

# Formation et Analyse d'Images

James L. Crowley

ENSIMAG 3

2009/2010

Séance 12

18 janvier 2010

## PCA, Mélange de Gaussiennes et L'Algorithme EM (Expectation-Maximization)

La Reconnaissance de Visage .....	2
L'Analyse en Composantes Principales .....	4
Exemple : .....	8
Reconstruction .....	11
Mélange de Gaussiens. ....	12
Ebauche de l'Algorithme EM.....	12
L'Algorithme EM (Expectation-Maximization).....	14
L'etape E.....	15
L'etape M.....	16

Sources Bibliographiques :

"Neural Networks for Pattern Recognition", C. M. Bishop, Oxford Univ. Press, 1995.

"Pattern Recognition and Scene Analysis", R. E. Duda and P. E. Hart, Wiley, 1973.

## La Reconnaissance de Visage

Ayant détecté et normalisé les imagerie de visages en position et taille (séance 11), il est possible de construire un système de reconnaissance Bayésienne.

Pour cela nous allons utiliser l'Analyse en Composants Principales (ACP ou PCA en Anglais) et une Mélange de Gaussiennes. (GMM pour Gaussian Mixture Model en Anglais)

Il nous faut un ensemble d'apprentissage. Soit  $M$  imagerie normalisés,  $\{W_m\}$  composées de  $K$  ensembles  $\{W_m^k\}$  de  $M_k$  imagerie pour  $K$  personnes.

$$\{W_m\} = \bigcup_k \{W_m^k\}, M = \sum_k M_k$$

Notre problème :

Ayant un nouvelle imagerie (normalisé)  $W$ , déterminer son identité,  $k$ .

$\omega_k \equiv W$  est une imagerie du face de la personne  $k$ .

$$\omega_k = \arg\text{-max}_k \{p(\omega_k | W)\}$$

Pour faire cette estimation, nous allons utiliser la règle de Bayes :

$$p(\omega_k | W) = \frac{p(W | \omega_k)p(\omega_k)}{p(W)}$$

Mais nous avons deux problèmes :

- 1) Quel vecteur de caractéristique,  $\vec{X}$ , doit en utiliser pour représenter  $W$
- 2) Comment déterminer (estimer)  $p(\omega_k | \vec{X})$  et  $P(\vec{X})$ .

Solutions proposé

- 1) Quel vecteur de caractéristiques  $\vec{X}$  d'utiliser ?

Pour le premier problème, nous allons utiliser une analyse en composantes principales pour construire un "sous-espace" de l'espace de  $W$ .

Avec un espace de composant principales  $\vec{\Phi}$

$$\bar{X} = \langle W, \vec{\varphi} \rangle$$

2) Comment représenter  $p(\omega_k | \bar{X})$  et  $P(\bar{X})$  ?

Pour le 2ième problème nous allons construire un mélange de Gaussiennes avec l'algorithme EM.

Mélange de Gaussiens. (GMM)

Nous allons représenter  $P(\bar{X})$  par :

$$P(\bar{X}) = \sum_{n=1}^N \alpha_n \mathcal{N}(\bar{X}; \vec{\mu}_n, \mathbf{C}_n)$$

et

$$P(\bar{X} | \omega_k) = \sum_{n=1}^N \alpha_n \mathcal{N}(\bar{X}; \vec{\mu}_{kn}, \mathbf{C}_{kn})$$

## L'Analyse en Composantes Principales

L'analyse en composantes principales d'un signal est une méthode de déterminer un sous-espace "optimale" pour la reconstruction. Elle est parfois utilisée pour définir un espace de caractéristiques pour la reconnaissance.

Soit un ensemble de  $M$  images normalisées en position et taille composé de  $N$  pixels :  $W_m(i, j)$

$W_m(i, j)$  pour tel que  $i \in [1, I], j \in [1, J]$ ,

Nous allons les exprimer en vecteur de  $N = I \times J$  :  $W_m(n)$

ou  $n = j \cdot I + i$  :  $W_m(n) = W_m(i, j)$

Il serait possible d'utiliser les pixels directement comme caractéristiques. Par exemple, pour des images de taille  $32 \times 32$ ,  $W_m(n)$  est un vecteur de  $1K$  caractéristique.

