

# Méthode variationnelle pour l'estimation d'un modèle spatial de données binaires

Cécile Hardouin  
MODAL'X, Université Paris Nanterre

SIXIEMES RECONTRES DE STATISTIQUE AVIGNON-MARSEILLE  
2018

Données binaires 0, 1

Modèle auto-logistique, modèle hiérarchique

Estimation : Vraisemblance complétée, et problème dans l'étape E

- Méthodes de Monte-Carlo
- Importance sampling
- Approximations de Laplace
- Approche variationnelle

Jaakola T., Jordan M., 2000, Bayesian parameter estimation via variational methods. *Statistics and Computing* (2000) 10, 25–37

## Plan de l'exposé

1. Le modèle
2. Estimation
3. Quelques résultats
4. Discussion

Domaine fini  $D \equiv \{\mathbf{s}_i : i = 1, \dots, n\} \subset \mathbf{R}^2$ ,

avec  $\mathbf{s}_i = (s_{i1}, s_{i2})$  pour  $i = 1, \dots, n$ .

Processus  $\mathbf{Z} = (Z(\mathbf{s}_1), \dots, Z(\mathbf{s}_n))^T$ , à valeurs dans  $E = \{0, 1\}^n$ ,

$$Z(\mathbf{s}_i) \mid Y(\mathbf{s}_i) \sim \text{Ber}(p(\mathbf{s}_i))$$

Les  $Z(\mathbf{s}_i) \mid Y(\mathbf{s}_i)$  sont indépendantes

Domaine fini  $D \equiv \{\mathbf{s}_i : i = 1, \dots, n\} \subset \mathbf{R}^2$ ,

avec  $\mathbf{s}_i = (s_{i1}, s_{i2})$  pour  $i = 1, \dots, n$ .

Processus  $\mathbf{Z} = (Z(\mathbf{s}_1), \dots, Z(\mathbf{s}_n))^T$ , à valeurs dans  $E = \{0, 1\}^n$ ,

$$Z(\mathbf{s}_i) \mid Y(\mathbf{s}_i) \sim \text{Ber}(p(\mathbf{s}_i))$$

Les  $Z(\mathbf{s}_i) \mid Y(\mathbf{s}_i)$  sont indépendantes

$$p(\mathbf{s}_i) = \frac{e^{Y(\mathbf{s}_i)}}{1 + e^{Y(\mathbf{s}_i)}}.$$

ou encore  $\text{logit}(p(\mathbf{s}_i)) = \ln \frac{p(\mathbf{s}_i)}{1 - p(\mathbf{s}_i)} = Y(\mathbf{s}_i)$

On pose

$$Y(\mathbf{s}) = \mathbf{X}(\mathbf{s})^T \boldsymbol{\beta} + \varepsilon(\mathbf{s}).$$

Premier terme :  $\mathbf{X}(\mathbf{s}) = (X_1(\mathbf{s}), \dots, X_p(\mathbf{s}))^T$ ;  $\boldsymbol{\beta}$  doit être estimé.

Second terme : variation spatiale à petite échelle,

$$\varepsilon \sim N_n(\mathbf{0}, \Sigma),$$

$\Sigma$  doit être estimée.

Si  $\Sigma = \Sigma(\boldsymbol{\theta})$ , les paramètres sont alors  $\boldsymbol{\beta}$  et  $\boldsymbol{\theta}$ .

# La vraisemblance

$\mathbf{Y}$  n'est pas observé,

On considère la vraisemblance complétée,

$$[\mathbf{Z}, \boldsymbol{\varepsilon} \mid \boldsymbol{\beta}, \Sigma] = [\mathbf{Z} \mid \boldsymbol{\varepsilon}, \boldsymbol{\beta}] \times [\boldsymbol{\varepsilon} \mid \Sigma],$$

log de la vrais. complétée,

$$\begin{aligned} L_c(\mathbf{Z}, \boldsymbol{\varepsilon} \mid \boldsymbol{\beta}, \Sigma) &= - \sum_{\mathbf{s} \in D} \ln(1 + e^{Y(\mathbf{s})}) + \sum_{\mathbf{s} \in D} Y(\mathbf{s})Z(\mathbf{s}) \\ &\quad - \frac{1}{2} \ln(\det \Sigma) - \frac{1}{2} \boldsymbol{\varepsilon}^T \Sigma^{-1} \boldsymbol{\varepsilon} - \frac{n}{2} \ln 2\pi \end{aligned}$$

avec  $Y(\mathbf{s}) = \mathbf{X}(\mathbf{s})^T \boldsymbol{\beta} + \varepsilon(\mathbf{s})$ .

On utilise un algorithme EM.

# Algorithme EM

Notons  $\varphi = (\beta, \Sigma)$ .

On définit

$$q(\varphi, \hat{\varphi}^{(l)}) = E \left[ L_c(\mathbf{Z}, \varepsilon \mid \varphi) \mid \mathbf{Z}, \hat{\varphi}^{(l)} \right].$$

- Initialisation  $\hat{\varphi}^{(0)}$ ,

# Algorithme EM

Notons  $\varphi = (\beta, \Sigma)$ .

On définit

$$q(\varphi, \hat{\varphi}^{(l)}) = E \left[ L_c(\mathbf{Z}, \varepsilon \mid \varphi) \mid \mathbf{Z}, \hat{\varphi}^{(l)} \right].$$

- Initialisation  $\hat{\varphi}^{(0)}$ ,
- A la  $l$ -ième étape,  
Étape E, on calcule  $q(\varphi, \hat{\varphi}^{(l-1)})$ .  
Étape M, on maximise  $q(\varphi, \hat{\varphi}^{(l-1)})$  pour obtenir  
 $\hat{\varphi}^{(l)} = \arg \max_{\varphi} q(\varphi, \hat{\varphi}^{(l-1)})$ .

# Algorithme EM

Notons  $\varphi = (\beta, \Sigma)$ .

