

# **Master IAD**

## **Module PS**

Reconnaissance de la parole (suite)

**Modèles de Markov et bases de données**



**Gaël RICHARD**

**Février 2008**




# Reconnaissance de la parole

---

- Introduction
- Approches pour la reconnaissance vocale
- Paramétrisation
- Distances et mesures de distortion spectrale
- Alignement Temporel et Programmation dynamique (DTW)
- **Introduction aux modèles de Markov Cachés**
- Bases de données pour la reconnaissance
- Exemples d'applications

# Chaînes de Markov discrètes



# Chaînes de Markov discrètes

## □ Notations

- ✓  $t=1,2 \dots$  sont les instants de changement d'états
- ✓  $q_t$  est l'état à l'instant  $t$
- ✓ La probabilité d'être dans l'état  $j$  sachant que l'on a été dans l'état  $i$  au temps  $t-1$  et dans l'état  $k$  à l'état  $t-2$ , etc... est:

$$P[q_t = j | q_{t-1} = i, q_{t-2} = k, \dots]$$

- ✓ Chaînes de Markov du premier ordre:

$$P[q_t = j | q_{t-1} = i, q_{t-2} = k, \dots] = P[q_t = j | q_{t-1} = i]$$

# Chaînes de Markov discrètes (notations)

- Système dont les changements d'états sont indépendants du temps:

Avec les propriétés suivantes:

$$a_{ij} = P[q_t = j | q_{t-1} = i] \quad \text{pour } 1 \leq i, j \leq N$$


$$a_{ij} \geq 0 \quad \forall j, i$$

$$\sum_{j=1}^N a_{ij} = 1 \quad \forall i$$

Probabilité de l'état initial

$$\pi_i = P[q_1 = i], \quad 1 \leq i \leq N$$

# Exercice: Modèle Météo à 3 états



- Ecrire la matrice de transition A
- Sachant qu'à  $t=1$  le temps est ensoleillé, quelle est la probabilité (connaissant le modèle) que le temps pour les 7 prochains jours soit *(Soleil, Soleil, pluie, pluie, Soleil, Nuageux, Soleil)*?
- Sachant que le système est dans un état connu, quelles est la probabilité qu'il reste dans cet état pendant exactement  $d$  jours ?

# Exercice: Modèle Météo à 3 états (correction)

□ La matrice A vaut:

$$A = \begin{pmatrix} 0.4_{11} & 0.3_{12} & 0.3_{13} \\ 0.2_{21} & 0.6_{22} & 0.2_{23} \\ 0.1_{31} & 0.1_{32} & 0.8_{33} \end{pmatrix}$$

□ Soit l'observation:

$\mathbf{O} = (\text{Soleil, Soleil, Soleil, Pluie, Pluie, Soleil, Nuageux, Soleil, } )$

$$\begin{aligned} P(\mathbf{O}|Model) &= P[3,3,3,1,1,3,2,3,|Model] \\ &= P[3]P[3|3]^2P[1|3]P[1|1]P[3|1]P[2|3]P[3|2] \\ &= \pi_3 \cdot (a_{33})^2 a_{31} a_{11} a_{13} a_{32} a_{23} \\ &= (1.0)(0.8)^2(0.1)(0.4)(0.3)(0.1)(0.2) \\ &= 1.536 \times 10^{-4} \end{aligned}$$

# Exercice: Modèle Météo à 3 états (correction)

□ Soit la séquence d'observation:

✓  $O = (i, i, i, i, \dots, i, j \neq i)$

$$\begin{aligned}P(\mathbf{O} | Model, q_1 = i) &= P(\mathbf{O}, q_1 = i | Model) / P(q_1 = i) \\&= P[i] P[i|i]^{d-1} P[i|j] / P[i] \\&= \pi_i (a_{ii})^{d-1} (1 - a_{ii}) / \pi_i \\&= (a_{ii})^{d-1} (1 - a_{ii})\end{aligned}$$


