



Cours Doctoral EDITE
Champs de Markov - Introduction - Analyse Bayésienne

Marc Sigelle

Année 2008-2009

Dernière mise à jour : 2 mars 2009

Plan du cours

- **introduction**
- **théorème d'Hammersley-Clifford**
 - propriétés fondamentales des champs de Markov.
- **échantillonneurs (Gibbs, Metropolis)**
 - propriétés de convergence.
- **estimateurs bayesiens en traitement des images**

Introduction

- utilisation en imagerie bas niveau
 - Compression
 - Restauration
 - Détection de contours
 - Segmentation
 - Détection du mouvement
 - Tomographie

Champs de Markov

- méthode probabiliste
- synthétise des informations a priori

numériques → Niveaux de gris


topologiques → Voisinage (connexité)

- traitement des images par approche bayésienne → régularisation
- vraisemblance importante des résultats de traitement

A priori dans les images naturelles : le contexte spatial



Contexte spatial dans les images naturelles (suite)



s : site

\mathcal{V}_s : voisinage (spatial) de s

- régions homogènes en niveaux de gris

$x_s \leftrightarrow$ Intensités aux sites voisins

Moyenne

- régions texturées

$x_s \leftrightarrow$ Intensités aux sites voisins (!!)

Contraste, Entropie

réalisation globale de l'image	\Leftrightarrow	voisinage local
probabilité globale	\Leftrightarrow	probabilités locales [conditionnelles]

Vocabulaire

$$S = \{s\} \subset \mathbf{Z}^d$$

$$x_s \in E$$

exemples :

$$x = \{x_s\}_{s \in S} = \{x_s\} \cup x^s$$

$$\Omega = E^{|S|}$$

$$X_s$$

$$P(X_s = x_s)$$

$$X = \{X_s\}_{s \in S} = \{X_s\} \cup X^s$$

$$P(X_s = x_s / X^s = x^s)$$

$$P(X = x) = P(X_1 = x_1, X_2 = x_2 \dots X_s = x_s \dots)$$

ensemble de sites (fini)

espace des niveaux de gris

$$E = \{0..255\} \quad \{0..q - 1\} \text{ (système de labels)} \quad \mathbf{R}$$

configuration : niv. gris au site s + autres sites

espace des configurations


v.a. de niveau de gris au site s

probabilité locale

champ aléatoire : v.a. au site s + autres sites

probabilité conditionnelle (locale)

... $X_s = x_s$... loi globale (jointe)




o extension possible : système des bords

Topologie pour les champs de Markov

○ système de voisinage - définition


voisinage du site s : \mathcal{V}_s

propriétés : $s \notin \mathcal{V}_s$ $s \in \mathcal{V}_r \Leftrightarrow r \in \mathcal{V}_s$



$\mathcal{V} = \{\mathcal{V}_s\}_{s \in S}$ système de voisinage

$x \rightarrow V_s = \{x_r\}_{r \in \mathcal{V}_s}$ configuration locale



○ cliques

$c \subset S$ est une clique / \mathcal{V} ssi :

- $\text{card}(c) = 1$ (singleton)
- $\text{card}(c) \geq 2$ and $\forall r \neq s \in c \Rightarrow r, s$ voisins

○ notations $c = (r, s, t, \dots)$; $\mathcal{C} = \{c\}$

Topologie pour les champs de Markov (suite)

- 4-connexité

4-connexité



ordre 1



ordre 2

- 8-connexité

8-connexité




ordre 1



ordre 2




ordre 3



ordre 4

Champ de Markov



s : site

\mathcal{V}_s : voisinage (spatial) de s

$$\begin{aligned}
 P(X_s = x_s / \{X_r = x_r\}, r \neq s) &= P(X_s = x_s / \{X_r = x_r\}, r \in \mathcal{V}_s) \\
 P(X_s = x_s / X^s = x^s) &= P(X_s = x_s / V_s)
 \end{aligned}$$

Probabilité


Globale

\leftrightarrow

Probabilité

Locale

- extension de la notion de chaîne de Markov




Théorème d'Hammersley-Clifford :

