

Restauration non supervisée des chaînes de Markov couples avec bruitage non gaussien

Taoufik EN-NAJJARY

DEA de Statistiques
Universté Pierre et Marie Curie, Paris VI

Institut National des Télécommunications
Stage encadré par le Prof. Wojciech PIECZYNSKI

15 septembre 2001

Table de matières

1	introduction	4
2	les chaînes de Markov cachées (HMC):	5
2.1	Loi de X	5
2.2	loi du couple (X,Y)	6
2.3	loi de X a posteriori	6
2.4	Probabilités Forward-Backward	7
2.5	Simulation	8
2.6	Restauration	9
2.7	Estimation des paramètres des modèles cachés	10
2.8	Résultats des expérimentations	16
3	Chaînes de Markov couples (PMC)	18
3.1	loi de Z	18
3.2	Simulation de Z	19
3.3	Estimation des paramètres	21
3.4	Restauration	23
3.5	Comparaison de résultat de reastoration de PMC et HMC	25
4	PMC dans le cas de bruit non gaussien	27
4.1	Simulation et Restauration avec bruitage exponentielle	28
4.2	Présentation des paramètres	28
4.3	Comparaisons des résultats	29
5	Annexes	30
5.1	Quelques expressions sur la distribution de Z	30
5.2	Markovienté des chaînes $y x$ et $x y$	31
6	Perspectives	33

Avant-propos

Le présent rapport présente les travaux entrepris par l'auteur dans le cadre d'un stage de recherche faisant partie de sa préparation du *diplôme d'Etudes Approfondies* de statistiques de l'*Université Pierre et Marie Curie*.

Ce stage est effectu au Département *Communications, Images et Traitement de l'Information (CITI)* de l'*Institut national des Télécommunications* sous l'encadrement du Prof. Wojciech PIECZYNSKI.

Remerciements

Je tiens à remercier mon encadrant Prof. Wojciech PIECZYNSKI pour la considération et l'intérêt qu'il a porté à mon travail. Je lui suis très reconnaissant de m'avoir fait profiter de son expertise en traitement statistiques d'image. Je remercie également M. Stéphane derrode pour son aide informatique. Je tiens également à remercier toute l'équipe du Département Communications, Images et Traitement de l'Information (CITI) pour leur accueil.

chapitre 1

introduction

Dans un cadre décisionnel, on dispose d'un échantillon d'apprentissage étiqueté, i.e. d'un échantillon $Z=(X,Y)$. Le problème est alors de construire une règle de décision pour classer des futures unités pour lesquelles seules les valeurs y_i seront observées. Il s'agit alors d'un problème courant en reconnaissance statistique des formes ou en diagnostic médicale. De nombreuses méthodes existent. La recherche consiste surtout, à l'heure actuelle, à proposer des techniques répondant à des contextes particuliers et à proposer des méthodes fiables.

Segmentation et restauration d'image:

Des mécanismes de dégradation des observations sont souvent inhérents aux problèmes d'images. Dans les problèmes de segmentation, de classification ou de restauration d'image, il s'agit de construire ou de retrouver une image inconnue X lorsque seule une version dégradée Y est observée. Cela relève naturellement des modèles à structure cachée, où les phénomènes aléatoires ont un rôle important. Les images sont constituées d'un ensemble S de pixels qui peuvent prendre une valeur parmi un petit nombre k de couleurs non ordonnées (les classes). Les données mises en jeu sont spatialement localisées et induisent l'utilisation de modèles probabilistes spatiaux. Ceux-ci soulèvent de nombreuses questions de modélisation et d'inférence statistique et n'ont cessé de gagner de l'intérêt. En particulier, le choix de modèles appropriés et l'estimation des paramètres associés aux modèles utilisés sont des questions essentielles pour aller vers une automatisation des algorithmes et tirer tout le profit de la richesse des modèles stochastiques. Ces problèmes, abondamment traités, restent cependant ouverts.

chapitre 2

les chaînes de Markov cachées (HMC):

Une chaîne de Markov cachée est un processus à temps discret doublement stochastique composé de deux processus $X = (X_n)_{n \in \mathcal{N}}$ et $Y = (Y_n)_{n \in \mathcal{N}}$. Le processus X est une chaîne de Markov et le processus Y est réel. L'appellation cachée signifie que les réalisations de X sont inobservables, le problème est alors de l'estimation de la réalisation de X à partir de la réalisation de Y.

2.1 Loi de X

Une suite de variables aléatoires $(X_n)_{n \in \mathcal{N}}$ prenant leurs valeurs dans l'ensemble des classes $\Omega = \{\omega_1, \dots, \omega_k\}$ est une chaîne de Markov si elle vérifie pour tout $n \geq 1$:

$$P[X_n = x_n | X_0 = x_0, \dots, X_{n-1} = x_{n-1}] = P[X_n = x_n | X_{n-1} = x_{n-1}]$$

la loi de $X = (X_n)_{n \in \mathcal{N}}$ est alors déterminée par la loi π de X_0 , dite loi initiale, et la suite des matrices de transition

$$a_{ij}^n = P[X_{n+1} = \omega_j | X_n = \omega_i].$$

Dans ce travail nous supposons $c_{ij} = P[X_n = \omega_i, X_{n+1} = \omega_j]$ ne dépendent pas de n. La loi initiale est alors donnée par

$$\pi_i = P[X_1 = \omega_i] = \sum_{1 \leq j \leq k} c_{ij}$$

et la matrice de transition, également indépendante de n, donnée par:

$$a_{ij} = P[X_{n+1} = \omega_j | X_n = \omega_i] = \frac{c_{ij}}{\sum_{1 \leq j \leq k} c_{ij}}$$

Ainsi, par le théorème de Kolmogorov, les k^2 paramètres $(c_{ij})_{1 \leq i \leq k, 1 \leq j \leq k}$ déterminent la loi du processus X.

La loi de probabilité du vecteur aléatoire $X_n = (X_1, \dots, X_n)$ s'écrit:

$$P[X_1 = \omega_1, X_2 = \omega_2, \dots, X_n = \omega_n] = \pi_{i_1} a_{i_1 j_1} \dots a_{i_{n-1} i_n}$$

2.2 loi du couple (X,Y)

La loi du couple (X,Y) est définie par la loi de X (définie ci-dessus) et les lois de Y conditionnelles à X. Nous supposons que les variables aléatoires (Y_n) sont indépendantes conditionnellement à X. De plus, la loi de chaque Y_n conditionnelle à X est égale à sa loi conditionnelle à X_n . Nous notons f_1, \dots, f_k les densités des lois de Y_n conditionnelles à $X_n = \omega_1, X_n = \omega_2, \dots, X_n = \omega_k$ respectivement, ainsi les densités f_1, \dots, f_k définissent toutes les lois de Y conditionnelles à X.

Dans la suite n sera fixé et nous noterons $X = (X_1, \dots, X_n), Y = (Y_1, \dots, Y_n)$ les suites finies de variables aléatoire et $x = (x_1, \dots, x_n), y = (y_1, \dots, y_n)$ leurs réalisations. f_x étant la densité de la loi de Y conditionnelle à $X=x$, la loi de (X,Y) est définie par :

$$h(x, y) = P[X = x] f_x(y)$$

Étant donné l'indépendance des Y_n conditionnellement à X, on a la factorisation suivante:

$$f_x = \prod_{m=1}^n f_{i_m}(y_m)$$

Or nous avons vu que la probabilité de $X = x = (\omega_{i_1}, \dots, \omega_{i_n})$ s'écrit:

$$P[X = x] = \pi_{i_1} a_{i_1 j_1} \dots a_{i_{n-1} i_n}$$

finalement h s'écrit:

$$h(x, y) = \pi_{i_1} f_{\omega_{i_1}}(y_1) a_{i_1 i_2} f_{\omega_{i_2}}(y_2) \dots a_{i_{n-1} i_n} f_{\omega_{i_n}}(y_n)$$

2.3 loi de X a posteriori

La loi de X a posteriori, i.e. conditionnelle à $Y=y$, contient toute l'information sur X contenue dans l'observation $Y=y$, ce qui joue un rôle important pour l'estimation de la réalisation cachée de X à partir de la réalisation observée $Y=y$. Elle est donnée

par :

$$\begin{aligned} P^{Y=y}[X = x] &= P[X = x|Y = y] \\ &= \frac{h(x, y)}{\sum_{x \in \Omega^n} h(x, y)} \end{aligned}$$

on montre que la distribution de X a posteriori est celle d'une chaîne de Markov non stationnaire. Plus précisément, les matrices de transitions de cette distribution sont :

$$\begin{aligned} a_{ij}^{m+1} &= P^{Y=y}[X_{m+1} = \omega_j | X_m = \omega_i] \\ &= \frac{a_{ij} f_j(y_{m+1}) \beta_{m+1}(j)}{\sum_{j=1}^k a_{ij} f_j(y_{m+1}) \beta_{m+1}(j)} \end{aligned}$$

où les β_j , dite probabilité "backward" est définie dans la paragraphe suivant.

