



# Algoritmi di minimizzazione - EM - Mixture models

I. Frosio

AIS Lab.

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

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



## Overview


- Stima di due rette (riassunto)
- Minimizzazione: metodi "di ordine zero" (simpleso, ...)
- Minimizzazione: metodi "di primo ordine" (gradiente, ...)
- Minimizzazione: metodi "di secondo ordine" (Newton, ...)
- Minimizzazione: Expectation-Maximization
- Mixture models: introduzione
- Mixture models: segmentazione di radiografia cefalometrica



## Stima di due rette (riassunto)



- 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  $\sigma^2$ .



A.A. 2007-2008

3/58

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



## Stima di due rette (riassunto)



- 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.

A.A. 2007-2008

4/58

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



## Stima di due rette (riassunto)



- Calcolo il logaritmo negativo della verosimiglianza:

$$f(m1, m2) = -\sum_{i=1}^N \ln[p(y_i)] = -\sum_{i=1}^N \ln[P1 \cdot G(m1 \cdot xi, \sigma^2) + P2 \cdot G(m2 \cdot xi, \sigma^2)]$$

$$= -\sum_{i=1}^N \ln[P1 \cdot p_1(xi, \sigma^2) + P2 \cdot p_2(xi, \sigma^2)]$$

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

- Non può essere minimizzato analiticamente ponendo le derivate uguali a zero - è necessario usare un algoritmo di minimizzazione iterativo.





## Minimizzazione: metodi di ordine 0



Strategia di base:

- Sia  $f(x)$  la funzione da minimizzare,  $x_0$  la soluzione di partenza;
- La soluzione viene perturbata ( $x_{k+1} = x_k + \Delta x$ ) in modo più meno "furbo", testando diverse perturbazioni  $\Delta x$ .
- Per ogni perturbazione  $\Delta x$  si calcola la  $f(x_k + \Delta x)$ .
- Si sceglie la  $\Delta x$  tale per cui la  $f(x_k + \Delta x)$  è minima e si aggiorna la soluzione ( $x_{k+1} = x_k + \Delta x$ ).
- Esempi: metodo del simplesso, simulated annealing, algoritmi genetici...
- Se si utilizza un metodo di ordine 0 è necessario calcolare la sola  $f(x)$ .
- Facile da implementare, bassa velocità di convergenza.





## Minimizzazione: metodi di ordine 1



Strategia di base:

- Sia  $f(x)$  la funzione da minimizzare,  $x_0$  la soluzione di partenza;
- Si calcoli il gradiente della  $f$  in  $x_k$ ,  $J(x_k)$ .
- La soluzione viene aggiornata utilizzando l'informazione del gradiente.
- Nell'ipotesi più semplice (metodo del gradiente), muovendosi nella direzione opposta rispetto al gradiente ( $x_{k+1} = x_k - \alpha J(x_k)$ ).
- Esempi: metodo del gradiente, gradiente coniugato, ...
- Se si utilizza un metodo di ordine 1 è necessario calcolare la  $f(x)$  e  $J(x)$ .
- Abbastanza facile da implementare, velocità di convergenza media (dipende dalla strategia adottata).
- Il parametro scalare  $\alpha$  (learning rate) determina la velocità di convergenza e la stabilità del metodo.


A.A. 2007-2008

9/58

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




## Minimizzazione: metodi di ordine 1



A.A. 2007-2008

10/58

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



## Minimizzazione: metodi di ordine 1

- Nel caso del problema delle due rette abbiamo già calcolato le derivate (si veda la lezione precedente).
- Utilizzando il metodo del gradiente, la soluzione può essere aggiornata come:

$$m_j^{k+1} = m_j^k - \alpha \cdot \frac{\partial f(m_1, m_2)}{\partial m_j} = m_j^k - \alpha \cdot \sum_{i=1}^N \frac{P_j}{p(x_i)} \cdot p_j(x_i) \cdot \frac{(x - m_j \cdot x_i) \cdot x_i}{\sigma^2}$$

- (Esercizio → implementazione Matlab del metodo del gradiente - confronto con EM per vari valori di  $\alpha$ )

