

**TRAITEMENT D'IMAGE**

**MODELES FONCTIONNELS**

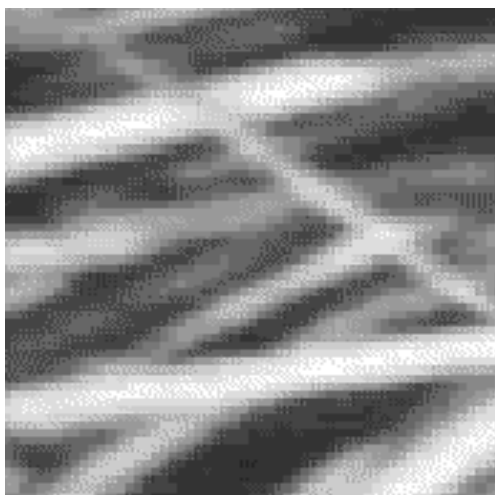
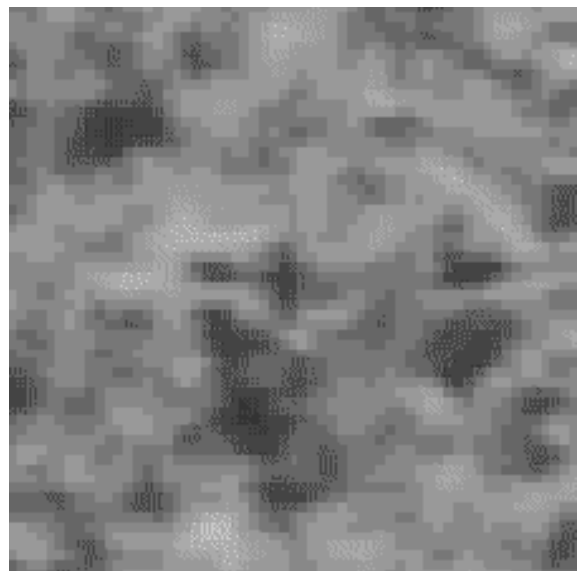
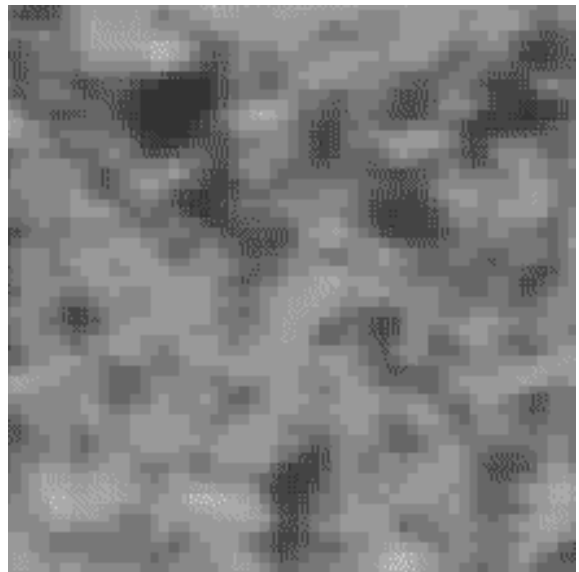
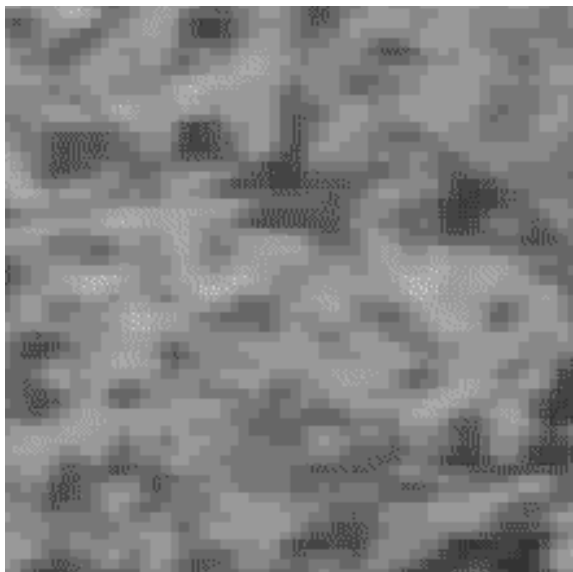
**CHAMPS ALÉATOIRES**

