



# Mixture models - Soft Tissue Filter

I. Frosio

AIS Lab.

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

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

A.A. 2009-2010

1/45

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



## Overview



- Mixture models: introduzione;
- Segmentazione di radiografia cefalometrica;
- Derivazione di EM per il caso di un mixture model a componenti gaussiane;
- Ottimizzazione vincolata (moltiplicatori di Lagrange);
- Soft Tissue Filter.

A.A. 2009-2010

2/45

<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. 2009-2010

3/45

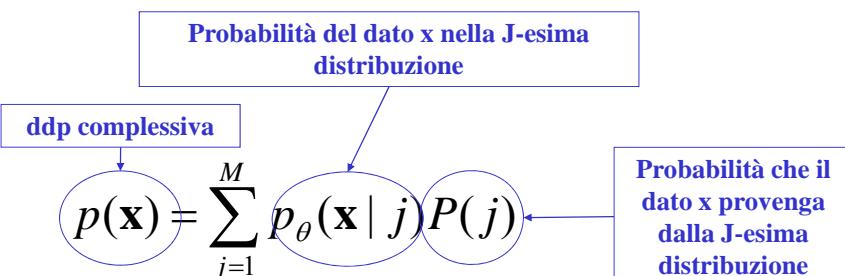
<http://homes.dsi.unimi.it/~frosio/>



# Mixture models: introduzione



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



$$\sum_{j=1}^M P(j) = 1; 0 \leq P(j) \leq 1; \int p_\theta(\mathbf{x} | j) = 1$$

A.A. 2009-2010

4/45

<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,  $p(x)$ , viene misurata.

La forma delle d.d.p. di base,  $p_q(x|j)$ , viene scelta *a priori* (es. gaussiana).

## Incognite

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

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



# 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:**
- $$L = L(\theta) = p(x_1 / \theta) \cdot p(x_2 / \theta) \cdots p(x_D / \theta)$$
- **Negative log likelihood function:**
- $$E = E(\theta) = -\log(L) = -\sum_{i=1..D} \log [p(x_i / \theta)] =$$

$$= -\sum_{i=1..D} \log [\sum_{j=1..M} p_\theta(x_i | j)P(j)]$$



## Mixture models: esempi



- In un supermercato vi sono due tipi di clienti: single e coppie. La percentuale di single è pari al 33%. La spesa per un single è descritta da una variabile casuale distribuita come una gaussiana, media 70 euro, varianza 30 euro; per una coppia, la media è pari a 100 euro, la varianza 40 euro → mixture model per descrivere la spesa media (istogramma bimodale);
- Si supponga che esistano altre categorie (famiglie, frequentatore occasionale, ...) → è sufficiente estendere il modello per includere le nuove categorie...
- Si supponga che la spesa per le famiglie sia ben rappresentata da una variabile casuale con distribuzione chi quadro, media xxx, etc... E' un problema? → NO! Possiamo includere anche questo caso nel mixture model...