A.A. 2007-2008 12/58 http://homes.dsi.unimi.it/~frosio/



## Minimizzazione: metodi di ordine 2



Strategia di base:

- Sia  $f(x)$  la funzione da minimizzare,  $x_0$  la soluzione di partenza;
- L'espansione in serie di Taylor arrestata al 2° ordine di  $f(x)$  è la seguente:  
$$f(x_k + \Delta x) = f(x_k) + J(x_k) (\Delta x) + 1/2 (\Delta x)^T H(x_k) (\Delta x),$$
dove  $H(x_k)$  è l'Hessiano di  $f$ .
- L'espansione in serie di Taylor dà un'approssimazione locale della  $f(x)$ .
- E' possibile minimizzare analiticamente tale approssimazione; il minimo si ottiene derivando e ponendo la derivata uguale a zero (metodo di Newton):
- $J(x_k) + H(x_k)(\Delta x) = 0 \rightarrow \Delta x = -H(x_k)^{-1} J(x_k)$
- E' oneroso calcolare l'hessiano, velocità di convergenza alta.


A.A. 2007-2008

13/58

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



## Minimizzazione: metodi di ordine 2




A.A. 2007-2008

14/58

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



## Minimizzazione: metodi di ordine 2



A.A. 2007-2008

15/58

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



## Minimizzazione - metodi iterativi (riassunto)



- Quando la funzione da minimizzare è fortemente non lineare, è necessario ricorrere ad un metodo iterativo.
- Si fanno delle ipotesi sull'andamento locale della  $f(x)$  e si aggiorna la soluzione  $x$  in modo da garantire che la  $f(x)$  decresca, fino al raggiungimento di un minimo locale.
- I metodi di ordine 0 utilizzano il calcolo della sola  $f(x)$  per studiarne l'andamento locale e scegliere l'aggiornamento della soluzione - facili da implementare, lenti nella convergenza.
- I metodi di ordine 1 utilizzano anche il gradiente per studiare l'andamento locale della soluzione - discretamente complessi, velocità di convergenza media.
- I metodi di ordine 2 utilizzano anche l'hessiano per descrivere con maggior cura l'andamento locale della soluzione (funzione "surrogato") e minimizzano ad ogni iterazione la funzione "surrogato" invece della  $f(x)$  - il calcolo dell'hessiano è complesso, velocità di convergenza alta.

A.A. 2007-2008

16/58

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



## Minimizzazione: Expectation- Maximization



- Expectation-Maximization: un algoritmo di massimizzazione della verosimiglianza per modelli con variabili latenti.
- Si consideri un problema di massimizzazione della verosimiglianza (es. stima delle due rette).
- Tale problema ha una formulazione complessa, ma...
- ... Se vengono inserite alcune variabili nascoste nel modello, la formulazione matematica del problema può essere semplificata.



## Minimizzazione: Expectation- Maximization



- Sia  $\theta$  il vettore dei parametri del modello da stimare;
- Scriviamo la verosimiglianza del problema introducendo delle variabili nascoste,  $Z$ , oltre alle variabili misurate,  $Y$ :

$$\ln[p(Y | \theta)] = \ln \left\{ \sum_Z p(Y, Z | \theta) \right\}$$



## Minimizzazione: Expectation- Maximization



- Nel caso della stima delle due rette...
- ... Cosa succederebbe se ci fosse data l'appartenenza di una misura  $y_i$  all'una o all'altra retta?
- In tal caso il problema si ridurrebbe a due semplici problemi di stima di retta ai minimi quadrati.
- Per formulare EM, introduciamo delle variabili nascoste  $Z$  che descrivono l'appartenenza di una misura  $y_i$  alla retta 1 o alla retta 2.

A.A. 2007-2008

19/58

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



## Minimizzazione: Expectation- Maximization



- Dal momento che le variabili nascoste non sono note, devono essere stimate a partire dai dati.
- Utilizzando il teorema di Bayes, e considerando un vettore di parametri stimato  $\theta^{old}$ , possiamo stimare le probabilità delle  $Z$ ,  $p(Z|Y, \theta^{old})$ .

