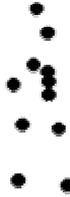
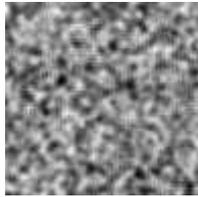


De la détection de changement à l'analyse du mouvement

*Applications en télésurveillance et
navigation autonome*

Antoine MANZANERA – ENSTA/LEI



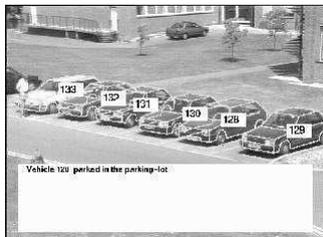
Cours ETASM 2006

Antoine MANZANERA – ENSTA/LEI

1

Applications et enjeux (1)

Surveillance de zone



(University of Surrey)

Compression et
Indexation



Cours ETASM 2006

Antoine MANZANERA – ENSTA/LEI

2

Applications et enjeux (2)

Navigation robotique

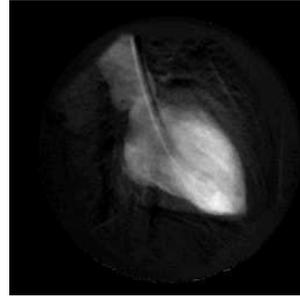


(Ecole des Mines / CMM)

Poursuite automatique



Mouvement fluide

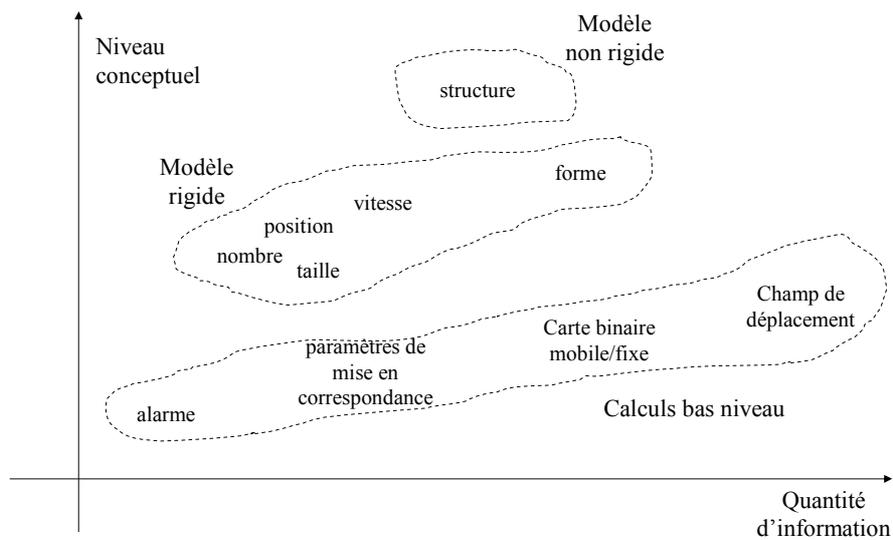


Cours ETASM 2006

Antoine MANZANERA - ENSTA/EI

3

Quelle information extraire ?

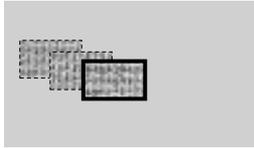


Cours ETASM 2006

Antoine MANZANERA - ENSTA/EI

4

Détection – Estimation – Poursuite



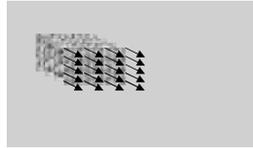
DETECTION

Objectif : identifier dans chaque image les pixels appartenant à des objets mobiles

- Certaine continuité temporelle
- Mouvement de la caméra nul ou très simple.



Chapitre 1



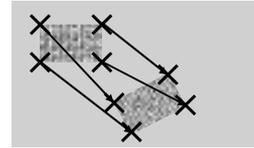
ESTIMATION

Objectif : calculer le mouvement apparent (vitesse instantanée) de chaque pixel

- Continuité temporelle
- Plutôt « traiter après »



Chapitre 2



POURSUITE

Objectif : apparier certaines structures spatiales pour chaque couple d'images.

- Discontinuité temporelle
- Plutôt « traiter avant »



Chapitre 3

MOUVEMENT ① Détection

PLAN DU CHAPITRE

- Introduction du problème
- Observation & différenciation
- Régularisation spatiotemporelle

Introduction du problème

BUT : Associer à chaque pixel de I une étiquette binaire [*fixe,mobile*]...
0 1

...en fonction des changements temporels de $I(x,y,t)$.