# Extension aux modèles de Markov cachés

## ❑ Modèle Pile (P) ou Face (F)

❑ Fournit une séquence d'observations

$$\begin{aligned} \mathbf{O} &= ( \mathbf{O}_1 \quad \mathbf{O}_2 \quad \mathbf{O}_3 \quad \dots \quad \mathbf{O}_T ) \\ &= ( \quad \text{F} \quad \text{P} \quad \text{F} \quad \dots \quad \text{F} \end{aligned}$$


- ✓ Le premier modèle qui vient à l'esprit est le modèle suivant où une seule pièce de monnaie est utilisée



# Extension aux modèles de Markov cachés


- Construire d'autres modèles en supposant que l'on a:
  - ✓ **2 pièces de monnaie** qui possèdent un biais différent (par exemple la pièce A a une probabilité 0.6 de sortir Face alors que la pièce B a une probabilité 0.4 de sortir Face)
  - ✓ **Extrapoler à un modèle de 3 pièces de monnaie**

# Extension aux modèles de Markov cachés (solution)



$$P(F) = P_1 \quad P(F) = P_2$$

$$P(P) = 1 - P_1 \quad P(P) = 1 - P_2$$



ETAT

	1	2	3
$P(F)$	$P_1$	$P_2$	$P_3$
$P(P)$	$1 - P_1$	$1 - P_2$	$1 - P_3$

# Extension aux modèles de Markov cachés

## □ Modèle des boules et des urnes



## □ M couleurs

## □ Le tirage s'effectue de la façon suivante:

- ✓ Une urne est sélectionnée (selon une procédure aléatoire)
- ✓ Une boule est ensuite tirée dans cette urne. La couleur de la boule constitue l'observation
- ✓ La boule est remplacée dans l'urne et une nouvelle urne peut être sélectionnée pour le tirage suivant

# Extension aux modèles de Markov cachés

---

- ❑ Le tirage est effectué dans une autre pièce  
ne permet pas de savoir dans quelle urne a été tirée chaque boule
- ❑ Un modèle approprié: modèle de markov à N états

# Caractérisation des HMM

□ Un modèle HMM pour des données d'observations discrètes sera caractérisé par:

✓ **Le nombre  $N$  d'états du modèle**

- Modèle HMM ergodique
- Modèle HMM Gauche-droite
- $q_t$  est l'état à l'instant  $t$

✓ **Le nombre  $M$  de symboles distincts d'observation** par état (soit la taille de l'alphabet)

- Ex P et F pour le modèle Pile ou Face
- Ex. Les couleurs pour le modèle Boules et urnes
- On notera ces symboles sous la forme:

$$V = \mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_M$$



# Caractérisation des HMM

- ✓ **La matrice  $A=a_{ij}$  de transition** entre états où

$$a_{ij} = P[q_t = j | q_{t-1} = i] \quad \text{pour } 1 \leq i, j \leq N$$

*Notons que  $a_{ij} = 0$  pour les transitions impossibles*

- ✓ **La distribution de probabilité  $B=b_j(k)$  d'observation** des symboles où

$$b_j(k) = P[\mathbf{o}_t = \mathbf{v}_k | q_t = j], \quad \text{pour } 1 \leq k \leq M$$

définit la distribution de probabilité des symboles dans l'état  $j$

- ✓ **La distribution de l'état initial pour laquelle**

$$\pi_j = P[q_1 = j], \quad \text{pour } 1 \leq j \leq N$$

# Caractérisation des HMM

- En résumé, la spécification complète d'un HMM est donnée par:
  - ✓ Paramètres  $N$  et  $M$  du modèle
  - ✓ La spécification des symboles d'observation
  - ✓ La spécification des probabilités  $A$ ,  $B$  et  $\Pi$
  - ✓ On notera par convention  $\lambda = (A, B, \pi)$  pour désigner le modèle complet.
  - ✓ Ce modèle inclut une mesure de probabilité soit:  $P(\mathbf{O}|\lambda)$