A.A. 2009-2010

7/45

<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. 2009-2010

8/45

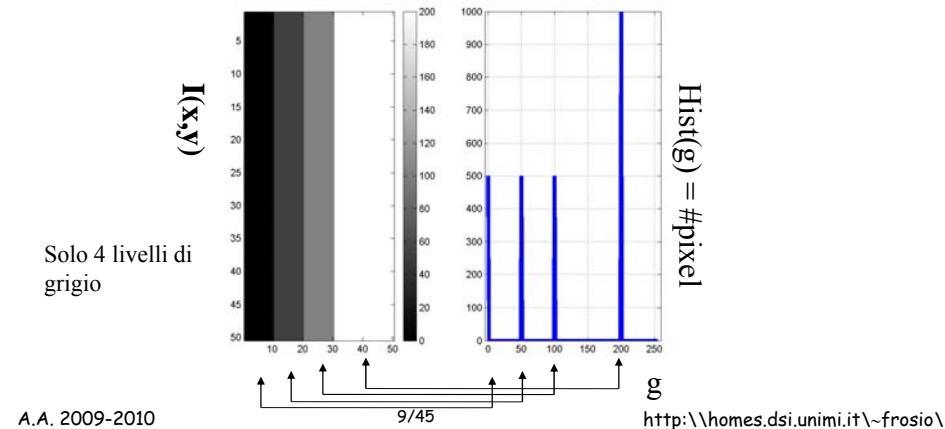
<http://homes.dsi.unimi.it/~frosio/>



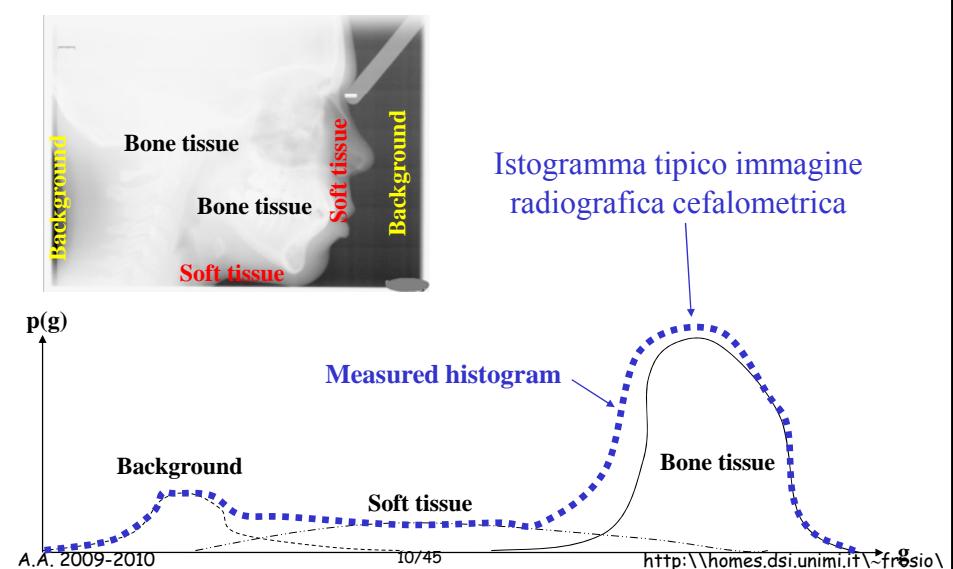
## Mixture models: segmentazione radiografia cefalometrica



$I(x,y) \rightarrow$  immagine NRow x NCol, 8 bit (256 livelli di grigio g);  
 $Hist(\cdot) \rightarrow$  istogramma, 256 componenti;  
 $Hist(g) \rightarrow$  # pixel t.c.  $I(x,y)=g$ ;  
 $Hist(g) / (NRow * NCol) = p(g)$   $\rightarrow$  ddp

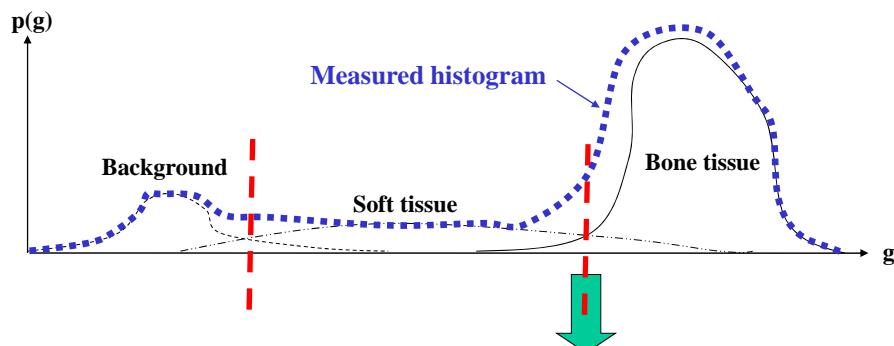


## Mixture models: segmentazione radiografia cefalometrica



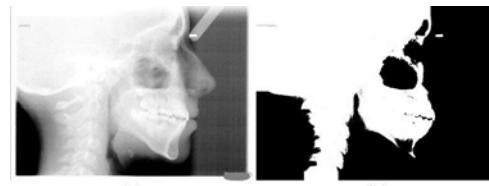


## Mixture models: segmentazione radiografia cefalometrica



Livelli di grigio diversi identificano tessuti diversi (soglia → segmentazione).