**PH.BOLON**

**LISTIC**

**POLYTECH ANNECY-CHAMBÉRY**

**UNIVERSITÉ DE SAVOIE**



# 1. CHAMPS ALÉATOIRES

## 1.1. introduction

variabilité locale des images naturelles,  
 textures,  
 bruits de capteurs

## 1.2. représentation

### 1.2.1. modèle mathématique

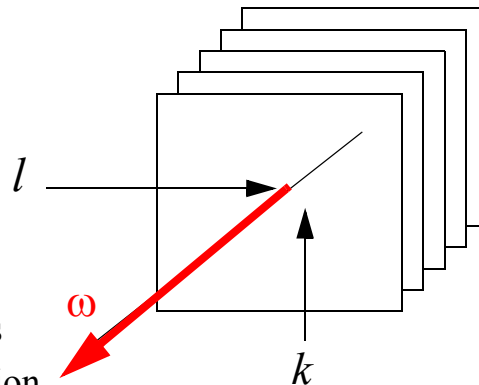
$$X \quad \mathbf{R} \times \mathbf{R} \times \Omega \longrightarrow \mathbf{R}$$

$$(l, k, \omega) \quad X(l, k, \omega)$$

 extension en 2D des fonctions aléatoires

$\omega = \text{constante}$  image déterministe  $x(l, k)$   
 $(l, k) = \text{constante}$  variable aléatoire  $X$

collection de réalisations particulières  
 variable aléatoire dépendant de position



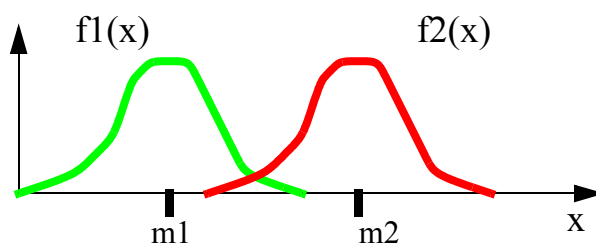
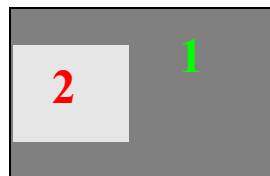
## 1.3. étude statistique

au premier ordre : étude de la variable  $X(l, k)$

densité de probabilité :  $f(x, l, k)$

fonction de répartition :  $F(x, l, k)$

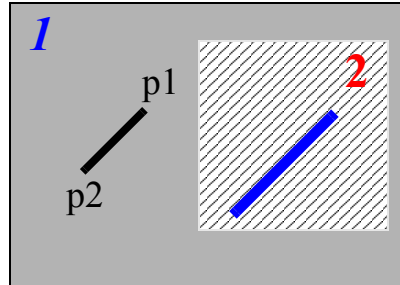
étude simplifiée :  $E[X(l, k)]$



au deuxième ordre : étude des couples aléatoire  $X(l_1, k_1)$ ,  $X(l_2, k_2)$ .

densité de probabilité conjointe :  $f(a, l_1, k_1, b, l_2, k_2)$

moment d'ordre 2 :  $E[X(l_1, k_1)X(l_2, k_2)]$



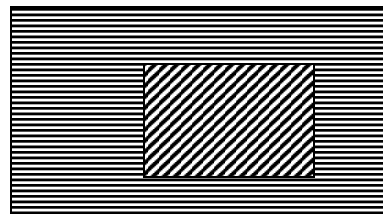
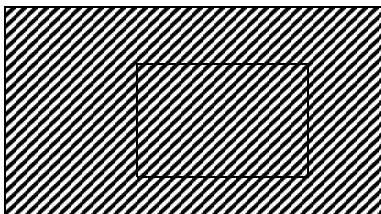
fonction de corrélation

