

# Bruit à dépendance longue dans les Chaînes de Markov Cachées (cas gaussien)

Stéphane Derrode

Séminaire PHARE'09, ENSI, Tunisie



École Centrale Marseille

&



Institut Fresnel (CNRS)

28 octobre 2009

## Modélisation stochastique des données

- Processus des observations :

$$\mathbf{Y} = \{Y_1, \dots, Y_N\}, \quad Y_n \in \mathbb{R}.$$

- Processus (caché) des classes :

$$\mathbf{X} = \{X_1, \dots, X_N\}, \quad X_n \in \Omega = \{1, \dots, K\}.$$

↳  $\mathbf{X}$  est une chaîne de Markov :

$$\boxed{p(X_{n+1} | X_1, \dots, X_n) = p(X_{n+1} | X_n)}.$$

Elle est cachée et doit être estimée à partir de  $\mathbf{Y} = \mathbf{y}$ .

## Hypothèses

[H1]  $\mathbf{X}$  est une chaîne de Markov stationnaire

- Loi initiale :  $\pi_j = p(X_1 = j)$
- Loi stationnaire (matrice stochastique  $\mathbf{A}$ ) :

$$a_{j|i} = p(X_2 = j | X_1 = i)$$

[H2] Les V.A.  $Y_n$  sont indépendantes conditionnellement à  $\mathbf{X}$

$$p(\mathbf{y} | \mathbf{x}) = \prod_{n=1}^N p(y_n | \mathbf{x})$$

[H3]  $p(y_n | \mathbf{x}) = p(y_n | x_n) = f_{x_n}(y_n)$  (loi d'attache aux données)

# Structure de dépendance

CMC à bruit  
indépendant

CMC à  
dépendance  
longue

Simulations

Restauration  
des CMC-ML

Globalement


Loi *a priori*

$$p(\mathbf{x}) = p(x_1) \prod_{n=1}^{N-1} p(x_{n+1} | x_n)$$

Loi du couple

$$p(\mathbf{x}, \mathbf{y}) = p(x_1) f_{x_1}(y_1) \prod_{n=1}^{N-1} p(x_{n+1} | x_n) f_{x_{n+1}}(y_{n+1}).$$

Localement (contextuellement)



$$p(x_{n+1}, y_{n+1} | x_n, y_n) = p(x_{n+1} | x_n) f_{x_{n+1}}(y_{n+1})$$

# Processus à dépendance longue

Soit  $\mathbf{Y} = (Y_n)_{n \in \mathbb{Z}}$ , un processus stationnaire au second ordre, i.e.

$$\gamma(k) = E[Y_n Y_{n-k}] - E[Y_n] E[Y_{n-k}]$$

ne dépend pas de  $n$ .  $(\gamma(k))_{k \in \mathbb{Z}}$  est appelée « famille de covariances ».

## Définition

Le processus est à dépendance longue si  $\exists \alpha \in ]0, 1]$ ,  $C \in \mathbb{R}$  tels que :

$$\lim_{k \rightarrow +\infty} k^\alpha \gamma(k) = C.$$

On note  $\gamma(k) \sim_{+\infty} C k^{-\alpha}$ . Lorsque  $\alpha > 1$ , on dit que  $\mathbf{Y}$  est à dépendance intermédiaire.

➡ **Exemple : Processus 2-stationnaire.** C'est un processus de moyenne  $m$  et de famille de covariance

$$\forall k \in \mathbb{Z}, \quad \gamma(k) = \sigma^2 (|k| + 1)^{-\alpha}.$$

## Autres exemples

CMC à bruit  
indépendant

CMC à  
dépendance  
longue

Simulations

Restauration  
des CMC-ML

↳ **Bruit gaussien fractionnaire** : c'est un processus auto-similaire à accroissement stationnaire  $Y_n = Z_{n+1} - Z_n + m$ , tel que le processus  $Z$  est un mouvement brownien fractionnaire. Famille de covariance :

$$\forall k \in \mathbb{Z}, \quad \gamma(k) = \frac{\sigma^2}{2} \left[ |k+1|^{2H} - 2|k|^{2H} + |k-1|^{2H} \right],$$

avec  $\sigma^2 = E[Z_0]$ . Si  $H > 1/2$ , alors  $Y$  est à dépendance longue.

↳ **Processus FARIMA** : On peut construire un FARIMA de paramètre  $d \in [-1/2, 1/2] - \{0\}$  en filtrant un processus bruit blanc  $Z$  de variance  $\sigma^2$  de la manière suivante :  $Y = a \star Z + m$ , avec  $a_k = \Gamma(d+k) / (\Gamma(d) \Gamma(k+1))$ . Famille de covariance :

$$\forall k \in \mathbb{Z}, \quad \gamma(k) = \sigma^2 \frac{\Gamma(k+d) \Gamma(1-2d)}{\Gamma(k-d+1) \Gamma(d) \Gamma(1-d)}.$$

Si  $d > 0$ , alors  $Y$  est à dépendance longue.

