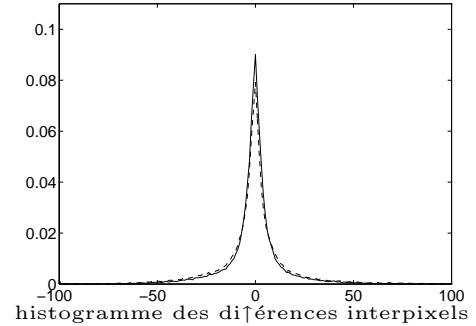
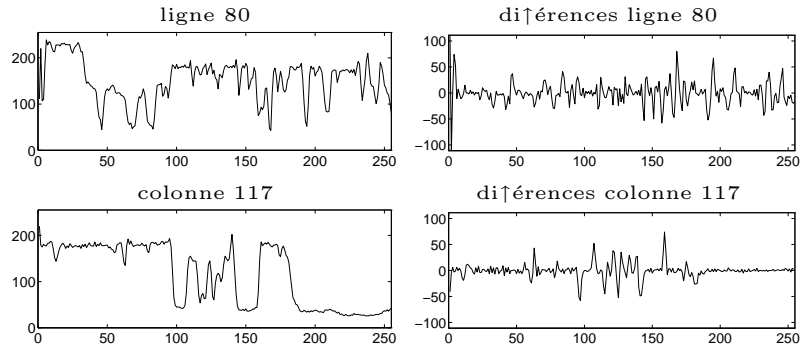


# IV. Déconvolution d'images, modèles markoviens, algorithmes stochastiques

## MODÉLISATION MARKOVIENNE EN IMAGERIE

### ■ Résumé des épisodes précédents

- Règle de Bayes  $f(\mathbf{x} | \mathbf{z}) \propto f(\mathbf{z} | \mathbf{x})f(\mathbf{x})$ ,  $f(\mathbf{x}) \propto \exp \{-\Omega(\mathbf{x})\}$
- Loi *a priori* gaussienne = régularisation quadratique
$$\Omega(\mathbf{x}) = (\mathbf{x} - \mathbf{m}_x)^t \mathbf{R}_x^{-1} (\mathbf{x} - \mathbf{m}_x), \quad e.g., \quad \Omega_{\text{PTT}}(\mathbf{x}) = \|\mathbf{D}^{(q)} \mathbf{x}\|^2$$
- Lois *a priori* blanches non gaussiennes
  - Critères convexes
$$\Omega(\mathbf{x}) = \sum_i G(x_i), \quad G_p(x) = |x|^p, \quad G_{21}(x) = \sqrt{s^2 + x^2}$$
  - Variables cachées : modèle Bernoulli-Gaussien  $\mathbf{x} = (\mathbf{r}, \mathbf{q})$



CHAMPS DE GIBBS-MARKOV

$$f(\mathbf{x}) = \frac{1}{Z} \exp -\Omega(\mathbf{x}),$$

$$f_T(\mathbf{x}) = \frac{1}{Z(T)} \exp \{-\Omega(\mathbf{x})/T\}$$

$$\left( \begin{array}{ll} \bullet \quad \Omega \text{ séparable} & \iff X \ll \text{bruit blanc} \gg \\ \Omega(\mathbf{x}) = \sum_{s \in \mathcal{S}} G_s(x_s) & f(\mathbf{x}) = \prod_{s \in \mathcal{S}} f_s(x_s) \end{array} \right)$$

$$\bullet \quad \Omega \text{ énergie de Gibbs} \iff X \text{ markovien}$$

$$\Omega(\mathbf{x}) = \sum_{c \in \mathcal{C}} G_c(\mathbf{x}) \quad f(x_s | x_r, r \in \mathcal{S} \setminus s) = f(x_s | x_r, r \in \mathcal{V}_s)$$

$$\Omega(\mathbf{x}) < \infty \quad \forall \mathbf{x} \quad \mathcal{V}_s = \{r \in \mathcal{C} \ni s, r \neq s\}$$

$c \in \mathcal{C} \subset \mathcal{P}(\mathcal{S})$  clique, voisinage du site  $s$   
 $G_c$  potentiel associé

