

# Sistemi Intelligenti Stimatori e identificazione - II

Alberto Borghese

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





# Overview



Densità di probabilità

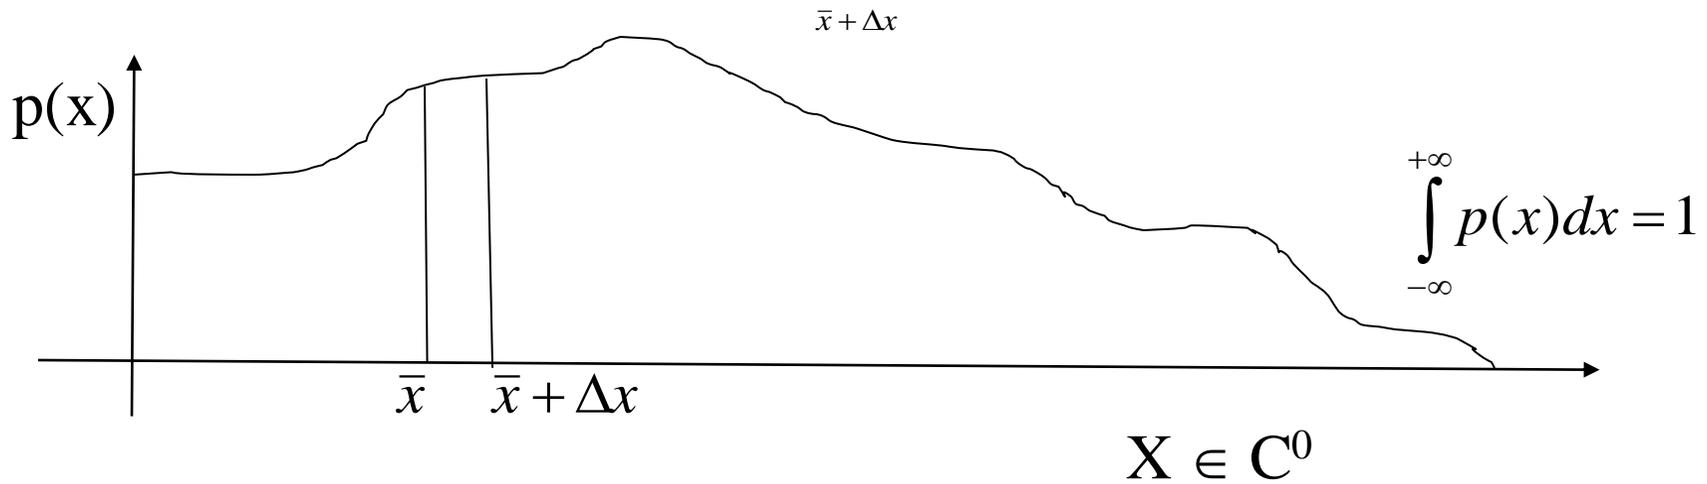
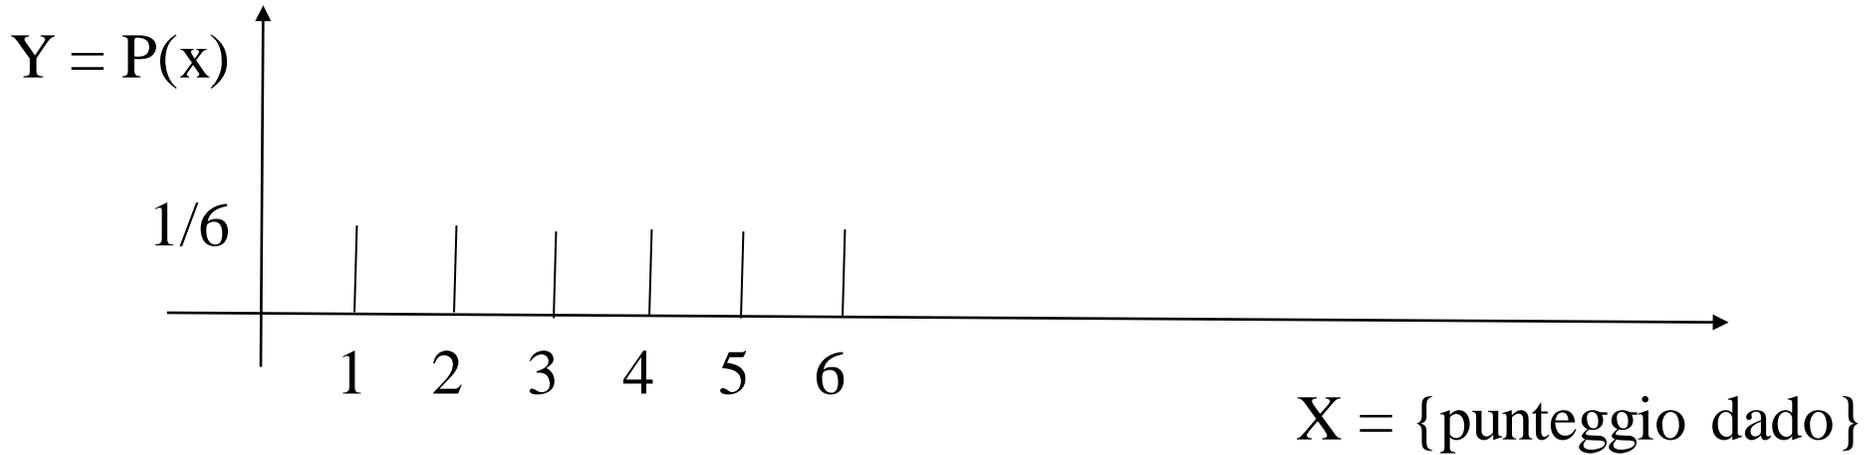
Stimatori

