

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



A.A. 2006-2007

1/44

<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. 2006-2007

2/44

<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

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

Esempio:

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

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

.....

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

A.A. 2006-2007

3/44

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



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

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

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

A.A. 2006-2007

4/44

<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 gode della proprietà commutativa:

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

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

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

$$AI = A = IA$$

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

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

A.A. 2006-2007

5/44

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



Determinante di una matrice Quadrata



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

a_{ij}^* minore complementare di a_{ij} = determinante della matrice ottenuta eliminando la riga i e la colonna j di A .

$$A = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \quad \det(A) = a_{11} a_{22} - a_{12} a_{21}$$

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

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

A.A. 2006-2007

6/44

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



Matrice Inversa

$A = [a_{ij}]$, matrice quadrata.

A_{ij} matrice dei
complementi algebrici =
minori complementari
moltiplicati $(-1)^{i+j}$

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

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

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

Se esiste, la matrice inversa è unica.

A.A. 2006-2007

7/44

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



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)**.

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

A.A. 2006-2007

8/44


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



Esempio

$$y = x + 2$$

$$y = -3x + 1$$



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

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

$$x_1 = x$$

$$x_2 = y$$

Risolve per sostituzione:

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

$$x_1 = -2 + 7/4 \quad \rightarrow \quad x_1 = -1/4$$

A.A. 2006-2007

9/44

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



Soluzione dei sistemi lineari

Scrivo il sistema lineare: $Ax = b$

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

$$y = x + 2$$

$$y = -3x + 1$$

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

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

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 (∞^k soluzioni – sistema indeterminato).

A.A. 2006-2007

10/44

<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



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 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 ∞ soluzioni

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

A è N x N quadrata

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

altrimenti, **nessuna** (rette parallele)

o

∞ soluzioni (rette coincidenti).

Esempio:

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

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

.....

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

A.A. 2006-2007

13/44

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



Sistema M x 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 ∞ soluzioni

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

A è M x N, M > N.

1, nessuna, ∞ 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, combinate linearmente).

Posso sempre calcolare la soluzione in forma matriciale.

A.A. 2006-2007

14/44

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



Soluzione come problema di ottimizzazione



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 minima da tutte le rette.

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

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

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

NB le funzioni costo sono spesso quadratiche (problemi di minimizzazione convessi) perchè il costo cresce sia che il modello sovrastimi che sottostimi le misure.



Giustificazione statistica

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, $\{x\}$. $b = f(a; x)$.

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:

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

Dove i $\{\theta\}$ sono non noti e devono essere determinati.

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

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



Massimizzazione

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

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

Massimizzazione rispetto ai $\{\theta\}$

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

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 Λ :

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



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:

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

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

A.A. 2006-2007

21/44

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



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:

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

A.A. 2006-2007

22/44

<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



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 (diagonalizzazione)

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 $N \times N$

$$V^T W^{-1} U^T U W V X = V^T W^{-1} U^T B \quad \rightarrow \quad X = V^T W^{-1} U^T B$$

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

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

A.A. 2006-2007

25/44

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



Rank-deficiency nella matrice dei coefficienti

Quando C è singolare?

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

$$\boxed{x = V' W^{-1} U' b}$$

Se A è rank-deficient, $A' A$ è singolare.

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

In questo caso il problema è sovrapparametrizzato.

A.A. 2006-2007

26/44

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



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 $N(0, \sigma^2)$

$$\langle v_k \rangle = 0$$

$$\hat{\sigma}_0^2 = \sum_{k=1}^M (v_k^2) = |v|^2$$

Varianza della stima = varianza dell'errore di misura

A.A. 2006-2007

27/44

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



Richiamo di statistica



Data una variabile casuale, x , il suo valore medio calcolato su N campioni è dato da:

$$M_x = \frac{\sum_{k=1}^N x_k}{N}$$

Data una variabile casuale, x , la sua varianza su N campioni è data da:

$$\sigma_x^2 = \frac{\sum_{k=1}^N (x_k - M_x)^2}{N}$$

Data una variabile casuale, x , la sua deviazione standard su N campioni è data da:

$$\sigma_x = \sqrt{\frac{\sum_{k=1}^N (x_k - M_x)^2}{N}}$$

Varianza e deviazione standard descrivono la dispersione attorno al valor medio.

A.A. 2006-2007

28/44

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



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.

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



$$u = C A' v$$



Impostazione del calcolo della correlazione tra i parametri



$$u = C A' v$$

Vogliamo individuare la correlazione tra due parametri i e j . Devo quindi determinare la loro correlazione:

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

$$\langle u_i, u_j \rangle$$

$$u = C A' v$$

\Rightarrow

$$u' = v' A (C)'$$

$u u' = C A' v v' A C' \Rightarrow$ 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 $\langle v v' \rangle = I \sigma_0^2$.