Quelles variations temporelles ?

$$Y(x,y,t) = |I(x,y,t) - I(x,y,t-1)|$$

$$Y(x,y,t) = |I(x,y,t) - I_{ref}(x,y,t)|$$

Idéalement : $\begin{cases} Y = 0 \text{ pas de mvt} \\ Y > 0 \text{ mvt} \end{cases}$

Contraintes et difficultés



CONTRAINTES

$\left\{ \begin{array}{l} (1) \text{ Camera fixe} \\ (2) \text{ Eclairage constant} \end{array} \right. \longrightarrow \left\{ \begin{array}{l} (1)' \text{ Camera bougeant lentement} \\ (2)' \text{ Variation d'éclairage basse fréquence} \end{array} \right.$

$\left\{ \begin{array}{l} (1)'' \text{ Camera mobile avec mouvement compensé (Cf Chap. 2)} \\ (2)'' \text{ Intensité lumineuse variable avec mise à l'échelle de l'histogramme} \end{array} \right.$



DIFFICULTES

$\left\{ \begin{array}{l} (1) \text{ Bruits de capteur (acquisition + numérisation)} \\ (2) \text{ Zones homogènes } (\Delta \text{luminance} < \tau) \end{array} \right. \longrightarrow 0 \longrightarrow \text{seuil } \tau > 0$

Détection : méthode générique

(1) Calcul du changement temporel

On calcule, pour chaque pixel, une ou plusieurs statistiques temporelles des niveaux de gris, ainsi que l'écart par rapport à ces statistiques.



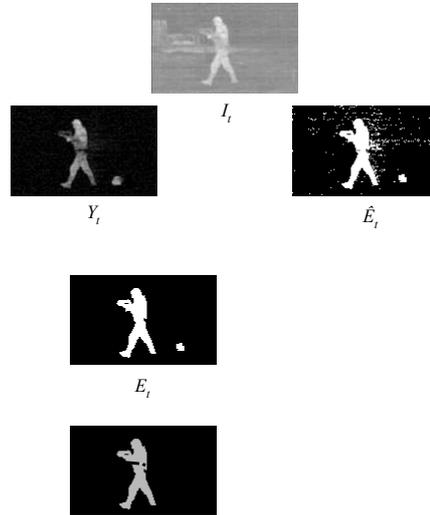
(2) Régularisation spatiotemporelle

On agrège spatialement les résultats de changement temporel afin d'obtenir des objets réguliers.



(3) Sélection des objets

On sélectionne les régions obtenues en fonction de critères morphologiques ou cinématiques.



Changement par gradient temporel

$$Y(x,y,t) = |I(x,y,t) - I(x,y,t-1)|$$

$$Y_t = |I_t - I_{t-1}|$$

$$\text{Si } Y_t > S, \text{ alors } \hat{E}_t = 1 \text{ sinon } \hat{E}_t = 0$$

Ici l'observation correspond à une estimation du gradient temporel, discrétisé par une différence finie.

Avantages :

- simplicité de calcul
- grande adaptation aux variations de conditions de la scène

Inconvénients :

- problème de l'ouverture



I_t



Y_t

Changement par gradient temporel

Problème de la détermination du seuil S



I_t



Y_t



$\hat{E}_t (S=3)$



$\hat{E}_t (S=9)$

Cours ETASM 2006

Antoine MANZANERA - ENSTALEI

11

Estimation de fond statique

$$Y(x,y,t) = |I(x,y,t) - I_{\text{ref}}(x,y,t)|$$

Ici l'observation correspond à un écart entre la valeur courante et la valeur de référence de la scène (le « fond » statique).

Le fond statique correspond à la valeur habituelle du fond, il est généralement calculé sous la forme d'une **moyenne**...

- Moyenne arithmétique sur les n dernières images :

Très coûteux car nécessité de conserver en permanence n images consécutives en *mémoire*...

- Moyenne récursive (filtre exponentiel) :

Nécessite seulement la moyenne et l'image courante...

$$M_t = \alpha I_t + (1 - \alpha)M_{t-1} \quad \alpha, 0 < \alpha < 1 \text{ est le paramètre d'oubli, } (1/\alpha \text{ a la dimension du temps)}$$

$$Y_t = |M_t - I_t|$$

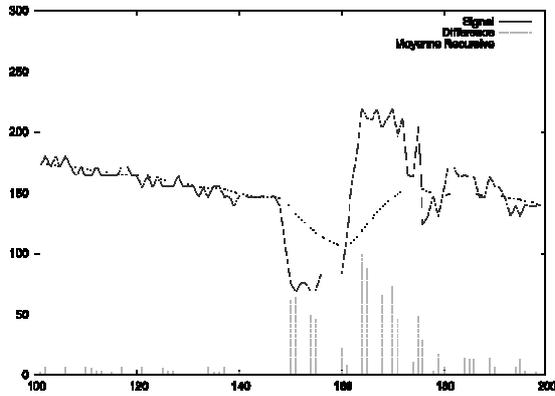
Si $Y_t > S$, alors $\hat{E}_t = 1$ sinon $\hat{E}_t = 0$

Cours ETASM 2006

Antoine MANZANERA - ENSTALEI

12

Moyenne réursive



Comportement de la moyenne réursive au cours du temps pour 1 pixel donné (200 trames) correspondant au passage d'un objet mobile.