Mais il est préférable d'avoir un espace de dimension  $D < K < M$  ( $K$  est le nombre de classes,  $M$  est le nombre d'exemplaires). Dans ce cas, nous pouvons déterminer un sous-espace de dimension réduite par l'ACP.

On cherche une base orthogonale  $\vec{\varphi}(n) = \{\varphi_d(n)\} \forall d = 1, 2, \dots, D$  pour représenter les  $X(n)$ , telles que  $D \ll M$ .

Image moyenne  $\mu(n) = \frac{1}{M} \sum_{m=1}^M W_m(n)$

Image moyenne zéro  $V_m(n) = W_m(n) - \mu(n)$

Base orthogonale  $\vec{\varphi}(n) = \{\varphi_d(n)\}$  avec  $D \leq M$ .

Vecteur  $x_d = \langle V(n), \varphi_d(n) \rangle$

Image reconstruite :  $\hat{W}(n) = \mu(n) + \sum_{d=1}^D x_d \varphi_d(n)$

Image de résidu :  $R(n) = W(n) - \hat{W}(n)$

Energie de résidu :  $\varepsilon_r^2 = \sum_{n=1}^N R(n)^2$

Les bases  $\{\varphi_d(n)\}$  sont les vecteur propres du  $\{V_m(n)\}$  :  
 Sa covariance,  $C$ , est composée de  $N \times N = N^2$  termes

Soit le matrice  $V$  :

$$V = [V_1(n) V_2(n) \dots V_M(n)] = \begin{bmatrix} V_1(1) & V_2(1) & \dots & V_M(1) \\ V_1(2) & V_2(2) & \dots & V_M(2) \\ \dots & \dots & \dots & \dots \\ V_1(n) & V_2(n) & \dots & V_M(n) \end{bmatrix}$$

$V$  est  $N$  par  $M$ . Chaque colonne de  $V$  est une image.

$$C \equiv V V^T = \begin{pmatrix} \bullet & \bullet & \bullet & \bullet \\ \bullet & \bullet & \bullet & \bullet \\ \bullet & \bullet & \bullet & \bullet \\ \bullet & \bullet & \bullet & \bullet \\ \bullet & \bullet & \bullet & \bullet \\ \bullet & \bullet & \bullet & \bullet \\ \bullet & \bullet & \bullet & \bullet \end{pmatrix} \begin{pmatrix} \bullet & \bullet & \bullet & \bullet & \bullet & \bullet & \bullet & \bullet \\ \bullet & \bullet & \bullet & \bullet & \bullet & \bullet & \bullet & \bullet \\ \bullet & \bullet & \bullet & \bullet & \bullet & \bullet & \bullet & \bullet \\ \bullet & \bullet & \bullet & \bullet & \bullet & \bullet & \bullet & \bullet \\ \bullet & \bullet & \bullet & \bullet & \bullet & \bullet & \bullet & \bullet \end{pmatrix}$$

$$C = E\{V_m(n)V_m(n)^T\}$$

Les termes de  $C$  sont les covariances pour des pairs de pixels  $i$  et  $j$ .

$$\sigma_{ij}^2 = \frac{1}{M} \sum_{m=1}^M (V_m(i) \cdot V_m(j))$$

Pour une imagerie de taille  $N$  pixels, il y a  $N^2$  termes dans la covariance.

Chaque coefficient,  $\sigma_{ij}^2$ , est une covariance de la pixel  $i$  et  $j$  pour l'ensemble de  $M$  images. Par exemple, pour une imagerie de  $32 \times 32$ , le matrice  $C = VV^T$  est de taille  $1024 \times 1024$ .

Les vecteurs propres de  $C$  sont des vecteurs orthogonaux  $\vec{\varphi}(n) = \{\varphi_m(n)\}$  tels que :  $\varphi^T C \varphi = \varphi^T V V^T \varphi = \Lambda$  où  $\Lambda_n$  est un matrice diagonal de  $N$  termes  $\lambda_n$  des valeurs principales de  $C$ .

Chaque  $\varphi_m(n)$  est un vecteur de direction. L'ensemble  $\{\varphi_m(n)\}$  est orthogonal.

Une telle matrice de rotation est fournie par une d'analyse en composants principales. (Voir Recettes Numérique en C pour les procédures programmées).

$$(\varphi_m(n), \lambda_n) \leftarrow \text{PCA}(C).$$

Pour une imagerie de 32 x 32, le matrice  $C = V V^T$  est de taille  $2^{10} \times 2^{10} = 2^{20}$ .

