

# Méthodes de Monte Carlo en Vision Stéréoscopique

Application à l'Etude de Modèles Numériques de Terrain


Julien Sénégas

senegas@cg.ensmp.fr




# **Vision stéréoscopique**

## ⑥ Couple stéréoscopique




Extrait d'un couple stéréoscopique SPOT - Région d'Aix-Marseille.

# Des coordonnées images aux coordonnées 3D




Systeme stéréoscopique composé de 2 caméras projectives linéaires parallèles.

# Des coordonnées images aux coordonnées 3D




Définition de la disparité en géométrie épipolaire.

# Mise en correspondance par corrélation





Calcul de la disparité par maximisation de la corrélation.

# Mise en correspondance par corrélation



Calcul de la disparité par maximisation de la corrélation.



# Mise en correspondance par corrélation



Calcul de la disparité par maximisation de la corrélation.




# Mise en correspondance par corrélation



Calcul de la disparité par maximisation de la corrélation.

## ⑥ Calcul de la disparité



Carte de disparité du couple d'Aix-Marseille. ⑥

# Formulation du problème

# Un problème inverse

Soit  $C_{u,v}(d)$  une mesure de la similarité des images  $I_1$  et  $I_2$  au voisinage du point  $(u, v)$  pour une disparité  $d$ .

# Un problème inverse

Soit  $C_{u,v}(d)$  une mesure de la similarité des images  $I_1$  et  $I_2$  au voisinage du point  $(u, v)$  pour une disparité  $d$ .

L'estimation de la disparité est un **problème inverse** dont une solution est donnée par **optimisation** :

$$\hat{d}(u, v) = \arg \max_d C_{u,v}(d)$$

# Un problème inverse

Soit  $C_{u,v}(d)$  une mesure de la similarité des images  $I_1$  et  $I_2$  au voisinage du point  $(u, v)$  pour une disparité  $d$ .

L'estimation de la disparité est un **problème inverse** dont une solution est donnée par **optimisation** :

$$\hat{d}(u, v) = \arg \max_d C_{u,v}(d)$$

Problème d'information :

- similarité locale entre les 2 images non vérifiée (bruit d'acquisition ☹, déformations géométriques ☹, ...),
- information radiométrique non discriminante (faible contraste ☹, périodicité, ...).

## 6 Formulation bayésienne

L'**ensemble** des solutions est décrit par la distribution de probabilité *a posteriori* de la disparité  $D$  connaissant le couple stéréoscopique  $Y = (I_1, I_2)$  :

$$\pi_D(d|y) \propto L(y|d)\pi_D(d)$$

## 6 Formulation bayésienne

L'**ensemble** des solutions est décrit par la distribution de probabilité ***a posteriori*** de la disparité  $D$  connaissant le couple stéréoscopique  $Y = (I_1, I_2)$  :

$$\pi_D(d|y) \propto L(y|d)\pi_D(d)$$

- $L(.|d)$  est la **vraisemblance** du couple  $Y$  à  $D = d$  fixé,
- $\pi_D(.)$  est la distribution ***a priori*** de la disparité  $D$ .



## 6 Formulation bayésienne

L'**ensemble** des solutions est décrit par la distribution de probabilité ***a posteriori*** de la disparité  $D$  connaissant le couple stéréoscopique  $Y = (I_1, I_2)$  :

$$\pi_D(d|y) \propto L(y|d)\pi_D(d)$$

- $L(.|d)$  est la **vraisemblance** du couple  $Y$  à  $D = d$  fixé,
- $\pi_D(.)$  est la distribution ***a priori*** de la disparité  $D$ .

Analyser l'incertitude liée à l'estimation de la disparité  $D$  :  
étudier la distribution ***a posteriori***  $\pi_D(.|y)$ .

# Un problème d'échantillonnage

Reformulation du problème initial :

# Un problème d'échantillonnage

Reformulation du problème initial :

- **choix** du modèle stochastique pour

$$\pi_D(d|y) \propto L(y|d)\pi_D(d),$$

# Un problème d'échantillonnage

Reformulation du problème initial :

- **choix** du modèle stochastique pour

$$\pi_D(d|y) \propto L(y|d)\pi_D(d),$$

- calcul d'intégrales sous  $\pi_D(\cdot|y)$  par **Monte Carlo** à partir d'un échantillon  $\{z_k, k = 1, m\}$  de  $\pi_D(\cdot|y)$  :

$$\frac{1}{m} \sum_{k=1}^m g(z_k) \rightarrow \mathbb{E}_{\pi_D(\cdot|y)}(g) = \int_z g(z)\pi_D(z|y)dz,$$

# Un problème d'échantillonnage

Reformulation du problème initial :

