

*Méthodes par ensembles de niveaux et modes conditionnels  
itérés pour la segmentation vidéo*

Florent Ranchin,

Directeur de Recherches : Mme Françoise Dibos

CEREMADE, Université Paris Dauphine

## Plan général

- Segmentation d'objets en mouvement à partir du flot optique

## Plan général

- Segmentation d'objets en mouvement à partir du flot optique
- Application de l'ICM à deux problèmes de segmentation vidéo et de tracking

## Plan général

- Segmentation d'objets en mouvement à partir du flot optique
- Application de l'ICM à deux problèmes de segmentation vidéo et de tracking
- Algorithmes pour deux problèmes de vidéosurveillance

*Segmentation d'objets en mouvement à partir du flot  
optique*

# Plan

---

- Estimation du flot optique

# Plan

---

- Estimation du flot optique
- Dérivées de forme, optimisation de forme, théorèmes principaux

# Plan

---

- Estimation du flot optique
- Dérivées de forme, optimisation de forme, théorèmes principaux
- Segmentation d'objets en mouvement par contours actifs basés région avec flot optique précalculé




# Plan

---

- Estimation du flot optique
- Dérivées de forme, optimisation de forme, théorèmes principaux
- Segmentation d'objets en mouvement par contours actifs basés région avec flot optique précalculé
- Résultats expérimentaux

# Analyse d'une séquence d'images



Séquence d'images : suite finie de valeurs définies sur une grille rectangulaire pour chaque image de la séquence.

Prolongement de  $I$  à tout le domaine spatio-temporel :

$$(I(i, j, t_k))_{i,j,k} \longrightarrow I : D \times [0, T] \rightarrow \mathbb{R}, (\mathbf{x}, t) \mapsto I(\mathbf{x}, t)$$

## Détermination du flot optique

---

- Soit une séquence d'images  $I(\cdot, t)$ , l'intensité est constante le long d'une trajectoire  $\mathbf{x}(t)$

$$I(\mathbf{x}(t), t) = \text{cte} \iff \frac{DI}{Dt} = \langle \nabla_{\mathbf{x}} I, \mathbf{v} \rangle + I_t = 0 \text{ (OFC).}$$

## Détermination du flot optique

- Soit une séquence d'images  $I(\cdot, t)$ , l'intensité est constante le long d'une trajectoire  $\mathbf{x}(t)$

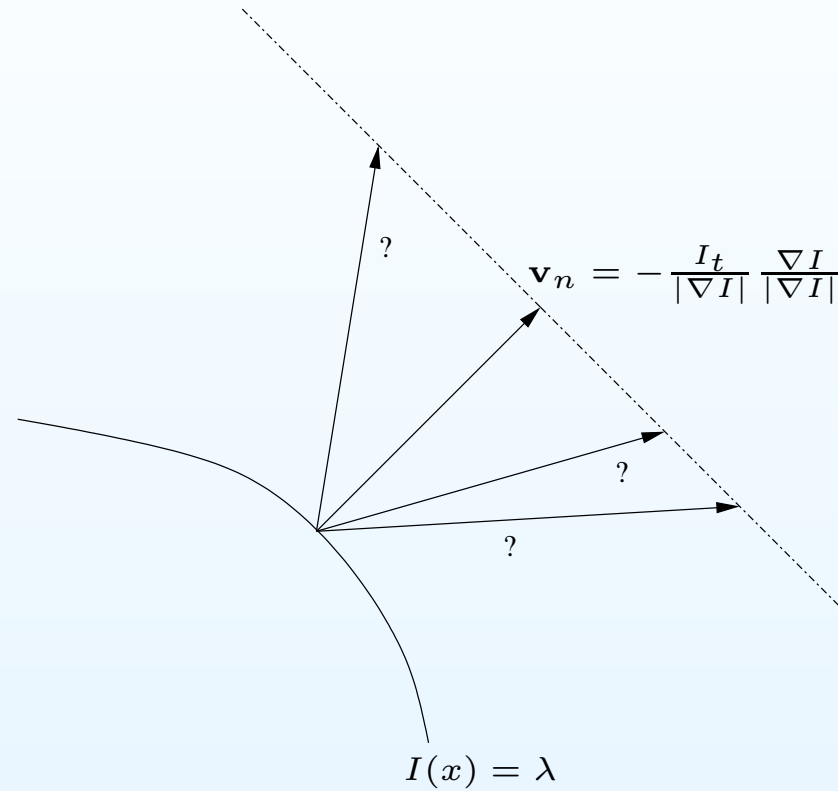
$$I(\mathbf{x}(t), t) = \text{cte} \iff \frac{DI}{Dt} = \langle \nabla_{\mathbf{x}} I, \mathbf{v} \rangle + I_t = 0 \text{ (OFC)}.$$

- L'OFC permet seulement de calculer le flot normal (problème d'*ouverture*)

$$\mathbf{v} = -\frac{I_t}{|\nabla I|} \mathbf{n} + \mu \mathbf{n}^\perp$$

( $\mathbf{n} = \frac{\nabla I}{|\nabla I|}$  normale à une ligne de niveau de  $I$ ) avec  $\mu$  indéterminé.