☐ champs aléatoires gaussiens

## 1.4. champs aléatoires stationnaires

**def.** La loi de probabilité est invariante par translation spatiale

au premier ordre :  $f(a, l, k) = f(a)$  ----->  $E[X(l, k)] = \text{constante}$



au deuxième ordre :  $f(\mathbf{a}, l_1, k_1, \mathbf{b}, l_2, k_2) = f(\mathbf{a}, l_1 + dl, k_1 + dk, \mathbf{b}, l_2 + dl, k_2 + dk)$

ne dépend que de la translation entre les 2 points

$$dl = -l_2, dk = -k_2$$

$$f(\mathbf{a}, l_1 - l_2, k_1 - k_2, \mathbf{b}, 0, 0)$$

fonction de corrélation  $C(\Delta l, \Delta k)$

$$C(\Delta l, \Delta k) = E[X(l, k)X(l - \Delta l, k - \Delta k)]$$

$$E[X(l, k)X(l - \Delta l, k - \Delta k)] = \int_{\mathbf{R} \times \mathbf{R}} \int abf(a, l, k, b, l - \Delta l, k - \Delta k)dad b$$

## 1.5. modèle pour champs non stationnaires

$$X = s + B$$

s : image déterministe

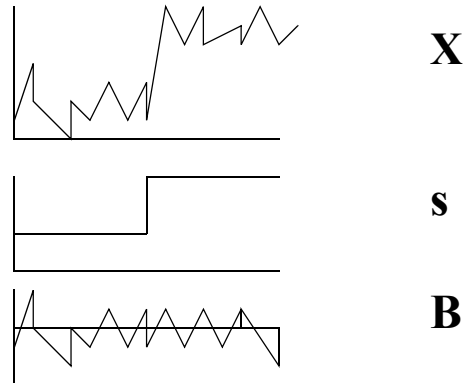
B : champ aléatoire

stationnaire (au moins localement)

centré

éventuellement blanc

pas forcément gaussien

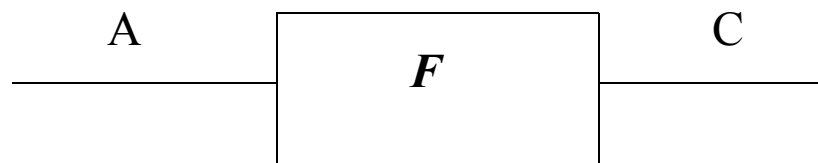


## 2. FILTRAGE LINÉAIRE DES CHAMPS ALÉATOIRES

### 2.1. cas continu

modèle :  $A = s + B$

s : déterministe , B : aléatoire, centré,



$$C = F(A) = F(s) + F(B) \\ = d + N$$

h : réponse impulsionnelle (PSF)

$$d = h * s$$

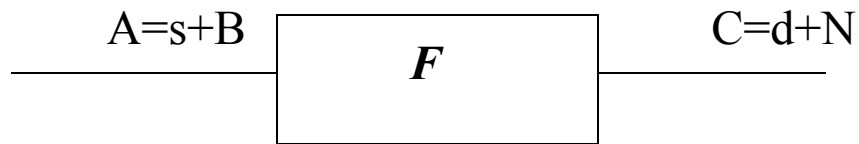
$$d(x, y) = \iint h(\alpha, \beta) s(x - \alpha, y - \beta) d\alpha d\beta$$