On définit

$$q(\varphi, \hat{\varphi}^{(l)}) = E \left[ L_c(\mathbf{Z}, \varepsilon \mid \varphi) \mid \mathbf{Z}, \hat{\varphi}^{(l)} \right].$$

- Initialisation  $\hat{\varphi}^{(0)}$ ,
- A la  $l$ -ième étape,  
Etape E, on calcule  $q(\varphi, \hat{\varphi}^{(l-1)})$ .  $E[\varepsilon \mid \mathbf{Z}, \hat{\varphi}^{(l)}]$  is unknown  
Etape M, on maximise  $q(\varphi, \hat{\varphi}^{(l-1)})$  pour obtenir  
 $\hat{\varphi}^{(l)} = \arg \max_{\varphi} q(\varphi, \hat{\varphi}^{(l-1)})$ .

**E step:** Monte Carlo

Importance Sampling

Laplace Approximation

On remplace par un VEM

### E step: Monte Carlo

1. On simule  $M$  fois les  $\varepsilon$  sous la loi conditionnelle  $[\varepsilon \mid \mathbf{Z}, \hat{\boldsymbol{\phi}}^{(l)}]$ .

Cette loi n'étant pas connue, on simule  $\varepsilon$  avec un algo. de Metropolis

2. On approxime les espérances  $E [g(\varepsilon(\mathbf{s})) \mid \mathbf{Z}, \hat{\boldsymbol{\phi}}^{(l)}]$  par

$$\overline{g_M(\mathbf{s})} = \frac{1}{M} \sum_{m=1}^M g(\varepsilon^{(m)}(\mathbf{s}))$$

### Algorithme de Metropolis

- 1 Initialisation avec tirage de  $\varepsilon_0$ .

### Algorithme de Metropolis

- 1 Initialisation avec tirage de  $\varepsilon_0$ .
- 2 On tire  $\varepsilon_1$  de loi  $h(\varepsilon_0)$ . *Choix de  $h$  ?*

### Algorithme de Metropolis

- 1 Initialisation avec tirage de  $\varepsilon_0$ .
- 2 On tire  $\varepsilon_1$  de loi  $h(\varepsilon_0)$ . *Choix de  $h$  ?*
- 3 On calcule  $f(\varepsilon_0, \mathbf{z})$  et  $f(\varepsilon_1, \mathbf{z})$  les densités de  $[\varepsilon_0, \mathbf{Z} \mid \varphi]$  et  $[\varepsilon_1, \mathbf{Z} \mid \varphi]$  (avec  $[\mathbf{Z}, \varepsilon \mid \varphi] = [\mathbf{Z} \mid \varepsilon, \varphi] \times [\varepsilon \mid \varphi]$ ).  
On calcule le ratio d'acceptation de Metropolis

$$r_{0,1} = \frac{f(\varepsilon_1, \mathbf{z})h(\varepsilon_0)}{f(\varepsilon_0, \mathbf{z})h(\varepsilon_1)}$$

Si  $f(\varepsilon_1, \mathbf{z})h(\varepsilon_0) \geq f(\varepsilon_0, \mathbf{z})h(\varepsilon_1)$ , alors on garde  $\varepsilon_1$ . Retour en 2.  
Sinon, on tire  $u$  suivant une loi uniforme sur  $[0; 1]$  ; si  $u \leq r_{0,1}$  alors on garde  $\varepsilon_1$ , sinon on conserve la valeur initiale  $\varepsilon_0$ . Retour en 2.

### Algorithme de Metropolis

*Choix de h ?* Chib and Greenberg 95

$$h : N(\boldsymbol{\varepsilon}_m, -cH(\boldsymbol{\varepsilon}_m)^{-1})$$

*c* doit être calibré

### Algorithme de Metropolis - Inconvénients

- Choix du burn-in
- Calibrage de  $c$
- Calcul du mode  $\varepsilon_m$  de  $f(\varepsilon, z)$  puis recalculer  $N(\varepsilon_m, -cH(\varepsilon_m)^{-1})$ .
- Le temps: simulation de  $M$  champs

### Algorithme de Metropolis - Inconvénients

- Choix du burn-in
- Calibrage de  $c$
- Calcul du mode  $\varepsilon_m$  de  $f(\varepsilon, z)$  puis recalculer  $N(\varepsilon_m, -cH(\varepsilon_m)^{-1})$ .
- Le temps: simulation de  $M$  champs
- ET surtout, le  $\sum_{s \in D} \ln(1 + e^{Y(s)})$  pose problème...

*Changements de  $h$ ....Rien à faire*

### EM avec Importance Sampling

Principe de l'importance sampling

On a  $X_1, \dots, X_M$  de loi  $f(x)$

$\tilde{X}_1, \dots, \tilde{X}_M$  de loi  $h(x)$ ,  $h$  est l'importance density

$$E_f[X] = \int xf(x)dx = \int x \frac{f(x)}{h(x)} h(x) dx = E_h[X \frac{f(X)}{h(X)}]$$

### EM avec Importance Sampling

Principe de l'importance sampling

On a  $X_1, \dots, X_M$  de loi  $f(x)$

$\tilde{X}_1, \dots, \tilde{X}_M$  de loi  $h(x)$ ,  $h$  est l'importance density

$$E_f[X] = \int xf(x)dx = \int x \frac{f(x)}{h(x)} h(x) dx = E_h[X \frac{f(X)}{h(X)}]$$

ici,  $X = g(\varepsilon)$ ,  $f = f(\varepsilon | \mathbf{Z}, \varphi)$  et  $h$  une densité pour  $\varepsilon$ .