- **choix** du modèle stochastique pour

$$\pi_D(d|y) \propto L(y|d)\pi_D(d),$$

- calcul d'intégrales sous  $\pi_D(\cdot|y)$  par **Monte Carlo** à partir d'un échantillon  $\{z_k, k = 1, m\}$  de  $\pi_D(\cdot|y)$  :

$$\frac{1}{m} \sum_{k=1}^m g(z_k) \rightarrow \mathbb{E}_{\pi_D(\cdot|y)}(g) = \int_z g(z)\pi_D(z|y)dz,$$

- **échantillonnage** de la loi  $\pi_D(\cdot|y)$  à l'aide d'une chaîne de Markov  $\mathcal{Z} = (z_k)_{k \geq 0}$ .

# Choix du modèle stochastique

## ⑥ Vraisemblance : modèles gaussiens

Expression générale :

$$L(y|d) \propto \frac{1}{\sigma_l |C_l|^{\frac{1}{2}}} \exp \left( -\frac{1}{2\sigma_l^2} (\eta - m_l)^\top C_l^{-1} (\eta - m_l) \right)$$

avec  $\eta(u, v) = I_1(u, v) - I_2(u + d(u, v), v)$  (intensité résiduelle)

## ⑥ Vraisemblance : modèles gaussiens

Expression générale :

$$L(y|d) \propto \frac{1}{\sigma_l |C_l|^{\frac{1}{2}}} \exp \left( -\frac{1}{2\sigma_l^2} (\eta - m_l)^\top C_l^{-1} (\eta - m_l) \right)$$

avec  $\eta(u, v) = I_1(u, v) - I_2(u + d(u, v), v)$  (intensité résiduelle)

Choix possibles :

- modèle de bruit additif **non corrélé** (GMF-0) :  $C_l^{-1} = I$ ,
- modèle avec **structure spatiale** (GMF-1) :  $C_l^{-1}$  est la matrice de précision ⑥ d'un champ de Markov de paramètre spatial  $\rho$ .



## ⑥ Vraisemblance : modèle de mélange

But : prendre en compte l'existence de valeurs aberrantes du résidu :

$$L(y|d) \propto \prod_{u,v} (p_{l_1} \phi_1(\eta_{u,v}) + p_{l_2} \phi_2(\eta_{u,v}))$$

## 6 Vraisemblance : modèle de mélange

But : prendre en compte l'existence de valeurs aberrantes du résidu :

$$L(y|d) \propto \prod_{u,v} (p_{l_1} \phi_1(\eta_{u,v}) + p_{l_2} \phi_2(\eta_{u,v}))$$

Modèle de mélange (MIXT) :

- une loi gaussienne  $\phi_1$  modélisant le bruit d'acquisition (non corrélé spatialement),
- une loi uniforme ou gaussienne  $\phi_2$  de variance élevée modélisant les valeurs fortes (dus par exemple à la violation de l'hypothèse lambertienne).

# Modèle *a priori*

Cadre des fonctions aléatoires gaussiennes (Belhumeur, 1996, Szeliski, 1989) :

$$\pi_D(d) \propto \frac{1}{\sigma_p |C_p|^{\frac{1}{2}}} \exp \left( -\frac{1}{2\sigma_p^2} (d - m_p)^\top C_p^{-1} (d - m_p) \right)$$

# Modèle *a priori*

Cadre des fonctions aléatoires gaussiennes (Belhumeur, 1996, Szeliski, 1989) :

$$\pi_D(d) \propto \frac{1}{\sigma_p |C_p|^{\frac{1}{2}}} \exp \left( -\frac{1}{2\sigma_p^2} (d - m_p)^\top C_p^{-1} (d - m_p) \right)$$

Deux approches :

- Modèle stationnaire :  $m_p$  constante et  $C_p$  stationnaire,
- Modèle avec dérive :  $m_p$  varie et  $C_p$  stationnaire.

# Modèle *a priori*

Cadre des fonctions aléatoires gaussiennes (Belhumeur, 1996, Szeliski, 1989) :

$$\pi_D(d) \propto \frac{1}{\sigma_p |C_p|^{\frac{1}{2}}} \exp \left( -\frac{1}{2\sigma_p^2} (d - m_p)^\top C_p^{-1} (d - m_p) \right)$$

Deux approches :

- Modèle stationnaire :  $m_p$  constante et  $C_p$  stationnaire,
- Modèle avec dérive :  $m_p$  varie et  $C_p$  stationnaire.

Difficulté : comment sortir de l'hypothèse stationnaire et prendre en compte une dérive ?