2.4 Probabilités Forward-Backward

Nous définissons dans ce paragraphe les probabilités Forward-Backward qui jouent un rôle cruciale aussi bien au niveau de l'estimation des paramètres qu'à celui de la restauration proprement dite.

2.4.1 Probabilités Forward

La probabilité backward est définie par : $\alpha_t(i) = P[X_t = \omega_i, Y_1 = y_1, \dots, Y_t = y_t]$. Cette expression peut se calculer de manière réursive:

- Initialisation: $\pi_i f_i(y_1)$ pour $1 \leq i \leq k$
- Induction: $\alpha_{t+1}(j) = [\sum_{i=1}^k \alpha_t(i) a_{ij}] f_j(y_{t+1})$ pour $1 \leq j \leq k, 1 \leq t \leq n - 1$

2.4.2 Probabilités Backward

La probabilité backward est définie par : $\beta_t(i) = P[Y_{t+1} = y_{t+1}, \dots, Y_n = y_n | X_t = \omega_i]$. Le calcul de β_t s'obtient à partir de β_{t+1} par une récurrence réursive :

- Initialisation: $\beta_n(i) = 1$ pour $1 \leq i \leq k$
- Induction:

$$\beta_t(i) = [\sum_{j=1}^k a_{ij} f_j(y_{t+1}) \beta_{t+1}(j)] \text{ pour } 1 \leq i \leq k, 1 \leq t \leq n - 1.$$

Le calcul respectif des probabilités forward et backward se heurte à des difficultés d'ordre numérique, Afin de s'affranchir de ce problème, Devijver et al. [4] ont proposé une solution qui consiste à remplacer les probabilités conjointes par les probabilités a posteriori. les reformulations de α_t et β_t sont les suivantes:

$$\begin{aligned}\alpha_t(i) &= P[X_t = \omega_i | Y_1 = y_1, \dots, Y_t = y_t] \\ \beta_t(i) &= \frac{P[Y_{t+1} = y_{t+1}, \dots, Y_n = y_n | X_t = \omega_i]}{P[Y_{t+1} = y_{t+1}, \dots, Y_n = y_n | Y_1 = y_1, \dots, Y_t = y_t]}\end{aligned}$$

La procédure de calcul de probabilité forward devient :

- Initialisation:

$$\alpha_1(i) = \frac{\pi_i f_i(y_1)}{\sum_{j=1}^k \pi_j f_j(y_1)} \text{ pour } 1 \leq i \leq k$$

- Induction:

$$\alpha_{t+1}(i) = \frac{f_i(y_{t+1}) \sum_{j=1}^k \alpha_t(j) a_{ij}}{\sum_{l=1}^k f_l(y_{t+1}) \sum_{j=1}^k \alpha_t(j) a_{ji}} \text{ pour } 1 \leq i \leq k, 1 \leq t \leq n - 1$$

La procédure de calcul de probabilité backward devient :

- Initialisation: $\beta_n(i) = 1$ pour $1 \leq i \leq k$

- Induction: $\beta_t(i) = \frac{\sum_{j=1}^k a_{ij} f_j(y_{t+1}) \beta_{t+1}(j)}{\sum_{l=1}^k f_l(y_{t+1}) \sum_{j=1}^k \alpha_t(j) a_{ji}}$ pour $1 \leq i \leq k, 1 \leq t \leq n - 1$

2.5 Simulation

Dans cette section nous supposons connaître les paramètre caractérisant la chaîne de Markov X (La loi initiale π et la matrice de transition $A = (a_{ij})$), ainsi que les moyennes et les variances caractérisant les densités (qu'on suppose gaussiennes) des lois de Y_n conditionnelles à X_n (pour chaque ω_i , m_i (resp σ_i) est la moyenne (resp la variance) de la densité de Y_n conditionnelle à $X_n = \omega_i$).

2.5.1 Simulation de X

La simulation de X_1 est obtenue en effectuant un tirage uniforme selon le vecteur de probabilités initiale π .

En supposons $X_n = \omega_i$ connu, on simulera X_{n+1} en effectuant un tirage uniforme selon le vecteur de probabilités correspondant à la i^{ieme} ligne de la matrice de transition A.

2.5.2 Simulation de Y

En supposons $X_n = \omega_i$ connu, on effectue un tirage selon la densité f_{ω_i} dont les paramètres (la moyenne m_i et la variance σ_i) sont supposés connus par hypothèse. Et pour cela on utilise le fait que pour $m \in \mathbf{R}$, $\sigma \in \mathbf{R}_+^*$ et U, V deux variables aléatoires uniformes sur $[0,1]$, la variable aléatoire $m + \sigma\sqrt{(-2\log(U))} * \cos(2\pi V)$ suit la loi $\mathcal{N}(m, \sigma)$.

2.6 Restauration

Pour la restauration de La chaîne de Markov X, nous utiliserons la méthode “mode de la marginale a posteriori” (MPM).

considérons la probabilité que le système soit à l'état ω_i à l'instant t sachant l'observation $Y=y$.

$$\xi_t(i) = P[X_t = \omega_i | Y = y]$$

Cette Probabilité peut s'exprimer simplement en fonction des probabilités forward et backward, en effet nous avons:

$$\begin{aligned} \xi_t(i) &= \frac{P[X_t = \omega_i, Y = y]}{P[Y = y]} \\ &= \alpha_t(i)\beta_t(i) \end{aligned}$$

en effet:

$$\begin{aligned} \xi_t(i) &= \frac{P[X_t = \omega_i, Y = y]}{P[Y = y]} \\ &= \frac{P[Y = y | X_t = \omega_i]P[X_t = \omega_i]}{P[Y = y]} \\ &= \frac{P[Y_1 = y_1, \dots, Y_t = y_t | X_t = \omega_i]P[Y_{t+1} = y_{t+1}, \dots, Y_n = y_n | X_t = \omega_i]P[X_t = \omega_i]}{P[Y = y]} \end{aligned}$$

$$\begin{aligned}
&= \frac{P[Y_1 = y_1, \dots, Y_t = y_t, X_t = \omega_i] P[Y_{t+1} = y_{t+1}, \dots, Y_n = y_n | X_t = \omega_i] P[Y_1 = y_1, \dots, Y_t = y_t]}{P[Y_1 = y_1, \dots, Y_t = y_t] P[Y = y]} \\
&= P[X_t = \omega_i | Y_1 = y_1, \dots, Y_t = y_t] \frac{P[Y_{t+1} = y_{t+1}, \dots, Y_n = y_n | X_t = \omega_i]}{P[Y_{t+1} = y_{t+1}, \dots, Y_n = y_n | Y_1 = y_1, \dots, Y_t = y_t]} \\
&= \alpha_t(i) \beta_t(i)
\end{aligned}$$

La méthode MPM consiste en “estimation”, pour chaque t de la réalisation “invisible” de X_t par la classe ω dont la probabilité a posteriori, i.e. conditionnelle à $Y = y$, est maximale, c-à-d:

$$[\hat{X}_t = \omega_i] \iff [\xi_t(j) = \max_{1 \leq i \leq k} \xi_t(i)]$$

L’algorithme MPM se déroule de la manière suivante:

- Calcul en chaque t et pour chaque i
 - la probabilité forward $\alpha_t(i)$;
 - la probabilité backward $\beta_t(i)$;
 - la probabilité a posteriori $\xi_t(i)$.
- Estimation de la réalisation de chaque X_t par l’état qui maximise ξ_t .

