \begin{bmatrix} -2 \\ -1 \end{bmatrix}$$

$$\det(A) = 1(-1) - (-1)(-3) = -1 - 3 = -4$$

**Rango di A è pieno**

$$x_1 = -1/4$$

$$x_2 = 7/4$$

$$P = A^{-1} b$$

$$P = [-1/4 \quad 7/4]$$



# Risoluzione di un sistema 2x2

$$a_{11}x_1 + a_{12}x_2 = b_1$$

$$a_{21}x_1 + a_{22}x_2 = b_2$$

$$\mathbf{y} = \mathbf{A}\mathbf{x}$$

$$\mathbf{x} = \mathbf{A}^{-1}\mathbf{y}$$

$$\mathbf{A}^{-1} = \frac{1}{\det(\mathbf{A})} \begin{bmatrix} a_{22} & -a_{12} \\ -a_{21} & a_{11} \end{bmatrix}$$

$$\det(\mathbf{A}) = a_{11} * a_{22} - a_{12} * a_{21}$$




# Esempio di soluzione non univoca

$$y = x + 2$$

$$2y = 2x + 3$$

$$A = \begin{bmatrix} 1 & -1 \\ 2 & -2 \end{bmatrix} \quad b = \begin{bmatrix} -2 \\ -3 \end{bmatrix}$$

Non esistono soluzioni



$$1 x_1 - 1 x_2 = -2$$

$$2 x_1 - 2 x_2 = -3$$

$$x_1 = x$$

$$x_2 = y$$

$\det(A) = 1(-2) - (-1)(2) = -2 + 2 = 0$       La soluzione non esiste o  $\infty$  soluzioni.

$$y = x + 2$$

$$2y = 2x + 4$$

La soluzione, se esiste non è unica: tutti i punti della retta soddisfano contemporaneamente le 2 equazioni. In questo caso  $\infty$  soluzioni: rette sovrapposte.



# Sistema $M \times N, M > N$



$$a_{11}x_1 + a_{12}x_2 + \dots + a_{1N}x_N = b_1$$

$$a_{21}x_1 + a_{22}x_2 + \dots + a_{2N}x_N = b_2$$

.....

$$a_{M1}x_1 + a_{M2}x_2 + \dots + a_{MN}x_N = b_M$$

Ammette 1, nessuna o  $\infty$  soluzioni

$$\mathbf{A} \mathbf{x} = \mathbf{b}$$

A è  $M \times N, M > N$ , non è una matrice quadrata.

1, nessuna,  $\infty$  soluzioni.

## Esempio:

$$3x_1 + 2x_2 + \dots + 4x_N = 5$$

$$4x_1 - 2x_2 + \dots + 0.5x_N = 3$$

.....

$$2x_1 + 3x_2 + \dots - 3x_N = -1$$

Ho delle equazioni di troppo, devono essere correlate (combinare linearmente), perché il sistema ammetta soluzione.

Posso sempre calcolare la soluzione in forma matriciale.



# Sistemi lineari con $m > n$

$J(W,L)$  è rettangolare: numero di righe maggiore del numero di colonne


$$y = x + 2$$

$$y = -3x + 1$$

$$y = -x + 3/2$$

Una delle 3 righe di  $A$  è  
combinazione lineare  
delle altre.

$$A = \begin{bmatrix} 1 & -1 \\ -3 & -1 \\ -1 & -1 \end{bmatrix} \quad b = \begin{bmatrix} -2 \\ -1 \\ -1.5 \end{bmatrix}$$



Esiste un'equazione "di troppo"

**Nessuna, 1 o  $\infty$  soluzioni**

**Rango di  $A$  è pieno**



# Rango di una matrice

$\det (A^{\S ij})$


Minore complementare

Data una matrice  $A$  di ordine  $n$  ( $n \times n$ ),

una matrice  $A$   $n \times n$  ha rango  $m < n$  se e solo se  
esiste un suo minore di ordine  $m$  non nullo  
mentre sono nulli tutti i minori di ordine  $m + 1$ .

Una matrice  $A$   $n \times n$  ha rango  $n$  (rango pieno) se e solo se  
il suo determinante è diverso da 0

# Relazione tra le equazioni (combinazione lineare)



$$\alpha_1 (y - x - 2) +$$
$$\alpha_2 (y + 3x - 1) =$$
$$(y + x - 3/2)$$

In questo caso:

$$\alpha_1 = -1/2$$

$$\alpha_2 = -1/2$$

Tutte le rette per la soluzione P possono essere descritte come un fascio (di rette).

Un fascio di rette è univocamente identificato da due rette (che si incontrino in un punto).