Modelli

Stima alla massima verosimiglianza di parametri di un modello



# La probabilità nel caso continuo



$$P(x \in [\bar{x}, \bar{x} + \Delta x]) = \int_{\bar{x}}^{\bar{x} + \Delta x} p(x) dx$$



# Definizione di $p(x)$

Caso discreto: prescrizione della probabilità per ognuno dei finiti valori che la variabile  $X$  può assumere:  $P(X)$ .

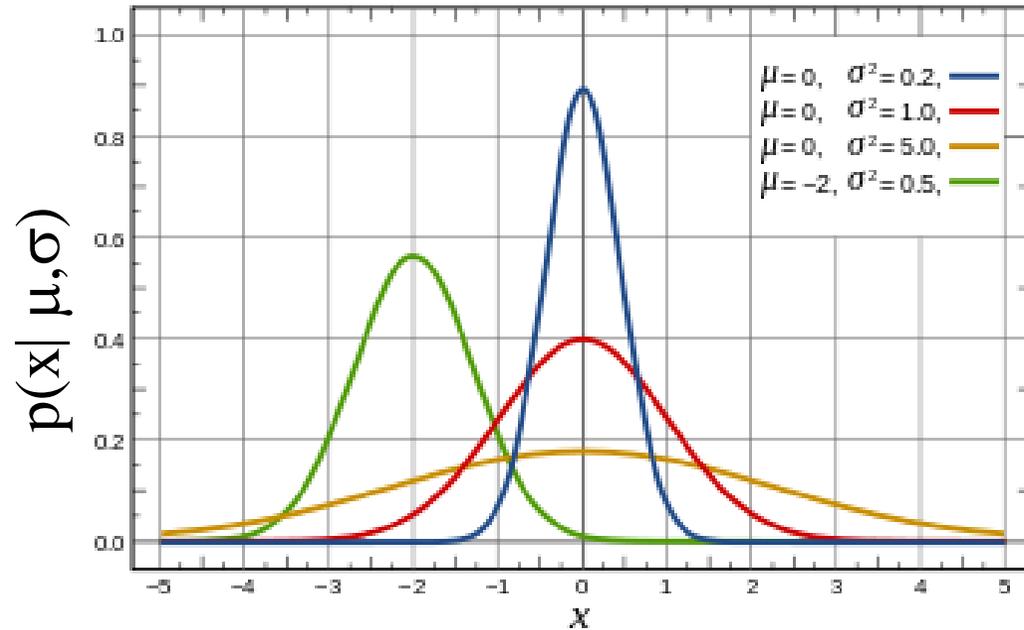
Caso continuo: i valori che  $X$  può assumere sono infiniti. Devo trovare un modo per definirne la probabilità. Descrizione **analitica** mediante la funzione densità di probabilità. Si considera la probabilità che  $x$  cada in un certo intervallo.

Valgono le stesse relazioni del caso discreto, dove alla somma si sostituisce l'integrale.

$$P(X = x \in [\bar{x}, \bar{x} + \Delta x]) = \int_{\bar{x}}^{\bar{x} + \Delta x} \int_{-\infty}^{+\infty} p(x, y) dx dy$$



# Distribuzioni notevoli: la Gaussiana



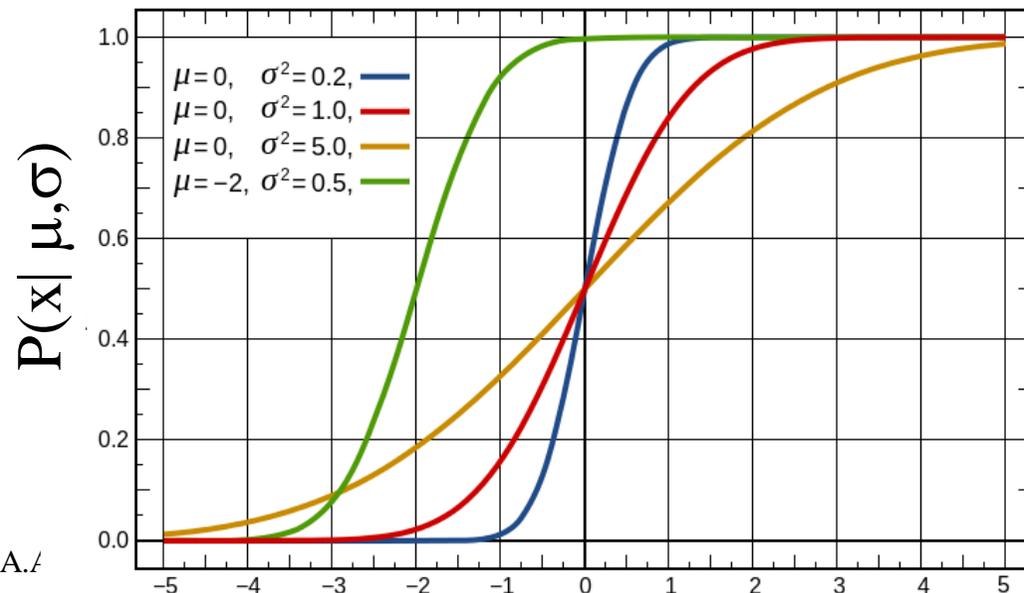
$$p(x | \mu, \sigma) = \frac{1}{(\sqrt{2\pi}) \Sigma^D} \cdot \exp \left[ -\frac{1}{2} \left( \frac{x - \mu}{\Sigma} \right)^2 \right]$$