# Problème d'ouverture



## Méthode de Weickert/Schnörr

---


Méthode variationnelle où le flot optique est supposé régulier en temps et en espace

$$E(\mathbf{v}) = \int_{\Omega \times [0, T]} |\nabla I \cdot \mathbf{v} + I_t|^2 dx dy dt$$
$$+ \alpha \int_{\Omega \times [0, T]} \Psi \left( |\nabla^\theta v_1|^2 + |\nabla^\theta v_2|^2 \right) dx dy dt$$

## Méthode de Weickert/Schnörr

Méthode variationnelle où le flot optique est supposé régulier en temps et en espace

$$E(\mathbf{v}) = \int_{\Omega \times [0, T]} |\nabla I \cdot \mathbf{v} + I_t|^2 dx dy dt$$
$$+ \alpha \int_{\Omega \times [0, T]} \boxed{\Psi} \left( |\nabla^\theta v_1|^2 + |\nabla^\theta v_2|^2 \right) dx dy dt$$


$$\Psi(s^2) = \epsilon s^2 + (1 - \epsilon)\lambda^2 \sqrt{1 + \left(\frac{s}{\lambda}\right)^2}$$

## Méthode de Weickert/Schnörr

Méthode variationnelle où le flot optique est supposé régulier en temps et en espace

$$E(\mathbf{v}) = \int_{\Omega \times [0, T]} |\nabla I \cdot \mathbf{v} + I_t|^2 dx dy dt$$
$$+ \alpha \int_{\Omega \times [0, T]} \boxed{\Psi} \left( |\nabla^\theta v_1|^2 + |\boxed{\nabla^\theta} v_2|^2 \right) dx dy dt$$

$$\boxed{\Psi}(s^2) = \epsilon s^2 + (1 - \epsilon) \lambda^2 \sqrt{1 + \left(\frac{s}{\lambda}\right)^2}, \quad \nabla^\theta = \left( \frac{\partial}{\partial x}, \frac{\partial}{\partial y}, \frac{\partial}{\partial t} \right)^T$$

Si  $s \gg \lambda$  :  $\Psi(s^2) - \epsilon s^2 \sim (1 - \epsilon) \lambda |s| \implies$  variation totale.



# Résolution du problème de minimisation

Minimisation par descente de gradient sur l'énergie

$$\frac{\partial v_1}{\partial t} = \operatorname{div}^\theta \left( \Psi' \left( |\nabla^\theta v_1|^2 + |\nabla^\theta v_2|^2 \right) \nabla^\theta v_1 \right) - \frac{1}{\alpha} I_x (I_x v_1 + I_y v_2 + I_t)$$

$$\frac{\partial v_2}{\partial t} = \operatorname{div}^\theta \left( \Psi' \left( |\nabla^\theta v_1|^2 + |\nabla^\theta v_2|^2 \right) \nabla^\theta v_2 \right) - \frac{1}{\alpha} I_y (I_x v_1 + I_y v_2 + I_t)$$

Etat final du système ( $t \rightarrow +\infty$ )  $\implies$  solution du problème de minimisation.

## Méthodes par tenseurs

---

Intégration de l'OFC sur un voisinage sur lequel le flot est supposé constant (Lucas-Kanade: 2D, Bigün *et al.*: 3D)

$$\left( \int_{\mathcal{V}} \nabla I (\nabla I)^T d\mathbf{x} \right) \mathbf{v} = - \left( \int_{\mathcal{V}} I_t \nabla I d\mathbf{x} \right)$$

## Méthodes par tenseurs

Intégration de l'OFC sur un voisinage sur lequel le flot est supposé constant (Lucas-Kanade: 2D, Bigün *et al.*: 3D)

$$\left( \int_{\mathcal{V}} \nabla I (\nabla I)^T d\mathbf{x} \right) \mathbf{v} = - \left( \int_{\mathcal{V}} I_t \nabla I d\mathbf{x} \right)$$

$$(\mathbf{v}_1, \mathbf{v}_2, 1) = \operatorname{argmin}_{\mathbf{v} \neq \mathbf{0}} \frac{\mathbf{v}^T S \mathbf{v}}{\mathbf{v}^T \mathbf{v}} \quad \text{où } S = \left( \int_{\mathcal{V}} \nabla^\theta I (\nabla^\theta I)^T d\mathbf{x} \right)$$

## Illustration et comparaisons




FIG. 1 : Horn et Schunck (spatial,  $\Psi(s^2) = s^2$ , coefficient de régularisation assez bas),  
Weickert et Schnörr, méthode des tenseurs (3D).

## Dérivées de forme: définitions

Transformation d'une forme  $\Omega$  par un champ de vecteurs  $V$  donné.

