



Reconnaissance et segmentation de texture : application à la cartographie des fonds marins

Ronan Fablet

Département Signal & Communications

Tél : 02 29 00 12 87 - Fax : 02 29 00 10 12

courriel : ronan.fablet@telecom-bretagne.eu

Web : perso.enst-bretagne.eu/ronanfablet



Telecom Bretagne

- Yearly budget: 38 M€ - 70 % from State grant (Ministry of Industry)
- Staff: 354
 - 154 Professors
 - 20 full-time researchers
- > 1000 Students (MSc, PhD)
- UMR LabSTICC, équipe TOMS (~50 pers.)

3 schools
engineer

1 business
school

4 associated
schools
EURECOM and
Telecom Lille 1,
Telecom Saint
Étienne and ENSPS



Research@Telecom Bretagne: core topics

in ICT

■ Optical telecommunications

- *FOTON...*: devices and architecture of optical networks (Perdyn), liquid crystals

■ Networks and Computer engineering

- Mobile networks, Dynamic network engineering, Protocols and architectures, Internet of the Future

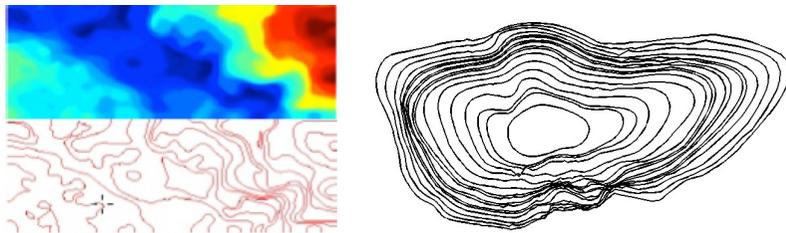
■ Digital communication, Coding theory, radiocommunications...,

- *Lab-STICC, PRACOM, ...*: microwave systems, digital communications, coding theory, algorithms and circuits, information processing, ...
- **LabSTICC/TOMS (remote sensing)**

Thèmes de recherche : contributions méthodologiques

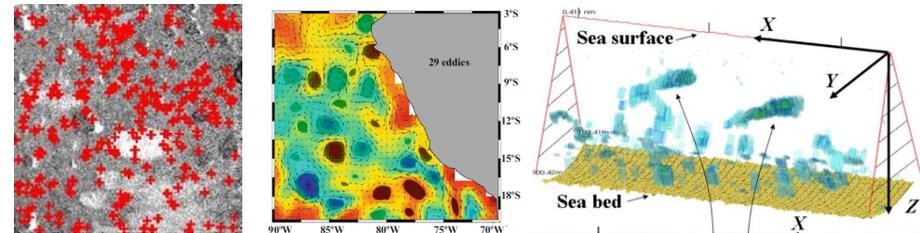
Géométrie des images & courbes, Géométrie stochastique

Extraction de structures géométriques
Régularité géométrique multi-échelle



[e.g., CVIU'2008, GRSL'2011]

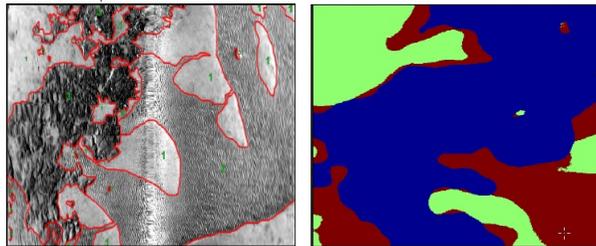
Distribution de signatures locales
Processus ponctuels marqués



[e.g., IEEE GRS 2011, CVPR'2011]

Apprentissage et Classification

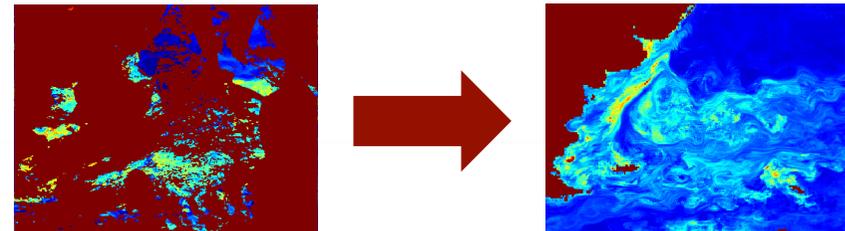
Méthodes de classification
Segmentation basée texture
Emulation statistique/super-résolution



[e.g., IEEE IP 2010, ECCV'2010]

Méthodes variationnelles

Détection et suivi de structures
Interpolation de données éparses
Assimilation multi-résolution



[e.g., IEEE IP 2010, ECCV'2006]



Thèmes de recherche : application en écologie marine et océanographie

Archives biologiques marines

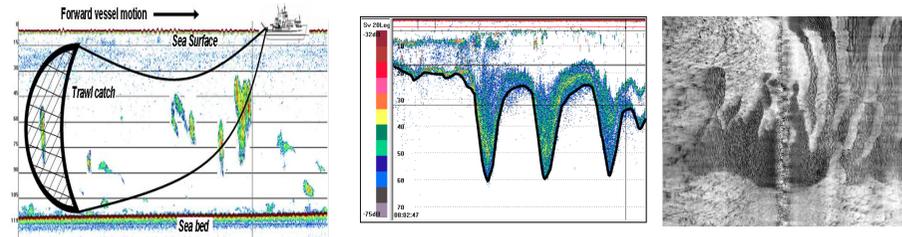
Morphogénèse
Modélisation bio-énergétique



[e.g., CVIU'2008, PLOS One'2011]

Observation sonar de l'océan

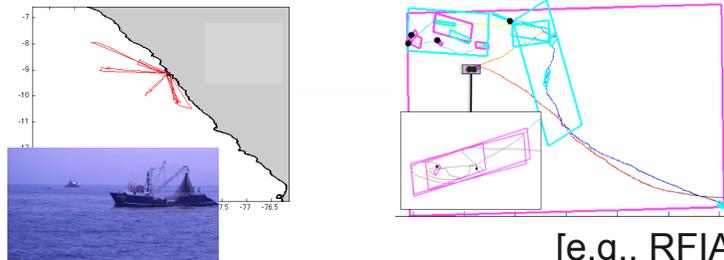
Cartographie des fonds marins
Imagerie sonar de la colonne d'eau



[e.g., GRSL 2011, IEEE GRS 2011, IEEE IP 2011]

Données trajectométriques

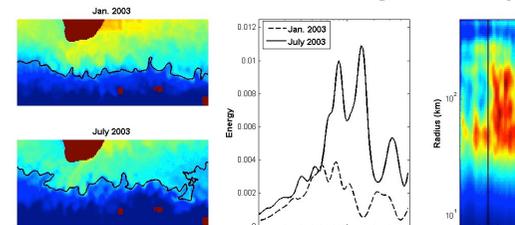
Modèle de marches aléatoires
Détection de structures
Segmentation espace-état



[e.g., RFIA'2012]

Obs. satellitaires de l'océan

Dynamique des zones de front
Interpolation multirésolution
Estimation de champs géophysiques



[e.g., GRSL'2011, ICIP'2011]

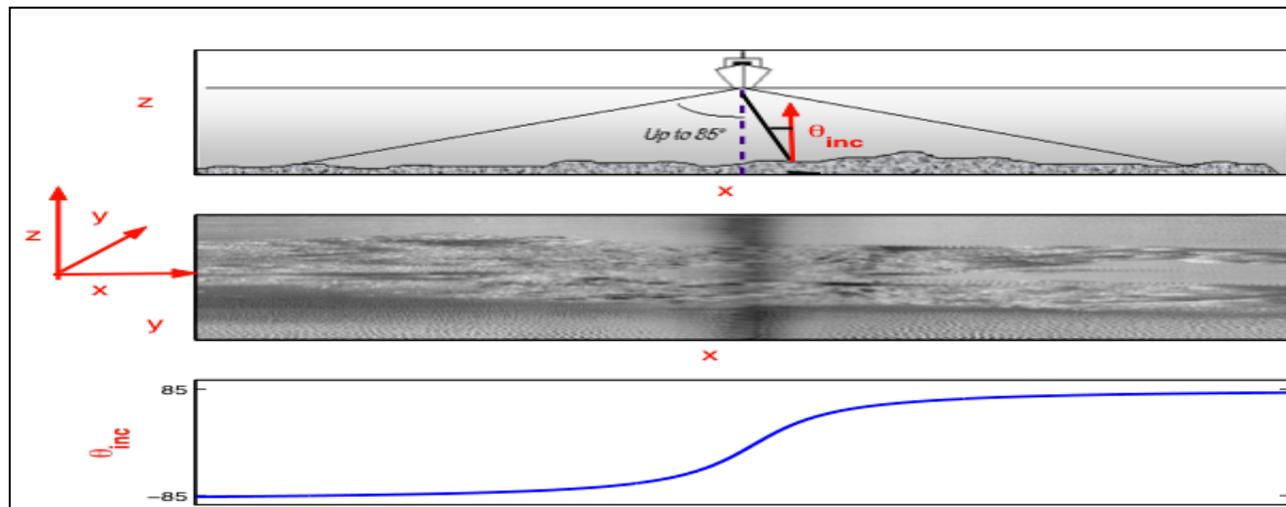
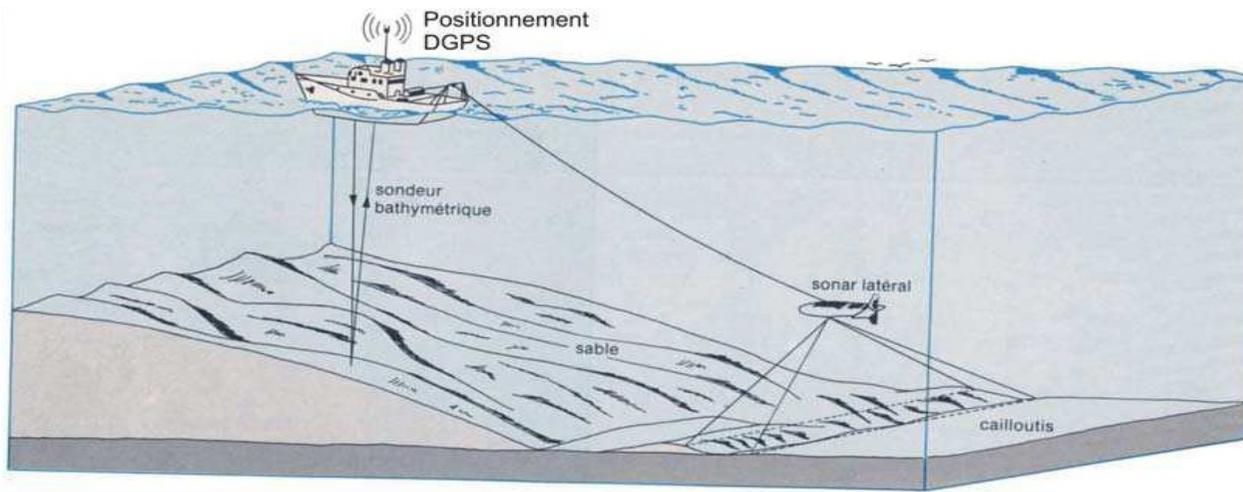