# Algorithme EM

## Etape E

### EM avec Importance Sampling

1. On simule  $M$  fois les  $\varepsilon$
2. On approxime  $E \left[ g(\varepsilon(\mathbf{s})) \mid \mathbf{Z}, \hat{\boldsymbol{\phi}}^{(l)} \right]$  par

$$\sum_{m=1}^M g(\varepsilon^{(m)}(\mathbf{s})) p_m$$

$$p_m = \frac{\frac{1}{M} \pi(\mathbf{Z}(\mathbf{s}) \mid \varepsilon^{(m)}, \hat{\boldsymbol{\phi}}^{(l)})}{\frac{1}{M} \sum_{m=1}^M \pi(\mathbf{Z}(\mathbf{s}) \mid \varepsilon^{(m)}, \hat{\boldsymbol{\phi}}^{(l)})}$$

### EM avec Importance Sampling

1. On simule  $M$  fois les  $\varepsilon$  sous la loi conditionnelle  $[\varepsilon \mid \hat{\phi}^{(l-1)}]$  :

$$\varepsilon \sim N(0, \Sigma(\hat{\phi}^{(l-1)})) \text{ semble judicieux}$$

2. On approxime  $E [g(\varepsilon(\mathbf{s})) \mid \mathbf{Z}, \hat{\phi}^{(l-1)}]$  par  $\sum_{m=1}^M g(\varepsilon^{(m)}(\mathbf{s})) p_m$

A nouveau le  $\sum_{\mathbf{s} \in D} \ln(1 + e^{Y(\mathbf{s})})$  pose problème... Il ne se simplifie pas.

*Changements de lois pour les  $\varepsilon$ ... Rien à faire*

### EM avec Approximation de Laplace

La densité  $f(\boldsymbol{\varepsilon} \mid \mathbf{Z}, \boldsymbol{\varphi})$  est proportionnelle à  $\exp L_c(\mathbf{Z}, \boldsymbol{\varepsilon} \mid \boldsymbol{\varphi})$ .

On cherche  $\boldsymbol{\varepsilon}_m$  le mode de  $L_c(\mathbf{Z}, \boldsymbol{\varepsilon} \mid \boldsymbol{\varphi})$  et on écrit un devt de Taylor à l'ordre 2 de  $L_c(\mathbf{Z}, \boldsymbol{\varepsilon} \mid \boldsymbol{\varphi})$  en  $\boldsymbol{\varepsilon}_m$ :

$$\begin{aligned} L_c(\mathbf{Z}, \boldsymbol{\varepsilon} \mid \boldsymbol{\varphi}) &= L_c(\mathbf{Z}, \boldsymbol{\varepsilon}_m \mid \boldsymbol{\varphi}) + (\boldsymbol{\varepsilon} - \boldsymbol{\varepsilon}_m)^T \frac{\partial}{\partial \boldsymbol{\varepsilon}} L_c(\mathbf{Z}, \boldsymbol{\varepsilon} \mid \boldsymbol{\varphi}) \Big|_{\boldsymbol{\varepsilon}_m} \\ &\quad + \frac{1}{2} (\boldsymbol{\varepsilon} - \boldsymbol{\varepsilon}_m)^T (H(\boldsymbol{\varepsilon}_m)) (\boldsymbol{\varepsilon} - \boldsymbol{\varepsilon}_m) + \dots \end{aligned}$$

avec  $H(\boldsymbol{\varepsilon}_m) = \frac{\partial^2}{\partial \boldsymbol{\varepsilon} \partial \boldsymbol{\varepsilon}^T} L_c(\mathbf{Z}, \boldsymbol{\varepsilon} \mid \boldsymbol{\varphi}) \Big|_{\boldsymbol{\varepsilon}_m}$ .

# Algorithme EM

## Etape E

### EM avec Approximation de Laplace

Alors  $f(\boldsymbol{\varepsilon} \mid \mathbf{Z}, \boldsymbol{\varphi})$  est approx. proportionnelle à

$$\exp L_c(\mathbf{Z}, \boldsymbol{\varepsilon}_m \mid \boldsymbol{\varphi}) \times \exp \left[ -\frac{1}{2}(\boldsymbol{\varepsilon} - \boldsymbol{\varepsilon}_m)^T (-H(\boldsymbol{\varepsilon}_m))(\boldsymbol{\varepsilon} - \boldsymbol{\varepsilon}_m) \right];$$

c.à.d. une distribution gaussienne.

$$\int f(\boldsymbol{\varepsilon} \mid \mathbf{Z}, \boldsymbol{\varphi}) d\boldsymbol{\varepsilon} = 1 \simeq \text{Cnste} \times \exp L_c(\mathbf{Z}, \boldsymbol{\varepsilon}_m \mid \boldsymbol{\varphi}) \times | -H(\boldsymbol{\varepsilon}_m) |^{-1/2} \times (2\pi)^{n/2}$$

Finalement on a les approximations

$$\begin{aligned} E[\boldsymbol{\varepsilon} \mid \mathbf{Z}, \boldsymbol{\varphi}] &\simeq \boldsymbol{\varepsilon}_m \\ \text{Var}(\boldsymbol{\varepsilon} \mid \mathbf{Z}, \boldsymbol{\varphi}) &\simeq -H(\boldsymbol{\varepsilon}_m)^{-1}. \end{aligned}$$

# Algorithme EM

## Etape E

### EM avec Approximation de Laplace

L'étape E doit calculer  $E[L_c(\mathbf{Z}, \boldsymbol{\varepsilon} \mid \boldsymbol{\varphi}) \mid \mathbf{Z}, \boldsymbol{\varphi}]$ ,

avec  $L_c(\mathbf{Z}, \boldsymbol{\varepsilon} \mid \boldsymbol{\varphi}) =$

$$-\sum_{\mathbf{s} \in D} \ln(1 + e^{Y(\mathbf{s})}) + \sum_{\mathbf{s} \in D} Y(\mathbf{s})Z(\mathbf{s}) - \frac{1}{2} \ln(\det \Sigma) - \frac{1}{2} \boldsymbol{\varepsilon}^T \Sigma^{-1} \boldsymbol{\varepsilon} - \frac{n}{2} \ln 2\pi$$

Il reste à calculer  $E[\ln(1 + e^{Y(\mathbf{s})})]$ . On suit la même méthode.

### EM avec Approximation de Laplace

C'est facile, assez rapide, mais biais négatif.

En fait, c'est  $\ln(1 + e^{Y(s)})$  qui nous embête.

