

Sistemi Intelligenti Relazione tra ottimizzazione e statistica - IV

Alberto Borghese

Università degli Studi di Milano
Laboratory of Applied Intelligent Systems (AIS-Lab)
Dipartimento di Informatica
borgnese@di.unimi.it




A.A. 2017-2018 1/34 <http://borgnese.di.unimi.it/>




Sommario

Analisi dell'affidabilità della stima

Metodo del gradiente

Linearizzazione e metodo di Gauss-Newton

A.A. 2017-2018 2/34 <http://borgnese.di.unimi.it/>




Valutazione della bontà della stima

$$\mathbf{x} = (\mathbf{A}' * \mathbf{A})^{-1} \mathbf{A}' * \mathbf{b} \iff \min_{\mathbf{x}} \sum_k v_k^2 = \min_{\mathbf{x}} (\mathbf{A}\mathbf{x} - \mathbf{b})^2$$

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. 2017-2018 3/34 http://borghese.di.unimi.it/




Valutazione della bontà della stima del singolo parametro

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

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

$$\mathbf{x} = \mathbf{C} \mathbf{A}' * \mathbf{b}$$

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

$$\mathbf{u} = \Delta \mathbf{x} \quad (\mathbf{x} + \mathbf{u}) = \mathbf{C} \mathbf{A}' (\mathbf{b} + \mathbf{v})$$

\downarrow

$$\mathbf{x} = \mathbf{C} \mathbf{A}' \mathbf{b} \quad \mathbf{u} = \mathbf{C} \mathbf{A}' * \mathbf{v} \quad E[\mathbf{u}] = 0$$

\mathbf{C} è la matrice di covarianza

A.A. 2017-2018 4/34 http://borghese.di.unimi.it/




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:

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

$\langle u_i, u_j \rangle$

$u = C A' v \quad \Rightarrow \quad u' = v' A (C)'$

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

A.A. 2017-2018 5/34 <http://borghese.di.unimi.it/>




Incertezza sulla stima dei parametri

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

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

Incertezza su y -> incertezza su u

A.A. 2017-2018 6/34 <http://borghese.di.unimi.it/>



Visione geometrica



$$\sigma^2(u_{ij}) = c_{ij} \sigma_0^2 \quad \langle u'u \rangle = C \sigma_0^2$$

$x = m + \text{noise}$
 $Ax = b + \text{noise}$
Determino la pendenza m della retta

Calcolo m come: $m = y * x^{-1}$

Quanto è sensibile questa stima? Cosa succede se, per effetto del noise, invece di misurare y , misuro $y + v$?

$$\sigma^2(m) = c_m \sigma_0^2$$

$$C = (A^*A)^{-1} \quad \Rightarrow \quad m = (x^*x)^{-1}$$

La varianza di m varierà in modo inversamente proporzionale a x^2 . Il rumore viene cioè moltiplicato per $1/x^2$.

Tanto più prendo i punti lontani dall'origine tanto meglio riesco a stimare m (tangente angolo).

A.A. 2017-2018
7/34
<http://borghese.di.unimi.it/>



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

A.A. 2017-2018
8/34
<http://borghese.di.unimi.it/>



Correlazione tra coppie di parametri



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:

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



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.



La covarianza: momenti di 2 variabili statistiche



Covarianza = $E[(x - \mu_x)(y - \mu_y)]$

Varianza = $E[(x - \mu_x)(x - \mu_x)]$

Per due variabili indipendenti, la covarianza = 0, non variano assieme (covariano)

$$C = \begin{bmatrix} \sigma_x^2 & \sigma_x \sigma_y \\ \sigma_y \sigma_x & \sigma_y^2 \end{bmatrix}$$

```
>> x = randn(N,1);
>> y = randn(N,1);
>> temp = x.*y;
>> covarianza = mean(temp)
```