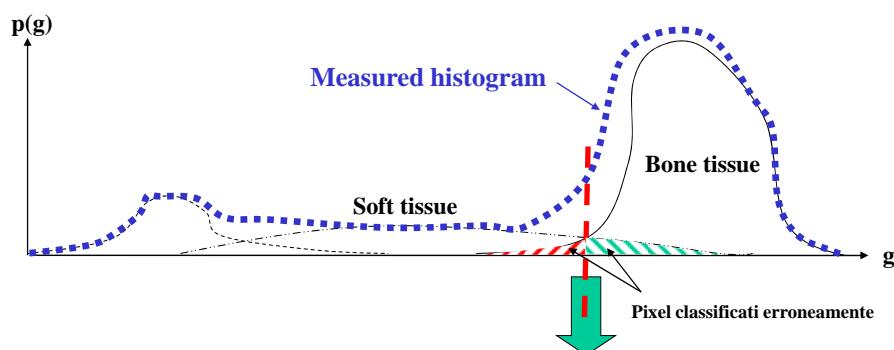
A.A. 2009-2010



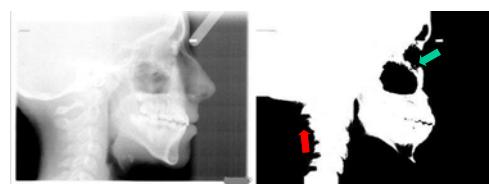
it\~frosio\



## Mixture models: segmentazione radiografia cefalometrica



A.A. 2009-2010



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. 2009-2010

13/45

<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. 2009-2010

14/45

<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:

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

1

Si ottiene:

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

A.A. 2009-2010

15/45

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



## Mixture models: segmentazione radiografia cefalometrica



- La diseguaglianza di Jensen dice che:

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

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

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

A.A. 2009-2010

16/45

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



## Mixture models: segmentazione radiografia cefalometrica



$$\sum_{j=1}^M \lambda_j^2 = 1$$

Jensen

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

Mixture model

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



## Mixture models: segmentazione radiografia cefalometrica



- Applicando Jensen:

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

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



## Mixture models: segmentazione radiografia cefalometrica



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

A.A. 2009-2010

19/45

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

## Mixture models: segmentazione radiografia cefalometrica



$$\begin{aligned}
 E^{new} - E^{old} &\leq -\sum_{n=1}^N \sum_{j=1}^M P^{old}(j | x^n) \ln \left\{ \frac{P^{new}(j)p^{new}(x^n | j)}{p^{old}(x^n) \cdot P^{old}(j | x^n)} \right\} \\
 E^{new} &\leq E^{old} + Q \quad \text{Minimizzando } Q \text{ si minimizza } E!
 \end{aligned}$$

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

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

A.A. 2009-2010

20/45

<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:

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

Tenendo inoltre conto del fatto che:

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

Siamo tornati alla funzione expectation!!!  
L'ottimizzazione è però, in questo caso,  
VINCOLATA...



## Mixture models: segmentazione radiografia cefalometrica



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

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

Cioè:

$$\begin{cases} \frac{\partial f}{\partial \mu_j^{new}} = 0 \\ \frac{\partial f}{\partial \sigma_j^{new}} = 0 \\ \frac{\partial f}{\partial P^{new}(j)} = 0 \\ \frac{\partial f}{\partial \psi} = 0 \quad (\text{vincolo}) \end{cases}$$

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



## Ottimizzazione vincolata (moltiplicatori di Lagrange)



- Vogliamo trovare  $(x,y)$  t.c.  $f(x,y)$  è minimia nell'insieme  $g(x,y) = c$ .
- $f(x,y) \rightarrow$  funzione da ottimizzare.
- $g(x,y) - c = 0 \rightarrow$  vincolo.
  
- Nel caso dell'ottimizzazione non vincolata  $\rightarrow (df/dx = 0) \& (df/dy = 0)$ .

A.A. 2009-2010

23/45

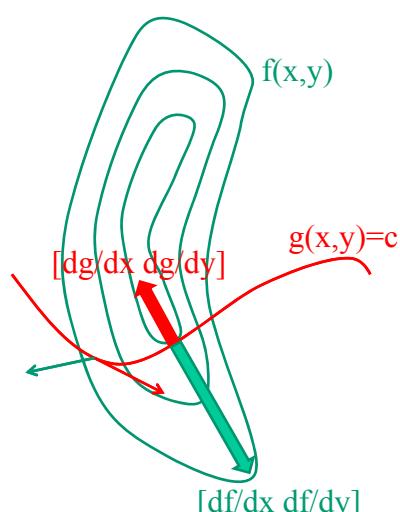
<http://homes.dsi.unimi.it/~frosio/>



## Ottimizzazione vincolata (moltiplicatori di Lagrange)



- Nel caso di ottimizzazione vincolata  $\rightarrow$  la  $g(x,y) - c = 0$  identifica una linea curva nello spazio  $(x,y)$ .
- Il vettore  $[dg/dx \ dg/dy]$  identifica la normale a  $g(x,y)=c$ .
- Il punto massimo/minimo t.x.  $g(x,y) = c$  deve essere t.c.  $[dg/dx \ dg/dy]$  è parallelo al gradiente di  $f$  [quindi, muovendosi lungo  $g(x,y)=c$ , si osserva localmente una variazione nulla di  $f$ ].