$V$  définit le flot  $T_t(V) : \mathbf{x} \mapsto \mathbf{X}(t)$

$$\begin{cases} \mathbf{X}'(t) &= V(\mathbf{X}(t)) \\ \mathbf{X}(0) &= \mathbf{x}. \end{cases}$$

Image de  $\Omega$  par  $T_t$  et de  $\Gamma = \partial\Omega$  par l'application  $T_t$

$$\begin{aligned} \Gamma_t &= \{T_t(V)(\mathbf{x}), \mathbf{x} \in \Gamma\} = T_t(V)(\Gamma) \\ \Omega_t &= \{T_t(V)(\mathbf{x}), \mathbf{x} \in \Omega\} = T_t(V)(\Omega). \end{aligned}$$

## Dérivées de forme: principaux résultats

La **dérivée eulérienne** de la fonctionnelle  $J$  est définie par

$$dJ(\Omega; V) = \lim_{t \downarrow 0} \frac{1}{t} (J(\Omega_t) - J(\Omega)).$$

Soit  $J(\Omega) = \int_{\Omega} \phi(\Omega, \mathbf{x}) d\mathbf{x}$ .

$$dJ(\Omega; V) = \int_{\Omega} \underbrace{\phi'(\Omega; V)}_{\text{dérivée de forme}} d\mathbf{x} + \int_{\partial\Omega} \phi \langle V, \mathbf{n} \rangle d\mathcal{H}^1(\mathbf{x})$$

$\mathbf{n}$  normale extérieure à  $\partial\Omega/\Gamma$ .

## Dérivées de forme: principaux résultats

La **dérivée eulérienne** de la fonctionnelle  $J$  est définie par

$$dJ(\Gamma; V) = \lim_{t \downarrow 0} \frac{1}{t} (J(\Gamma_t) - J(\Gamma)).$$

Soit  $J(\Gamma) = \int_{\Gamma} \phi(\Gamma, \mathbf{x}) d\mathcal{H}^1(\mathbf{x})$ .

$$dJ(\Omega; V) = \int_{\Gamma} \underbrace{\phi'(\Gamma; V)}_{\text{dérivée de forme}} d\mathcal{H}^1(\mathbf{x}) + \int_{\Gamma} \left( \kappa\phi + \frac{\partial\phi}{\partial n} \right) \langle V, \mathbf{n} \rangle d\mathcal{H}^1(\mathbf{x})$$

$\mathbf{n}$  normale extérieure à  $\partial\Omega/\Gamma$ .  $\kappa$  courbure de  $\partial\Omega/\Gamma$ ,

$$\frac{\partial\phi}{\partial n} = \langle \nabla\phi, \mathbf{n} \rangle.$$

## Dérivées de forme: principaux résultats

La **dérivée eulérienne** de la fonctionnelle  $J$  est définie par

$$dJ(\Gamma; V) = \lim_{t \downarrow 0} \frac{1}{t} (J(\Gamma_t) - J(\Gamma)).$$

Soit  $J(\Gamma) = \int_{\Gamma} \phi(\Gamma, \mathbf{x}) d\mathcal{H}^1(\mathbf{x})$ .

$$dJ(\Omega; V) = \int_{\Gamma} \underbrace{\phi'(\Gamma; V)}_{\text{dérivée de forme}} d\mathcal{H}^1(\mathbf{x}) + \int_{\Gamma} \left( \kappa\phi + \frac{\partial\phi}{\partial n} \right) \langle V, \mathbf{n} \rangle d\mathcal{H}^1(\mathbf{x})$$

$\mathbf{n}$  normale extérieure à  $\partial\Omega/\Gamma$ .  $\kappa$  courbure de  $\partial\Omega/\Gamma$ ,

$$\frac{\partial\phi}{\partial n} = \langle \nabla\phi, \mathbf{n} \rangle.$$

Références : Sokolowski-Zolésio (1992), Delfour-Zolésio (SIAM 2001).



## Dérivation de fonctionnelles

$$J(\Omega) = \int_{\Omega} k^{\text{in}}(\mathbf{x}) d\mathbf{x} + \int_{\Omega^c} k^{\text{out}}(\mathbf{x}) d\mathbf{x} + \int_{\partial\Omega} k^{\text{b}}(\mathbf{x}) d\mathcal{H}^1(\mathbf{x})$$

Première méthode : appliquer les théorèmes sur les dérivées de forme ( $\mathbf{n}$  normale extérieure)

$$dJ(\Omega; V) = \int_{\partial\Omega} \left( k^{\text{in}} - k^{\text{out}} + k^{\text{b}} \kappa + \frac{\partial k^{\text{b}}}{\partial n} \right) \langle V, \mathbf{n} \rangle d\mathcal{H}^1(\mathbf{x})$$

$$\frac{\partial \Gamma}{\partial t} = - \left( k^{\text{in}} - k^{\text{out}} + k^{\text{b}} \kappa + \frac{\partial k^{\text{b}}}{\partial n} \right) \mathbf{n}$$

## Dérivation de fonctionnelles

$$J(\Omega) = \int_{\Omega} k^{\text{in}}(\mathbf{x}) d\mathbf{x} + \int_{\Omega^c} k^{\text{out}}(\mathbf{x}) d\mathbf{x} + \int_{\partial\Omega} k^b(\mathbf{x}) d\mathcal{H}^1(\mathbf{x})$$