➔  $\mathbf{Z} = (\mathbf{X}, \mathbf{Y})$  est une chaîne couple de Markov :

$$\boxed{p(z_{n+1} | z_{1:n}) = p(z_{n+1} | z_n)}.$$

Loi du couple  $p(\mathbf{z}) = p(z_1) \prod_{n=1}^{N-1} p(z_{n+1} | z_n).$

➔  $\mathbf{Z} = (\mathbf{X}, \mathbf{Y})$  est une chaîne couple *partiellement de Markov* :

$$\boxed{p(z_{n+1} | z_{1:n}) = p(z_{n+1} | x_n, y_{1:n})}.$$

Loi du couple  $p(\mathbf{z}) = p(z_1) \prod_{n=1}^{N-1} p(z_{n+1} | x_n, y_{1:n}).$

# Structure de dépendance

CMC à bruit  
indépendant

CMC à  
dépendance  
longue

Simulations

Restauration  
des CMC-ML


## Hypothèses simplificatrices

$$p(z_{n+1} | x_n, y_{1:n}) = p(y_{n+1} | x_n, x_{n+1}, y_{1:n}) p(x_{n+1} | x_n, y_{1:n})$$

[H1]  $p(x_{n+1} | x_n, y_{1:n}) = p(x_{n+1} | x_n)$

[H2]  $p(y_{n+1} | x_{n+1}, x_n, y_{1:n}) = p(y_{n+1} | x_{n+1}, y_{1:n})$

## Localement (contextuellement)



## Simulation d'une CMC-ML

CMC à bruit  
indépendant

CMC à  
dépendance  
longue

Simulations

Restauration  
des CMC-ML

Soit  $\pi_k$  le vecteur de probabilités initiale et  $\mathbf{A}$  la matrice de transition caractérisant la chaîne de Markov stationnaire. Soit  $f_k(\cdot)$  les lois d'attache aux données gaussiennes de moyennes  $m_k$  et de variance  $\sigma_k^2$ .

### Simulation de $\mathbf{X}$

- $x_1$  est simulé en effectuant un tirage sur  $p(x_1)$ .
- $x_n, n > 1$  est simulé en effectuant un tirage sur le vecteur de probabilités  $p(x_n | x_{n-1})$ .

### Simulation de $\mathbf{Y}$

- $y_n, n \geq 1$  est simulé en effectuant un tirage sur la gaussienne de paramètre  $m_{x_n}$  et  $\sigma_{x_n}^2$ .

## Simulation de $\mathbf{Y}$ : paramètres des gaussiennes

- $n = 1$   $p(y_1 | x_1)$  est une gaussienne de paramètres  $m_{x_1}$  et  $\gamma_{x_1}(0)$ .
- $n > 1$   $p(y_{n+1} | x_{n+1}, y_{1:n})$  est une gaussienne de paramètres

$$\begin{aligned}\tilde{m}_{x_{n+1}} &= m_{x_{n+1}} + \Gamma_{x_{n+1}}^{2,1} (\Gamma_{x_{n+1}}^n)^{-1} (y_{1:n} - m_{x_{n+1}}^n) \\ \tilde{\gamma}_{x_{n+1}} &= \gamma_{x_{n+1}}(0) + \Gamma_{x_{n+1}}^{2,1} (\Gamma_{x_{n+1}}^n)^{-1} \Gamma_{x_{n+1}}^{1,2}\end{aligned}$$

avec

$$m_{x_{n+1}}^n = \underbrace{(m_{x_{n+1}}(0), \dots, m_{x_{n+1}}(n))}_{n \text{ fois}}$$

$$\Gamma_{x_{n+1}}^{2,1} = (\gamma_{x_{n+1}}(n), \dots, \gamma_{x_{n+1}}(1))$$

$$\Gamma_{x_{n+1}}^n = \begin{pmatrix} \gamma_{x_{n+1}}(0) & \gamma_{x_{n+1}}(1) & \cdots & \gamma_{x_{n+1}}(n-1) \\ \gamma_{x_{n+1}}(1) & \gamma_{x_{n+1}}(0) & \cdots & \gamma_{x_{n+1}}(n-2) \\ \vdots & \vdots & \ddots & \vdots \\ \gamma_{x_{n+1}}(n-1) & \gamma_{x_{n+1}}(n-2) & \cdots & \gamma_{x_{n+1}}(0) \end{pmatrix}$$