$P(X = x) > 0 \quad \forall x \in \Omega$ est un champ de Markov ssi

$P(X = x) = \frac{\exp - U(x)}{Z}$	distribution de Gibbs
$U(x) = \sum_{c \in \mathcal{C}} U_c(x)$	énergie globale
$U_c(x) = U_c(x_s, s \in c)$	potentiel de cliques
$Z = \sum_{y \in \Omega} \exp - U(y)$	fonction de partition

○ **exemple : cliques**



$$U(x) = A \sum_{s \in S} x_s + B \sum_{(r,s)} x_r x_s + C \sum_{(r,s,t)} x_r x_s x_t$$

non-stationnarité possible : $A \rightarrow A_s$, $B \rightarrow B_{rs}$...


○ fait important : énergie $U(x)$ basse \Leftrightarrow probabilité $P(X = x)$ forte

Distribution de Gibbs avec température

$$P_T(X = x) = \frac{1}{Z_T} \exp -\frac{U(x)}{T}$$

$$U(x) = \sum_{c \in \mathcal{C}} U_c(x) \quad \text{énergie globale}$$

$$Z_T = \sum_{y \in \Omega} \exp -\frac{U(y)}{T} \quad \text{fonction de partition}$$



Comportement aux températures limites

◦ intuition

$$\frac{P_T(X = y)}{P_T(X = x)} = \exp - \frac{[U(y) - U(x)]}{T} \quad \forall x, y \in \Omega$$
$$T \rightarrow \infty \quad \exp - \frac{[U(y) - U(x)]}{T} \rightarrow 1 \quad \forall x, y \in \Omega \text{ fini}$$
$$T \rightarrow 0 \quad \exp - \frac{[U(y) - U(x)]}{T} \rightarrow 0 \quad \text{si } U(y) > U(x)$$

◦ démonstration pour $T \rightarrow \infty$

$$P_T(X = x) = \frac{\exp - \frac{U(x)}{T}}{\sum_{y \in \Omega} \exp - \frac{U(y)}{T}} = \frac{1}{\sum_{y \in \Omega} \exp - \frac{[U(y) - U(x)]}{T}}$$
$$\rightarrow \frac{1}{|\Omega|} \quad \forall x \in \Omega \quad \text{équadistribution sur } \Omega$$

Distribution de Gibbs avec température(suite)

o démonstration pour $T \rightarrow 0$

$$U^* = \min_{x \in \Omega} U(x) \quad \Omega^* = \{x \in \Omega \mid U(x) = U^*\}$$

$$P_T(X = x) = \frac{\exp -\frac{[U(x) - U^*]}{T}}{\sum_{y \in \Omega} \exp -\frac{[U(y) - U^*]}{T}} = \frac{\exp -\frac{[U(x) - U^*]}{T}}{|\Omega^*| + \sum_{y \in \Omega, y \notin \Omega^*} \exp -\frac{[U(y) - U^*]}{T}}$$

$$\rightarrow \begin{cases} \frac{1}{|\Omega^*|} & \text{si } x \in \Omega^* \\ 0 & \text{si } x \notin \Omega^* \end{cases} \quad \text{équidistribution sur } \Omega^*$$

$$(\text{rappel : } \exp -\frac{[U(y) - U(x)]}{T} \rightarrow 0 \text{ si } U(y) > U(x))$$


Forme des probabilités conditionnelles locales

$$P(X_s = x_s / V_s) = \frac{1}{Z_T^s} \exp - \frac{U(x_s / V_s)}{T}$$

avec :

$$U(x_s / V_s) = \sum_{c \subset C, s \in c} U_c(x) \quad \text{énergie conditionnelle locale}$$

$$Z_T^s = \sum_{\xi \in E} \exp - \frac{U(\xi / V_s)}{T} \quad \text{fonction de partition locale}$$



○ \Rightarrow forme locale de la loi de Gibbs

Probabilités conditionnelles locales (suite)