L'approche variationnelle va nous débarrasser de cette fonction.



### EM Variationnel

On considère la fonction logistique,

$$g(x) = \frac{e^x}{1 + e^x} = \frac{1}{1 + e^{-x}},$$

Jaakola et Jordan (2000):

$$\ln g(x) \geq \ln g(\tau) + \frac{x - \tau}{2} - \lambda(\tau)(x^2 - \tau^2) \quad (\text{JJ})$$

$$\text{où } \lambda(\tau) = \frac{1}{4\tau} \tanh(\tau/2) = \frac{g(\tau) - 1/2}{2\tau}.$$

De plus, on a l'égalité pour  $\tau^2 = x^2$ .

On applique ceci à  $-\ln(1 + e^{Y(\mathbf{s})}) = \ln g(-Y(\mathbf{s}))$ , pour chaque  $\mathbf{s} \in \mathcal{D}$ .

### EM Variationnel

On introduit des *paramètres variationnels*  $\boldsymbol{\tau} = (\tau(\mathbf{s}_1), \dots, \tau(\mathbf{s}_n))^T$ ;

On obtient une fonction minorante pour  $L_c$ ,

$$L_c(\mathbf{Z}, \boldsymbol{\varepsilon} \mid \boldsymbol{\beta}, \boldsymbol{\Sigma}) \geq \tilde{L}_c(\mathbf{Z}, \boldsymbol{\varepsilon} \mid \boldsymbol{\beta}, \boldsymbol{\Sigma}, \boldsymbol{\tau}),$$

Et en plus, on a  $L_c(\mathbf{Z}, \boldsymbol{\varepsilon} \mid \boldsymbol{\beta}, \boldsymbol{\Sigma}) = \tilde{L}_c(\mathbf{Z}, \boldsymbol{\varepsilon} \mid \boldsymbol{\beta}, \boldsymbol{\Sigma}, \boldsymbol{\tau})$  pour  $\tau(\mathbf{s}_i)^2 = Y(\mathbf{s}_i)^2$ ,  $i = 1, \dots, n$ .

### EM Variationnel

On part d'une initialisation des  $\tau(\mathbf{s}_i)$ , et alternativement, on maximise en paramètres du modèle, puis on met à jour les paramètres variationnels;

$$\text{Init} : L_c(\mathbf{Z}, \boldsymbol{\varepsilon} \mid \boldsymbol{\beta}, \Sigma) = \tilde{L}_c(\mathbf{Z}, \boldsymbol{\varepsilon} \mid \boldsymbol{\beta}, \Sigma, \boldsymbol{\tau})$$

$$\tilde{L}_c(\mathbf{Z}, \boldsymbol{\varepsilon} \mid \boldsymbol{\beta}, \Sigma, \boldsymbol{\tau}) \leq \tilde{L}_c(\mathbf{Z}, \boldsymbol{\varepsilon} \mid \boldsymbol{\beta}', \Sigma', \boldsymbol{\tau}) \leq \tilde{L}_c(\mathbf{Z}, \boldsymbol{\varepsilon} \mid \boldsymbol{\beta}', \Sigma', \boldsymbol{\tau}')$$

On itère cette procédure pour obtenir à la fin

$$\tilde{L}_c(\mathbf{Z}, \boldsymbol{\varepsilon} \mid \boldsymbol{\beta}_{\max}, \Sigma_{\max}, \boldsymbol{\tau}_{\max}) \simeq L_c(\mathbf{Z}, \boldsymbol{\varepsilon} \mid \boldsymbol{\beta}_{\max}, \Sigma_{\max}).$$

# Algorithme EM

## Étape E

### EM Variationnel

$$\ln g(x) \geq \ln g(\tau) + \frac{x - \tau}{2} - \lambda(\tau)(x^2 - \tau^2)$$

$$\tilde{L}_c(\mathbf{Z}, \boldsymbol{\varepsilon} \mid \boldsymbol{\beta}, \boldsymbol{\Sigma}, \boldsymbol{\tau}) = T_1(\boldsymbol{\tau}) + T_2(\boldsymbol{\tau}, \boldsymbol{\beta}) + T_3(\boldsymbol{\tau}, \boldsymbol{\beta}, \boldsymbol{\Sigma}) - \frac{1}{2} \boldsymbol{\varepsilon}' \boldsymbol{\Sigma}^{-1} \boldsymbol{\varepsilon} - \frac{1}{2} \ln(\det \boldsymbol{\Sigma})$$

$$T_1(\boldsymbol{\tau}) = \sum_{\mathbf{s} \in D} \left\{ \ln g(\tau(\mathbf{s})) - \frac{\tau(\mathbf{s})}{2} + \tau(\mathbf{s})^2 \lambda(\tau(\mathbf{s})) \right\},$$

$$T_2(\boldsymbol{\tau}, \boldsymbol{\beta}) = \sum_{\mathbf{s} \in D} \left\{ -\lambda(\tau(\mathbf{s})) (\mathbf{X}(\mathbf{s})^T \boldsymbol{\beta})^2 + \mathbf{X}(\mathbf{s})^T \boldsymbol{\beta} (Z(\mathbf{s}) - \frac{1}{2}) \right\},$$

et

$$T_3(\boldsymbol{\tau}, \boldsymbol{\beta}, \boldsymbol{\Sigma}) = \sum_{\mathbf{s} \in D} \left\{ \begin{array}{c} -\boldsymbol{\varepsilon}(\mathbf{s})^2 \lambda(\tau(\mathbf{s})) \\ + \boldsymbol{\varepsilon}(\mathbf{s}) \left[ Z(\mathbf{s}) - \frac{1}{2} - 2\lambda(\tau(\mathbf{s})) \mathbf{X}(\mathbf{s})^T \boldsymbol{\beta} \right] \end{array} \right\}.$$