Pour une image de 512 x 512, le matrice  $C = V V^T$  est de taille  $2^{18} \times 2^{18} = 2^{36}$ .

Les plupart des procédures PCA exige que  $N < 1024$ .

Mais, il y a une astuce pour éviter le calcul d'une matrice de covariance de  $N \times N$  coefficients.

Les algorithmes PCA fournissent les vecteurs propres  $\{\varphi_m(n)\}$  dans l'ordre décroissante de  $\lambda_n$ .

Ors, pour une ensemble de M image  $M \ll N$ , le rank de  $V V^T$  est de M.

Les premiers M vecteurs propres  $\varphi_1(n) \dots \varphi_m(n)$  sont les vecteurs propres de l'espace des images :

$C_m = V^T V$  est une  $M \times M$  covariance pour les paires d'images.

$C_m$  est de taille  $M^2$ , où M est le nombre d'images.

Les coefficients sont :

$$\sigma_{kl}^2 = \frac{1}{N} \sum_{n=1}^N V_k(n) V_l(n)$$

Les premiers M valeurs propres sont  $\{R_m(n)\}$

Chaque coefficient est une produit de deux images !

$$V^T V = C_m = \begin{pmatrix} \bullet & \bullet & \bullet & \bullet \\ \bullet & \bullet & \bullet & \bullet \\ \bullet & \bullet & \bullet & \bullet \\ \bullet & \bullet & \bullet & \bullet \end{pmatrix} = \begin{pmatrix} \bullet & \bullet & \bullet & \bullet & \bullet & \bullet & \bullet \\ \bullet & \bullet & \bullet & \bullet & \bullet & \bullet & \bullet \\ \bullet & \bullet & \bullet & \bullet & \bullet & \bullet & \bullet \\ \bullet & \bullet & \bullet & \bullet & \bullet & \bullet & \bullet \end{pmatrix} \begin{pmatrix} \bullet & \bullet & \bullet & \bullet \\ \bullet & \bullet & \bullet & \bullet \\ \bullet & \bullet & \bullet & \bullet \\ \bullet & \bullet & \bullet & \bullet \\ \bullet & \bullet & \bullet & \bullet \\ \bullet & \bullet & \bullet & \bullet \end{pmatrix}$$

Pour  $M < 1024$  on peut facilement calculer une matrice  $R$  de rotation tels que chaque colonne est un vecteur directeur orthogonal.

$$\mathbf{R}^T \mathbf{V}^T \mathbf{V} \mathbf{R} = \mathbf{\Lambda}_m$$

On multiplie les deux cotés par  $R$  :

$$\mathbf{R} \mathbf{R}^T \mathbf{V}^T \mathbf{V} \mathbf{R} = \mathbf{R} \mathbf{\Lambda}_m$$

On note que  $\mathbf{R}^T \mathbf{R} = \mathbf{I}$ .

donc :

$$\mathbf{V}^T \mathbf{V} \mathbf{R} = \mathbf{R} \mathbf{\Lambda}_m$$

Maintenant on multiplie par  $V$

$$\begin{aligned} \mathbf{V} \mathbf{V}^T \mathbf{V} \mathbf{R} &= \mathbf{V} \mathbf{R} \mathbf{\Lambda}_m \\ &= (\mathbf{V} \mathbf{V}^T) (\mathbf{V} \mathbf{R}) = (\mathbf{V} \mathbf{R}) \mathbf{\Lambda}_m \end{aligned}$$

Mais

$$\boldsymbol{\varphi}^T (\mathbf{V} \mathbf{V}^T) \boldsymbol{\varphi} = \mathbf{\Lambda}_N$$

donc

$$(\mathbf{V} \mathbf{V}^T) \boldsymbol{\varphi} = \boldsymbol{\varphi} \mathbf{\Lambda}_N$$

est le  $\mathbf{\Lambda}_m$  est un  $M \times M$  sous matrice de  $\mathbf{\Lambda}_N$

$\mathbf{\Lambda}_m = \mathbf{\Lambda}_N$  pour les premier  $m$  terms.

