

Chaînes de Markov triplets et Segmentation non supervisée de signaux

Pierre Lanchantin

GET/INT, département CITI

5 décembre 2006



- 1 Introduction
- 2 Modélisation de la loi jointe $Z = (X, Y)$
- 3 Chaînes de Markov M -non stationnaires cachées
- 4 Chaînes de Markov évidentielles cachées
- 5 Arbres de Markov cachés flous multispectraux
- 6 Conclusions et perspectives



- 1 Introduction
- 2 Modélisation de la loi jointe $Z = (X, Y)$
- 3 Chaînes de Markov M -non stationnaires cachées
- 4 Chaînes de Markov évidentielles cachées
- 5 Arbres de Markov cachés flous multispectraux
- 6 Conclusions et perspectives



Principe de la segmentation




Fig.: Image observée y



Principe de la segmentation




Fig.: Image observée y




Fig.: Image segmentée x

Principe de la segmentation

Créer une partition x du signal observé y en sous-ensembles appelés *régions* possédant certaines caractéristiques d'homogénéité.



Segmentation statistique bayésienne

Modélisation probabiliste

- $Y = (Y_n)_{n \in \mathcal{N}}$: le p.a observé prenant ses valeurs dans $\mathcal{Y}^{\mathcal{N}}$
- $X = (X_n)_{n \in \mathcal{N}}$: le p.a caché prenant ses valeurs dans $\mathcal{X}^{\mathcal{N}}$
- Liens statistiques modélisés par la loi de $Z = (X, Y)$: $p(z|\phi)$



Segmentation statistique bayésienne

Modélisation probabiliste

- $Y = (Y_n)_{n \in \mathcal{N}}$: le p.a observé prenant ses valeurs dans \mathcal{Y}^N
- $X = (X_n)_{n \in \mathcal{N}}$: le p.a caché prenant ses valeurs dans \mathcal{X}^N
- Liens statistiques modélisés par la loi de $Z = (X, Y)$: $p(z|\phi)$

- Objectif : **Estimer une réalisation \hat{x} à partir de y**

Estimateur du mode des marginales a posteriori (MPM)

Minimise le taux de sites mal classés : $\forall n \in \mathcal{N}$,

$$(\hat{x}_n)_{MPM} = \arg \max_{x'_n \in \mathcal{X}} p(x'_n | y, \phi)$$



Segmentation statistique bayésienne

Modélisation probabiliste

- $Y = (Y_n)_{n \in \mathcal{N}}$: le p.a observé prenant ses valeurs dans \mathcal{Y}^N
- $X = (X_n)_{n \in \mathcal{N}}$: le p.a caché prenant ses valeurs dans \mathcal{X}^N
- Liens statistiques modélisés par la loi de $Z = (X, Y)$: $p(z|\phi)$

- Objectif : **Estimer une réalisation \hat{x} à partir de y**

Estimateur du mode des marginales a posteriori (MPM)

Minimise le taux de sites mal classés : $\forall n \in \mathcal{N}$,

$$(\hat{x}_n)_{MPM} = \arg \max_{x'_n \in \mathcal{X}} p(x'_n | y, \phi)$$

- Les paramètres ϕ doivent être au préalable estimés (algorithme Espérance Maximisation (EM)) : segmentation non supervisée



Segmentation statistique bayésienne

Modélisation probabiliste

- $Y = (Y_n)_{n \in \mathcal{N}}$: le p.a observé prenant ses valeurs dans \mathcal{Y}^N
- $X = (X_n)_{n \in \mathcal{N}}$: le p.a caché prenant ses valeurs dans \mathcal{X}^N
- Liens statistiques modélisés par la loi de $Z = (X, Y)$: $p(z|\phi)$

- Objectif : **Estimer une réalisation \hat{x} à partir de y**

Estimateur du mode des marginales a posteriori (MPM)

Minimise le taux de sites mal classés : $\forall n \in \mathcal{N}$,

$$(\hat{x}_n)_{MPM} = \arg \max_{x'_n \in \mathcal{X}} p(x'_n | y, \phi)$$


- Les paramètres ϕ doivent être au préalable estimés (algorithme Espérance Maximisation (EM)) : segmentation non supervisée

Choix de la loi jointe $Z = (X, Y)$

- Définir la loi de Z tel que les $p(x_n | y, \phi) \forall n \in \mathcal{N}$ soient calculables
- Le modèle doit être suffisamment riche pour pouvoir modéliser un grand nombre de situations et de comportements


Conversion d'image 2D en processus monodimensionnel

- Conversion 2D \rightarrow 1D réalisée à partir d'un parcours de Hilbert-Peano



Conversion d'image 2D en processus monodimensionnel

- Conversion 2D \rightarrow 1D réalisée à partir d'un parcours de Hilbert-Peano



- Permet la mise en place d'algorithmes de calcul récursif des probabilités *a posteriori* nécessaires à l'estimation du processus caché.



Calcul des probabilités marginales *a posteriori* dans le cas général

Écritures factorisées des lois de $Z = (X, Y)$ et de $X|Y$

$$p(z) = p(z_1) \prod_{n=2}^N p(z_n | z_{1:n-1}) \text{ et } p(x|y) = p(x_1|y) \prod_{n=2}^N p(x_n | x_{1:n-1}, y)$$



Calcul des probabilités marginales *a posteriori* dans le cas général

Écritures factorisées des lois de $Z = (X, Y)$ et de $X|Y$

$$p(z) = p(z_1) \prod_{n=2}^N p(z_n | z_{1:n-1}) \text{ et } p(x|y) = p(x_1|y) \prod_{n=2}^N p(x_n | x_{1:n-1}, y)$$

Calcul des lois de transitions *a posteriori*

- Les lois de transitions *a posteriori* peuvent être écrites sous la forme :

$$p(x_n | x_{1:n-1}, y) \propto p(z_n | z_{1:n-1}) \beta_n(z_{1:n})$$



Calcul des probabilités marginales *a posteriori* dans le cas général

Écritures factorisées des lois de $Z = (X, Y)$ et de $X|Y$

$$p(z) = p(z_1) \prod_{n=2}^N p(z_n | z_{1:n-1}) \text{ et } p(x|y) = p(x_1|y) \prod_{n=2}^N p(x_n | x_{1:n-1}, y)$$

Calcul des lois de transitions *a posteriori*

- Les lois de transitions *a posteriori* peuvent être écrites sous la forme :

$$p(x_n | x_{1:n-1}, y) \propto p(z_n | z_{1:n-1}) \beta_n(z_{1:n})$$

- avec $\beta_n(z_{1:n}) = p(y_{n+1:N} | z_{1:n})$ exprimables récursivement $\forall n \in \mathcal{N} \setminus \{1\}$:

$$\beta_{n-1}(z_{1:n-1}) \propto \begin{cases} \sum_{x_n \in \mathcal{X}} p(z_n | z_{1:n-1}) & \text{si } n = N \\ \sum_{x_n \in \mathcal{X}} p(z_n | z_{1:n-1}) \beta_n(z_{1:n}) & \text{sinon} \end{cases}$$



Calcul des probabilités marginales *a posteriori* dans le cas général

Écritures factorisées des lois de $Z = (X, Y)$ et de $X|Y$

$$p(z) = p(z_1) \prod_{n=2}^N p(z_n | z_{1:n-1}) \text{ et } p(x|y) = p(x_1|y) \prod_{n=2}^N p(x_n | x_{1:n-1}, y)$$

Calcul des lois de transitions *a posteriori*

- Les lois de transitions *a posteriori* peuvent être écrites sous la forme :

$$p(x_n | x_{1:n-1}, y) \propto p(z_n | z_{1:n-1}) \beta_n(z_{1:n})$$

- avec $\beta_n(z_{1:n}) = p(y_{n+1:N} | z_{1:n})$ exprimables récursivement $\forall n \in \mathcal{N} \setminus \{1\}$:

$$\beta_{n-1}(z_{1:n-1}) \propto \begin{cases} \sum_{x_n \in \mathcal{X}} p(z_n | z_{1:n-1}) & \text{si } n = N \\ \sum_{x_n \in \mathcal{X}} p(z_n | z_{1:n-1}) \beta_n(z_{1:n}) & \text{sinon} \end{cases}$$

- Cette formulation dans le cas général sera valable pour l'ensemble des modèles présentés par la suite
- Permet la mise en place d'algorithmes de calcul récursif des $p(x_n | y) \forall n \in \mathcal{N}$ en deux passes sur le processus.