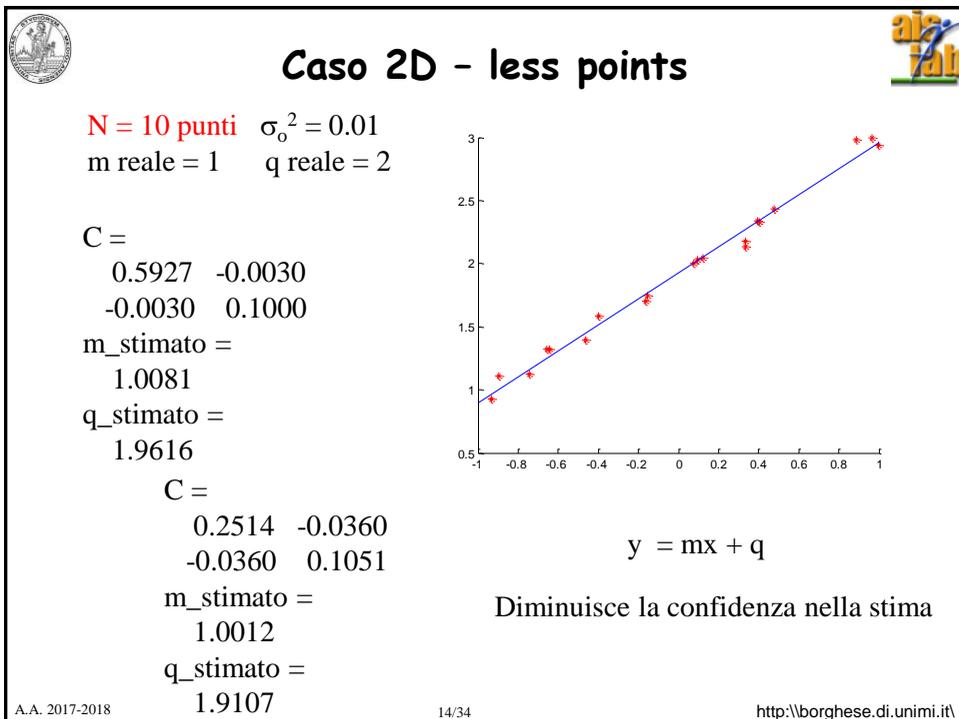
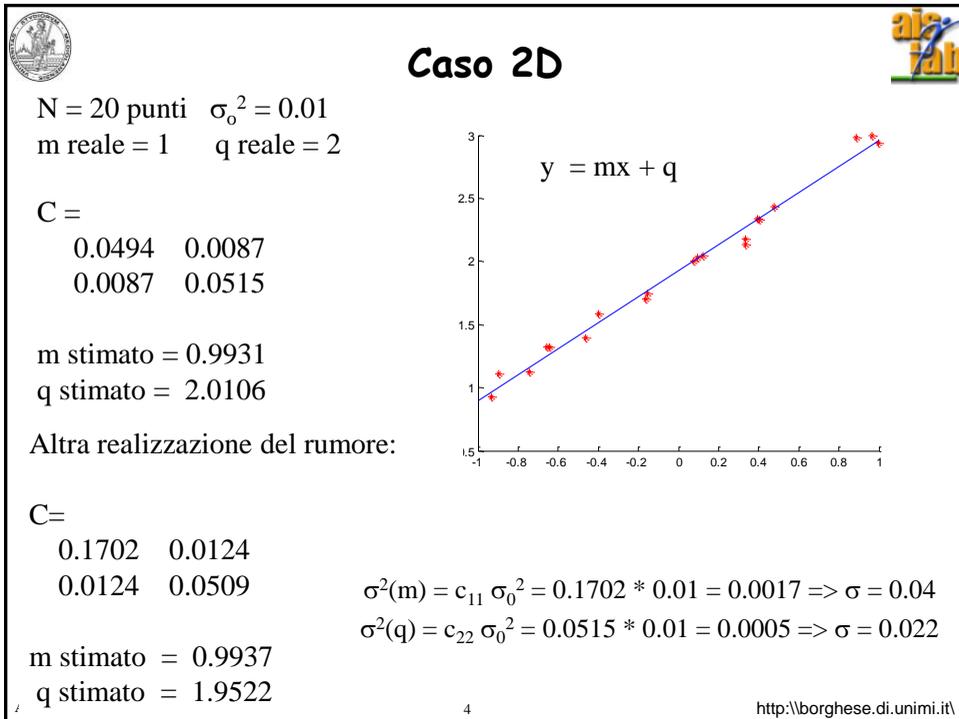
Misura di correlazione su 2 parametri