Première méthode : appliquer les théorèmes sur les dérivées de forme ( $\mathbf{n}$  normale extérieure)

$$dJ(\Omega; V) = \int_{\partial\Omega} \left( k^{\text{in}} - k^{\text{out}} + k^b \kappa + \frac{\partial k^b}{\partial n} \right) \langle V, \mathbf{n} \rangle d\mathcal{H}^1(\mathbf{x})$$

$$\frac{\partial \Gamma}{\partial t} = - \left( k^{\text{in}} - k^{\text{out}} + k^b \kappa + \frac{\partial k^b}{\partial n} \right) \mathbf{n}$$

par la méthode des ensembles de niveaux ( $u > 0$  sur  $\Omega$  et  $u < 0$  sur  $\Omega^c$ )

$$\frac{\partial u}{\partial t} = |\nabla u| \left( k^{\text{out}} - k^{\text{in}} + \text{div} \left( k^b \frac{\nabla u}{|\nabla u|} \right) \right)$$

## Dérivation de fonctionnelles

Deuxième méthode : intégrer la fonction  $u$  dans la fonctionnelle

$$J_\epsilon(u) = \int_D k^{\text{in}} H_\epsilon(u) d\mathbf{x} + \int_D k^{\text{out}} (1 - H_\epsilon(u)) d\mathbf{x} + \int_D k^b \delta_\epsilon(u) |\nabla u| d\mathbf{x}$$

$H_\epsilon$  et  $\delta_\epsilon$  : approximations régulières des distributions de Heaviside et de Dirac. Calcul de la dérivée au sens de Gâteaux

$$J'_\epsilon(u; v) = \int_D \left( k^{\text{in}} - k^{\text{out}} - \text{div} \left( k^b \frac{\nabla u}{|\nabla u|} \right) \right) \delta_\epsilon(u) v d\mathbf{x}$$

## Dérivation de fonctionnelles

Deuxième méthode : intégrer la fonction  $u$  dans la fonctionnelle

$$J_\epsilon(u) = \int_D k^{\text{in}} H_\epsilon(u) d\mathbf{x} + \int_D k^{\text{out}} (1 - H_\epsilon(u)) d\mathbf{x} + \int_D k^b \delta_\epsilon(u) |\nabla u| d\mathbf{x}$$

$H_\epsilon$  et  $\delta_\epsilon$  : approximations régulières des distributions de Heaviside et de Dirac. Calcul de la dérivée au sens de Gâteaux

$$J'_\epsilon(u; v) = \int_D \left( k^{\text{in}} - k^{\text{out}} - \text{div} \left( k^b \frac{\nabla u}{|\nabla u|} \right) \right) \delta_\epsilon(u) v d\mathbf{x}$$

et descente de gradient

$$\frac{\partial u}{\partial t} = \delta_\epsilon(u) \left( k^{\text{out}} - k^{\text{in}} + \text{div} \left( k^b \frac{\nabla u}{|\nabla u|} \right) \right)$$

## Segmentation des objets en mouvement

---

Calcul du flot optique par Weickert/Schnörr, de norme  $|\mathbf{v}|$ .  
La norme du flot optique devrait être suffisamment élevée sur les objets en mouvement.

# Segmentation des objets en mouvement

Calcul du flot optique par Weickert/Schnörr, de norme  $|\mathbf{v}|$ .  
La norme du flot optique devrait être suffisamment élevée sur les objets en mouvement.

Minimisation de la fonctionnelle

$$E(\Omega) = \int_{\Omega} \alpha d\mathbf{x} + \int_{D \setminus \Omega} |\mathbf{v}| d\mathbf{x} + \nu \int_{\partial\Omega} d\mathcal{H}^1(\mathbf{x}) + \lambda \int_{\partial\Omega} \underbrace{g(\mathbf{x})}_{\frac{1}{1+|\nabla I_{\sigma}|^2}} d\mathcal{H}^1(\mathbf{x}).$$

Modèle d'Aubert/Barlaud/Jehan-Besson :  $|\mathbf{v}| \longleftrightarrow |B - I|^2$ ,  $B$  fond statique calculé par Aubert/Deriche/Kornprobst ou médian temporel, pas de terme géodésique ( $\lambda = 0$ ).

Flot optique : faiblement exploité pour la segmentation vidéo (Cremers/Schnörr, Kühne/Weickert/Schuster/Richter).

# Comparaison



FIG. 1 : Etude de l'influence de chaque terme: seuillage, avec terme géodésique  $\lambda = 2$  et sans terme de longueur, sans terme géodésique et avec terme de longueur  $\nu = 0.2$ , avec les deux.

## Résultats

---

- Film complet des voitures.
- Séquence "Coastguard".
- Séquence "Edberg".



*Application de l'ICM à deux problèmes de segmentation  
vidéo et de tracking*

# Plan

---

- Approches discrètes pour des modèles de contours actifs.

# Plan

---

- Approches discrètes pour des modèles de contours actifs.
- Formalisation par champs de Markov, présentation de l'ICM.

# Plan

---

- Approches discrètes pour des modèles de contours actifs.
- Formalisation par champs de Markov, présentation de l'ICM.
- Résultats.

