

①.

# Algorithm EM. Mélanges gaussiens

## Modèle linéaire mixte

Contexte: - Publié TRDS B- 1977. 39(1).

NLÉ from incomplete data via the  
EM Algorithm.

→ Proposent un algo itératif de max. de vrais.

pour modèles à observations incomplètes.

→ Applications:

- mélange (Gaussian process) / clustering
- HMM (Forward-Backward)
- données tronquées, censurées
- estimateur de Genotypes
- mod. linéaire mixte

→ Ingédient de base pour toute famille d'algo.  
(ex: Stat. Bayésienne, SART, SETH...).

Exemple du clustering:

On observe  $(y_1, \dots, y_n)$ , on suppose  $J$  K groups mixtes.

↳ les labels ne sont pas ds.

→ les données sont incomplètes.

(2)

On cherche à retrouver les labels  $(z_1 \rightarrow z_n)$

Mais on ne dispose que des  $(y_i \rightarrow y_n)$

Données Complètes :  $(Y, Z)$

- Si on avait  $(Y, Z)$  alors on aurait toutes les infos.

$$Y_i | Z_i = k \sim N(\mu_k, \sigma^2)$$

$$Z_i \sim M(1, \pi_1 \dots \pi_K)$$

$\hookrightarrow$  loi conditionnelle, très facile à écrire, formuler, calculer.

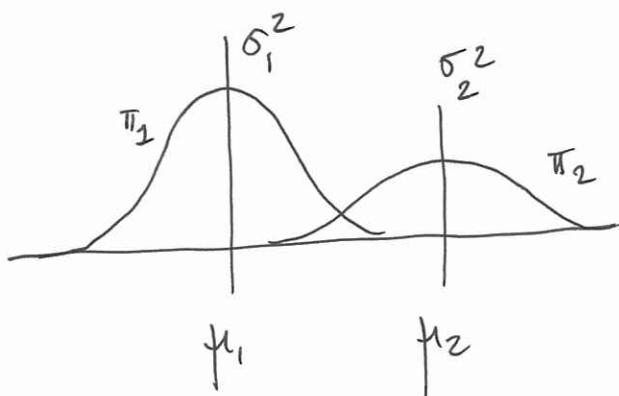
$$f(y, z; \theta) = \underbrace{f(y|z; \theta)}_{N} \underbrace{f(z; \theta)}_{M}$$

Paramètres:  $(\mu_1 \dots \mu_K)$ : moyenne par groupe

$\sigma^2$ : dispersion

$(\pi_1 \dots \pi_K)$ : taille des groupes

$$\theta: (\mu, \sigma^2, \pi)$$



- Estimation par Max. de Vrai.

$$\begin{aligned}\log \mathcal{L}(\gamma; \theta) &= \sum_i \log f(y_i; \theta) \\ &= \sum_i \log \left[ \sum_{k=1}^K f(y_i | z_i = k; \theta_k) P(z_i = k) \right] \\ &= \sum_i \log \left( \sum_{k=1}^K \pi_k f(y_i; \theta_k) \right).\end{aligned}$$

↳ Si on veut MLE alors il faut calculer.

$$\frac{\partial \log \mathcal{L}(\gamma; \theta)}{\partial \theta} = 0.$$

↳ Comment faire numériquement ?

↳ Et si on veut avoir les labels ?

↳ Dans certains modèles, la vraisemblance marginale ne peut pas être calculée directement (ex HMM).

→ Modèle de classif. probabiliste dont les paramètres s'estiment par EM (lien avec K-means).