○ démonstration

$$\begin{aligned} \mathbb{P}(X_s = x_s / X^s = x^s) &= \frac{\mathbb{P}(X_s = x_s, X^s = x^s)}{\mathbb{P}(X^s = x^s)} \\ &= \frac{\mathbb{P}(X_s = x_s, X^s = x^s)}{\sum_{\xi \in E} \mathbb{P}(X_s = \xi, X^s = x^s)} = \frac{\mathbb{P}(X = x)}{\sum_{\xi \in E} \mathbb{P}(X = x')} \end{aligned}$$

○ → maintenant posons $U(x) = U(x_s / V_s) + \sum_{c \in C, s \notin c} U_c(x)$

$\swarrow \mathcal{W}$

$$\mathbb{P}(X_s = x_s / X^s = x^s) = \mathbb{P}(X_s = x_s / V_s) = \frac{\exp - \frac{U(x_s / V_s)}{T}}{\sum_{\xi \in E} \exp - \frac{U(\xi / V_s)}{T}} \quad \swarrow Z_T^s$$

Champs de Markov prototypes

- modèle d'Ising

$$U(x) = -\beta \sum_{c=(s,t)} x_s x_t - B \sum_{s \in S} x_s \quad E = \{-1, +1\}$$

- modèle de Potts


$$\text{définissons } \Delta(a, b) = \begin{cases} +1 & \text{si } a = b \\ -1 & \text{si } a \neq b \end{cases}$$

$$U(x) = -\beta \sum_{c=(s,t)} \Delta(x_s, x_t) - B \sum_{s \in S} \Delta(x_s, 0) \quad E = \{0..q-1\}$$

- modèles markoviens gaussiens

$$U(x) = \beta \sum_{c=(s,t)} (x_s - x_t)^2 + \alpha \sum_{s \in S} (x_s - \mu_s)^2 \quad E = \mathbf{R}$$


Modèle d'Ising en 4-connexité et $B = 0$



A	B
C	D

- A : *Image aléatoire* : $\beta = 0$ - B : *régularisation faible* : $\beta = 0.2$
- C : *régularisation "critique"* : $\beta \approx 0.44$ - D : *régularisation forte* : $\beta = 4.0$


Modèle de Potts en 4-connexité et $B = 0$ ($q = 4$)



A	B
C	D

- A : Image aléatoire : $\beta = 0$ - B : régularisation faible : $\beta = 0.2$
- C : régularisation "critique" : $\beta \approx 1,099$ - D : régularisation forte : $\beta = 4.0$

Modèle markovien gaussien en 4-connexité



$$U(x) = \beta \sum_{c=(s,t)} (x_s - x_t)^2 + \alpha \sum_{s \in S} (x_s - \mu_s)^2$$

A	B
C	D

- A : $\alpha = 5.10^{-4}$ - B : $\alpha = 5.10^{-3}$
- C : $\alpha = 2.10^{-3}$ - D : $\alpha = \infty$ ($\mu = 127$ pour toutes simulations)

Modèles markoviens gaussiens

- modèle à pixels indépendants

$$P(X = x) = \left[\sqrt{\frac{\alpha}{\pi}} \right]^{|S|} \prod_{s \in S} e^{-\alpha (x_s - \mu)^2} \Leftrightarrow \frac{\exp -U(x)}{Z}$$

avec $U(x) = \alpha \sum_{s \in S} (x_s - \mu)^2$ $(\alpha = \frac{1}{2 \sigma^2})$

- cas général - modèle auto-normal

$$U(x) = \alpha \sum_{s \in S} (x_s - \mu_s)^2 + \beta \sum_{c=(s,t)} (x_s - x_t)^2$$

↓

moyenne locale

- illumination variable μ_s

- illumination constante $\mu_s = \mu = 128$

↓

couplage

Loi conditionnelle locale en connexité γ : gaussienne

$$\begin{aligned} \mathbb{P}(X_s = x_s / V_s) &= \frac{1}{z} \exp - \left[\alpha(x_s - \mu_s)^2 + \beta \sum_{c=(s,t), t \in \mathcal{V}_s} (x_s - x_t)^2 \right] \\ &= \sqrt{\frac{2(\alpha + \beta \gamma)}{\pi}} \cdot \exp - (\alpha + \beta \gamma) \left[x_s - \left(\frac{\alpha \mu_s + \beta \sum_{t \in \mathcal{V}_s} x_t}{\alpha + \beta \gamma} \right) \right]^2 \end{aligned}$$