Avantages :

- réduction drastique du problème de l'ouverture

Inconvénients :

- adaptation aux changements de conditions plus délicat

- Changement d'illumination (graduel, soudain,...)
- Mouvements parasites
- Mouvements de la caméra
- Changement de la nature du fond

Moyenne réursive

$\alpha = 0.125$

$\alpha = 0.0625$



I_t



M_t



M_t

...et pour un instant t fixé.



Y_t

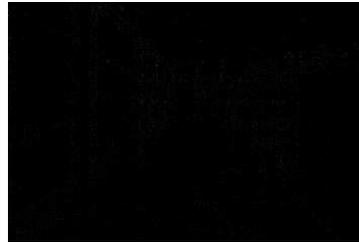


Y_t

Moyenne réursive

Pour des durées importantes, on retrouve le problème de l'ouverture, critique pour les *mouvements radiaux* :

Par ailleurs, la détermination du *seuil* demeure critique...



Estimation gaussienne

$$Y(x,y,t) = |I(x,y,t) - I_{\text{ref}}(x,y,t)|$$

$$M_t = \alpha I_t + (1 - \alpha) M_{t-1}$$

$$Y_t = |M_t - I_t|$$

$$V_t = \alpha Y_t^2 + (1 - \alpha) V_{t-1}$$

$$\text{Si } Y_t > N \cdot \sqrt{V_t}, \text{ alors } \hat{E}_t = 1 \text{ sinon } \hat{E}_t = 0$$

En chaque pixel, le niveau de gris est modélisé comme un signal aléatoire gaussien, qu'on peut entièrement caractériser par sa moyenne M_t et sa variance V_t .

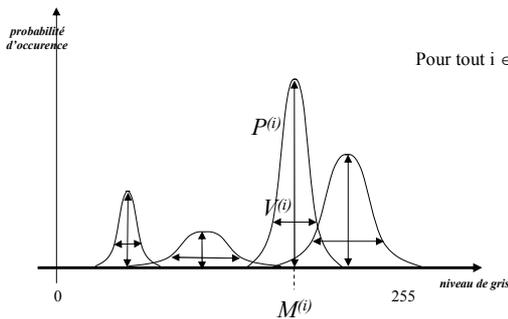
L'hypothèse gaussienne permet en outre d'adapter le seuil de binarisation à un nombre moyen de fausses alarmes.

Wren et al 1997

Estimation multi-gaussienne

Adapté aux fonds multimodaux
(rivières, écrans, drapeaux,...)

Pour chaque pixel, on calcule K modes $i \in \{0, \dots, K\}$, qui sont partitionnés en « fond » F ou « non fond » NF.



Pour tout $i \in \{0, \dots, K\}$: $Y_t^{(i)} = |M_t^{(i)} - I_t|$

si $Y_t^{(i)} < N \cdot V_t^{(i)}$:

$$Q_t^{(i)} = Q_{t-1}^{(i)} + 1$$

$$M_t^{(i)} = \alpha I_t + (1 - \alpha) M_{t-1}^{(i)}$$

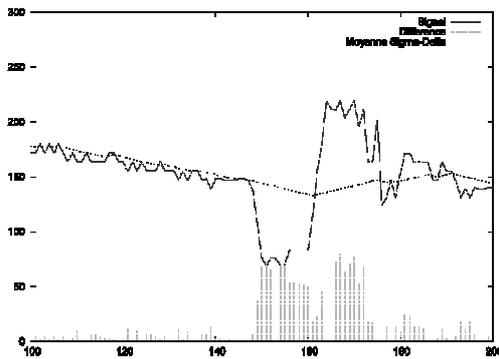
$$V_t^{(i)} = \alpha (Y_t^{(i)})^2 + (1 - \alpha) V_{t-1}^{(i)}$$

Pour tout $i \in \{0, \dots, K\}$: $P_t^{(i)} = \frac{1}{\sum_{i=0, \dots, K} Q_t^{(i)}} Q_t^{(i)}$

Si $\frac{P_t^{(i)}}{V_t^{(i)}} \geq S$ alors $i \in F$
sinon $i \in NF$

Stauffer et Grimson 1999

Estimation Sigma-Delta



Comportement de la moyenne Σ -A au cours du temps pour 1 pixel donné (200 trames) correspondant au passage d'un objet mobile.