Algorithme de calcul des marginales *a posteriori*

◁ Passe arrière : pour $n = N \dots 2$

$$\beta_{n-1}(z_{1:n-1}) \propto \begin{cases} \sum_{x_n \in \mathcal{X}} p(z_n | z_{1:n-1}) & \text{si } n = N \\ \sum_{x_n \in \mathcal{X}} p(z_n | z_{1:n-1}) \beta_n(z_{1:n}) & \text{sinon} \end{cases}$$

$$p(x_n | x_{1:n-1}, y) \propto \begin{cases} p(z_n | z_{1:n-1}) & \text{si } n = N \\ p(z_n | z_{1:n-1}) \beta_n(z_{1:n}) & \text{sinon} \end{cases}$$



Algorithme de calcul des marginales *a posteriori*

◁ Passe arrière : pour $n = N \dots 2$

$$\beta_{n-1}(z_{1:n-1}) \propto \begin{cases} \sum_{x_n \in \mathcal{X}} p(z_n | z_{1:n-1}) & \text{si } n = N \\ \sum_{x_n \in \mathcal{X}} p(z_n | z_{1:n-1}) \beta_n(z_{1:n}) & \text{sinon} \end{cases}$$

$$p(x_n | x_{1:n-1}, y) \propto \begin{cases} p(z_n | z_{1:n-1}) & \text{si } n = N \\ p(z_n | z_{1:n-1}) \beta_n(z_{1:n}) & \text{sinon} \end{cases}$$

$n = 1$

$$p(x_1 | y) \propto p(z_1) \beta_1(z_1)$$



Algorithme de calcul des marginales *a posteriori*

◀ Passe arrière : pour $n = N \dots 2$

$$\beta_{n-1}(z_{1:n-1}) \propto \begin{cases} \sum_{x_n \in \mathcal{X}} p(z_n | z_{1:n-1}) & \text{si } n = N \\ \sum_{x_n \in \mathcal{X}} p(z_n | z_{1:n-1}) \beta_n(z_{1:n}) & \text{sinon} \end{cases}$$

$$p(x_n | x_{1:n-1}, y) \propto \begin{cases} p(z_n | z_{1:n-1}) & \text{si } n = N \\ p(z_n | z_{1:n-1}) \beta_n(z_{1:n}) & \text{sinon} \end{cases}$$

$n = 1$

$$p(x_1 | y) \propto p(z_1) \beta_1(z_1)$$

▷ Passe avant : pour $n = 2 \dots N$

$$p(x_{1:n} | y) = p(x_{1:n-1} | y) p(x_n | x_{1:n-1}, y)$$

$$p(x_n | y) = \sum_{x_{1:n-1} \in \mathcal{X}^{n-1}} p(x_{1:n} | y)$$



Algorithme de calcul des marginales *a posteriori*

◀ Passe arrière : pour $n = N \dots 2$

$$\beta_{n-1}(z_{1:n-1}) \propto \begin{cases} \sum_{x_n \in \mathcal{X}} p(z_n | z_{1:n-1}) & \text{si } n = N \\ \sum_{x_n \in \mathcal{X}} p(z_n | z_{1:n-1}) \beta_n(z_{1:n}) & \text{sinon} \end{cases}$$
$$p(x_n | x_{1:n-1}, y) \propto \begin{cases} p(z_n | z_{1:n-1}) & \text{si } n = N \\ p(z_n | z_{1:n-1}) \beta_n(z_{1:n}) & \text{sinon} \end{cases}$$

$n = 1$

$$p(x_1 | y) \propto p(z_1) \beta_1(z_1)$$

▷ Passe avant : pour $n = 2 \dots N$

$$p(x_{1:n} | y) = p(x_{1:n-1} | y) p(x_n | x_{1:n-1}, y)$$

$$p(x_n | y) = \sum_{x_{1:n-1} \in \mathcal{X}^{n-1}} p(x_{1:n} | y)$$


Hypothèses d'indépendance conditionnelle

- $\{p(z_n | z_{1:n-1})\}_{n=2:N}$ non calculables numériquement pour de grandes valeurs de N
- Introduction d'hypothèses d'indépendance conditionnelle.

Chaîne de Markov Cachée à Bruit Indépendant (CMC-BI)

Hypothèses d'indépendance conditionnelle

$$\begin{cases} X_{n+1} \perp\!\!\!\perp X_{1:n-1} | X_n \\ Y_n \perp\!\!\!\perp Z_{\mathcal{N} \setminus n} | X_n \end{cases} \Rightarrow p(z_n | z_{1:n-1}) = p(x_n | x_{n-1}) p(y_n | x_n)$$




- X est une chaîne de Markov d'ordre 1 (CM).



Chaîne de Markov Cachée à Bruit Indépendant (CMC-BI)

Hypothèses d'indépendance conditionnelle

$$\begin{cases} X_{n+1} \perp\!\!\!\perp X_{1:n-1} | X_n \\ Y_n \perp\!\!\!\perp Z_{\mathcal{N} \setminus n} | X_n \end{cases} \Rightarrow p(z_n | z_{1:n-1}) = p(x_n | x_{n-1}) p(y_n | x_n)$$




- X est une chaîne de Markov d'ordre 1 (CM).
- Z est une CM



Chaîne de Markov Cachée à Bruit Indépendant (CMC-BI)

Hypothèses d'indépendance conditionnelle

$$\begin{cases} X_{n+1} \perp\!\!\!\perp X_{1:n-1} | X_n \\ Y_n \perp\!\!\!\perp Z_{\mathcal{N} \setminus n} | X_n \end{cases} \Rightarrow p(z_n | z_{1:n-1}) = p(x_n | x_{n-1}) p(y_n | x_n)$$




- X est une chaîne de Markov d'ordre 1 (CM).
- Z est une CM
- $X|Y$ est une CM \rightarrow calcul numérique possible des marginales *a posteriori*



Chaîne de Markov Cachée à Bruit Indépendant (CMC-BI)

Hypothèses d'indépendance conditionnelle

$$\begin{cases} X_{n+1} \perp\!\!\!\perp X_{1:n-1} | X_n \\ Y_n \perp\!\!\!\perp Z_{\mathcal{N} \setminus n} | X_n \end{cases} \Rightarrow p(z_n | z_{1:n-1}) = p(x_n | x_{n-1}) p(y_n | x_n)$$




- X est une chaîne de Markov d'ordre 1 (CM).
- Z est une CM
- $X|Y$ est une CM \rightarrow calcul numérique possible des marginales *a posteriori*
- Modèle largement utilisé : parcimonie, grande robustesse.