(Théorème de Hammersley-Clifford)


$$\Omega(\mathbf{x}) = \sum_{\{r,s\} \in \mathcal{C}} G(x_r - x_s)$$

$$\mathcal{C} = \{\{r, s\}, |r - s| = 1\} = \left\{ \begin{array}{c} \circ \quad \circ \\ \circ \quad \circ \end{array} \right\} \iff \mathcal{N}_s = \left\{ \begin{array}{c} \circ \\ \circ \quad \bullet \quad \circ \\ \circ \end{array} \right\}$$

$$G_{22}(x) = x^2$$

$$G_{21}(x) = \sqrt{t^2 + x^2} - t$$

$$G_{20}(x) = \min\{x^2, t^2\}$$



### CRITÈRE ET OPTIMISATION CONVEXES

Exemple (ordre 1) :  $G_{21}(\mathbf{x}) = \sum_{\{r,s\}, \|r-s\|=1} \sqrt{s^2 - (x_r - x_s)^2}$

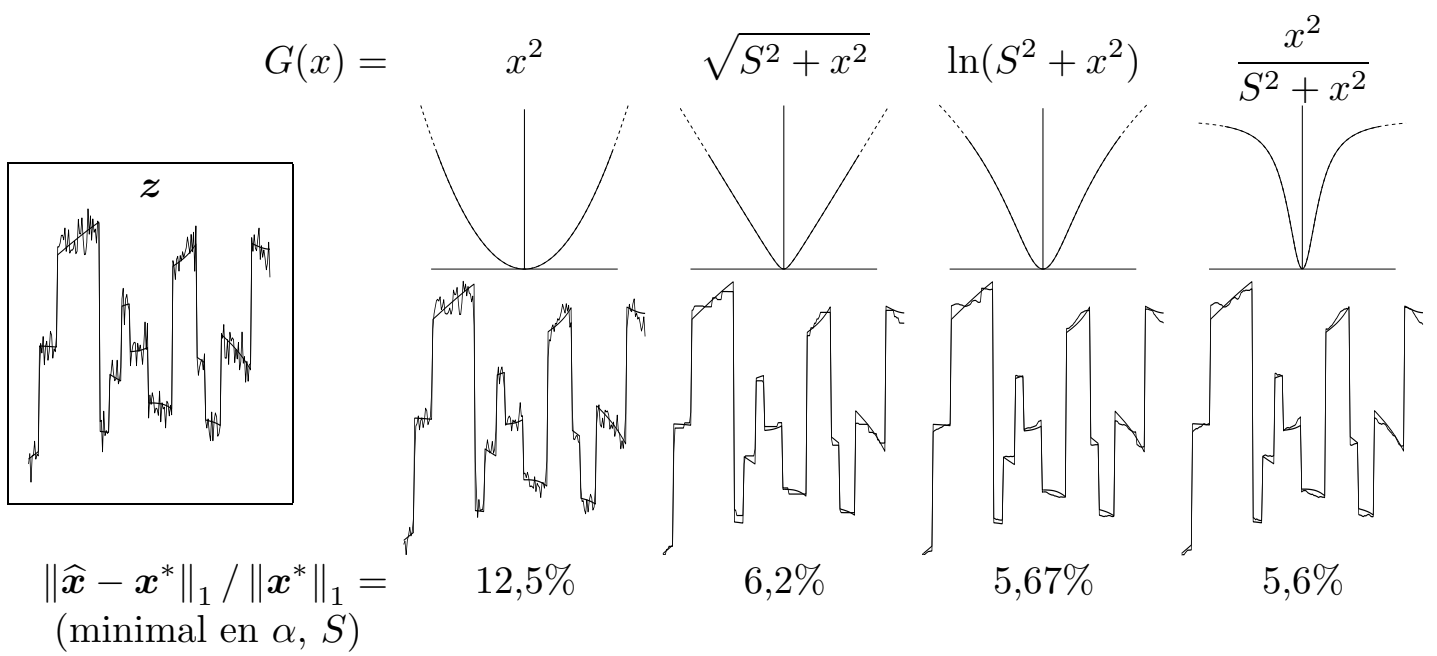
*application* : restauration d'images, en minimisant

$$J(\mathbf{x}) = \|\mathbf{z} - \mathbf{H}\mathbf{x}\|^2 + \alpha G_{21}(\mathbf{x}), \quad \mathbf{x} \in [0, x_{max}]^S$$


image originale      image observée      résultat gaussien  $G_{22}$       résultat  $G_{21}$