par transformation de Fourier

$$\tilde{d}(u, v) = \tilde{h}(u, v) \tilde{s}(u, v)$$

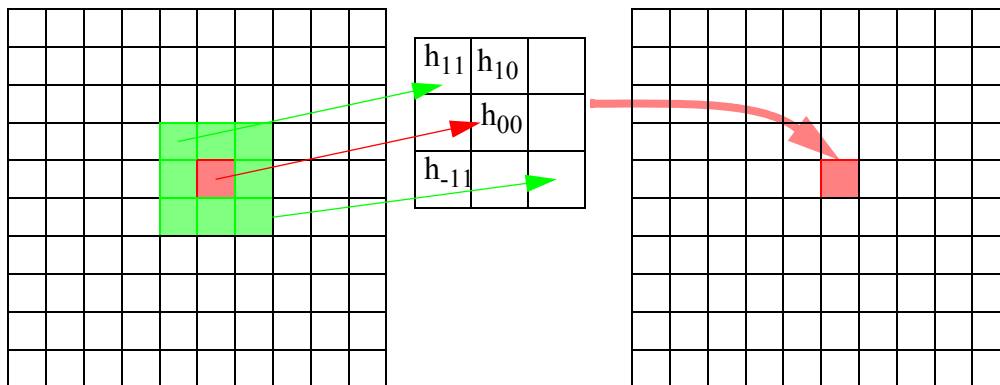
effet passe-bas, passe-haut, passe-bande, etc.

## 2.2. cas discret



$$d(l, k) = \sum_i \sum_j h(i, j) s(l-i, k-j)$$

$$N(l, k) = \sum_i \sum_j h(i, j) B(l-i, k-j)$$



caractérisation :