2.7 Estimation des paramètres des modèles cachés

La méthode de restauration exposée dans le paragraphe précédent requiert la connaissance de certains paramètres de la loi du couple (X, Y) . Nous avons vu que cette loi est définie par la loi de X , dite a priori, et les lois de conditionnelles à X . Lorsque le nombre de classes est k , les paramètres de la loi de X sont au nombre de k^2 (ce sont les coefficients (c_{ij}) définies précédemment). lorsque les densités f_1, \dots, f_k sont gaussiennes (ce que nous supposons dans la suite), les paramètres définissant les lois de Y conditionnelles à X sont au nombre de $2k$ (k moyennes et k variances). Nous présentons dans cette section deux méthodes d’estimation des paramètres dans les chaînes de Markov cachées :

- L’algorithme Expectation-Maximisation (EM), proposé par Baum et al. [2] connu sous le nom “Forward-Backward Algorithm”.
- L’algorithme Iterative Conditional Estimation (ICE), proposé par Pieczynski [3], [?] dont l’application aux chaînes de Markov a été rapidement décrite dans [1].

2.7.1 Algorithme EM

Principe général

L'algorithme EM est une méthode générale d'estimation des paramètres dans le cas des "données manquantes". De façon générale, considérons un couple de variable aléatoires (X, Y) , dont la densité $f_\theta(X, Y)$. Le problème est d'estimer θ à partir de Y seul. Si X était observable, on pourrait envisager l'application du maximum de vraisemblance, qui consiste en recherche de θ maximisant $\text{Log}[f_\theta(x, y)]$. X n'étant pas observable, on remplace la variable aléatoire $\text{Log}[f_\theta(x, y)]$ par $E_\theta[\text{Log}[f_\theta(x, y)|Y = y]]$.

On arrive alors à une méthode itérative : la valeur suivante du paramètre θ_{k+1} est donnée à partir de sa valeur courante θ_k et $Y=y$ par :

$$E_{\theta_k}[\text{Log}[f_{\theta_{k+1}}(X, Y)|Y = y]] = \max_{\theta} E_{\theta_k}[f_\theta(X, Y)|Y = y]$$

Il existe deux phases dans chaque itération : calcul de $E_{\theta_k}[f_\theta(X, Y)|Y = y]$ et sa maximisation, d'où l'appellation de la méthode.

Cas des chaînes de Markov cachées

Nous décrivons ci-dessous les itérations de l'algorithme EM dans le cas du modèle de chaîne de Markov cachées.

On considère la probabilité d'être à l'instant t dans la classe ω_i et à l'instant suivant dans la classe ω_j sachant la suite des observations

$$\Psi_t(i, j) = P[X_t = \omega_i, X_{t+1} = \omega_j | Y = y].$$

Cette expression peut s'écrire en fonction des probabilités forward-backward :

$$\Psi_t(i, j) = \frac{\alpha_t(i) a_{ij} f_j(y_{t+1}) \beta_{t+1}(j)}{\sum_{l=1}^k f_l(y_{t+1}) \sum_{o=1}^k \alpha_t(o) a_{ol}}$$

Les formules de la re-estimation des paramètres du modèle à l'itération $q + 1$ sont les suivantes:

- les probabilités initiales et la matrice de transition :

$$\pi_i^{q+1} = \frac{1}{n} \sum_{t=1}^n \xi_t^q(i)$$

$$a_{ij}^{q+1} = \frac{\sum_{t=1}^{n-1} \Psi_t^q(i, j)}{\sum_{t=1}^{n-1} \xi_t^q(i)}$$

où ξ_t est la loi de X a posteriori définie précédemment.

- Les paramètres définissant la densité de probabilité, pour le cas gaussien considéré, associée à la classe ω_i est donné par le couple (μ_i, σ_i) , μ_i étant la moyenne de la loi et σ_i sa variance. On obtient pour la re-estimation :

$$\mu_i^{q+1} = \frac{\sum_{t=1}^n \xi_t^q(i) y_t}{\sum_{t=1}^n \xi_t^q(i)}$$

$$(\sigma_i^2)^{q+1} = \frac{\sum_{t=1}^n \xi_t^q(i) (y_t - \mu_i^{q+1})^2}{\sum_{t=1}^n \xi_t^q(i)}$$

L'algorithme EM se déroule de la façon suivante:

- Initialisation des paramètres $a_{ij}^0, \mu_i^0, (\sigma_i^2)^0$
- A chaque itération q :
 - * Etape “E”: calcul des probabilités suivantes:
 - $\alpha_t(i), \beta_t(i)$
 - Déduction de $\Psi_t^q(i, j)$ à partir de $\alpha_t(i)$ et $\beta_t(i)$ calculée sur la base des paramètres $a_{ij}^q, \mu_i^q, (\sigma_i^2)^q$
 - * Etape “M”: calcul des paramètres $\pi_i^{q+1}, a_{ij}^{q+1}, \mu_i^{q+1}, (\sigma_i^2)^{q+1}$ par les formules ci-dessus.

Remarque:

On peut retenir cet algorithme en se souvenant que la probabilité a priori est re-estimée par la moyenne des probabilités a posteriori, les moyennes sont re-estimées par les moyennes des observations “pondérées par les probabilités a posteriori”, et les variances sont re-estimés par les variances empiriques en considérant des observations “pondérées par les probabilités a posteriori”.

2.7.2 Algorithme ICE

Principe général

De façon générale, considérons un couple de variables aléatoires (X, Y) , dont la loi $P_{(X, Y)}$ dépend d'un paramètre θ . Nous cherchons une méthode d'estimation de θ à partir de Y .

Considérons un estimateur $\hat{\theta} = \hat{\theta}(X, Y)$ de θ à partir de (X, Y) . L'idée de l'ICE est de rechercher l'approximation de $\hat{\theta} = \hat{\theta}(X, Y)$ dans l'ensemble de variables aléatoires fonctions de Y , le seul observable [?].

La meilleure approximation, au sens de l'erreur quadratique moyenne, est l'espérance conditionnelle. L'espérance conditionnelle $E[\hat{\theta}|Y]$ de $\hat{\theta} = \hat{\theta}(X, Y)$ par rapport à Y dépend du paramètre θ . En effet, c'est la projection orthogonale par rapport au produit scalaire de L^2 , qui dépend de θ , sur l'ensemble de variables aléatoire fonctions de Y .

Lorsqu'on cherche à calculer, ou à approcher $E[\hat{\theta}|Y]$, on est ainsi amené à considérer la valeur "courante" θ_k du paramètre, la valeur suivante est donnée par $\theta_{k+1} = E_k[\hat{\theta}|Y]$, où E_k est l'espérance conditionnelle correspondant à θ_k . On arrive à la démarche itérative suivante :

- on considère une valeur initiale θ_0
- on pose :

$$\theta_{k+1} = E_k[\hat{\theta}|Y = y] \tag{2.1}$$

Lorsque $E_k[\hat{\theta}|Y = y]$ n'est pas explicitement calculable mais la simulation des réalisations de X selon la loi conditionnelle à Y possible, (1.1) peut être approché par :

$$\theta_{k+1} = \frac{1}{N} [\hat{\theta}(x_1, y) + \dots + \hat{\theta}(x_N, y)]$$

Cas des chaînes de Markov cachées

La procédure ICE est applicable au problème de l'estimation des paramètres dans le cas des chaînes de Markov cachées. Nous examinons successivement le problème de l'estimation des paramètres définissant la loi de X , et celui de l'estimation des paramètres du bruit.

