



# Massima verosimiglianza

I. Frosio

AIS Lab.

[frosio@dsi.unimi.it](mailto:frosio@dsi.unimi.it)

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



# Overview

- Nozioni di base
- Funzione di verosimiglianza
- Stima alla massima verosimiglianza
- Il caso Gaussiano
- Sistemi ai minimi quadrati
- Il caso Poissoniano
- Stima di due rette



# Nozioni di base

- Variabile casuale: variabile che può assumere un valore secondo una densità di probabilità.
- Es. distribuzione gaussiana, poissoniana, binomiale, uniforme, ...
- Gaussiana (media  $\mu$ , std  $\sigma$ ):

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



# Nozioni di base

- *Gaussiana*: quale è la probabilità che la variabile  $x$  assuma il valore  $y$ ?

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



# Nozioni di base

- **Gaussiana:** siano date due realizzazioni **indipendenti** della stessa variabile casuale  $x$ ... Quale è la probabilità di misurare  $y_1$  nella prima realizzazione e  $y_2$  nella seconda realizzazione?

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

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

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



# Funzione di verosimiglianza



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

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

- Questa è la FUNZIONE DI VEROSIMIGLIANZA (Likelihood,  $L$ ).



# Funzione di verosimiglianza (riassunto)



- Data una serie di misure  $y_i$   $i=1\dots N$  di variabili casuali...
- ... Note le 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



- Supponiamo il vettore  $y$  corrisponda a  $N$  realizzazioni di una variabile gaussiana a media  $\mu$ , std  $\sigma$ .
- La funzione verosimiglianza dipende da  $\mu$  e  $\sigma$ .

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



# Stima alla massima verosimiglianza

- Se massimizziamo  $L=L(y|\mu,\sigma)$ ...
- Troviamo i parametri  $\mu,\sigma$  tali per cui è massima la probabilità di misurare il vettore di dati  $y$ .
- STIMA ALLA MASSIMA VEROSIMIGLIANZA.
- Att.ne! In generale, le variabili possono avere densità di probabilità diverse, ciascuna descritta da un set di parametri stimabili con l'approccio alla massima verosimiglianza...



# Stima alla massima verosimiglianza (riassunto)

- 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  $y_i \quad i=1...N$  sia massimamente probabile (massima verosimiglianza).



# Il caso gaussiano

- Nella maggior parte dei casi viene assunto rumore gaussiano sui dati.
- $N$  misurazioni di una variabile casuale distribuita in modo gaussiano.
- Si vogliono stimare media e varianza della gaussiana.

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



# Il caso gaussiano

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

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



# Il caso gaussiano

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

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

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

$$\sum_{i=1}^N (y_i - \mu) = 0 \Rightarrow \sum_{i=1}^N y_i = N \cdot \mu \Rightarrow \mu = \frac{\sum_{i=1}^N y_i}{N} \quad \underline{\underline{\text{Media campionaria!}}}$$



# Il caso gaussiano

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

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

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

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

$$N \cdot \sigma^2 = \sum_{i=1}^N (y_i - \mu)^2 \Rightarrow \sigma^2 = \frac{\sum_{i=1}^N (y_i - \mu)^2}{N} \quad \underline{\underline{\text{Varianza campionaria!}}}$$



# Il caso gaussiano (riassunto)



- Date  $N$  misurazioni di una variabile casuale con distribuzione gaussiana, posso scrivere la funzione di verosimiglianza;
- Massimizzando la funzione di verosimiglianza (minimizzando il logaritmo negativo della verosimiglianza) rispetto a  $\mu$  e  $\sigma$ , ottengo una stima della media e varianza della distribuzione;
- Tali stime coincidono con la media e la varianza campionarie.



# Stima ai minimi quadrati e verosimiglianza



- Si consideri il problema di stima di una retta:
- Sia  $y = mx + b$  una retta, con  $m$  e  $b$  incogniti;
- Siano  $y_i=1\dots N$  una serie di  $N$  misure effettuate per  $x_i=x_1\dots x_N$ .
- Le misure  $y_i$  siano affette da rumore gaussiano a media nulla.
- In pratica:  $y_i = G(mx_i+b, \sigma^2)$ , dove  $G(\mu, \sigma^2)$  indica una distribuzione gaussiana a media  $\mu$  e varianza  $\sigma^2$ .