$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x}} \|\mathbf{z} - \mathbf{x}\|^2 + \alpha \sum_m G(x_m - x_{m-1})$$




NON CONVEXITÉ GRADUELLE (GNC)




■  $G_{20}$  : le cas du débruitage [BLAKE ET ZISSERMAN 1987]

$$J_c(\mathbf{x}) = \beta \|\mathbf{z} - \mathbf{x}\|^2 + \sum_{\{r,s\} \in \mathcal{C}} G_c(x_r - x_s)$$



$J$  convexe  $\Rightarrow \hat{x}(z)$  continue [BOUMAN ET SAUER 1993]  
 $\Rightarrow$  stabilité au sens de Hadamard


Contre-exemple pour  $J$  non convexe :  
 (d'après [LI et coll. 1995] ; voir aussi [KÜNSCH 1994])



**PRINCIPE DE DÉTECTION, VARIABLES CACHÉES**

■ [BLAKE ET ZISSERMAN 1987]

$$\begin{aligned} & \min_{\mathbf{x}} \beta \|\mathbf{z} - A(\mathbf{x})\|^2 + \sum_{\{r,s\} \in \mathcal{C}} \min \{ (x_r - x_s)^2, S^2 \} \\ & = \min_{\mathbf{x}, \mathbf{l}} \beta \|\mathbf{z} - A(\mathbf{x})\|^2 + \sum_{\{r,s\} \in \mathcal{C}} (1 - l_{rs})(x_r - x_s)^2 + l_{rs}S^2 \end{aligned}$$

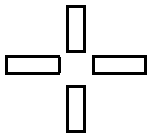
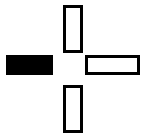
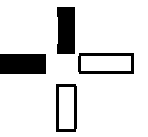
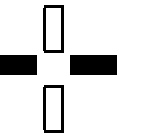
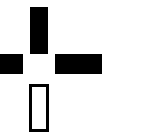
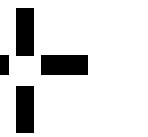


Variables cachées  $l_{rs} \in \{0, 1\} \rightsquigarrow$  problème de *détection-estimation*

$\mathbf{X}, \mathbf{L}$ , champ de Markov composite.

$$\min_{\mathbf{x}, \mathbf{l}} \beta \|\mathbf{z} - A(\mathbf{x})\|^2 + \sum_{\{r,s\} \in \mathcal{C}} (1 - l_{rs})(x_r - x_s)^2 + \sum_{c \in \mathcal{C}_L} G_c(\mathbf{l})$$

Exemple :

$c \in \mathcal{C}_L$						
$G_c(\mathbf{l})$	0	2, 7	1, 8	0, 9	1, 8	2, 7

ÉCHANTILLONNAGE STOCHASTIQUE


■ Application en synthèse d'image

- Exemple : modèle de Gibbs aux plus proches voisins

$$\mathcal{C} = \{\{r, s\}, \|r - s\| = 1\}$$

Exemple d'échantillon pour

$$\Phi(\mathbf{x}) = \sum_{\{r,s\}, \|r-s\|=1} \sqrt{1 + (x_s - x_r)^2}$$



## ■ Application à l'inférence

Contexte :

- $\mathbf{z} = [z_1, \dots, z_N]^t$  vecteur observé
- $\mathbf{x} = [x_1, \dots, x_M]^t$  vecteur inconnu
- $\mathbf{z}$  est relié à  $\mathbf{x}$  sous forme probabiliste : on connaît la loi de  $(\mathbf{X}, \mathbf{Z})$ , typiquement, sous la forme  $f_{\mathbf{X}, \mathbf{Z}}(\mathbf{x}, \mathbf{z}) = f_{\mathbf{Z}|\mathbf{X}}(\mathbf{z} | \mathbf{x})f_{\mathbf{X}}(\mathbf{x})$

On veut estimer  $\mathbf{x}$  sous la forme  $\hat{\mathbf{x}} = \hat{\mathbf{X}}(\mathbf{z})$

① Estimation à coût bayésien séparable :


Si  $\{\mathbf{X}^{(k)}\}$  est stationnaire ergodique et de loi instantanée  $f(\mathbf{x} | \mathbf{z})$ , alors

$$\hat{\mathbf{x}}^{\text{EAP}}(\mathbf{z}) = \mathbb{E}[\mathbf{X} | \mathbf{z}] = \lim_{K \rightarrow \infty} \frac{1}{K} \sum_{k=1}^K \mathbf{x}^{(k)}$$