- **espérance conditionnelle**

$$\mathbb{E}[X_s / V_s] = \frac{\alpha \mu_s + \beta \sum_{t \in \mathcal{V}_s} x_t}{\alpha + \beta \gamma} = \frac{\alpha \mu + \beta \sum_{t \in \mathcal{V}_s} x_t}{\alpha + \beta \gamma} \rightarrow \text{barycentre } (\mu_s = \mu)$$


- **variance conditionnelle**

$$\text{var}(X_s / V_s) = \frac{1}{2(\alpha + \beta \gamma)} \rightarrow \text{indépendante de } \mu_s \text{ et de } x_t, t \in \mathcal{V}_s$$

- \Rightarrow **permet un ensemble de statistiques à variable $X_{\mathbf{V}} = \sum_{t \in \mathcal{V}_s} x_t$ fixée**

Échantillonnage d'un champ de Markov

- chaîne de Markov



$$\begin{aligned} P(X^{(n)} = x^{(n)} / X^{(0)} = x^{(0)}, X^{(1)} = x^{(1)} \dots X^{(n-1)} = x^{(n-1)}) \\ = P(X^{(n)} = x^{(n)} / X^{(n-1)} = x^{(n-1)}) \end{aligned}$$

- noyau de transition

$$Q_n(x, y) = P(X^{(n)} = y / X^{(n-1)} = x) \quad x \rightarrow y$$


- chaîne de Markov homogène : $Q_n(x, y)$ indépendant de n

$$T = \text{Cte}$$

- chaîne de Markov inhomogène : $Q_n(x, y)$ dépendant de n

$$T_n \searrow 0$$

Échantillonnage : chaîne de Markov de variables d'images !



- échantillonnage homogène : trouver $Q(x, y)$ tel que

$$\lim_{n \rightarrow +\infty} \mathbb{P}(X^{(n)} = x) = \mathbb{P}_T(X = x) \quad \text{distribution de Gibbs à température } T$$

- échantillonnage inhomogène : trouver $Q_n(x, y)$ tel que

$$\lim_{n \rightarrow +\infty} \mathbb{P}(X^{(n)} = x) = \frac{1}{|\Omega^*|} \mathbb{1}_{x \in \Omega^*} \quad \text{distribution de Gibbs à température "0"}$$

→ minimum globaux de $U(x)$

Échantillonnage homogène (température T fixe)

- noyau irréductible - noyau réversible

$$Q(x, y) > 0 \quad P_T(X = x) Q(x, y) = P_T(X = y) Q(y, x) \quad \forall x, y \in \Omega$$

- théorème pour l'échantillonnage homogène

Si $Q(., .)$ est un noyau homogène, irréductible et réversible par rapport à la distribution $P_T(., .)$, alors

$$\forall X^{(0)} = x^{(0)} \quad \lim_{n \rightarrow +\infty} P(X^{(n)} = x) = P_T(X = x)$$

- loi des grands nombres (échantillons $X^{(n)}$ non indépendants!)

$$\frac{\sum_{n=M}^{M+N} f(X^{(n)})}{N} \xrightarrow{N \rightarrow +\infty} \mathbf{E}_T[f(X)] \quad \text{ex:} \quad \frac{\sum_{n=M}^{M+N} \mathbb{1}_{X_s^{(n)}=i}}{N} \xrightarrow{N \rightarrow +\infty} \mathbf{E}_T[\mathbb{1}_{X_s=i}] = P_T(X_s = i) !$$

Echantillonneurs homogènes de Metropolis et de Gibbs

- **Metropolis** : $Q(x, y) = 1$ si $U(y) < U(x) \Rightarrow$ cas $U(y) \geq U(x)$:


$$P_T(X = x) Q(x, y) = P_T(X = y) \underbrace{Q(y, x)}_1 \quad (\text{réversibilité})$$

$$\Rightarrow Q(x, y) = \frac{P_T(X = y)}{P_T(X = x)} = \exp - \frac{[U(y) - U(x)]}{T} = \exp - \frac{\Delta U}{T}$$