## Minimisation de fonctionnelles discrètes

---

- Soit à minimiser

$$E(\Omega) = \int_{\Omega} f_1(\mathbf{x}) d\mathbf{x} + \int_{\Omega^c} f_2(\mathbf{x}) d\mathbf{x} + \mu \int_{\partial\Omega} ds,$$

et  $\phi$  fonction binaire telle que  $\Omega = \{\phi = 1\}$ ,  $\Omega^c = \{\phi = -1\}$

# Minimisation de fonctionnelles discrètes

- Soit à minimiser

$$E(\Omega) = \int_{\Omega} f_1(\mathbf{x}) d\mathbf{x} + \int_{\Omega^c} f_2(\mathbf{x}) d\mathbf{x} + \mu \int_{\partial\Omega} ds,$$

et  $\phi$  fonction binaire telle que  $\Omega = \{\phi = 1\}$ ,  $\Omega^c = \{\phi = -1\}$  ( $H$  distribution de Heaviside).

$$E(\phi) = \sum_s f_1(s)H(\phi(s)) + \sum_s f_2(s)(1 - H(\phi(s))) \\ + \mu \sum_s U_3(\phi(s), \phi(s_+), \phi(s^+))$$

## Minimisation de fonctionnelles discrètes

- Soit à minimiser

$$E(\Omega) = \int_{\Omega} f_1(\mathbf{x}) d\mathbf{x} + \int_{\Omega^c} f_2(\mathbf{x}) d\mathbf{x} + \mu \int_{\partial\Omega} ds,$$

et  $\phi$  fonction binaire telle que  $\Omega = \{\phi = 1\}$ ,  $\Omega^c = \{\phi = -1\}$  ( $H$  distribution de Heaviside).

$$E(\phi) = \sum_s f_1(s)H(\phi(s)) + \sum_s f_2(s)(1 - H(\phi(s))) \\ + \mu \sum_s U_3(\phi(s), \phi(s_+), \phi(s^+))$$

- Cas de la fonctionnelle de Chan-Vese : cf. T. Chan-B. Song.

## Minimisation de fonctionnelles discrètes

- Soit à minimiser

$$E(\Omega) = \int_{\Omega} f_1(\mathbf{x}) d\mathbf{x} + \int_{\Omega^c} f_2(\mathbf{x}) d\mathbf{x} + \mu \int_{\partial\Omega} ds,$$

et  $\phi$  fonction binaire telle que  $\Omega = \{\phi = 1\}$ ,  $\Omega^c = \{\phi = -1\}$  ( $H$  distribution de Heaviside).

$$E(\phi) = \sum_s f_1(s)H(\phi(s)) + \sum_s f_2(s)(1 - H(\phi(s))) \\ + \mu \sum_s U_3(\phi(s), \phi(s_+), \phi(s^+))$$

- Cas de la fonctionnelle de Chan-Vese : cf. T. Chan-B. Song.
- Application de la même idée au cas de descripteurs indépendants de la forme. Justification d'un point de vue markovien. Algorithme de Chan et Song : cas particulier d'ICM.



## Formalisation par champs de Markov

---

- L'énergie  $E$  est une énergie *a posteriori* conditionnellement à  $f_1$  et  $f_2$ .

$$E(\phi) = E(\phi|f_1, f_2) = \underbrace{U_{\text{data}|\Phi}(f_1, f_2|\phi)}_{\text{énergie } a \text{ priori}} + \mu U_{\Phi}(\phi).$$

## Formalisation par champs de Markov

- L'énergie  $E$  est une énergie *a posteriori* conditionnellement à  $f_1$  et  $f_2$ .

$$E(\phi) = E(\phi|f_1, f_2) = \underbrace{U_{\text{data}|\Phi}(f_1, f_2|\phi)}_{\text{énergie } a \text{ priori}} + \mu U_{\Phi}(\phi).$$

- On peut associer un champ de Gibbs  $\Phi$  à l'énergie  $U_{\Phi}$  :

$$P(\Phi = \phi) = \frac{e^{-U_{\Phi}(\phi)}}{Z}.$$

## Formalisation par champs de Markov

- L'énergie  $E$  est une énergie *a posteriori* conditionnellement à  $f_1$  et  $f_2$ .

$$E(\phi) = E(\phi|f_1, f_2) = \underbrace{U_{\text{data}|\Phi}(f_1, f_2|\phi)}_{\text{énergie a priori}} + \mu U_{\Phi}(\phi).$$

- On peut associer un champ de Gibbs  $\Phi$  à l'énergie  $U_{\Phi}$  :  
$$P(\Phi = \phi) = \frac{e^{-U_{\Phi}(\phi)}}{Z}.$$
- Minimisation de  $E(\phi|f_1, f_2) \Leftrightarrow$  Maximisation de  $P(\Phi|\mathcal{F}_1, \mathcal{F}_2)$   
 $\Leftrightarrow$  MAP estimation.

## Formalisation par champs de Markov

- L'énergie  $E$  est une énergie *a posteriori* conditionnellement à  $f_1$  et  $f_2$ .

$$E(\phi) = E(\phi|f_1, f_2) = \underbrace{U_{\text{data}|\Phi}(f_1, f_2|\phi)}_{\text{énergie } a \text{ priori}} + \mu U_{\Phi}(\phi).$$

- On peut associer un champ de Gibbs  $\Phi$  à l'énergie  $U_{\Phi}$  :  
$$P(\Phi = \phi) = \frac{e^{-U_{\Phi}(\phi)}}{Z}.$$
- Minimisation de  $E(\phi|f_1, f_2) \Leftrightarrow$  Maximisation de  $P(\Phi|\mathcal{F}_1, \mathcal{F}_2) \Leftrightarrow$  MAP estimation.
- Minimisation par l'algorithme des modes conditionnels itérés (ICM, [Besag]).