Cartographie des fonds marins par imagerie sonar





Principe de l'imagerie sonar des fonds marins

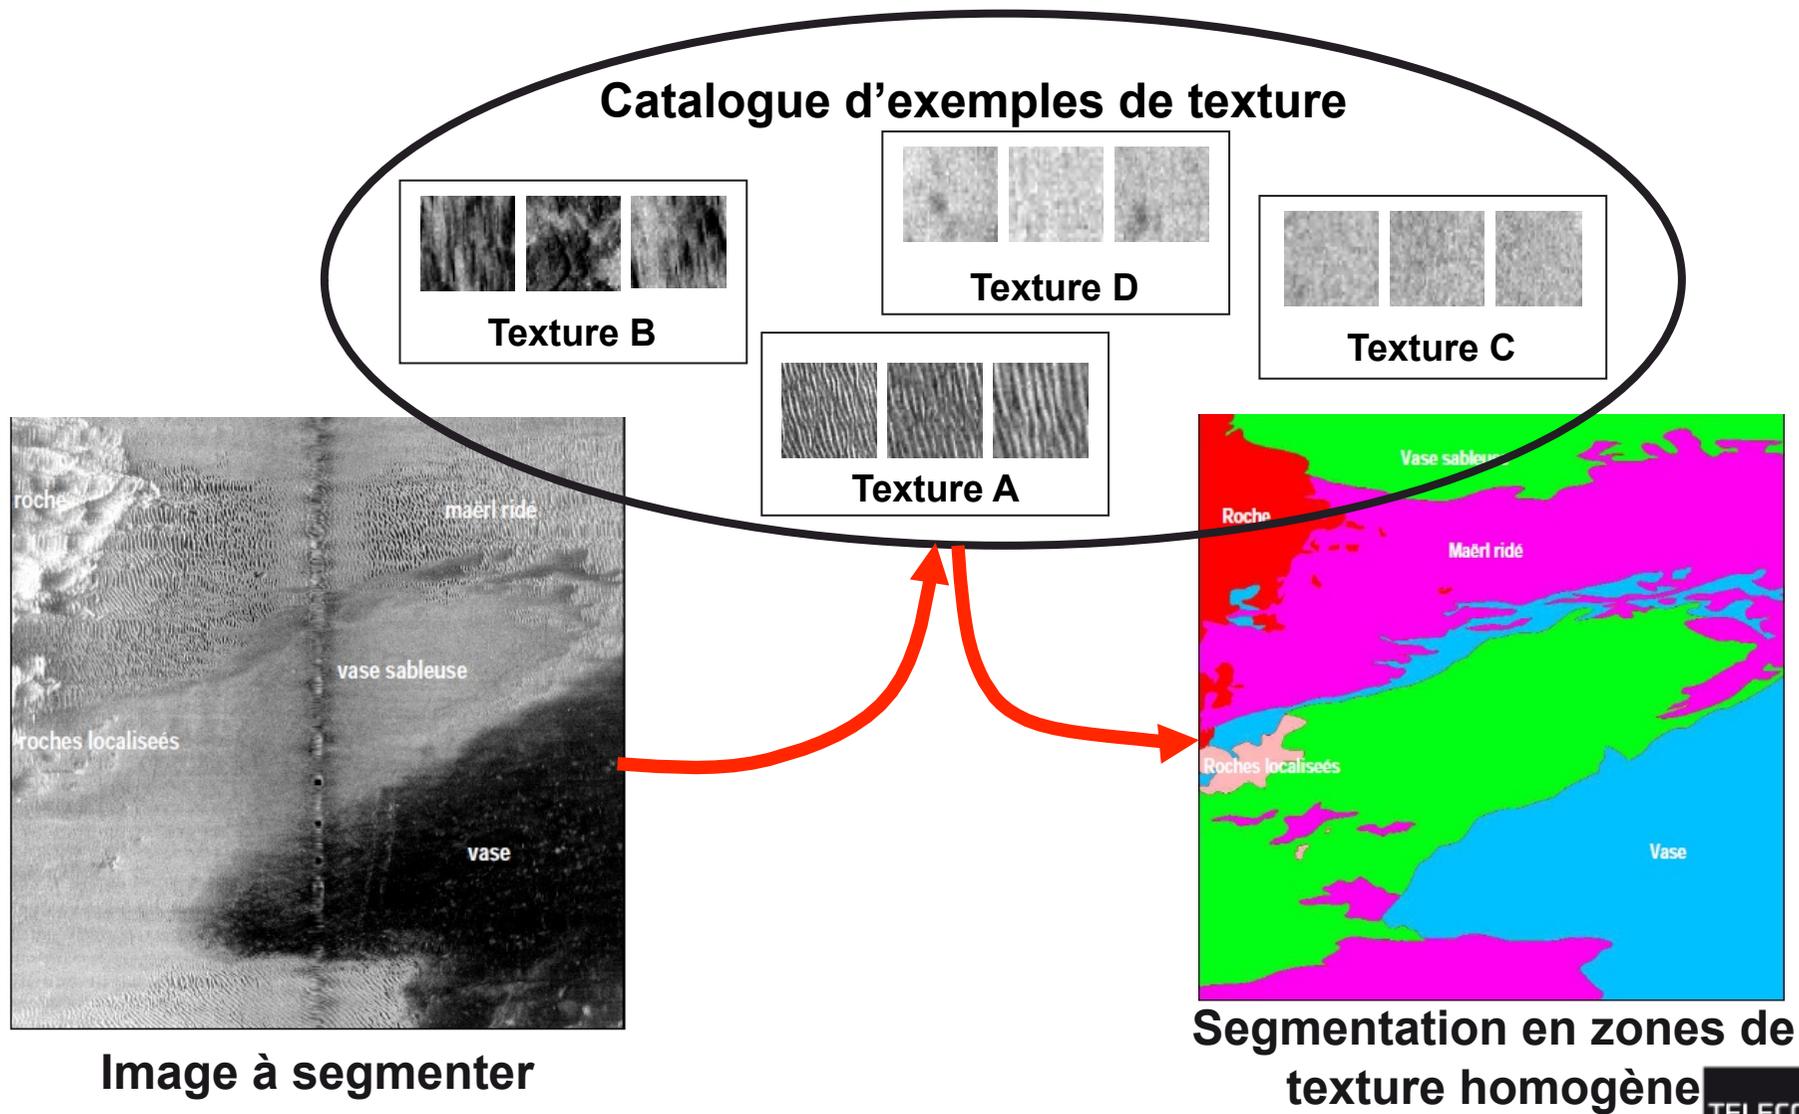


Principe de la cartographie sonar des fonds marins



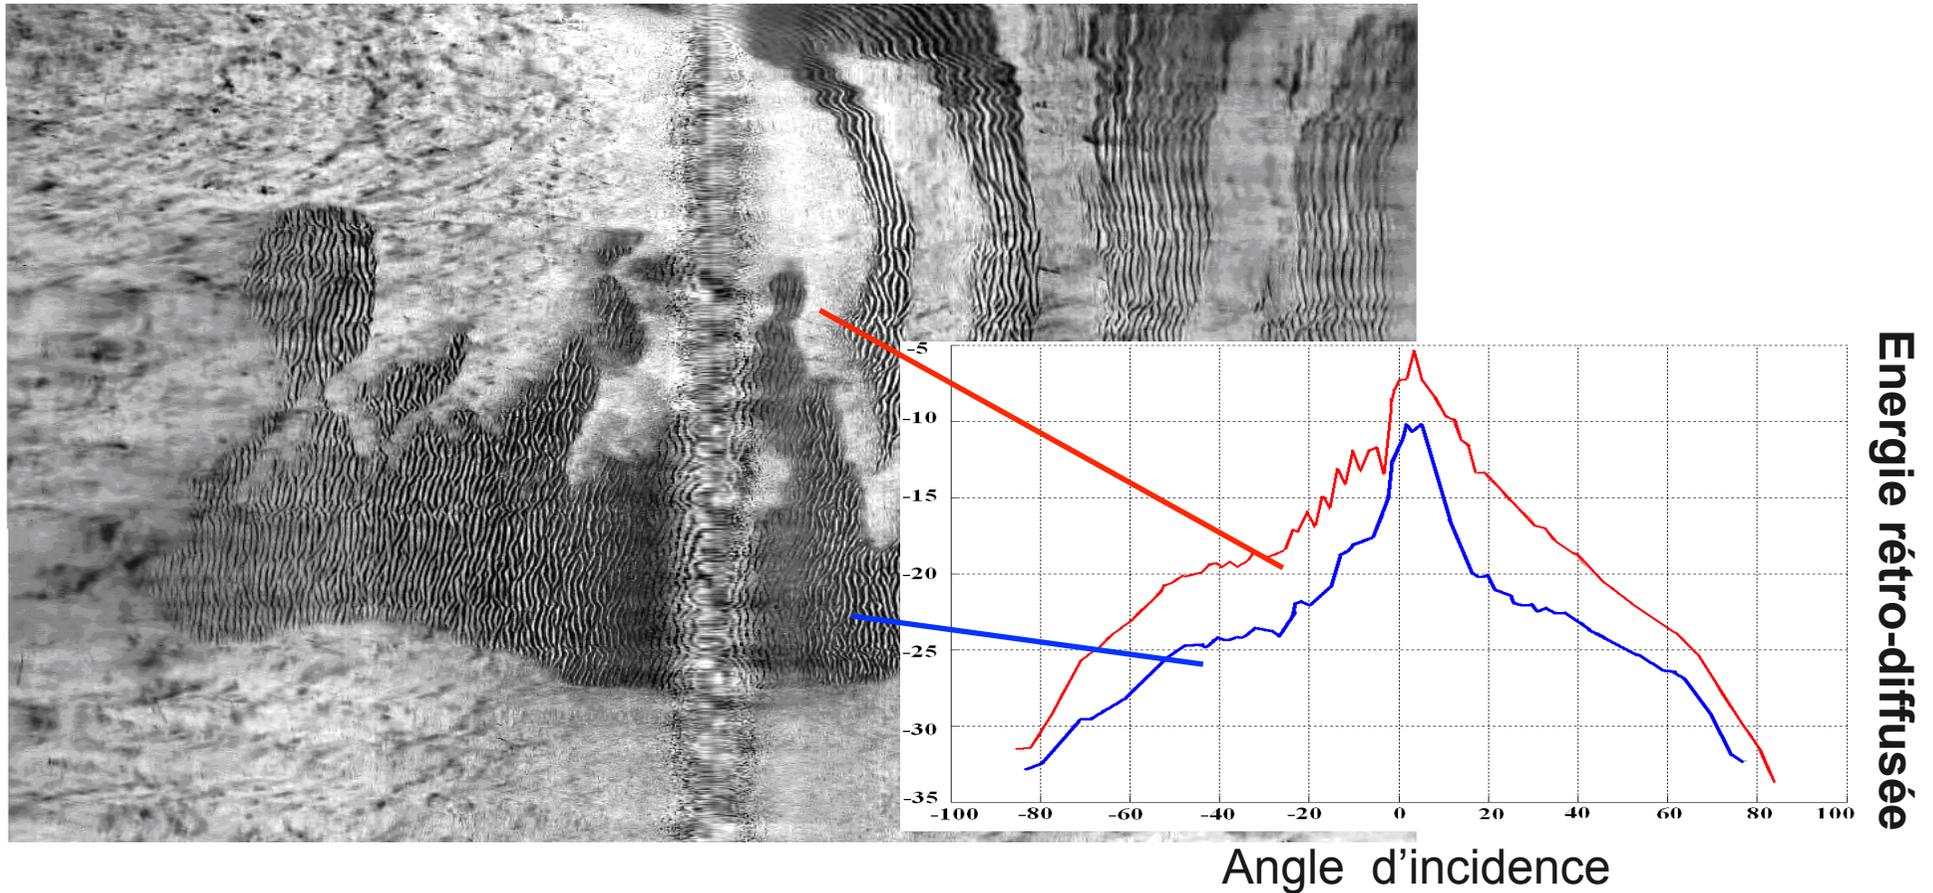


Principe de la cartographie supervisée des fonds marins par reconnaissance de texture