# Algorithme EM

Etape E

## EM Variationnel

On a

$$T_3(\boldsymbol{\tau}, \boldsymbol{\beta}, \boldsymbol{\Sigma}) = \sum_{\mathbf{s} \in D} \left\{ \begin{array}{l} -\varepsilon(\mathbf{s})^2 \lambda(\tau(\mathbf{s})) \\ +\varepsilon(\mathbf{s}) \left[ Z(\mathbf{s}) - \frac{1}{2} - 2\lambda(\tau(\mathbf{s})) \mathbf{X}(\mathbf{s})^T \boldsymbol{\beta} \right] \end{array} \right\}.$$

Notons  $\mathbf{M} = (M(\mathbf{s}_1), \dots, M(\mathbf{s}_n))^T$ , avec

$$M(\mathbf{s}) = Z(\mathbf{s}) - \frac{1}{2} - 2\lambda(\tau(\mathbf{s})) \mathbf{X}(\mathbf{s})^T \boldsymbol{\beta}.$$

Alors on écrit

$$T_3(\boldsymbol{\tau}, \boldsymbol{\beta}, \boldsymbol{\Sigma}) - \frac{1}{2} \boldsymbol{\varepsilon}^T \boldsymbol{\Sigma}^{-1} \boldsymbol{\varepsilon} = \boldsymbol{\varepsilon}^T \mathbf{M} - \frac{1}{2} \boldsymbol{\varepsilon}^T \mathbf{W}^{-1} \boldsymbol{\varepsilon}$$

où

$$\mathbf{W}^{-1} = \boldsymbol{\Sigma}^{-1} + 2\boldsymbol{\Lambda}(\boldsymbol{\tau}),$$

$$\boldsymbol{\Lambda}(\boldsymbol{\tau}) = \text{diag}(\lambda(\tau(\mathbf{s})))$$

# Algorithme EM

## Etape E

### EM Variational

On obtient

$$\tilde{L}_c(\mathbf{Z}, \boldsymbol{\varepsilon} \mid \boldsymbol{\beta}, \Sigma, \boldsymbol{\tau}) = T_1(\boldsymbol{\tau}) + T_2(\boldsymbol{\tau}, \boldsymbol{\beta}) + \boldsymbol{\varepsilon}^T \mathbf{M} - \frac{1}{2} \boldsymbol{\varepsilon}^T \mathbf{W}^{-1} \boldsymbol{\varepsilon} - \frac{1}{2} \ln(\det \Sigma) + \text{const}$$

Pour  $\boldsymbol{\tau}$  fixé,

$$\begin{aligned} p(\boldsymbol{\varepsilon} \mid \mathbf{Z}, \boldsymbol{\beta}, \Sigma, \boldsymbol{\tau}) &\propto \exp \left\{ T_1(\boldsymbol{\tau}) + T_2(\boldsymbol{\tau}, \boldsymbol{\beta}) + \frac{1}{2} \boldsymbol{\mu}^T \mathbf{W}^{-1} \boldsymbol{\mu} \right\} \\ &\times \frac{1}{\sqrt{\det \Sigma}} \exp \left\{ -\frac{1}{2} (\boldsymbol{\varepsilon} - \boldsymbol{\mu})^T \mathbf{W}^{-1} (\boldsymbol{\varepsilon} - \boldsymbol{\mu}) \right\}. \end{aligned}$$

### Variational EM

A  $\tau$  fixé,

$$[\varepsilon \mid \mathbf{Z}, \beta, \Sigma, \tau] = N(\boldsymbol{\mu}, \mathbf{W})$$

$$\begin{aligned} q(\boldsymbol{\varphi}, \hat{\boldsymbol{\varphi}}^{(l)}; \tau) &= E \left[ \tilde{L}_c(\mathbf{Z}, \varepsilon \mid \boldsymbol{\varphi}, \tau) \mid \mathbf{Z}, \hat{\boldsymbol{\varphi}}^{(l)} \right] \\ &= T_1(\boldsymbol{\tau}) + T_2(\boldsymbol{\tau}, \beta) + \hat{\boldsymbol{\mu}}^{(l)\text{T}} \mathbf{M} \\ &\quad - \frac{1}{2} \text{Tr}((\widehat{\mathbf{W}}^{(l)} + \hat{\boldsymbol{\mu}}^{(l)} \hat{\boldsymbol{\mu}}^{(l)\text{T}}) \mathbf{W}^{-1}) - \frac{1}{2} \ln(\det \Sigma) + \text{const.} \end{aligned}$$

**VEM** /-ième tour

$$\begin{aligned}q(\boldsymbol{\varphi}, \hat{\boldsymbol{\varphi}}^{(l)}; \boldsymbol{\tau}) &= E \left[ \tilde{L}_c(\mathbf{Z}, \boldsymbol{\varepsilon} \mid \boldsymbol{\varphi}, \boldsymbol{\tau}) \mid \mathbf{Z}, \hat{\boldsymbol{\varphi}}^{(l)} \right] \\ &= T_1(\boldsymbol{\tau}) + T_2(\boldsymbol{\tau}, \boldsymbol{\beta}) + \hat{\boldsymbol{\mu}}^{(l)\text{T}} \mathbf{M} \\ &\quad - \frac{1}{2} \text{Tr}((\widehat{\mathbf{W}}^{(l)} + \hat{\boldsymbol{\mu}}^{(l)} \hat{\boldsymbol{\mu}}^{(l)\text{T}}) \mathbf{W}^{-1}) - \frac{1}{2} \ln(\det \Sigma) + \text{const.}\end{aligned}$$

Paramètres du modèle:  $\Sigma$  et  $\boldsymbol{\beta}$  (dans  $T_2$  et  $\mathbf{M}$ )

Paramètres variationnels:  $\boldsymbol{\tau}$ , dans  $T_1$ ,  $T_2$ ,  $\mathbf{M}$  et  $\mathbf{W}$

$$M(\mathbf{s}) = Z(\mathbf{s}) - \frac{1}{2} - 2\lambda(\boldsymbol{\tau}(\mathbf{s})) \mathbf{X}(\mathbf{s})^{\text{T}} \boldsymbol{\beta}.$$

$$\mathbf{W}^{-1} = \Sigma^{-1} + 2\Lambda(\boldsymbol{\tau})$$

## Variational EM

- 1 E-step. Calcul de  $q(\boldsymbol{\varphi}, \hat{\boldsymbol{\varphi}}^{(l-1)}; \hat{\boldsymbol{\tau}}^{(l-1)})$ .