# Exemple du modèle linéaire multiple

(4)

$$Y = x_p + zU + \epsilon$$

$\downarrow \mathbb{R}^p$        $\nearrow \mathbb{R}^q$

$$\mathbb{V}(Y) = ZGZ^T + R$$

$$E \perp U$$

$$Y \sim N(x_p, \mathbb{V})$$

$$U \sim N(0, G)$$

$$\epsilon \sim N(0, R).$$

- On cherche à estimer  $(\beta, G, R)$  et à prédire  $U$ , en ayant observé que  $Y$ .
- loi marginale de  $Y \sim N(x_p, \mathbb{V})$
  - loi conditionnelle  $Y|U \sim N(x_p + zU, R)$

$$f(y; \theta) = \frac{1}{(2\pi)^{N/2} |\mathbb{V}|^{1/2}} \exp \left( -\frac{1}{2} \|Y - x_p\|_{\mathbb{V}^{-1}}^2 \right)$$

$$f(y|u; \theta) = \frac{1}{(2\pi)^{N/2} |R|^{1/2}} \exp \left( -\frac{1}{2} \|Y - x_p - zu\|_R^2 \right).$$

On prendra:  $R = \sigma_e^2 I_N$ ,  $G = \sigma_u^2 I_q$ .

et le modèle  $Y_{ij} = \mu + u_i + \epsilon_{ij} \quad \begin{matrix} j=1, n_j \\ i=1, I \end{matrix}$

↳ On veut estimer et prédire sans utiliser  $\mathbb{V}^{-1}$

## Définition des Nuisibles

- Vrais. incomplète ou marginale.

↳ c'est la densité marginale des obs.

$$\log \mathcal{L}(Y; \theta) = \sum_i \log f(y_i; \theta) \text{ si les } y_i \text{ sont liés}$$

- Vrais. de données complètes.

↳ c'est la densité jointe des obs. & Mar. cachées.

$$\log \mathcal{L}(Y, Z; \theta) = \underbrace{\log \mathcal{L}(Y|Z; \theta)}_{\text{Somme facile}} + \log \mathcal{L}(Z|\theta).$$

à formuler  
combiner.

Ex: mélange Gaussien  $Y_i | z_i = k \sim N(\mu_k, \sigma^2)$

$$\begin{aligned} \log \mathcal{L}(Y, Z; \theta) &= \log \left[ \prod_{i=1}^n f(y_i, z_i; \theta) \right] \\ &= \log \left[ \prod_i \prod_k \left[ f(y_i | z_i=k; \theta) f(z_i=k) \right] \right]^{1(z_i=k)} \\ &= \log \left( \prod_{i,k} \left[ \pi_k \phi(x_i; \mu_k, \sigma^2) \right]^{1(z_i=k)} \right) \end{aligned}$$

On représenté :  $z_{ik}=1$  si  $i \in k$ . (6)

$$\log \mathcal{L}(Y, Z; \theta) = \sum_{i \in k} z_{ik} \log (\pi_k \phi(y_i, \mu_k, \sigma^2))$$

Ex. du modèle mixte.

$$\log \mathcal{L}(Y, U; \theta) = \log \mathcal{L}(Y|U; \theta) + \log \mathcal{L}(U; \theta)$$

$$\begin{aligned} -2 \log \mathcal{L}(Y|U; \theta) &= N \log (2\pi) + \log |R| + \|Y - X\beta - Zu\|_{R^{-1}}^2 \\ &= N \log 2\pi + N \log \sigma_u^2 + \frac{1}{\sigma_u^2} \|Y - X\beta - Zu\|^2. \end{aligned}$$

$$-2 \log \mathcal{L}(U; \theta) = q \log 2\pi + q \log \sigma_u^2 + \frac{1}{\sigma_u^2} \|u\|^2.$$

Idee d'EM: Maximiser une fonction  
de  $\log \mathcal{L}(Y, U; \theta)$  pour  
maximiser (indirectement)  $\log \mathcal{L}(Y)$ .

Maximisation de la vraisemb. Complete.

$$\frac{\partial \log L(\gamma, z; \theta)}{\partial \theta} = 0.$$

↳ Si on conserve les var. fictives.