Correlazione tra i parametri

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

$$\langle u'u \rangle = C \sigma_0^2$$

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

Segue che: $\sigma^2(u_{ij}) = c_{ij} \sigma_0^2$ 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.



Matrice di covarianza

Date N variabili casuali: $x = [x_1, x_2, \dots, x_N]$ si può misurare la correlazione tra coppie di variabili. E' comodo rappresentare la correlazione tra variabili casuali in un'unica matrice detta **matrice di covarianza** come:

$$C = \begin{bmatrix} \sigma_{x_1 x_1} & \sigma_{x_1 x_2} & \cdot & \sigma_{x_1 x_N} \\ \sigma_{x_2 x_1} & \sigma_{x_2 x_2} & \cdot & \sigma_{x_2 x_N} \\ \cdot & \cdot & \cdot & \cdot \\ \sigma_{x_N x_1} & \sigma_{x_N x_2} & \cdot & \sigma_{x_N x_N} \end{bmatrix}$$

Varianza: $\sigma_{x_i x_i} = \sigma_{x_i}^2$ N parametri

Covarianza: $\sigma_{x_i x_j} = \sigma_{x_j x_i}$ $i \neq j$ $(N-1)^2/2$ parametri



Correlazione

Date due variabili casuali: x_i, x_j , l'indice di correlazione misura quanto le coppie di variabili estratte: $p(x_i, x_j)$ stanno su una retta:

$$r = \frac{M_{x_i x_j} - M_{x_i} M_{x_j}}{\sigma_{x_i} \sigma_{x_j}} \quad -1 \leq r \leq +1$$

Definendo la covarianza tra x_i ed x_j come:

$$\sigma_{x_i x_j} = \frac{1}{N} \sum_i \sum_j (x_i - M_{x_i})(x_j - M_{x_j})$$

Dalla definizione di deviazione standard risulta:

$$r = \frac{\sigma_{x_i x_j}}{\sigma_{x_i} \sigma_{x_j}}$$

A.A. 2006-2007

33/44

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



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?

A.A. 2006-2007

34/44

<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. 2006-2007

35/44


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



Minimizzazione tramite gradiente: 1 variabile



Tecnica del gradiente applicata alla minimizzazione di funzioni non-lineari di **una variabile, p** , e di **un parametro, w** : $f = f(P | w)$.



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.

$$dw \propto -f'(w;P) \quad \text{dati } P, w.$$

Occorre un'inizializzazione.

Metodo iterativo.

ese\



Esempio di applicazione tecnica del gradiente per funzioni di 1 variabile



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


Misuriamo un punto sulla parabola: $x = 1, y = 3$.

Vogliamo modificare a in modo che la parabola passi per $P(x,y)$.

La funzione costo da minimizzare sarà: $e = f(x,y | w) = (y - ax^2)^2$

La soluzione è $a = 3$

Partiamo da $a_{ini} = 2$.



Utilizziamo il metodo del gradiente:

Calcoliamo la derivata di $f(\cdot)$ $\rightarrow f'(\cdot) = -2(y - ax^2)x^2$

A.A. 2006-2007

37/44

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



Minimizzazione - underdamping



Consideriamo $\alpha = 1$

Calcoliamo la derivata di $f(\cdot)$ $\rightarrow f'(\cdot) = -2(y - ax^2)x^2$

Utilizziamo il metodo del gradiente:

Passo 1:

Calcoliamo l'incremento da dare al parametro a :

$$da = -[-2(3 - 2 \cdot 1) \cdot 1] = -[-6 + 4] = 2 \quad a' = 2 + 2 = 4$$

Passo 2:

Calcoliamo l'incremento da dare al parametro a :

$$da = -[-2(3 - 4 \cdot 1) \cdot 1] = -[-6 + 8] = -2 \quad a'' = 4 - 2 = 2$$

Oscillazioni!!!

Mi sposto troppo velocemente da una parte all'altra del minimo.

A.A. 2006-2007

38/44

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



Minimizzazione -2 passi



Consideriamo $\alpha = 0.4$

Calcoliamo la derivata di $f(\cdot) \rightarrow f'(\cdot) = -2(y - ax^2)x^2$

Utilizziamo il metodo del gradiente:

Passo 1:

Calcoliamo l'incremento da dare al parametro a:

$$da = -0.4 [-2(3 - 2 \cdot 1) \cdot 1] = -[-6 + 4] = 0.8 \quad a' = 2 + 0.8 = 2.8$$

Passo 2:

Calcoliamo l'incremento da dare al parametro a:

$$da = -0.4 [-2(3 - 2.8 \cdot 1) \cdot 1] = -[-6 + 5.6] = 0.16 \quad a'' = 2.8 + 0.16 = 2.96$$

Converge ad $a = 3$.