A.A. 2009-2010

24/45

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



## Ottimizzazione vincolata (moltiplicatori di Lagrange)



- Come facciamo ad imporre che  $[dg/dx \ dg/dy]$  sia parallelo a  $[df/dx \ df/dy]$ ?
- Imponiamo che  $\text{grad}(f)$  possa essere ottenuto semplicemente scalando  $\text{grad}(g)$  per un fattore  $\lambda$  (incognito - moltiplicatore di Lagrange), ovvero:  
$$\text{grad}(f) + \lambda \cdot \text{grad}(g) = 0 \quad (1)$$
- L'equazione (1) si ottiene **minimizzando** (ottimizzazione non vincolata) la **funzione  $f + \lambda \cdot (g - c)$**  (detta funzione Lagrangiana).

A.A. 2009-2010

25/45

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



## Ottimizzazione vincolata (moltiplicatori di Lagrange)



- $(x^*, y^*, \lambda^*) = \underset{x,y,\lambda}{\operatorname{argmax}} f(x,y) + \lambda \cdot (g(x,y) - c) \Rightarrow$

$$\left\{ \begin{array}{l} df(x^*, y^*)/dx + \lambda \cdot dg(x, y)/dx = 0 \\ df(x^*, y^*)/dy + \lambda \cdot dg(x, y)/dy = 0 \\ g(x, y) - c = 0 \end{array} \right.$$

Derivando rispetto  
a  $x, y$  ottieniamo il  
parallelismo tra i  
due gradienti

Derivando rispetto a  $\lambda$  ottieniamo il vincolo

A.A. 2009-2010

26/45

<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:

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

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

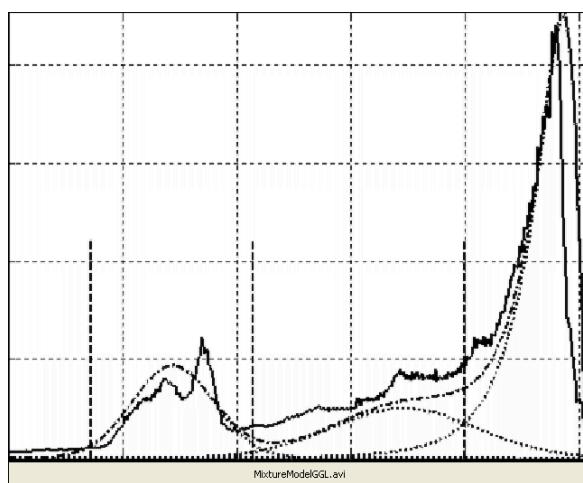
A.A. 2009-2010

27/45

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



## Mixture models: segmentazione radiografia cefalometrica



A.A. 2009-2010

28/45

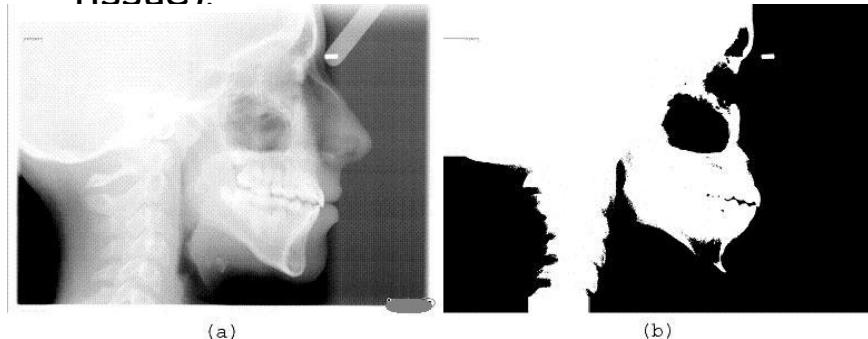
<http://homes.dsi.unimi.it/~frosio/>



## Risultato (bone tissue)



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



(a)

(b)



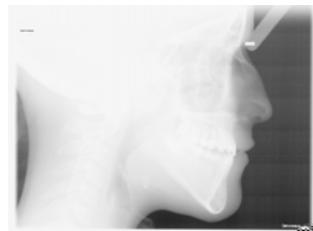
## Bibliografia



- 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).