Donc

$$(\mathbf{V} \mathbf{V}^T) \boldsymbol{\varphi} = \boldsymbol{\varphi} \mathbf{\Lambda}_n = (\mathbf{V} \mathbf{R}) \mathbf{\Lambda}_m$$

pour les premier  $m$  terms

$$\varphi_m(n) = \sum_{l=1}^M V_l(n) R(l, m)$$

$$\begin{pmatrix} \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \end{pmatrix} = \begin{pmatrix} \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \end{pmatrix} \begin{pmatrix} \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \end{pmatrix}$$

Raison : Les mêmes images ont été utilisé pour  $\varphi$  et pour  $R$ .

Les premiers  $M$  vecteurs propres de  $V^T V$  sont aussi les premiers  $M$  vecteurs propres de  $V V^T$ , le Rank de  $\varphi$  est le même que  $R$ , et  $\lambda_b$  sont les premiers  $M$  valeurs propre de  $\lambda_c$  et Donc, les vecteurs propres :  $\varphi_d(n) = V R$  triés par  $\lambda_b$

$$\varphi = V R$$

Chaque colonne est un vecteur dans une base orthogonale.

$$\vec{\varphi}(n) = \sum_{m=1}^M V_{m(n)} R(m,n)$$

$\vec{\varphi}(n)$  fournit une base orthogonal pour  $W_{m(n)}$ .

Une imagerie (normalisée) peut être projeté sur  $\vec{\varphi}(n)$

Nous pouvons même utiliser une sous ensemble de  $D$  composants.


$$x_d = \langle V, \varphi_d \rangle = \sum_{n=1}^N V(n) \varphi_d(n)$$

Les valeurs  $x_d$  sont un "code" qui représente  $V(n)$  pour la reconnaissance ou la reconstruction.

**Exemple :**

16 images prise au hasard dans une séquence de 2 minutes. (F. Bérard, 1995).