effet sur les transitions : flou, rehaussement

effet de réduction de bruit : biais, variance

$$\sum_i \sum_j h^2(i, j)$$

### 3. CHAMPS MARKOVIENS

modèle local décrivant les formes et la distribution des amplitudes

#### 3.1. définitions et notations

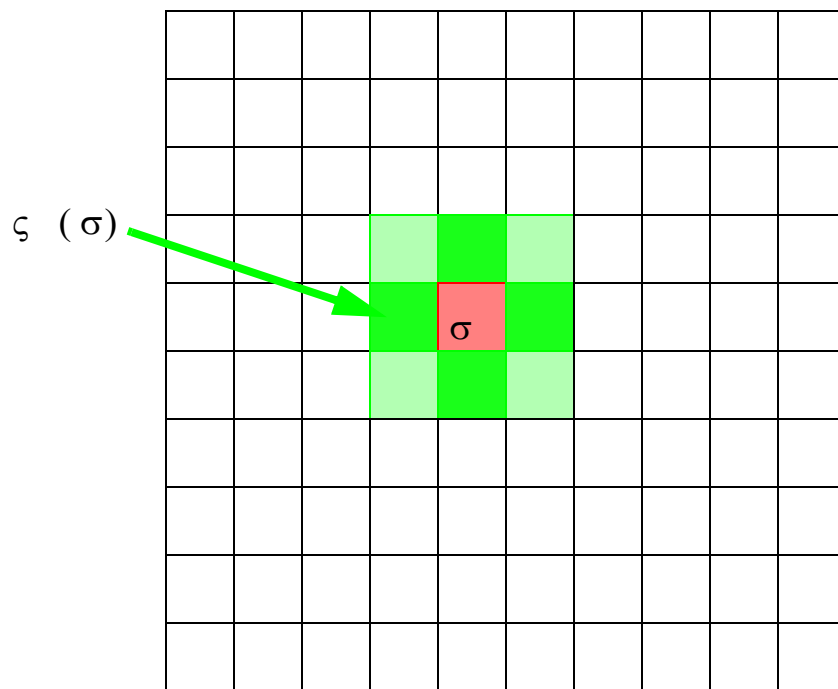
site  $s$                       pixel

support spatial               $S = \{s\}$

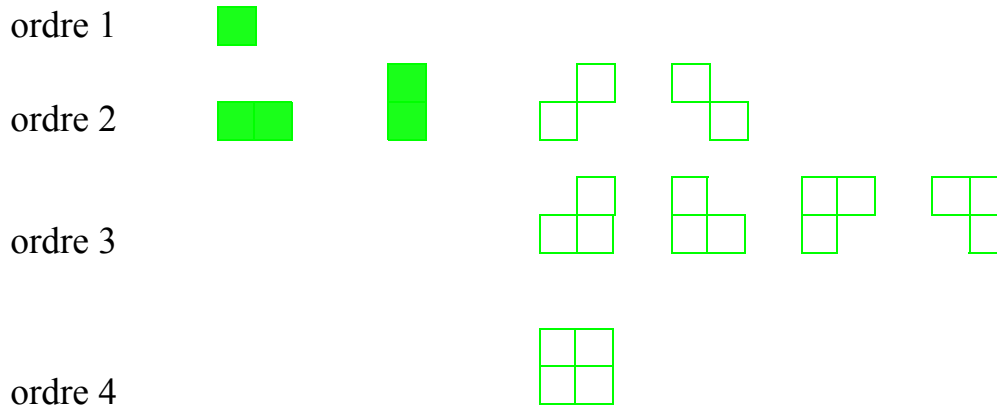
système de voisinage

$V(s)$                        $t \in V(s) \Leftrightarrow s \in V(t)$

$s \notin V(s)$



clique : ensemble de sites mutuellement voisins



### 3.2. propriété markovienne

$X$  : champ aléatoire défini sur  $S$

$x$  : réalisation particulière de  $X$

$X$  est un champ de Markov ssi

$$P(x) > 0$$

$$P(x_s | x_t, t \neq s) = P(x_s | x_t, t \in V(s))$$

### 3.3. Théorème de Hammersley-Clifford

$X$  est un champ de Markov ssi  $X$  suit une distribution de Gibbs.

$$P(x) = \frac{1}{Z(T)} \exp\left(-\frac{U(x)}{T}\right) \quad T : \text{paramètre de Température}$$

$$Z(T) = \sum_x \exp\left(-\frac{U(x)}{T}\right) \quad \text{constante de normalisation}$$

(difficile à calculer)

$$U(x) = \sum_{c \in C} V_c(t_1, t_2, \dots) \quad \text{avec } (t_1, t_2, \dots) \in c$$

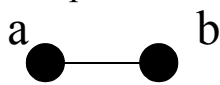
$V_c(t_1, t_2, \dots)$  : potentiel de la clique  $c$

conséquence

$$P(x_s = v | x_t, t \in V(s)) = \frac{\exp\left(-\frac{1}{T} \sum_{c \ni s} V_c(x_s = v, x_t \dots)\right)}{\sum_w \exp\left(-\frac{1}{T} \sum_{c \ni s} V_c(x_s = w, x_t \dots)\right)}$$

peu de termes à calculer

exemple :



$V(x_a, x_b) = (x_a - x_b)^2$  favorise les intensités proches

### 3.4. synthèse d'un champ de Markov

choisir :  
 système de voisinage  
 ordre des cliques  
 fonctions potentiels  
 paramètre de 'température'

échantillonneur de Gibbs

étape 0 : tirer une configuration  $x^0$  au hasard

....

étape n : ...

étape n+1 :

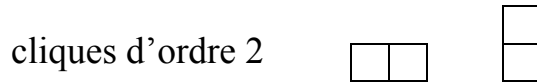
balayer tous les pixels

calculer  $P(x_s = v | x^n_t, t \in V(s))$

tirer au hasard la valeur  $x_s^{n+1}$  selon la loi ci-dessus

arrêt      au bout d'un nombre déterminé d'itérations  
             énergie  $U(x)$  n'évolue plus

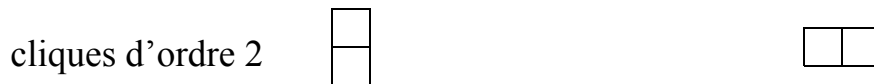
### exemple : Modèle d'Ising champ aléatoire binaire



potentiels  $V_c(x_s, x_t) = -b$  si  $x_s = x_t$   
 $V_c(x_s, x_t) = +b$  sinon