# HMM: Générateur d'observations (Exercice)

- Supposons les modèles à 3 états suivants dans le cadre d'une expérience Pile ou Face:

	Etat 1	Etat 2	Etat3
P(F)	0.5	0.75	0.25
P(P)	0.5	0.25	0.75

avec chaque probabilité de transition étant gale à 1/3 (la probabilité d'état initiale étant également égale à 1/3)

## Questions:

- Connaissant la séquence  $O=(F F F F P F P P P P)$ , quelle est la séquence d'états la plus probable ? Quelle est la probabilité d'observer cette séquence et celle de cette séquence d'états
- Quelle est la probabilité que la séquence d'observation provienne entièrement de l'état 1 ?
- En est-il de même avec la séquence  $O=(F P P F P F F P P F)$  ?
- Quelles seraient vos réponses avec la matrice de transition suivante:

$a_{11}=0.9$	$A_{21}=0.45$	$a_{33}=0.45$
$a_{12}=0.05$	$a_{22}=0.1$	$a_{32}=0.45$
$a_{13}=0.05$	$a_{23}=0.45$	$a_{33}=0.1$



# Les trois problèmes des HMM

## ❑ Problème 1: Évaluer la probabilité d'une séquence d'observations.

*connaissant la séquence d'observation  $\mathbf{O} = (o_1, o_2, o_3, \dots, o_T)$   
et le modèle,  $\lambda = (A, B, \pi)$  comment peut-on calculer  $P(\mathbf{O}|\lambda)$  qui est la  
probabilité de la séquence d'observations, connaissant le modèle.*

## ❑ Problème 2: Retrouver la séquence d'états optimale.

*connaissant la séquence d'observation  $\mathbf{O} = (o_1, o_2, o_3, \dots, o_T)$   
et le modèle  $\lambda = (A, B, \pi)$  comment choisit-on la séquence d'état  
 $q = (q_1, q_2, q_3, \dots, q_T)$  qui est optimale au sens d'un certain critère (i.e. la  
séquence d'état qui "explique" au mieux les observations)*

# Les trois problèmes des HMM

## □ Problème 3: Ré-estimer les paramètres du modèle.

*Comment ajuste-t-on les paramètres du modèle  $\lambda = (A, B, \pi)$  pour maximiser  $P(\mathbf{O}|\lambda)$  qui est la probabilité de la séquence d'observation connaissant le modèle.*

# Problème 1: Évaluer la probabilité d'une séquence d'observations.

*connaissant la séquence d'observation et le modèle, comment peut-on calculer la probabilité de la séquence d'observations, connaissant le modèle.*

- ✓ **Solution intuitive:** énumérer toutes les séquences d'états de taille  $T$  ( $N^T$  séquences possibles)

Soit  $\mathbf{q}$  l'une de ces séquences:  $\mathbf{q} = (q_1, q_2, \dots, q_T)$

En supposant que les observations sont statistiquement indépendantes:

$$P(\mathbf{O}|\mathbf{q},\lambda) = \prod_{t=1}^T P(\mathbf{o}_t|q_t,\lambda)$$

On en déduit:

$$P(\mathbf{O}|\mathbf{q},\lambda) = b_{q_1}(\mathbf{o}_1) \cdot b_{q_2}(\mathbf{o}_2) \dots b_{q_T}(\mathbf{o}_T)$$



# Problème 1: Évaluer la probabilité d'une séquence d'observations.

- ✓ la probabilité d'une telle séquence d'états est aussi donnée par:

$$P(\mathbf{q}|\lambda) = \pi_{q_1} a_{q_1 q_2} a_{q_2 q_3} \dots a_{q_{T-1} q_T}$$

- ✓ La probabilité jointe de  $\mathbf{O}$  et  $\mathbf{q}$  est le produit des deux termes

$$P(\mathbf{O}, \mathbf{q}|\lambda) = P(\mathbf{O}|\mathbf{q}, \lambda) \cdot P(\mathbf{q}|\lambda)$$