A.A. 2007-2008

20/58

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



## Minimizzazione: Expectation- Maximization



- Stimiamo le variabili nascoste per il problema di stima delle due rette.
- Dal teorema di Bayes:

$$p(J | y) = \frac{p(y | J) \cdot p(J)}{p(y)}$$

Probabilità che sia stata la retta J-esima a generare il dato y  
 Probabilità del dato y quando generato dalla componente J  
 Probabilità della componente J  
 Probabilità del dato y

A.A. 2007-2008

21/58

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



## Minimizzazione: Expectation- Maximization



- Specificando per nostro caso:

$$p(J | y_i) = \frac{p_j(y_i) \cdot P_j}{P_1 \cdot p_1(y_i) + P_2 \cdot p_2(y_i)}$$

- La  $p(j|y_i)$  descrive il "grado di appartenenza" del dato  $y_i$  alla retta  $j$ .
- All'iterazione  $k$ -esima, può essere calcolato con i parametri  $m_1$ ,  $m_2$  dell'iterazione stessa.

A.A. 2007-2008

22/58

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



## Minimizzazione: Expectation- Maximization



- Ciò consente di costruire la funzione di Expectation, che verrà massimizzata ad ogni passo - si richiede di **massimizzare la media su Z della funzione di verosimiglianza**:

$$\theta^{new} = \arg \max_{\theta} Q(\theta, \theta^{old}) \leftarrow \text{Maximization}$$

$$Q(\theta, \theta^{old}) = \sum_Z \{ p(Z | Y, \theta^{old}) \cdot \ln[p(Y, Z | \theta)] \}$$

← Expectation

A.A. 2007-2008

23/58

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



## Minimizzazione: Expectation- Maximization



- Scriviamo il passo di maximization per il problema di stima delle due rette:

$$Q(\theta, \theta^{old}) = \sum_Z \{ p(Z | Y, \theta^{old}) \cdot \ln[p(Y, Z | \theta)] \} \Rightarrow$$

$$\sum_Z \{ p(Z | Y, m1^{old}, m2^{old}) \cdot \ln[p(Y, Z | m1, m2)] \}$$

Costante, calcolata nella fase di  
Expectation  $\rightarrow K(y_i, j)$

A.A. 2007-2008

24/58

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



## Minimizzazione: Expectation-Maximization



$$\begin{aligned}
 Q &= \sum_{i=1}^N \sum_{j=1}^2 k(y_i, j) \cdot \ln[p_j(y_i)] = \sum_{i=1}^N \sum_{j=1}^2 k(y_i, j) \cdot \ln \left[ \frac{1}{\sqrt{2\pi}\sigma} \cdot e^{-\frac{1}{2} \left( \frac{y_i - m_j \cdot x_i}{\sigma} \right)^2} \right] = \\
 &= \sum_{i=1}^N \sum_{j=1}^2 k(y_i, j) \cdot \ln \left[ \frac{1}{\sqrt{2\pi}\sigma} \right] + \sum_{i=1}^N \sum_{j=1}^2 k(y_i, j) \cdot \left[ -\frac{1}{2} \left( \frac{y_i - m_j \cdot x_i}{\sigma} \right)^2 \right] = \\
 &= \sum_{i=1}^N \sum_{j=1}^2 k(y_i, j) \cdot \ln \left[ \frac{1}{\sqrt{2\pi}\sigma} \right] - \frac{1}{2\sigma^2} \cdot \sum_{i=1}^N \sum_{j=1}^2 k(y_i, j) \cdot (y_i - m_j \cdot x_i)^2
 \end{aligned}$$