Chaîne de Markov Couple (CMCo)

Hypothèse d'indépendance conditionnelle

$$Z_{n+1} \perp\!\!\!\perp Z_{1:n-1} | Z_n \Rightarrow p(z_n | z_{1:n-1}) = p(z_n | z_{n-1})$$




- On suppose directement la markovianité de Z



Chaîne de Markov Couple (CMCo)

Hypothèse d'indépendance conditionnelle

$$Z_{n+1} \perp\!\!\!\perp Z_{1:n-1} | Z_n \Rightarrow p(z_n | z_{1:n-1}) = p(z_n | z_{n-1})$$




- On suppose directement la markovianité de Z
- $X|Y$ et $Y|X$ sont des CM



Chaîne de Markov Couple (CMCo)

Hypothèse d'indépendance conditionnelle

$$Z_{n+1} \perp\!\!\!\perp Z_{1:n-1} | Z_n \Rightarrow p(z_n | z_{1:n-1}) = p(z_n | z_{n-1})$$




- On suppose directement la markovianité de Z
- $X|Y$ et $Y|X$ sont des CM
- X n'est plus nécessairement une CM : modèle plus général que CMC-BI : on connaît une condition nécessaire et suffisante mettant en lumière l'intérêt des CM Couples par rapport aux CMC-BI



Chaîne Couple Partiellement de Markov (CCPM)

Hypothèse d'indépendance conditionnelle

$$Z_{n+1} \perp\!\!\!\perp X_{1:n-1} | (Z_n, Y_{1:n-1}) \Rightarrow p(z_n | z_{1:n-1}) = p(z_n | z_{n-1}, y_{1:n-2})$$




- On obtient directement la markovianité de $X|Y$



Chaîne Couple Partiellement de Markov (CCPM)

Hypothèse d'indépendance conditionnelle

$$Z_{n+1} \perp\!\!\!\perp X_{1:n-1} | (Z_n, Y_{1:n-1}) \Rightarrow p(z_n | z_{1:n-1}) = p(z_n | z_{n-1}, y_{1:n-2})$$



- On obtient directement la markovianité de $X|Y$
- $Y|X$ n'est pas nécessairement une CM : prise en compte de bruits à corrélation longue tels que :

$$\lim_{\tau \rightarrow \infty} \tau^\alpha \rho(\tau) = c_\rho$$


où $\alpha \in]0, 1[$, $c_\rho > 0$ est une constante, et $\rho(\tau)$ est une fonction d'autocorrélation.



Chaîne de Markov Cachée à bruit à corrélation longue (CMC-BCL)

Cas particulier de CCPM gaussienne avec

$$\begin{cases} X_{n+1} \perp\!\!\!\perp X_{1:n-1} | X_n \\ Y_n \perp\!\!\!\perp X_{\mathcal{N} \setminus n} | X_n, Y_{1:n-1} \end{cases} \Rightarrow p(z_n | z_{1:n-1}) = p(x_n | x_{n-1}) p(y_{1:n} | x_n)$$



Restauration supervisée d'un processus à bruit à corrélation longue



Fig.: Initiale



Restauration supervisée d'un processus à bruit à corrélation longue



Fig.: Initiale




Fig.: Bruitée

- Processus gaussiens stationnaires centrées, variances=1
- Les autocorrélations sont les seuls paramètres discriminants



Restauration supervisée d'un processus à bruit à corrélation longue




Fig.: Initiale




Fig.: Bruitée




Fig.: Restaurée

- Processus gaussiens stationnaires centrées, variances=1
- Les autocorrélations sont les seuls paramètres discriminants

Autocorrélations

$$\rho(\tau) = |\tau + 1|^{-\alpha} \text{ avec } \tau = |j - i| \text{ avec } \alpha_{\omega_1} = 0.99, \alpha_{\omega_2} = 0.3, \alpha_{\omega_3} = 0.05, \alpha_{\omega_4} = 0.01$$

- MPM : taux d'erreur 6.9%





Fig.: Initiale

- Image à 2 classes
- On souhaite étudier la robustesse des modèles CMC-BI et CMC-BCL





Fig.: Initiale

- Image à 2 classes
- On souhaite étudier la robustesse des modèles CMC-BI et CMC-BCL
- On considère 2 types de bruits :



Segmentation non supervisée d'un processus à bruit à corrélation longue



Fig.: Initiale




Fig.: BI

- Image à 2 classes
- On souhaite étudier la robustesse des modèles CMC-BI et CMC-BCL
- On considère 2 types de bruits :
 - ▶ Bruit indépendant (BI) : variances (1,4) , moyennes (0,0)



Segmentation non supervisée d'un processus à bruit à corrélation longue



Fig.: Initiale




Fig.: BI




Fig.: BCL

- Image à 2 classes
- On souhaite étudier la robustesse des modèles CMC-BI et CMC-BCL
- On considère 2 types de bruits :
 - ▶ Bruit indépendant (BI) : variances (1,4) , moyennes (0,0)
 - ▶ Bruit à corrélation longue (BCL) : variances=1 et $\alpha_{\omega_1} = 0.99, \alpha_{\omega_2} = 0.2$



Segmentation non supervisée d'un processus à bruit à corrélation longue



Fig.: Initiale




Fig.: BI




Fig.: BCL

- Image à 2 classes
- On souhaite étudier la robustesse des modèles CMC-BI et CMC-BCL
- On considère 2 types de bruits :
 - ▶ Bruit indépendant (BI) : variances (1,4) , moyennes (0,0)
 - ▶ Bruit à corrélation longue (BCL) : variances=1 et $\alpha_{\omega_1} = 0.99, \alpha_{\omega_2} = 0.2$
- Paramètres estimés par EM initialisé par K-moyennes en considérant le cas CMC-BI et le cas CMC-BCL



Résultats de segmentations




Fig.: Image bruitée par BI



Résultats de segmentations




Fig.: Image bruitée par BI



Fig.: CMC-BI (5.3%)



Résultats de segmentations




Fig.: Image bruitée par BI



Fig.: CMC-BI (5.3%)



Fig.: CMC-BCL(5.3%)



Résultats de segmentations




Fig.: Image bruitée par BI



Fig.: CMC-BI (5.3%)




Fig.: CMC-BCL(5.3%)




Fig.: Image bruitée par BCL



Résultats de segmentations




Fig.: Image bruitée par BI



Fig.: CMC-BI (5.3%)



Fig.: CMC-BCL(5.3%)




Fig.: Image bruitée par BCL




Fig.: CMC-BI(27.6%)



Résultats de segmentations




Fig.: Image bruitée par BI

Fig.: CMC-BI (5.3%)

Fig.: CMC-BCL(5.3%)






Fig.: Image bruitée par BCL

Fig.: CMC-BI(27.6%)

Fig.: CMC-BCL(6.5%)

- 1 Introduction
- 2 Modélisation de la loi jointe $Z = (X, Y)$
- 3 Chaînes de Markov M -non stationnaires cachées**
- 4 Chaînes de Markov évidentielles cachées
- 5 Arbres de Markov cachés flous multispectraux
- 6 Conclusions et perspectives



Principes des modèles triplets partiellement de Markov

Principe des modèles triplets partiellement de Markov

Ajouter un processus auxiliaire caché U prenant ses valeurs dans \mathcal{U}^N discret tel que $V|Y$ soit une CM (avec $V = (X, U)$).




Fig.: CCPM




Fig.: CTPM



Principes des modèles triplets partiellement de Markov

Principe des modèles triplets partiellement de Markov

Ajouter un processus auxiliaire caché U prenant ses valeurs dans \mathcal{U}^N discret tel que $V|Y$ soit une CM (avec $V = (X, U)$).