D = dimensione, in questo caso D = 1

$$\Pr( | X - \mu | < \sigma ) = 0.68268$$

$$\Pr( | X - \mu | < 2\sigma ) = 0.95452$$

$$\Pr( | X - \mu | < 3\sigma ) = 0.9973$$





# I momenti di una variabile statistica

$$\mu^k(X) = \int_{-\infty}^{+\infty} (x - a)^k p(x) dx$$

Momento rispetto ad a, solitamente alla media

$$E[X] = \int_{-\infty}^{+\infty} (x - \mu) p(x) dx$$

Valore atteso (Expected value) di X = media distribuzione

$$E[(X - \mu)^2] = \int_{-\infty}^{+\infty} (x - \mu)^2 p(x) dx$$

Varianza ( $\sigma^2$ )

$$E[(X - \mu)^3] = \int_{-\infty}^{+\infty} (x - \mu)^3 p(x) dx$$

Asimmetria

$$E[(X - \mu)^4] = \int_{-\infty}^{+\infty} (x - \mu)^4 p(x) dx$$

Kurtosi – peso delle code di p(x)



# Overview



Densità di probabilità

Stimatori

Modelli

Stima alla massima verosimiglianza di parametri di un modello



# Stimatori

Variabili indipendenti:  $p(y_1, y_2) = p(y_1)p(y_2)$

Gaussiana: siano date due realizzazioni **indipendenti** della stessa variabile casuale  $Y$ ... Quale è la probabilità di misurare  $y_1$  nella prima realizzazione e  $y_2$  nella seconda realizzazione (estrazione con ripetizione)?

$$p(y_1 | \mu, \sigma) = \frac{1}{\sqrt{2\pi\sigma^2}} \cdot \exp\left[-\frac{1}{2}\left(\frac{y_1 - \mu}{\sigma}\right)^2\right]$$

$$p(y_2 | \mu, \sigma) = \frac{1}{\sqrt{2\pi\sigma^2}} \cdot \exp\left[-\frac{1}{2}\left(\frac{y_2 - \mu}{\sigma}\right)^2\right]$$

$$p(y_1, y_2 | \mu, \sigma) = p(y_1 | \mu, \sigma) \cdot p(y_2 | \mu, \sigma) =$$

$$= \frac{1}{\sqrt{2\pi\sigma^2}} \cdot \exp\left[-\frac{1}{2}\left(\frac{y_1 - \mu}{\sigma}\right)^2\right] \cdot \frac{1}{\sqrt{2\pi\sigma^2}} \cdot \exp\left[-\frac{1}{2}\left(\frac{y_2 - \mu}{\sigma}\right)^2\right]$$

Il risultato dipende dai parametri della Gaussiana che descrive l'errore di misura:  $\mu$  e  $\sigma$ .  
Qual'è il valore più ragionevole per  $\mu$  e  $\sigma$ ?



# Funzione di verosimiglianza

- Siano date **N** variabili casuali indipendenti... Quale è la **probabilità di misurare il vettore**  $[y_1, \dots, y_N]$ ?

$$p(y_1, y_2, \dots, y_N) = p(y_1) \cdot p(y_2) \cdot \dots \cdot p(y_N) = L(y_1, y_2, \dots, y_N)$$

- E' il prodotto delle probabilità semplici.
- Questa è la **Funzione di verosimiglianza** o **funzione di Likelihood**,  $L(\cdot)$



# Funzione di verosimiglianza (riassunto)



- Data una serie di misure  $y_i$   $i=1 \dots N$  di variabili casuali...
- ... Nota la distribuzione statistica dell'errore sulla misura espressa come densità di probabilità di ciascuna variabile casuale...
- ... Sotto l'ipotesi che le variabili siano tra loro indipendenti...
- ... E' possibile scrivere la funzione di verosimiglianza come il prodotto delle probabilità di ciascuna misura  $y_i$   $i=1 \dots N$ .