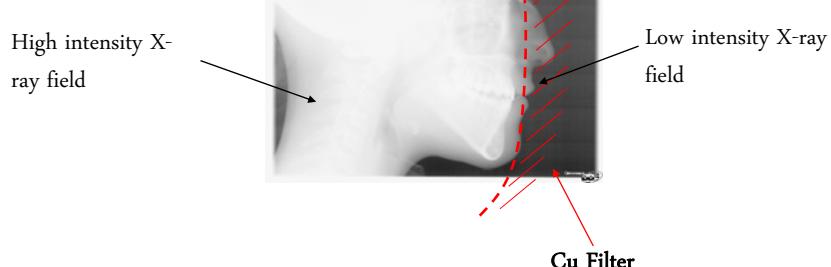
## Exposure problems



- From film to phosphor film to CCD
- Underexposed radiographies: bone cannot be distinguished from soft tissue
- Overexposed radiographies: soft tissue tends to mix with background



## Typical HW solution

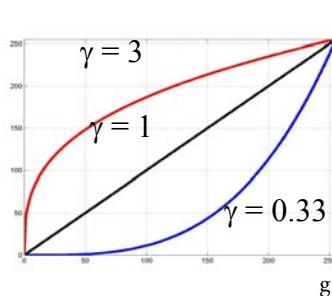




# SW solution: gamma correction



- ▶ Gray level correction formula;
- ▶ Used for global exposure correction;
- ▶ For 8 bit image, gray level  $g$  is corrected to  $g'$  as:  
$$g' = 255 \cdot [(g / 255)^{1/\gamma}]$$



$\gamma > 1 \rightarrow$  Stretching of the low levels, compression of the high levels.

$\gamma < 1 \rightarrow$  Compression of the low levels, stretching of the high levels.



# Global $\gamma$ correction



$$\gamma = 3$$



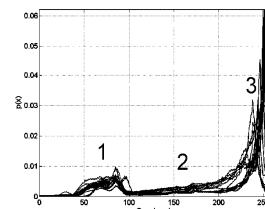
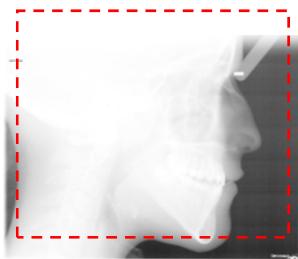
$$\gamma = 0.25$$



- Nowadays clinical practice: global  $\gamma$  correction
- $\gamma = 0.25$  (underexposed), soft tissue darkens!
- $\gamma = 3$  (overexposed), bone tissue mixes with soft tissue!



## Typical histogram



- Three characteristic gray zones: background (1), soft tissue (2), bone tissue (3)
- 5% boundary eliminated (white margins, logo)
- Gray level zero eliminated (saturated pixels)



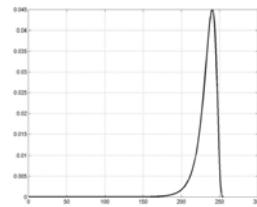
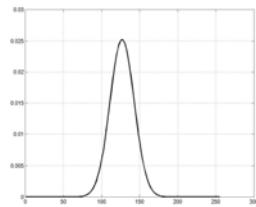
## Mixture model

- A powerful technique to estimate complex probability densities distributions by using a restricted number of parameters
- Linear combination of M probability densities:

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



## Two Gaussian, one Lognormal



- Mixture of three components ( $M = 3$ )
- Two Gaussians: background, soft tissue (symmetric peaks)
- One Inverted Lognormal: bone tissue (asymmetric peak)



## Parameters estimation

- Parameters:  $P(j)$ ,  $\mu_j$ ,  $\sigma_j$ ,  $j=1\dots 3$
- Negative log likelihood  
$$E = -\ln L = -\sum_{n=1}^N \ln p_{MM}(x^n) = -\sum_{n=1}^N \ln \{p(x^n | j)P(j)\}$$
- $E$  is minimized through the EM algorithm



## Updating equations



- **Mixing parameters**  $P(j)^{new} = \frac{1}{N} \sum_{g=0}^{N_{GL}-1} P^{old}(j|g) \cdot H(g)$