Fig.: CCPM




Fig.: CTPM

- $V|y$ étant une CM, est il est possible de calculer les marginales $p(v_n|y)$ et d'en déduire

$$p(x_n|y) = \sum_{u_n \in \mathcal{U}} p(v_n|y) = \sum_{u_n \in \mathcal{U}} p(x_n, u_n|y)$$



Principes des modèles triplets partiellement de Markov

Principe des modèles triplets partiellement de Markov

Ajouter un processus auxiliaire caché U prenant ses valeurs dans \mathcal{U}^N discret tel que $V|Y$ soit une CM (avec $V = (X, U)$).




Fig.: CCPM




Fig.: CTPM

- $V|y$ étant une CM, est il est possible de calculer les marginales $p(v_n|y)$ et d'en déduire

$$p(x_n|y) = \sum_{u_n \in \mathcal{U}} p(v_n|y) = \sum_{u_n \in \mathcal{U}} p(x_n, u_n|y)$$

- On peut dès lors estimer le processus caché par MPM



Généralisations des modèles présentés

- Chacun des modèles présentés peut être généralisé



Généralisations des modèles présentés

- Chacun des modèles présentés peut être généralisé




Fig.: CMC-BI




Fig.: CMCouple-BI



Généralisations des modèles présentés

- Chacun des modèles présentés peut être généralisé




Fig.: CMC-BI




Fig.: CM Couple-BI




Fig.: CM Couple




Fig.: CMT



Problématique

- Lors de l'estimation des paramètres ϕ du modèle, $Z = (X, Y)$ est supposé stationnaire.
- Si Z n'est pas stationnaire, mauvaise estimation des paramètres, qui peut se traduire par une mauvaise segmentation.



Problématique


- Lors de l'estimation des paramètres ϕ du modèle, $Z = (X, Y)$ est supposé stationnaire.
- Si Z n'est pas stationnaire, mauvaise estimation des paramètres, qui peut se traduire par une mauvaise segmentation.

Approche proposée

- La non stationnarité de Z est modélisé par un processus auxiliaire U gouvernant les changement de régime du processus.
- On suppose que $T = (X, U, Y)$ est une CMT stationnaire
- $Z|U$ n'est pas stationnaire




Chaîne de Markov M -Non Stationnaire Cachée BI



- CMT particulière où le processus $V = (X, U)$ est une CM stationnaire et la loi $p(y|v)$ de Y conditionnelle à V vérifie : $p(y|v) = p(y|x) = \prod_{n=1}^N p(y_n|x_n)$.



Chaîne de Markov M -Non Stationnaire Cachée BI



- CMT particulière où le processus $V = (X, U)$ est une CM stationnaire et la loi $p(y|v)$ de Y conditionnelle à V vérifie : $p(y|v) = p(y|x) = \prod_{n=1}^N p(y_n|x_n)$.
- Estimation des paramètres effectuée par Stochastique EM initialisé par un algorithme de K-moyennes
- Le modèle CM M -NSC-BI sera dénoté CMT dans les expérimentations



Segmentation de processus synthétiques

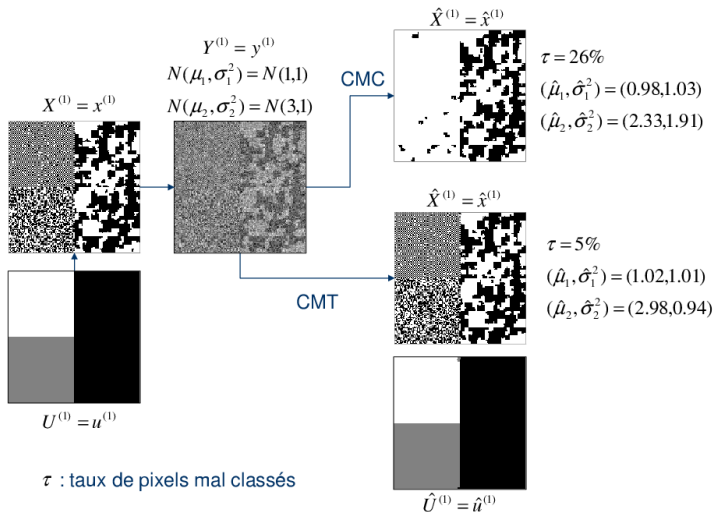




Fig.: Image initiale cachée

- Image binaire
- La peau présente des bandes de tailles et d'espacements variés





Fig.: Image initiale cachée



Fig.: Image bruitée

- Image binaire
- La peau présente des bandes de tailles et d'espacements variés
- y est échantillonné de la même manière que dans la première expérimentation



Résultats de segmentation



Fig.: CMC-BI(7.2%)



Résultats de segmentation



Fig.: CMC-BI(7.2%)



Fig.: CMT(3.5%)

- Amélioration du résultat de la segmentation



Résultats de segmentation



Fig.: CMC-BI(7.2%)



Fig.: CMT(3.5%)




Fig.: $\hat{U} = \hat{u}$

- Amélioration du résultat de la segmentation
- Visualisation des différentes zones sur le corps du zèbre en visualisant l'estimation de $\hat{U} = \hat{u}$



Segmentation de textures de Brodatz




Fig.: Processus auxiliaire initial



Segmentation de textures de Brodatz




Fig.: Processus auxiliaire initial




Fig.: Image observée simulée

- y construit par rapport à un processus u en considérant 3 textures différentes de Brodatz



Segmentation de textures de Brodatz




Fig.: Processus auxiliaire initial




Fig.: Image observée simulée

- y construit par rapport à un processus u en considérant 3 textures différentes de Brodatz
- CMT avec 3 classes auxiliaires et 4 classes réelles






Fig.: processus auxiliaire estimé,
 $\hat{U} = \hat{u}$

- $\hat{U} = \hat{u}$ est bien estimé avec $\tau = 2.5\%$
- Les CMT peuvent être utiles dans le contexte de la segmentation non supervisée de textures






Fig.: processus auxiliaire estimé,
 $\hat{U} = \hat{u}$




Fig.: processus caché estimé \hat{X}

- $\hat{U} = \hat{u}$ est bien estimé avec $\tau = 2.5\%$
- Les CMT peuvent être utiles dans le contexte de la segmentation non supervisée de textures



Segmentation d'une image réelle



Segmentation d'une image réelle



Bayesian Information Criteria (BIC)

$$BIC = -2 \log L(y) + 2k \log N$$

$L(y)$: vraisemblance

k : nombre de paramètres non nuls

N : nombre d'échantillons



Valeurs du BIC

Nombre d'états réels	Nombre d'états auxiliaires	LL	Nombre de paramètres	BIC
2	1	-338750	7	677580
2	2	-337460	13	675060
2	3	-337360	23	674980
3	1	-334310	14	668780
3	2	-332070	27	664440
3	3	-331760	55	664130
4	1	-333020	21	666280
4	2	-331210	43	662610



Segmentation d'image réelle

4 classes réelles

1 état auxiliaire

BIC=666280



4 classes réelles

2 états auxiliaires

BIC= 662610



- 1 Introduction
- 2 Modélisation de la loi jointe $Z = (X, Y)$
- 3 Chaînes de Markov M -non stationnaires cachées
- 4 Chaînes de Markov évidentielles cachées**
- 5 Arbres de Markov cachés flous multispectraux
- 6 Conclusions et perspectives