La terza equazione è combinazione lineare delle prime due.



# Sistema lineare: soluzione algebrica

Caso generale:

$$\mathbf{A} \mathbf{x} = \mathbf{b} \quad \Longrightarrow \quad \mathbf{A}' \mathbf{A} \mathbf{x} = \mathbf{A}' \mathbf{b} \quad \Longrightarrow \quad (\mathbf{A}' \mathbf{A})^{-1} \mathbf{A}' \mathbf{A} \mathbf{x} = (\mathbf{A}' \mathbf{A})^{-1} \mathbf{A}' \mathbf{b}$$



$(\mathbf{A}' \mathbf{A})$  gioca il ruolo di  $\mathbf{A}$  quadrata.

$$\mathbf{x} = (\mathbf{A}' \mathbf{A})^{-1} \mathbf{A}' \mathbf{b}$$

Quale criterio viene soddisfatto da  $\mathbf{x}$ ?

$\mathbf{C} = (\mathbf{A}^T * \mathbf{A})^{-1}$  è la matrice di **covarianza** (matrice quadrata  $n \times n$ )



# Sistemi lineari con $m > n$

$$y = x - 2$$

$$y = -3x + 1$$


$$y = -x + 3/2$$

$$A = \begin{bmatrix} 1 & -1 \\ -3 & -1 \\ -1 & -1 \end{bmatrix} \quad b = \begin{bmatrix} -2 \\ -1 \\ +1.5 \end{bmatrix}$$

$$A^T * A = \begin{bmatrix} 11 & 3 \\ 3 & 3 \end{bmatrix} \quad \det = 24$$

$$C = (A^T A)^{-1} = \begin{bmatrix} 0.1250 & -0.1250 \\ -0.1250 & 0.4583 \end{bmatrix}$$

$Ax = b$  A di dimensioni  $m \times n$



$$P = [-1/4 \quad 7/4]$$

$$P = C * A^T * b$$

$$P = [-0.25 \quad +1.75]$$

**intersezione**



# Riformulazione del problema con rumore



$$a_{11}x_1 + a_{12}x_2 + \dots + a_{1N}x_N = b_1 + v_1$$

$$a_{21}x_1 + a_{22}x_2 + \dots + a_{2N}x_N = b_2 + v_2$$

.....

$$a_{M1}x_1 + a_{M2}x_2 + \dots + a_{MN}x_N = b_M + v_M$$

Errore di modello (sistematico, randomico).  $M \times 1 \Rightarrow$  **Residuo**.

$$A x = b + N$$

$M \times 1$

Vettore dei termini noti

Modello

Misure

$M \times N$

$N \times 1$

(Matrice di disegno)

Vettore delle incognite

Quale criterio viene soddisfatto da  $x$ ?



# Soluzione come problema di ottimizzazione



$$\text{Funzione costo: } (Ax - b)^2 = \sum_k v_k^2 = \|Ax - b\|^2$$

Assegno un costo al fatto che la soluzione  $x$ , non soddisfi tutte le equazioni, la somma dei residui associati ad ogni equazioni viene minimizzata. Geometricamente: viene trovato il punto a distanza (verticale) minima da tutte le rette.

$$\min_x \sum_k v_k^2 = \min_x (Ax - b)^2$$

$$\frac{d}{dx} (Ax - b)^2 = 2A^T (Ax - b) = 0$$

$$A^T A x = A^T b$$

$$x = (A^T A)^{-1} A^T b$$

NB le funzioni costo sono spesso quadratiche (problemi di minimizzazione convessi) perchè il costo cresce sia che il modello sovrastimi che sottostimi le misure. Inoltre, le derivate calcolate per imporre le condizioni di stazionarietà (minimo), sono relativamente semplici.



# Sistemi lineari con $m > n$

$$y = x - 2$$

$$y = -3x + 1$$

$$y = -x + 3/2$$

$$A = \begin{bmatrix} 1 & -1 \\ -3 & -1 \\ -1 & -1 \end{bmatrix} \quad b = \begin{bmatrix} -2 \\ -1 \\ -1.5 \end{bmatrix}$$

$$A^T * A = \begin{bmatrix} 11 & 3 \\ 3 & 3 \end{bmatrix} \quad \det = 24$$


$$C = (A^T A)^{-1} = \begin{bmatrix} 0.1250 & -0.1250 \\ -0.1250 & 0.4583 \end{bmatrix}$$

$$P = C * A^T * b$$

$$P = [-0.25 \quad +1.75]$$

**intersezione**

$$\|Ax - b\| = 0$$





# Sistemi lineari con $m > n$ - non esiste soluzione (matematica)



$$y = x + 2$$

$$y = -3x + 1$$

$$y = -x + \frac{1}{2}$$


$$A = \begin{bmatrix} 1 & -1 \\ -3 & -1 \\ -1 & -1 \end{bmatrix} \quad b = \begin{bmatrix} -2 \\ -1 \\ -0.5 \end{bmatrix}$$

$$A^T * A = \begin{bmatrix} 11 & 3 \\ 3 & 3 \end{bmatrix} \quad \det = 24$$

$$C = (A^T A)^{-1} = \begin{bmatrix} 0.1250 & -0.1250 \\ -0.1250 & 0.4583 \end{bmatrix}$$