# Modèle *a priori*

Cadre des fonctions aléatoires gaussiennes (Belhumeur, 1996, Szeliski, 1989) :

$$\pi_D(d) \propto \frac{1}{\sigma_p |C_p|^{\frac{1}{2}}} \exp \left( -\frac{1}{2\sigma_p^2} (d - m_p)^\top C_p^{-1} (d - m_p) \right)$$




Deux approches :

- Modèle stationnaire :  $m_p$  constante et  $C_p$  stationnaire,
- Modèle avec dérive :  $m_p$  varie et  $C_p$  stationnaire.

Modèle de disparité résiduelle : prendre  $m_p = \hat{d}$  et modéliser le résidu par un champ de Markov.


# Résultats

# Cas d'étude

- couple stéréoscopique (taille  $2048 \times 2048$ ) SPOT ,
- carte de disparité calculée par corrélation (taille  $1024 \times 1024$ ) ,
- modèle *a priori* de disparité résiduelle, et modèle de vraisemblance GMF-0,
- 2000 simulations générées (taille  $1024 \times 1024$ , temps CPU : 16H) ,
- validation sur un extrait (taille  $256 \times 256$ ) à partir d'une carte de disparité de référence (haute-résolution).




# Statistiques globales



Moyenne des simulations. 6

# Statistiques globales



Ecart type des simulations. 6

# Vers une mesure de l'incertitude

But : à partir d'une estimation  $\hat{d}$  de la disparité et d'un **niveau d'erreur  $s$** , localiser les points pour lesquels l'erreur dépasse  $s$ .

# Vers une mesure de l'incertitude

But : à partir d'une estimation  $\hat{d}$  de la disparité et d'un **niveau d'erreur**  $s$ , localiser les points pour lesquels l'erreur dépasse  $s$ .

⇒ calculer pour chaque point  $(u, v)$  la **probabilité** :


$$P \left( D - \hat{d} \geq s \right) \approx \frac{1}{m} \sum_{k=1}^m 1_{z_k - \hat{d} \geq s}, \quad s \geq 0$$

# Vers une mesure de l'incertitude

But : à partir d'une estimation  $\hat{d}$  de la disparité et d'un **niveau d'erreur  $s$** , localiser les points pour lesquels l'erreur dépasse  $s$ .

⇒ mesure de l'incertitude **locale**.

## ⑥ Probabilités ponctuelles de dépassement de seuil



Probabilité d'erreurs positives supérieures à 2 pixels. ⑥

# Vers une mesure de l'incertitude

But : à partir d'une estimation  $\hat{d}$  de la disparité et d'un **niveau d'erreur  $s$** , localiser les points pour lesquels l'erreur dépasse  $s$  *n'importe où sur un domaine  $T$* .

# Vers une mesure de l'incertitude

But : à partir d'une estimation  $\hat{d}$  de la disparité et d'un **niveau d'erreur**  $s$ , localiser les points pour lesquels l'erreur dépasse  $s$  *n'importe où sur un domaine*  $T$ .

⇒ calculer pour chaque domaine  $T$  la **probabilité** :

$$P \left( (D - \hat{d})_T \geq s \right) \approx \frac{1}{m} \sum_{k=1}^m 1_{\max_T (z_k - \hat{d}) \geq s}, \quad s \geq 0$$




# Vers une mesure de l'incertitude

But : à partir d'une estimation  $\hat{d}$  de la disparité et d'un **niveau d'erreur**  $s$ , localiser les points pour lesquels l'erreur dépasse  $s$  *n'importe où sur un domaine*  $T$ .

⇒ nécessite la connaissance de la distribution **multi-variable** (et non seulement marginale).

# Probabilités sur un domaine de dépassement de seuil



Probabilité d'erreurs positives supérieures à 3 pixels. 6

# Validation : Dépassement de seuil

<i>a priori</i>	stationnaire			dérive	
	GMF-0	GMF-1	MIXT	GMF-0	MIXT
vraisemblance					
$s = 2, \alpha = 10\%$	13.10	13.24	13.89	17.50	24.44
$s = -2, \alpha = 10\%$	8.87	8.47	7.84	25.00	40.32
$s = 2, \alpha = 5\%$	5.81	6.68	6.23	11.33	14.43
$s = -2, \alpha = 5\%$	5.73	5.99	5.10	19.07	27.27

% de points erronnés en fonction du seuil  $s$  et du risque  $\alpha$ .

# Validation : Limites de confiance

<i>a priori</i>	stationnaire			dérive	
vraisemblance	GMF-0	GMF-1	MIXT	GMF-0	MIXT
$[d_{\text{inf}}, +\infty[ (0.05)$	0.23	0.38	0.08	0.57	0.08
$] -\infty, d_{\text{sup}}] (0.05)$	0.69	0.83	0.57	0.12	0.03
$[d_{\text{inf}}, d_{\text{sup}}] (0.1)$	0.92	1.22	0.66	0.69	0.11

Risques (en %) associés aux limites de confiance.