# Stima alla massima verosimiglianza caso Gaussiano



- Supponiamo il vettore  $\mathbf{y}$  corrisponda a  $N$  realizzazioni di una variabile Gaussiana a media  $\mu$ , deviazione standard  $\sigma$  ( $N$  misure indipendenti di una stessa quantità)
- La funzione verosimiglianza dipende da  $\mu$  e  $\sigma$  che non sono note a-priori.

$$\begin{aligned} L(y_1, y_2, \dots, y_N | \mu, \sigma) &= p(y_1) \cdot p(y_2) \cdot \dots \cdot p(y_N) = \\ &= \frac{1}{\sqrt{2\pi\sigma^2}} \cdot \exp\left[-\frac{1}{2}\left(\frac{y_1 - \mu}{\sigma}\right)^2\right] \cdot \dots \cdot \frac{1}{\sqrt{2\pi\sigma^2}} \cdot \exp\left[-\frac{1}{2}\left(\frac{y_N - \mu}{\sigma}\right)^2\right] = \end{aligned}$$

- Quale sarà il valore più verosimile per  $\mu$  e  $\sigma$ ?



# Stima alla massima verosimiglianza

- Se massimizziamo  $L=L(\mathbf{y} | \mu, \sigma)$  rispetto a  $\mu$  e  $\sigma$
- troviamo i parametri  $\mu, \sigma$  tali per cui è massima la probabilità di misurare il vettore di dati  $\mathbf{y} = \{y_i, i=1 \dots N\}$ .
- **Stima alla massima verosimiglianza.**
- Più in generale, le variabili possono avere densità di probabilità diverse, ciascuna descritta da un set di parametri. I parametri delle diverse densità di probabilità possono essere calcolati utilizzando l'approccio alla massima verosimiglianza...
- La funzione di verosimiglianza dipende dai parametri che definiscono le densità di probabilità delle variabili casuali che entrano nella verosimiglianza...
- Massimizzando la funzione di verosimiglianza rispetto a tali parametri se ne effettua la stima in modo tale che il vettore osservato  $\mathbf{y} = \{y_i\} i=1 \dots N$  sia massimamente probabile (massima verosimiglianza).
- E' una forma di problema inverso.



# Stima alla massima verosimiglianza Il caso gaussiano



- E' solitamente più facile minimizzare il logaritmo negativo della verosimiglianza,  $f(\cdot)$ , (prodotto  $\rightarrow$  sommatoria)

$$\begin{aligned} f(y_1, y_2, \dots, y_N | \mu, \sigma) &= -\ln[L(y_1, y_2, \dots, y_N | \mu, \sigma)] = \\ &= -\ln \left\{ \prod_{i=1}^N \frac{1}{\sqrt{2\pi\sigma}} \cdot \exp \left[ -\frac{1}{2} \left( \frac{y_i - \mu}{\sigma} \right)^2 \right] \right\} = \\ &= -\sum_{i=1}^N \ln \left\{ \frac{1}{\sqrt{2\pi\sigma}} \cdot \exp \left[ -\frac{1}{2} \left( \frac{y_i - \mu}{\sigma} \right)^2 \right] \right\} = \\ &= N \cdot \ln(\sqrt{2\pi}) + N \cdot \ln(\sigma) + \sum_{i=1}^N \left[ \frac{1}{2} \left( \frac{y_i - \mu}{\sigma} \right)^2 \right] \end{aligned}$$



# Determino $\mu$

- Per trovare il minimo, poniamo a zero le derivate:

$$\frac{\partial f(y_1, y_2, \dots, y_N | \mu, \sigma)}{\partial \mu} = \frac{\partial}{\partial \mu} \left\{ N \cdot \ln(\sqrt{2\pi}) + N \cdot \ln(\sigma) + \sum_{i=1}^N \left[ \frac{1}{2} \cdot \left( \frac{y_i - \mu}{\sigma} \right)^2 \right] \right\} =$$

$$= 0 + 0 + \sum_{i=1}^N \frac{1}{2} \cdot \left( \frac{y_i - \mu}{\sigma} \right) \cdot 2 \cdot \left( -\frac{1}{\sigma} \right) = -\frac{1}{\sigma^2} \cdot \sum_{i=1}^N (y_i - \mu) = 0 \Rightarrow$$

$$\sum_{i=1}^N (y_i - \mu) = 0 \Rightarrow \sum_{i=1}^N y_i = N \cdot \mu \Rightarrow \mu = \frac{\sum_{i=1}^N y_i}{N}$$

*Media campionaria!*



# Determino $\sigma$



- Per trovare il minimo, poniamo a zero le derivate:

$$\frac{\partial f(y_1, y_2, \dots, y_N | \mu, \sigma)}{\partial \sigma} = \frac{\partial}{\partial \sigma} \left\{ N \cdot \ln(\sqrt{2\pi}) + N \cdot \ln(\sigma) + \sum_{i=1}^N \left[ \frac{1}{2} \cdot \left( \frac{y_i - \mu}{\sigma} \right)^2 \right] \right\} =$$

$$= 0 + \frac{N}{\sigma} + \sum_{i=1}^N 2 \frac{1}{2} \cdot \left( \frac{y_i - \mu}{\sigma} \right) \cdot (y_i - \mu) \cdot \left( -\frac{1}{\sigma^2} \right) =$$

$$= \frac{N}{\sigma} - \frac{1}{\sigma^3} \sum_{i=1}^N (y_i - \mu)^2 = 0 \Rightarrow N - \frac{1}{\sigma^2} \sum_{i=1}^N (y_i - \mu)^2 = 0 \Rightarrow$$

$$N \cdot \sigma^2 = \sum_{i=1}^N (y_i - \mu)^2 \Rightarrow \sigma^2 = \frac{\sum_{i=1}^N (y_i - \mu)^2}{N}$$