1). Méthode des moments:

$$\begin{aligned} \frac{\partial \log L(\gamma, z; \theta)}{\partial \mu_k} &= \sum_{i=1}^n z_{ik} \frac{\partial \log f(z_i; \mu_k, \sigma^2)}{\partial \mu_k} \\ &= \sum_{i=1}^n z_{ik} \frac{(y_i - \mu_k)}{\sigma^2} = 0 \end{aligned}$$

$$\hookrightarrow \hat{\mu}_k = \frac{\sum z_{ik} y_i}{\sum z_{ik}}$$

2). Modèle mixte

$$\frac{\partial \log L(\gamma, v; \theta)}{\partial \beta} = \sum_{i=1}^m \frac{1}{\sigma_i^2} x_i (\gamma_i - x_i \beta - z_i v_i)$$

$$\tilde{\gamma}_i = \gamma_i - z_i v_i.$$

$$\rightarrow \hat{\beta} = \sum_{i=1}^m (x_i x_i)^{-1} x_i \tilde{\gamma}_i$$

Car  $R^{-1} = 1/\sigma_i^2 I$  facile à inverser!

- Comment relier la maximisation de la vraisemblance complète (facile) à l'incomplète ?

- Comment prendre en compte le fait qu'on n'observe pas les var. cachées ?.

- Ingédient:  $E_\theta(z|y)$ .

$$E_\theta(z|y) = \int z f(z|y; \theta) dz$$


  
 parmi de la  
 loi sous laquelle on intègre

$$E(g(z)|y) = \int g(z) f(z|y; \theta) dz$$

↳ la vrais. est une fonction des  $z$  et des  $y$ .

$$E_\theta(\log L(y, z; \theta) | y)$$

$$= \int \log L(y, z; \theta) \times f(z|y; \theta) dz$$

On va maximiser l'esp. cond. de la vraisemblance complète des obs.

$$\mathbb{E}_{\theta} \left( \log L(\gamma, z; \theta) \mid \gamma \right) = \int \log L(\gamma, z; \theta) \times f(z \mid \gamma; \theta) dz$$

paramètre  
sur lequel  
on calcule  
l'espérance

paramètre  
inconnu.

⇒ Algorithmus d'optimisation itératif:

- Si on fixe une valeur courante du paramètre  $\theta = \theta^{(t)}$ .

$$\mathbb{E}_{\theta^{(t)}} \left( \log L(\gamma, z; \theta) \mid \gamma \right) = Q(\theta, \theta^{(t)})$$

- Identité de Fisher.

$$\frac{\partial \log L(\gamma; \theta)}{\partial \theta} = \mathbb{E}_{\theta} \left( \frac{\partial \log f(y, z; \theta)}{\partial \theta} \mid \gamma \right).$$

Demonstration:

$$\frac{\partial \log L(\gamma; \theta)}{\partial \theta} = \frac{\partial L(\gamma; \theta)}{\partial \theta} \times \frac{1}{L(\gamma; \theta)}$$

$$L(\gamma; \theta) = \int L(\gamma, z; \theta) dz$$

$$\frac{\partial L(\gamma; \theta)}{\partial \theta} = \int \frac{\partial L(\gamma, z; \theta)}{\partial \theta} dz = \int L(\gamma, z; \theta) \times \frac{\partial \log L(\gamma, z; \theta)}{\partial \theta} dz$$

$$\frac{\partial \log L(\gamma, z; \theta)}{\partial \theta} = \overbrace{\frac{\partial L(\gamma, z; \theta)}{\partial \theta}}^{\uparrow} \times \frac{1}{L(\gamma, z; \theta)}$$

$$L(\gamma, z; \theta) = L(\gamma; \theta) \times \cancel{L(z; \theta)} \quad L(z|\gamma; \theta).$$

$$L \frac{\partial \log L(\gamma; \theta)}{\partial \theta} = \frac{1}{L(\gamma; \theta)} \int L(\gamma; \theta) \times L(z|\gamma; \theta) \times \frac{\partial \log L(\gamma, z; \theta)}{\partial \theta} dz.$$

$$= \int L(z|\gamma; \theta) \times \frac{\partial \log L(\gamma, z; \theta)}{\partial \theta} dz.$$