La théorie de L'évidence

- Introduite par Dempster puis reformulée par Shafer



La théorie de L'évidence

- Introduite par Dempster puis reformulée par Shafer
- Présentée comme une généralisation de la théorie de Bayes au traitement de l'incertain



La théorie de L'évidence

- Introduite par Dempster puis reformulée par Shafer
- Présentée comme une généralisation de la théorie de Bayes au traitement de l'incertain

Définition

Une fonction de masse élémentaire m est une fonction de $P(\mathcal{X})$ dans R^+ vérifiant

$$\begin{cases} m(\emptyset) = 0 \\ \sum_{A \in P(\mathcal{X})} m(A) = 1 \end{cases}$$



- Introduite par Dempster puis reformulée par Shafer
- Présentée comme une généralisation de la théorie de Bayes au traitement de l'incertain

Définition

Une fonction de masse élémentaire m est une fonction de $P(\mathcal{X})$ dans R^+ vérifiant

$$\begin{cases} m(\emptyset) = 0 \\ \sum_{A \in P(\mathcal{X})} m(A) = 1 \end{cases}$$

- Possibilité d'affecter une masse aux hypothèses composites : modélisation plus flexible permettant de représenter l'incomplétude, l'ambiguïté, l'ignorance



- Introduite par Dempster puis reformulée par Shafer
- Présentée comme une généralisation de la théorie de Bayes au traitement de l'incertain

Définition

Une fonction de masse élémentaire m est une fonction de $P(\mathcal{X})$ dans R^+ vérifiant

$$\begin{cases} m(\emptyset) = 0 \\ \sum_{A \in P(\mathcal{X})} m(A) = 1 \end{cases}$$

- Possibilité d'affecter une masse aux hypothèses composites : modélisation plus flexible permettant de représenter l'incomplétude, l'ambiguïté, l'ignorance
- Ignorance totale : $m(\mathcal{X}) = 1$ et $m(A) = 0, \forall A \subset \mathcal{X}, A \neq \mathcal{X}$



- Introduite par Dempster puis reformulée par Shafer
- Présentée comme une généralisation de la théorie de Bayes au traitement de l'incertain

Définition

Une fonction de masse élémentaire m est une fonction de $P(\mathcal{X})$ dans R^+ vérifiant

$$\begin{cases} m(\emptyset) = 0 \\ \sum_{A \in P(\mathcal{X})} m(A) = 1 \end{cases}$$

- Possibilité d'affecter une masse aux hypothèses composites : modélisation plus flexible permettant de représenter l'incomplétude, l'ambiguïté, l'ignorance
- Ignorance totale : $m(\mathcal{X}) = 1$ et $m(A) = 0, \forall A \subset \mathcal{X}, A \neq \mathcal{X}$
- Jeu de masses bayésien : masses réparties uniquement sur les hypothèses singletons : probabilité



Fusion de Dempster-Shafer (Fusion DS)

Masses m_1, \dots, m_l fournies par plusieurs sources d'information



Fusion de Dempster-Shafer (Fusion DS)

Masses m_1, \dots, m_l fournies par plusieurs sources d'information

Définition

$$m(A) = (m_1 \oplus m_2 \oplus \dots \oplus m_l)(A) \propto \sum_{B_1 \cap \dots \cap B_l = A} m_1(B_1) m_2(B_2) \dots m_l(B_l)$$



Fusion de Dempster-Shafer (Fusion DS)

Masses m_1, \dots, m_l fournies par plusieurs sources d'information

Définition

$$m(A) = (m_1 \oplus m_2 \oplus \dots \oplus m_l)(A) \propto \sum_{B_1 \cap \dots \cap B_l = A} m_1(B_1) m_2(B_2) \dots m_l(B_l)$$

Propriété

Lorsque au moins l'une des masses impliquées dans la combinaison est bayésienne, le résultat de la combinaison est une masse bayésienne.



Fusion de Dempster-Shafer (Fusion DS)

Masses m_1, \dots, m_l fournies par plusieurs sources d'information

Définition

$$m(A) = (m_1 \oplus m_2 \oplus \dots \oplus m_l)(A) \propto \sum_{B_1 \cap \dots \cap B_l = A} m_1(B_1)m_2(B_2)\dots m_l(B_l)$$

Propriété

Lorsque au moins l'une des masses impliquées dans la combinaison est bayésienne, le résultat de la combinaison est une masse bayésienne.

Calcul de la loi *a posteriori* : cas particulier de Fusion DS.

Soit $m(x) = p(x)$, $x \in \mathcal{X}$, et $q(x) \propto p(y|x)$, $x \in \mathcal{X}$, ($y \in \mathcal{Y}$ est fixé).

$$(m \oplus q)(x) = \frac{m(x)q(x)}{\sum_{x' \in \mathcal{X}} m(x')q(x')} = \frac{p(x)p(y|x)}{\sum_{x' \in \mathcal{X}} p(x')p(y|x')} = p(x|y)$$



Fusion de Dempster-Shafer (Fusion DS)

Masses m_1, \dots, m_l fournies par plusieurs sources d'information

Définition

$$m(A) = (m_1 \oplus m_2 \oplus \dots \oplus m_l)(A) \propto \sum_{B_1 \cap \dots \cap B_l = A} m_1(B_1)m_2(B_2)\dots m_l(B_l)$$

Propriété

Lorsque au moins l'une des masses impliquées dans la combinaison est bayésienne, le résultat de la combinaison est une masse bayésienne.

Calcul de la loi *a posteriori* : cas particulier de Fusion DS.

Soit $m(x) = p(x)$, $x \in \mathcal{X}$, et $q(x) \propto p(y|x)$, $x \in \mathcal{X}$, ($y \in \mathcal{Y}$ est fixé).

$$(m \oplus q)(x) = \frac{m(x)q(x)}{\sum_{x' \in \mathcal{X}} m(x')q(x')} = \frac{p(x)p(y|x)}{\sum_{x' \in \mathcal{X}} p(x')p(y|x')} = p(x|y)$$

Généralisation du calcul de la loi *a posteriori*

Remplacement de l'une des masses par une masse évidentielle $m(u)$, $u \in \mathcal{P}(\mathcal{X})$.

Affaiblissement

Probabilité est connue avec imprécision : remplacement de la probabilité non fiable $p(x)$ par la masse $m(u)$ définie par :

$$m(u) = \alpha p(x), \quad m(\mathcal{X}) = 1 - \alpha$$

- $\alpha \in [0, 1]$ étant le coefficient d'affaiblissement (ou de fiabilité)



Affaiblissement

Probabilité est connue avec imprécision : remplacement de la probabilité non fiable $p(x)$ par la masse $m(u)$ définie par :

$$m(u) = \alpha p(x), \quad m(\mathcal{X}) = 1 - \alpha$$

- $\alpha \in [0, 1]$ étant le coefficient d'affaiblissement (ou de fiabilité)
- Permet de prendre en compte la fiabilité relative des sources d'informations.



Affaiblissement

Probabilité est connue avec imprécision : remplacement de la probabilité non fiable $p(x)$ par la masse $m(u)$ définie par :

$$m(u) = \alpha p(x), \quad m(\mathcal{X}) = 1 - \alpha$$

- $\alpha \in [0, 1]$ étant le coefficient d'affaiblissement (ou de fiabilité)
- Permet de prendre en compte la fiabilité relative des sources d'informations.
- L'opération d'affaiblissement a pour effet de pondérer l'importance d'une source d'information lors de sa combinaison avec d'autres sources.