## Description de l'algorithme ICM

---

- Balayage des sites de l'image,

## Description de l'algorithme ICM

---

- Balayage des sites de l'image,
- en chaque site/pixel  $s$ , on fige les valeurs de  $\phi \in \{-1, +1\}^S$  en tous les sites différents de  $s$ ,

## Description de l'algorithme ICM

- Balayage des sites de l'image,
- en chaque site/pixel  $s$ , on fige les valeurs de  $\phi \in \{-1, +1\}^S$  en tous les sites différents de  $s$ ,
- on calcule de la variation d'énergie  $E$  induite par un changement de signe de  $\phi$  :  $\phi^{n+1}(s) = -\phi^n(s)$

$$\Delta E = (f_1(s) - f_2(s))(1 - 2H(\phi^n(s))) + \mu\Delta U_3.$$

$\phi(s) = \phi^{n+1}(s)$  si  $\Delta E < 0$ ,  $\phi(s) = \phi^n(s)$  sinon,

## Description de l'algorithme ICM

- Balayage des sites de l'image,
- en chaque site/pixel  $s$ , on fige les valeurs de  $\phi \in \{-1, +1\}^S$  en tous les sites différents de  $s$ ,
- on calcule de la variation d'énergie  $E$  induite par un changement de signe de  $\phi$  :  $\phi^{n+1}(s) = -\phi^n(s)$

$$\Delta E = (f_1(s) - f_2(s))(1 - 2H(\phi^n(s))) + \mu\Delta U_3.$$

$\phi(s) = \phi^{n+1}(s)$  si  $\Delta E < 0$ ,  $\phi(s) = \phi^n(s)$  sinon,

- on itère la procédure.



## Description de l'algorithme ICM

- Balayage des sites de l'image,
- en chaque site/pixel  $s$ , on fige les valeurs de  $\phi \in \{-1, +1\}^S$  en tous les sites différents de  $s$ ,
- on calcule de la variation d'énergie  $E$  induite par un changement de signe de  $\phi$  :  $\phi^{n+1}(s) = -\phi^n(s)$

$$\Delta E = (f_1(s) - f_2(s))(1 - 2H(\phi^n(s))) + \mu\Delta U_3.$$

$\phi(s) = \phi^{n+1}(s)$  si  $\Delta E < 0$ ,  $\phi(s) = \phi^n(s)$  sinon,

- on itère la procédure.
- **Avantage : rapidité, inconvénient : sensibilité aux minima locaux.**


## Approximation du terme de longueur

---

- $U(\phi)(s) = \sum_s U_3(\phi(s), \phi(s_+), \phi(s^+)) = \sum_s \sqrt{(H\phi(s_+) - H\phi(s))^2 + (H\phi(s^+) - H\phi(s))^2}$ .
- Si  $s = (i, j)$ ,  $s_+ = (i + 1, j)$ ,  $s^+ = (i, j + 1)$ .

## Approximation du terme de longueur


- $U(\phi)(s) = \sum_s U_3(\phi(s), \phi(s_+), \phi(s^+)) = \sum_s \sqrt{(H\phi(s_+) - H\phi(s))^2 + (H\phi(s^+) - H\phi(s))^2}$ .
- Si  $s = (i, j)$ ,  $s_+ = (i + 1, j)$ ,  $s^+ = (i, j + 1)$ .



$$\Delta U = (0 - 1) + (1 - 1) + (1 - \sqrt{2}) = -\sqrt{2}$$

# Approximation du terme de longueur

- $U(\phi)(s) = \sum_s U_3(\phi(s), \phi(s_+), \phi(s^+)) = \sum_s \sqrt{(H\phi(s_+) - H\phi(s))^2 + (H\phi(s^+) - H\phi(s))^2}$ .
- Si  $s = (i, j)$ ,  $s_+ = (i + 1, j)$ ,  $s^+ = (i, j + 1)$ .



$$\Delta U = (0 - 1) + (1 - 1) + (1 - \sqrt{2}) = -\sqrt{2}$$

$$\Delta U_3 = \Delta l(c(i-1, j)) + \Delta l(c(i, j)) + \Delta l(c(i, j-1))$$

## Applications à divers modèles

---

- Modèle d'Aubert, Barlaud, Jehan-Besson  
 $\Rightarrow f_1(s) = \alpha, f_2(s) = |B(s) - I(s)|.$