- ✓ La probabilité de la séquence  $\mathbf{O}$  est donnée en sommant cette probabilité jointe sur l'ensemble des séquences d'états possibles  $\mathbf{q}$

$$\begin{aligned} P(\mathbf{O}|\lambda) &= \sum_{\text{all } \mathbf{q}} P(\mathbf{O}|\mathbf{q}, \lambda) \cdot P(\mathbf{q}|\lambda) \\ &= \sum_{q_1, q_2, \dots, q_T} \pi_{q_1} b_{q_1}(\mathbf{o}_1) a_{q_1 q_2} b_{q_2}(\mathbf{o}_2) a_{q_2 q_3} \dots b_{q_T}(\mathbf{o}_T) a_{q_{T-1} q_T} \end{aligned}$$

# Problème 1: Évaluer la probabilité d'une séquence d'observations.

## □ Interprétation

- à **t=1**: nous sommes dans l'état  $q_1$  avec la probabilité  $\pi_{q_1}$  et nous générons un symbole  $\mathbf{o}_1$  avec la probabilité  $b_{q_1}(\mathbf{o}_1)$
- à **t=2**, nous faisons une transition à l'état  $q_2$  à partir de l'état  $q_1$  avec la probabilité  $a_{q_1q_2}$  et générons le symbole  $\mathbf{o}_2$  avec la probabilité  $b_{q_2}(\mathbf{o}_2)$
- et ainsi de suite jusqu'à  $\mathbf{o}_T$

# Problème 1: Évaluer la probabilité d'une séquence d'observations.

- Complexité de l'approche pour évaluer  $P(\mathbf{O}|\lambda)$ 
  - ✓  $(2T - 1)N^T$  multiplications
  - ✓  $N^T - 1$  additions
  
- Calcul impossible même pour des petites valeurs de N (nombre d'états) et T (nombre d'observations).
  
- **Une solution:** l'algorithme forward (ou récurrence avant)

# Algorithme Forward

- Soit la variable définie par :

$$\alpha_t(i) = P(\mathbf{o}_1, \mathbf{o}_2, \mathbf{o}_3 \dots \mathbf{o}_t, q_t = i | \lambda)$$

qui est la probabilité de la séquence d'observations partielle  $\mathbf{o}_1, \mathbf{o}_2, \mathbf{o}_3 \dots \mathbf{o}_t$  et de l'état  $i$  à l'instant  $t$  connaissant le modèle

- **Algorithme:**

- ✓ Initialisation

$$\alpha_1(i) = \pi_i b_i(\mathbf{o}_1), \quad 1 \leq i \leq N$$

- ✓ Récursion

$$\alpha_{t+1}(j) = \left[ \sum_{i=1}^N \alpha_t(i) a_{ij} \right] b_j(\mathbf{o}_{t+1}), \quad 1 \leq t \leq T - 1, \quad 1 \leq j \leq N$$

- ✓ Arrêt

$$P(\mathbf{O} | \lambda) = \sum_{i=1}^N \alpha_T(i)$$

# Algorithme Forward

- Approche largement moins complexe:

- ✓  $N(N+1)(T-1) + N$  multiplications

- ✓  $N(N-1)(T-1)$  additions

- De façon similaire, on peut définir un algorithme backward à partir de la probabilité de la séquence d'observation partielle de  $t+1$  à la fin étant donné l'état  $i$  au temps  $t$  et le modèle:

$$\beta_t(i) = P(\mathbf{o}_{t+1}, \mathbf{o}_{t+2}, \mathbf{o}_{t+3} \dots \mathbf{o}_T | q_t = i, \lambda)$$



## Problème 2: Retrouver la séquence d'états optimale.

- ❑ On cherche ici à trouver une séquence optimale d'états connaissant la séquence d'observations
- ❑ L'approche couramment retenue est de trouver **l'unique** meilleure séquence d'états (ou encore chemin)
- ❑ Méthode basée sur la programmation dynamique : **l'algorithme de Viterbi**