$AX = b$

A di dimensioni  $m \times n$



$$\sum_k v_k^2 = \|Ax - b\|^2 = 0.333333$$

$$P = C * A^T * b \quad P' = [-0.5 \quad +1.4167]$$

**No intersezione**



# Commenti

$$\sum_k v_k^2 = \|Ax - b\|^2 = \sum_k \|A_{k,*}x - b_k\|^2 =$$
$$\left[ (A_{11}x_1 + A_{12}x_2) - b_1 \right]^2 + \left[ (A_{21}x_1 + A_{22}x_2) - b_2 \right]^2 +$$
$$\left[ (A_{31}x_1 + A_{32}x_2) - b_3 \right]^2$$

Lo scarto misura la distanza (verticale) dalla retta



# Overview



Stima alla massima verosimiglianza di parametri di un modello

Sistemi lineari

Significato geometrico della stima

Relazione tra soluzione di un sistema lineare e stima alla massima verosimiglianza



# Fitting di una retta

Vogliamo stimare i parametri di una retta:  $y = mz + q$ , con  $m$  e  $q$  incogniti:

$$X = \{m, q\}$$

Abbiamo a disposizione  $N$  misure effettuate:


$$Y = \{y_i ; x_i\}$$

Sappiamo che le  $y_i$  sono affette da rumore Gaussiano a media nulla. In pratica:

$$y_i = y_i + v_i \text{ dove } v_i \text{ è il rumore di misura.}$$

Possiamo anche scrivere che:

$y_i = G(mx_i + b, \sigma^2)$ , dove  $G(\mu, \sigma^2)$  indica una distribuzione monodimensionale gaussiana a media  $\mu$  e varianza  $\sigma^2$ .





# Stima alla massima verosimiglianza

- Impostiamo il problema scrivendo la funzione di verosimiglianza e massimizzando tale funzione rispetto a  $m$  e  $q$ ...
- Scriviamo prima di tutto la densità di probabilità di ottenere  $y_i$  per ciascun dato:

$$p(y_i | m, q; x_i) = \frac{1}{\sqrt{2\pi\sigma}} \cdot \exp\left[-\frac{1}{2} \left(\frac{y_i - mx_i - q}{\sigma}\right)^2\right]$$



# Stima alla massima verosimiglianza

Scriviamo il logaritmo negativo della verosimiglianza:

$$\begin{aligned} f(y_1, y_2, \dots, y_N; m, b; x_1, x_2, \dots, x_N) &= -\sum_{i=1}^N \ln \left\{ \frac{1}{\sqrt{2\pi\sigma}} \cdot \exp \left[ -\frac{1}{2} \left( \frac{y_i - mx_i - q}{\sigma} \right)^2 \right] \right\} = \\ &= -\sum_{i=1}^N \ln \left( \frac{1}{\sqrt{2\pi\sigma}} \right) - \sum_{i=1}^N \left[ -\frac{1}{2} \left( \frac{y_i - mx_i - q}{\sigma} \right)^2 \right] = \\ &= -\sum_{i=1}^N \ln \left( \frac{1}{\sqrt{2\pi\sigma}} \right) + \frac{1}{2\sigma^2} \sum_{i=1}^N (y_i - mx_i - q)^2 \end{aligned}$$

Minimizzo  $f(\cdot)$  rispetto a  $\{m, q\}$



# Stima massima verosimiglianza

$$\left[ \sum_{i=1}^N (x_i^2) \right] \cdot m + \left[ \sum_{i=1}^N (x_i) \right] \cdot b = \left[ \sum_{i=1}^N (y_i \cdot x_i) \right] \quad 1^\circ \text{ equazione}$$

$$\left[ \sum_{i=1}^N (x_i) \right] \cdot m + \left[ \sum_{i=1}^N (1) \right] \cdot b = \left[ \sum_{i=1}^N (y_i) \right] \quad 2^\circ \text{ equazione}$$

Le incognite,  $m$  e  $b$ , compaiono con esponente 1  $\Rightarrow$  equazioni lineari in  $m$  e  $b$ :  $X = \{m, b\}$ .