A.A. 2007-2008

25/58

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



## Minimizzazione: Expectation-Maximization



- Cerchiamo allora il massimo di  $Q$  (Maximization) per avere l'aggiornamento della soluzione:

$$\begin{aligned}
 \frac{\partial Q}{\partial m_j} &= \frac{\partial}{\partial m_j} \left\{ \sum_{i=1}^N \sum_{j=1}^2 k(y_i, j) \cdot \ln \left[ \frac{1}{\sqrt{2\pi}\sigma} \right] - \frac{1}{2\sigma^2} \cdot \sum_{i=1}^N \sum_{j=1}^2 k(y_i, j) \cdot (y_i - m_j \cdot x_i)^2 \right\} = \\
 &= 0 - \frac{1}{2\sigma^2} \cdot \frac{\partial}{\partial m_j} \sum_{i=1}^N \sum_{j=1}^2 k(y_i, j) \cdot (y_i - m_j \cdot x_i)^2 = \\
 &= -\frac{1}{2\sigma^2} \cdot \frac{\partial}{\partial m_j} \sum_{i=1}^N k(y_i, j) \cdot (y_i - m_j \cdot x_i)^2 = \\
 &= -\frac{1}{2\sigma^2} \cdot \sum_{i=1}^N k(y_i, j) \cdot 2 \cdot (y_i - m_j \cdot x_i) \cdot (-x_i) = \\
 &= \frac{1}{\sigma^2} \cdot \sum_{i=1}^N k(y_i, j) \cdot (y_i - m_j \cdot x_i) \cdot (x_i)
 \end{aligned}$$

A.A. 2007-2008

26/58

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



## Minimizzazione: Expectation- Maximization



- Ponendo la derivata di Q uguale a zero...

$$\frac{\partial Q}{\partial m_j} = \frac{1}{\sigma^2} \cdot \sum_{i=1}^N k(y_i, j) \cdot (y_i - m_j \cdot x_i) \cdot (x_i) = 0 \Rightarrow$$

$$\sum_{i=1}^N k(y_i, j) \cdot (y_i - m_j \cdot x_i) \cdot (x_i) = 0 \Rightarrow$$

$$\sum_{i=1}^N k(y_i, j) \cdot (y_i \cdot x_i) - m_j \cdot \sum_{i=1}^N k(y_i, j) \cdot (x_i^2) = 0 \Rightarrow$$

$$m_j = \frac{\sum_{i=1}^N k(y_i, j) \cdot (y_i \cdot x_i)}{\sum_{i=1}^N k(y_i, j) \cdot (x_i^2)}$$

- Otteniamo le equazioni di aggiornamento per i parametri del modello secondo EM.

A.A. 2007-2008

27/58

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



## Minimizzazione: Expectation- Maximization



- Analizzando la funzione di aggiornamento per EM...

$$m_j = \frac{\sum_{i=1}^N k(y_i, j) \cdot (y_i \cdot x_i)}{\sum_{i=1}^N k(y_i, j) \cdot (x_i^2)}$$

- I parametri vengono aggiornati secondo uno schema ai minimi quadrati pesati dai fattori  $k(y_i, j)$  che descrivono l'appartenenza di un dato alla retta 1 o alla retta 2.
- Vedere anche → codice Matlab

A.A. 2007-2008

28/58

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



## Minimizzazione: Expectation- Maximization



- Discorso "al limite" per interpretare EM...
- Si assegna un punto alla retta 1 o alla retta 2 sulla base della distanza dalle due rette (expectation);
- Si risolvono i due problemi di stima ai minimi quadrati (facili! - maximization);
- Si itera fino a convergenza...
  
- Nell'EM reale l'assegnazione è "soft" invece che "hard".
- Vedere anche → codice Matlab


A.A. 2007-2008

29/58

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



## Minimizzazione: Expectation- Maximization





A.A. 2007-2008

30/58

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



# Minimizzazione: Expectation- Maximization





A.A. 2007-2008

31/58

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



# Minimizzazione: Expectation- Maximization



A.A. 2007-2008

32/58

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



## Minimizzazione: Expectation- Maximization (riassunto)



- La funzione di verosimiglianza può portare ad una minimizzazione complessa;
- Introducendo delle variabili nascoste  $Z$  nel modello la formulazione può essere semplificata;
- Il valore delle variabili nascoste  $Z$  viene calcolato con il teorema di Bayes nella fase di costruzione della funzione di Expectation;
- Nel passo di Maximization, si massimizza la media su  $Z$  della verosimiglianza.