*Varianza campionaria!*



# Overview

Densità di probabilità

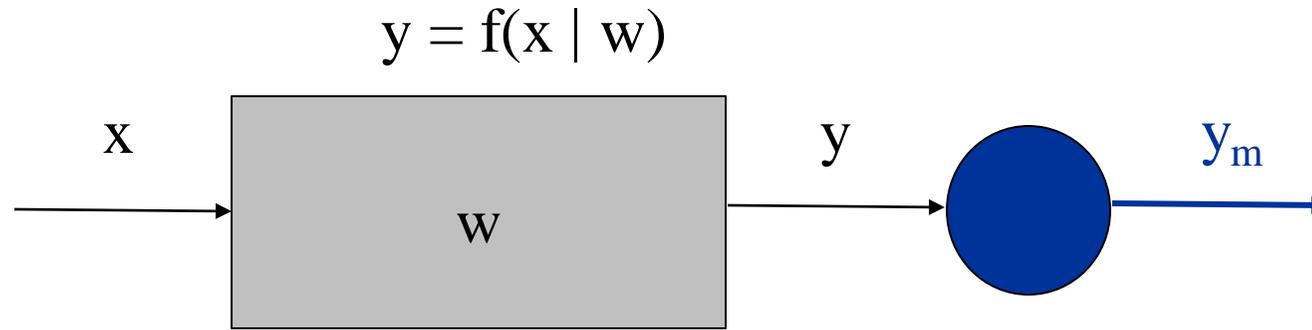
Stimatori

**Modelli**

Stima alla massima verosimiglianza di parametri di un modello



# Modello



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

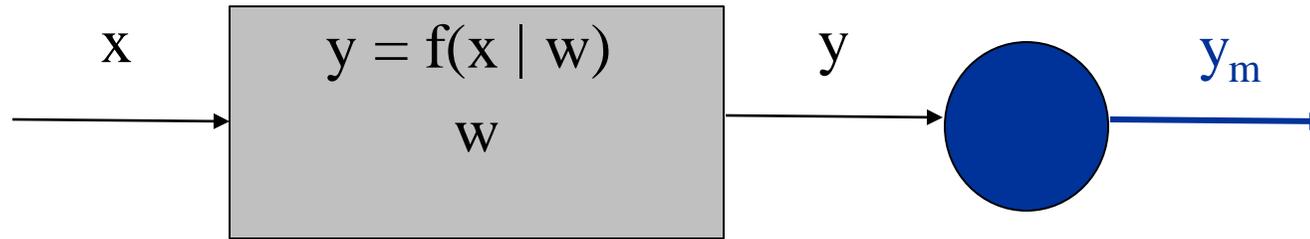
Control / Prediction: determine  $\{y\}$  from  $\{x\}, \{w\}$

**Inverse problem: determine cause  $\{x\}$  from  $\{y_m\}, \{w\}$**

**Inverse problem: Identification: determine  $\{w\}$  from  $\{x\}, \{y_m\}$  -  
*Supervised learning***



# Controllo/Predizione



$x$  – causa  $\Rightarrow$   $y$  – effetto

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

$$p(y_{m1} | \mu, \sigma) = \frac{1}{\sqrt{2\pi\sigma^2}} \cdot \exp\left[-\frac{1}{2}\left(\frac{y_1 - \mu}{\sigma}\right)^2\right]$$

$$p(y_1 | \mu, \sigma) = f\left(\frac{1}{\sqrt{2\pi\sigma^2}} \cdot \exp\left[-\frac{1}{2}\left(\frac{f(x_1 | w) - \mu}{\sigma}\right)^2\right]\right)$$

# Controllo/Predizione



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

$$p(y_1 | \mu, \sigma) = f \left( \frac{1}{\sqrt{2\pi\sigma^2}} \cdot \exp \left[ -\frac{1}{2} \left( \frac{f(x_1 | w) - \mu}{\sigma} \right)^2 \right] \right)$$

$$p(y_2 | \mu, \sigma) = f \left( \frac{1}{\sqrt{2\pi\sigma^2}} \cdot \exp \left[ -\frac{1}{2} \left( \frac{f(x_2 | w) - \mu}{\sigma} \right)^2 \right] \right)$$

$$p(y_3 | \mu, \sigma) = f \left( \frac{1}{\sqrt{2\pi\sigma^2}} \cdot \exp \left[ -\frac{1}{2} \left( \frac{f(x_3 | w) - \mu}{\sigma} \right)^2 \right] \right)$$