Estimation des paramètres de la loi de X

Rapportons la définition des c_{ij} :

$$c_{ij} = P[X_m = \omega_i, X_{m+1} = \omega_j]$$

Supposons, conformément au principe général de ICE, que X est observable. Le paramètre de transition c_{ij} peut alors être estimé par :

$$\hat{c}_{ij}(X) = \frac{1}{n-1} \sum_{t=1}^{n-1} 1_{[X_t = \omega_i, X_{t+1} = \omega_j]}$$

qui est la fréquence empirique. Afin d'obtenir la valeur suivante du paramètre c_{ij} on considère, conformément au principe général de ICE, l'espérance conditionnelle de \hat{c}_{ij} :

$$c_{ij}^{q+1} = E_{\theta^q}[\hat{c}_{ij}(X)|Y = y]$$

ce qui donne :

$$c_{ij}^{q+1} = \frac{1}{n-1} \sum_{t=1}^{n-1} P^q[X_t = \omega_i, X_{t+1} = \omega_j | Y = y]$$

la matrice de transition correspondante à l'itération $q + 1$ est donc :

$$\begin{aligned} a_{ij}^{q+1} &= \frac{c_{ij}^{q+1}}{\sum_{j=1}^k c_{ij}^{q+1}} \\ &= \frac{\sum_{t=1}^{n-1} P^q[X_t = \omega_i, X_{t+1} = \omega_j | Y = y]}{\sum_{j=1}^k \sum_{t=1}^{n-1} P^q[X_t = \omega_i, X_{t+1} = \omega_j | Y = y]} \end{aligned}$$

ou encore, en reprenant les notations ci-dessus :

$$a_{ij}^{q+1} = \frac{\sum_{t=1}^{n-1} \Psi_t^q(i, j)}{\sum_{t=1}^{n-1} \xi_t^q(i)}$$

Remarque:

Les formules ci-dessus de la re-estimation des paramètres de la loi de X sont les mêmes que celles obtenus par la méthode EM. Contrairement à EM, la méthode ICE n'utilise pas la notion de vraisemblance et le calcul reste valable quel que soit la forme de bruit.

Pour le bruit gaussien les paramètres des densités conditionnelles sont donnés par les moyennes μ_i et les variances σ_i . Suivant le principe de ICE, supposons X observable. Les paramètres μ_i et σ_i peuvent alors être estimés par les moyennes et les variances empiriques :

$$\begin{aligned} \hat{\mu}_i(X, Y) &= \frac{\sum_{j=1}^n Y_j 1_{[X_j = \omega_i]}}{\sum_{j=1}^n 1_{[X_j = \omega_i]}} \\ \hat{\sigma}_i^2(X, Y) &= \frac{\sum_{j=1}^n (Y_j - \hat{\mu}_i)^2 1_{[X_j = \omega_i]}}{\sum_{j=1}^n 1_{[X_j = \omega_i]}} \end{aligned}$$

Les espérances conditionnelles des estimateurs $\hat{\mu}_i(X, Y)$, $\hat{\sigma}_i^2(X, Y)$ ne sont pas calculables explicitement, on peut cependant utiliser l'approximation stochastique. En effet, la simulation des réalisations de X selon sa loi a posteriori est possible.

La démarche à chaque itération q est la suivante :

- Simulation de N réalisations de X selon sa loi a posteriori : (X^1, \dots, X^N) (chaque X^i est un n-uple).
- Calcul, pour chaque $1 \leq i \leq k$ et $1 \leq j \leq k$, de $\hat{\mu}_i^j$ et $(\hat{\sigma}_i^j)^2$ (à partir de X^j, y) par les formules ci-dessus.
- Calcul, pour chaque $1 \leq i \leq k$ de μ_i^{q+1} et $(\sigma_i^{q+1})^2$ par :

$$\mu_i^{q+1} = \frac{1}{N}(\mu_i^1, \dots, \mu_i^N)$$

$$(\sigma_i^{q+1})^2 = \frac{1}{N}((\sigma_i^1)^2, \dots, (\sigma_i^N)^2)$$

Remarque

ICE est une méthode d'estimation à la fois déterministe (les paramètres a_{ij}) et stochastique (les paramètres μ_i et σ_i). Grâce à sa phase stochastique ICE s'avère moins sensible au choix des paramètres de l'initialisation que EM. Cette situation est précisée dans les tableaux ci-dessous.

Parmètres à estimer	EM	ICE
(c_{ij})	Déterministe	Déterministe
(μ_i, σ_i^2)	Déterministe	Stochastique

2.8 Résultats des expérimentations

Nous présentons maintenant quelques résultats concernant la simulation de X et Y dans le cas de deux classes ($k=2$) en utilisant les résultats précédents pour certaines valeurs de paramètres, puis la restauration de X à partir des paramètres de Y, selon l'algorithme MPM.

Les chaînes sont constituées de 25000 éléments (pour la restauration, nous avons utilisé les probabilités " Backward " et " Forward " normalisées).

Dans cette étude X est simulé avec les paramètres suivantes:

$$C_{k,l} = \begin{pmatrix} 0.49 & 0.01 \\ 0.01 & 0.49 \end{pmatrix}$$

2.8.1 Résultats des expérimentations dans le cas supervisé

Le mot "supervisé" signifie qu'on utilise les vrais paramètres pour la restauration de X. Le bruit est supposé gaussien de moyenne μ et variance σ . On peut distinguer trois types de bruits selon leurs moyennes et variances :

1. $\mu_1 \neq \mu_2, \sigma_1 = \sigma_2$:discrimination par les moyennes.
2. $\mu_1 = \mu_2, \sigma_1 \neq \sigma_2$:discrimination par les variances
3. $\mu_1 \neq \mu_2, \sigma_1 \neq \sigma_2$:discrimination par les moyennes et les variances.

Le tableau suivant résume les résultats des expérimentations.

μ_1	μ_2	σ_1	σ_2	Taux d'erreur
0	1	1	1	3.65%
1	1	1	2	6.8%
2	3	1	2	6.17%

2.8.2 Résultats des expérimentations dans le cas non supervisé

Le mot "non supervisé" signifie qu'on utilise des paramètres estimés à partir de la version dégradée Y pour la restauration de X.

Nous présentons les taux d'erreur de la restauration avec les trois types de bruitages décrits ci-dessus, en utilisant les valeurs des paramètres estimés dans un cas par la méthode ICE, et dans un autre cas par la méthode EM.

Initialisation des algorithmes

Notons M la moyenne et Σ l'écart-type de l'échantillon. Pour k nombre de classe, les paramètres sont initialisés de la façon suivante :

- Initialisation des paramètres de modèle (loi a priori):

- $\forall 1 \leq i \leq k \pi_i^0 = \frac{1}{k}$
- $\forall 1 \leq i, j \leq k$ avec $i \neq j$ $a_{ij}^0 = \frac{1}{2(k-1)}$
- $\forall 1 \leq i \leq k a_{ii}^0 = 0.5$

- Initialisation des moyennes du bruit:

- pour k pair et $\forall i$ tel que $0 \leq i \leq \frac{k}{2}$
 - * $\mu_{i+1}^0 = M - (\frac{k}{2} - i) \frac{\Sigma}{2}$
 - * $\mu_{k-i}^0 = M + (\frac{k}{2} - i) \frac{\Sigma}{2}$
- Pour k impair et $\forall 0 \leq i \leq k$:
 - * $\mu_{i+1}^0 = M - (\frac{k}{2} - i) \frac{\Sigma}{2}$

- Initialisation des variances du bruit:

- $\forall 1 \leq i \leq k \sigma_i = \Sigma$

Résultats dans le cas des paramètres estimer par la méthode ICE

Le tableau suivant nous présente les taux d'erreur de la restauration, les paramètres de bruit sont estimer avec la méthode ICE, sur le tableau n'apparait que les vrais paramètres du bruit :

μ_1	μ_2	σ_1	σ_2	Taux d'erreur
0	1	1	1	5.94%
1	1	1	2	9.98%
2	3	1	2	11.3%

Résultats dans le cas des paramètres estimer par la méthode EM

Le tableau suivant présente les taux d'erreur de la restauration, les paramètres du bruit sont estimés avec la méthode EM, sur le tableau n'apparait que les vrais paramètres du bruit :

μ_1	μ_2	σ_1	σ_2	Taux d'erreur
0	1	1	1	6.11%
1	1	1	2	10.18%
2	3	1	2	11.2%

chapitre 3

Chaînes de Markov couples (PMC)

Une chaîne de Markov couple est un processus $Z = (Z_1, \dots, Z_N)$ (N fixé) avec $Z_n = (X_n, Y_n)$ la variable aléatoire couple à l'instant n , où $X_n \in \Omega = [1, \dots, k]$ avec k le nombre d'états, et Y_n dans \mathbf{R} , si sa distribution est définie par

$$p(z) = \frac{p(z_1, z_2) \dots p(z_{N-1}, z_N)}{p(z_2) \dots p(z_{N-1})} \quad (3.1)$$

