

# Sistemi Intelligenti I sistemi lineari

Alberto Borghese

Università degli Studi di Milano  
Laboratorio di Sistemi Intelligenti Applicati (AIS-Lab)  
Dipartimento di Scienze dell'Informazione  
[borghese@dsi.unimi.it](mailto:borghese@dsi.unimi.it)



A.A. 2005-2006

1/38

<http://homes.dsi.unimi.it/~borghese/>



## Sommario



Sistemi lineari e matrici

Soluzione dei sistemi lineari

Analisi dell'affidabilità della stima

Linearizzazione di sistemi di funzioni

Determinazione dei parametri di un modello non-lineare

A.A. 2005-2006

2/38

<http://homes.dsi.unimi.it/~borghese/>



## 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,  $M$

{ $b_j$ } – termini noti,  $N$

### Esempio:

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

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

.....

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



## Esempio



Barca a vela con motore + vento

$$3x_1 + 5x_2 = 100$$

Il vento produce un effetto di 3 volte la sua velocità.

Il motore produce un effetto di 5 volte la sua velocità di rotazione.

Se  $x_2 = 10$ ,  $x_1 = 25$ , sono collegati. Quanto valgono in quella particolare configurazione?

$$2x_1 + 2x_2 = 50$$

Manteniamo il numero di giri del motore ed il vento, ma il mare ingrossa ed il rendimento dei due motori cambia.

$$\text{Ottengo } x_2 \cong 16.6 \quad x_1 \cong 8.3$$



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

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

A.A. 2005-2006

5/38

<http://homes.dsi.unimi.it/~borghese/>



## Matrici (Proprietà)



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

Il prodotto è associativo rispetto alla somma ma non commutativo  $(A+B)C = AC + BC$ .

**$AB \neq BA$**

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

$$AI = A = IA$$

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

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

A.A. 2005-2006

6/38

<http://homes.dsi.unimi.it/~borghese/>



## Determinante



$$\mathbf{A} = [a_{ij}] \quad \det(\mathbf{A}) = \sum_j (-1)^{(i+j)} a_{ij} A_{ij}^* = \sum_i (-1)^{(i+j)} a_{ij} A_{ij}^*$$

$A^*$  minore complementare di  $A$

$$\mathbf{A} = \begin{bmatrix} 1 & 3 & -2 \\ 2 & 0 & 1 \\ 1 & 1 & 2 \end{bmatrix} \quad \leftarrow \text{Elementi sulla riga}$$

$$\det(\mathbf{A}) = (-1)^{(2+1)} (2) [(3 * 2) - (-2 * 1)] + (-1)^{(2+2)} (0) [(1 * 2) - (-2 * 1)] + (-1)^{(2+3)} (1) [(1 * 1) - (3 * 1)] = -16 + 2 = -14$$

A.A. 2005-2006

7/38

<http://homes.dsi.unimi.it/~borghese/>



## Matrice Inversa



$$\mathbf{A} = [a_{ij}]$$

$$\mathbf{A}^{-1} = 1/\det(\mathbf{A}) \begin{bmatrix} A_{11} & A_{21} & A_{n1} \\ A_{12} & A_{22} & A_{32} \\ A_{13} & A_{23} & A_{33} \end{bmatrix}$$

$$\mathbf{A} = \begin{bmatrix} 1 & 3 & -2 \\ 2 & 0 & 1 \\ 1 & 1 & 2 \end{bmatrix} \quad \mathbf{A}^{-1} = \begin{bmatrix} 02-11 & -[32-(-2)1] & 31-(-2)0 \\ -[22-11] & 12-(-2)1 & -[11-(-2)2] \\ 21-01 & -[11-31] & 10-32 \end{bmatrix} = (-1/14) \begin{bmatrix} -1 & -8 & 3 \\ -3 & 0 & -5 \\ 2 & 2 & -6 \end{bmatrix}$$

$$\det \mathbf{A} = -14 \quad \mathbf{A} \mathbf{A}^{-1} = -1/14 \begin{bmatrix} 1(-1)+3(-3)-22 & 1(-8)+34-2(2) & 13+3(-5)-2(-6) \\ 2(-1)+0(-3)+1(2) & 2(-8)+04+12 & 23+0(-5)+1(-6) \\ 1(-1)+1(-3)+22 & 1(-8)+14+22 & 13+1(-5)+2(-6) \end{bmatrix} = \mathbf{I}$$