L DV

- Alors on fixe une valeur constante du paramètre:

$$E_{\theta^{(t)}} \left( \frac{\partial}{\partial \theta} \log L(\gamma, z; \theta) \mid \gamma \right)$$

$$= \int \underbrace{\left[ \frac{\partial}{\partial \theta} \log L(\gamma, z; \theta) \right]}_{\text{fonction de } \theta} \times \underbrace{L(z \mid \gamma; \theta^{(t)})}_{\substack{\text{ce n'est plus une fonction} \\ \text{de } \theta}} dz$$

$$\Rightarrow \frac{\partial}{\partial \theta} \int \log L(\gamma, z; \theta) \times L(z \mid \gamma; \theta^{(t)}) dz =$$

$$= \frac{\partial}{\partial \theta} \left[ E_{\theta^{(t)}} \left( \log L(\gamma, z; \theta) \mid \gamma \right) \right]$$

Exemple du mélange Gaussien :

$$\log L(\gamma, z; \theta) = \sum_{ik} z_{ik} \log \pi_k + \sum_{ik} z_{ik} \log f(y_i \mid z_{ik}; \theta_k)$$

$$\begin{aligned} E_{\theta^{(t)}} \left( \log L(\gamma, z; \theta) \mid \gamma \right) &= \sum_{ik} E_{\theta^{(t)}}(z_{ik} \mid \gamma_i) \log \pi_k \\ &\quad + \sum_{ik} E(z_{ik} \mid \gamma_i) \log —. \end{aligned}$$

$$\begin{aligned}
 \text{On note } \tau_{ik} &= \underset{\theta^{(t)}}{\mathbb{E}}(z_{ik} | y_i) = \frac{P(z_{ik}=1 | y_i)}{\sum_{\theta^{(t)}} f(y_i; \theta^{(t)})} \\
 &= \frac{P(z_{ik}=1) \times \mathbb{P}(y_i | z_{ik}=1)}{\sum_{\theta^{(t)}} f(y_i; \theta^{(t)})} \\
 &= \frac{\pi_k^{(t)} f(y_i; \theta_k^{(t)})}{\sum_{\theta^{(t)}} f(y_i; \theta^{(t)})}.
 \end{aligned}$$

$$Q(\theta, \theta^{(t)}) = \sum_{ik} \tau_{ik} \log \pi_k + \sum_{ik} \tau_{ik} \log f(y_i; \theta_k).$$

$$\hookrightarrow \frac{\partial Q}{\partial \theta} = 0 \Rightarrow \hat{f}_{ik} = \frac{\sum_{ik} \tau_{ik} y_i}{\sum_{ik} \tau_{ik}}$$

→ Estimation sous la forme d'une moyenne pondérée.

#### Algorithme EM:

1)- Calcul de l'espérance: Expectation Step

2)- Maximisation de  $Q(\theta, \theta')$

Algorithme EN pour les modèles linéaires mixtes.

13.

$$\log \mathcal{L}(Y, U; \theta) = \log \mathcal{L}(Y|U; \theta) + \log \mathcal{L}(U; \theta)$$

Etape E :

$$\begin{aligned} \mathbb{E}_{\theta^{(t)}} \left( \log \mathcal{L}(Y, U; \theta) \mid Y \right) &= Q(\theta, \theta^{(t)}) \\ &= Q_E(\theta, \theta^{(t)}) + Q_U(\theta, \theta^{(t)}). \end{aligned}$$

$$Q_U(\theta, \theta^{(t)}) = -\frac{1}{2} \left[ q \log 2\pi + q \log \sigma_u^2 + \mathbb{E}_{\theta^{(t)}}(U'U|Y) / \sigma_u^2 \right]$$

↳ Calcul de  $\mathbb{E}_{\theta^{(t)}}(U'U|Y)$

Etape M :  $\frac{\partial Q_U}{\partial \theta} = 0 \Rightarrow q/\sigma_u^2 = \frac{1}{\sigma_u^2} \mathbb{E}(U'U|Y) = 0.$

$$\Rightarrow \boxed{\sigma_u^2 = \frac{1}{q} \mathbb{E}(U'U|Y)}$$

↳ Reste à calculer  $\mathbb{E}_\theta(U'U|Y)$ .

$$\mathbb{E}(U|Y) = \frac{(Z' R^{-1} Z + G^{-1})^{-1}}{Z' Z + X' I}$$

→ On utilise l'identité.