Rappelons que dans le cas d'une chaîne de Markov caché (HMC), nous avons:

$$p(z) = p(x, y) = p(x_1) f_{x_1}(y_1) p(x_2|x_1) f_{x_2}(y_2) \dots p(x_N|x_{N-1}) f_{x_N}(y_N)$$

3.1 loi de Z

Soit Z une chaîne de Markov couple (PMC) dont la distribution est donnée par (3.1). On se donne $p(z_n, z_{n+1})$, indépendant de n , qui définit la probabilité a priori $p(z_1)$ et la matrice de transition stationnaire $p(Z_2|Z_1)$.

l'objectif est de savoir calculer:

$$p(z_n, z_{n+1}) = p(x_n, x_{n+1}) f_{x_n, x_{n+1}}(y_n, y_{n+1}) \quad (3.2)$$

Notons que le cas des chaîne Markov couple apparait comme un cas particulier de PMC, avec:

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

3.1.1 Calcul de $P(z_n)$

d'après (3.2), on'a:

$$p(z_n) = \int_{\mathbf{R}} \sum_{k=1}^K p(x_n, y_n, x_{n+1} = k, y_{n+1}) dy_{n+1}$$

$$\begin{aligned}
&= \sum_{k=1}^k p(x_n, x_{n+1} = k) \int_{\mathbf{R}} f_{x_n, x_{n+1}=k}(y_n, y_{n+1}) dy_{n+1} \\
&= \sum_{k=1}^k p(x_n, x_{n+1} = k) f_{x_n, x_{n+1}=k}(y_n)
\end{aligned}$$

ce qui se présente comme le mélange de densités mono-dimensionnelles.

3.1.2 Calcul de $P(z_n | z_{n+1})$

La matrice de transition de la chaîne de Markov Z s'écrit :
pour $1 \leq n \leq N - 1$

$$\begin{aligned}
p(z_{n+1} | z_n) &= \frac{p(z_n, z_{n+1})}{p(z_n)} \\
&= \frac{p(x_n, x_{n+1}) f_{x_n, x_{n+1}}(y_n, y_{n+1})}{\sum_{k=1}^k p(x_n, x_{n+1} = k) f_{x_n, x_{n+1}=k}(y_n)}
\end{aligned}$$

3.2 Simulation de Z

Pour la simulation de Z , i.e. la simulation de X et Y , nous supposons connaître l'ensemble des paramètres caractérisant le processus Z , i.e. les paramètres du modèle $p(x_n, x_{n+1})$ et les paramètres de bruits que nous supposons gaussien.

Lorsque le nombre de classes est k on a :

- Paramètres de modèle : k^2 paramètres
- Paramètres de bruit : $f_{x_n, x_{n+1}}(y_n, y_{n+1})$: k^2 densités dans \mathbf{R} , pour chaque densité, deux moyennes, deux variances et une covariance, soit $5k^2$ paramètres.

Au total, dans le cadre d'un bruit gaussien, on a $6k^2$ paramètres. x_n, y_n étant fixés, on simulera $z_{i+1} = (x_{i+1}, y_{i+1})$ en simulant d'abord x_{i+1} , puis y_{i+1} .

3.2.1 Simulation de x_1 et y_1

nous avons l'expression de $p(z_1)$:

$$\begin{aligned}
p(z_1) &= p(x_1, y_1) \\
&= \sum_{k=1}^k p(x_1, x_2 = k) f_{x_1, x_2=k}(y_1)
\end{aligned}$$

d'où :

$$\begin{aligned} p(x_1) &= \sum_{i=1}^k p(x_1, x_2 = i) \\ p(y_1|x_1) &= \frac{\sum_{l=1}^k p(x_1, x_2 = l) f_{x_1, x_2=l}(y_1)}{p(x_1)} \\ &= \sum_{l=1}^k \frac{p(x_1, x_2 = l)}{p(x_1)} f_{x_1, x_2=l}(y_1) \end{aligned}$$

La simulation de x_1 est obtenue en effectuant un tirage uniforme selon le vecteur de probabilités $p(x_1)$.

Dans le cas de y_1 , x_1 est connu, nous devons effectuer un tirage selon un mélange pondéré de densités mono-dimensionnelles. Pour cela, nous effectuons d'abord un tirage selon les poids $\frac{p(x_1, x_2=l)}{p(x_1)}$ pour $1 \leq l \leq k$. On note le résultat du tirage par ω_1 , ensuite nous effectuons un second tirage selon la densité f_{x_1, ω_1} dont les paramètres sont connus par hypothèses.

3.2.2 Simulation de x_{n+1} et y_{n+1}

En supposons x_n et y_n connus, on simulera $z_{n+1} = (x_{n+1}, y_{n+1})$ en simulant d'abord x_{n+1} puis y_{n+1} de manière alternative.

Simulation de x_{n+1} à partir de z_n

La densité de la loi de x_{n+1} se calcule en intégrant $p(z_{n+1}|z_n)$ par rapport à y_{n+1}

$$\begin{aligned} p(x_{n+1}|z_n) &= \int_{\mathbf{R}} p(x_{n+1}, y_{n+1}|z_n) dy_{n+1} \\ &= \frac{p(x_n, x_{n+1}) f_{x_n, x_{n+1}}(y_n)}{\sum_{j=1}^k p(x_n, x_{n+1} = j) f_{x_n, x_{n+1}=j}(y_n)}, 1 \leq n \leq N-1 \end{aligned}$$

Remarque

Dans le cas classique d'une chaîne de Markov caché, étant donné l'hypothèse d'indépendance conditionnelle, nous avons :

$$p(x_{n+1}|z_n) = \frac{P(x_n, x_{n+1})}{p(x_n)}, 1 \leq n \leq N-1.$$

Simulation de y_{n+1} à partir de x_{n+1} et z_n

La densité de la loi de y_{n+1} conditionnellement à x_{n+1} et à z_n est donné par :

$$p(y_{n+1}|x_{n+1}, z_n) = \frac{p(z_{n+1}|z_n)}{p(x_{n+1}|z_n)}$$

$$= \frac{f_{x_n, x_{n+1}}(y_n, y_{n+1})}{f_{x_n, x_{n+1}}(y_n)}, 1 \leq n \leq N - 1$$

Si on note les moyennes et la matrice de variances-covariances de $f_{x_n, x_{n+1}}$ par :

$$m_{x_n, x_{n+1}} = (m_{x_n, x_{n+1}}^1, m_{x_n, x_{n+1}}^2)$$

$$\Gamma = \begin{pmatrix} (\sigma_{x_n, x_{n+1}}^2)^1 & \rho_{x_n, x_{n+1}} \\ \rho_{x_n, x_{n+1}} & (\sigma_{x_n, x_{n+1}}^2)^2 \end{pmatrix}$$

alors y_{n+1} conditionnellement aux x_{n+1} et z_n est gaussien de densité $g_{y_{n+1}|x_{n+1}, z_n}$ caractérisé par la moyenne :

$$m_{y_{n+1}|x_{n+1}, z_n} = m_{x_n, x_{n+1}}^2 - \frac{(y_n - m_{x_n, x_{n+1}}^1) \rho_{x_n, x_{n+1}}}{(\sigma_{x_n, x_{n+1}}^2)^1}$$

et la variance

$$\sigma_{y_{n+1}|x_{n+1}, z_n} = (\sigma_{x_n, x_{n+1}}^2)^2 - \frac{\rho_{x_n, x_{n+1}}^2}{(\sigma_{x_n, x_{n+1}}^2)^1}$$

La simulation de y_{n+1} est réalisé par un tirage selon la densité $g_{y_{n+1}|x_{n+1}, z_n}$

3.3 Estimation des paramètres

Lorsque le nombre de classes est k , le modèle couple est définie par $6k^2$ paramètres :

- Paramètres de modèle : k^2 paramètres
- Paramètres de bruit : $f_{x_n, x_{n+1}}(y_n, y_{n+1})$: k^2 densités dans \mathbf{R} , pour chaque densité, deux moyennes, deux variances et une covariances, soit $5k^2$ paramètres.