A.A. 2005-2006

8/38

<http://homes.dsi.unimi.it/~borghese/>



# Matrici ortonormali



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

### Condizione di ortogonalità:

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

### Condizione di normalità:

- Il determinante è = 1.

### Condizione di normalità:

- Il determinante è = 1.
- La somma dei prodotti di due righe o di due colonne è = 0.

⇒ La somma dei quadrati degli elementi di una riga o colonna è = 1.

$$\Rightarrow A^T = A^{-1}$$



# 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:

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

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

.....

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





## Sommario



Sistemi lineari e matrici

Soluzione dei sistemi lineari

**Analisi dell'affidabilità della stima**

Linearizzazione di sistemi di funzioni

Determinazione dei parametri di un modello non-lineare



## Sistema N x N



$$\begin{aligned} a_{11}x_1 + a_{12}x_2 + \dots + a_{1N}x_N &= b_1 \\ a_{21}x_1 + a_{22}x_2 + \dots + a_{2N}x_N &= b_2 \end{aligned}$$

.....

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

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

A è N x N quadrata

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

1,  $\infty$  soluzioni.

**Esempio:**

$$\begin{aligned} 3x_1 + 2x_2 + \dots + 4x_N &= 5 \\ 4x_1 - 2x_2 + \dots + 0.5x_N &= 3 \end{aligned}$$

.....

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



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



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

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

.....

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

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

$\mathbf{A}$  è  $M \times N$ ,  $M > N$ .

1, nessuna,  $\infty$  soluzioni.

Ho delle equazioni di troppo.

Scelgo  $N$  delle  $M$  righe e scrivo  $\mathbf{A}^*$

$$\mathbf{x} = \mathbf{A}^{*-1} \mathbf{b} \text{ se } \mathbf{A}^{*-1} \text{ esiste.}$$

### 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 lineare: soluzione algebrica



$$\mathbf{A} \mathbf{X} = \mathbf{B}$$



$$\mathbf{A}' \mathbf{A} \mathbf{X} = \mathbf{A}' \mathbf{B}$$



$$(\mathbf{A}' \mathbf{A})^{-1} \mathbf{A}' \mathbf{A} \mathbf{X} = (\mathbf{A}' \mathbf{A})^{-1} \mathbf{A}' \mathbf{B}$$



$$\mathbf{X} = (\mathbf{A}' \mathbf{A})^{-1} \mathbf{A}' \mathbf{B}$$

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



## Rappresentazione statistica




$$\begin{aligned} a_{11}x_1 + a_{12}x_2 + \dots & a_{1N}x_N = b_1 + v_1 \\ a_{21}x_1 + a_{22}x_2 + \dots & a_{2N}x_N = b_2 + v_2 \end{aligned}$$

$$\dots$$

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

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



## Soluzione come problema di minimo



$$\min_{\mathbf{x}} \sum_k v_k^2 = \min_{\mathbf{x}} (\mathbf{Ax} - \mathbf{b})^2$$

$$\frac{\partial}{\partial \mathbf{x}} (\mathbf{Ax} - \mathbf{b})^2 = \mathbf{A}'(\mathbf{Ax} - \mathbf{b})$$

$$\mathbf{X} = (\mathbf{A}'\mathbf{A})^{-1}\mathbf{A}'\mathbf{B}$$

*Esempio:*

$$(a_{11}x_1 + a_{12}x_2 - b_1)^2$$

$$R = (a_{11}^2 x_1^2 + a_{12}^2 x_2^2 + b_1^2 a_{11}^2 + 2 a_{11} a_{12} x_1 x_2 - 2 a_{11} b_1 x_1 + a_{12} b_1 x_2)$$

$$\frac{\partial}{\partial x_1} R = 2 a_{11}^2 x_1 + 2 a_{11} a_{12} x_2 - 2 a_{11} b_1 x_1$$