Affaiblissement

Probabilité est connue avec imprécision : remplacement de la probabilité non fiable $p(x)$ par la masse $m(u)$ définie par :

$$m(u) = \alpha p(x), \quad m(\mathcal{X}) = 1 - \alpha$$

- $\alpha \in [0, 1]$ étant le coefficient d'affaiblissement (ou de fiabilité)
- Permet de prendre en compte la fiabilité relative des sources d'informations.
- L'opération d'affaiblissement a pour effet de pondérer l'importance d'une source d'information lors de sa combinaison avec d'autres sources.

Objectif

Affaiblir automatiquement en chaque site $n \in \mathcal{N}$ la source d'information *a priori* (information contextuelle) lorsque celle-ci est connue avec insuffisamment de précision.



Chaîne de Markov Evidentielle (CME)

Une fonction de masse m définie sur $\mathcal{P}(\mathcal{X}^N)$ est une chaîne de Markov évidentielle (CME) si elle est nulle en dehors de $[\mathcal{P}(\mathcal{X})]^N$ et si

$$m(u) = m(u_1, \dots, u_N) = m(u_1)m(u_2|u_1) \dots m(u_N|u_{N-1})$$



Chaîne de Markov Evidentielle (CME)

Une fonction de masse m définie sur $\mathcal{P}(\mathcal{X}^N)$ est une chaîne de Markov évidentielle (CME) si elle est nulle en dehors de $[\mathcal{P}(\mathcal{X})]^N$ et si

$$m(u) = m(u_1, \dots, u_N) = m(u_1)m(u_2|u_1) \dots m(u_N|u_{N-1})$$

- Dans CMC-BI, la CM X est remplacée par une CME U et

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



Chaîne de Markov Evidentielle (CME)

Une fonction de masse m définie sur $\mathcal{P}(\mathcal{X}^N)$ est une chaîne de Markov évidentielle (CME) si elle est nulle en dehors de $[\mathcal{P}(\mathcal{X})]^N$ et si

$$m(u) = m(u_1, \dots, u_N) = m(u_1)m(u_2|u_1) \dots m(u_N|u_{N-1})$$

- Dans CMC-BI, la CM X est remplacée par une CME U et $q(x) \propto p(y|x) = \prod_{n=1}^N p(y_n|x_n)$
- La fusion s'écrit : $(m \oplus q)(x) \propto \sum_{u \in [\mathcal{P}(\mathcal{X})]^N} 1_{[x \in u]} m(u) q(x)$



Chaîne de Markov Evidentielle Cachée à Bruit Indépendant (CMEC-BI)

Chaîne de Markov Evidentielle (CME)

Une fonction de masse m définie sur $\mathcal{P}(\mathcal{X}^N)$ est une chaîne de Markov évidentielle (CME) si elle est nulle en dehors de $[\mathcal{P}(\mathcal{X})]^N$ et si

$$m(u) = m(u_1, \dots, u_N) = m(u_1)m(u_2|u_1) \dots m(u_N|u_{N-1})$$

- Dans CMC-BI, la CM X est remplacée par une CME U et

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

- La fusion s'écrit : $(m \oplus q)(x) \propto \sum_{u \in [\mathcal{P}(\mathcal{X})]^N} 1_{[x \in u]} m(u) q(x)$

La fusion détruit la markovianité : impossibilité de calculer directement les marginales *a posteriori*.



Chaîne de Markov Evidentielle Cachée à Bruit Indépendant (CMEC-BI)

Chaîne de Markov Evidentielle (CME)

Une fonction de masse m définie sur $\mathcal{P}(\mathcal{X}^N)$ est une chaîne de Markov évidentielle (CME) si elle est nulle en dehors de $[\mathcal{P}(\mathcal{X})]^N$ et si

$$m(u) = m(u_1, \dots, u_N) = m(u_1)m(u_2|u_1) \dots m(u_N|u_{N-1})$$

- Dans CMC-BI, la CM X est remplacée par une CME U et
$$q(x) \propto p(y|x) = \prod_{n=1}^N p(y_n|x_n)$$
- La fusion s'écrit : $(m \oplus q)(x) \propto \sum_{u \in [\mathcal{P}(\mathcal{X})]^N} 1_{[x \in u]} m(u) q(x)$

La fusion détruit la markovianité : impossibilité de calculer directement les marginales *a posteriori*.

CMEC-BI

- $(m \oplus q)(x)$ est la marginale d'une CMT particulière appelée CMEC-BI avec $p(v) \propto 1_{[x \in u]} m(u)$ et $\mathcal{U} = \mathcal{P}(\mathcal{X})$
- Les probabilités marginales *a posteriori* peuvent être calculées en considérant la CMT avant fusion.
- L'affaiblissement est estimé automatiquement par EM initialisé par k-moyennes.

Restauration d'une CM Non Stationnaire




Fig.: De haut en bas : (a) processus caché, (b) processus observé, (c) résultat de la restauration non supervisée de la CMC, (d) variation de l'affaiblissement représentée par $1 - p(\mathcal{X}|y)$, (e) résultat de la segmentation non supervisée de la CMEC-BI



Segmentation d'image : comparaison CMC-BI/CMEC-BI




Fig.: Image originale



Segmentation d'image : comparaison CMC-BI/CMEC-BI




Fig.: Image originale



Fig.: Image bruitée $\mathcal{N}(0, 1)$, $\mathcal{N}(2, 1)$



Segmentation d'image : comparaison CMC-BI/CMEC-BI



Fig.: CMC-BI(14.6%)



Segmentation d'image : comparaison CMC-BI/CMEC-BI



Fig.: CMC-BI(14.6%)



Fig.: CMEC-BI(5.0%)



Segmentation d'image : comparaison CMC-BI/CMEC-BI




Fig.: Coefficient d'affaiblissement



Segmentation d'image : comparaison CMC-BI/CMEC-BI




Fig.: Coefficient d'affaiblissement

- L'affaiblissement est plus fort pour les zones comprenant des détails fins



CMM -NSC-BI

- On considère différentes zones de stationnarités correspondant chacune à un état auxiliaire.



CMM-NSC-BI

- On considère différentes zones de stationnarités correspondant chacune à un état auxiliaire.

CMEC-BI

- L'influence de la loi *a priori* et donc de l'information contextuelle est affaiblie par rapport à l'information issue des observations dans les zones présentant des détails fins.
- Le modèle CMEC-BI permet donc d'adapter automatiquement l'influence de l'information contextuelle en fonction des caractéristiques de l'image.



- 1 Introduction
- 2 Modélisation de la loi jointe $Z = (X, Y)$
- 3 Chaînes de Markov M -non stationnaires cachées
- 4 Chaînes de Markov évidentielles cachées
- 5 Arbres de Markov cachés flous multispectraux**
- 6 Conclusions et perspectives



Caractéristique des images astronomiques

Multirésolutions

Images acquises à différentes résolutions :



Caractéristique des images astronomiques

Multirésolutions

Images acquises à différentes résolutions :

Multispectrales

Différentes longueurs d'ondes :



Caractéristique des images astronomiques

Multirésolutions

Images acquises à différentes résolutions :

Multispectrales

Différentes longueurs d'ondes :

Structures diffuses

Nuages, poussières :



Caractéristique des images astronomiques

Multirésolutions

Images acquises à différentes résolutions : **Arbre de Markov caché**

Multispectrales

Différentes longueurs d'ondes :

Structures diffuses

Nuages, poussières :



Caractéristique des images astronomiques

Multirésolutions

Images acquises à différentes résolutions : **Arbre de Markov caché**

Multispectrales

Différentes longueurs d'ondes : **Loi d'observation multivariée**

Structures diffuses

Nuages, poussières :



Caractéristique des images astronomiques

Multirésolutions

Images acquises à différentes résolutions : **Arbre de Markov caché**

Multispectrales

Différentes longueurs d'ondes : **Loi d'observation multivariée**

Structures diffuses

Nuages, poussières : **Modélisation floue**



Approche floue

Pour $\mathcal{X} = \{0, 1\}$, existence de sites contenant un mélange des deux classes sans qu'aucune des deux classes ne s'impose.