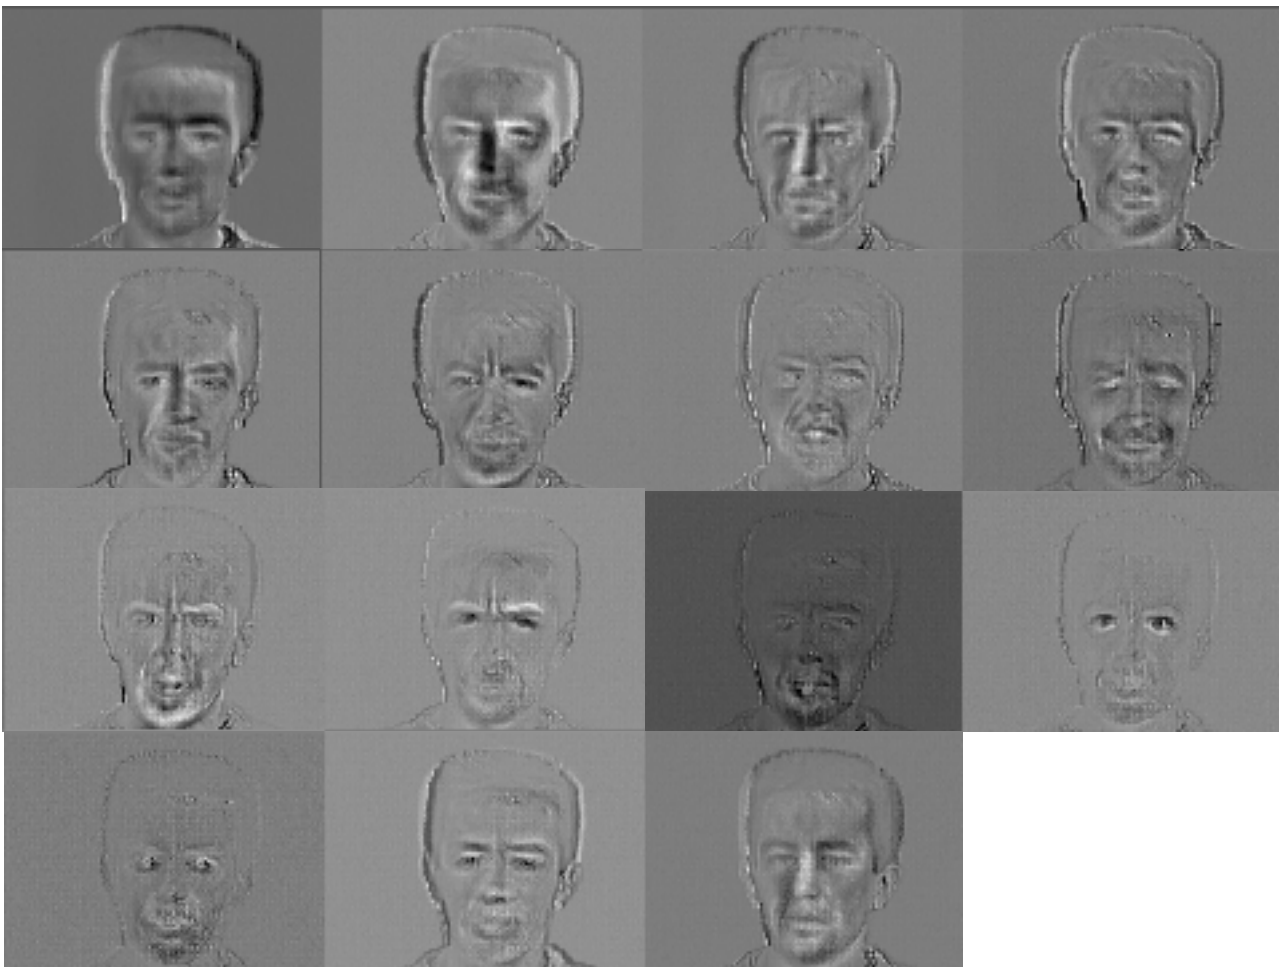





Average Image



Components Principales :



Eigen Values.



**Reconstruction**

Image                      Reconstructed image (120 bytes)    Error Image.



Reconstruction (120 bytes)



Image Error

## Mélange de Gaussiens.

Pour la reconnaissance, nous avons besoin :

$$p(\omega_k | \vec{X}) = \frac{p(\vec{X} | \omega_k) p(\omega_k)}{p(\vec{X})}$$

Si les imagettes de personne k sont issus d'une composition de "N" phénomènes, la densité  $p(\vec{X} | \omega_k)$  prendra la forme d'une composition de N lois Normales. Pour les visages, il peut s'agir des variations dans l'angle de l'éclairage, l'angle de vue, ou les expressions.

Dans un tel cas, on peut approximer par une somme pondérée de densités Normales.

$$P(\vec{X}) = \sum_{n=1}^N \alpha_n N(\vec{X}; \vec{\mu}_n, C_n) \quad \text{et} \quad P(\vec{X} | \omega_k) = \sum_n^N \alpha_n N(\vec{X}; \vec{\mu}_{nk}, C_{nk})$$

De telle somme est connue par le terme "mélange de Gaussiens"

Pour chaque Gaussien il faut estimer trois paramètres :

$$\vec{v} = (\alpha_n, \vec{\mu}_n, C_n)$$

Pour un vecteur X de D dimensions

En total il y a  $N(1+D+D^2)$  coefficients à estimer.

Pour simplifier, nous pouvons remplacer  $C_n$  par une matrice diagonale de variances :  $\sigma_{dn}^2$

Ca donnerait :  $N(1+2D)$  paramètres.

En tout cas, les paramètres  $\vec{v} = (\alpha_n, \vec{\mu}_n, C_n)$  sont les paramètres cachés des sources cachés des données.

L'algorithme d'Expectation Maximisation permet d'estimer les paramètres cachés.

## Ebauche de l'Algorithme EM

On suppose chaque événement  $E_m$  est issu d'un des N sources.

Nous allons construire une table de probabilités.  $h(m, n)$

$h(m, n) = \Pr\{\text{l'événement } E_m \text{ est issu de la source } N\}$

Les probabilités,  $h(m, n)$  donne des facteurs de Mélange,  $\alpha_n$ , ainsi que les  $\mu_n, \sigma_n$ .

Soit une ensemble ("training set") de  $M$  observations  $\mathbf{T} = \{X_m\}$ .

Fait une première estimation des paramètres,  $\vec{v}^{(0)}$ .

Ensuite l'algorithme va les raffiner par alternance des étapes "E" et "M".

E: Faire une estimation des valeurs manquantes,  $h(m, n)$ , pour les événements.