## Giustificazione statistica



[http://www.weibull.com/AccelTestWeb/mle\\_maximum\\_likelihood\\_parameter\\_estimation.htm](http://www.weibull.com/AccelTestWeb/mle_maximum_likelihood_parameter_estimation.htm)

Data set, S, di N punti (a, b) da fittare con un modello in M parametri, {x}.  $b = f(\mathbf{a}; \mathbf{x})$ .

Quale relazione c'è tra la minimizzazione dell'errore residuo e la statistica?

Dato un certo insieme di parametri, vogliamo valutare quanto sia verosimile estrarre il data set S. Ovverosia la *likelihood* (verosimiglianza) dei parametri, dati i dati S → Parametri tali che la likelihood sia massimizzata.

Ogni punto viene visto come estratto da una distribuzione statistica parametrica:

$$f(\mathbf{a}, \mathbf{b}; x_1, x_2, \dots, x_N)$$

Dove i {θ} sono non noti e devono essere determinati.

Funzione di verosimiglianza:  $L(\mathbf{x} | \theta) =$

$$L(a_1, a_2, \dots, a_M, \mathbf{b}; x_1, x_2, \dots, x_N) = \prod_{i=1}^N f(a_i, b_i; x_1, x_2, \dots, x_N)$$



## Massimizzazione



$$L(a_1, a_2, \dots, a_M, \mathbf{b}; x_1, x_2, \dots, x_N) = \prod_{i=1}^N f(a_i, b_i; x_1, x_2, \dots, x_N)$$

Si passa al logaritmo, il prodotto diventa una somma.  $\Lambda = \ln L = \sum_{i=1}^N \ln(f(\mathbf{a}, \mathbf{b}; x_1, x_2, \dots, x_N))$

Massimizzazione rispetto ai {θ}

$$L'(\theta) / L(\theta) = \frac{\partial \Lambda}{\partial x_j} = 0, \quad j = 1, 2, 3, \dots, N$$

Sistema di tante equazioni quanti sono i parametri.



## Dalla massima verosimiglianza ai minimi quadrati - I



Supponiamo l'errore sui dati Gaussiano:  $f(T) = \frac{1}{\sigma_T \sqrt{2\pi}} e^{-\frac{1}{2} \left( \frac{T - \bar{T}}{\sigma_T} \right)^2}$

$$L(T_1, T_2, \dots, T_N | \bar{T}, \sigma_T) = L = \prod_{i=1}^N \left[ \frac{1}{\sigma_T \sqrt{2\pi}} e^{-\frac{1}{2} \left( \frac{T_i - \bar{T}}{\sigma_T} \right)^2} \right]$$

$$L = \frac{1}{(\sigma_T \sqrt{2\pi})^N} e^{-\frac{1}{2} \sum_{i=1}^N \left( \frac{T_i - \bar{T}}{\sigma_T} \right)^2}$$

Scriviamo  $\Lambda$ :

$$\Lambda = \ln(L) = -\frac{N}{2} \ln(2\pi) - N \ln \sigma_T - \left( \frac{1}{2} \sum_{i=1}^N \left( \frac{T_i - \bar{T}}{\sigma_T} \right)^2 \right)$$



## Dalla massima verosimiglianza ai minimi quadrati - II



Then taking the partial derivatives of with respect to each one of the parameters and setting it equal to zero yields:

$$\frac{\partial(\Lambda)}{\partial \bar{T}} = \frac{1}{\sigma_T^2} \sum_{i=1}^N (T_i - \bar{T}) = 0 \quad \frac{\partial(\Lambda)}{\partial \sigma_T} = -\frac{N}{\sigma_T} + \frac{1}{\sigma_T^3} \sum_{i=1}^N (T_i - \bar{T})^2 = 0$$