# Estimation des paramètres du modèle

# Point de vue bayésien

Prendre en compte l'incertitude sur les paramètres en les **randomisant**.

⇒ simulation conjointe des paramètres et de la disparité.

# Point de vue bayésien

Prendre en compte l'incertitude sur les paramètres en les **randomisant**.

⇒ simulation conjointe des paramètres et de la disparité.

Le modèle (hiérarchique) à simuler devient :

$$\pi_{D, \Theta_p, \Theta_l}(d, \theta_p, \theta_l | y) \propto L(y | d, \theta_l) \pi_D(d | \theta_p) \pi_{\Theta_p}(\theta_p) \pi_{\Theta_l}(\theta_l)$$

# Point de vue bayésien

Prendre en compte l'incertitude sur les paramètres en les **randomisant**.

⇒ simulation conjointe des paramètres et de la disparité.

Le modèle (hiérarchique) à simuler devient :

$$\pi_{D, \Theta_p, \Theta_l}(d, \theta_p, \theta_l | y) \propto L(y | d, \theta_l) \pi_D(d | \theta_p) \pi_{\Theta_p}(\theta_p) \pi_{\Theta_l}(\theta_l)$$

Simulation par l'échantillonneur de Gibbs :

1.  $d | y, \theta_p, \theta_l \sim L(y | d, \theta_l) \pi_D(d | \theta_p),$
2.  $\theta_l | y, d \sim L(y | d, \theta_l) \pi_{\Theta_l}(\theta_l),$
3.  $\theta_p | d \sim \pi_D(d | \theta_p) \pi_{\Theta_p}(\theta_p),$
4. retour en 1.



# Algorithme EM stochastique

Approche similaire, où l'on substitue à l'étape de simulation de  $\theta_l$  et  $\theta_p$  une étape d'estimation par **maximum de vraisemblance**.

# Algorithme EM stochastique


Approche similaire, où l'on substitue à l'étape de simulation de  $\theta_l$  et  $\theta_p$  une étape d'estimation par **maximum de vraisemblance**.

Algorithme SEM :


1.  $d|y, \hat{\theta}_p, \hat{\theta}_l \sim L(y|d, \hat{\theta}_l)\pi_D(d|\hat{\theta}_p),$
2. estimation par MLE :  $\hat{\theta}_l = \arg \max_{\theta_l} L(y|d, \theta_l),$
3. estimation par MLE :  $\hat{\theta}_p = \arg \max_{\theta_p} \pi_D(d|\theta_p),$
4. retour en 1.

# Paramètres du modèle GMF-0


Ecart Type - Simulation




Ecart Type - SEM



Histogramme - Simulation




Histogramme - SEM




Estimation de l'écart type du modèle GMF-0  par simulation et algorithme SEM

# Paramètres du modèle de mélange


Proportion de melange - Simulation




Proportion de melange - SEM




Histogramme - Simulation



Histogramme - SEM



Estimation du paramètre de mélange du modèle de mélange  par simulation et algorithme SEM

# **Simulations spatiales par itérations markoviennes**

# Présentation du problème

Soit :

- $S = \{1, \dots, n\}$  un ensemble fini de sites,
- $Z$  un vecteur aléatoire défini sur  $S$ , à valeurs dans  $E$ , muni de la tribu  $\mathcal{E}$ .

# Présentation du problème

Soit :

- $S = \{1, \dots, n\}$  un ensemble fini de sites,
- $Z$  un vecteur aléatoire défini sur  $S$ , à valeurs dans  $E$ , muni de la tribu  $\mathcal{E}$ .

On note :

- $\pi$  la loi de  $Z$ ,
- $\pi(z)$  la (densité de) probabilité de l'état  $z$ ,
- $(z_1, \dots, z_m)$  un  $m$ -échantillon de loi  $\pi$ .

# Présentation du problème

Soit :

- $S = \{1, \dots, n\}$  un ensemble fini de sites,
- $Z$  un vecteur aléatoire défini sur  $S$ , à valeurs dans  $E$ , muni de la tribu  $\mathcal{E}$ .

On note :

- $\pi$  la loi de  $Z$ ,
- $\pi(z)$  la (densité de) probabilité de l'état  $z$ ,
- $(z_1, \dots, z_m)$  un  $m$ -échantillon de loi  $\pi$ .

Problème : simuler la loi  $\pi$



# Invariance et réversibilité d'une chaîne de Markov

Soit  $\mathcal{Z} = (z_k)_{k \geq 0}$  une chaîne de Markov de noyau de transition  $K$ .