## Applications à divers modèles

- Modèle d'Aubert, Barlaud, Jehan-Besson

$$\Rightarrow f_1(s) = \alpha, f_2(s) = |B(s) - I(s)|.$$

- Modèle de tracking d'Aron, Mansouri et Mitiche (ICIP 2003)

$$\Rightarrow f_1(s) = \xi_1(s), f_2(s) = \xi_2(s)$$

$$\xi_1(\mathbf{x}) = \inf_{\substack{\mathbf{v}, |\mathbf{v}| \leq \alpha \\ \mathbf{x} + \mathbf{v} \in \Omega_{\text{ref}}}} |I(\mathbf{x}) - I_{\text{ref}}(\mathbf{x} + \mathbf{v})|^2$$

$$\xi_2(\mathbf{x}) = \inf_{\substack{\mathbf{v}, |\mathbf{v}| \leq \alpha \\ \mathbf{x} + \mathbf{v} \in \Omega_{\text{ref}}^c}} |I(\mathbf{x}) - I_{\text{ref}}(\mathbf{x} + \mathbf{v})|^2$$

## Applications à divers modèles

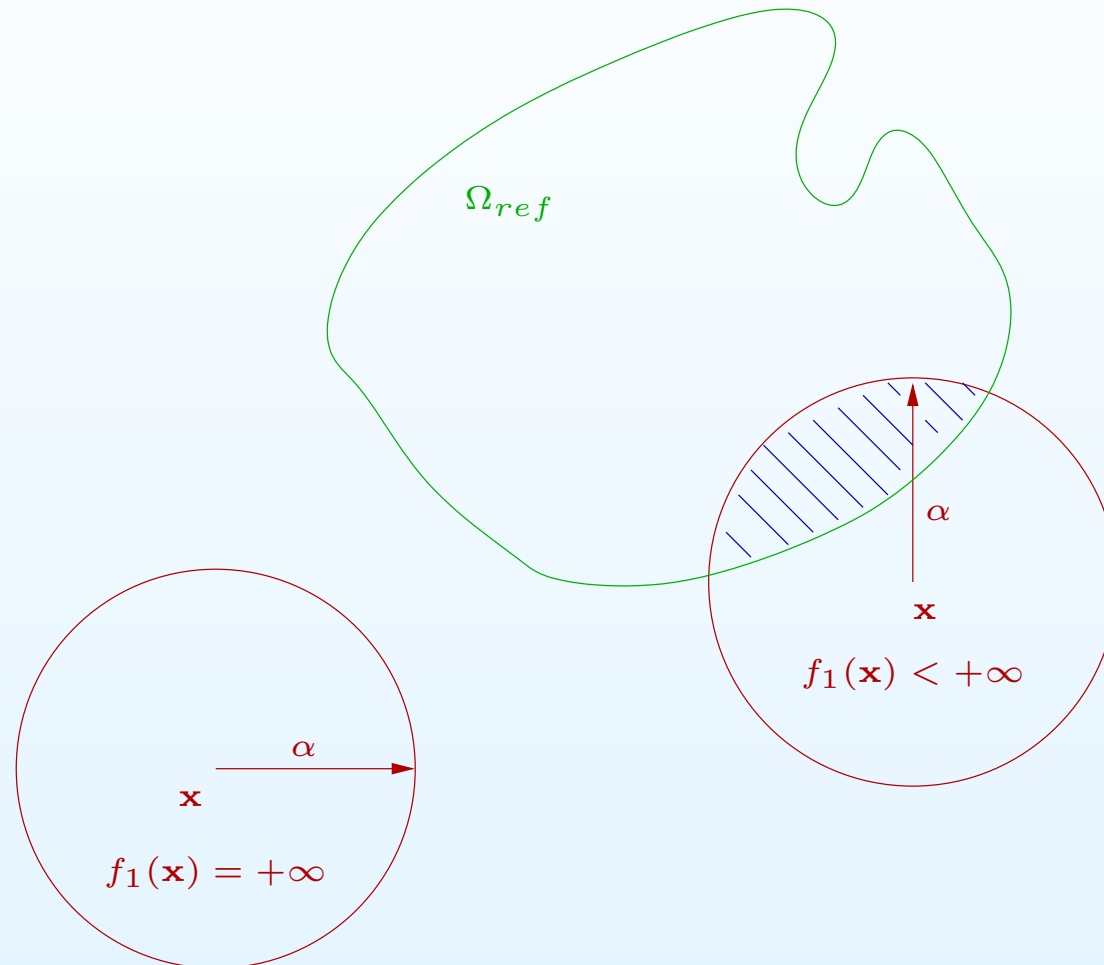
- Modèle d'Aubert, Barlaud, Jehan-Besson  
 $\Rightarrow f_1(s) = \alpha, f_2(s) = |B(s) - I(s)|.$
- Modèle de tracking d'Aron, Mansouri et Mitiche (ICIP 2003)  
 $\Rightarrow f_1(s) = \xi_1(s), f_2(s) = \xi_2(s)$

$$\xi_1(\mathbf{x}) = \inf_{\substack{\mathbf{v}, |\mathbf{v}| \leq \alpha \\ \mathbf{x} + \mathbf{v} \in \Omega_{\text{ref}}}} |I(\mathbf{x}) - I_{\text{ref}}(\mathbf{x} + \mathbf{v})|^2$$

$$\xi_2(\mathbf{x}) = \inf_{\substack{\mathbf{v}, |\mathbf{v}| \leq \alpha \\ \mathbf{x} + \mathbf{v} \in \Omega_{\text{ref}}^c}} |I(\mathbf{x}) - I_{\text{ref}}(\mathbf{x} + \mathbf{v})|^2$$

Modèles écrits et dérivés dans le cadre continu. L'ICM est beaucoup plus rapide.