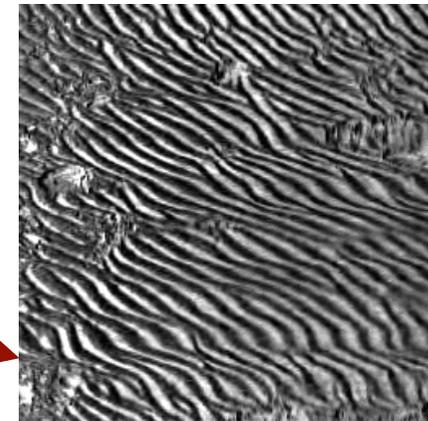
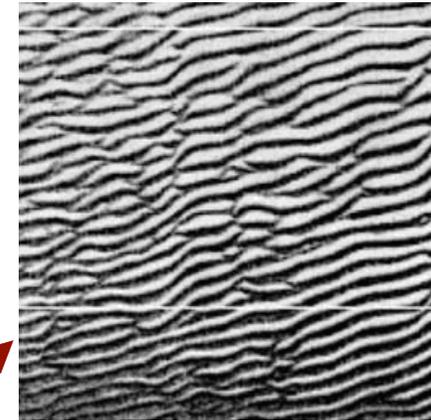
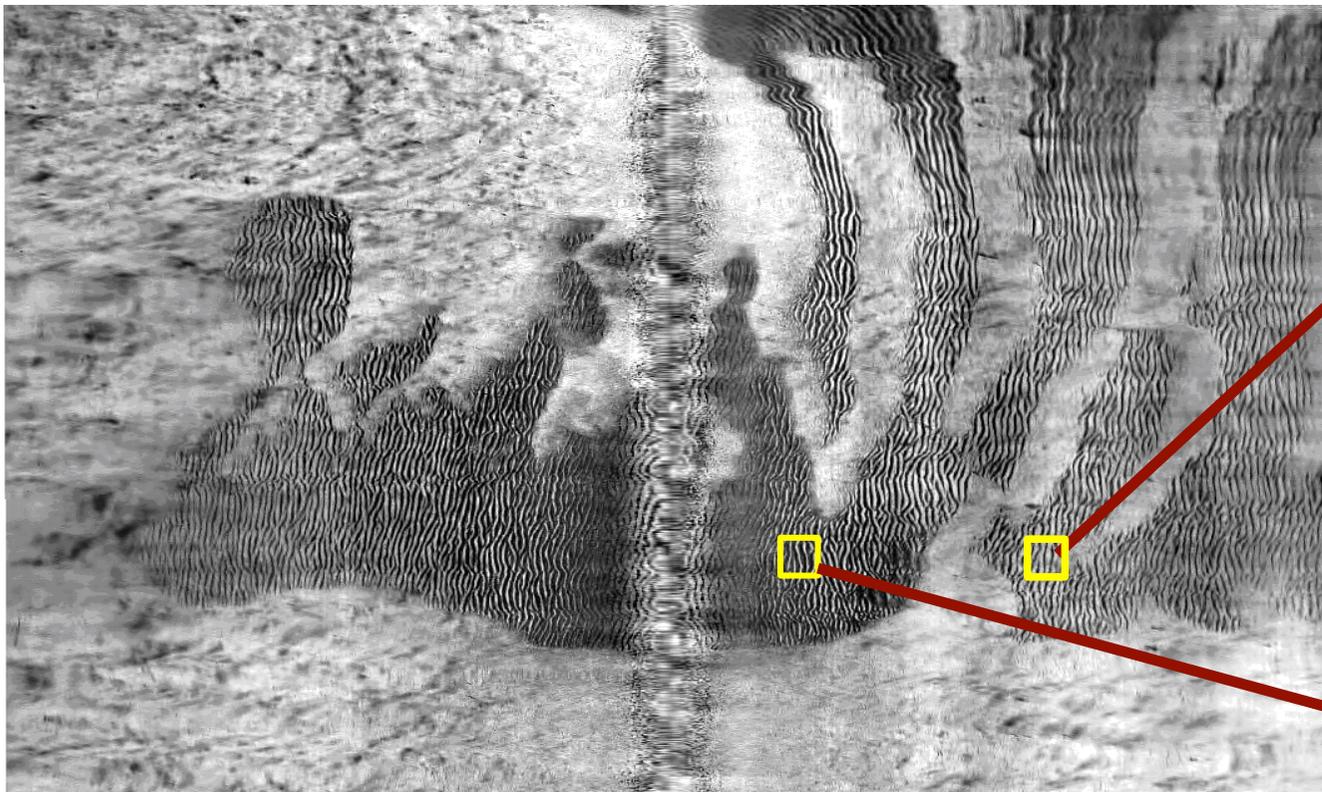
Caractéristiques des textures sonar : distorsions associées

■ Distorsions « photométriques »



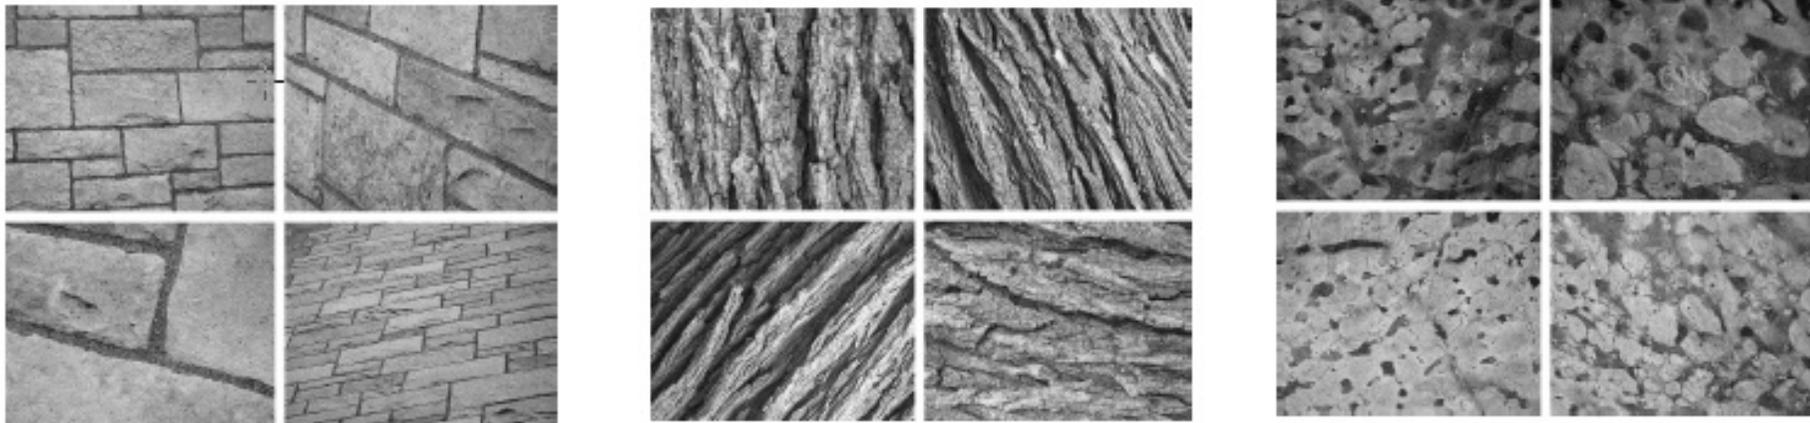
■ Caractéristiques des textures sonar : ■ distorsions associées