- $x_s = 0$ si s appartient à la classe "0"
- $x_s = 1$ si s appartient à la classe "1"
- $x_s = \varepsilon_s \in]0, 1[$ si la proportion de la classe "0" dans le site est $\varepsilon_s \in]0, 1[$.

On obtient une appartenance "floue" du site



Approche floue

Pour $\mathcal{X} = \{0, 1\}$, existence de sites contenant un mélange des deux classes sans qu'aucune des deux classes ne s'impose.

- $x_s = 0$ si s appartient à la classe "0"
- $x_s = 1$ si s appartient à la classe "1"
- $x_s = \varepsilon_s \in]0, 1[$ si la proportion de la classe "0" dans le site est $\varepsilon_s \in]0, 1[$.

On obtient une appartenance "floue" du site

Loi de X_s

Donnée par une densité $p(x_s)$ par rapport à une mesure ν incluant des composantes discrètes et continues

$$\nu = \delta_0 + \delta_1 + \mu$$

et

$$p(0) + p(1) + \int_0^1 p(\varepsilon) d\varepsilon = 1$$



Notations

\mathcal{S} : ensemble fini d'indices

$\mathcal{S}^1, \dots, \mathcal{S}^N$: partition de \mathcal{S}

\mathcal{S}^1 : racine de l'arbre

s^- : parent d'un site s

s^+ : enfants de s

s^{++} : ensemble des descendants de s



Notations

\mathcal{S} : ensemble fini d'indices

$\mathcal{S}^1, \dots, \mathcal{S}^N$: partition de \mathcal{S}

\mathcal{S}^1 : racine de l'arbre

s^- : parent d'un site s

s^+ : enfants de s

s^{++} : ensemble des descendants de s

- Nous considérons à présent un arbre de Markov $X = (X)_{s \in \mathcal{S}}$ avec $X_s \in [0, 1]$



Notations

\mathcal{S} : ensemble fini d'indices

$\mathcal{S}^1, \dots, \mathcal{S}^N$: partition de \mathcal{S}

\mathcal{S}^1 : racine de l'arbre

s^- : parent d'un site s

s^+ : enfants de s

s^{++} : ensemble des descendants de s

- Nous considérons à présent un arbre de Markov $X = (X)_{s \in \mathcal{S}}$ avec $X_s \in [0, 1]$
- La loi d'un arbre de Markov flou X par rapport à la mesure $\nu^{\mathcal{S}}$ est définie par

$$p(x) = p(x_1) \prod_{n=2}^N \prod_{s \in \mathcal{S}^n} p(x_s | x_{s^-})$$



Arbre de Markov flou multispectral

- La distribution de $Y_s = (Y_s^{(1)}, Y_s^{(2)}, \dots, Y_s^{(D)})$ conditionnellement à x_s est modélisée par une densité gaussienne multivariée $p(y_s | x_s)$



Arbre de Markov flou multispectral

- La distribution de $Y_s = (Y_s^{(1)}, Y_s^{(2)}, \dots, Y_s^{(D)})$ conditionnellement à x_s est modélisée par une densité gaussienne multivariée $p(y_s|x_s)$
- Le vecteur moyenne μ_{ε_s} et la matrice Γ_{ε_s} associées au site flou $X_s = \varepsilon_s$ dépendent linéairement des paramètres durs $(\mu_0, \mu_1), (\Gamma_0, \Gamma_1)$:

$$\begin{cases} \mu_{\varepsilon_s} = (1 - \varepsilon_s)\mu_0 + \varepsilon_s\mu_1 \\ \Gamma_{\varepsilon_s} = (1 - \varepsilon_s)^2\Gamma_0 + \varepsilon_s^2\Gamma_1 \end{cases}$$



Arbre de Markov flou multispectral

- La distribution de $Y_s = (Y_s^{(1)}, Y_s^{(2)}, \dots, Y_s^{(D)})$ conditionnellement à x_s est modélisée par une densité gaussienne multivariée $p(y_s|x_s)$
- Le vecteur moyenne μ_{ε_s} et la matrice Γ_{ε_s} associées au site flou $X_s = \varepsilon_s$ dépendent linéairement des paramètres durs $(\mu_0, \mu_1), (\Gamma_0, \Gamma_1)$:

$$\begin{cases} \mu_{\varepsilon_s} = (1 - \varepsilon_s)\mu_0 + \varepsilon_s\mu_1 \\ \Gamma_{\varepsilon_s} = (1 - \varepsilon_s)^2\Gamma_0 + \varepsilon_s^2\Gamma_1 \end{cases}$$

Loi de Z

$$p(z) = p(x_1)p(y_1|x_1) \prod_{n=2}^N \prod_{s \in S^n} p(x_s|x_{s-})p(y_s|x_s)$$



Calcul des marginales a posteriori

Passage montante : pour $n = N \dots 2, \forall s \in \mathcal{S}^n$

$$\beta_{s,s-}(z_{s-}) \propto \begin{cases} \int_{x_s \in \mathcal{X}} p(x_s | x_{s-}) p(y_s | x_s) d\nu(x_s) & \text{si } n = N \\ \int_{x_s \in \mathcal{X}} p(x_s | x_{s-}) p(y_s | x_s) \prod_{t \in s^+} \beta_{t,s}(z_s) d\nu(x_s) & \text{sinon} \end{cases}$$
$$p(x_s | x_{s-}, y) \propto \begin{cases} p(x_s | x_{s-}) p(y_s | x_s) & \text{si } n = N \\ p(x_s | x_{s-}) p(y_s | x_s) \prod_{t \in s^+} \beta_{t,s}(z_s) & \text{sinon} \end{cases}$$



Calcul des marginales a posteriori

Passage montante : pour $n = N \dots 2, \forall s \in \mathcal{S}^n$

$$\beta_{s,s-}(z_{s-}) \propto \begin{cases} \int_{x_s \in \mathcal{X}} p(x_s | x_{s-}) p(y_s | x_s) d\nu(x_s) & \text{si } n = N \\ \int_{x_s \in \mathcal{X}} p(x_s | x_{s-}) p(y_s | x_s) \prod_{t \in s^+} \beta_{t,s}(z_s) d\nu(x_s) & \text{sinon} \end{cases}$$
$$p(x_s | x_{s-}, y) \propto \begin{cases} p(x_s | x_{s-}) p(y_s | x_s) & \text{si } n = N \\ p(x_s | x_{s-}) p(y_s | x_s) \prod_{t \in s^+} \beta_{t,s}(z_s) & \text{sinon} \end{cases}$$

Racine

$$p(x_1 | y) \propto p(z_1) \prod_{t \in 1^+} \beta_{t,1}(x_1)$$



Calcul des marginales a posteriori

Passage montante : pour $n = N \dots 2, \forall s \in \mathcal{S}^n$

$$\beta_{s,s-}(z_{s-}) \propto \begin{cases} \int_{x_s \in \mathcal{X}} p(x_s | x_{s-}) p(y_s | x_s) d\nu(x_s) & \text{si } n = N \\ \int_{x_s \in \mathcal{X}} p(x_s | x_{s-}) p(y_s | x_s) \prod_{t \in s^+} \beta_{t,s}(z_s) d\nu(x_s) & \text{sinon} \end{cases}$$
$$p(x_s | x_{s-}, y) \propto \begin{cases} p(x_s | x_{s-}) p(y_s | x_s) & \text{si } n = N \\ p(x_s | x_{s-}) p(y_s | x_s) \prod_{t \in s^+} \beta_{t,s}(z_s) & \text{sinon} \end{cases}$$