## Variational EM

- 1 E-step. Calcul de  $q(\boldsymbol{\varphi}, \hat{\boldsymbol{\phi}}^{(l-1)}; \hat{\boldsymbol{\tau}}^{(l-1)})$ .
- 2 M-step for the model parameters.

## Variational EM

- 1 E-step. Calcul de  $q(\boldsymbol{\varphi}, \hat{\boldsymbol{\varphi}}^{(l-1)}; \hat{\boldsymbol{\tau}}^{(l-1)})$ .
- 2 M-step for the model parameters.

a Calcul  $\hat{\boldsymbol{\beta}}^{(l)} = \arg \max_{\boldsymbol{\beta}} \left( T_2(\hat{\boldsymbol{\tau}}^{(l-1)}, \boldsymbol{\beta}) + \hat{\boldsymbol{\mu}}_{\hat{\boldsymbol{\tau}}^{(l-1)}, \hat{\boldsymbol{\beta}}^{(l-1)}, \hat{\boldsymbol{\tau}}^{(l-1)}}^T \mathbf{M}_{\hat{\boldsymbol{\tau}}^{(l-1)}, \boldsymbol{\beta}} \right)$

## Variational EM

- 1 E-step. Calcul de  $q(\boldsymbol{\varphi}, \hat{\boldsymbol{\varphi}}^{(l-1)}; \hat{\boldsymbol{\tau}}^{(l-1)})$ .
- 2 M-step for the model parameters.

a Calcul  $\hat{\boldsymbol{\beta}}^{(l)} = \arg \max_{\boldsymbol{\beta}} \left( T_2(\hat{\boldsymbol{\tau}}^{(l-1)}, \boldsymbol{\beta}) + \hat{\boldsymbol{\mu}}_{\hat{\boldsymbol{\tau}}^{(l-1)}, \hat{\boldsymbol{\beta}}^{(l-1)}, \hat{\boldsymbol{\Sigma}}^{(l-1)}}^T \mathbf{M}_{\hat{\boldsymbol{\tau}}^{(l-1)}, \boldsymbol{\beta}} \right)$

b MAJ  $\hat{\boldsymbol{\beta}}^{(l)}$ ; calcul de  $\hat{\mathbf{M}}_{\hat{\boldsymbol{\tau}}^{(l-1)}, \hat{\boldsymbol{\beta}}^{(l)}}$  et  $\hat{\boldsymbol{\mu}}_{\hat{\boldsymbol{\tau}}^{(l-1)}, \hat{\boldsymbol{\beta}}^{(l)}, \hat{\boldsymbol{\Sigma}}^{(l-1)}}$ ,

Puis calcul

$$\hat{\boldsymbol{\Sigma}}^{(l)} = \arg \max_{\boldsymbol{\Sigma}} \left\{ -\frac{1}{2} \text{Tr}((\widehat{\mathbf{W}} + \hat{\boldsymbol{\mu}}\hat{\boldsymbol{\mu}}^T) \mathbf{W}_{\hat{\boldsymbol{\tau}}^{(l-1)}, \boldsymbol{\Sigma}}^{-1}) - \frac{1}{2} \ln(\det \boldsymbol{\Sigma}) \right\}$$

## Variational EM

1 E-step. Calcul de  $q(\boldsymbol{\varphi}, \hat{\boldsymbol{\varphi}}^{(l-1)}; \hat{\boldsymbol{\tau}}^{(l-1)})$ .

2 M-step for the model parameters.

a Calcul  $\hat{\boldsymbol{\beta}}^{(l)} = \arg \max_{\boldsymbol{\beta}} \left( T_2(\hat{\boldsymbol{\tau}}^{(l-1)}, \boldsymbol{\beta}) + \hat{\boldsymbol{\mu}}_{\hat{\boldsymbol{\tau}}^{(l-1)}, \hat{\boldsymbol{\beta}}^{(l-1)}, \hat{\boldsymbol{\Sigma}}^{(l-1)}}^T \mathbf{M}_{\hat{\boldsymbol{\tau}}^{(l-1)}, \boldsymbol{\beta}} \right)$

b MAJ  $\hat{\boldsymbol{\beta}}^{(l)}$ ; calcul de  $\hat{\mathbf{M}}_{\hat{\boldsymbol{\tau}}^{(l-1)}, \hat{\boldsymbol{\beta}}^{(l)}}$  et  $\hat{\boldsymbol{\mu}}_{\hat{\boldsymbol{\tau}}^{(l-1)}, \hat{\boldsymbol{\beta}}^{(l)}, \hat{\boldsymbol{\Sigma}}^{(l-1)}}$ ,

Puis calcul

$$\hat{\boldsymbol{\Sigma}}^{(l)} = \arg \max_{\boldsymbol{\Sigma}} \left\{ -\frac{1}{2} \text{Tr}((\widehat{\mathbf{W}} + \hat{\boldsymbol{\mu}}\hat{\boldsymbol{\mu}}^T) \mathbf{W}_{\hat{\boldsymbol{\tau}}^{(l-1)}, \boldsymbol{\Sigma}}^{-1}) - \frac{1}{2} \ln(\det \boldsymbol{\Sigma}) \right\}$$

3 Variational parameter update:

$$\text{Update } \hat{\boldsymbol{\Sigma}}^{(l)} \quad \text{Then compute } \hat{\boldsymbol{\tau}}^{(l)} = \arg \max_{\boldsymbol{\tau}} \left\{ T_1(\boldsymbol{\tau}) + T_2(\boldsymbol{\tau}, \hat{\boldsymbol{\beta}}^{(l)}) + \hat{\boldsymbol{\mu}}^T \mathbf{M}_{\boldsymbol{\tau}, \hat{\boldsymbol{\beta}}^{(l)}, \hat{\boldsymbol{\Sigma}}^{(l)}} - \frac{1}{2} \text{Tr}((\widehat{\mathbf{W}} + \hat{\boldsymbol{\mu}}\hat{\boldsymbol{\mu}}^T) \mathbf{W}_{\boldsymbol{\tau}, \hat{\boldsymbol{\Sigma}}^{(l)}}^{-1}) \right\}$$