$$(1) \begin{cases} \text{Si } M_t < I_t \text{ alors } M_t = M_t + I_t; \\ \text{Si } M_t > I_t \text{ alors } M_t = M_t - I_t; \end{cases}$$

$$(2) Y_t = |I_t - M_t|;$$

$$(3) \begin{cases} \text{Si } V_t < K \cdot \Delta_t \text{ alors } V_t = V_t + I_t; \\ \text{Si } V_t > K \cdot \Delta_t \text{ alors } V_t = V_t - I_t; \end{cases}$$

$$(4) \begin{cases} \text{Si } Y_t > V_t \text{ alors } D_t = I_t; \\ \text{sinon } D_t = 0; \end{cases}$$

Estimation Sigma-Delta



I_t



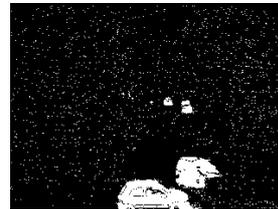
M_t



$Y_t = |M_t - I_t|$



$V_t (N = 2, \text{normalisée})$



\hat{E}_t

Estimation Sigma-Delta

- Jeu d'instruction utile extrêmement réduit :
Comparaison – Incrément – Différence



Système de détection à base de rétine artificielle basée sur l'estimation $\Sigma-\Delta$

- Moyenne $\Sigma-\Delta$ converge vers la médiane temporelle : plus robuste.
- Extensible aux fonds complexes en adaptant les fréquence/phase des estimateurs $\Sigma-\Delta$.

Manzanera et Richefeu 2004



Sigma-Delta : rebouclage

for each pixel x :

$$D_t(x) = M_{t-1}(x) - I_t(x)$$

$$O_t(x) = |D_t(x)|$$

step1: compute difference

for each pixel x such that $O_t(x) \neq 0$:

$$\text{if } V_{t-1}(x) < N \times O_t(x), V_t(x) = V_{t-1}(x) + 1$$

$$\text{if } V_{t-1}(x) > N \times O_t(x), V_t(x) = V_{t-1}(x) - 1$$

$$\text{otherwise } V_t(x) = V_{t-1}(x)$$

step2: update time-variance

for each pixel x :

$$\text{if } O_t(x) < V_t(x)$$

$$\text{then } \hat{E}_t = 0$$

$$\text{else } \hat{E}_t = 1$$

step3: estimate initial label

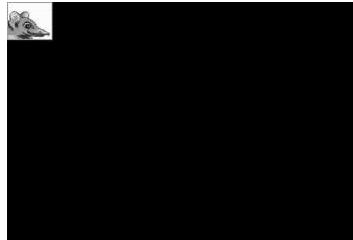
for each pixel x such that $\hat{E}_t = 0$:

$$\text{if } D_t(x) < 0, M_t(x) = M_{t-1}(x) + 1$$

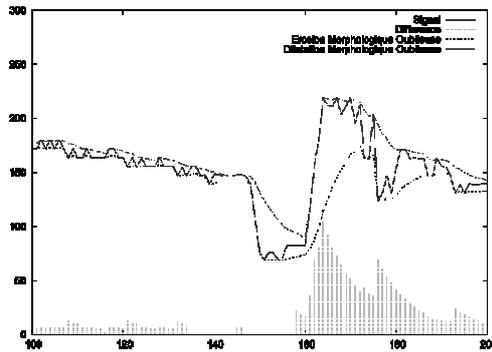
$$\text{if } D_t(x) > 0, M_t(x) = M_{t-1}(x) - 1$$

$$\text{otherwise } M_t(x) = M_{t-1}(x)$$

step4: update background



Morphologie oubliuse



Comportement des opérateurs de morphologie oubliuse au cours du temps pour 1 pixel donné (200 trames) correspondant au passage d'un objet mobile.

$$m_t = \alpha I_t + (1-\alpha) \text{MIN}(m_{t-1}, I_t)$$

$$M_t = \alpha I_t + (1-\alpha) \text{MAX}(M_{t-1}, I_t)$$

$$D_t = M_t - m_t$$

Morphologie oublieuse



I_t



M_t



m_t

Le gradient morphologique oublieux Y_t correspond à l'estimation réursive de l'amplitude de variation du niveau de gris dans les $1/\alpha$ dernières trames. Cet opérateur est particulièrement adapté aux mouvements de faible amplitude (petits objets, lents).



$$Y_t = M_t - m_t$$

Richefeu et Manzanera 2004

Régularisation spatiotemporelle

Objectif : Exploiter les corrélations spatiales et temporelles entre pixels voisins – Obtenir des résultats plus réguliers.

La régularisation spatiotemporelle utilise le résultat binaire de la détection temporelle \hat{E}_t , ainsi que la valeur de « l'observation » Y_t , pour calculer une étiquette régularisée E_t .