Racine

$$p(x_1 | y) \propto p(z_1) \prod_{t \in 1^+} \beta_{t,1}(x_1)$$

pour $n = 2 \dots N, \forall s \in \mathcal{S}^n$

$$p(x_s, x_{s-} | y) = p(x_{s-} | y) p(x_s | x_{s-}, y)$$
$$p(x_s | y) = \int_{x_{s-} \in \mathcal{X}} p(x_s, x_{s-} | y) d\nu(x_{s-})$$



Calcul des marginales a posteriori

Passage montante : pour $n = N \dots 2, \forall s \in \mathcal{S}^n$

$$\beta_{s,s-}(z_{s-}) \propto \begin{cases} \int_{x_s \in \mathcal{X}} p(x_s | x_{s-}) p(y_s | x_s) d\nu(x_s) & \text{si } n = N \\ \int_{x_s \in \mathcal{X}} p(x_s | x_{s-}) p(y_s | x_s) \prod_{t \in \mathcal{S}^+} \beta_{t,s}(z_s) d\nu(x_s) & \text{sinon} \end{cases}$$
$$p(x_s | x_{s-}, y) \propto \begin{cases} p(x_s | x_{s-}) p(y_s | x_s) & \text{si } n = N \\ p(x_s | x_{s-}) p(y_s | x_s) \prod_{t \in \mathcal{S}^+} \beta_{t,s}(z_s) & \text{sinon} \end{cases}$$

Racine

$$p(x_1 | y) \propto p(z_1) \prod_{t \in \mathcal{I}^+} \beta_{t,1}(x_1)$$

pour $n = 2 \dots N, \forall s \in \mathcal{S}^n$

$$p(x_s, x_{s-} | y) = p(x_{s-} | y) p(x_s | x_{s-}, y)$$
$$p(x_s | y) = \int_{x_{s-} \in \mathcal{X}} p(x_s, x_{s-} | y) d\nu(x_{s-})$$

- Approximation numérique : Intervalle $[0, 1]$ divisé en F sous-intervalles flous $[a_0 = 0, a_1 = \frac{1}{F}], [a_1 = \frac{1}{F}, a_2 = \frac{2}{F}], \dots, [a_{F-1} = \frac{F-1}{F}, a_F = 1]$.



Image de synthèse

- Image de synthèse trispectrale. La "vérité-terrain" est un champ de Markov flou à 10 niveaux. le taux de flou = 53.96%





Image de synthèse

- Image de synthèse trispectrale. La "vérité-terrain" est un champ de Markov flou à 10 niveaux. le taux de flou = 53.96%



- Les paramètres sont estimés par un algorithme EM initialisé par k-moyennes.



Résultat de la segmentation




Fig.: 1ere bande




Fig.: 2e bande



Fig.: 3e bande



Résultat de la segmentation




Fig.: 1ere bande




Fig.: 2e bande



Fig.: 3e bande




Fig.: 8 niveaux de flou et 2 classes dures, 4,58% d'erreur, 44.96% de flou



Résultat de la segmentation




Fig.: 1ere bande




Fig.: 2e bande



Fig.: 3e bande



Fig.: 8 niveaux de flou et 2 classes dures, 4,58% d'erreur, 44.96% de flou

- L'algorithme restitue correctement l'image d'origine avec un taux d'erreur de 4.58%



Résultat de la segmentation




Fig.: 1ere bande




Fig.: 2e bande



Fig.: 3e bande



Fig.: 8 niveaux de flou et 2 classes dures, 4,58% d'erreur, 44.96% de flou

- L'algorithme restitue correctement l'image d'origine avec un taux d'erreur de 4.58%
- L'information floue est correctement restituée 44.96% vs 53.96%



Image astronomique




Fig.: $60\mu\text{m}$




Fig.: $100\mu\text{m}$



Fig.: $170\mu\text{m}$

- Objectif : mettre en évidence la structure filamentaire de poussière interstellaire gênant l'observation de champs de haute altitude de notre galaxie



Image astronomique




Fig.: $60\mu\text{m}$




Fig.: $100\mu\text{m}$



Fig.: $170\mu\text{m}$




Fig.: 8 niveaux de flou et 2 classes dures

- Objectif : mettre en évidence la structure filamentaire de poussière interstellaire gênant l'observation de champs de haute altitude de notre galaxie
- Ne permet pas de mettre en évidence la structure filamentaire de la poussière interstellaire
- Restitue une gradation floue entre les régions homogènes



- 1 Introduction
- 2 Modélisation de la loi jointe $Z = (X, Y)$
- 3 Chaînes de Markov M -non stationnaires cachées
- 4 Chaînes de Markov évidentielles cachées
- 5 Arbres de Markov cachés flous multispectraux
- 6 Conclusions et perspectives**



Contributions



Contributions

- Algorithme d'estimation EM dans le cas des chaînes de Markov Couples.



Contributions

- Algorithme d'estimation EM dans le cas des chaînes de Markov Couples.
- Etude d'un cas particulier de chaîne couple partiellement de Markov permettant la segmentation de processus gaussiens à corrélation longue.



Contributions

- Algorithme d'estimation EM dans le cas des chaînes de Markov Couples.
- Etude d'un cas particulier de chaîne couple partiellement de Markov permettant la segmentation de processus gaussiens à corrélation longue.
- Proposition d'un cas particulier de chaîne triplet permettant la segmentation non supervisée de processus non stationnaires.



Contributions

- Algorithme d'estimation EM dans le cas des chaînes de Markov Couples.
- Etude d'un cas particulier de chaîne couple partiellement de Markov permettant la segmentation de processus gaussiens à corrélation longue.
- Proposition d'un cas particulier de chaîne triplet permettant la segmentation non supervisée de processus non stationnaires.
- Etude des possibilités d'extension des modèles probabilistes classiques à un modèle « évidentiel », avec la loi *a posteriori* du processus caché donnée par la fusion de Dempster-Shafer.



Contributions

- Algorithme d'estimation EM dans le cas des chaînes de Markov Couples.
- Etude d'un cas particulier de chaîne couple partiellement de Markov permettant la segmentation de processus gaussiens à corrélation longue.
- Proposition d'un cas particulier de chaîne triplet permettant la segmentation non supervisée de processus non stationnaires.
- Etude des possibilités d'extension des modèles probabilistes classiques à un modèle « évidentiel », avec la loi *a posteriori* du processus caché donnée par la fusion de Dempster-Shafer.
- Extension des modèles de chaînes de Markov floues et de champs de Markov flous à un modèle d'arbres de Markov flou caché multispectraux



Perspectives

- Extension des CCPM gaussiennes au cas non centré.



Perspectives

- Extension des CCPM gaussiennes au cas non centré.
- Extension du modèle d'arbres de Markov cachés flous multispectraux à un modèle d'arbres de Markov couples flous multispectraux



Perspectives

- Extension des CCPM gaussiennes au cas non centré.
- Extension du modèle d'arbres de Markov cachés flous multispectraux à un modèle d'arbres de Markov couples flous multispectraux
- Etudes des liens entre les modèles de Markov conditionnels et les modèles triplet partiellement de Markov.