## Minimizzazione: Expectation- Maximization (riassunto e...)



- Derivazione rigorosa di EM:
  - Nel passo di expectation si costruisce un lower bound per la funzione di verosimiglianza (upper bound per  $-\text{Log}(L)$ );
  - Nel passo di maximization si massimizza il lower bound;
- Per approfondire: Christopher M. Bishop, Pattern Recognition and Machine Learning, Capitolo 9.4.



## Minimizzazione: Expectation- Maximization (riassunto e...)



A.A. 2007-2008

35/58

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



## Mixture models: introduzione



- La funzione di verosimiglianza permette di stimare i parametri incogniti di una distribuzione (es. media e varianza di una gaussiana);
- Nei casi reali, la densità di probabilità può essere complessa a piacere;
- In particolare, si può considerare una combinazione lineare (mixture) di variabili casuali → **mixture models**

A.A. 2007-2008

36/58


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



## Mixture models: introduzione



- In un mixture model, la d.d.p. complessiva è la combinazione lineare di  $M$  d.d.p. di base.



A.A. 2007-2008

37/58

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



## Mixture models: introduzione

(incognite)



$$p(\mathbf{x}) = \sum_{j=1}^M p_{\theta}(\mathbf{x} | j) P(j)$$

### Dati

La d.d.p. complessiva,  $p(\mathbf{x})$ , viene misurata.

La forma delle d.d.p. di base,  $p_{\theta}(\mathbf{x} | j)$ , viene scelta *a priori* (es. gaussiana).

### Incognite

I parametri  $\theta$  di ogni d.d.p. di base,  $p_{\theta}(\mathbf{x} | j)$ , devono essere stimati.

Le probabilità per ogni d.d.p. di base,  $P(j)$ , devono essere stimate.

A.A. 2007-2008

38/58

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



## Mixture models: introduzione



- Per la stima del vettore dei parametri  $\theta$  viene utilizzato...
- ... L'approccio alla **massima verosimiglianza**.
- **Mixture model:**
- $p(x) = \sum_{j=1..M} p_{\theta}(x | j) \cdot P(j)$
- **Likelihood function:**
- $L = L(\theta) = p(x_1 / \theta) \cdot p(x_2 / \theta) \dots p(x_D / \theta)$
- **Negative log likelihood function:**
- $E = E(\theta) = -\log(L) = -\sum_{i=1..D} \log [p(x_i / \theta)] =$   
 $= -\sum_{i=1..D} \log [\sum_{j=1..M} p_{\theta}(x_i | j) P(j)]$

A.A. 2007-2008

39/58

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



## Mixture models: introduzione (riassunto)



- Mixture models: una combinazione lineare di densità di probabilità utilizzata per descrivere la densità di probabilità degli elementi di un vettore di dati misurato.
- Le incognite sono i parametri di ogni ddp del mixture e la probabilità di ogni singola componente del mixture.
- I parametri vengono calcolati massimizzando la funzione di verosimiglianza.

A.A. 2007-2008

40/58

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



# Mixture models: segmentazione radiografia cefalometrica




$I(x,y)$  → immagine NRow x NCol, 8 bit (256 livelli di grigio  $g$ );

Hist( $\cdot$ ) → istogramma, 256 componenti;

Hist( $g$ ) → # pixel t.c.  $I(x,y)=g$ ;

Hist( $g$ ) / (NRow \* NCol) =  $p(g)$ . → **ddp**



Solo 4 livelli di grigio

A.A. 2007-2008

41/58


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



# Mixture models: segmentazione radiografia cefalometrica





Istogramma tipico immagine radiografica cefalometrica



A.A. 2007-2008

42/58

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





## Mixture models: segmentazione radiografia cefalometrica



- L'istogramma di una radiografia cefalometrica è composto da tre componenti principali;
- Il problema di segmentazione dell'immagine si presta ad essere trattato con un approccio tipo mixture model;
- Ogni componente del mixture model sarà responsabile rispettivamente della generazione dei dati relativi a background, soft tissue e bone tissue;
- Massimizzazione della verosimiglianza: EM (massimizzazione di lower bound).