FILTRAGE MORPHOLOGIQUE :

Souvent, la régularisation spatiotemporelle se réduit à l'application de filtres morphologiques binaires, qui calculent E_t à partir de \hat{E}_t , éventuellement de \hat{E}_{t-1} , voire \hat{E}_{t+1} .

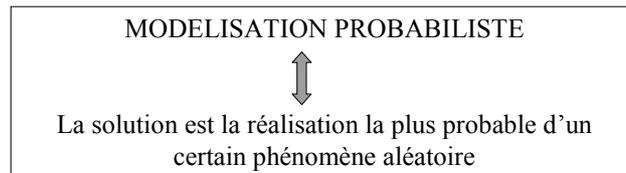
- Filtres alternés séquentiels.
- Filtres majoritaires.
- Filtres connexes.

REGULARISATION MARKOVIENNE :

Basée sur un modèle probabiliste, calcule E_t à partir de Y_t , en utilisant un algorithme de relaxation initialisé par \hat{E}_t .

Régularisation markovienne

Régularisation de problème mal posé \longleftrightarrow Injection de connaissances a priori sur les données du problème

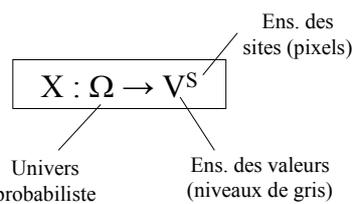


3 questions :

- Comment *construire* ce phénomène aléatoire ? \rightarrow **MODELISATION**
- Comment obtenir des *réalisations* de ce phénomène \rightarrow **SIMULATION**
- Comment obtenir la réalisation *la plus probable* ? \rightarrow **OPTIMISATION**

Propriétés du modèle

Un *champ aléatoire* X sur S à valeur dans V est défini par :



Notations :

Pour $\omega \in \Omega$, $X_\omega : S \rightarrow V$ réalisation d'un champ aléatoire.

Pour $s \in S$, $X_s : \Omega_s \rightarrow V$ variable aléatoire au pixel s .

Dans notre contexte de détection :

$$\begin{cases} V = \{0,1\} & (\{\text{fixe,mobile}\}) \\ S = Z^3 \text{ ou } Z^2 \times N & (\text{espace-temps discret}) \end{cases}$$

Topologie et système de voisinage

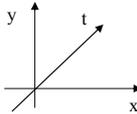
La donnée d'une topologie sur S détermine les relations de dépendances entre les variables aléatoires X_s

Topologie sur $S \Leftrightarrow$ Système de voisinage \mathcal{V}

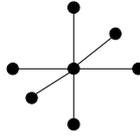
$$\mathcal{V}: S \rightarrow \mathcal{P}(S)$$

$$tq, qq \text{ soit } (s,r) \in S^2, \begin{cases} s \notin \mathcal{V}(s) \\ s \in \mathcal{V}(r) \Rightarrow r \in \mathcal{V}(s) \end{cases}$$

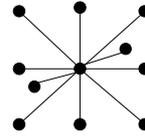
Ex:



6-connexité



8-connexité spatiale
2-connexité temporelle



Champs de Markov

$X: \Omega \rightarrow V^S$ est un *champ de Markov* relativement au système de voisinage \mathcal{V} ssi, pour tout $s \in S$,

$$P(X_s = x_s / X_r = x_r; r \neq s) = P(X_s = x_s / X_r = x_r; r \in \mathcal{V}(s))$$

Théorème de Hammersley-Clifford



J. Besag 1974

La densité de probabilité de X est une *mesure de Gibbs*

$$P(X = x) = e^{-U(x)} / Z$$

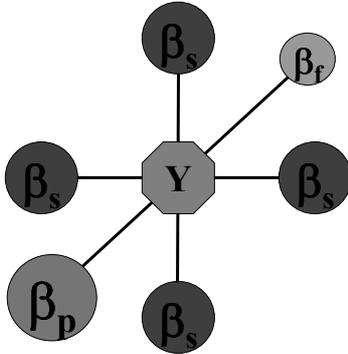
$$\text{avec } Z = \sum_{y \in V^S} e^{-U(y)}, \text{ et } U(x) = \sum_{c \in \mathcal{C}} V_c(x)$$

\mathcal{C} est l'ensemble des cliques (sous-graphes complets) de \mathcal{V}

$V_c(x)$ est une fonction dite *potentiel* qui ne dépend que des valeurs $\{x_s\}_{s \in c}$

- On peut décrire un modèle de champ de Markov dans une topologie donnée en spécifiant les potentiels attachés à chaque clique.
- La donnée de la fonctionnelle d'énergie U permet de « prévoir » le comportement du champ aléatoire puisque la réalisation est d'autant plus probable que l'énergie est faible.