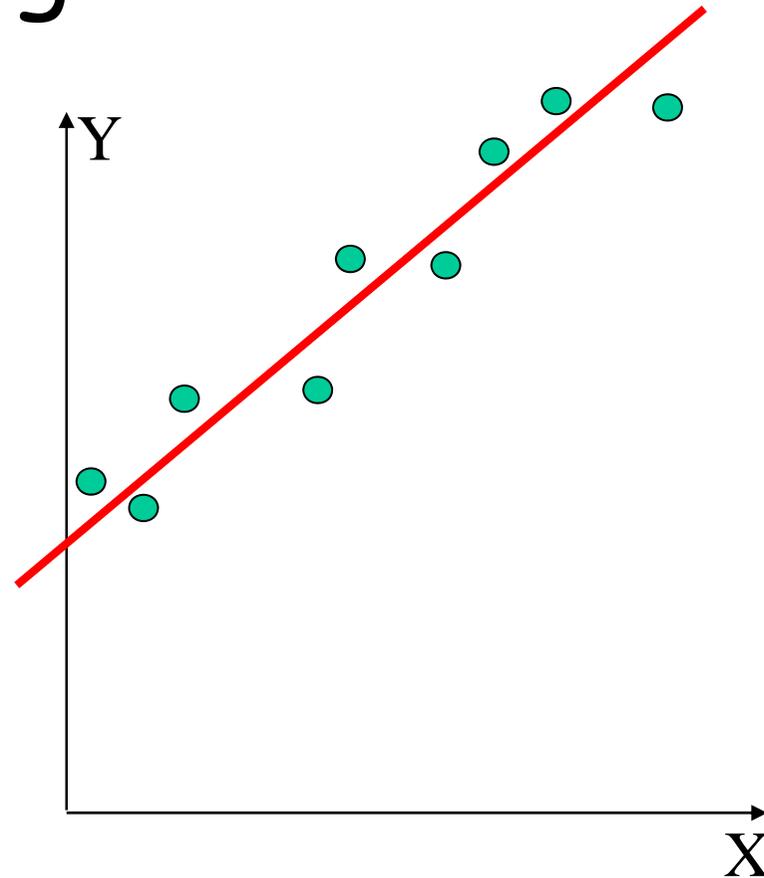


# Stima ai minimi quadrati e verosimiglianza



Il problema di stima della retta:

- Date le misure  $y_i$   $i=1\dots N$  per le posizioni  $x_i$   $i=1\dots N$ ...
- ... Trovare i parametri  $m$  e  $b$  della retta  $y=mx+b$  cui appartengono i dati.





# Stima ai minimi quadrati e verosimiglianza



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

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



# Stima ai minimi quadrati e verosimiglianza



- Scriviamo allora il logaritmo negativo della verosimiglianza:

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



# Stima ai minimi quadrati e verosimiglianza



- E massimizziamolo ponendo a zero le derivate rispetto a  $m$  e  $b$ :

$$\begin{aligned}\frac{\partial f(m,b)}{\partial m} &= \frac{\partial}{\partial m} \left[ -\sum_{i=1}^N \ln\left(\frac{1}{\sqrt{2\pi}\sigma}\right) + \frac{1}{2\sigma^2} \sum_{i=1}^N (y_i - m \cdot x_i - b)^2 \right] = \\ &= 0 + \frac{1}{2\sigma^2} \sum_{i=1}^N (y_i - m \cdot x_i - b) \cdot 2 \cdot (-x_i) = \\ &= \frac{1}{\sigma^2} \sum_{i=1}^N (y_i - m \cdot x_i - b) \cdot x_i = 0 \Rightarrow \sum_{i=1}^N (y_i - m \cdot x_i - b) \cdot x_i = 0 \Rightarrow \\ &\left[ \sum_{i=1}^N (y_i \cdot x_i) \right] - m \cdot \left[ \sum_{i=1}^N (x_i^2) \right] - b \cdot \left[ \sum_{i=1}^N (x_i) \right] = 0 \Rightarrow \\ &m \cdot \left[ \sum_{i=1}^N (x_i^2) \right] + b \cdot \left[ \sum_{i=1}^N (x_i) \right] = \left[ \sum_{i=1}^N (y_i \cdot x_i) \right]\end{aligned}$$