■ Distorsions « géométriques »



■ Généricité des problématiques d'invariance ■ en vision par ordinateur

- Variabilité des caractéristiques des textures visuelles en fonction des conditions d'acquisition



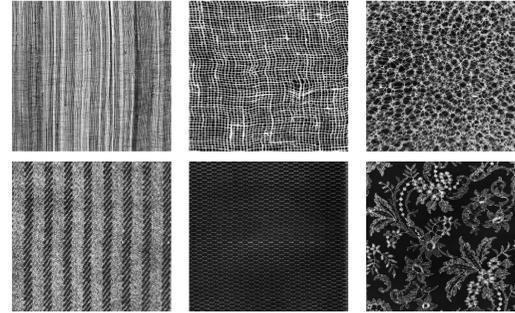
Propriétés recherchées pour l'analyse des textures :

- Invariance géométrique (translation, rotation, transformation affine,...)
- Invariance au changement de contraste : Le changement de contraste entre deux images est une transformation ϕ de l'image telle que:

$$\Phi(0) = 0 \quad \Phi(1) = 1 \quad \Phi'(x) \geq 0$$

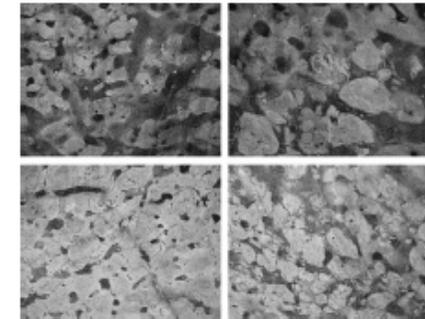
Reconnaissance de texture et d'objets en vision par ordinateur

Descripteurs d'Haralick (70's)
Matrice de Cooccurrences
Textures de Brodatz



Modèles 3D
(70-80)

Filtres de Gabor
Filtres orientés (80's)



Points d'intérêt
(Harris & Stephen 88)

Invariance aux transformations géométriques (rotation) (90's)



Descripteurs globaux (90's)

Descripteurs locaux (95->)
Invariances : contraste & Géométrie

Signatures locales (2004-)
Invariances: contraste & géométrie
Nouvelles bases de texture

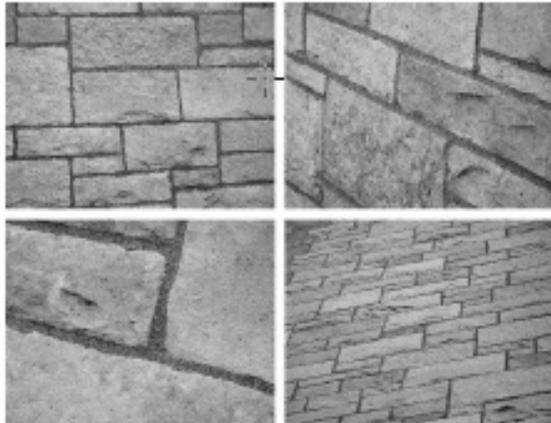


Points d'intérêt SIFT (Lowe 2001)
Bags of Features/Sacs de mots
Reconnaissance de scènes

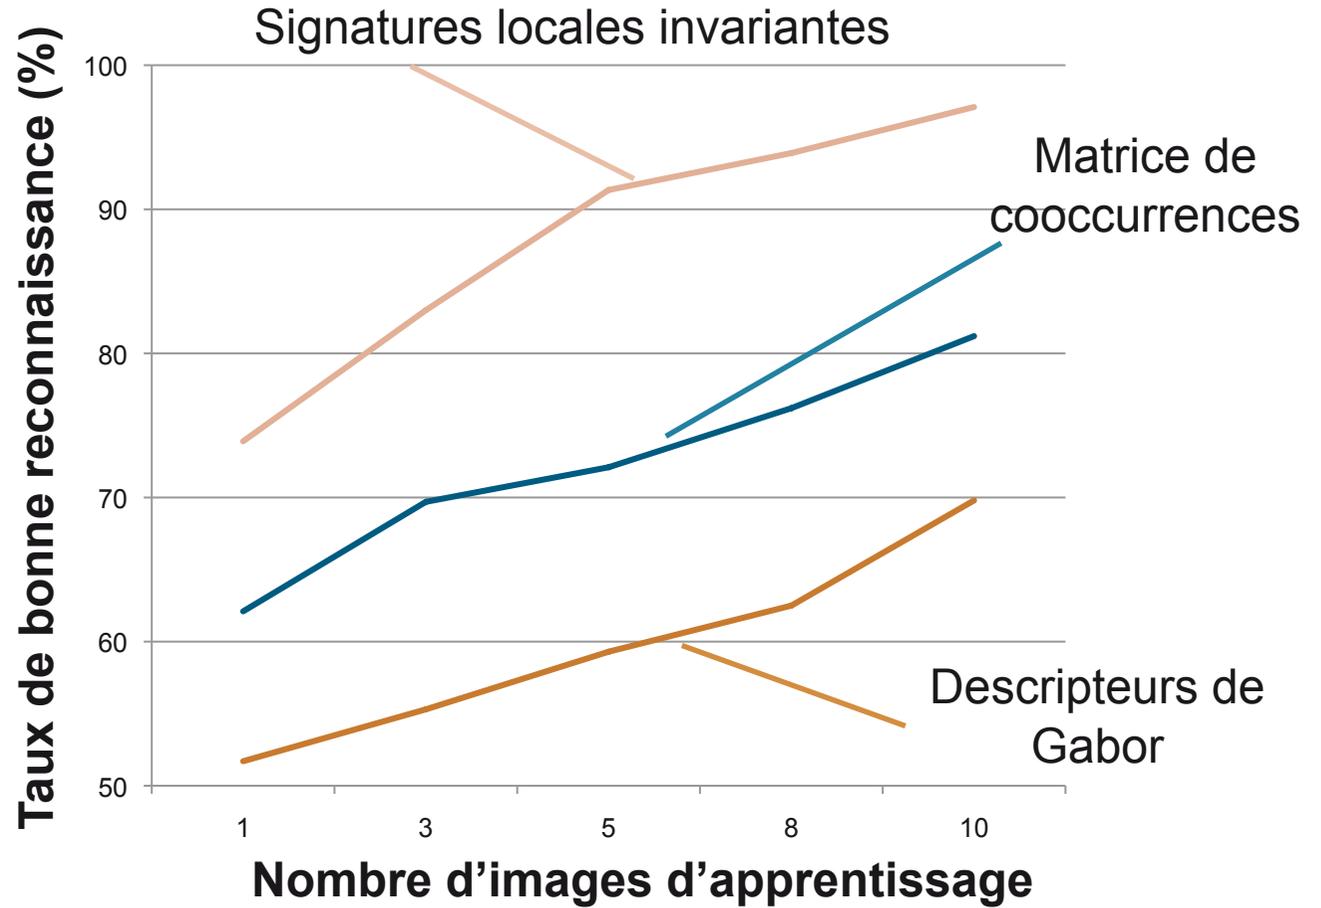




Reconnaissance de texture : quelles avancées en 30/40 ans?



Base UIUC

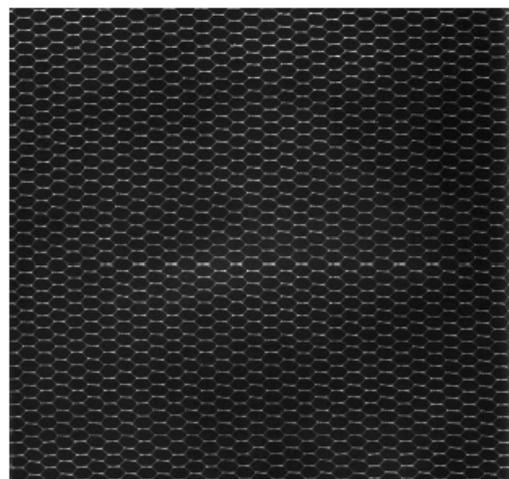
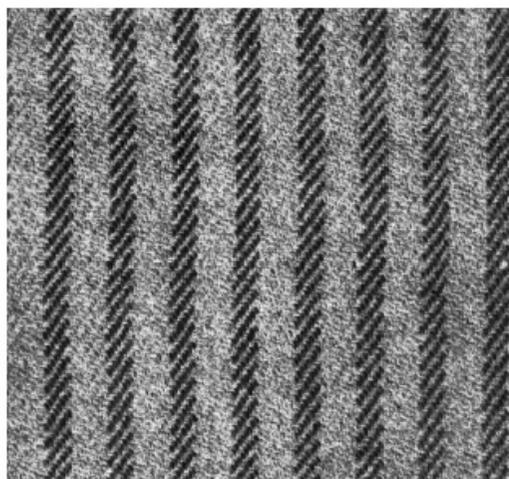
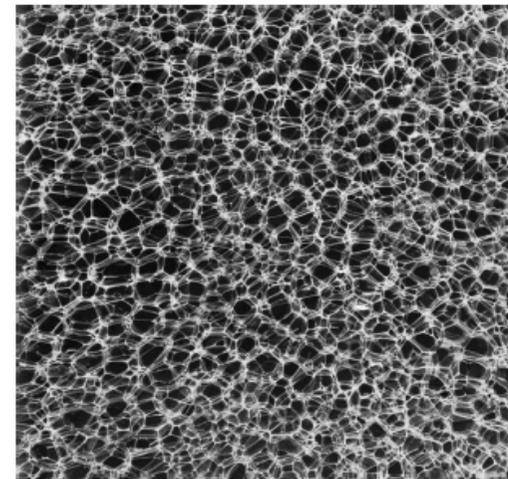
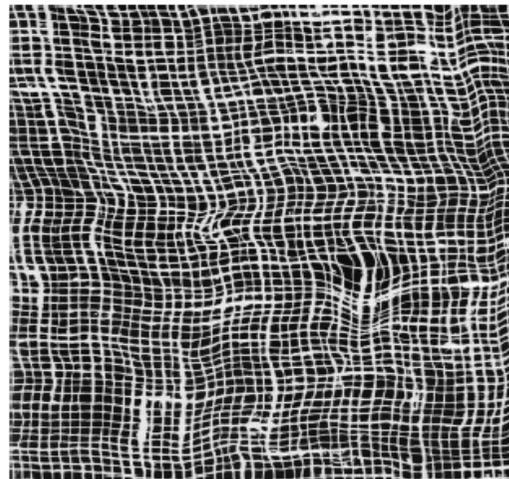