Modèle pour la détection de mouvement



$U_m(x)$: énergie du modèle
 $U_a(y,x)$: énergie d'attache
 aux données

$$U(x) = U_m(x) + U_a(x,y)$$

$$U_m(x) = \sum_{s \in S} \sum_{r \in \mathcal{V}(s)} V_x(s,r)$$

avec $V_x(s,r) = -\beta_{sr}$ si $x(s) = x(r)$
 $= +\beta_{sr}$ si $x(s) \neq x(r)$

(Modèle de Potts)

$$U_a(x,y) = \frac{1}{2\sigma^2} \sum_{s \in S} (y(s) - \Psi(s))^2$$

avec $\Psi(s) = 0$ si $x(s) = 0$
 $= \alpha$ si $x(s) = 1$

Sémantique du modèle

$$U(x) = U_m(x) + U_a(x,y)$$

$$U_m(x) = \sum_{s \in S} \sum_{r \in \mathcal{V}(s)} \pm \beta_{sr}$$

$$U_a(x,y) = \frac{1}{2\sigma^2} \sum_{s \in S} (y(s) - \Psi(s))^2$$

avec $\Psi(s) = 0$ si $x(s) = 0$
 $= \alpha$ si $x(s) = 1$

Modélisation :

On suppose :

$$P(X = x) = \frac{e^{-U_m(x)}}{Z_1}$$

(caractère markovien de X)

L'énergie du modèle exprime une hypothèse de régularité.

et : $P(Y = y / X = x) = \frac{e^{-U_a(x,y)}}{Z_2}$

Avec : α = moyenne de Y ; σ^2 = variance de Y

(modèle de bruit liant X et Y)

L'énergie d'adéquation assure un lien significatif entre le résultat de l'étiquetage et les données d'entrée.

Alors : $\arg \min_x U(x) = \arg \max_x P(X = x).P(Y = y / X = x)$

$$= \arg \max_x P(X = x / Y = y)$$

P. Bouthémy
 P. Lalande
 1993

↪ Critère bayésien du Maximum A Posteriori

Simulation et chaînes de Markov

But : une fois le modèle défini, on souhaite générer des réalisations (échantillons) de ce modèle

Principe : Construire une suite de champs aléatoires $(X_n)_{n \in \mathbb{N}}$, telle que

$$\text{Pour tout } x \in \mathcal{V}^S, \lim_{n \rightarrow +\infty} P(X_n = x) = \Pi(x)$$

avec $\Pi(x) = e^{-U(x)} / Z$

Pour cela, on va construire une chaîne de Markov qui converge en loi vers Π :

Une suite $(X_n)_n$ est une chaîne de Markov (d'ordre 1) ssi :

$$P(X_{n+1} = x_{n+1} / X_i = x_i ; i \leq n) = P(X_{n+1} = x_{n+1} / X_n = x_n)$$

Simulation

Exemple : les deux algorithmes suivants...

Algorithme de Metropolis

Soit $X_0 = x_0$ un état initial quelconque.

Pour $n \geq 0$, faire :

1. Tirer un pixel s au hasard (Loi uniforme sur S).
2. Tirer une étiquette e au hasard (Loi uniforme sur \mathcal{V}).

On note : $\tilde{x} \in \mathcal{V}^S$ tel que $\tilde{x}(r) = x_r(r)$ si $r \neq s$
et $\tilde{x}(s) = e$

3. Calculer la différence : $\Delta U = U(\tilde{x}) - U(x_n)$

Si $\Delta U < 0$, alors : $x_{n+1} = \tilde{x}$

sinon : $x_{n+1} = x_n$ avec une probabilité $e^{-\Delta U}$

$x_{n+1} = \tilde{x}$ avec une probabilité $1 - e^{-\Delta U}$

Echantillonneur de Gibbs

Soit $X_0 = x_0$ un état initial quelconque.

Pour $n \geq 0$, faire :

1. Tirer un pixel s au hasard (Loi uniforme sur S).
2. Calculer les probabilités conditionnelles :
 $P(X_{n+1}(s) = x_s / X_n(r) = x_r ; r \neq s)$
 $= P(X_{n+1}(s) = x_s / X_n(r) = x_r ; r \in \mathcal{V}(s))$
3. Effectuer un tirage de X_{n+1} en fonction de cette loi.

S. Geman & D. Geman 1984

N. Metropolis 1953

... produisent des chaînes de Markov qui converge en loi vers la mesure de Gibbs d'énergie U .

J.L. Marroquin 1985

Optimisation

But : Nous avons vu comment produire des échantillons de la loi qu'on a modélisée.
On souhaite à présent obtenir la réalisation *la plus probable*.

1er cas : RELAXATION DETERMINISTE

Supposons qu'on soit capable d'obtenir un état initial $X_0 = x_0$ qui constitue une instance crédible (= une réalisation pas trop improbable) du modèle de Gibbs qu'on a construit.