# Stima ai minimi quadrati e verosimiglianza



- E massimizziamolo ponendo a zero le derivate rispetto a  $m$  e  $b$ :

$$\frac{\partial f(m, b)}{\partial b} = \frac{\partial}{\partial b} \left[ -\sum_{i=1}^N \ln \left( \frac{1}{\sqrt{2\pi}\sigma} \right) + \frac{1}{2\sigma^2} \sum_{i=1}^N (y_i - m \cdot x_i - b)^2 \right] =$$

$$= 0 + \frac{1}{2\sigma^2} \sum_{i=1}^N (y_i - m \cdot x_i - b) \cdot 2 \cdot (-1) =$$

$$= \frac{1}{\sigma^2} \sum_{i=1}^N (y_i - m \cdot x_i - b) = 0 \Rightarrow \sum_{i=1}^N (y_i - m \cdot x_i - b) = 0 \Rightarrow$$

$$\left[ \sum_{i=1}^N (y_i) \right] - m \cdot \left[ \sum_{i=1}^N (x_i) \right] - b \cdot \left[ \sum_{i=1}^N (1) \right] = 0 \Rightarrow$$

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



# Stima ai minimi quadrati e verosimiglianza



- Ponendo a zero le due derivate abbiamo dunque ottenuto un sistema lineare che permette di calcolare  $m$  e  $b^*$ :

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

- $*Ax=b \rightarrow x=A^{-1}b$



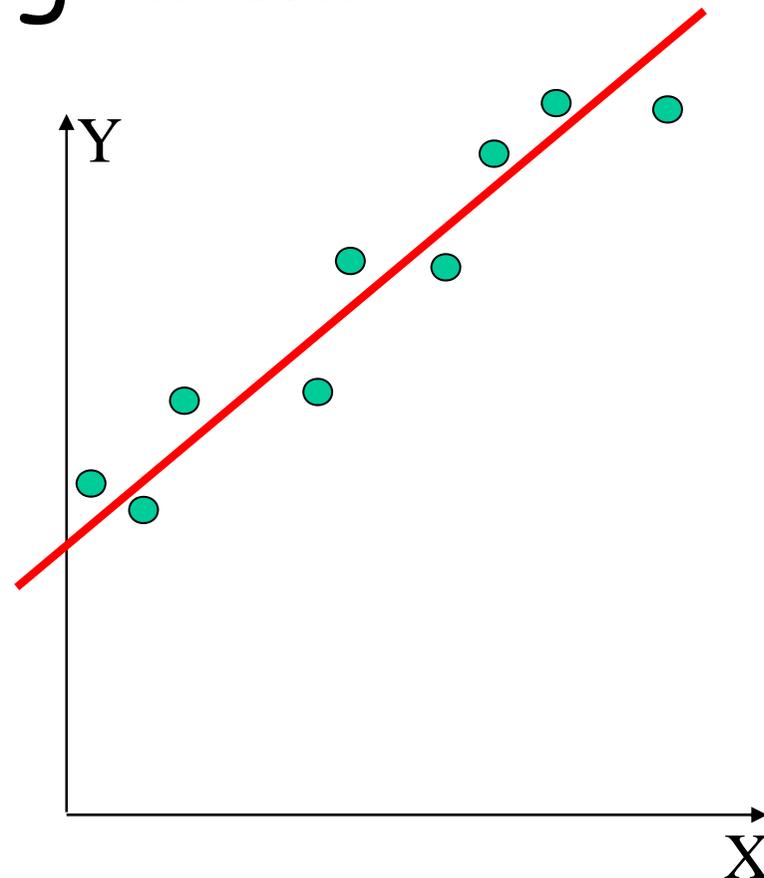
# Stima ai minimi quadrati e verosimiglianza



Riformuliamo il problema della retta come un problema ai minimi quadrati.