- **Gibbs** : $Q_s(x_s^{(n)}, x_s^{(n+1)} = \xi) = P(X_s^{(n+1)} = \xi / V_s)$

réversible *p.r.* distribution de Gibbs $P_T(x)$

- \Rightarrow tirage de $x_s^{(n+1)}$ selon la loi conditionnelle locale courante



Échantillonnage inhomogène (température T variable)

- **théorème (Geman and Geman 1984)**

si $Q_n(x, y)$ avec $T_n \searrow 0$, $T_n \geq \frac{T_0}{\log(1+n)}$

alors $\lim_{n \rightarrow +\infty} P(X^{(n)} = x) = \frac{1}{|\Omega^*|} \mathbb{1}_{x \in \Omega^*} \leftarrow$ minimum global de l'énergie


- **condition théorique**

$$T_0 = \begin{cases} \Delta U_{max} & \textit{Metropolis} \\ \sum_{s \in S} \delta U(\cdot / V_s)_{max} & \textit{Gibbs} \end{cases}$$

- **en pratique : $T_n = T_0 \alpha^n$ avec :**

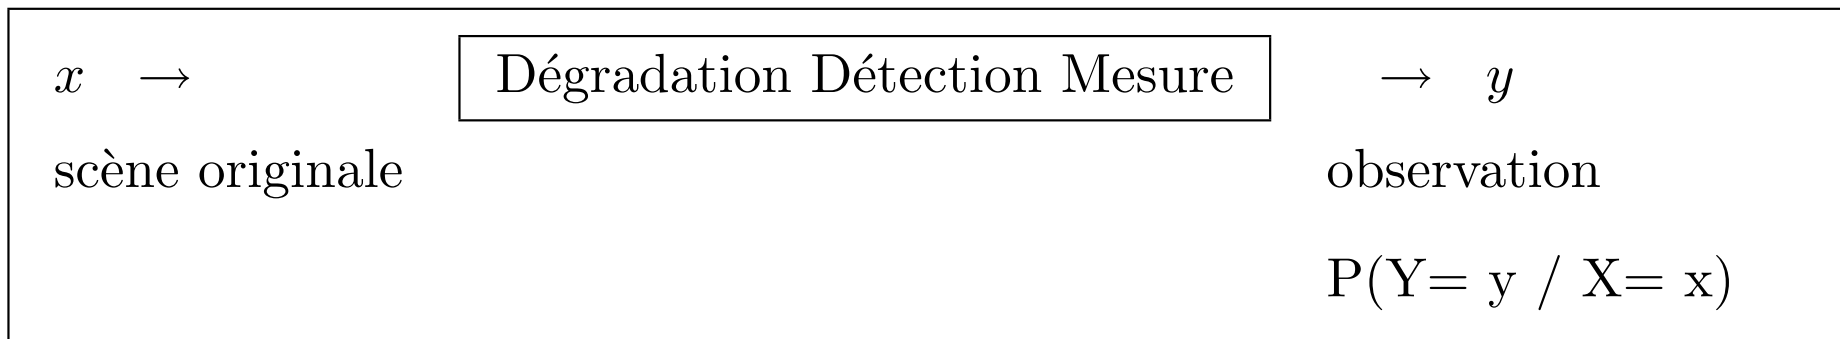
$$T_0 \approx \delta U(\cdot / V_s)_{max} , \alpha \approx 0.98$$

Recuit simulé



Analyse Bayésienne en Traitement des Images

Loi du processus de formation des observations



- **bruit blanc additif gaussien**


$$\left[\begin{array}{l}
 y = x + \epsilon \qquad y_s = x_s + \epsilon_s \quad \forall s \in S \qquad \epsilon_s \rightarrow \mathcal{N}(0, \sigma^2) \\
 P(Y = y / X = x) = \prod_{s \in S} P(Y_s = y_s / X_s = x_s) \propto \prod_{s \in S} \exp - \frac{(y_s - x_s)^2}{2\sigma^2}
 \end{array} \right.$$

Loi du processus de formation des observations (suite)