Condition nécessaire de convergence vers  $\pi$  : **invariance** de  $\pi$  sous  $K$ , soit :

$$\int_E \pi(z) K(z, A) dz = \pi(A), \quad \forall A \in \mathcal{E}$$

# Invariance et réversibilité d'une chaîne de Markov

Soit  $\mathcal{Z} = (z_k)_{k \geq 0}$  une chaîne de Markov de noyau de transition  $K$ .

Condition nécessaire de convergence vers  $\pi$  : **invariance** de  $\pi$  sous  $K$ , soit :

$$\int_E \pi(z) K(z, A) dz = \pi(A), \quad \forall A \in \mathcal{E}$$

Une condition suffisante d'invariance est la propriété de **réversibilité** :

$$\pi(z) K(z, z') = \pi(z') K(z', z), \quad \forall z, z' \in E^2$$

# Metropolis-Hastings

Idée (Hastings, 1970) : construire un noyau de transition réversible pour  $\pi$  à partir d'un noyau (de proposition)  $q(z, \cdot)$ .

# Metropolis-Hastings

Idée (Hastings, 1970) : construire un noyau de transition réversible pour  $\pi$  à partir d'un noyau (de proposition)  $q(z, \cdot)$ .

- **proposition** : on génère un nouvel état  $z'$  selon  $q(z, z')$ ,
- **acceptation** :  $z'$  est accepté avec la probabilité  $a(z, z')$ .

# Metropolis-Hastings

Idée (Hastings, 1970) : construire un noyau de transition réversible pour  $\pi$  à partir d'un noyau (de proposition)  $q(z, \cdot)$ .

- **proposition** : on génère un nouvel état  $z'$  selon  $q(z, z')$ ,
- **acceptation** :  $z'$  est accepté avec la probabilité  $a(z, z')$ .

Condition de réversibilité :

$$\pi(z)q(z, z')a(z, z') = \pi(z')q(z', z)a(z', z) \text{ si } z' \neq z$$

# Metropolis-Hastings

Idée (Hastings, 1970) : construire un noyau de transition réversible pour  $\pi$  à partir d'un noyau (de proposition)  $q(z, \cdot)$ .

- **proposition** : on génère un nouvel état  $z'$  selon  $q(z, z')$ ,
- **acceptation** :  $z'$  est accepté avec la probabilité  $a(z, z')$ .

Condition de réversibilité :

$$\pi(z)q(z, z')a(z, z') = \pi(z')q(z', z)a(z', z) \text{ si } z' \neq z$$

- dynamique de Barker :  $a(z, z') = \frac{\pi(z')q(z', z)}{\pi(z)q(z, z') + \pi(z')q(z', z)}$
- dynamique de Metropolis :  $a(z, z') = \min \left( 1, \frac{\pi(z')q(z', z)}{\pi(z)q(z, z')} \right)$

# Metropolis-Hastings Multiple

Soit un entier  $p$  fixé. Un noyau de **transition multiple** (“échangeable”) sur  $E^p \times E$  est une application  $q(.|.)$  telle que :

$$q(z'_1, \dots, z'_p | z) = q(z'_{\sigma(1)}, \dots, z'_{\sigma(p)} | z)$$

pour toute permutation  $\sigma$  de  $\{1, \dots, p\}$ .

# Metropolis-Hastings Multiple

Soit un entier  $p$  fixé. Un noyau de **transition multiple** (“échangeable”) sur  $E^p \times E$  est une application  $q(.|.)$  telle que :

$$q(z'_1, \dots, z'_p | z) = q(z'_{\sigma(1)}, \dots, z'_{\sigma(p)} | z)$$

pour toute permutation  $\sigma$  de  $\{1, \dots, p\}$ .

Algorithme :

- **proposition** : on génère un ensemble  $(z'_1, \dots, z'_p)$  selon  $q(z'_1, \dots, z'_p | z)$ ,
- **acceptation** :  $z' = z'_i$  avec la probabilité  $a(z, z'_i)$ , et  $z' = z$  avec la probabilité  $1 - \sum_{i=1}^p a(z, z'_i)$ .



# Choix de la probabilité d'acceptation

Généralisation de la dynamique de Barker :

$$a(z, z'_i) = \frac{\pi(z'_i)q(z'^i, z|z'_i)}{\sum_{j=1}^p \pi(z'_j)q(z'^j, z|z'_j) + \pi(z)q(z'_1, \dots, z'_p|z)}, \quad i = 1, p$$

# Choix de la probabilité d'acceptation

Généralisation de la dynamique de Barker :

$$a(z, z'_i) = \frac{\pi(z'_i)q(z'^i, z|z'_i)}{\sum_{j=1}^p \pi(z'_j)q(z'^j, z|z'_j) + \pi(z)q(z'_1, \dots, z'_p|z)}, \quad i = 1, p$$

**Propriété:** *Le noyau de transition généré par un noyau multiple associé à la dynamique de Barker généralisée est  $\pi$ -réversible.*

# Le cas gaussien

On utilise comme loi auxiliaire la loi gaussienne  $\phi$ .

