



Massima verosimiglianza

I. Frosio

AIS Lab.

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 μ , std σ):

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



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 μ , std σ .
- La funzione verosimiglianza dipende da μ e σ .

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



Stima alla massima verosimiglianza

- Se massimizziamo $L=L(\mathbf{y}|\mu,\sigma)$...
- Troviamo i parametri μ,σ tali per cui è massima la probabilità di misurare il vettore di dati \mathbf{y} .
- STIMA ALLA MASSIMA VEROSIMIGLIANZA.
- Più 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.

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



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 μ e σ , 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 μ e varianza σ^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:

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



Stima ai minimi quadrati e verosimiglianza



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

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

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

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

$$\left[\sum_{i=1}^N (y_i \cdot x_i) \right] - m \cdot \left[\sum_{i=1}^N (x_i^2) \right] - b \cdot \left[\sum_{i=1}^N (x_i) \right] = 0 \Rightarrow$$

$$m \cdot \left[\sum_{i=1}^N (x_i^2) \right] + b \cdot \left[\sum_{i=1}^N (x_i) \right] = \left[\sum_{i=1}^N (y_i \cdot x_i) \right]$$



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:

$$A^T A \rightarrow \begin{bmatrix} x1 & x2 & \dots & xN \\ 1 & 1 & \dots & 1 \end{bmatrix} \begin{bmatrix} x1 & 1 \\ x2 & 1 \\ \dots & \dots \\ xN & 1 \end{bmatrix} = \begin{bmatrix} \sum_{i=1}^N (xi^2) & \sum_{i=1}^N (xi) \\ \sum_{i=1}^N (xi) & \sum_{i=1}^N (1) \end{bmatrix}$$

$$A^T b \rightarrow \begin{bmatrix} x1 & x2 & \dots & xN \\ 1 & 1 & \dots & 1 \end{bmatrix} \begin{bmatrix} y1 \\ y2 \\ \dots \\ yN \end{bmatrix} = \begin{bmatrix} \sum_{i=1}^N (yi \cdot xi) \\ \sum_{i=1}^N (yi) \end{bmatrix}$$



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!

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

- 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) = λ .

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



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 λ (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 (0.5).
- Sui dati misurati è presente rumore gaussiano con varianza σ^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).