- **convolution**

$$\left[\begin{array}{l} y = h x + \epsilon \\ y_s = \sum_{s \in S} h_{rs} x_s + \epsilon_s \quad \forall s \in S \quad \epsilon_s \rightarrow \mathcal{N}(0, \sigma^2) \end{array} \right.$$

- flou de bougé isotrope uniforme



- flou de mise au point (gaussien)



Modèle (loi) a priori : propriétés désirées sur l'image réelle

{ Homogénéité de zones
Contours
Textures
Intensité


→ Modélisation markovienne

$$P(X = x) = \frac{\exp -U(x)}{Z}$$

Distribution a posteriori

- modélise le problème : $y \rightarrow x$?

$$P(X = x / Y = y) = \frac{P(Y = y / X = x) \cdot P(X = x)}{P(Y = y)} \quad [\text{Bayes}]$$



- estimateur MAP : $\arg \max P(X = x / Y = y)$

Débruitage d'image avec bruit blanc additif gaussien

$$P(Y = y / X = x) = \prod_{s \in S} P(Y_s = y_s / X_s = x_s) \propto \prod_{s \in S} \exp - \frac{(y_s - x_s)^2}{2\sigma^2}$$

- régularité de l'image réelle à niveaux de gris

$$P(X = x) = \frac{\exp - \beta \sum_{(r,s) \in \mathcal{C}} \Phi(x_r, x_s)}{Z}$$

- \Rightarrow on en déduit $P(X = x / Y = y) = \frac{\exp - \mathcal{U}}{Z'}$


$$\mathcal{U} = \sum_{s \in S} \frac{(y_s - x_s)^2}{2\sigma^2} + \beta \sum_{(r,s) \in \mathcal{C}} \Phi(x_r, x_s) \quad \max_{x \in \Omega} P(X = x / Y = y) \Leftrightarrow \min_{x \in \Omega} \mathcal{U}$$

- régularisation

Débruitage d'image (suite) : le potentiel Φ [Geman]

- sa formulation

$$\beta \Phi(x_r, x_s) = \frac{-\beta}{1 + \left(\frac{x_r - x_s}{\delta}\right)^2}$$




- β : “Portée” du potentiel
- δ : “Amplitude” du potentiel

- \Rightarrow choix de β et δ : choix des paramètres

Restauration de photographies (J-M. Dinten CEA/LETI)



Restauration de photographies : flou de bougé




Restauration de photographies : flou de mise au point



$\beta = 10$
 $\delta = 60$
 $\sigma_c = 1,5$



$\beta = 10$
 $\delta = 60$
 $\sigma_c = 5$



$\beta = 10$
 $\delta = 60$
 $\sigma_c = 10$



$\beta = 10$
 $\delta = 60$
 $\sigma_c = 5$
filtrage médian



Segmentation d'image par champs de Markov

- position du problème

$$Y \quad \rightarrow \quad X$$

processus pixel (observation)

processus label (étiquettes)

- estimateur MAP : $\arg \max \mathbf{P}(X = x / Y = y)$

$$\mathbf{P}(X = x / Y = y) = \frac{\mathbf{P}(Y = y / X = x) \cdot \mathbf{P}(X = x)}{\mathbf{P}(Y = y)}$$

↑

probabilité a posteriori

↑

Bayes

$$\left[\begin{array}{l} \mathbf{P}(Y_s = y_s / x_s = i) = \frac{1}{\sqrt{2\pi}\sigma_i} \exp - \frac{(x_s - \mu_i)^2}{2\sigma_i^2} \leftarrow \text{Gaussien} \\ \mathbf{P}(X = x) = \frac{\exp - \sum_{c \in \mathcal{C}} U_c(x)}{Z} \leftarrow \text{Markov : Potts etc..} \end{array} \right.$$

Segmentation d'image par champs de Markov (suite)

$$\min \mathcal{U}(x) = U(y / x) + U(x)$$

$$U(y / x) = \sum_{s \in S} \frac{(y_s - \mu_{l_s})^2}{2\sigma_{x_s}^2} + \log \sigma_{x_s}$$

$$U(x) = -K \sum_{(r,s) \in \mathcal{C}} \delta(x_r, x_s)$$

- → recuit simulé

Segmentation d'image : exemple