# Le cas gaussien

On utilise comme loi auxiliaire la loi gaussienne  $\phi$ .

Algorithme :

1. on simule  $w$  selon  $\phi$ , indépendamment de  $z$ ,
2. chaque état  $z'_i$  est généré par la combinaison linéaire :

$$z'_i = z \cos \theta_i + w \sin \theta_i, \quad \theta_i \in [0, 2\pi[, \quad i = 1, p.$$

3. acceptation :  $a(z, z'_i) = \frac{r(z'_i)}{\sum_{j=0}^p r(z'_j)}$ ,  $r(z) = \frac{\pi(z)}{\phi(z)}$

# Le cas gaussien

On utilise comme loi auxiliaire la loi gaussienne  $\phi$ .

Algorithme :


1. on simule  $w$  selon  $\phi$ , indépendamment de  $z$ ,
2. chaque état  $z'_i$  est généré par la combinaison linéaire :

$$z'_i = z \cos \theta_i + w \sin \theta_i, \quad \theta_i \in [0, 2\pi[, \quad i = 1, p.$$

3. acceptation :  $a(z, z'_i) = \frac{r(z'_i)}{\sum_{j=0}^p r(z'_j)}$ ,  $r(z) = \frac{\pi(z)}{\phi(z)}$


**Propriété:** *Le noyau multiple gaussien avec  $\theta_i = i \frac{2\pi}{p+1}$  vérifie la relation de  $\pi$ -multi-réversibilité.*

# Transition




Loi cible bivariable  $\pi$  et état courant  $z$ .

# Transition



Utilisation d'un noyau de transition  $q$ .


# Transition



Proposition d'une transition vers  $z'$  (MH).




# Transition



Construction d'un ensemble de transitions.

# Transition



Proposition d'un transition vers  $z'$  (MMH).

# Liens avec d'autres algorithmes

- Sur-relaxation (Barone, 1990, Green, 1992, Galli, 2001) : simulation d'une loi gaussienne selon la transition :

$$z' \sim \phi \left( \frac{z' - \omega z}{\sqrt{1 - \omega^2}} \right), \quad \omega \in [-1, 1]$$

Cette transition est toujours acceptée dans Metropolis, quel que soit  $\omega$ .

# Liens avec d'autres algorithmes

- Sur-relaxation (Barone, 1990, Green, 1992, Galli, 2001) : simulation d'une loi gaussienne selon la transition :

$$z' \sim \phi \left( \frac{z' - \omega z}{\sqrt{1 - \omega^2}} \right), \quad \omega \in [-1, 1]$$

Cette transition est toujours acceptée dans Metropolis, quel que soit  $\omega$ .

- Déformation graduelle (Hu, 2000) : choix du paramètre  $\theta$  dans  $z' = z \cos \theta + w \sin \theta$  qui minimise une fonction de coût donnée.

# Conclusion et Perspectives

# Modélisation stochastique

Proposition et comparaison de différents modèles :

- relative robustesse vis-à-vis du modèle de vraisemblance,
- limites de l'hypothèse stationnaire, intérêt pratique du modèle de disparité résiduelle.

# Modélisation stochastique

Proposition et comparaison de différents modèles :

- relative robustesse vis-à-vis du modèle de vraisemblance,
- limites de l'hypothèse stationnaire, intérêt pratique du modèle de disparité résiduelle.

Limites :

- grande subjectivité et influence du modèle *a priori* (et donc validation indispensable),
- quel estimateur pour les paramètres (Descombes *et al*, 1999, Hurn *et al*, 2002) ?

# Modélisation stochastique

Proposition et comparaison de différents modèles :

- relative robustesse vis-à-vis du modèle de vraisemblance,
- limites de l'hypothèse stationnaire, intérêt pratique du modèle de disparité résiduelle.

Développements :

- passer de modèles de bas-niveau (niveau de gris) à des modèles de haut-niveau (objets stochastiques),
- généralisation à d'autres systèmes stéréoscopiques (haute résolution),
- modélisation plus fine du système : occlusions, intensité résiduelle,...



# Algorithmes de simulation par chaînes de Markov

Metropolis-Hastings multiple :

- extension de l'algorithme de Metropolis-Hastings,
- cas gaussien d'un grand intérêt pratique.

# Algorithmes de simulation par chaînes de Markov

Metropolis-Hastings multiple :

- extension de l'algorithme de Metropolis-Hastings,
- cas gaussien d'un grand intérêt pratique.