$$\mathbb{E}(U'U|Y) = \underbrace{\mathbb{E}(U|Y)}_{BLUP} \mathbb{E}(U|Y) + \text{tr} \underbrace{(\mathbb{V}(U|Y))}_{\downarrow}$$

$$\hat{U}^{(t)}$$

$$\begin{aligned} \mathbb{V}(U|Y) &= \mathbb{V}(\hat{U} - U) \\ &= \mathbb{V}(\hat{U}) - \mathbb{V}(\hat{U}) \end{aligned}$$

par la prop du BLUP.

$$\text{Or } V(\hat{U}) = \underbrace{G^T V^{-1} Z G}_{=} = \left( (Z^T R^{-1} Z + G^{-1})^{-1} Z^T R^{-1} \right) \times Z G.$$

$$= \left( Z^T Z + \frac{\sigma_e^2}{\sigma_u^2} I_q \right)^{-1} Z^T Z \times \frac{\sigma_e^2}{\sigma_u^2}.$$

$$\text{Car } Z^T R^{-1} Z + G^{-1} = \frac{1}{\sigma_e^2} Z^T Z + \frac{1}{\sigma_u^2} I_q \\ = \frac{1}{\sigma_e^2} \left( Z^T Z + \frac{\sigma_e^2}{\sigma_u^2} I_q \right).$$

$$(Z^T R^{-1} Z + G^{-1})^{-1} = \sigma_e^2 \left( Z^T Z + \frac{\sigma_e^2}{\sigma_e^2} I_q \right)^{-1}$$

$$V(U|Y) = \sigma_u^2 I_q - \sigma_u^2 \left( Z^T Z + \lambda I_q \right)^{-1} Z^T Z = V(U) - \hat{V}(U)$$

$$= V(U - \hat{U}).$$

On peut montrer (Searle p 298)  
Foulley p 135

$$\text{tr} \left( (Z^T Z + \lambda I)^{-1} Z^T Z \right) = q - \lambda \text{tr} \left( (Z^T Z + \lambda I_q)^{-1} \right)$$

$$\boxed{\text{tr} (V(U|Y)) = \sigma_e^2 \text{tr} \left[ (Z^T Z + \lambda I_q)^{-1} \right].}$$

On de trouve direction avec  
 $V(U|Y) = (Z^T R^{-1} Z + G^{-1})^{-1}$

$$\sigma_u^2 = \frac{1}{q} E_{\theta^{(t)}} \left( \|U\|^2 | Y \right) = \frac{1}{q} \left[ \hat{U}^{(t)} \hat{U}^{(t)\top} + \text{tr}(V(U|Y)) \right].$$

$$\boxed{\hat{\sigma}_u^2 = \frac{1}{q} \left( \hat{U}^{(t)\top} \hat{U}^{(t)} + \sigma_e^2 \text{tr} \left( [Z'Z + \lambda I_q]^{-1} \right) \right)}$$

↳ Il faut maintenant calculer  $\hat{U}$ .

→ Mais on se trouve dans le cadre Gaussien donc  $E(U|Y)$  est connu.

$$E(U|Y) = G Z' V^{-1} (Y - X\beta)$$

Mais d'après les résultats d'Henderson

$$E_{\theta^{(t)}}(U|Y) = (Z'Z + \lambda I)^{-1} Z' (Y - X\beta^{(t)})$$

à l'étape  $t$ ,  $\theta$  est fixé @  $\theta^{(t)}$

$$\hookrightarrow \beta^{(t)}, \lambda^{(t)} = \frac{\sigma_e^{2(t)}}{\sigma_u^{2(t)}} \quad \text{ sont fixes.}$$