A.A. 2007-2008

45/58

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



## Mixture models: segmentazione radiografia cefalometrica



- Funzione da minimizzare (incognita  $\theta$ ):

$$E = -\ln(L) = -\ln \prod_{n=1}^N p_g(x^n) = -\sum_{n=1}^N \ln p_g(x^n)$$

- Per ogni iterazione, i parametri vengono aggiornati (old  $\rightarrow$  new, indice  $\theta$  omesso):

$$E^{new} - E^{old} = -\sum_{n=1}^N \ln p^{new}(x^n) - \left[ -\sum_{n=1}^N \ln p^{old}(x^n) \right] = -\sum_{n=1}^N \ln \left[ \frac{p^{new}(x^n)}{p^{old}(x^n)} \right]$$

A.A. 2007-2008

46/58

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



## Mixture models: segmentazione radiografia cefalometrica



$$E^{new} - E^{old} = -\sum_{n=1}^N \ln p^{new}(x^n) - \left[ -\sum_{n=1}^N \ln p^{old}(x^n) \right] = -\sum_{n=1}^N \ln \left[ \frac{p^{new}(x^n)}{p^{old}(x^n)} \right]$$

Ricordando che:

$$p(x) = \sum_{j=1}^M P(j) \cdot p(x | j)$$

Si ottiene:

$$E^{new} - E^{old} = \sum_{n=1}^N -\ln \left[ \frac{\sum_{j=1}^M P^{new}(j) p^{new}(x^n | j)}{p^{old}(x^n)} \cdot \frac{P^{old}(j | x^n)}{P^{old}(j | x^n)} \right]$$

A.A. 2007-2008

47/58

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



## Mixture models: segmentazione radiografia cefalometrica



- La disuguaglianza di Jensen dice che:

$$\text{dati } \lambda_j^2 \text{ t.c. } \sum_{j=1}^M \lambda_j^2 = 1$$

$$\ln \left( \sum_{j=1}^M \lambda_j^2 K_j \right) \geq \sum_{j=1}^M \lambda_j^2 \ln(K_j) \Rightarrow$$

$$\Rightarrow -\ln \left( \sum_{j=1}^M \lambda_j^2 K_j \right) \leq -\sum_{j=1}^M \lambda_j^2 \ln(K_j)$$

A.A. 2007-2008

48/58

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



## Mixture models: segmentazione radiografia cefalometrica



$$\sum_{j=1}^M \lambda_j^2 = 1 \quad \longleftrightarrow \quad \sum_{j=1}^M P^{old}(j | x^n) = 1, \forall n$$

Jensen

Mixture model

E' possibile applicare la disuguaglianza di Jensen ai mixture model, ove i  $P^{old}(j | x^n)$  giocano il ruolo dei  $\lambda_j^2$ .

A.A. 2007-2008

49/58

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



## Mixture models: segmentazione radiografia cefalometrica



- Applicando Jensen:

$$-\ln\left(\sum_{j=1}^M \lambda_j^2 K_j\right) \leq -\sum_{j=1}^M \lambda_j^2 \ln(K_j)$$

$$E^{new} - E^{old} = \sum_{n=1}^N -\ln\left[\sum_{j=1}^M \frac{P^{new}(j)p^{new}(x^n | j)}{p^{old}(x^n)} \cdot \frac{P^{old}(j | x^n)}{P^{old}(j | x^n)}\right]$$

A.A. 2007-2008

50/58

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



## Mixture models: segmentazione radiografia cefalometrica



$$E^{new} - E^{old} = \sum_{n=1}^N -\ln \left[ \sum_{j=1}^M \frac{P^{new}(j)p^{new}(x^n | j)}{p^{old}(x^n)} \cdot \frac{P^{old}(j | x^n)}{P^{old}(j | x^n)} \right]$$

$$\leq -\sum_{j=1}^M P^{old}(j | x^n) \cdot \ln \left[ \frac{P^{new}(j) \cdot p^{new}(x^n | j)}{p^{old}(x^n) \cdot P^{old}(j | x^n)} \right]$$