Posso risolvere come:

$$\mathbf{A}^T \mathbf{A} \mathbf{x} = \mathbf{A}^T \mathbf{b}$$
$$\mathbf{x} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{b}$$



# Stima alla massima verosimiglianza: caso 2D



- Ottengo un sistema di 2 equazioni in 2 incognite

$$\begin{bmatrix} \sum_{i=1}^N (x_i^2) & \sum_{i=1}^N (x_i) \\ \sum_{i=1}^N (x_i) & \sum_{i=1}^N (1) \end{bmatrix} \begin{bmatrix} m \\ b \end{bmatrix} = \begin{bmatrix} \sum_{i=1}^N (y_i \cdot x_i) \\ \sum_{i=1}^N (y_i) \end{bmatrix}$$

$A \quad X = \quad b \rightarrow$

$$X = (A'A)^{-1}A'B = CA'B \quad - \quad C \text{ è matrice di covarianza.}$$

NB Le  $y_i$  sono solo ai termini noti



# Stima ai minimi quadrati caso 2D



- Scriviamo l'equazione della retta per tutti i punti in forma matriciale (sistema lineare  $Ax=b$ ,  $N$  equazioni, 2 incognite):

$$\begin{bmatrix} x1 & 1 \\ x2 & 1 \\ \dots & \dots \\ xN & 1 \end{bmatrix} \begin{bmatrix} m \\ b \end{bmatrix} = \begin{bmatrix} y1 \\ y2 \\ \dots \\ yN \end{bmatrix}$$

- Vogliamo trovare  $x$  t.c.  $(Ax-b)^T(Ax-b)$  è minima (minimizzazione dei quadrati dei residui).

$$\mathbf{X} = (\mathbf{A}'\mathbf{A})^{-1}\mathbf{A}'\mathbf{B} = \mathbf{C}\mathbf{A}'\mathbf{B} \quad - \quad \mathbf{C} \text{ è matrice di covarianza.}$$



# Esempio - Caso 2D (2 parametri)

$N = 20$  punti


$\sigma_0^2 = 0.01$

$m$  reale = 1

$q$  reale = 2

$m$  stimato = 0.9931

$q$  stimato = 2.0106



Cosa vuol dire che  $\{m, q\}$  sono i più verosimili?  
Quanto sono più verosimili?



# Stima a massima verosimiglianza e minimi quadrati



$$\mathbf{A}^T \mathbf{A} \mathbf{x} = \mathbf{A}^T \mathbf{b}$$

$$\mathbf{x} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{b}$$

La soluzione a massima verosimiglianza, quando il rumore è Gaussiano a media nulla, coincide con la soluzione ai minimi quadrati del sistema lineare associato (la soluzione ai minimi quadrati è un caso particolare della stima alla massima verosimiglianza).

La soluzione è quella che minimizza lo scarto quadratico medio dei residui, ovvero sia è a minima varianza.

La stima a massima verosimiglianza è un approccio generale, e si presta a  $p(x)$  di qualsiasi forma. La Gaussiana consente di ottenere una formulazione lineare del problema.



# Stima ai minimi quadrati e verosimiglianza



- Nella soluzione ai minimi quadrati del sistema lineare  $Ax=b$  si definisce un vettore errore  $v = Ax - b$ ;
- Nel caso di soluzione “perfetta”  $v = 0$ ;
- Dal momento che abbiamo un numero di equazioni maggiore rispetto al numero di incognite, cerchiamo il vettore  $e$  a norma minima;
- In pratica cerchiamo  $x$  t.c.  $v^T v = \sum_i v_i^2$  è minimo.



# Giustificazione statistica

- **C'è un solo insieme vero dei parametri**, mentre ci possono essere **infiniti universi di dati per effetto dell'errore di misura.**
- La domanda quindi più corretta sarebbe: "Dato un certo insieme di parametri, qual'è la probabilità che questo insieme di dati sia estratto?" (più correttamente si parla di densità di probabilità?)
- Cioè, per ogni insieme di parametri, calcoliamo la probabilità che i dati siano estratti. Ovverosia la **likelihood (verosimiglianza) dei dati, dato un certo insieme di parametri.**

La stima ai minimi quadrati dei parametri è equivalente a determinare i parametri che massimizzano la funzione di **verosimiglianza** sotto l'ipotesi di errore **Gaussiano a media nulla.**



# Overview

Stima alla massima verosimiglianza di parametri di un modello

Sistemi lineari

Significato geometrico della stima

Relazione tra soluzione di un sistema lineare e stima alla massima verosimiglianza