## Exemple de simulations ( $K = 2$ )

CMC à bruit  
indépendant

CMC à  
dépendance  
longue

Simulations

Restauration  
des CMC-ML

### Paramètres de la chaîne de Markov

$$\boldsymbol{\pi} = \begin{pmatrix} 0.5 \\ 0.5 \end{pmatrix}, \quad \mathbf{A} = \begin{pmatrix} 0.96 & 0.04 \\ 0.04 & 0.96 \end{pmatrix}$$

### Paramètres des lois d'attache aux données (gaussiennes)

- Loi de la classe #1 :  $m_1 = 1, \sigma_1^2 = 1$
- Loi de la classe #2 :  $m_2 = 2, \sigma_2^2 = 1$
- Pour la longue dépendance, nous utilisons la famille de covariance  $\gamma(k) = \sigma^2 (|k| + 1)^{-\alpha}$ , avec  $\alpha_1 = 0.1$  et  $\alpha_2 = 0.9$ .




## Résultat de simulations

CMC à bruit  
indépendant

CMC à  
dépendance  
longue

Simulations

Restauration  
des CMC-ML



## Algorithmes de classification

CMC à bruit  
indépendantCMC à  
dépendance  
longue

Simulations

Restauration  
des CMC-ML

## Décision bayésienne

$$\hat{\mathbf{x}}^{OPT}(\mathbf{y}) = \arg \min_{\hat{\mathbf{x}} \in \Omega^N} E[L(\mathbf{x}, \hat{\mathbf{x}}) | \mathbf{Y} = \mathbf{y}]$$

- **MAP** - Fonction de perte :  $L_2(\mathbf{x}, \hat{\mathbf{x}}) = 1_{\{\mathbf{x} \neq \hat{\mathbf{x}}\}}$

$$\hat{\mathbf{x}}^{MAP}(\mathbf{y}) = \arg \max_{\mathbf{x} \in \Omega^N} p(\mathbf{X} = \mathbf{x} | \mathbf{Y} = \mathbf{y})$$

- **MPM** - Fonction de perte :  $L_1(\mathbf{x}, \hat{\mathbf{x}}) = \sum_{n=1}^N 1_{x_n \neq \hat{x}_n}$

$$\hat{x}_n^{MPM}(\mathbf{y}) = \arg \max_{x_n \in \Omega} p(X_n = x_n | \mathbf{Y} = \mathbf{y}) = \alpha_n(k) \beta_n(k)$$

↪ Tous basés sur l'algorithme "forward/backward" de Baum (1970).

## Algo. « forward/backward »

CMC à bruit  
indépendant

CMC à  
dépendance  
longue

Simulations

Restauration  
des CMC-ML

### Probabilités « forward »

$$\alpha_n(x_n) = p(x_n | y_{1:n}) = \frac{1}{S_n} p(x_n, y_n | y_{1:n-1}),$$

avec  $S_n = p(y_n | y_{1:n-1})$ ,  $n > 1$  le facteur de normalisation.

➡  $n = 1$  :

$$\alpha_1(x_1) = p(x_1 | y_1).$$

➡  $1 \leq n < N - 1$  :

$$\alpha_{n+1}(x_{n+1}) = \frac{1}{S_{n+1}} \sum_{x_n} \alpha_n(x_n) p(z_{n+1} | x_n, y_{1:n}).$$

## Probabilités « backward »

$$\beta_n(x_n) = \frac{p(y_{n+1:N} | x_n)}{p(y_{n+1:N} | y_{1:n})} = \frac{1}{S_{n+1}} \frac{p(y_{n+1:N} | x_n)}{p(y_{n+2:N} | y_{1:n+1})}.$$

➡  $n = N$  :

$$\beta_N(x_N) = 1.$$

➡  $1 \leq n < N$  :

$$\beta_n(x_n) = \frac{1}{S_{n+1}} \sum_{x_{n+1}} \beta_{n+1}(x_{n+1}) p(z_{n+1} | x_n, y_{1:n}).$$

# Résultat de restauration


CMC à bruit  
indépendant

CMC à  
dépendance  
longue


Simulations

Restauration  
des CMC-ML


## Restauration d'une CMC-BI (vrais paramètres)



**BI** -  $\tau = 8.4\%$



**ML** ( $\alpha_1 = \alpha_2 = 10$ )  
 $\tau = 8.4\%$




CMC à bruit  
indépendant

CMC à  
dépendance  
longue


Simulations

Restauration  
des CMC-ML

## Restauration d'une CMC-ML (vrais paramètres)



**BI** -  $\tau = 47.5\%$



**ML** -  $\tau = 6.1\%$