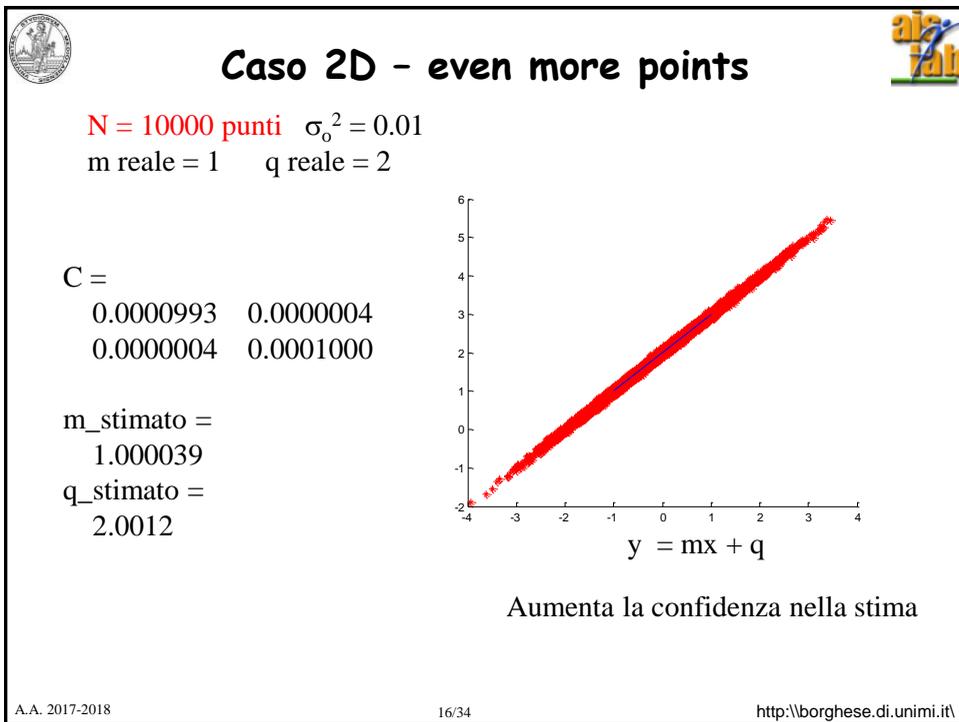
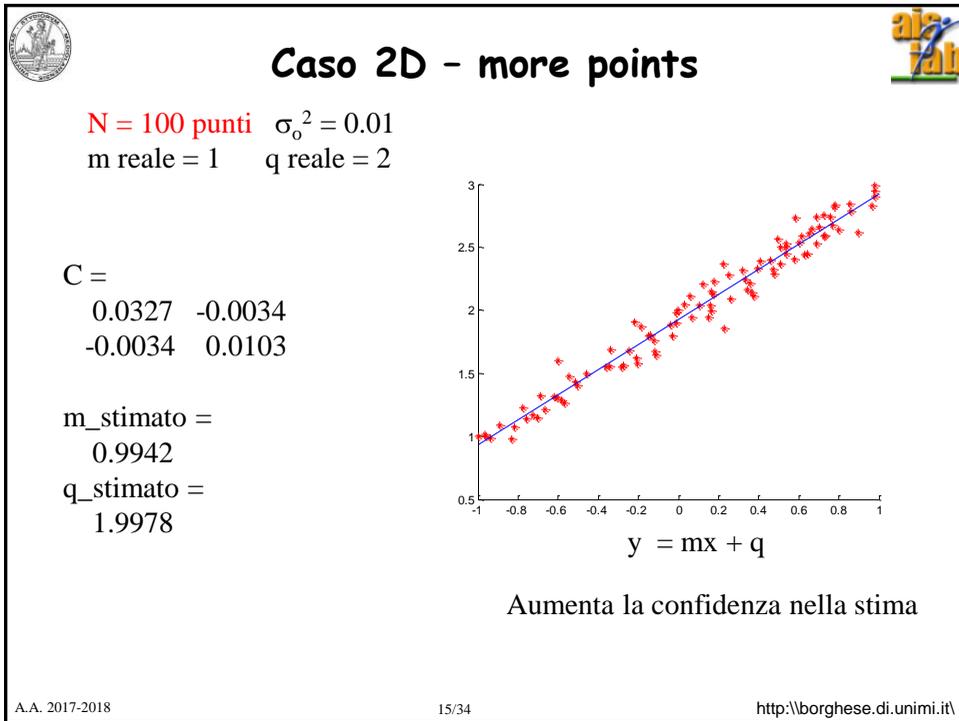