Per ogni punto, dovrebbe valere  $y_i = mx_i + b$ .

Cerchiamo i parametri  $m$  e  $b$  tali per cui questa condizione è verificata "al meglio" nel senso dei minimi quadrati.





# Stima ai minimi quadrati e verosimiglianza



- 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.x.  $\|(Ax-b)^T(Ax-b)\|$  è minima (minimizzazione dei quadrati dei residui).



# Stima ai minimi quadrati e verosimiglianza



- Nella soluzione ai minimi quadrati del sistema lineare  $Ax=b$  si definisce un vettore errore  $e=Ax-b$ ;
- Nel caso di soluzione "perfetta"  $e=0$ ;
- 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.  $e^T e = \sum_i e_i^2$  è minimo.



# Stima ai minimi quadrati e verosimiglianza



- La soluzione ai minimi quadrati del sistema  $Ax=b$  si ottiene da:
- $A^T Ax = A^T b \rightarrow x = (A^T A)^{-1} A^T b$ .
- Scriviamo allora  $A^T A$  e  $A^T b$  per il nostro sistema:

$$A^T A \rightarrow \begin{bmatrix} x_1 & x_2 & \dots & x_N \\ 1 & 1 & \dots & 1 \end{bmatrix} \begin{bmatrix} x_1 & 1 \\ x_2 & 1 \\ \dots & \dots \\ x_N & 1 \end{bmatrix} = \begin{bmatrix} \sum_{i=1}^N (x_i^2) & \sum_{i=1}^N (x_i) \\ \sum_{i=1}^N (x_i) & \sum_{i=1}^N (1) \end{bmatrix}$$

$$A^T b \rightarrow \begin{bmatrix} x_1 & x_2 & \dots & x_N \\ 1 & 1 & \dots & 1 \end{bmatrix} \begin{bmatrix} y_1 \\ y_2 \\ \dots \\ y_N \end{bmatrix} = \begin{bmatrix} \sum_{i=1}^N (y_i \cdot x_i) \\ \sum_{i=1}^N (y_i) \end{bmatrix}$$



# Stima ai minimi quadrati e verosimiglianza



- Se confrontiamo il sistema lineare ottenuto dalla massimizzazione della verosimiglianza (slide 22) con il sistema lineare  $A^T Ax = A^T b$  per la soluzione del sistema ai minimi quadrati (slide 27) ci accorgiamo che... Sono uguali!

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

- In generale: LA SOLUZIONE DEL PROBLEMA DI MASSIMIZZAZIONE DELLA VEROSMIGLIANZA E' EQUIVALENTE ALLA SOLUZIONE DEL PROBLEMA AI MINIMI QUADRATI IN CASO DI DISTRIBUZIONE GAUSSIANA (RUMORE GAUSSIANO SUL VETTORE DEI DATI MISURATI Y).



# Stima ai minimi quadrati e verosimiglianza



- Anche nella formulazione di  $f(m,b)$  è evidente l'analogia con i minimi quadrati (slide 18):

$$f(m,b) = -\sum_{i=1}^N \ln\left(\frac{1}{\sqrt{2\pi\sigma}}\right) + \frac{1}{2\sigma^2} \sum_{i=1}^N (y_i - mx_i - b)^2$$

$$\min_{m,b} f(m,b) = \min_{m,b} \frac{1}{2\sigma^2} \sum_{i=1}^N (y_i - mx_i - b)^2 =$$

$$\min_{m,b} \sum_{i=1}^N (y_i - mx_i - b)^2$$

Minizzazione dei quadrati dei residui!



# Stima ai minimi quadrati e verosimiglianza (riassunto)



- La formulazione di un problema nei termini dei minimi quadrati rappresenta un caso particolare di problema di massimizzazione della verosimiglianza.
- In particolare, l'approccio alla verosimiglianza e ai minimi quadrati sono equivalenti nel caso di distribuzione gaussiana della variabili misurate.