$h(m, n)^{(i)} = p(h_m | X_1, X_2, \dots, X_M, \vec{v}^{(i)})$  pour chaque terme "n".

$$h(m, n)^{(i)} = \frac{\alpha_n^{(i)} \mathcal{N}(X_m; \mu_n^{(i)}, \sigma_n^{(i)})}{\sum_{j=1}^N \alpha_j^{(i)} \mathcal{N}(X_m; \mu_j^{(i)}, \sigma_j^{(i)})}$$

M: Recalculer  $\vec{v}^{(i+1)}$  avec  $p(h_m | X_1, X_2, \dots, X_M, \vec{v}^{(i)})$

$$S_n^{(i+1)} = \sum_{m=1}^M h(m, n)^{(i)}$$

$$\alpha_n^{(i+1)} = \frac{1}{M} S_n^{(i+1)} = \frac{1}{M} \sum_{m=1}^M h(m, n)^{(i)}$$

$$\mu_n^{(i+1)} = \frac{1}{S_n^{(i+1)}} \sum_{m=1}^M h(m, n)^{(i)} X_m$$

$$\sigma_n^{2(i+1)} = \frac{1}{S_n^{(i+1)}} \sum_{m=1}^M h(m, n)^{(i)} (X_m - \mu_n^{(i+1)})^2$$

Pour la dérivation l'algorithme EM, il faut introduire le concept de "likelihood" (vraisemblance).

## L'Algorithme EM (Expectation-Maximization)

L'algorithme EM s'applique à l'estimation de données cachés.

Il est utilisé notamment pour l'estimation des Modèles de Markov Cachées (HMM's) et pour l'estimation des Mélanges de Gaussiens.

Pour un mélange de Gaussiens, les variables cachées sont les sources des événements. On suppose que chaque événement est produit par un des N sources.

Pour chaque événement  $E_m$  On définit la variable "cachée"  $h_m$

$h_m = N$  si l'événement  $E_m$  (avec caractéristique  $X_m$ ) est issu de la source N.

Nous cherchons à estimer

$$P(\vec{X}) = \sum_n^N \alpha_n N(\vec{X}; \vec{\mu}_n, C_n) \quad \text{tels que} \quad \sum_{n=1}^N \alpha_n = 1.$$

ou

$$\vec{v} = (\alpha_n, \vec{\mu}_n, C_n)$$

Il faut estimer  $\vec{v} = (\alpha_n, \vec{\mu}_n, C_n)$

Le likelihood de  $\{X_m\}$  est  $L(\vec{v} | \{X_m\}) = \prod_{m=1}^M P(X_m | \vec{v})$

Le Log-likelihood est

$$\begin{aligned} &= \text{Log} (L(\vec{v} | X_1, X_2, \dots, X_M)) = \text{Log} \left( \prod_{m=1}^M P(X_m | \vec{v}) \right) \\ &= \sum_{m=1}^M \text{Log} \{p(X_m | \vec{v})\} \\ &= \sum_{m=1}^M \text{Log} \left( \sum_{n=1}^N \alpha_n N(\vec{X}; \vec{\mu}_n, C_n) \right) \end{aligned}$$

Il faut  $\hat{v} = \arg\max_v \{L(\vec{v} | \{X_m\})\}$

Il n'y pas de solution analytique, parce qu'il n'y est pas une dérivé pour la logarithme de la somme.

Soit  $\mathbf{T} = \{X_m\} \cup h(m,n)$  le donnée Complète.

On vas maximiser une mesure de qualité  $Q(\vec{v}^{(i)})$  définit par une esperence conditionnel

$$Q(\vec{v}^{(i)}) = E\{l(\vec{v}^{(i)}) | \mathbf{T}\} = \text{Log} \left\{ \prod_{m=1}^M p(X_m | \vec{v}) \right\}$$

### L'etape E

Pour chaque événement  $E_m$  avec caractéristique  $X_m$ ,  
On suppose qu'il manque l'information:  $h_m$

$h_m = n$ , la source de l'événement  $E_m$ .

On ne connaît pas  $h_m$ , mais on peut estimer les probabilités  $P(h_m = n)$ .  
par une table  $h(m,n)$ .