Misura la inter-dipendenza tra 2 variabili statistiche:

$$-1 \leq \frac{\sigma_{xy}}{\sigma_x \sigma_y} = c = \lim_{N \rightarrow \infty} \frac{\sum_k (x_k - \mu_x)(y_k - \mu_y)}{\sqrt{\sum_k (x_k - \mu_x)^2} \sqrt{\sum_k (y_k - \mu_y)^2}} \leq +1$$

```
>> x = randn(N,1);
>> y1 = randn(N,1);
>> y2 = x;
>> temp1 = x.*y1;
>> temp2 = x.*y2;
>> covarianza1 = mean(temp1) % Uncorrelated variables (c -> 1)
>> covarianza2 = mean(temp2) % Correlated variables (c = 0)
```







Sommarrio



Analisi dell'affidabilità della stima

Metodo del gradiente

Linearizzazione e metodo di Gauss-Newton

A.A. 2017-2018

17/34

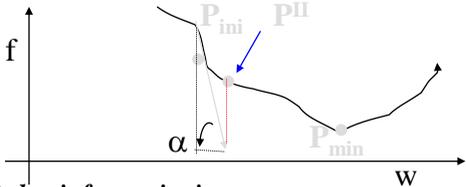
<http://borghese.di.unimi.it/>



Minimizzazione tramite gradiente (metodo del primo ordine): 1 variabile



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



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 della funzione f (e.g. errore) nello spazio dei parametri w : maggiore la pendenza maggiore lo spostamento.

$dw \propto -f'(w;P)$ dati P, w . La derivata viene calcolata rispetto a w .

Occorre un'inizializzazione.

Metodo iterativo.

mi.it\



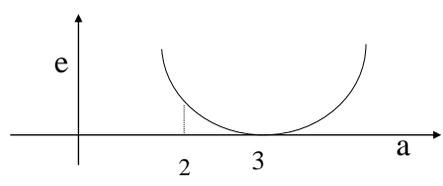
Esempio di applicazione tecnica del gradiente per funzioni di 1 variabile



*Supponiamo che il modello da noi considerato sia semplice: $y = ax^2$
Abbiamo un unico parametro da determinare: a . La funzione è lineare in a (la soluzione è semplice: $a = y/x^2$!!) ma applichiamo il metodo del gradiente:*

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: $e = f(a | x,y) = (y - ax^2)^2$
La soluzione è $a = 3$

Partiamo da $a_{ini} = 2$.
 $err = (3 - 2 \cdot 1)^2 = 1$



Utilizziamo il metodo del gradiente:
Calcoliamo la derivata di $f(a | x,y) \rightarrow f'(a) = -2 (y - a x^2) x^2$

A.A. 2017-2018
19/34
<http://borghese.di.unimi.it/>



Minimizzazione - underdamping



Consideriamo $\alpha = 1$
Calcoliamo la derivata di $f(.) \rightarrow f'(.) = -2 (y - a x^2) x^2$

Utilizziamo il metodo del gradiente:

Passo 1:
Calcoliamo l'incremento da dare al parametro a :
 $da = -[-2 (3 - 2 \cdot 1) \cdot 1] = -[-6 + 4] = 2$ $a' = 2 + 2 = 4$

Passo 2:
Calcoliamo l'incremento da dare al parametro a :
 $da = -[-2 (3 - 4 \cdot 1) \cdot 1] = -[-6 + 8] = -2$ $a'' = 4 - 2 = 2$
Oscillazioni!!!

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

A.A. 2017-2018
20/34
<http://borghese.di.unimi.it/>




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

Passo 2:
 Calcoliamo l'incremento da dare al parametro a:
 $da = -0.4 [-2(3 - 2.8 \cdot 1) 1] = -[-6 + 5.6] = 0.16$ $a'' = 2.8 + 0.16 = 2.96$
 Converge ad $a = 3$.

Posso correre il rischio di spostarmi troppo lentamente

A.A. 2017-2018 21/34 http://borghese.di.unimi.it/




Osservazioni

- Nel metodo del gradiente mi sposto lungo la tangente alla curva dell'errore per raggiungere il minimo.
- Lo spostamento lungo la tangente non mi porta al minimo direttamente.
- Se mi muovo velocemente lo supero.
- Se mi muovo lentamente arrivo lentamente.
- Esistono algoritmi che:
 - ◆ Verificano che il singolo passo di gradiente porta a un miglioramento della soluzione.
 - ◆ Determinano il passo di apprendimento, α .