② Estimation MAP (principe du recuit simulé) :

Si la loi instantanée de  $\{\mathbf{X}^{(k)}\}$  est  $f_{T(k)}(\mathbf{x} | \mathbf{z})$ , avec  $T(k) \searrow 0$  et

$$f_T(\mathbf{x} | \mathbf{z}) \propto (f(\mathbf{x} | \mathbf{z}))^{1/T}, \text{ alors : } \lim_{T \rightarrow 0} f_T(\mathbf{x} | \mathbf{z}) = \delta_{\hat{\mathbf{x}}^{\text{MAP}}(\mathbf{x})}$$



③ Estimation non supervisée (principe de l'augmentation de données) :


$$\{\mathbf{X}^{(k)}, \Theta^{(k)}\} \sim f(\mathbf{x}, \theta | \mathbf{z}) \implies \begin{cases} \Theta^{(k)} \sim f(\theta | \mathbf{z}) = \int f(\mathbf{x}, \theta | \mathbf{z}) d\mathbf{x} \\ \mathbf{X}^{(k)} \sim f(\mathbf{x} | \mathbf{z}) = \int f(\mathbf{x}, \theta | \mathbf{z}) d\theta. \end{cases}$$

## ■ Méthodes d'échantillonnage i.i.d. ( $\mathbf{X}$ faible dimension)

- directes :

- lois uniformes,
- par transformation : discrètes, normales, lois avec  $F^{-1}$  explicite, etc.

- par réjection [PRESS et coll. 1992]



- ① Trouver une densité  $q$  et  $M > 0$  tel que  $\forall x, r(x) = Mq(x) \geq p(x)$ .
- ② Tirer  $X = x$  suivant  $q$ .
- ③ Tirer  $Y = y$  suivant  $\mathcal{U}([0, r(x)])$ .
- ④ Accepter  $x$  si  $y \leq p(x)$ , sinon retour en ②

## ■ Méthodes d'échantillonnage MCMC (*Monte-Carlo Markov chain*)

$\{\mathbf{X}^{(k)}\}$  est une chaîne de Markov :  $f(\mathbf{x}^{(k)} | \mathbf{x}^{(k-1)}, \dots, \mathbf{x}^{(1)}) = f(\mathbf{x}^{(k)} | \mathbf{x}^{(k-1)})$

- Théorème 1 :

Soit  $\{\mathbf{X}^{(k)}\}_{k \in \mathbb{N}}$  une chaîne de Markov homogène « ergodique » (irréductible récurrente positive de période 1) dont le noyau de transition  $\varphi$  vérifie la *condition d'équilibre*

$$\varphi(\mathbf{x}' | \mathbf{x})f(\mathbf{x}) = \varphi(\mathbf{x} | \mathbf{x}')f(\mathbf{x}'),$$

alors la densité de probabilité de  $\mathbf{X}^{(\infty)}$  est  $f$ .

- Théorème 2 (loi des grands nombres) :

$$\text{si } E_f[\psi^2] < \infty, \quad \lim_{K \rightarrow \infty} \frac{1}{K} \sum_{k=1}^K \psi(\mathbf{x}^{(k)}) = E_f[\psi] \text{ p.s.}$$



- Soit  $f(\mathbf{x})$  à échantillonner et  $g(\mathbf{x}' | \mathbf{x})$  un *noyau de proposition* symétrique

① Configuration courante :  $\mathbf{x}$

② Proposer  $\mathbf{x}'$  par échantillonnage de  $g(\mathbf{x}' | \mathbf{x})$  ;

③ Si  $f(\mathbf{x}') \geq f(\mathbf{x})$ ,  $\mathbf{x}'$  remplace  $\mathbf{x}$  ;

Si  $f(\mathbf{x}') < f(\mathbf{x})$ ,  $P(\mathbf{x}' \text{ remplace } \mathbf{x}) = f(\mathbf{x}')/f(\mathbf{x})$  ;

retour en ① pour l'itération suivante

- Application à  $\mathbf{X}$  champ de Gibbs :  $f(\mathbf{x}) = \frac{1}{Z} \exp - \sum_c G_c(\mathbf{x})$