- **Gaussians**  $\mu_j^{new} = \frac{\sum_{g=0}^{N_{GL}-1} P^{old}(j|g) \cdot g \cdot H(g)}{\sum_{g=0}^{N_{GL}-1} P^{old}(j|g) \cdot H(g)}$   $(\sigma_j^{new})^2 = \frac{\sum_{g=0}^{N_{GL}-1} P^{old}(j|g) \cdot (g - \mu_j^{new})^2 \cdot H(g)}{\sum_{g=0}^{N_{GL}-1} P^{old}(j|g) \cdot H(g)}$

- **Lognormal**  $\mu_j^{new} = \frac{\sum_{g=0}^{N_{GL}-1} P^{old}(j|g) \cdot \ln(N_{GL} - g) \cdot H(g)}{\sum_{g=0}^{N_{GL}-1} P^{old}(j|g) \cdot H(g)}$   $(\sigma_j^{new})^2 = \frac{\sum_{g=0}^{N_{GL}-1} P^{old}(j|g) \cdot [\ln(N_{GL} - g) - \mu_j^{new}]^2 \cdot H(g)}{\sum_{g=0}^{N_{GL}-1} P^{old}(j|g) \cdot H(g)}$

A.A. 2009-2010

39/45

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

## Clustering



- **Thresholds  $Th(j, j+1)$  minimize**  

$$\int_0^{Th(j, j+1)} P(j+1) \cdot p(x | j+1) dx + \int_{Th(j, j+1)}^{N_{GL}-1} P(j) \cdot p(x | j) dx$$
- **Three classes:** Background, soft tissue, bone tissue

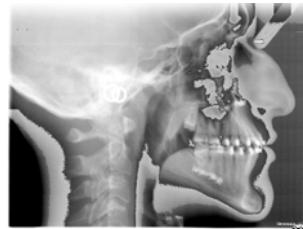
A.A. 2009-2010

40/45

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



## Local $\gamma$ Correction



- $\gamma = 1$  background
- $\gamma = 0.25$  bone tissue
- $\gamma = 1.5$  soft tissue
- Artifacts, patient profile not clearly visible!

A.A. 2009-2010

41/45

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

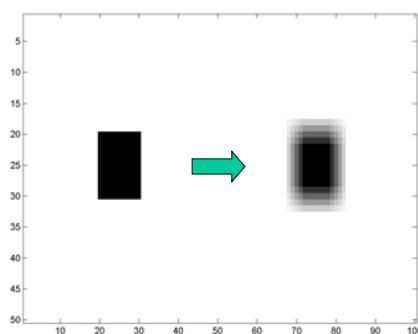


## $\gamma$ smoothing: low pass filtering

- Low pass filtering of  $\gamma$  ...

Filter (5x5):

$$\begin{pmatrix} 1/25 & 1/25 & 1/25 & 1/25 & 1/25 \\ 1/25 & \dots & & & \\ \dots & & & & \\ \dots & & & & 1/25 \end{pmatrix}$$



A.A. 2009-2010

42/45

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



## $\gamma$ smoothing



- $\gamma$  map has to be smoothed
- Down sampling, moving average  $3 \times 3$  filtering, up sampling using bilinear interpolation (or efficient moving average filter in space domain)
- Two classes: Background & soft tissue, bone tissue

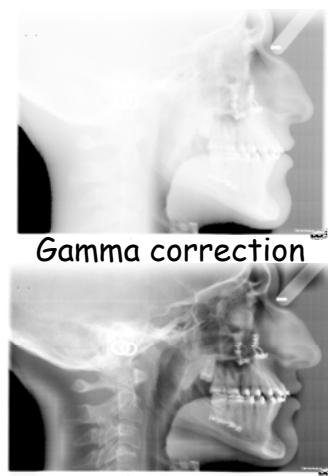
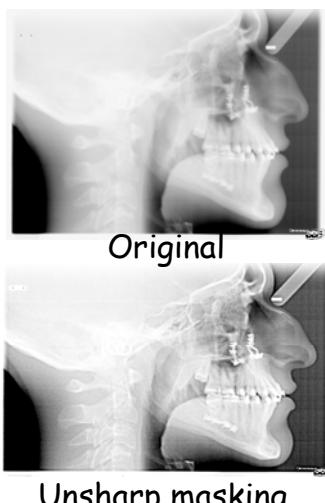
A.A. 2009-2010

43/45

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



## Results



A.A. 2009-2010

44/45

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



## Summary Soft Tissue Filter



- Mixture model for clustering;
- Gamma correction;
- Low pass filtering of gamma map.