A.A. 2017-2018 22/34 http://borghese.di.unimi.it/




Sommarrio

Analisi dell'affidabilità della stima

Metodo del gradiente

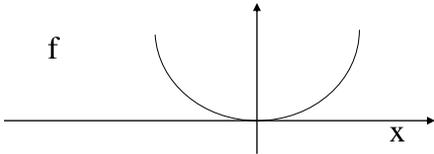
Linearizzazione e metodo di Gauss-Newton

A.A. 2017-2018 23/34 <http://borghese.di.unimi.it/>




Linearizzazione

- Descrizione differenziale locale di una funzione.



$y = ax^2$

Posso descrivere localmente in ogni punto la funzione come:

$$y + dy = f(x) + f'(x)dx \Rightarrow dy = f'(x) dx \Rightarrow dy = 2ax dx$$

A.A. 2017-2018 24/34 <http://borghese.di.unimi.it/>



Linearizzazione



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

$$dy = f(x_o) + \left. \frac{df(x)}{dx} \right|_{x=x_o} dx = y_o + \left. \frac{df(x)}{dx} \right|_{x=x_o} dx$$

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

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

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

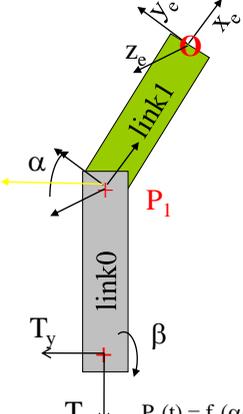
E' un'equazione lineare che descrive il comportamento della funzione $F(\cdot)$ nell'intorno del punto \mathbf{P}_o con i parametri \mathbf{W}_o .

A.A. 2017-2018
25/34
<http://borghese.di.unimi.it/>



Esempio di sistema





$P_x(t) = f_x(\alpha(t), \beta(t), T_x(t), T_y(t) | l_0, l_1).$
 $P_y(t) = f_y(\alpha(t), \beta(t), T_x(t), T_y(t) | l_0, l_1).$
 $P_z(t) = f_z(\alpha(t), \beta(t), T_x(t), T_y(t) | l_0, l_1).$

Voglio determinare α, β, T_x, T_y per ottenere un certo movimento dell'end-point.

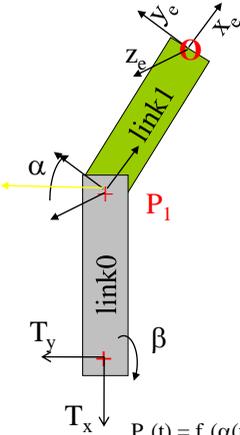


A.A. 2017-2018
26/34
<http://borghese.di.unimi.it/>



Esempio di "sistema"







Le funzioni legano la posizione dell'end point, uscita **P**, alla posizione degli angoli, α e β e della posizione della base, **T**, che rappresentano gli ingressi.

$$P_x(t) = f_x(\alpha(t), \beta(t), T_x(t), T_y(t) | l_0, l_1).$$

$$P_y(t) = f_y(\alpha(t), \beta(t), T_x(t), T_y(t) | l_0, l_1).$$

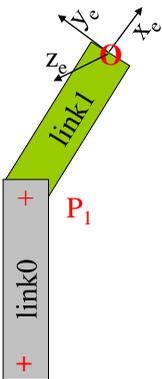
$$P_z(t) = f_z(\alpha(t), \beta(t), T_x(t), T_y(t) | l_0, l_1).$$

A.A. 2017-2018
27/34
<http://borghese.di.unimi.it/>



In forma matriciale





$$\begin{bmatrix} x_e \\ y_e \\ z_e \end{bmatrix} = \begin{bmatrix} l_1 \cos(\alpha + \beta) + l_0 \cos \beta + T_x \\ -l_1 \sin(\alpha + \beta) - l_0 \sin \beta + T_y \\ 0 \\ 1 \end{bmatrix}$$

Sono equazioni non-lineari nei parametri.