A.A. 2007-2008

51/58

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



## Mixture models: segmentazione radiografia cefalometrica



$$E^{new} - E^{old} \leq -\sum_{n=1}^N \sum_{j=1}^M P^{old}(j | x^n) \ln \left\{ \frac{P^{new}(j)p^{new}(x^n | j)}{p^{old}(x^n) \cdot P^{old}(j | x^n)} \right\}$$

$$E^{new} \leq E^{old} + Q \quad \text{Minimizzando } Q \text{ si minimizza } E!$$

$P^{old}(x^n), P^{old}(j | x^n) \rightarrow$  costanti...

... dunque  $Q = Q(\theta^{new})!$

A.A. 2007-2008

52/58

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



## Mixture models: segmentazione radiografia cefalometrica



Eliminando i termini costanti (old) nella somma (! trasf. Logaritmica!), è sufficiente minimizzare ad ogni iterazione:

$$\tilde{Q} = - \sum_{n=1}^N \sum_{j=1}^M P^{old}(j | x^n) \ln \{ P^{new}(j) p^{new}(x^n | j) \}$$

Tenendo inoltre conto del fatto che:

$$\sum_{j=1}^M P^{new}(j | x^n) = 1, \forall n$$

A.A. 2007-2008

53/58

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



## Mixture models: segmentazione radiografia cefalometrica



Si minimizza allora (*metodo dei moltiplicatori di Lagrange*):

$$f = \tilde{Q} + \psi \left( \sum_{j=1}^M P^{new}(j) - 1 \right)$$

*Vincolo*

Cioè:

$$\left\{ \begin{array}{l} \frac{\partial f}{\partial \mu_j^{new}} = 0 \\ \frac{\partial f}{\partial \sigma_j^{new}} = 0 \\ \frac{\partial f}{\partial P^{new}(j)} = 0 \\ \frac{\partial f}{\partial \psi} = 0 \text{ (vincolo)} \end{array} \right.$$

Da questo sistema possono essere ricavate le equazioni per l'aggiornamento dei parametri del mixture model ad ogni iterazione.

A.A. 2007-2008

54/58

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



## Mixture models: segmentazione radiografia cefalometrica



- Aggiornamento  $P(j)$ :

$$P^{new}(j) = \frac{1}{N} \sum_{n=1}^N P^{old}(j | x^n)$$

- Nel caso di ddp gaussiane:

$$\mu_j^{new} = \frac{\sum_{n=1}^N P^{old}(j | x^n) x^n}{\sum_{n=1}^N P^{old}(j | x^n)} \quad (\sigma_j^{new})^2 = \frac{\sum_{n=1}^N P^{old}(j | x^n) (x^n - \mu_j)^2}{\sum_{n=1}^N P^{old}(j | x^n)}$$


A.A. 2007-2008

55/58

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



## Mixture models: segmentazione radiografia cefalometrica



A.A. 2007-2008

56/58


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



## Risultato (bone tissue)



- Clusterizzazione immagine in 3 zone (background, soft tissue, bone tissue).



A.A. 2007-2008

57/58

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



## Bibliografia



- Christopher M. Bishop, *Pattern Recognition and Machine Learning*, Capitolo 2.3.9 (mixture di gaussiane), Capitolo 9.1, 9.2, 9.3 (K-means, mixture models, EM).
- I. Frosio, G. Ferrigno, N. A. Borghese, "Enhancing Digital Cephalic Radiography with Mixture Model and Local Gamma Correction," *IEEE Transaction on Medical Imaging*, Vol. 25, No. 1, Jan. 2006, pp. 113-121 (mixture models e radiografia cefalometrica).
- Poul Erik Frandsen, Kristian Jonasson, Hans Bruun Nielsen, Ole Tingleff, *Unconstrained Optimization, disponibile in rete, algoritmi di minimizzazione (approfondimento)*.
- Christopher M. Bishop, *Pattern Recognition and Machine Learning*, Capitolo 9.4, EM come minimizzazione di un lower bound (approfondimento).

A.A. 2007-2008

58/58

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