# Calcul des erreurs $f_i$





## Résultats

---

- Avec le modèle d'Aubert/Barlaud/Jehan-Besson :
  - Film de voitures
  - Séquence "finlandaise".
  - Séquence "Edberg" recalée.
  - La même avec application de l'ICM et de l'algorithme par EDP.
- Avec le modèle d'Aron/Mansouri/Mitiche: séquence du speaker.
- Le même avec application d'un snake niveau de gris: le même.

# *Algorithmes pour deux problèmes de vidéosurveillance*

# Présentation des problèmes

---

- Estimation de la densité d'une foule : une séquence, une autre séquence...
- Détection de comportements anormaux : première partie de la séquence, deuxième partie.

## Solution pour l'estimation de la densité d'une foule

---

Courbure principalement portée par la foule (quai vide : éléments rectilignes,...).

Régularisation par l'équation de la courbure moyenne

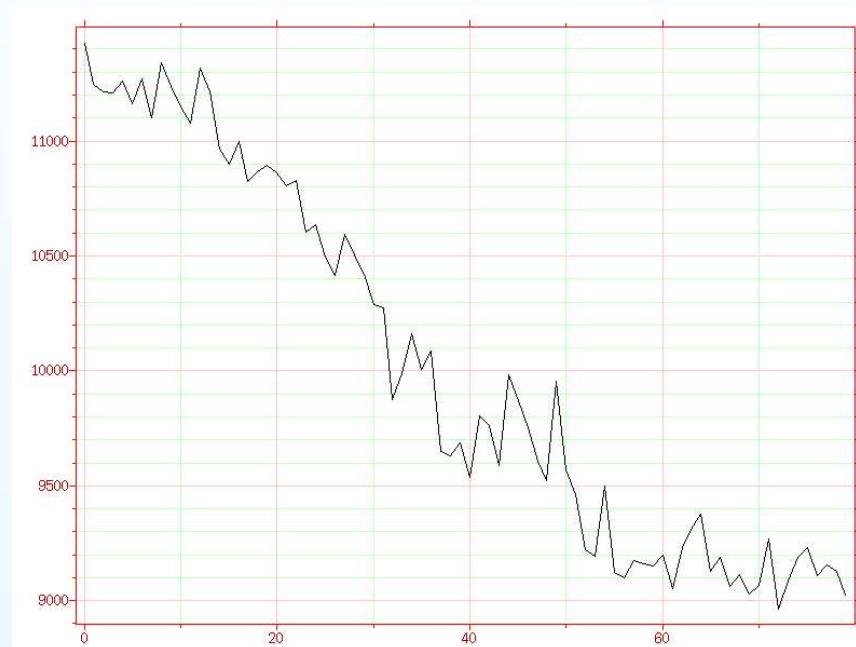
$$\frac{\partial u}{\partial t} = |\nabla u| \operatorname{div} \left( \frac{\nabla u}{|\nabla u|} \right)$$

Calcul de la valeur moyenne de la courbure en valeur absolue,


$$\operatorname{curv}(u) = \operatorname{div} \left( \frac{\nabla u}{|\nabla u|} \right) \quad \overline{|\operatorname{curv}|} = \frac{1}{N} \sum_{(i,j)} |\operatorname{curv}(u)|(i,j)$$

# Résultats

---



# Résultats



## Détection de comportements anormaux

---

Calcul de l'histogramme discret des directions du flot optique calculé par la méthode de Lucas-Kanade ou Bernard :

$$H_k = |\{\mathbf{x} \mid \theta_k \leq \theta(\mathbf{x}) \leq \theta_{k+1}\}| \quad M = \max_{k, \theta_k < 0} (H_k)$$

Critère de détection :  $M \geq \tau$ .  
séquence des alarmes.

## Conclusion et Perspectives

---

- Segmentation totale du flot optique:
  - segmentation de la norme,
  - séparation des objets en mouvement par l'étude des directions (applications en vidéosurveillance).



## Conclusion et Perspectives

---

- Segmentation totale du flot optique:
  - segmentation de la norme,
  - séparation des objets en mouvement par l'étude des directions (applications en vidéosurveillance).
- Jusqu'où peut-on aller avec l'ICM?

## Conclusion et Perspectives

---

- Segmentation totale du flot optique:
  - segmentation de la norme,
  - séparation des objets en mouvement par l'étude des directions (applications en vidéosurveillance).
- Jusqu'où peut-on aller avec l'ICM?
- Techniques de graph-cut (Y. Boykov) pour la minimisation discrète : abandonner l'ICM?

## Conclusion et Perspectives

---

- Segmentation totale du flot optique:
  - segmentation de la norme,
  - séparation des objets en mouvement par l'étude des directions (applications en vidéosurveillance).
- Jusqu'où peut-on aller avec l'ICM?
- Techniques de graph-cut (Y. Boykov) pour la minimisation discrète : abandonner l'ICM?
- Combinaison de plusieurs détecteurs pour la détection de comportements anormaux (calcul de fond puis calcul de flot sur les objets en mouvement)

*Merci*