Dans le modèle  $Y_{ij} = \mu + \mu_i + \epsilon_{ij}$ . (16)

$$i=1, I \quad , \quad j=1, n_0, \quad \mu_i \sim N(0, \sigma_u^2) \\ \epsilon_{ij} \sim N(0, \sigma_\varepsilon^2) -$$

$$X_P = 1_N \mu, \quad Z = Id_I \otimes 1_{n_0}.$$

→ On veut calculer  $\hat{\mu}_i$ :

$$(Z_i' Z_i + \lambda I)^{-1} = (M_0 + \lambda)^{-1} I_{n_0} = \frac{\sigma_u^2}{M_0 \sigma_u^2 + \sigma_\varepsilon^2} I_{n_0}.$$

$$Z_i' (Y_i - 1_{n_0} \mu) = M_0 (y_{i0} - \hat{\mu}) = \sum_{j=1}^{n_0} (y_{ij} - \hat{\mu}).$$

$$\hat{\mu}_i = \underbrace{\frac{M_0 \sigma_u^2}{M_0 \sigma_u^2 + \sigma_\varepsilon^2}}_{\text{on retrouve bien le poids}} (y_{i0} - \hat{\mu})$$

on retrouve bien le poids  $W(Y_{i0}) = \sigma_u^2 + \frac{1}{n_0} \sigma_\varepsilon^2$

$$\sigma_u^2 = \frac{1}{I} \left( \sum_i \hat{\mu}_i^2 + \sigma_\varepsilon^2 \text{Tr}((Z' Z + \lambda I)^{-1}) \right).$$

$$\text{Tr} \left[ (Z' Z + \lambda I)^{-1} \right] = \text{Tr} \left[ \begin{matrix} (M_0 + \lambda) & \\ & n_0 + \lambda \end{matrix} \right]^{-1} = \frac{I}{n_0 + \lambda}.$$

$$\boxed{\sigma_u^2 = \frac{1}{I} \sum_i \left( \hat{\mu}_i^2 + \frac{\sigma_\varepsilon^2}{n_0 + \lambda} \right)}$$

# Estimation de $\sigma_{\varepsilon}^2$ .

(17)

$$Q_E(\theta, \theta^{(t)}) = -2 \mathbb{E}_{\theta} \left( N \log 2\pi + N \log \sigma_{\varepsilon}^2 + \frac{1}{\sigma_{\varepsilon}^2} \| Y - X\beta - ZU \|^2 \right) | Y$$

⇒ Il faut Calculer  $\mathbb{E}_{\theta} (\| Y - X\beta - ZU \|^2 | Y)$ . avec la  $\hat{m}$  égalité que pour  $\mathbb{E}(\| U \|^2 | Y)$ .

$$= \| Y - X\beta - Z \underbrace{\mathbb{E}(U|Y)}_u \|^2 + \text{tr} (Z' V(U|Y) Z) \times \sigma_{\varepsilon}^2$$

$$= \underbrace{\| Y - X\beta - Z\hat{U} \|^2}_\text{résidus du modèle} + \text{tr} (Z' V(U|Y) Z) \times \sigma_{\varepsilon}^2$$

si on prend directement

↳ Dans l'étape M:  $(Z'Z + \lambda I)$

$$\sigma_{\varepsilon}^2 = \frac{1}{N} \mathbb{E}_{\theta^{(t)}} (\| Y - X\beta - ZU \|^2 | Y)$$

↳ Il reste à Calculer  $\text{tr} (Z' V(U|Y) Z)$ .

$$V(U|Y) = \sigma_u^2 \left( I_q - (Z'Z + \lambda I_q)^{-1} Z'Z \right)$$

$$\text{tr} (V(U|Y)) = \sigma_{\varepsilon}^2 \text{tr} \left( (Z'Z + \lambda I_q)^{-1} \right).$$

$$\sigma_{\varepsilon}^2 \text{tr} \left[ (Z'Z + \lambda I_q)^{-1} \right] = \sigma_u^2 \left( q - \text{tr} (Z'Z (Z'Z + \lambda I_q)^{-1}) \right)$$

$$\lambda \operatorname{tr} \left( (Z'Z + \lambda I_q)^{-1} \right) = q - \operatorname{tr} \left( Z'Z (Z'Z + \lambda I_q)^{-1} \right). \quad (18)$$

$$\hookrightarrow \boxed{\operatorname{tr} (Z V(V|Y) Z') = q - \lambda \operatorname{tr} ((Z'Z + \lambda I)^{-1})}$$