Siamo in grado di predire  $y$ :  $p(y)$  per ogni  $x$  (dato il modello  $f(\cdot)$ )



# Funzione di verosimiglianza

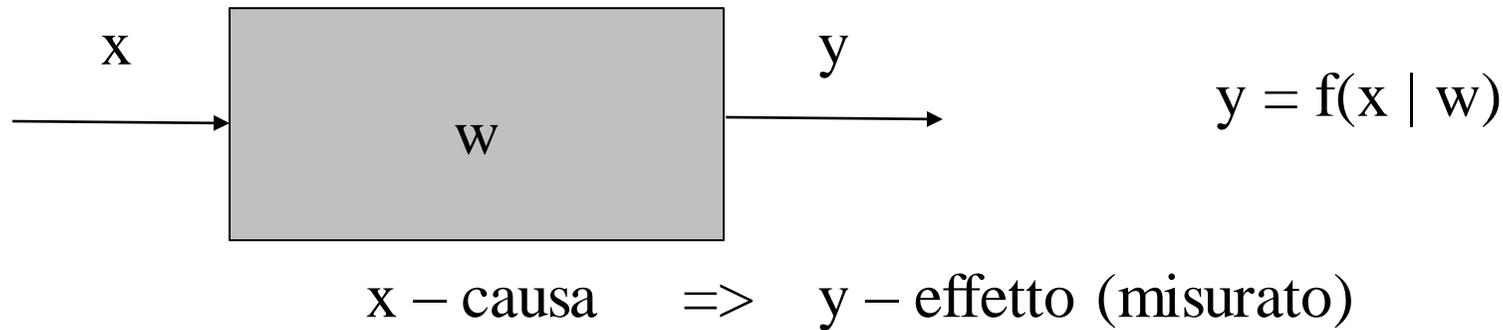
- Siano date **N** **variabili casuali indipendenti**... Quale è la **probabilità di misurare il vettore**  $[y_1, \dots, y_N]$ ?

$$p(y_1, y_2, \dots, y_N) = p(y_1) \cdot p(y_2) \cdot \dots \cdot p(y_N) = L(y_1, y_2, \dots, y_N)$$

- E' il prodotto delle probabilità semplici.
- Questa è la **Funzione di verosimiglianza** o **funzione di Likelihood**,  $L(\cdot)$
- In questo caso le  $y$  sono legate alle  $x$  da  $f(x)$ .



# I due problemi inversi con i modelli



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

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

$$p(y_1, y_2, \dots, y_N) = p(y_1) \cdot p(y_2) \cdot \dots \cdot p(y_N) = L(y_1, y_2, \dots, y_N)$$



$$p(y_1, y_2, \dots, y_N | x, w) = p(y_1 | x_1, w) \cdot p(y_2 | x_2, w) \cdot \dots \cdot p(y_N | x_N, w) = L(y_1, y_2, \dots, y_N | x, w)$$



# Overview

Densità di probabilità

Stimatori

Modelli

Stima alla massima verosimiglianza di parametri di un modello

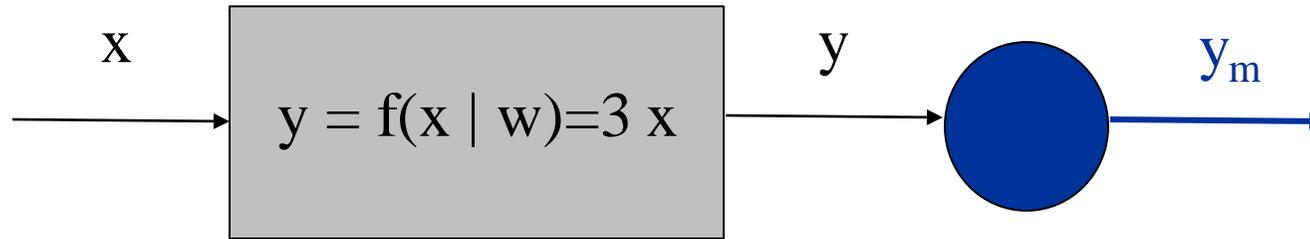


# Stima alla massima verosimiglianza di un modello

- Se massimizziamo  $L=L(\mathbf{y} \mid \mathbf{x}, \mathbf{w})$  rispetto a  $\mathbf{w}$
- troviamo i parametri  $\mathbf{w}$  tali per cui è massima la probabilità di misurare il vettore di dati  $\mathbf{y} = \{y_i, i=1 \dots N\}$ .
- **Stima alla massima verosimiglianza.**
- Più in generale, le variabili possono avere densità di probabilità diverse, ciascuna descritta da un set di parametri. I parametri delle diverse densità di probabilità possono essere calcolati utilizzando l'approccio alla massima verosimiglianza...
- La funzione di verosimiglianza dipende dai parametri che definiscono le densità di probabilità delle variabili casuali che entrano nella verosimiglianza...
- Massimizzando la funzione di verosimiglianza rispetto a tali parametri se ne effettua la stima in modo tale che il vettore osservato  $\mathbf{y} = \{y_i\} i=1 \dots N$  sia massimamente probabile (massima verosimiglianza).