Analyse de texture : descripteurs globaux



Des exemples de texture

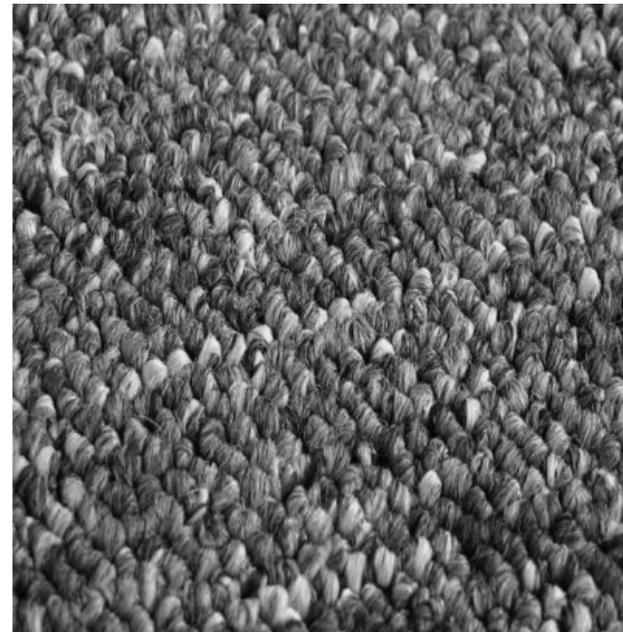
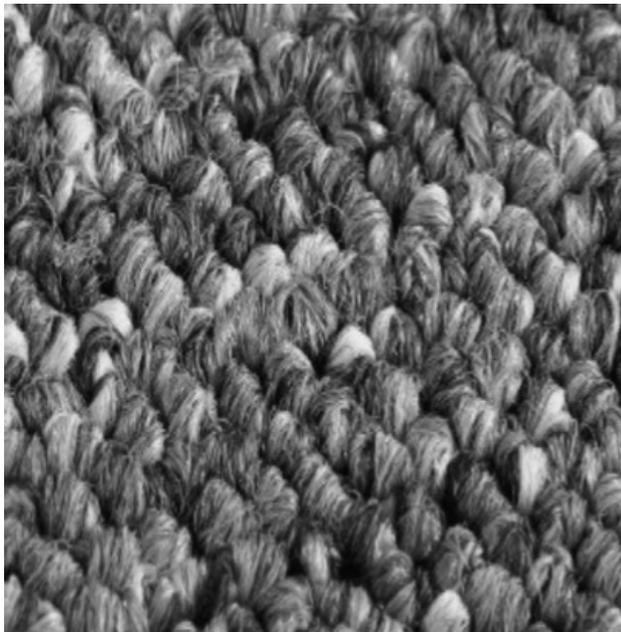


Exemples de textures de Brodatz

Comment analyser des textures ?

Difficultés

- Pas de modèle mathématique suffisamment général et manipulable
- Pas de notion satisfaisante de distance entre textures
- Notion fortement dépendante de l'échelle (Invariance en échelle?)



Une approche assez naturellement statistique/probabiliste

Comment analyser des textures ?

La plupart des méthodes considèrent une texture comme la réalisation d'un champ aléatoire.

■ **Problème** : quelles sont les statistiques pertinentes pour la perception d'une texture ?

- **Beck 73** : statistiques d'ordre 1 sur des “propriétés” (contraste, orientation, couleurs)
- **Julesz 73-75** : statistiques d'ordre 1 et 2 entre valeurs ponctuelles de niveau de gris (cf. matrice de cooccurrences d'Haralick)
- **Julesz 81** : statistiques d'ordre 1 et 2 entre “textons” (éléments structurés, terminaisons, jonctions en “T”,...)

■ **Problème** : à quels objets mathématiques correspondent les textons ?

Descripteurs globaux : Matrices de cooccurrences (Haralick'73)

- **Définition** : Il s'agit de statistiques du second-ordre de l'image. Pour un voisinage (dx,dy), la matrice de cooccurrence $M(dx,dy)$ est donnée par :

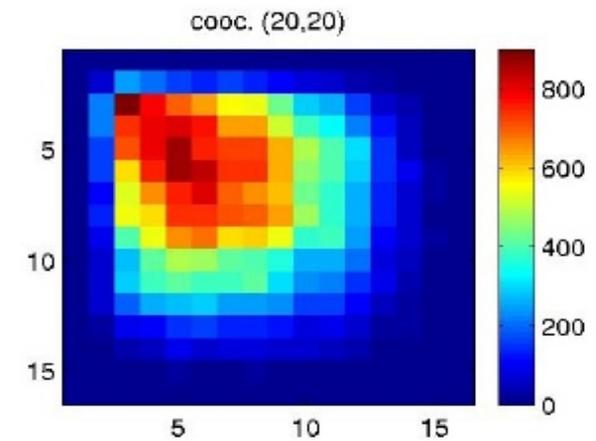
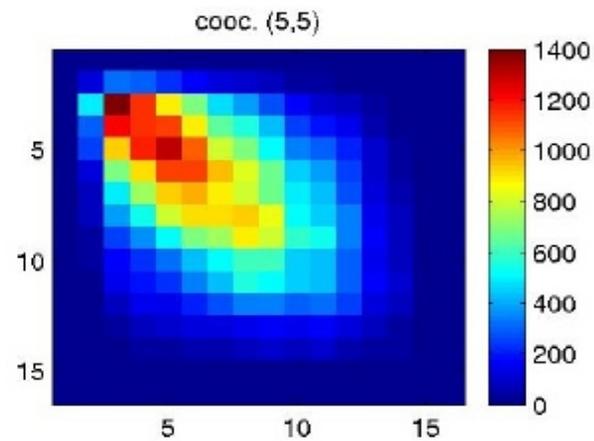
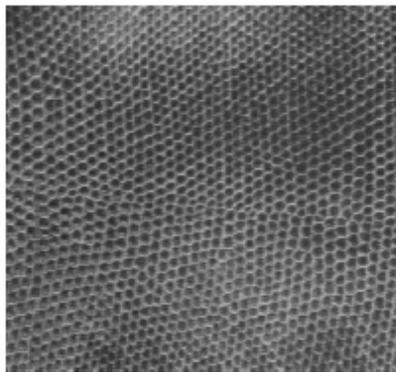
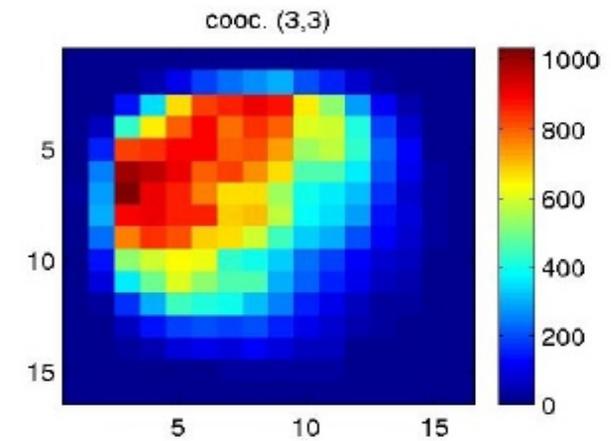
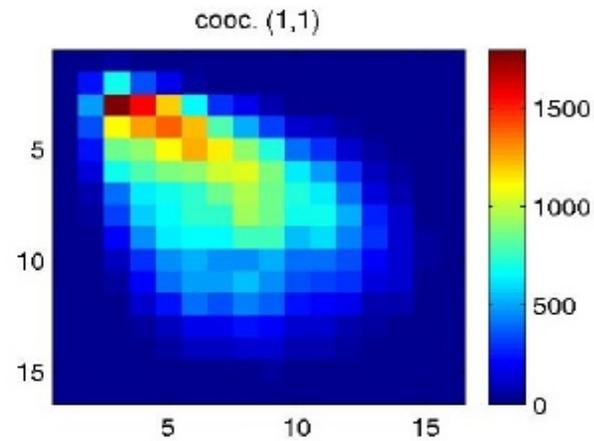
$$M_{[dx,dy]}(u,v) = \frac{1}{(N_x - dx)(N_y - dy)} \sum_{i,j} 1[I(i,j) = u \& I(i + dx, j + dy) = v]$$

- (N_x, N_y) : taille de l'image
- (u,v) : niveaux de gris de l'image (valeur quantifiée)
- Chaque matrice est de taille $G \times G$ où G est le nombre de niveaux de gris (on considère généralement 8 ou 16 niveaux)
- On considère généralement des matrices de cooccurrences pour un ensemble de voisinage (dx,dy) (e.g., (1,0), (0,1), (1,1),)



Matrices de cooccurrences (Haralick'73)

Exemples de matrices de cooccurrences





Matrices de cooccurrences (Haralick'73)