Risolvendole simultaneamente, si ottiene:

$$\bar{T} = \frac{1}{N} \sum_{i=1}^N T_i$$

$$\hat{\sigma}_T^2 = \frac{1}{N} \sum_{i=1}^N (T_i - \bar{T})^2$$

$$\hat{\sigma}_T = \sqrt{\frac{1}{N} \sum_{i=1}^N (T_i - \bar{T})^2}$$



## Stima ai minimi quadrati e MaxVer



$$\frac{\partial(\Lambda)}{\partial \bar{T}} = \frac{1}{\sigma_T^2} \sum_{i=1}^N (T_i - \bar{T}) = 0 \quad \frac{\partial(\Lambda)}{\partial \sigma_T} = -\frac{N}{\sigma_T} + \frac{1}{\sigma_T^3} \sum_{i=1}^N (T_i - \bar{T})^2 = 0$$

$$\bar{T} = \frac{1}{N} \sum_{i=1}^N T_i$$

Se supponiamo che il modello, dal quale viene calcolato il residuo, non sia rappresentato da un singolo parametro, ma da una combinazione lineare dei parametri, otteniamo:

$$\mathcal{G} = \sum_{k=1}^N a_{ij} x_j \quad \min \frac{1}{\sigma^2} \sum_{j=1}^M \left( T_j - \sum_{i=1}^N a_{ij} \mathcal{G}_i \right)^2$$



## Sommario



Sistemi lineari e matrici

Soluzione dei sistemi lineari

Analisi dell'affidabilità della stima

**Linearizzazione di sistemi di funzioni**

Determinazione dei parametri di un modello non-lineare



## Condizionamento della matrice $C = A^*A$



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

Per evitare di ottenere elementi troppo grandi che rendono la norma della matrice  $C$  vicina alla precisione della macchina, si preferisce utilizzare la Singular Value Decomposition per risolvere il sistema lineare.

$$A x = b$$



## Sistema lineare: soluzione robusta



$$A X = B \quad \Longrightarrow \quad A^* A X = A^* B \quad \Longrightarrow \quad X = (A^*A)^{-1}A^*B$$

Numero di condizionamento varia circa con  $(A^*A)$ .

*Soluzione tramite Singular Value Decomposition*

Numero di condizionamento varia circa con  $A$ .

$$A X = B$$

$$U W V X = B \quad \boxed{x = V^* W^{-1} U^* b}$$

Ortonormale  $M \times N$      Diagonale  $(N \times N)$      Ortonormale  $N \times N$

$$V^* W^{-1} U^* U W V X = V^* W^{-1} U^* B \quad \Rightarrow \quad X = V^* W^{-1} U^* B$$

- La matrice  $C$  non viene formata.
- $W^{-1}$  contiene i reciproci degli elementi di  $W$ .

$W^{-1}$  è diagonale.  $w_{ii}^{-1} = 1/w_{ii}$



## Rank-deficiency nella matrice dei coefficienti



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

$$x = V^T W^{-1} U^T b$$

Se  $A$  è rank-deficient,  $A^T A$  è singolare.

Si può facilmente osservare valutando il valore singolare più piccolo della matrice  $W$ .

In questo caso il problema è sovrapparametrizzato.



## Valutazione della bontà della stima



$$x = (A^T A)^{-1} A^T b \iff \min_x \sum_k v_k^2 = \min_x (Ax - b)^2$$

Errore di modellizzazione Gaussiano a media nulla  $e(0, \sigma^2)$

$$\langle v_k \rangle = 0$$

$$\hat{\sigma}_0^2 = \sum_{m=1}^M (v_m^2)$$



## Valutazione della bontà della stima del singolo parametro e della loro correlazione



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

$$x = C A' b$$

$$\hat{\sigma}_0^2 = \sum_{m=1}^M (v_m^2)$$

Chiamiamo  $u$  e  $v$  le variabili casuali associate all'errore sui parametri e all'errore di modellizzazione, rispettivamente. Si suppone errore a media nulla e Gaussianamente distribuito.