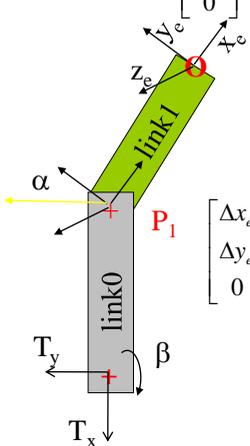
Non riesco a calcolare α , β , T_x , T_y per ottenere una certa Posizione dell'end-point

A.A. 2017-2018
28/34
<http://borghese.di.unimi.it/>



Rappresentazione linearizzata Sistema lineare





$$\begin{bmatrix} \Delta x_e \\ \Delta y_e \\ 0 \end{bmatrix} = \begin{bmatrix} -l_1 \sin(\alpha + \beta) & -l_1 \sin(\alpha + \beta) - l_0 \sin \beta & 1 & 0 \\ -l_1 \cos(\alpha + \beta) & -l_1 \cos(\alpha + \beta) - l_0 \cos \beta & 0 & 1 \\ 0 & 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} \Delta \alpha \\ \Delta \beta \\ \Delta T_x \\ \Delta T_y \end{bmatrix}$$

$\alpha = 90$ $l_0 = 2,5$
 $\beta = 0$ $l_1 = 2$



$$\begin{bmatrix} \Delta x_e \\ \Delta y_e \\ 0 \end{bmatrix} = \begin{bmatrix} -2 & -2 & 1 & 0 \\ 0 & -2.5 & 0 & 1 \\ 0 & 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} \Delta \alpha \\ \Delta \beta \\ \Delta T_x \\ \Delta T_y \end{bmatrix}$$

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

A.A. 2017-2018

29/34

<http://borghese.di.unimi.it/>



Minimizzazione di funzioni di più variabili



$\min(f(\mathbf{x}, \mathbf{w}))$ 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 costo, $f(\cdot)$.
 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 parametri $\mathbf{W}_{ini} = \{w_j\}_{ini}$.

A.A. 2017-2018

30/34

<http://borghese.di.unimi.it/>




Metodo di Gauss-Newton

- L'idea:

Inizializzazione:

- Inizializzo i parametri ad un valore iniziale.

Iterazioni:

- 1) Linearizzazione delle equazioni.
- 2) Stima dell'aggiornamento dei parametri nel modello linearizzato ai minimi quadrati (soluzione ottimale, minimo del problema linearizzato).
- 3) Correzione dei parametri.

Può essere pesante perchè richiede l'inversione della matrice di covarianza. Spesso si preferiscono utilizzare metodi di ottimizzazione del primo ordine.

A.A. 2017-2018 31/34 http://borghese.di.unimi.it/




In pratica

$\mathbf{y} = f(\mathbf{x})$ \mathbf{x}, \mathbf{y} vettori di N ed M elementi rispettivamente

$\mathbf{y}_0 = f(\mathbf{x}_0)$ $\mathbf{x}_0, \mathbf{y}_0$ valore iniziale

Iterazione di (nella prima iterazione $k = 0$):

- $\mathbf{d}\mathbf{y}_k + \mathbf{y}_k = (\sum \delta f(\mathbf{x}) / \mathbf{d}\mathbf{x})_{\mathbf{x}_k} \mathbf{d}\mathbf{x} + \mathbf{f}(\mathbf{x}_k)$ $(\sum \delta f(\mathbf{x}) / \mathbf{d}\mathbf{x})_{\mathbf{x}_k}$ are numbers!
- Si ottiene un sistema lineare
- Viene risolto come $\mathbf{d}\mathbf{x}_k = (\mathbf{A}\mathbf{A}^T)^{-1} \mathbf{A}^T \mathbf{d}\mathbf{y}_k$
- Si aggiorna il valore di \mathbf{x} come $\mathbf{x}_{k+1} = \mathbf{x}_k + \mathbf{d}\mathbf{x}_k$

Fino a convergenza

A.A. 2017-2018 32/34 http://borghese.di.unimi.it/



Evoluzione dei metodi del primo ordine

- α è un parametro critico. Se è troppo piccolo convergenza molto lenta, se è troppo grande overshooting.
- Ottimizzazione di α . Ad ogni passo viene calcolato α ottimale, per cui la funzione è decrescente (line search).

A.A. 2017-2018 33/34 http://borghese.di.unimi.it/



Sommario

Analisi dell'affidabilità della stima

Metodo del gradiente

Linearizzazione e metodo di Gauss-Newton

A.A. 2017-2018 34/34 http://borghese.di.unimi.it/