Développement :

- comparaison avec l'algorithme de sur-relaxation,
- influence et choix de la dimension de l'échantillonneur,
- généralisation de la dynamique de Metropolis ?
- propriétés de convergence...

# Approche générale

Formulation du problème en termes :

- de distribution *a posteriori* (l'objet),
- d'intégrales de Monte Carlo (la propriété),
- d'algorithmes d'échantillonnage (l'outil).

# Approche générale

Formulation du problème en termes :

- de distribution *a posteriori* (l'objet),
- d'intégrales de Monte Carlo (la propriété),
- d'algorithmes d'échantillonnage (l'outil).

Perspectives :

- approche applicable à tout problème inverse,
- étude plus fine via la distribution,
- besoin d'algorithmes de simulation performants.

**Merci !** 



# Appendix

## ⑥ Différences radiométriques importantes



Exemples de différence radiométrique importante due au changement de la scène (diachronisme), ici dans le cas de champs.

## ⑥ Déformations géométriques, ombres



Exemples de déformations géométriques importantes, ici dans une région montagneuse. A noter également la présence d'ombres dues au relief.



# Modèle de vraisemblance

Modèle de formation d'images (sous hypothèse lambertienne) :

$$\begin{aligned} I_1(u, v) &= \psi (I(x, y, z) \star \zeta) + \eta_1(u, v) \\ I_2(u + d(u, v), v) &= \psi (I(x, y, z) \star \zeta) + \eta_2(u + d(u, v), v) \end{aligned}$$

# Modèle de vraisemblance

Modèle de formation d'images (sous hypothèse lambertienne) :

$$\begin{aligned}I_1(u, v) &= \psi (I(x, y, z) \star \zeta) + \eta_1(u, v) \\I_2(u + d(u, v), v) &= \psi (I(x, y, z) \star \zeta) + \eta_2(u + d(u, v), v)\end{aligned}$$

On définit alors l'**intensité résiduelle** :

$$\eta_{u,v} = I_1(u, v) - I_2(u + d(u, v), v)$$


Choisir un modèle de vraisemblance revient à modéliser l'intensité résiduelle  $\eta$ .

# ⑥ Champ de Markov d'ordre 1

$$C_l^{-1} = \begin{pmatrix} 2 & -\rho & & & & & -\rho & & & & \\ -\rho & 3 & -\rho & & & & & & -\rho & & \\ & \ddots & \ddots & \ddots & & & & & & \ddots & \\ & & -\rho & 3 & -\rho & & & & & -\rho & \\ -\rho & & & -\rho & 2 & 0 & & & & -\rho & \\ & -\rho & & & 0 & 3 & -\rho & & & & -\rho \\ & & & & -\rho & 4 & -\rho & & & & -\rho \\ & & \ddots & & & \ddots & \ddots & \ddots & & & \ddots \end{pmatrix}$$

Matrice de précision

## ⑥ Disparité calculée par corrélation




Carte de disparité du couple d'Aix-Marseille. ⑥

## ⑥ Image SPOT



Image gauche du couple d'Aix-Marseille. ⑥


# Probabilités ponctuelles de dépassement de seuil



Probabilité d'erreurs négatives supérieures à 2 pixels.



# Probabilités sur un domaine de dépassement de seuil



Probabilité d'erreurs négatives supérieures à 3 pixels.




# Probabilités sur un domaine de dépassement de seuil

<i>a priori</i>	stationnaire			dérive	
vraisemblance	GMF-0	GMF-1	MIXT	GMF-0	MIXT
biais	0.140	0.141	0.130	0.141	0.134
écart quad. moy.	0.273	0.265	0.273	0.163	0.147




# Validation


selection: seuil= 2,  $p > 0.05$




selection: seuil= 2,  $p < 0.05$



selection: seuil= -2,  $p > 0.05$




selection: seuil= -2,  $p < 0.05$




Fonctions de répartition expérimentales pour les seuils 2 et  $-2$  pixels et un risque de 5%.

# Validation


selection: seuil= 2,  $p > 0.1$




selection: seuil= 2,  $p < 0.1$



selection: seuil= -2,  $p > 0.1$



selection: seuil= -2,  $p < 0.1$



Fonctions de répartition expérimentales pour les seuils 2 et  $-2$  pixels et un risque de 10%.

# Approche empirique

Difficilé : l'information disponible (le couple stéréoscopique  $Y$ ) ne permet pas d'estimer directement les paramètres du modèle.

# Approche empirique

Difficilé : l'information disponible (le couple stéréoscopique  $Y$ ) ne permet pas d'estimer directement les paramètres du modèle.

Idée : utiliser la carte de disparité estimée  $\hat{d}$  .