$$x + u = C A' (b + v)$$



$$u = C A' v$$

A.A. 2005-2006

27/38

<http://homes.dsi.unimi.it/~borghese/>



## Impostazione del calcolo della correlazione tra i parametri



$$u = C A' v$$

Vogliamo individuare la correlazione tra due parametri  $r$  ed  $s$ . Devo quindi determinare il valore atteso di  $u_r * u_s$ .

$$\begin{bmatrix} u_1^2 & u_1 u_2 & \dots & u_1 u_W \\ u_2 u_1 & u_2^2 & \dots & u_2 u_W \\ \dots & \dots & \dots & \dots \\ u_W u_1 & u_W u_2 & \dots & u_W^2 \end{bmatrix}$$

$$u = C^{-1} A' v \quad \Rightarrow \quad u' = v' A (C^{-1})'$$

$u u' = C A' v v' A C' \Rightarrow$  Applicando l'operatore di media, si ottiene:

$$\langle u u' \rangle = C A' \langle v v' \rangle A C'$$

Dato che  $v$  sono i residui, e sono indipendenti, e tutte i punti di controllo hanno lo stesso tipo di errore di misura, si avrà che  $\langle v v' \rangle = I \sigma_0^2$ .

A.A. 2005-2006

28/38

<http://homes.dsi.unimi.it/~borghese/>



## Calcolo della correlazione tra i parametri



$$\langle uu' \rangle = CA' IA C' \sigma_0^2 = C \sigma_0^2$$

Da cui si giustifica il nome di matrice di covarianza per C.

Segue che:  $\sigma^2(u_{ij}) = c_{ij}^{-1} \sigma_0^2$  Varianza sulla stima del parametro.

$$-1 \leq r_{ij} = \frac{\langle u_i u_j \rangle}{\sqrt{\langle u_i \rangle^2 \langle u_j \rangle^2}} = \frac{c_{ij}}{\sqrt{c_i c_j}} \leq +1$$

Indice di correlazione tra il parametro i ed il parametro j  
(empiricamente si scartano parametri quando la correlazione è superiore al 95%)

Vanno rapportati alle dimensioni dei parametri coinvolti.



## Esempio



Supponiamo di avere distorsione radiale misurata come segue:

Distanza [mm]	Distorsione radiale [mm]
0.000	0.000
20.072	0.004
40.855	0.018
63.155	0.047
88.034	0.062
116.995	0.035
152.472	-0.064

Modello lineare utilizzato:  $\Delta r = k_1 r + k_2 r^3 + k_3 r^5 + k_4 r^7$ .

Parametri determinati:

$$k_1 = 1.99697 \times 10^{-4}$$

$$k_2 = 1.94801 \times 10^{-7}$$

$$k_3 = -1.97388 \times 10^{-11}$$

$$k_4 = 0.43934 \times 10^{-15}$$

Analisi di varianza?



## Sommario



Sistemi lineari e matrici

Soluzione dei sistemi lineari

Analisi dell'affidabilità della stima

Linearizzazione di sistemi di funzioni

**Determinazione dei parametri di un modello non-lineare**

A.A. 2005-2006

31/38

<http://homes.dsi.unimi.it/~borghese/>




## Minimizzazione tramite gradiente



**Minimizzo**  $J(\cdot)$  rispetto ai parametri.

Tecnica del gradiente applicata alla minimizzazione di funzioni non-lineari di **una variabile**:  $J = J(w|\dots)$ .



**La derivata, mi dà due informazioni:**

- 1) In quale direzione di  $w$ , la funzione decresce.
- 2) Quanto rapidamente decresce.

Definisco uno spostamento arbitrario lungo la pendenza: maggiore la pendenza maggiore lo spostamento. Mi muovo lungo la direzione della pendenza, arrivo in  $P^{II}$ . Calcolo  $J(w^{II})$ .