# Il caso poissoniano

- La formulazione di un problema di verosimiglianza permette di trattare casi in cui la variabili misurate abbiano distribuzione diversa da quella gaussiana.
- Consideriamo ad esempio una variabile poissoniana (es. conteggio di un numero limitato di fotoni, es. radiografia).
- Media della variabile casuale (=varianza nel caso della poisson) =  $\lambda$ .

$$p(y_i | \lambda) = \frac{\lambda^{y_i} \cdot e^{-\lambda}}{y_i!}$$



# Il caso poissoniano

- Sia  $y$  un vettore di misure di una variabile poissoniana. Si vuole stimare la media della variabile.
- Scriviamo il logaritmo negativo della funzione di verosimiglianza:

$$\begin{aligned} -\ln(L) &= -\sum_{i=1}^N \ln[p(y_i | \lambda)] = -\sum_{i=1}^N \ln\left[\frac{\lambda^{y_i} \cdot e^{-\lambda}}{y_i!}\right] = \\ &= -\sum_{i=1}^N \ln[\lambda^{y_i}] - \sum_{i=1}^N \ln[e^{-\lambda}] - \sum_{i=1}^N \ln\left[\frac{1}{y_i!}\right] = \\ &= -\sum_{i=1}^N y_i \cdot \ln[\lambda] + \sum_{i=1}^N \lambda + \sum_{i=1}^N \ln[y_i!] = \\ &= -\ln(\lambda) \cdot \sum_{i=1}^N y_i + N \cdot \lambda + \sum_{i=1}^N \ln[y_i!] \end{aligned}$$



# Il caso poissoniano

- Massimizziamo la verosimiglianza rispetto a  $\lambda$  (ponendo a zero la derivata):

$$\begin{aligned}\frac{\partial}{\partial \lambda} [-\ln(L)] &= \frac{\partial}{\partial \lambda} \left[ -\ln(\lambda) \cdot \sum_{i=1}^N y_i + N \cdot \lambda + \sum_{i=1}^N \ln[y_i!] \right] = \\ &= -\frac{1}{\lambda} \cdot \sum_{i=1}^N y_i + N + 0 = 0 \Rightarrow \lambda = \frac{\sum_{i=1}^N y_i}{N}\end{aligned}$$

- Otteniamo anche in questo caso la media campionaria come stima della media della distribuzione.



# Il caso poissoniano (riassunto)



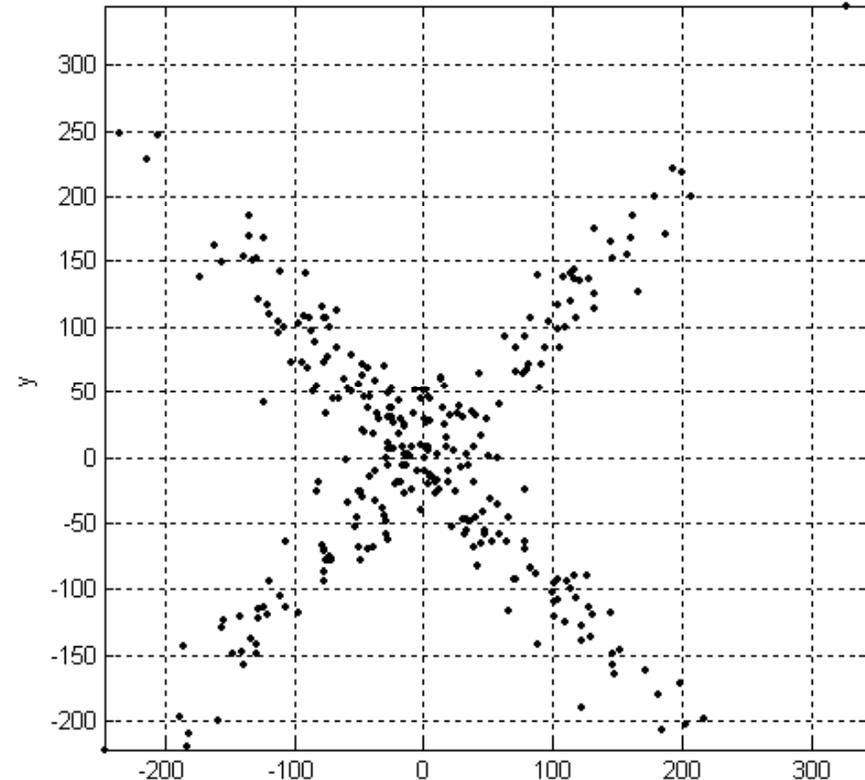
- L'approccio alla massima verosimiglianza permette di effettuare stime di parametri, data una qualsiasi densità di probabilità dei dati misurati (non solo gaussiana, poisson!)