Posso correre il rischio di spostarmi troppo lentamente



Minimizzazione di funzioni di più variabili (e.g. robotica)



$\min(f(\mathbf{x}, \mathbf{w}))$ funzione costo od errore, \mathbf{w} vettore.

Modifico il valore dei pesi di una quantità proporzionale alla pendenza della funzione costo rispetto a quel parametro. La pendenza è una direzione nello spazio, non è più solamente destra / sinistra. Devo calcolare la derivata spaziale = gradiente della funzione $f(\cdot)$.

Estensione della tecnica del gradiente a più variabili.

$$d\mathbf{w} = -\alpha \nabla f(\mathbf{x}; \mathbf{w}), \text{ dato } \mathbf{P}, \mathbf{W}.$$

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



Stima di parametri in insiemi di equazioni non lineari - linearizzazione



$y = f(x)$ viene linearizzata utilizzando il differenziale:

$$y = f(x_0) + \left. \frac{df(x)}{dx} \right|_{x=x_0} dx = y_0 + \left. \frac{df(x)}{dx} \right|_{x=x_0} dx$$

Si può vedere come sviluppo di Taylor arrestato al 1° ordine
E' un'equazione lineare in dx .

Per funzioni di più variabili, $f(\mathbf{P}; \mathbf{W}) = 0$, la linearizzazione si può scrivere come:

$$F(\mathbf{P}; \mathbf{W}) = F(\mathbf{P}_0; \mathbf{W}_0) + \sum_{j=1}^W \left. \frac{\partial F(\cdot)}{\partial w_j} \right|_{P_0, W_0} * dw_j = k - \sum_{j=1}^W a_j * dw_j$$

E' un'equazione lineare nei dw che descrive il comportamento della funzione $F(\cdot)$ nell'intorno del punto P_0 con i parametri W_0 .



Stima di parametri in insiemi di equazioni non lineari - sistema



$$F(\mathbf{P}; \mathbf{W}) = F(\mathbf{P}_0; \mathbf{W}_0) + \sum_{j=1}^W \left. \frac{\partial F(\cdot)}{\partial w_j} \right|_{P_0, W_0} * dw_j = k - \sum_{j=1}^W a_j * dw_j$$

Jacobiano:

$$J = \begin{bmatrix} \left. \frac{\partial F_1(\cdot)}{\partial x_1} \right|_{W_0, P_0} & \left. \frac{\partial F_1(\cdot)}{\partial x_2} \right|_{W_0, P_0} & \left. \frac{\partial F_1(\cdot)}{\partial x_N} \right|_{W_0, P_0} \\ \left. \frac{\partial F_2(\cdot)}{\partial x_1} \right|_{W_0, P_0} & \left. \frac{\partial F_2(\cdot)}{\partial x_2} \right|_{W_0, P_0} & \left. \frac{\partial F_2(\cdot)}{\partial x_N} \right|_{W_0, P_0} \\ \dots & & \\ \left. \frac{\partial F_M(\cdot)}{\partial x_1} \right|_{W_0, P_0} & & \left. \frac{\partial F_M(\cdot)}{\partial x_N} \right|_{W_0, P_0} \end{bmatrix}$$

$$F(\mathbf{P}; \mathbf{W}) = F(\mathbf{P}_0; \mathbf{W}_0) + \mathbf{J} \mathbf{dw}$$

Sistemi di equazioni lineari in \mathbf{dw} (vettore)



Soluzione del problema di ottimizzazione non lineare



$\min(f(\mathbf{x}; \mathbf{w})) = \min(F^*)^2$ Il minimo della funzione F^* sarà $\neq 0$ (errore di modellazione + errore di misura).

Inizializzazione

Determino un valore dei parametri \mathbf{w} da cui partire.

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

$$F^*(\mathbf{P}; \mathbf{W}) = F^*(\mathbf{P}; \mathbf{W}_0) + \sum_{j=1}^w \left. \frac{\partial F^*(\cdot)}{\partial w_j} \right|_{P_0} * dw_j = \mathbf{b} - \mathbf{J}(\mathbf{W}; \mathbf{P}) d\mathbf{w}$$

Soluzione del sistema lineare nei dw_j

Update

Aggiorno il valore dei parametri \mathbf{w}



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.