### exemples

On peut introduire des contraintes de formes à l'aide des fonctions potentiels

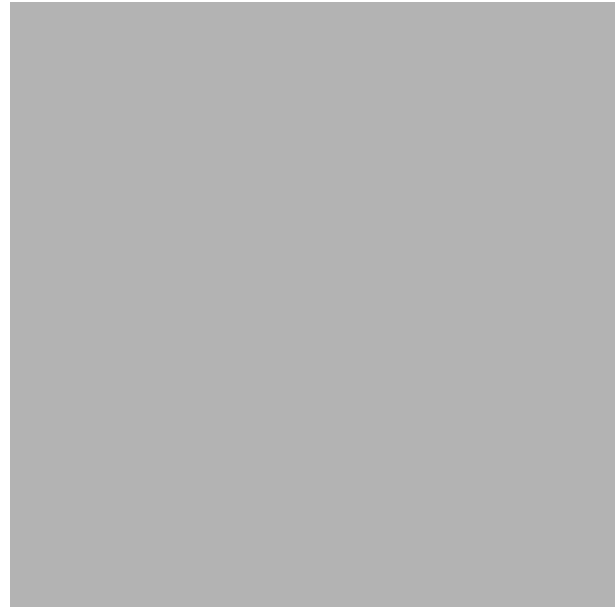


potentiels  $V_c(x_s, x_t) = -b1$  si  $x_s = x_t$   $V_c(x_s, x_t) = -b2$   
 $V_c(x_s, x_t) = +b1$  sinon  $V_c(x_s, x_t) = +b2$

exemple



initialisation



décroissance de l'énergie



image finale (35 itérations)

T=2

b1=5

b2=-0.1

### 3.5. application en segmentation ou restauration d'image

segmentation

Y : champ des étiquettes de région (classe), modèle markovien

X : champ des observations

problème : trouver Y sachant X

méthode MAP : chercher la configuration y maximisant  $P(Y=y|X=x)$

$$Y = y$$

$$P(Y = y|X = x) = \frac{P(X = x|Y = y)P(Y = y)}{P(X = x)}$$

pour une réalisation x donnée, P(x)=constante

-> maximiser le numérateur

Y : champ markovien -> énergie U1(y)

X|Y : champ markovien -> énergie U2(x|y)

il faut maximiser

$$P(X = x|Y = y)P(Y = y) = \frac{\exp\left(-\frac{U2(x|y)}{T}\right) \exp\left(-\frac{U1(y)}{T}\right)}{K2 \quad K1}$$

solution : minimiser l'énergie globale U(y)=U1(y)+U2(x|y), x connu.

méthode :

initialiser une configuration y

synthétiser un champ de Markov par échantillonneur de Gibbs

commencer avec T élevée, puis faire décroître T

☐ méthode du recuit simulé

☐ optimisation stochastique

exemple :

- T initiale = 40

- loi de décroissance :  $T^{n+1} = 0.98 * T^n$  jusqu'à T=1

- 60 itérations



initialisation



décroissance de l'énergie



configuration calculée

□ possibilité de **sortir d'un minimum local** si T élevée

restauration

Y : autant d'étiquettes de classe que de niveaux de gris, modèle markovien

X : champ des observations

problème : trouver Y sachant X

méthode MAP : chercher la configuration y maximisant  $P(Y=y|X=x)$

même situation que précédemment mais avec plus d'étiquettes

### 3.6. cas limites

□ T infinie : toutes les configurations sont équiprobables

$$P(x_s = v | x_t, t \in V(s)) = \frac{\exp\left(-\frac{1}{T} \sum_{c \ni s} V_c(x_s = v, x_t \dots)\right)}{\sum_w \exp\left(-\frac{1}{T} \sum_{c \ni s} V_c(x_s = w, x_t \dots)\right)}$$

□ T = 0 : sélection de la (ou d'une) configuration d'énergie minimale

$$a = \operatorname{argmin}_{c \ni s} \left( \sum V_c(x_s = v, x_t \dots) \right)$$

$$P(x_s = a | x_t, t \in V(s)) = 1$$

#### □ quelques cas particuliers

énergie U1 : régularisation spatiale

potentiel d'une clique

$$V(y_s, y_t) = (y_s - y_t)^2$$

énergie U2 : attache aux données

modèle de type bruit blanc

$$V(x_s | y_s) = (y_s - x_s)^2$$

solution : filtre moyennneur

solution itérée : filtrage linéaire gaussien

potentiels en

$$V(a, b) = |a - b|$$

solution : filtre médian

solution itérée : processus complexe => plateaux + transitions monotones

potentiels en

$$V(a, b) = |a - b|^\infty$$

solution : filtre milieu