

# TAPPE : Étude de document

Substate tying with combined parameter training  
and reduction in tied-mixture HMM design

Daniel Déchelotte

Encadré par Olivier Cappé

## Plan de la soutenance

- 1 Liage partiel d'états dans un HMM**
- 2 Entraînement et réduction combinés des paramètres**
- 3 Performances obtenues en utilisant ces techniques**

# 1 Liage partiel d'états dans un HMM

## 1.1 Motivation

## 1.2 TMHMM et liage d'état

## 1.3 Mélanges de gaussiennes à deux étages

## Mélanges de gaussiennes à deux étages : définitions

- $K$  gaussiennes, définies par  $v_k = (\mu_k, \Sigma_k)$
- $L$  sous-mélanges, définis par  $q_{k|l} = Pr(v_k|\omega_l)$
- Les densités de probabilités d'émission pour chaque état  $s_{m,n}$  sont données par

$$Pr(x|s_{m,n}) = \sum_{l=1}^L \left\{ \sum_{k=1}^K g(x|v_k) q_{k|l} \right\} p_{l|m,n}$$

où  $p_{l|m,n} = Pr(\omega_l|s_{m,n})$ .

## Mélanges de gaussiennes à deux étages : entraînement

$$\hat{\mu}_k = \frac{\sum_t \sum_{s_{m,n}} \sum_l \text{Pr}(v_k, \omega_l, s_{m,n} | x_t) \cdot x_t}{\sum_t \sum_{s_{m,n}} \sum_l \text{Pr}(\omega_l, s_{m,n} | x_t)} \quad (1)$$

$$\hat{\Sigma}_k = \frac{\sum_t \sum_{s_{m,n}} \sum_l \text{Pr}(v_k, \omega_l, s_{m,n} | x_t) \cdot (x_t - \hat{\mu}_k) \cdot (x_t - \hat{\mu}_k)^T}{\sum_t \sum_{s_{m,n}} \sum_l \text{Pr}(\omega_l, s_{m,n} | x_t)} \quad (2)$$

$$q_{k|l} = \frac{\sum_t \sum_{s_{m,n}} \text{Pr}(v_k, \omega_l, s_{m,n} | x_t)}{\sum_t \sum_{s_{m,n}} \text{Pr}(\omega_l, s_{m,n} | x_t)} \quad (3)$$

$$p_{l|s_{m,n}} = \frac{\sum_t \text{Pr}(\omega_l, s_{m,n} | x_t)}{\sum_t \sum_{l'} \text{Pr}(\omega_{l'}, s_{m,n} | x_t)} \quad (4)$$

## **2 Entraînement et réduction combinés des paramètres**

### **2.1 Motivation et description**

### **2.2 Application au cas des TMHMM à deux étages**

## Réduction des paramètres : quels paramètres ?

- Une gaussienne  $\nu_k$ , et les  $q_{k|l}$  correspondants
- Un sous-mélange  $\omega_l$ , et les  $p_{l|m,n}$  correspondants
- Certaines gaussiennes d'un mélange : les  $q_{k|l}$  inférieurs à un seuil sont mis à 0.
- Certains sous-mélanges de la densité de probabilité d'un état : les  $p_{l|m,n}$  inférieurs à un (autre) seuil sont mis à 0.

## Réduction des paramètres : quel critère ? (1/2)

Le critère utilisé pour déterminer quels gaussiennes et sous-mélanges éliminer est *l'entropie conditionnelle partielle*.

À partir de la probabilité a posteriori  $Pr(\omega_l | v_k) = \frac{Pr(\omega_l)q_{kl}}{Pr(v_k)}$ , on calcule « l'entropie a posteriori des sous-mélanges conditionnellement à la gaussienne  $v_k$  » :

$$H(\Omega | v_k) = - \sum_{l=1}^L Pr(\omega_l | v_k) \log \{ Pr(\omega_l | v_k) \}.$$



## Réduction des paramètres : quel critère ? (2/2)

On pondère par la probabilité de  $v_k$  pour obtenir l'entropie conditionnelle partielle  $H_k(\Omega|V)$ , qui mesure la contribution de la gaussienne  $v_k$  à l'entropie conditionnelle totale  $H(\Omega|V)$ .

$$H_k(\Omega|V) = Pr(v_k)H(\Omega|v_k) \quad (5)$$

$$H(\Omega|V) = \sum_{k=1}^K H_k(\Omega|V) \quad (6)$$

### 3 Performances obtenues en utilisant ces techniques

- Le TMHMM à deux étages diminue le pourcentage d’erreur par rapport au TMHMM classique (sans liage d’état).
- On peut retirer 30% des gaussiennes et 40% des sous-mélanges (en utilisant le critère PCE) et conserver pratiquement les performances du système avant réduction.
- On peut annuler 80% des  $q_{k|l}$  et  $p_{l|m,n}$  et sans diminuer les performances.
- En combinant entraînement et réduction des paramètres, on diminue les erreurs de reconnaissance de 20 à 25% par rapport au TMHMM classique.