3.3.1 Probabilité Forward

la probabilité Forward est définie par :

$$\alpha_t(i) = P[X_t = \omega_i, Y_1 = y_1, \dots, Y_t = y_t]$$

cette expression peut se calculer de manière récursive :

- Initialisation: $\alpha_1(l) = p(x_1 = l, y_1)$ pour $1 \leq l \leq k$
- Induction: $\alpha_{t+1}(j) = \left[\sum_{i=1}^k \alpha_t(i) p(x_{n+1} = j, y_{n+1} | x_n = i, y_n) \right]$ pour $1 \leq j \leq k$,
 $1 \leq t \leq n - 1$

Normalisation (par analogie avec le travail de Devijver) :

- Initialisation :

$$\alpha_1(l) = \frac{p(x_1 = k, y_1)}{\sum_{m=1}^k p(x_1 = m, y_1)}$$

- Induction :

$$\alpha_{n+1}(l) = \frac{\sum_{i=1}^k \alpha_n(i) p(x_{n+1} = l, y_{n+1} | x_n = i, y_n)}{\sum_{m=1}^k \sum_{i=0}^k \alpha_n(i) p(x_{n+1} = m, y_{n+1} | x_n = i, y_n)}$$

3.3.2 Probabilité Backward

la probabilité backward est définie par :

$$\beta_t(i) = P[Y_1 = y_1, \dots, Y_t = y_t | X_t = \omega_i]$$

cette expression peut se calculer de manière récursive :

- Initialisation: $\beta_1(l) = 1$ pour $1 \leq l \leq k$
- Induction: $\beta_{t+1}(j) = \left[\sum_{i=1}^k \beta_{t+1}(i) p(x_{n+1} = i, y_{n+1} | x_n = j, y_n) \right]$ pour $1 \leq j \leq k$,
 $1 \leq t \leq n - 1$

Normalisation (par analogie avec le travail de Devijver) :

- initialisation : $\beta_1(l) = 1$
- Induction :

$$\beta_n(l) = \frac{\sum_{i=1}^k \beta_{n+1}(i) p(x_{n+1} = i, y_{n+1} | x_n = l, y_n)}{\sum_{m=1}^k \sum_{i=0}^k \beta_{n+1}(i) p(x_{n+1} = m, y_{n+1} | x_n = i, y_n)}$$

Remarque:

$\alpha_n(i)$ et $\beta_n(i)$ se calculent en utilisant le resultat :

$$p(z_{n+1} | z_n) = \frac{p(x_n, x_{n+1}) f_{x_n, x_{n+1}}(y_n, y_{n+1})}{\sum_{k=1}^k p(x_n, x_{n+1} = k) f_{x_n, x_{n+1}=k}(y_n)}$$

3.3.3 Probabilités conjointes de \mathbf{X} a posteriori

C'est la probabilité que le système soit à l'instant t dans la classe k et à l'instant suivant dans la classe l sachant la suite des observations. Elle est donnée par :

$$\Psi_n(k, l) = p(x_n = k, x_{n+1} = l | y), \quad 1 \leq n \leq N - 1$$

et se calcule de la manière suivante:

$$\Psi_n(k, l) = \frac{\alpha_n(k)p(x_{n+1} = l, y_{n+1} | x_n = k, y_n)\beta_{n+1}(l)}{\sum_{j=1}^k \sum_{m=1}^k \alpha_n(j)p(x_{n+1} = m, y_{n+1} | x_n = j, y_n)\beta_{n+1}(j)}$$

3.3.4 Matrice de transition de la chaîne $x|y$: $T_n(k, l)$

Notons que la chaîne $x|y$ est de Markov. Sa matrice de transition est donnée par :

$$T_{n+1}(i, j) = p(x_{n+1} = j | x_n = i, y), \quad \text{pour } i \leq n \leq N - 1,$$

qui se calcule à l'aide de la probabilité marginale a posteriori et la probabilité conjointe a posteriori de la façon suivante:

$$\begin{aligned} T_{n+1}(i, j) &= \frac{\Psi_n(i, j)}{\xi_n(i)} \\ &= \frac{p(x_{n+1} = j, y_{n+1} | x_n = i, y_n)\beta_{n+1}(j)}{\sum_{m=0}^k p(x_{n+1} = m, y_{n+1} | x_n = i, y_n)\beta_{n+1}(m)}, \quad 1 \leq n \leq N - 1. \end{aligned}$$

3.3.5 Probabilités conjointes de \mathbf{X} a priori : $C(i, j)$

Notons que \mathbf{X} n'est pas markovien, mais stationnaire, la loi de \mathbf{X} a priori est définie par:

$$C(i, j) = p(x_n = i, x_{n+1} = j)$$

on peut l'estimer analytiquement par la moyenne des probabilités conjointes a posteriori sans faire appel à la simulation:

$$C(i, j) = \frac{1}{N-1} \sum_{n=1}^{N-1} \Psi_n(i, j)$$

3.4 Restauration

Comme dans le cas des chaînes de Markov cachés nous utiliserons la méthode MPM (mode de la marginale a posteriori) qui consiste en estimation de la réalisation de \mathbf{X} à chaque instant t par l'état ω qui maximise la probabilité de \mathbf{X} conditionnellement à \mathbf{Y} .

3.4.1 Loi marginale de \mathbf{X} a posteriori

La loi de \mathbf{X} a posteriori, i.e. conditionnelle à $\mathbf{Y}=\mathbf{y}$, contient toute l'information sur \mathbf{X} contenue dans l'observation $\mathbf{Y}=\mathbf{y}$, ce qui joue un rôle crucial pour l'estimation de la réalisation cachée de \mathbf{X} à partir de la réalisation observée $\mathbf{Y}=\mathbf{y}$. Elle est donnée par :

$$\xi_n(k) = p(x_n = k | \mathbf{y}) \quad 1 \leq n \leq N - 1.$$

et se calcule de la manière suivante:

$$\begin{aligned} \xi_n(i) &= \frac{\alpha_n(i)\beta_n(i)}{\sum_{l=1}^k \alpha_n(l)\beta_n(l)} \\ &= \sum_{l=1}^k \Psi_n(i, l), \quad 1 \leq n \leq N - 1. \end{aligned}$$

La méthode MPM consiste en “estimation”, pour chaque t , de la réalisation “invisible” de X_t par la classe ω dont la probabilité a posteriori, i.e. conditionnelle à $\mathbf{Y} = \mathbf{y}$, est maximale, c-à-d,

$$[\hat{X}_t = \omega_i] \iff [\xi_t(j) = \max_{1 \leq i \leq k} \xi_t(i)].$$

L'algorithme MPM se déroule de la manière suivante:

- Calcul en chaque t et pour chaque i
 - la probabilité forward $\alpha_t(i)$,
 - la probabilité backward $\beta_t(i)$,
 - la probabilité a posteriori $\xi_t(i)$,
- Estimation de la réalisation de chaque X_t par l'état qui maximise ξ_t .

3.5 Comparaison de résultat de reastoration de PMC et HMC

Nous présentons quelques résultats concernant la restauration de X , dans le cas de deux classes ($k=2$). Dans un premier temps, nous simulons $X_0=X$ et $Y_0=Y$ en utilisant les résultats précédents pour certaines valeurs de paramètres. Puis, dans un deuxième temps, nous restaurons X à partir des paramètres et de Y_0 , selon l'algorithme MPM. Nous noterons X_1 la restauration obtenue avec le MPM couple, et X_2 la restauration obtenue avec le modèle classique. En calculant le taux d'erreur entre X_0 et X_1 d'une part, et entre X_0 et X_2 d'autre part, nous obtenons une information sur l'apport du modèle couple par rapport au modèle classique. Les taux d'erreur présentés sont des taux moyens calculés à partir de 100 simulations. Les chaînes sont constituées de 10000 éléments. Pour la restauration, nous avons utilisé les probabilités "Forward" et "Backward" normalisées.