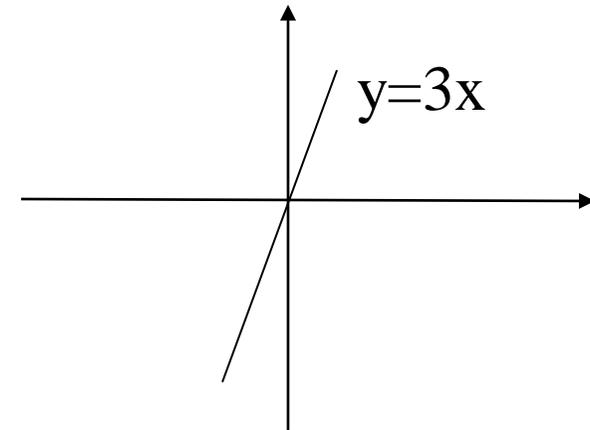
# Modello lineare



$$x = 0, \quad y = 0, \quad y_m = 0.0001$$

$$x = +1, \quad y = +3, \quad y_m = 2.997$$

$$x = -1, \quad y = -3, \quad y_m = -3.011$$



$$p(y_1, y_2, \dots, y_N) = p(y_1) \cdot p(y_2) \cdot \dots \cdot p(y_N) = L(y_1, y_2, \dots, y_N | k, \mu, \sigma)$$

Unica incognita è  $k$



# Derivazione del parametro k

$$\underset{k}{\text{Max}}(L(y_1, y_2, \dots, y_N | k, \mu, \sigma)) = -\underset{k}{\text{min}}(\log(L(y_1, y_2, \dots, y_N | k, \mu, \sigma))) =$$

$$-\underset{k}{\text{min}} \left( \log \Pi_i \left( \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2} \frac{(y_{mi} - y_i)^2}{\sigma^2}} \right) \right) =$$

NB  $y_i = kx_i$   
 $\langle y_m - y_i \rangle = \mu$

$$-\underset{k}{\text{min}} \left( \sum_i \log \left( \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2} \frac{(y_{mi} - y_i - \mu)^2}{\sigma^2}} \right) \right) = +\underset{k}{\text{min}} \left( 3\sqrt{2\pi}\sigma + \sum_i \frac{1}{2} \frac{(y_{mi} - y_i - \mu)^2}{\sigma^2} \right) =$$

$$+\underset{k}{\text{min}} \left( 3\sqrt{2\pi}\sigma + \frac{1}{2} \frac{(0.001 - k \cdot 0 - \mu)^2}{\sigma^2} + \frac{1}{2} \frac{(2.997 - k \cdot 1 - \mu)^2}{\sigma^2} + \frac{1}{2} \frac{(-3.011 - k \cdot (-1) - \mu)^2}{\sigma^2} \right) =$$



# Minimizzazione di $-\log(L)$

$$\min_k F(.) = \left( 3\sqrt{2\pi}\sigma + \frac{1}{2} \frac{(0.001 - k \cdot 0 - \mu)^2}{\sigma^2} + \frac{1}{2} \frac{(2.997 - k \cdot 1 - \mu)^2}{\sigma^2} + \frac{1}{2} \frac{(-3.011 - k \cdot (-1) - \mu)^2}{\sigma^2} \right)$$

$$\frac{\partial F(.)}{\partial k} = 0$$

$$\frac{\partial \left( 3\sqrt{2\pi}\sigma + \frac{1}{2} \frac{(0.001 - k \cdot 0 - \mu)^2}{\sigma^2} + \frac{1}{2} \frac{(2.997 - k \cdot 1 - \mu)^2}{\sigma^2} + \frac{1}{2} \frac{(-3.011 - k \cdot (-1) - \mu)^2}{\sigma^2} \right)}{\partial k} = 0$$

$$\frac{(0.001 - k \cdot 0 - \mu) \cdot 0}{\sigma^2} + \frac{(2.997 - k \cdot 1 - \mu)(-1)}{\sigma^2} + \frac{(-3.011 - k \cdot (-1) - \mu)(+1)}{\sigma^2} = 0$$

$$\frac{1}{\sigma^2} (-2.997 + k - 3.011 + k) + \frac{\mu}{\sigma^2} - \frac{\mu}{\sigma^2} = 0$$

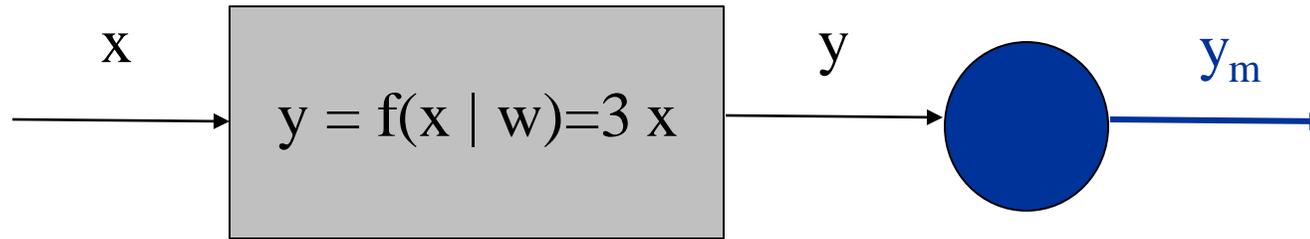
$$\frac{1}{\sigma^2} (-2.997 + k - 3.011 + k) = 0 \implies -6.008 + 2k = 0$$

$$k = 3.004$$



Eliminazione della polarizzazione introdotta dal rumore. Qui rumore a media nulla,  $\mu = 0$