- Calcul de descripteurs

$$MOYENNE = \sum_j \sum_i p(i, j)$$

$$VARIANCE_i = \sum_j \sum_i (i - MOYENNE)^2 p(i, j)$$

$$ENERGIE = \sum_j \sum_i (p(i, j))^2$$

$$INERTIE = \sum_j \sum_i (i - j)^2 p(i, j)$$

$$ENTROPIE = - \sum_j \sum_i p(i, j) \log(p(i, j))$$

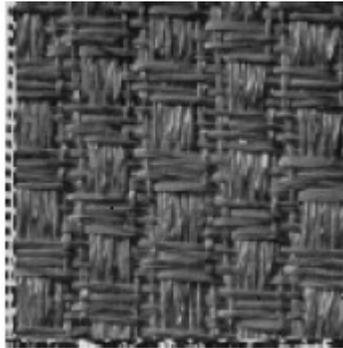
$$MOMENT DIFFERENTIEL INVERSE = \sum_i \sum_j \frac{1}{1 + (i - j)^2} p(i, j)$$

où

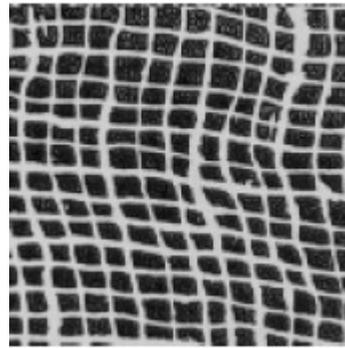
(i,j) : coordonnées dans la matrice

p(i,j) : valeurs normalisées de la matrice

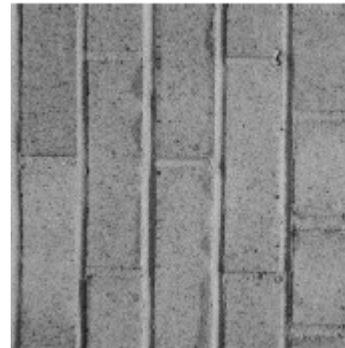
Matrices de cooccurrences (Haralick'73)



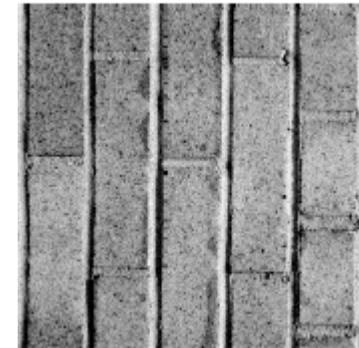
contraste=120



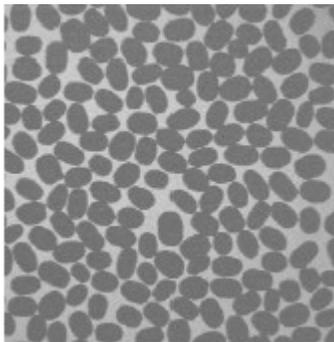
contraste=626



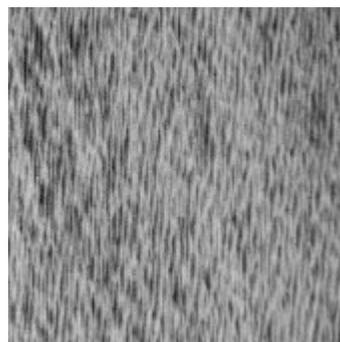
contraste=42



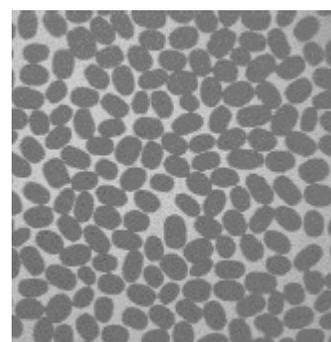
contraste=142



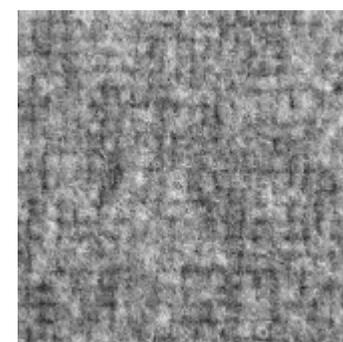
entropie=6.7



entropie=4.7



mdi=0.03



mdi=0.002

Matrices de cooccurrences (Haralick'73)

■ Intérêt des matrices de cooccurrences

- Caractérisation statistique des cooccurrences
- Relation statistiques descriptives \leftrightarrow modèles probabilistes (statistiques suffisantes de modèles Markoviens définis sur des cliques d'ordre 2)

■ Limites

- Pas d'invariance au changement de contraste ou aux distorsions géométriques
- Nécessité de disposer d'exemples couvrant l'ensemble des distorsions possibles pour définir un modèle robuste de reconnaissance



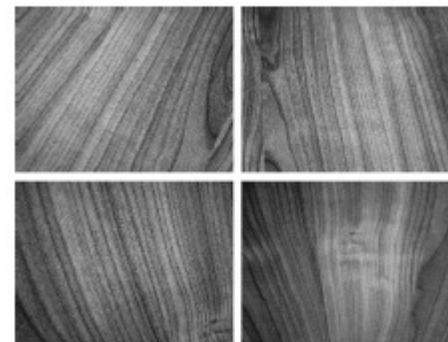
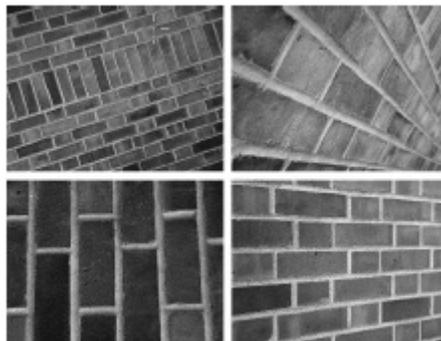
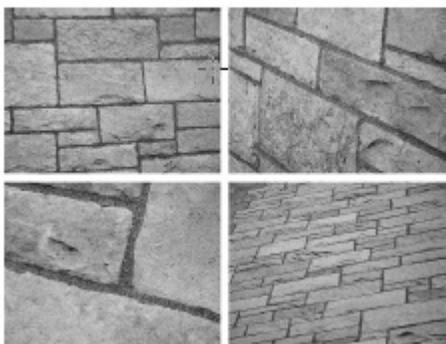
Texture et caractérisation invariante



Propriétés d'invariance recherchées

Invariance aux conditions d'acquisition des images

- Invariance géométrique : translation, rotation, zoom, transformation affine



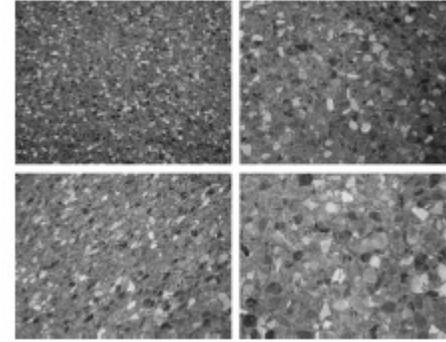
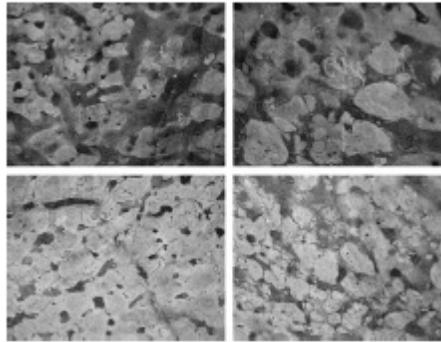
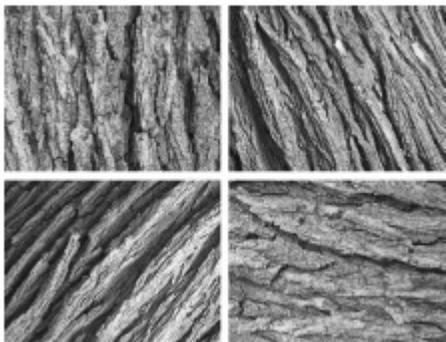
Propriétés d'invariance recherchées

Invariance aux conditions d'acquisition des images

- Invariance photométrique : invariance au changement de contraste

Le changement de contraste entre deux images est une transformation ϕ de l'image telle que:

$$\Phi(0) = 0 \quad \Phi(1) = 1 \quad \Phi'(x) \geq 0$$



Méthodes de caractérisation invariante

Méthodes globales :

- Calcul de statistiques invariantes à des transformations géométriques (rotation), e.g. cooccurrences sur des voisinages « circulaires »
- Calcul de statistiques invariantes à des changements de contraste linéaires, e.g. statistiques de différence d'intensité pour des points voisins

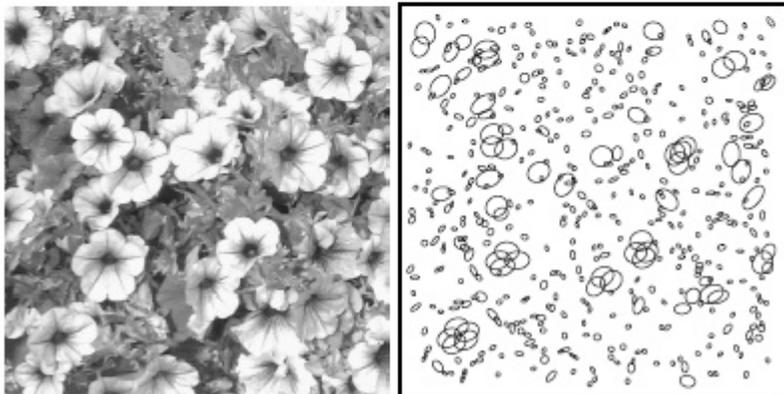
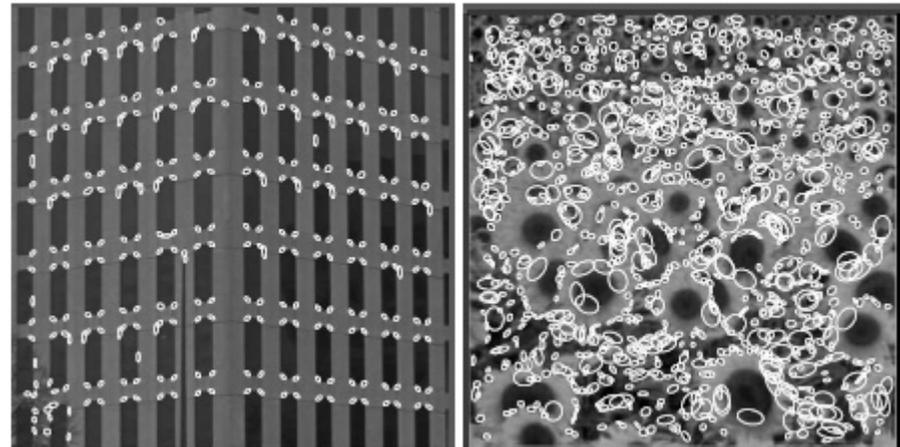
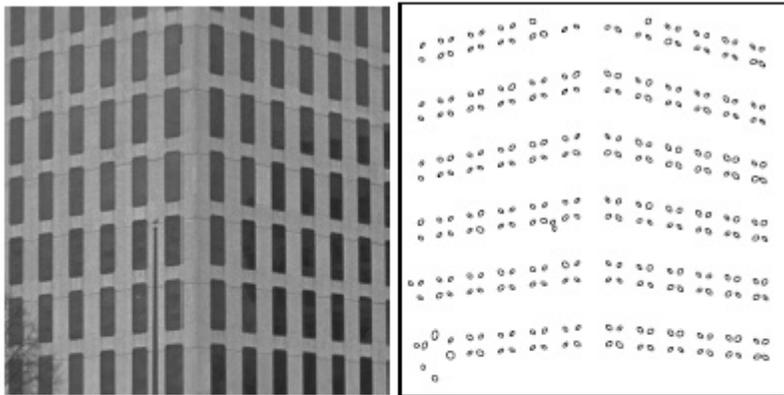
Méthodes locales :