Dans ce cas :

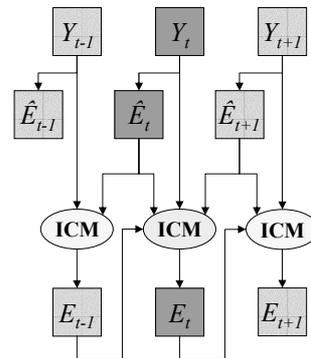


Ex: ICM (Iterated Conditional Mode), avec x_0 = seuillage de y

ICM

ALGORITHME ICM

Soit $X_0 = x_0$.
 Relaxation {
 Balayer l'ens. des pixels $s \in S$,
 et pour tout s : {
 pour chaque valeur $e \in V$,
 on note x^e tel que $x^e(r) = x(r)$ si $r \neq s$ et $x^e(s) = e$.
 on prend : $x(s) = \arg \min_{e \in V} U(x^e)$.
 }
 }



Algorithme de détection

ICM : résultats

- Algorithme complètement déterministe, s'apparente à une descente de gradient.
- Converge vers le premier minimum local de U rencontré.
- Correct si l'initialisation n'est pas trop loin du minimum global.

I

T

X



Meudon3.avi



MeuObs.avi



MeuLab.avi

Cours ETASM 2006

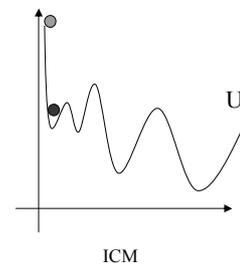
Antoine MANZANERA - ENSTALEI

35

ICM et optimisation

L'algorithme ICM correspond à une descente de gradient local :

Un algorithme de descente de gradient appliqué à une fonction U converge vers le premier minimum local rencontré en aval de l'initialisation. Ce minimum n'est le minimum global de la fonction U que si U est convexe :



Cours ETASM 2006

Antoine MANZANERA - ENSTALEI

36

Recuit simulé

2d cas : RELAXATION STOCHASTIQUE

On passe par une étape de simulation, qui contient du tirage aléatoire.

Problème : on a obtenu une convergence en loi, mais comment faire converger les réalisations ?

→ Mesure de Gibbs d'énergie U et de température T :

$$P(X=x) = \frac{\exp(-U(x)/T)}{Z_T}$$

avec $Z_T = \sum_{y \in V^S} \exp(-U(y)/T)$

Recuit simulé

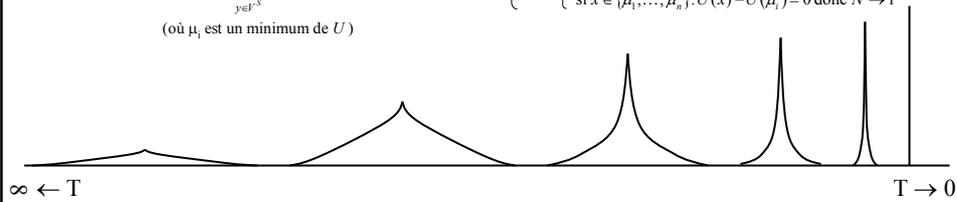
PROPRIETE :

1 - Lorsque $T \rightarrow +\infty$, la mesure de Gibbs d'énergie U et de température T tend vers la probabilité uniforme sur V^S .

1 - Lorsque $T \rightarrow 0$, la mesure de Gibbs d'énergie U et de température T tend vers la probabilité uniforme sur l'ensemble $\{\mu_1, \dots, \mu_n\}$ des minima de U.

(1) $T \rightarrow +\infty : \frac{e^{-U(x)}}{Z_T} \rightarrow 1$
 $Z_T \rightarrow \text{card } V^S$

(1) $T \rightarrow 0 : \frac{e^{-U(x)}}{Z_T} = \frac{e^{-\frac{U(x)-U(\mu_1)}{T}}}{\sum_{y \in V^S} e^{-\frac{U(y)-U(\mu_1)}{T}}} = \frac{N}{D}$ quand $T \rightarrow 0 : \begin{cases} (1) & D \rightarrow n \\ (2) & \begin{cases} \text{si } x \notin \{\mu_1, \dots, \mu_n\} : U(x) - U(\mu_1) > 0 \text{ donc } N \rightarrow 0 \\ \text{si } x \in \{\mu_1, \dots, \mu_n\} : U(x) - U(\mu_1) = 0 \text{ donc } N \rightarrow 1 \end{cases} \end{cases}$
 (où μ_i est un minimum de U)



Recuit simulé : résultats

Application : algorithme de Metropolis en faisant décroître T vers 0.

Inconvénient majeur : coût de calcul énorme.

—————> Mis en œuvre sur architectures parallèles...