# Algorithme EM

## Etape M

### Step 2-a

On veut maximiser (à  $\tau$  fixé)

$$T(\beta; \tau) = \sum_{\mathbf{s} \in D} \left\{ -\lambda(\tau(\mathbf{s})) (X(\mathbf{s})^T \beta)^2 + X(\mathbf{s})^T \beta (Z(\mathbf{s}) - \frac{1}{2} - 2\lambda(\tau(\mathbf{s})) \hat{\mu}(\mathbf{s})) \right\}$$

$\frac{\partial}{\partial \beta} T(\tau, \beta) = G(\tau, \beta)$ ; soit on résoud  $G(\tau, \beta) = 0$ ;

Sinon,

$$\hat{\beta}^{(k)} = \hat{\beta}^{(k-1)} - \left( \frac{\partial}{\partial \beta} G(\tau, \beta) \right)_{\beta = \hat{\beta}^{(k-1)}}^{-1} G(\tau, \hat{\beta}^{(k-1)}).$$

# Algorithme EM

## Etape M

### Step 2-b

Avec  $\mathbf{W}^{-1} = \Sigma^{-1} + 2\Lambda$ , (et à  $\boldsymbol{\tau}$ ,  $\boldsymbol{\beta}$  fixés), on cherche

$$\hat{\Sigma}^{(l)} = \arg \max_{\Sigma} \left\{ -\frac{1}{2} \text{Tr}((\widehat{\mathbf{W}} + \widehat{\boldsymbol{\mu}}\widehat{\boldsymbol{\mu}}^T)\Sigma^{-1}) - \frac{1}{2} \ln(\det \Sigma) \right\}$$

# Algorithme EM

## Etape M

### Step 2-b

Avec  $\mathbf{W}^{-1} = \Sigma^{-1} + 2\Lambda$ , (et à  $\boldsymbol{\tau}$ ,  $\boldsymbol{\beta}$  fixés), on cherche

$$\hat{\Sigma}^{(l)} = \arg \max_{\Sigma} \left\{ -\frac{1}{2} \text{Tr}((\widehat{\mathbf{W}} + \widehat{\boldsymbol{\mu}}\widehat{\boldsymbol{\mu}}^T)\Sigma^{-1}) - \frac{1}{2} \ln(\det \Sigma) \right\}$$

Si  $\Sigma = \sigma_{\varepsilon}^2 \mathbf{Q}$ , on veut minimiser

$$f(\mathbf{Q}, \sigma_{\varepsilon}^2) = \frac{1}{\sigma_{\varepsilon}^2} \text{Tr}((\widehat{\mathbf{W}} + \widehat{\boldsymbol{\mu}}\widehat{\boldsymbol{\mu}}^T)\mathbf{Q}^{-1}) + n \ln \sigma_{\varepsilon}^2 + \ln(\det \mathbf{Q}),$$

On obtient

$$\sigma_{\varepsilon}^2(\mathbf{Q}) = \frac{1}{n} \text{Tr}((\widehat{\mathbf{W}}_{\boldsymbol{\tau}, \hat{\Sigma}^{(l-1)}} + \widehat{\boldsymbol{\mu}}\widehat{\boldsymbol{\mu}}^T)\mathbf{Q}^{-1}).$$

Et on minimise

$$g(\mathbf{Q}) = n \ln \left[ \frac{1}{n} \text{Tr}((\widehat{\mathbf{W}} + \widehat{\boldsymbol{\mu}}\widehat{\boldsymbol{\mu}}^T)\mathbf{Q}^{-1}) \right] + \ln \det \mathbf{Q}.$$

Si de plus  $\mathbf{Q} = \mathbf{Q}(\boldsymbol{\theta})$ , on minimise par rapport à  $\boldsymbol{\theta}$ .

### Step 3

$$q(\boldsymbol{\varphi}, \hat{\boldsymbol{\varphi}}^{(l)}; \boldsymbol{\tau}) = A(\hat{\boldsymbol{\varphi}}^{(l)}; \boldsymbol{\tau}) + \text{autres termes qui ne dépendent pas de } \boldsymbol{\tau}$$

Après calculs...

$$\hat{\tau}^{(l)}(\mathbf{s})^2 = (\mathbf{X}(\mathbf{s})^T \hat{\boldsymbol{\beta}}^{(l-1)})^2 + 2\mathbf{X}(\mathbf{s})^T \hat{\boldsymbol{\beta}}^{(l-1)} \hat{\mu}^{(l-1)}(\mathbf{s}) + \widehat{W}_{ss}^{(l-1)} + \hat{\mu}^{(l-1)}(\mathbf{s})^2.$$

Ce résultat est attendu.

L'inégalité (JJ) devient égalité si  $x^2 = \tau^2$ ;

on veut donc  $\tau(\mathbf{s})^2 \simeq Y(\mathbf{s})^2 = (\mathbf{X}(\mathbf{s})^T \boldsymbol{\beta} + \varepsilon(\mathbf{s}))^2$ ;

On prend  $\hat{\tau}^{(l)}(\mathbf{s})^2 = E[Y(\mathbf{s})^2 \mid \mathbf{Z}, \hat{\boldsymbol{\varphi}}^{(l-1)}]$ .

$D$  lattice  $40 \times 60$ ,  $n = 2400$  sites.

1. On simule  $N_n(\mathbf{0}; \Sigma)$  avec  $C(\mathbf{h}) = \sigma^2 e^{-\frac{\|\mathbf{h}\|}{\theta}}$ , for  $\mathbf{h} \in \mathbb{R}^2$ .  
 $\sigma^2 = 1$ .  $\theta = 5, 20$ ;

$D$  lattice  $40 \times 60$ ,  $n = 2400$  sites.