## Problème 2: Retrouver la séquence d'états optimale.

- On introduit la notion de meilleur chemin partiel jusqu 'au temps  $t$  et finissant à l 'état  $i$ :

$$\delta_t(i) = \max_{q_1, q_2, \dots, q_{t-1}} P[q_1 q_2 \dots q_{t-1}, q_t = i, \mathbf{o}_1 \mathbf{o}_2, \dots, \mathbf{o}_t | \lambda]$$

- Par récurrence, on peut alors déterminer:

$$\delta_{t+1}(j) = [\max_i \delta_t(i) a_{ij}] \cdot b_j(\mathbf{o}_{t+1})$$

- En pratique, il sera aussi nécessaire de garder la séquence d 'états pour chaque temps  $t$ . Ce sera réalisé à l 'aide du tableau  $\psi_t(j)$

## Problème 2: Retrouver la séquence d'états optimale.

### □ Algorithme:

#### ✓ Initialisation

$$\delta_1(i) = \pi_i b_i(\mathbf{o}_1), \quad 1 \leq i \leq N$$

$$\psi_1(i) = 0$$

#### ✓ Récursion

$$\delta_t(j) = \max_{1 \leq i \leq N} [\delta_{t-1}(i) a_{ij}] \cdot b_j(\mathbf{o}_t), \quad 2 \leq t \leq T - 1; \quad 1 \leq j \leq N$$

$$\psi_t(j) = \arg \max_{1 \leq i \leq N} [\delta_{t-1}(i) a_{ij}], \quad 2 \leq t \leq T - 1; \quad 1 \leq j \leq N$$

#### ✓ Arrêt

$$P^* = \max_{1 \leq i \leq N} [\delta_T(i)]$$

$$q_T^* = \arg \max_{1 \leq i \leq N} [\delta_T(i)]$$

#### ✓ Rétropropagation (chemin optimal)

$$q_t^* = \psi_{t+1}(q_{t+1}^*), \quad t = T - 1, T - 2, \dots, 1$$

# Exercice: Algorithme de Viterbi

- Soit le modèle choisi pour l'expérience avec 3 pièces avec les probabilités suivantes:
  - ✓ Etat1:  $P(P) = P(F) = 0.5$
  - ✓ Etat2:  $P(P)=0.75; P(F) = 0.25$
  - ✓ Etat 3:  $P(P) = 0.25; P(F)=0.75$
  - ✓ Tous les  $a_{ij} = 1/3$ ; probabilités initiales =  $1/3$
  
- ✓ Quel est la séquence d'état optimale obtenue par l'algorithme de Viterbi pour l'observation (F F F F P F P P P P) ?

# Problème 3: Ré-estimer les paramètres du modèle.

- ❑ Problème plus complexe
- ❑ Utilisation de l'algorithme de Baum-Welch (aussi connu sous le nom d'algorithme Expectation-Maximisation)
- ❑ Objectif: Ré-estimer les paramètres du modèle  $\lambda = (A, B, \pi)$  pour maximiser localement  $P(\mathbf{O}|\lambda)$

## Ré-estimer les paramètres du modèle (2)


□ Définissons la probabilité d'être dans l'état  $i$  à l'instant  $t$  et dans l'état  $j$  à l'instant  $t + 1$  connaissant le modèle, et la séquence d'observation  $\mathbf{O}$ :  $\xi_t(i, j)$

□ On a:

$$\begin{aligned}\xi_t(i, j) &= P(q_t = i, q_{t+1} = j | \mathbf{O}, \lambda) \\ &= \frac{P(q_t = i, q_{t+1} = j, \mathbf{O} | \lambda)}{P(\mathbf{O} | \lambda)}\end{aligned}$$

# Ré-estimer les paramètres du modèle (2)

□ Interprétation:



□  $\xi_t(i, j)$  est l'ensemble des chemins vérifiant les conditions requises par l'équation précédente:

$$\begin{aligned} \xi_t(i, j) &= \frac{\alpha_t(i) a_{ij} b_j(\mathbf{o}_{t+1}) \beta_{t+1}(j)}{P(\mathbf{O} | \lambda)} \\ &= \frac{\alpha_t(i) a_{ij} b_j(\mathbf{o}_{t+1}) \beta_{t+1}(j)}{\sum_{i=1}^N \sum_{j=1}^N \alpha_t(i) a_{ij} b_j(\mathbf{o}_{t+1}) \beta_{t+1}(j)} \end{aligned}$$

# Ré-estimer les paramètres du modèle (3)

- La probabilité d'être dans l'état  $i$  à l'instant  $t$  connaissant la séquence d'observation  $\mathbf{O}$  et le modèle est  $\gamma_t(i)$ , et s'écrit:

$$\gamma_t(i) = \sum_{j=1}^N \xi_t(i, j)$$

- Par ailleurs, si l'on somme  $\gamma_t(i)$  sur le temps  $t$ , on obtient une quantité qui peut être interprétée comme une estimation du nombre de fois que l'état  $i$  est visité (Si l'on ne somme que sur les  $T-1$  premiers indices, on a une estimation du nombre de transitions à partir de l'état  $i$ ).
- De même, si l'on somme la variable  $\xi_t(i, j)$  sur le temps (sur les  $T$  premiers indices), on obtient une estimation du nombre de transitions de l'état  $i$  vers l'état  $j$ .

# Ré-estimer les paramètres du modèle (4)

□ On obtient finalement:

$$\begin{aligned}\bar{\pi}_j &= \text{estimation du nombre de fois dans l'état } i \text{ à l'instant } t = 1 \\ &= \gamma_1(i)\end{aligned}$$

$$\begin{aligned}\bar{a}_{ij} &= \frac{\text{estimation du nombre de transitions de l'état } i \text{ à l'état } j}{\text{estimation du nombre de transitions à partir de l'état } i} \\ &= \frac{\sum_{t=1}^{T-1} \xi_t(i,j)}{\sum_{t=1}^{T-1} \gamma_t(i)}\end{aligned}$$

$$\begin{aligned}\bar{b}_j(k) &= \frac{\text{estimation du nombre de fois dans l'état } j \text{ en y observant le symbole } \mathbf{v}_k}{\text{estimation du nombre de fois dans l'état } j} \\ &= \frac{\sum_{t=1, \mathbf{o}_t = \mathbf{v}_k}^{T-1} \gamma_t(i)}{\sum_{t=1}^{T-1} \gamma_t(i)}\end{aligned}$$

# Ré-estimer les paramètres du modèle (5)

- Ainsi, à partir du modèle courant  $\lambda = (A, B, \pi)$  on obtient un modèle réestimé  $\bar{\lambda} = (\bar{A}, \bar{B}, \bar{\pi})$  pour lequel, on a:

$$P(\mathbf{O}|\bar{\lambda}) > P(\mathbf{O}|\lambda)$$

- On peut montrer que l'approche décrite est équivalente à l'utilisation de l'algorithme EM qui maximisera par rapport à  $\lambda$  la fonction auxiliaire de Baum :

$$Q(\lambda', \lambda) = \sum_{\mathbf{q}} P(\mathbf{O}, \mathbf{q}|\lambda') \log P(\mathbf{O}, \mathbf{q}|\lambda)$$

# Densités d'observations continues

- Les paramètres prennent en général des valeurs continues, d'où l'intérêt d'utiliser des densités d'observation continues
- Pour des modèles simples (par exemple sommes de Gaussiennes), on peut trouver des expressions analytiques pour les formules de réestimation.

$$b_j(\mathbf{o}) = \sum_{k=1}^M c_{jk} \mathcal{N}(\mathbf{o}, \mu_{jk} \Gamma_{jk}), \quad 1 \leq j \leq N$$