3.5.1 présentation des paramètres:

Les paramètres du modèle sont fixés à:

$$C_{k,l} = \begin{pmatrix} 0.48 & 0.02 \\ 0.02 & 0.48 \end{pmatrix}$$

Pour simuler la chaîne avec le modèle couple, nous avons utilisé des bruits gaussien avec les moyennes et les variances suivantes:

Classe		Paramètres des lois				
k	l	μ_1	μ_2	σ_1	σ_2	ρ
0	0	0	0	1	1	$\rho_{0,0}$
0	1	0.2	0.8	1	1	$\rho_{0,1}$
1	0	0.8	0.2	1	1	$\rho_{1,0}$
1	1	1	1	1	1	$\rho_{1,1}$

et les coefficients de corrélation:

Coefficient de corélation	$\rho_{0,0}$	$\rho_{0,1}$	$\rho_{1,0}$	$\rho_{1,1}$
Expérience 1	0.1	0.1	0.1	0.1
Expérience 2	0.1	0.9	0.9	0.1
Expérience 3	0.9	-0.9	-0.9	0.9

Le modèle classique apparaît comme un cas particulier du modèle couple. Ainsi, pour restaurer la chaîne avec le modèle classique, nous avons utilisé le MPM couple avec les paramètres suivants:

Classe		Paramètres des lois				
k	l	μ_1	μ_2	σ_1	σ_2	ρ
0	0	0	0	1	1	$\rho_{0,0}$
0	1	0	1	1	1	$\rho_{0,1}$
1	0	1	0	1	1	$\rho_{1,0}$
1	1	1	1	1	1	$\rho_{1,1}$

3.5.2 Comparaisons des résultats

Le tableau suivant présente les résultats de restauration avec le MPM classique et le MPM couple:

Taux d'erreur moyen	MPM classique	MPM couple	Gain
Expérience 1	14.1%	11.08%	21.4%
Expérience 2	14.06%	9.08%	35.41%
Expérience 3	32.57%	15.13%	53.54%

chapitre 4

PMC dans le cas de bruit non gaussien

Le modèle traité au paragraphe précédent:

$$p(Z_i, Z_{i+1}) = p(x_i, x_{i+1})f_{x_i, x_{i+1}}(y_i, y_{i+1})$$

n'est pas restreint au cadre gaussien. Nous pourrions bien considérer que les densités $f_{x_i, x_{i+1}}$ appartient à d'autres familles de lois, en particulier des lois exponentielles. On a vu dans le chapitre précédent que la connaissance des paramètres du modèle $p(x_i, x_{i+1})$ et les densité des lois de (y_i, y_{i+1}) suffit pour faire la simulation et la restauration de la chaîne de Markov couple (X, Y) .

Calcul explicite de $f_{x_i, x_{i+1}}(y_i, y_{i+1})$

soit Γ la matrice des variances-covariances de (y_i, y_{i+1}) conditionnellement à (x_i, x_{i+1}) , on peut supposé que :

$$\Gamma = \begin{pmatrix} 1 & \rho \\ \rho & 1 \end{pmatrix}$$

Alors Γ peut se décomposer de la manière suivante:

$$\Gamma = \begin{pmatrix} 1 & \rho \\ \rho & 1 \end{pmatrix} = \begin{pmatrix} a & b \\ b & a \end{pmatrix} \begin{pmatrix} a & b \\ b & a \end{pmatrix}$$

avec $a = \cos(\alpha)$ et $b = \sin(\alpha)$ où $\alpha = \frac{\arcsin(\rho)}{2}$

Soit

$$A = \begin{pmatrix} a & b \\ a & b \end{pmatrix}$$

alors on peut écrire (Y_i, Y_{i+1}) de la forme suivante:

$$\begin{pmatrix} Y_i \\ Y_{i+1} \end{pmatrix} = A \begin{pmatrix} T_1 \\ T_2 \end{pmatrix}$$

où T_1 T_2 deux variables aléatoires indépendantes conditionnellement à (x_i, x_{i+1}) . Nous noterons g_1 et g_2 les densité des lois de T_1 T_2 (respectivement) conditionnelles à (x_i, x_{i+1}) .
notons

$$A_1 = (1, 0) \text{ et } A_2 = (0, 1)$$

finalement la densité de la loi de (Y_i, Y_{i+1}) conditionnellement à (x_i, x_{i+1}) s'écrit:

$$f_{x_i, x_{i+1}}(y_i, y_{i+1}) = \frac{1}{\det A} g_1 \left(A_1 A^{-1} \begin{pmatrix} y_i \\ y_{i+1} \end{pmatrix} \right) g_2 \left(A_2 A^{-1} \begin{pmatrix} y_i \\ y_{i+1} \end{pmatrix} \right)$$

4.1 Simulation et Restauration avec bruitage exponentielle

Pour la simulation de Z , i.e. la simulation de X et Y , nous supposons connaître l'ensemble des paramètres caractérisant le processus Z , i.e. les paramètres du modèle $p(x_n, x_{n+1})$ et les paramètres de bruits que nous supposons exponentielle .

Lorsque le nombres de classes est k on a :

- paramètres de modèle : k^2 paramètres
- paramètres de bruit : $f_{x_n, x_{n+1}}(y_n, y_{n+1})$: k^2 densités dans \mathbf{R} , pour chaque densité, deux paramètre $(\lambda_{x_i, x_{i+1}}^1, \lambda_{x_i, x_{i+1}}^2)$, soit $2k^2$ paramètres.

Au total, dans dans le cadre d'un bruit gaussien, on a $3k^2$ paramètres. x_n, y_n etant fixés, on simulera $z_{i+1} = (x_{i+1}, y_{i+1})$ en simulant d'abord x_{i+1} , ensuite, y_{i+1} . La simulation est faite d'une façon similaire que dans le cas avec bruitage gaussien. Comme dans le cas de PMC avec bruitage gaussien nous utiliserons la méthode MPM¹. Les expression des prababilités Forward-Backward et des probabilité marginale a posteriori sont les mêmes que dans le cas de PMC avec bruitage gaussien.

4.2 Présentation des paramètres

Les parmètres du modèle sont fixés à :

$$C_{k,1} = \begin{pmatrix} 0.48 & 0.02 \\ 0.02 & 0.48 \end{pmatrix}$$

¹mode de la marginale a posteriori : qui consiste en estimation de la réalisticion de X à chaque instant t par l'état ω qui maximise la probabilité de X conditionnellement à Y

Pour simuler la chaîne avec le nouveau modèle, nous avons utilisé des bruits exponentielle avec les paramètres suivantes :

Classe		Paramètres des lois		
k	l	λ_1	λ_2	ρ
0	0	1	1	$\rho_{0,0}$
0	1	1.2	1.8	$\rho_{0,1}$
1	0	1.8	1.2	$\rho_{1,0}$
1	1	2	2	$\rho_{1,1}$

et les coefficients de corrélation :

Coefficient de corrélation	$\rho_{0,0}$	$\rho_{0,1}$	$\rho_{1,0}$	$\rho_{1,1}$
Expérience 1	0.1	0.1	0.1	0.1
Expérience 2	0.1	0.9	0.9	0.1
Expérience 3	0.9	-0.9	-0.9	0.9

pour restaurer la chaîne avec le PMC avec bruitage gaussien, nous avons utilisé le MPM couple avec les paramètres suivants:

Classe		Paramètres des lois				
k	l	μ_1	μ_2	σ_1	σ_2	ρ
0	0	1	1	1	1	$\rho_{0,0}$
0	1	0.8	0.55	0.64	0.3	$\rho_{0,1}$
1	0	0.55	0.8	0.3	0.64	$\rho_{1,0}$
1	1	0.5	0.5	0.25	0.25	$\rho_{1,1}$

4.3 Comparaisons des résultats

Le tableau suivant présente les résultats de restauration avec MPM avec bruitage gaussien et le MPM avec bruitage exponentielle:

Taux d'erreur moyen	MPM avec bruit gaaussien	MPM avec bruit exponentielle	Gain
Expérience 1	38.61%	35.17%	8.9%
Expérience 2	38.26%	35.01%	8.49%
Expérience 3	33.47%	29.14%	12.93%

chapitre 5

Annexes

5.1 Quelques expressions sur la distribution de \mathbf{Z}

On note que $p(z_m, \dots, z_l)$, une distribuion marginale de $p(z)$ conserve la structure d'une PMC :

$$p(z_m, \dots, z_l) = \frac{p(z_m, z_{m+1}) \dots p(z_{l-1}, z_l)}{p(z_{m+1}) \dots p(z_{l-1})}$$