- modèle *a priori* (stationnaire) : les paramètres  $\theta_p$  sont inférés manuellement (étude **variographique**),
- modèle de vraisemblance : les paramètres  $\theta_l$  sont estimés par **maximum de vraisemblance** (ou pseudo-vraisemblance (Besag, 1974)).

# Approche empirique

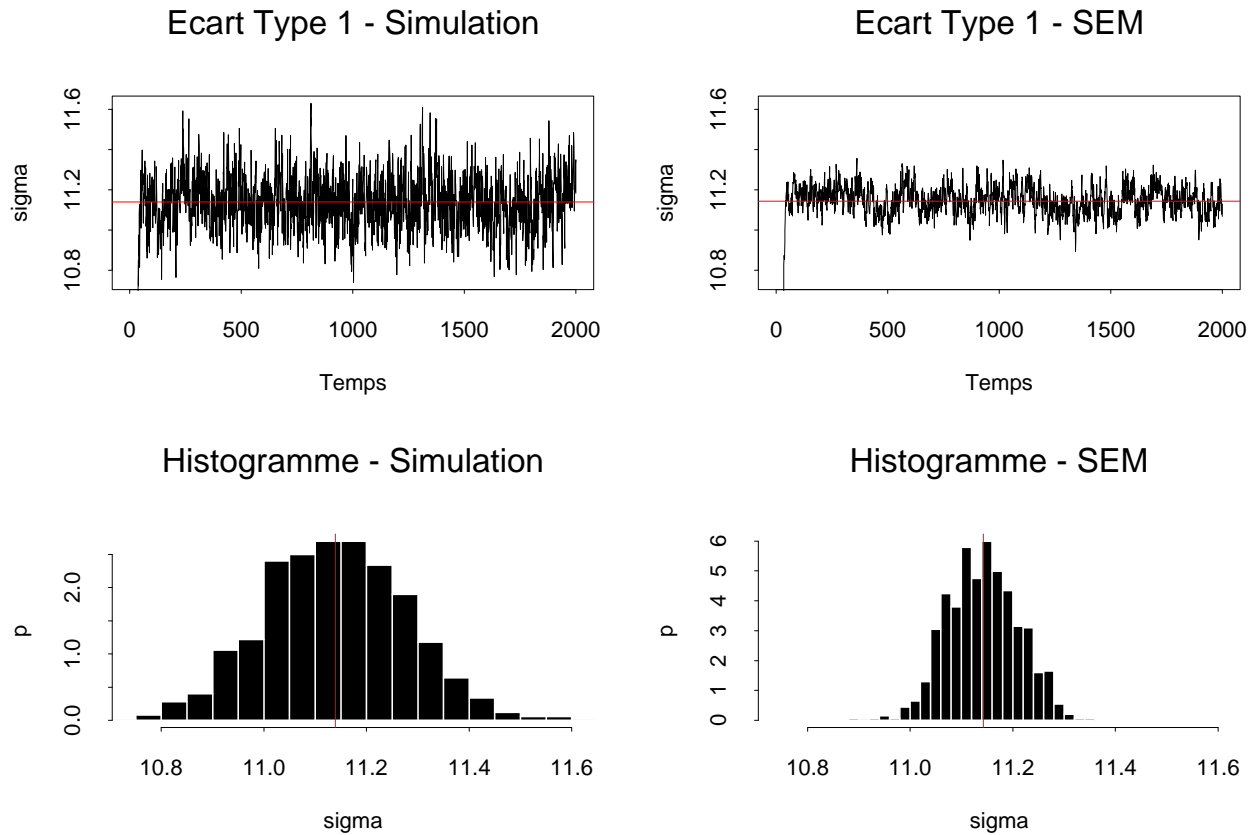
Difficilé : l'information disponible (le couple stéréoscopique  $Y$ ) ne permet pas d'estimer directement les paramètres du modèle.


Idée : utiliser la carte de disparité estimée  $\hat{d}$  .

- modèle *a priori* (stationnaire) : les paramètres  $\theta_p$  sont inférés manuellement (étude **variographique**),
- modèle de vraisemblance : les paramètres  $\theta_l$  sont estimés par **maximum de vraisemblance** (ou pseudo-vraisemblance (Besag, 1974)).

Limites :  $\hat{d}$  n'est qu'une estimation de  $d$ , possibilité de biais.


# Paramètres du modèle de mélange




Estimation de l'écart type 1 du modèle de mélange  par simulation et algorithme SEM

# Paramètres du modèle de mélange


Ecart Type 2 - Simulation




Ecart Type 2 - SEM




Histogramme - Simulation



Histogramme - SEM



Estimation de l'écart type 2 du modèle de mélange  par simulation et algorithme SEM