Noyau de proposition :

$$g(\mathbf{x}' | \mathbf{x}) = \begin{cases} h(x'_s | x_s) / \text{Card } \mathcal{S} & \text{si } \forall r \neq s, x'_r = x_r \\ = 0 & \text{sinon} \end{cases}$$

$$\Rightarrow f(\mathbf{x}')/f(\mathbf{x}) = \exp \sum_{c \ni s} (G_c(\mathbf{x}) - G_c(\mathbf{x}'))$$



Extensions : balayage systématique, partiellement parallélisable

- Exemple

Simulation d'un champ de Ising


Initialisation

Itération 1



Itération 10

Itération 100



## ■ MCMC 2 : Échantillonneur de Gibbs [GEMAN ET GEMAN 1984]

- ① Configuration courante :  $\mathbf{x}$
- ① Choisir  $s$  « au hasard » ou cycliquement ;
- ②  $\forall r \neq s, x'_r = x_r$  ; échantillonner  $x'_s$  suivant  $f(x'_s | \mathbf{x}_{-s})$ ,  $\mathbf{x}_{-s} = \{x_r, r \neq s\}$ .  
retour en ① pour l'itération suivante

Remarque : MCMC 1 et 2 sont des cas particuliers de l'échantillonneur de Métropolis-Hastings [HASTINGS 1970].

- discussion) », *J. R. Statist. Soc. B*, **36**, n°2, 192-236.
- [BESAG 1986] J. E. BESAG (1986), « On the statistical analysis of dirty pictures (With discussion) », *J. R. Statist. Soc. B*, **48**, n°3, 259-302.
- [BLAKE ET ZISSERMAN 1987] A. BLAKE ET A. ZISSERMAN (1987), *Visual reconstruction*, The MIT Press, Cambridge, MA, USA.
- [BOUMAN ET SAUER 1993] C. A. BOUMAN ET K. D. SAUER (1993), « A generalized Gaussian image model for edge-preserving MAP estimation », *IEEE Trans. Image Processing*, **2**, n°3, 296-310.
- [GEMAN ET GEMAN 1984] S. GEMAN ET D. GEMAN (1984), « Stochastic relaxation, Gibbs distributions, and the Bayesian restoration of images », *IEEE Trans. Pattern Anal. Mach. Intell.*, **PAMI-6**, n°6, 721-741.
- [HASTINGS 1970] W. K. HASTINGS (1970), « Monte Carlo sampling methods using Markov Chains and their applications », *Biometrika*, **57**, 97.
- [JENG ET WOODS 1991] F. C. JENG ET J. W. WOODS (1991), « Compound Gauss-Markov random fields for image estimation », *IEEE Trans. Signal Processing*, **39**, n°3, 683-697.
- [KÜNSCH 1994] H. R. KÜNSCH (1994), « Robust priors for smoothing and image restoration », *Ann. Inst. Stat. Math.*, **46**, n°1, 1-19.
- [LI et coll. 1995] S. Z. LI, Y. H. HUANG ET J. S. FU (1995), « Convex MRF potential functions », dans *Proc. IEEE ICIP*, volume 2, 296-299, Washington DC, USA.
- [MARROQUIN et coll. 1987] J. L. MARROQUIN, S. K. MITTER ET T. A. POGGIO (1987), « Probabilistic solution of ill-posed problems in computational vision », *J. Amer. Stat. Assoc.*, **82**, 76-89.
- [METROPOLIS et coll. 1953] N. METROPOLIS, A. W. ROSENBLUTH, M. N. ROSENBLUTH, A. H. TELLER ET E. TELLER (1953), « Equations of state calculations by fast computing machines », *Journal of chemical physics*, **21**, 1087-1092.
- [PRESS et coll. 1992] W. H. PRESS, S. A. TEUKOLSKY, W. T. VETTERLING ET B. P. FLANNERY (1992), *Numerical recipes in C, the art of scientific computing*, Cambridge Univ. Press, New York, 2nd ed.
- [ROBERT 1992] C. ROBERT (1992), *L'analyse statistique bayésienne*, Economica, Paris.
- [ROBERT 1996] C. ROBERT (1996), *Méthodes de Monte-Carlo par chaînes de Markov*, Economica, Paris.
- [WINKLER 1995] G. WINKLER (1995), *Image Analysis, Random Fields and Dynamic Monte Carlo Me-*