- Extraction de points d'intérêt (Détecteur de Harris, DoG,...)
- Caractérisation invariante des points d'intérêt (eg, descripteur SIFT)
- Approches alternatives : statistiques «denses» de mesures locales invariantes (e.g., caractéristiques de forme (Xao et al. 2011), indice fractal local (Xu et al. 2010))

Extraction de points d'intérêt dans les images

Principe :

- Détection de points anguleux « coins » : points de fort changement de contraste

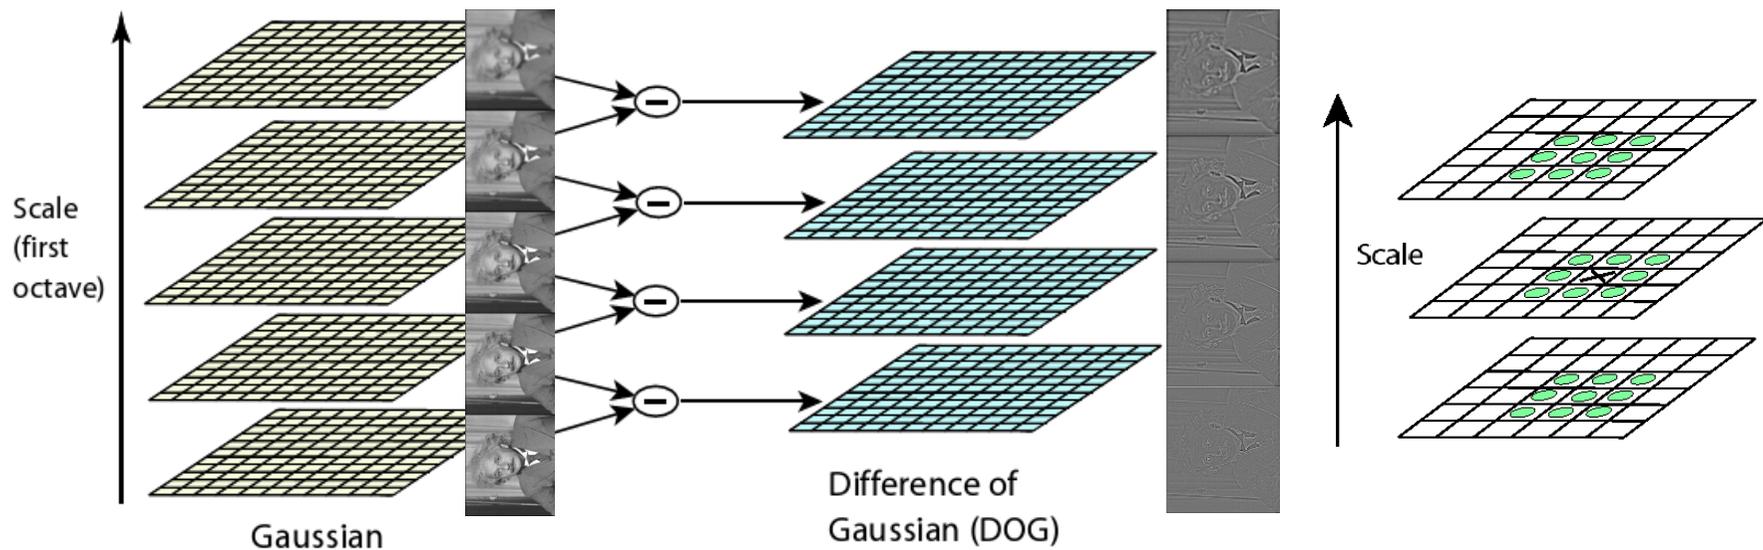


Eg, détecteur de Harris (Harris&Stephens 88)

Coin = variations fortes de l'intensité dans deux directions

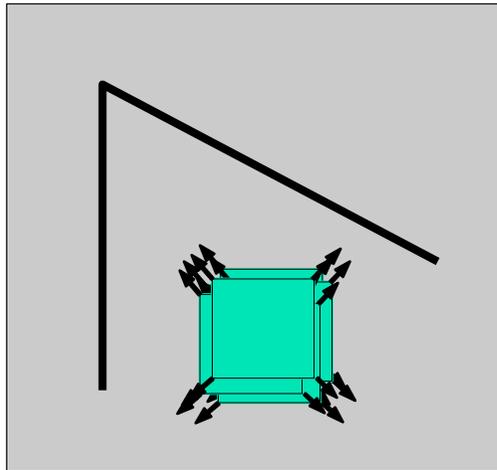
Points d'intérêt DoG (Difference of Gaussian)

e.g., local extrema in Gaussian scale-spaces [Lowe 2001]

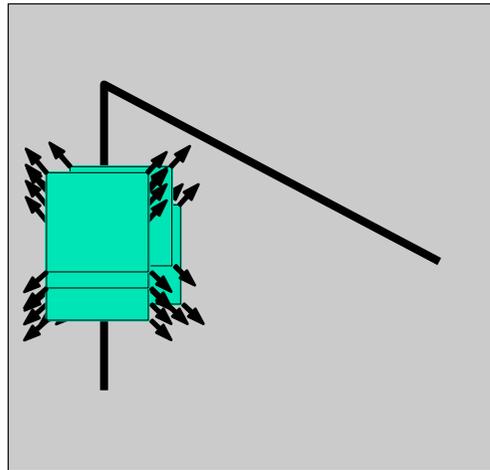


Extraction de points d'intérêt – Détecteur de Harris-Stephens [88]

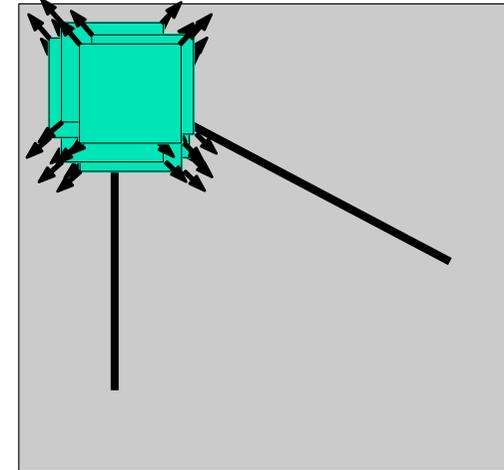
Principe : extraction de coins



Zone “homogène” : aucun changement dans aucune direction



“contour” : changement dans une seule direction



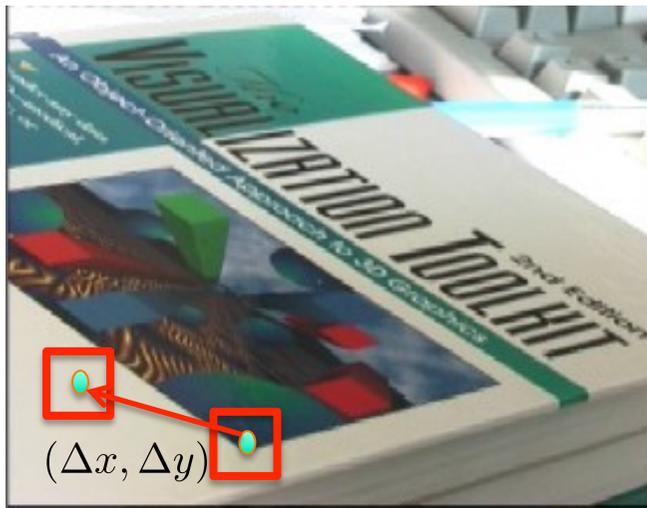
“coin” : changements dans plusieurs directions

Source : Frolova & Simakov, *Invariant Feature Detectors and Descriptors*, Weizmann Ins. (Israel).

Extraction de points d'intérêt – Détecteur de Harris-Stephen [88]

Principe : extraction de points anguleux

Les points anguleux sont des points de fort changement local de contraste, i.e. l'intensité varie significativement autour du point



$$\chi(x, y) = \sum_{(x_k, y_k) \in W} (I(x_k, y_k) - I(x_k + \Delta x, y_k + \Delta y))^2$$

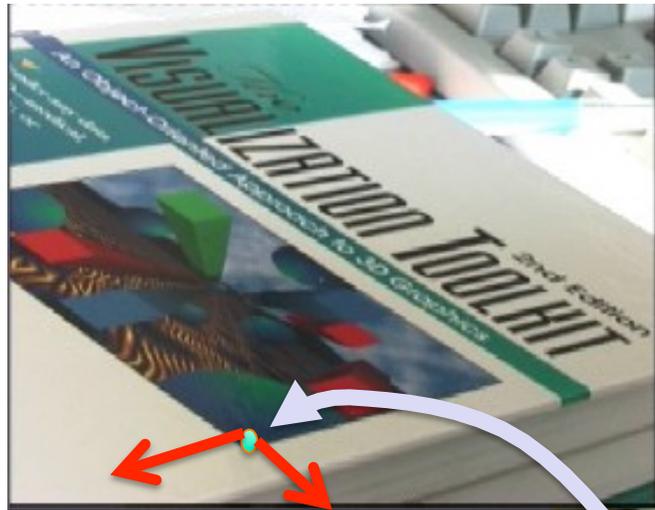
$$\chi(x, y) = [\Delta x; \Delta y] \Sigma [\Delta x; \Delta y]^t$$

$$\Sigma = \sum_{(x_k, y_k) \in W} \nabla I(x_k, y_k) \nabla I(x_k, y_k)^t$$

Tenseur de structure

Extraction de points d'intérêt – Détecteur de Harris-Stephen [88]