# Stima di due rette



- Proviamo ora a complicare il problema: si vogliono stimare i coefficienti angolari di due rette passanti per l'origine.
- I dati misurati  $y_i$  possono provenire dall'una o dall'altra retta con la stessa probabilità.
- Sui dati misurati è presente rumore gaussiano con varianza  $\sigma^2$ .





# Stima di due rette

- Scriviamo la funzione di verosimiglianza:

$$p(y_i) = P1 \cdot G(m1 \cdot x_i, \sigma^2) + P2 \cdot G(m2 \cdot x_i, \sigma^2)$$

$$G(\mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma}} \cdot e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}$$

- In pratica un punto  $y_i$  può provenire dalla retta 1 con probabilità  $P1$  o dalla retta 2 con probabilità  $P2$ . In ciascuno dei due casi il punto misurato ha una distribuzione gaussiana "centrata" sulla retta stessa.



# Stima di due rette

- Calcolo il logaritmo negativo della verosimiglianza:

$$\begin{aligned} f(m_1, m_2) &= -\sum_{i=1}^N \ln[p(y_i)] = -\sum_{i=1}^N \ln\left[P_1 \cdot G(m_1 \cdot x_i, \sigma^2) + P_2 \cdot G(m_2 \cdot x_i, \sigma^2)\right] \\ &= -\sum_{i=1}^N \ln\left[P_1 \cdot p_1(x_i, \sigma^2) + P_2 \cdot p_2(x_i, \sigma^2)\right] \end{aligned}$$

$$p_j(y_i, \sigma^2) = \frac{1}{\sqrt{2\pi}\sigma} \cdot e^{-\frac{1}{2}\left(\frac{x - m_j \cdot x_i}{\sigma}\right)^2}$$



# Stima di due rette

- Provo a minimizzare il logaritmo negativo ponendo a zero le derivate rispetto a  $m_1$  e  $m_2$ :

$$\begin{aligned}\frac{\partial}{\partial m_j} [f(m_1, m_2)] &= \frac{\partial}{\partial m_j} \left\{ - \sum_{i=1}^N \ln[p(y_i)] \right\} = - \sum_{i=1}^N \frac{\partial}{\partial m_j} \{ \ln[p(y_i)] \} = \\ &= - \sum_{i=1}^N \frac{1}{p(y_i)} \cdot \frac{\partial}{\partial m_j} \{ p(y_i) \} = - \sum_{i=1}^N \frac{1}{p(y_i)} \cdot \frac{\partial}{\partial m_j} \left\{ \sum_{k=1}^2 P_k \cdot p_k(y_i) \right\} = \\ &= - \sum_{i=1}^N \frac{1}{p(y_i)} \cdot \frac{\partial}{\partial m_j} \{ P_j \cdot p_j(y_i) \} = - \sum_{i=1}^N \frac{P_j}{p(y_i)} \cdot \frac{\partial}{\partial m_j} \{ p_j(y_i) \}\end{aligned}$$