# Densités d'observations continues

- Modèle par somme de Gaussiennes

$$b_j(\mathbf{o}) = \sum_{k=1}^M c_{jk} \mathcal{N}(\mathbf{o}, \mu_{jk} \Gamma_{jk}), \quad 1 \leq j \leq N$$

- Avec:

$$\sum_{k=1}^M c_{jk} = 1, \quad 1 \leq j \leq N$$
$$c_{jk} \geq 0, \quad 1 \leq j \leq N, \quad 1 \leq k \leq M$$

# Approche par Mélanges de Gaussiennes

(Voir Cours O. Cappé [http://tsi.enst.fr/~ocappe/em\\_tap.pdf](http://tsi.enst.fr/~ocappe/em_tap.pdf))

□ Modèle de mélange

$$f(\mathbf{x}) = \sum_{i=1}^M \pi_i f_i(\mathbf{x})$$


$f_i(\mathbf{x})$  est une densité de probabilité.

$$f_i(\mathbf{x}) = \frac{1}{(2\pi)^{p/2}} |\Sigma_i|^{-1/2} \exp \left[ -\frac{1}{2} (\mathbf{x} - \mu_i)' \Sigma_i^{-1} (\mathbf{x} - \mu_i) \right]$$

$\pi_i$  sont des scalaires positifs

$$\sum_{i=1}^M \pi_i = 1$$

□ Exemple à 2 dimensions avec 1, 2 puis 3 gaussiennes







TELECOM  
ParisTech







# Approche par Mélanges de Gaussiennes (GMM)

## □ Exemple de modèles à 2 composantes



# Approche par Mélanges de Gaussiennes (GMM)


□ Exemple de modèles à 2 composantes



# Equivalence de modèles

## □ Equivalence entre

- ✓ un état d'une chaîne de Markov cachée avec une densité d'observation sous la forme d'un mélange de Gaussiennes
- ✓ un modèle multi-états en parallèle contenant chacun une des Gaussiennes du mélange:



# Formules de ré-estimation

$$\overline{c_{jk}} = \frac{\sum_{t=1}^T \gamma_t(j,k)}{\sum_{t=1}^T \sum_{k=1}^M \gamma_t(j,k)}$$

$$\overline{\mu_{jk}} = \frac{\sum_{t=1}^T \gamma_t(j,k) \cdot \mathbf{o}_t}{\sum_{t=1}^T \gamma_t(j,k)}$$

$$\overline{\Gamma_{jk}} = \frac{\sum_{t=1}^T \gamma_t(j,k) \cdot (\mathbf{o}_t - \mu_{jk})(\mathbf{o}_t - \mu_{jk})'}{\sum_{t=1}^T \gamma_t(j,k)}$$

- Où la probabilité d'être dans l'état  $j$  au temps  $t$  avec la  $k^{\text{ième}}$  Gaussienne du mélange représentant  $\mathbf{o}_t$  est donnée par:

$$\gamma_t(j,k) = \left[ \frac{\alpha_t(j)\beta_t(j)}{\sum_{j=1}^N \alpha_t(j)\beta_t(j)} \right] \left[ \frac{c_{jk} \mathcal{N}(\mathbf{o}_t, \mu_{jk} \Gamma_{jk})}{\sum_{m=1}^M c_{jm} \mathcal{N}(\mathbf{o}_t, \mu_{jm} \Gamma_{jm})} \right]$$

# Exemples d'application

## □ Application de dialogue (technologie LIMSI-Vecsys)

- ✓ Application boursière: Live quotes (08 92 702 440)
  - Grand public
  - Peu de langage naturel
  
- ✓ Démo RATP : serveur SIEL (démon interne)
  - Illustration du barge in (interruption du système)
  
- ✓ Démo SNCF: Système RECITAL (0 805 90 22 22)
  - Grand public
  - Langage naturel plus développé
  - Pas de barge in