→ Dans le cas du modèle  $Y_{ij} = \mu + \bar{\mu}_i + \varepsilon_{ij}$ .

$$\operatorname{tr} (Z'Z + \lambda I)^{-1} = \frac{I}{n_0 + \lambda}.$$

$$\rightarrow \boxed{\sigma_0^2 = \frac{1}{N} \left( \sum_{i=1}^{n_0} \sum_{j=1}^{m_i} (Y_{ij} - \hat{\mu} - \hat{\mu}_i)^2 + \left( q - \frac{\lambda I}{n_0 + \lambda} \right) \times \sigma_\varepsilon^2 \right)}$$

Résumé :

- Etape E : Calcul de  $\hat{U}$  = BLUP  
avec les équations d'Henderson quand  $(\sigma_u^2, \sigma_e^2, \mu)$  sont fixés.
- Etape M : Calcul de  $\hat{\sigma}_u^2, \hat{\sigma}_e^2, \hat{\mu}$   
avec les estimateurs explicits et  $\hat{U}$  fixé  
qui a été calculé @ l'étape E précédente.

## Propriétés de l'Algorithmus EM

### 1). Accroissement monotone de la vraisemblance.

↳ EM génère une suite  $\theta^{(t)}$   $A > 0$ ,  
et on peut montrer:

$$\log L(\gamma; \theta^{(t)}) \geq \log L(\gamma; \theta^{(t-1)}) \quad \forall t.$$

↳ Pour le montrer il faut introduire de nouvelles quantités.

↳ L'identité de Fisher montre:  $\frac{\partial \log L}{\partial \theta} = \frac{\partial Q}{\partial \theta}$ .

mais quel lien entre  $\log L$  et  $Q$ ?

→ par définition de la densité jointe

$$g(y; \theta) \times h(z | y; \theta) = f(y, z; \theta).$$

↓                      ↓

terme  $\log L(\gamma)$           terme:  $Q(\theta, \theta^{(t)})$

terme  $H(\theta, \theta^{(t)})$ .

Quand on prend l' $\mathbb{E}(\cdot | \gamma)$   $g(y; \theta)$  reste inchangé.

$$\log \mathcal{L}(\gamma; \theta) = \log \mathcal{L}(\gamma, z; \theta) - \log(z|\gamma; \theta).$$

$$\mathbb{E}_{\theta^{(t)}}(-) = Q(\theta, \theta^{(t)}) - H(\theta, \theta^{(t)})$$

$$H(\theta, \theta^{(t)}) = \mathbb{E}_{\theta^{(t)}} \left[ \log \mathcal{L}(z|\gamma; \theta) \mid \gamma \right].$$

$$= \int \log h(z|y; \theta) \times h(z|y; \theta^{(t)}) dz.$$

Avancement de Q.

Par définition de la phase M.

$$Q(\theta^{(t+1)}; \theta^{(t)}) \geq Q(\theta^{(t)}, \theta^{(t)}).$$

Avancement de H (Par Jensen  $\mathbb{E} f(x) \leq f(\mathbb{E} x)$   
+ concave)

$$H(\theta^{(t+1)}, \theta^{(t)}) - H(\theta^{(t)}, \theta^{(t)})$$

$$= \int \log \left[ \frac{h(z|y; \theta^{(t+1)})}{h(z|y; \theta^{(t)})} \right] \times h(z|y; \theta^{(t)}) dz$$

$$\leq \log \int \frac{h(z|y; \theta^{(t+1)})}{h(z|y; \theta^{(t)})} \times h(z|y; \theta^{(t)}) dz = 0.$$

## Autour de l'Algorithmme EM

- Initialisation ? : Stratégie stochastique déterministe
- Accélération ? : Stratégie de classement "dur"
  - algorithmes en lignes (incrementaux)
- Preuve de convergence vers un max local ? global ?
- Extensions en Bayesian , aussi SATEM

Biblio: The EM Algorithm & Extensions Wiley.  
 N. Tschannen & Krishnan.