I



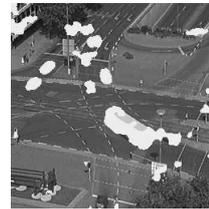
Karlsruhe2.avi

T



KarlObs.avi

X



KarlLab.avi

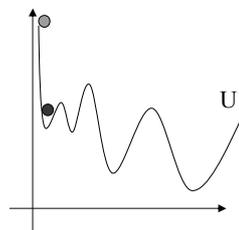
Cours ETASM 2006

Antoine MANZANERA - ENSTA/EI

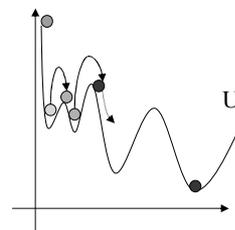
39

Recuit simulé et optimisation

Par rapport à la descente de gradient, le principe de l'algorithme de recuit simulé est de pouvoir sortir de « puits » de minima locaux en permettant aléatoirement une augmentation de l'énergie, d'autant plus grande que la température est élevée :



ICM



Recuit simulé

Cours ETASM 2006

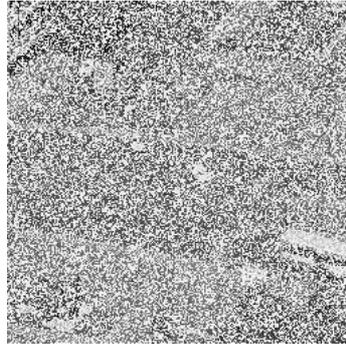
Antoine MANZANERA - ENSTA/EI

40

Convergences



ICM



Recuit simulé

GNC et espaces d'échelle

3ème cas : RELAXATION DETERMINISTE GNC (Graduated Non Convexity)

Principe : modéliser le problème par une hiérarchie de modèle de Gibbs $\{U_z\}_z$

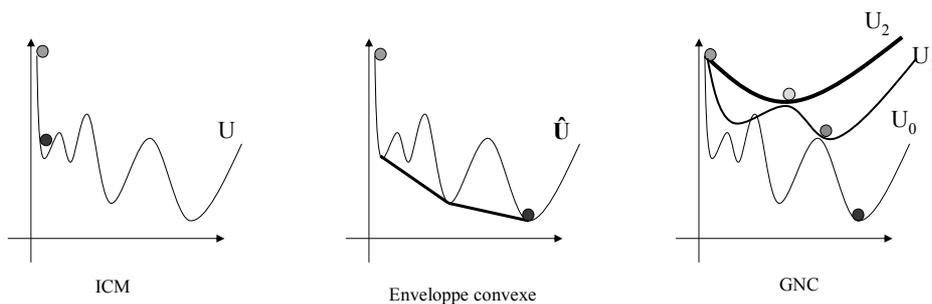
Par exemple, une hiérarchie de modèle de Gibbs peut être induite par une multi-résolution spatiotemporelle de la séquence d'images :



GNC et optimisation

3ème cas : RELAXATION DETERMINISTE GNC (Graduated Non Convexity)

Principe : modéliser le problème par une hiérarchie de modèle de Gibbs $\{U_z\}_z$



A.Blake & A.Zisserman 1987

Cours ETASM 2006

Antoine MANZANERA - ENSTA/EI

43

Conclusion Chapitre 1

CALCUL DU CHANGEMENT TEMPOREL

- Gradient temporel
- Fond statique
 - Moyenne réursive
 - Mélange de gaussiennes
 - Estimation Σ - Δ
- Morphologie oubliuse

REGULARISATION SPATIOTEMPORELLE

- Filtrage morphologique
- Relaxation markovienne
 - ICM
 - Recuit simulé
 - Modèles de Gibbs hiérarchiques

Cours ETASM 2006

Antoine MANZANERA - ENSTA/EI

44

Bibliographie Chapitre 1

- ***C. Wren et al 1997 « Pfnder: real-time tracking of the human body » IEEE Trans on Pattern Analysis and Machine Intelligence 19-7 pp 780-785***
- ***C. Stauffer & W.E.L. Grimson 2000 « Learning patterns of activity using real-time tracking » IEEE Trans on Pattern Analysis and Machine Intelligence 22-8 pp 747-757***
- ***A. Manzanera & J. Richefeu 2006 « A new motion detection algorithm based on Σ - Δ estimation » Pattern Recognition letters à paraître***
- ***P. Bouthémy & P. Lalande 1993 « Recovering of moving object in an image sequence using local spatiotemporal contextual information » Optical engineering 32-6 1205-1212***
- ***S. Geman & D. Geman 1984 « Stochastic relaxation, Gibbs distributions and the Bayesian restoration of images » IEEE Transactions on Pattern Analysis and Machine Intelligence 6-6 721-741***
- ***J.L. Marroquín 1985 « Probabilistic solution of inverse problems » PhD Thesis, MIT***
- ***A. Blake & A. Zisserman 1987 « Visual reconstruction » MIT Press***