# Stima di due rette

$$\begin{aligned}\frac{\partial}{\partial m_j} \{p_j(y_i)\} &= \frac{\partial}{\partial m_j} \left\{ \frac{1}{\sqrt{2\pi\sigma}} \cdot e^{-\frac{1}{2}\left(\frac{x-m_j \cdot xi}{\sigma}\right)^2} \right\} = \frac{1}{\sqrt{2\pi\sigma}} \cdot \frac{\partial}{\partial m_j} \left\{ e^{-\frac{1}{2}\left(\frac{x-m_j \cdot xi}{\sigma}\right)^2} \right\} = \\ &= \frac{1}{\sqrt{2\pi\sigma}} \cdot e^{-\frac{1}{2}\left(\frac{x-m_j \cdot xi}{\sigma}\right)^2} \cdot \frac{\partial}{\partial m_j} \left[ -\frac{1}{2}\left(\frac{x-m_j \cdot xi}{\sigma}\right)^2 \right] = \\ &= p_j(y_i) \cdot \left( -\frac{1}{2\sigma^2} \right) \cdot 2 \cdot (x - m_j \cdot xi) \cdot (-xi) = p_j(y_i) \cdot \frac{(x - m_j \cdot xi) \cdot xi}{\sigma^2}\end{aligned}$$



# Stima di due rette



- Riprendendo la derivata:

$$\begin{aligned}\frac{\partial}{\partial m_j} [f(m_1, m_2)] &= - \sum_{i=1}^N \frac{P_j}{p(x_i)} \cdot \frac{\partial}{\partial m_j} \{p_j(y_i)\} = \\ &= - \sum_{i=1}^N \frac{P_j}{p(y_i)} \cdot p_j(y_i) \cdot \frac{(x - m_j \cdot x_i) \cdot x_i}{\sigma^2}\end{aligned}$$



# Stima di due rette

- Se cerchiamo di porre a zero le due derivate contemporaneamente otteniamo il seguente sistema (non lineare in due incognite - non può essere risolto in maniera analitica!):

$$\left\{ \begin{array}{l} - \sum_{i=1}^N \frac{P1 \cdot \frac{1}{\sqrt{2\pi\sigma}} \cdot e^{-\frac{1}{2}\left(\frac{x-m_1 \cdot xi}{\sigma}\right)^2}}{P1 \cdot \frac{1}{\sqrt{2\pi\sigma}} \cdot e^{-\frac{1}{2}\left(\frac{x-m_1 \cdot xi}{\sigma}\right)^2} + P2 \cdot \frac{1}{\sqrt{2\pi\sigma}} \cdot e^{-\frac{1}{2}\left(\frac{x-m_2 \cdot xi}{\sigma}\right)^2}} \cdot \frac{(x - m_1 \cdot xi) \cdot xi}{\sigma^2} = 0 \\ - \sum_{i=1}^N \frac{P1 \cdot \frac{1}{\sqrt{2\pi\sigma}} \cdot e^{-\frac{1}{2}\left(\frac{x-m_2 \cdot xi}{\sigma}\right)^2}}{P1 \cdot \frac{1}{\sqrt{2\pi\sigma}} \cdot e^{-\frac{1}{2}\left(\frac{x-m_1 \cdot xi}{\sigma}\right)^2} + P2 \cdot \frac{1}{\sqrt{2\pi\sigma}} \cdot e^{-\frac{1}{2}\left(\frac{x-m_2 \cdot xi}{\sigma}\right)^2}} \cdot \frac{(x - m_2 \cdot xi) \cdot xi}{\sigma^2} = 0 \end{array} \right.$$



# Stima di due rette (riassunto)



- In generale, la formulazione di un problema alla massima verosimiglianza porta ad un sistema non lineare di equazioni non risolvibile analiticamente.
- Per la minimizzazione del logaritmo negativo della verosimiglianza è allora necessario ricorrere ad un algoritmo di ottimizzazione iterativo.



# Bibliografia

- Christopher M. Bishop, Pattern Recognition and Machine Learning, Capitoli: 1.2.3 (verosimiglianza), 1.2.4 (gaussiana), 2.3.4 (likelihood e gaussiana), 1.2.5 (fitting di curve con la verosimiglianza).