# Modello lineare

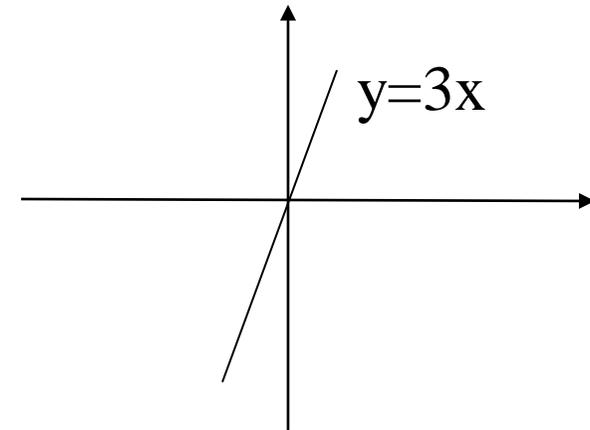


$$x = 0, \quad y = 0, \quad y_m = 5.0001$$

$$x = +1, \quad y = +3, \quad y_m = 5.997$$

$$x = -1, \quad y = -3, \quad y_m = -0.011$$

Rumore con  $\mu = 3$  e stessa varianza



$$p(y_1, y_2, \dots, y_N) = p(y_1) \cdot p(y_2) \cdot \dots \cdot p(y_N) = L(y_1, y_2, \dots, y_N | k, \mu, \sigma)$$

Unica incognita è  $k$



# Minimizzazione di $-\log(L)$

$$\min_k F(.) = \left( 3\sqrt{2\pi}\sigma + \frac{1}{2} \frac{(3.001 - k \cdot 0 - \mu)^2}{\sigma^2} + \frac{1}{2} \frac{(5.997 - k \cdot 1 - \mu)^2}{\sigma^2} + \frac{1}{2} \frac{(-0.011 - k \cdot (-1) - \mu)^2}{\sigma^2} \right)$$

$$\frac{\partial F(.)}{\partial k} = 0$$

$$\frac{\partial \left( 3\sqrt{2\pi}\sigma + \frac{1}{2} \frac{(3.001 - k \cdot 0 - \mu)^2}{\sigma^2} + \frac{1}{2} \frac{(5.997 - k \cdot 1 - \mu)^2}{\sigma^2} + \frac{1}{2} \frac{(-0.011 - k \cdot (-1) - \mu)^2}{\sigma^2} \right)}{\partial k} = 0$$

$$\frac{(3.001 - k \cdot 0 - \mu) \cdot 0}{\sigma^2} + \frac{(5.997 - k \cdot 1 - \mu)(-1)}{\sigma^2} + \frac{(-0.011 - k \cdot (-1) - \mu)(+1)}{\sigma^2} = 0$$

$$\frac{1}{\sigma^2} (-5.997 + k - 0.011 + k) + \frac{\mu}{\sigma^2} - \frac{\mu}{\sigma^2} = 0$$

$$\frac{1}{\sigma^2} (-5.997 + k - 0.011 + k) = 0 \implies -6.008 + 2k = 0$$

$$k = 3.004$$



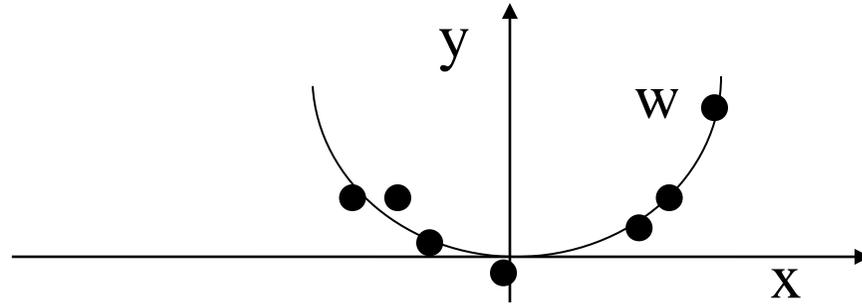
Eliminazione della polarizzazione introdotta dal rumore. Qui rumore a media non nulla,  $\mu = 3$ . Perché stesso risultato? (analizzate il residuo).



# Esempio di Modello - II

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

$$y = a x^2$$



**Identificazione:** determino i parametri  $w$  che fittano i punti campionati. La funzione  $z=f(x)$  varie forma con il parametro  $a$  in questo caso. A partire da insiemi di  $\mathbf{P}\{x,z\}$  determino  $w$ .

**Predizione:** 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.



# Overview

Densità di probabilità

Stimatori

Modelli

Stima alla massima verosimiglianza di parametri di un modello