Da qui riparto fino a quando non arrivo in  $P_{min}$ .

ese\





## Minimizzazione di funzioni di più variabili



$\min(J\{\mathbf{w}\} | \dots)$  funzione costo od errore

Gradiente: 
$$\frac{\partial J(\{w\} | \dots)}{\partial w_1} \frac{w_1}{|w_1|} + \frac{\partial J(\{w\} | \dots)}{\partial w_2} \frac{w_2}{|w_2|} +$$

$$\frac{\partial J(\{w\} | \dots)}{\partial w_3} \frac{w_3}{|w_3|} + \frac{\partial J(\{w\} | \dots)}{\partial w_4} \frac{w_4}{|w_4|} + \dots$$

Modifico il valore dei pesi di una quantità proporzionale alla pendenza della funzione costo rispetto a quel parametro.

Estensione della tecnica del gradiente a più variabili.

Serve un' **approssimazione iniziale** per i pesi  $W_{ini} = \{w_j\}_{ini}$ .



## Esempio di applicazione tecnica del gradiente per funzioni di 1 variabile



*Supponiamo che il modello da noi considerato sia semplice:  $y = ax^2$*

Consideriamo di avere stimato  $a = 2$  e di avere misurato  $y = 3$  per  $x = 1$ . Possiamo modificare il parametro  $a$  in modo tale che il modello fitta i dati ( $x=1$  e  $y=3$ ).

Linearizziamo il modello e scriviamo:  $(y - ax^2) = \left[ \frac{d}{da}(ax^2) \right] da$

Sostituendo i valori otteniamo:  $da = (3 - 2 \cdot 1) / (1) = 1$

$$a = 2 + 1 = 3.$$

$$da = (3 - 3 \cdot 1) / 1 = 0$$

Avendo più di una misurazione dobbiamo “mediare” tra gli incrementi  $dx$  calcolati per ogni misurazione.



## Minimizzazione di funzioni di più variabili



$\min(J\{\mathbf{w}\} | \dots)$  funzione costo od errore

Gradiente:

$$\frac{\partial J(\{\mathbf{w}\} | \dots)}{\partial w_1} \frac{w_1}{|w_1|} + \frac{\partial J(\{\mathbf{w}\} | \dots)}{\partial w_2} \frac{w_2}{|w_2|} +$$

$$\frac{\partial J(\{\mathbf{w}\} | \dots)}{\partial w_3} \frac{w_3}{|w_3|} + \frac{\partial J(\{\mathbf{w}\} | \dots)}{\partial w_4} \frac{w_4}{|w_4|} + \dots$$

Modifico il valore dei pesi di una quantità proporzionale alla pendenza della funzione costo rispetto a quel parametro.

Estensione della tecnica del gradiente a più variabili.

Serve un' **approssimazione iniziale** per i pesi  $W_{ini} = \{w_j\}_{ini}$ .



## Minimizzazione dei residui (problema di minimo non lineare)



$$\min(F(P|\{x\}) - b)^2 = \min(F^*)^2$$

Il minimo della funzione  $F^*$  sarà  $\neq 0$  (errore di modellazione + errore di misura).

**Inizializzazione**

Determino un valore dei parametri  $x$  da cui partire.

**Linearizzazione (sviluppo di Taylor del primo ordine)** attorno al valore attuale dei parametri

$$F^*(P) = F^*(P_0) + \sum_{j=1}^w \left. \frac{\partial F^*(.)}{\partial x_j} \right|_{P_0} * dx_j = \mathbf{b} - \mathbf{A}dx$$

**Soluzione del sistema lineare nei  $dx_j$**

**Update**

Aggiorno il valore dei parametri  $x$



## Esempio



$$F(P;x) = w_1 G(P;c_1,\sigma_1) + w_2 G(P;c_2,\sigma_2)$$

Dato un certo insieme di campioni, quanto devono valere i parametri per ottenere un buon fitting?



## Sommario



Sistemi lineari e matrici

Soluzione dei sistemi lineari

Analisi dell'affidabilità della stima

Linearizzazione di sistemi di funzioni

Determinazione dei parametri di un modello non-lineare.