1. On simule  $N_n(\mathbf{0}; \Sigma)$  avec  $C(\mathbf{h}) = \sigma^2 e^{-\frac{\|\mathbf{h}\|}{\theta}}$ , for  $\mathbf{h} \in \mathbb{R}^2$ .  
 $\sigma^2 = 1$ .  $\theta = 5, 20$ ;

Trend:

$$X(\mathbf{s})^T = (1, \mathbf{s}_1 - 20, \mathbf{s}_2 - 30).$$

On définit  $V_S = \frac{1}{n} \text{Tr}(\Sigma) + \frac{1}{n} \sum_{i=1}^n (X(\mathbf{s}_i)^T \boldsymbol{\beta} - \text{average}_{\mathbf{s} \in D} (X(\mathbf{s})^T \boldsymbol{\beta}))^2$ .

Suivant Aldworth et Cressie,  $V_S \simeq 2$ .

Ici on a pris  $\beta_0 = \frac{1}{10}$ ,  $\beta_1 = \frac{1}{16}$  et  $\beta_2 = \frac{1}{25}$

$D$  lattice  $40 \times 60$ ,  $n = 2400$  sites.

1. On simule  $N_n(\mathbf{0}; \Sigma)$  avec  $C(\mathbf{h}) = \sigma^2 e^{-\frac{\|\mathbf{h}\|}{\theta}}$ , for  $\mathbf{h} \in \mathbb{R}^2$ .  
 $\sigma^2 = 1$ .  $\theta = 5, 20$ ;

Trend:

$$X(\mathbf{s})^T = (1, \mathbf{s}_1 - 20, \mathbf{s}_2 - 30).$$

On définit  $Vs = \frac{1}{n} \text{Tr}(\Sigma) + \frac{1}{n} \sum_{i=1}^n (X(\mathbf{s}_i)^T \boldsymbol{\beta} - \text{average}_{\mathbf{s} \in D} (X(\mathbf{s})^T \boldsymbol{\beta}))^2$ .  
Suivant Aldworth et Cressie,  $Vs \simeq 2$ .

Ici on a pris  $\beta_0 = \frac{1}{10}$ ,  $\beta_1 = \frac{1}{16}$  et  $\beta_2 = \frac{1}{25}$

2.  $p(\mathbf{s}) = \frac{e^{Y(\mathbf{s})}}{1 + e^{Y(\mathbf{s})}}$ ,  $\mathbf{s} \in D$ .

# Estimation

Resultats sur 400 simulations

	$\beta_0$	$\beta_1$	$\beta_2$	$\theta$	$\sigma_\varepsilon^2$
Target	0.1	0.0625	0.0417	5	1
Mean	0.0838	0.0586	0.0398	5.3867	0.6204
Std. Dev.	0.183	0.014	0.011	1.328	0.138

	$\beta_0$	$\beta_1$	$\beta_2$	$\theta$	$\sigma_\varepsilon^2$
Target	0.1	0.0625	0.0417	10	1
Mean	0.1033	0.0605	0.0429	8.1660	0.5767
Std. Dev.	0.283	0.018	0.014	2.524	0.191

## Conclusion

On présente une méthode spécifique aux données binaires

## Extensions

SRE model;  $\varepsilon(\mathbf{s}) = \mathbf{X}(\mathbf{s})^T \boldsymbol{\beta} + S(\mathbf{s})^T \boldsymbol{\eta} + \nu(\mathbf{s})$

$$\boldsymbol{\eta} \sim N_r(0, K), \nu \sim N_n(0, \sigma_\varepsilon^2 I) \quad \Sigma = SKS^T + \sigma_\varepsilon^2 I$$

-  James H. Albert and Siddhartha Chib. Bayesian Analysis of Binary and Polychotomous Response Data. *Journal of the American Statistical Association*, Vol. 88, No. 422 (Jun., 1993), pp. 669-679
-  Jordan M., Ghahramani Z., Jaakkola T., Saul L. 1999. An introduction to variational methods in graphical models. In: Jordan M.I. (Ed.), *Learning in graphical models*. Cambridge, MA, MIT Press.
-  Jaakola T., Jordan M., 2000, Bayesian parameter estimation via variational methods. *Statistics and Computing* (2000) 10, 25–37
-  Rustagi J. 1976. *Variational methods in statistics*. New York, Academic press.

# References EM

-  Olivier Cappé, Eric Moulines and Tobias Rydén. 2005. Inference in Hidden Markov Models. Springer Series in Statistics. 2005
-  Ming-Hui Chen, Qi-Man Shao, Joseph G. Ibrahim. 2000. Monte Carlo methods in Bayesian computation. Springer Series in Statistics. Springer.
-  Chib S. Greenberg E. 1995 Understanding the Metropolis algorithm. The American statistician Vol 49 n4
-  Chib S. Greenberg E. 1996 Markov Chain Monte Carlo simulation methods in econometrics . Econometric Theory, 12, 1996, 409-431.
-  Dempster, A.P., Laird, N., Rubin, D., 1977. Maximum likelihood from incomplete data via the EM algorithm. Journal of the Royal Statistical Society, Series B 39, 1–38.
-  McLachlan, G.J., Krishnan, T., 2008. The EM Algorithm and Extensions, second ed. Wiley-Interscience, New York, NY.
-  Robert, C.P., Casella, G., 2004. Monte Carlo Statistical Methods. Springer,

-  Aldworth J., Cressie N., 1999. Sampling designs and prediction methods for Gaussian spatial processes. In: Ghosh, S. (Ed.), Multivariate Analysis, Designs of Experiments, and Survey Sampling. Marcel Dekker, Inc., New York, NY, pp. 1-54.
-  Sengupta, A., Cressie, N., 2013. Hierarchical statistical modeling of big spatial datasets using the exponential family of distributions, Spatial Statistics, 4, 14-44.