Pour chaque  $X_m$ , et son source caché  $h_m$

$$p(h_m, X_m | \vec{v}) = p(h_m | X_m, \vec{v}) p(X_m | \vec{v})$$

donc

$$p(h_m | X_m, \vec{v}) = \frac{p(h_m, X_m | \vec{v})}{p(X_m | \vec{v})}$$

d'où

$$p(h_m = n, X_m | \vec{v}) = \alpha_n \mathcal{N}(X_m; \mu_n, \sigma_n)$$

$$p(X_m | \vec{v}) = \sum_{n=1}^N \alpha_n \mathcal{N}(X_m; \mu_n, \sigma_n)$$

Donc

$$p(h_m=n \mid X_1, X_2, \dots, X_M, \vec{v}) = \frac{\alpha_n \mathcal{N}(X_m; \mu_n, \sigma_n)}{\sum_{j=1}^N \alpha_j \mathcal{N}(X_m; \mu_j, \sigma_j)}$$

Donc pour chaque itération (i) le premier étape E est :

$$h(m, n)^{(i)} = \frac{\alpha_n^{(i)} \mathcal{N}(X_m; \mu_n^{(i)}, \sigma_n^{(i)})}{\sum_{j=1}^N \alpha_j^{(i)} \mathcal{N}(X_m; \mu_j^{(i)}, \sigma_j^{(i)})}$$

### L'etape M

Pour le deuxième étape, M, nous allons maximiser le "likelihood"  $\text{Log}\{p(X_m \mid \vec{v})\}$   
On définit la "Expected Complete Data Log Likelihood" pour  $\mathbf{T} = \{X_m\} \cup h(m, n)$

$$\Delta Q = Q(\vec{v}^{(i)}) - Q(\vec{v}^{(i-1)})$$

Pour chaque cycle dans l'itération nous allons chercher :

$$\vec{v}^{(i+1)} = \underset{\vec{v}}{\text{argmax}} \{Q(\vec{v} \mid \vec{v}^{(i)})\}$$

Ce maximum est donné par :

$$S_n^{(i+1)} = \sum_{m=1}^M p(h_m=n \mid X_m, \vec{v}^{(i)}) = \sum_{m=1}^M h(m, n)$$

$$\alpha_n^{(i+1)} = \frac{1}{M} \sum_{m=1}^M P(h_m = n \mid X_m, \vec{v}^{(i)}) = \frac{1}{M} S_n^{(i+1)}$$

$$\mu_n^{(i+1)} = \frac{1}{S_n^{(i)}} \sum_{m=1}^M p(h_m=n \mid X_m, \vec{v}^{(i)}) X_m = \frac{1}{S_n^{(i+1)}} \sum_{m=1}^M h(m, n) X_m$$

$$\begin{aligned} \sigma_n^{2(i+1)} &= \frac{1}{S_n^{(i)}} \sum_{m=1}^M p(h_m=n \mid X_m, \vec{v}^{(i)}) (X_m - \mu_n^{(i+1)})^2 \\ &= \frac{1}{S_n^{(i+1)}} \sum_{m=1}^M h(m, n) (X_m - \mu_n^{(i+1)})^2 \end{aligned}$$



Avec notre table de probabilités  $h(m, n)$

$$h(m, n) = P(h_m=n \mid X_m, \vec{v}^{(i)})$$

E (Expectation) :

$$h(m, n)^{(i)} := \frac{\alpha_n^{(i)} \mathcal{N}(X_m; \mu_n^{(i)}, \sigma_n^{(i)})}{\sum_{j=1}^N \alpha_j^{(i)} \mathcal{N}(X_m; \mu_j^{(i)}, \sigma_j^{(i)})}$$

M: (Maximisation)

$$S_n^{(i+1)} := \sum_{m=1}^M h(m, n)^{(i)}$$

$$\alpha_n^{(i+1)} := \frac{1}{M} S_n^{(i+1)}$$

$$\mu_n^{(i+1)} := \frac{1}{S_n^{(i+1)}} \sum_{m=1}^M h(m, n)^{(i)} X_m$$

$$\sigma_n^{2(i+1)} := \frac{1}{S_n^{(i+1)}} \sum_{m=1}^M h(m, n)^{(i)} (X_m - \mu_n^{(i+1)})^2$$

Dans le cas Multivariate ( $D > 1$ ) la covariance  $C$  est composée de  $\sigma_{jk}^2$ :

$$\sigma_{jkn}^{2(i+1)} := \frac{1}{S_n^{(i+1)}} \sum_{m=1}^M h(m, n)^{(i)} (X_{jm} - \mu_{jn}^{(i+1)})(X_{km} - \mu_{kn}^{(i+1)})$$