On peut alors décompose la structure d'une PMC de façon suivante:

$$\begin{aligned} p(z_m, \dots, z_l) &= p(z_m, \dots, z_a, \dots, z_l) \\ &= \frac{p(z_m, z_{m+1}) \dots p(z_{a-1}, z_a) p(z_a, z_{a+1}) \dots p(z_{l-1}, z_l)}{p(z_{m+1}) \dots p(z_{a-1}) p(z_a) p(z_{a+1}) \dots p(z_{l-1})} \\ &= p(z_m, \dots, z_a) \frac{1}{p(z_a)} p(z_a, \dots, z_l) \end{aligned}$$

Ensuite, on peut écrire la distribution de \mathbf{Z} des deux manières :

$$p(z) = p(z_1, \dots, z_N) = p(z_1|z_2) p(z_2, \dots, z_N)$$

et

$$p(z) = p(z_1, \dots, z_N) = p(z_1, \dots, z_{N-1}) p(z_N|z_{N-1})$$

Par récurrence, ceci nous amène à exprimer la distribution de \mathbf{Z} des deux façons suivantes :

$$\begin{aligned} p(z) &= p(z_1|z_2) \dots p(z_{N-2}|z_{N-1}) p(z_{n-1}, z_N) \\ &= p(z_{N-1}, z_N) \prod_{n=1}^{N-2} p(z_n|z_{n+1}) = p(z_N) \prod_{n=1}^{N-1} p(z_n|z_{n+1}) \end{aligned}$$

et

$$\begin{aligned} p(z) &= p(z_1, z_2) p(z_3|z_2) \dots p(z_N|z_{N-1}) \\ &= p(z_1, z_2) \prod_{n=2}^{N-1} p(z_{n+1}|z_n) = p(z_1) \prod_{n=1}^{N-1} p(z_{n+1}|z_n) \end{aligned}$$

5.2 Markovienté des chaînes $y|x$ et $x|y$

Les distributions $p(y|x)$ et $p(x|y)$ sont de markov. On étudie les deux cas séparément.

5.2.1 Markovienté de la chaîne $y|x$

On cherche à montrer que $p(y|x) = p^x(y)$ est une chaîne de markov, i.e. $p^x(y_{n+1}|y_1, \dots, y_n) = p^x(y_{n+1}|y_n)$.

$$\begin{aligned} p^x(y_{n+1}|y_1, \dots, y_n) &= \frac{p^x(y_1, \dots, y_n, y_{n+1})}{p^x(y_1, \dots, y_n)} \\ &= \frac{p(x, y_1, \dots, y_n, y_{n+1})}{p(x)} \frac{p(x)}{p(x, y_1, \dots, y_n, y_n)} \\ &= \frac{p(z_1, \dots, z_{n+1}, x_{n+2}, \dots, x_N)}{p(z_1, \dots, z_n, x_{n+1}, \dots, x_N)} \end{aligned}$$

En notant $dy^2 = dy_{n+2} \dots dy_N$ (mesure sur \mathbf{R}^{N-n-1}) et $dy^1 = dy_{n+1} \dots dy_N = dy_{n+1} dy^2$ (mesure sur \mathbf{R}^{N-n}) nous avons:

$$p^x(y_{n+1}|y_1, \dots, y_n) = \frac{\int \dots \int p(z_1, \dots, z_{n+1}, z_{n+2}, \dots, z_N) dy^2}{\int \dots \int p(z_1, \dots, z_n, z_{n+1}, \dots, z_N) dy^1}$$

On peut décomposer les distributions à l'intérieur des intégrales ($a = n + 1$ pour le numérateur, et $a = n$ pour le dénominateur), et extraire les termes qui sont indépendants des variables d'intégration:

$$\begin{aligned} p^x(y_{n+1}|y_1, \dots, y_n) &= \frac{p(z_1, \dots, z_{n+1}) p(z_n) \int \dots \int p(z_{n+1}, \dots, z_N) dy^2}{p(z_1, \dots, z_n) p(z_{n+1}) \int \dots \int p(z_n, \dots, z_N) dy^1} \\ &= \frac{p(z_n + 1|z_n, \dots, z_1) p(z_n, \dots, z_1) p(z_n) \int \dots \int p(z_{n+1}, z_{n+2}, \dots, z_N) dy^2}{p(z_n, \dots, z_1) p(z_{n+1}) \int \dots \int p(z_n, z_{n+1}, \dots, z_N) dy^1} \\ &= \frac{p(z_n + 1|z_n) p(z_n) \int \dots \int p(z_{n+1}, z_{n+2}, \dots, z_N) dy^2}{p(z_{n+1}) \int \dots \int p(z_n, z_{n+1}, \dots, z_N) dy^1} \\ &= p(z_n|z_{n+1}) \frac{\int \dots \int p(z_{n+1}, z_{n+2}, \dots, z_N) dy^2}{\int \dots \int p(z_n, z_{n+1}, \dots, z_N) dy^1} \end{aligned}$$

L'expression précédente ne dépend pas de y_1, \dots, y_{n-1} . Ainsi,

$$p^x(y_{n+1}|y_1, \dots, y_n) = a_y(y_n, y_{n+1}, x_n, \dots, x_N)$$

correspond à un terme d'une matrice de transition a_y d'une chaîne de markov.

5.2.2 Markovité de la chaîne $x|y$

Par calcul similaire au précédent, nous obtenons:

$$p^y(y_{n+1}|y_1, \dots, y_n) = p(z_n, z_{n+1}) \frac{\sum_{(x_{n+2}, \dots, x_N) \in \Omega^{N-n-1}} p(z_{n+1}, \dots, z_N)}{\sum_{(x_{n+2}, \dots, x_N) \in \Omega^{N-n}} p(z_n, \dots, z_N)}$$

L'expression précédente ne dépend que de x_n, x_{n+1} . Ainsi,

$$p^y(y_{n+1}|y_1, \dots, y_n) = a_x(x_n, x_{n+1}, y_n, \dots, y_N)$$

correspond à un terme d'une matrice de transition a_x d'une chaîne de markov.

chapitre 6

Perspectives

Dans ce travail, nous avons traité une modélisation originale par chaîne de markov couple, pouvant être utilisée dans des problèmes d'estimation des champs aléatoires inobservable. Dans le cadre de traitement d'image, cette modélisation permet, en particulier, d'effectuer des segmentations statistiques d'images bruitées par des bruits corrélés. Nous avons présenté quelques résultats de restauration par la méthode bayésienne MPM, en comparant avec le modèle classique (chaînes de markov cachés), les résultats trouvés sont encourageants. L'application du modèle proposé en segmentation d'images, bruitées par du bruit corrélé réelle appartenant à une famille des formes admissibles (par exemple le système de pearson), nécessiterait une méthode d'estimation de mélange généralisé. La recherche de telle méthode constitue une perspective naturelle pour la poursuite de ce travail.

Bibliographie

- [1] B.Benmiloud, W.Pieczynski, “ Estimation des paramètres dans les chaîne de markov cachées et segmentation d’images”,*traitement du signal*, Vol. 12,No. 5, 1995 pp. 433-454
- [2] L.E.Baum,T. Petrie,G. Soules,N. Weiss,“A maximization technique occuring in the statistical analysis of probabilistic functions of Markov chains”,*Ann, math.* 41, 1970, pp. 803-806.
- [3] B.Braathen, W,Pieczynski, O.Masson,“Global and local methods of unsupervised bayesian segmentation of image”,*Machine graphics and vision*,Vol. 2,No 1, 1993,pp. 39-52.
- [4] P.A.Devijver,M.Deksel,“Champs aléatoires de Pickard et modilisation d’images digitales”,*Traitement du Signale*, vol. 5, N 5, 1983, pp. 131-150
- [5] W.Pieczynski,A.-N.Tebbache, “Pairwise Markov random fields and segmentation of textured images”,*Machine graphics and vision*,Vol. 9,No 4, 2000,pp. 705-718.
- [6] W.Pieczynski,“Pairwise Markov chain and bayesian unsupervised fusion”,*Proc.3rd Int.Conf.on Information Fusion,FUSION 2000*,1 july, 10th-13th,Paris, France, MoD4-24 - MoD4-31.