Principe : détection des points pour lesquelles la matrice d'autocorrélation traduit des variations importantes de l'intensité dans toutes les directions



$$\det(\Sigma) - \alpha \text{Trace}(\Sigma)^2$$

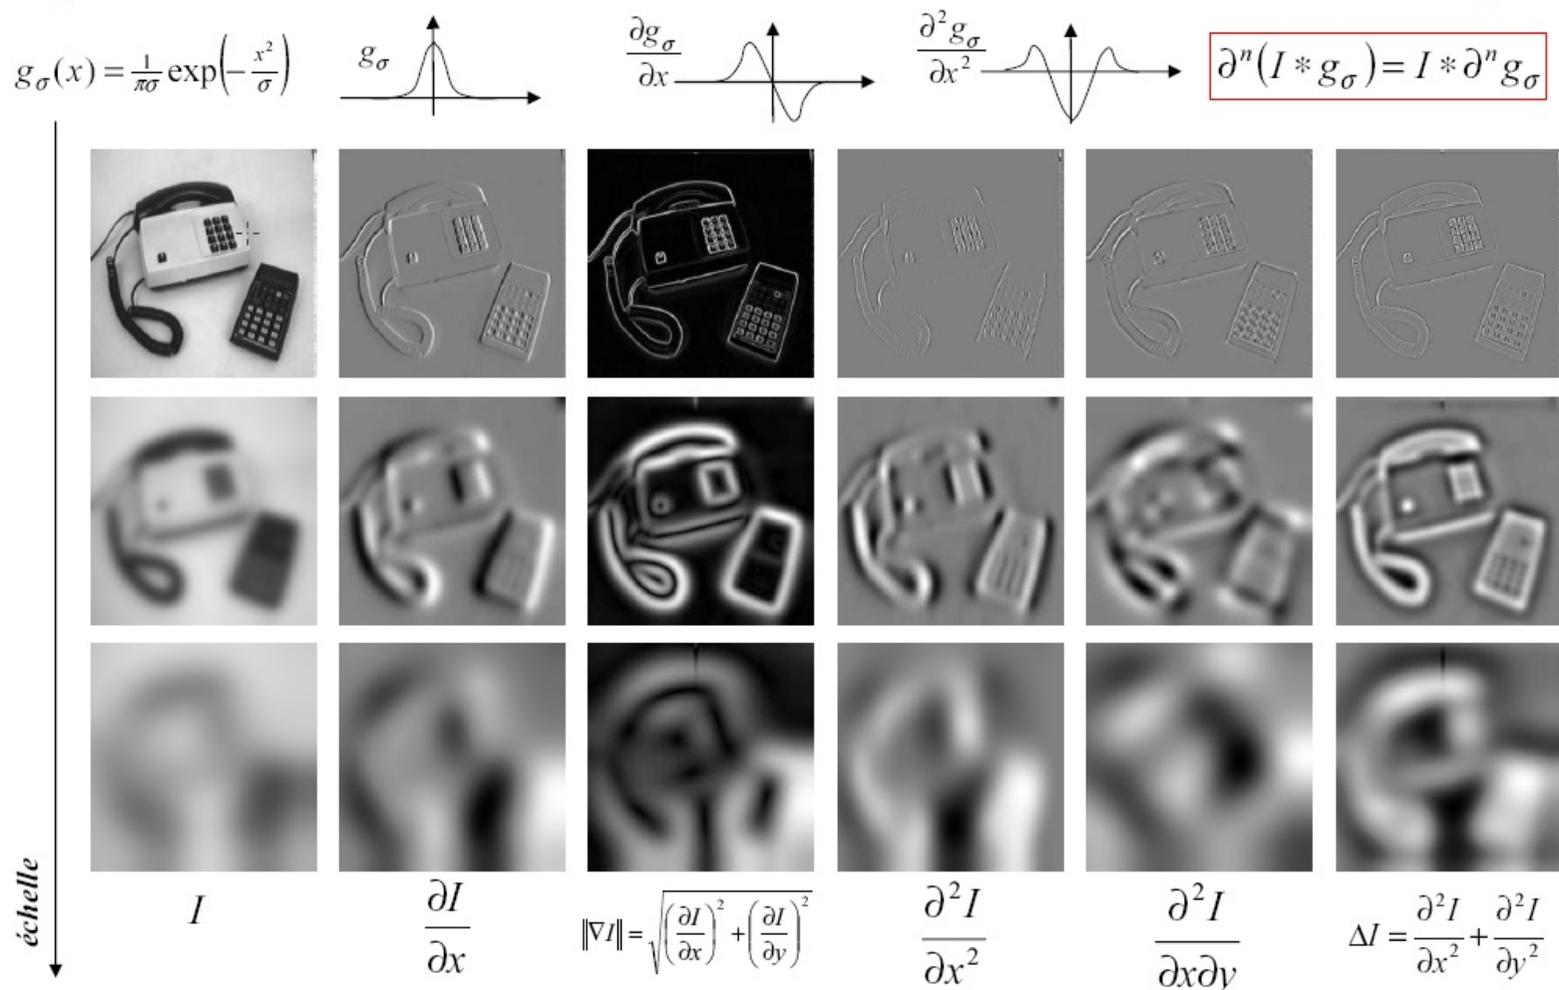
Favorise des valeurs propres importantes

Défavorise les contours pour lesquels une seule valeur est importante

Les points retenus sont ceux pour lesquels le critère est localement maximal (et au-dessus d'un seuil).

Extraction de points d'intérêt – Détecteur de Harris-Stephens [88]

Espace d'échelle gaussien



Points d'intérêt



Détection de points d'intérêt



Harris



Harris-Laplacien



Harris-Affine

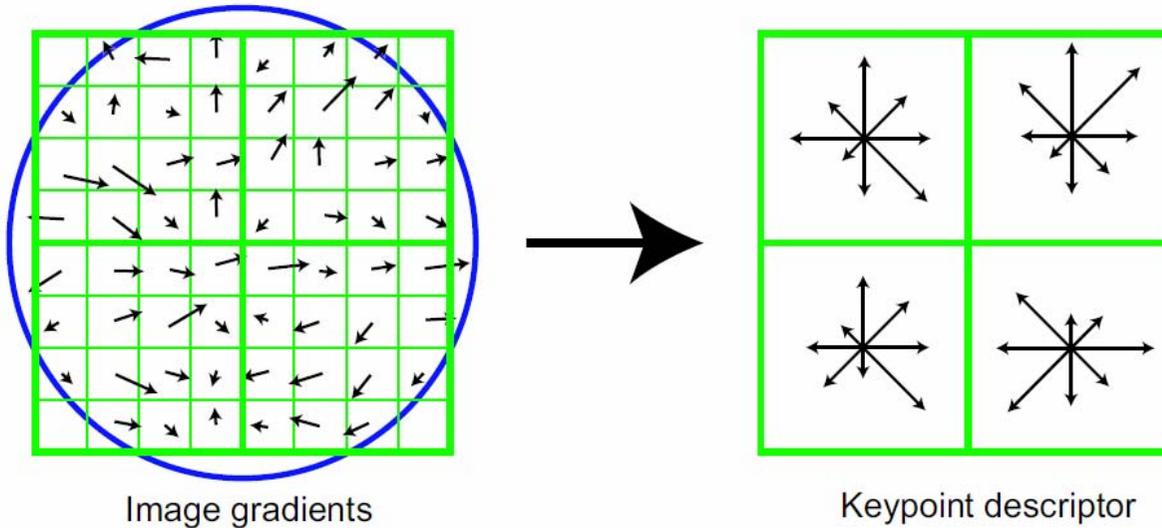


DoG

Détecteur	Coin	Région	Rotation	Echelle	Affine	Réf.
→ Harris	x		x			Harris88
→ Harris-Laplacien	x	(x)	x	x		Mikolajczyk01
→ Hessienne-Laplacien	(x)	x	x	x		
→ Harris-Affine	x	(x)	x	x	x	Mikolajczyk05
→ Fast Hessien	(x)	x	x	x		Bay06
→ DoG	(x)	x	x	x		Lowe04

Détection de points d'intérêt (Tuytelaars 07)

Descripteurs SIFT (Lowe, 2000)

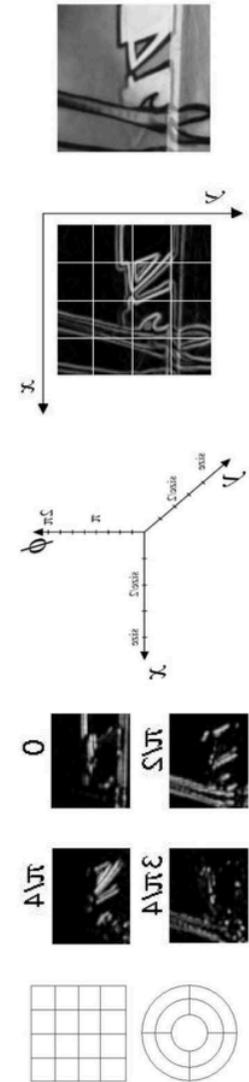


Calcul des **histogrammes des orientations** dans 8 directions dans des fenêtres autour du point d'intérêt

Invariance en rotation : « normalisation » par rapport à l'orientation locale principale

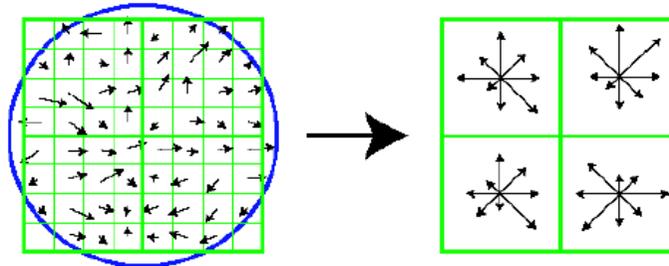
Invariance au changement de contraste : statistiques d'orientation

Invariance aux «petites» distorsions affines



From (Mikolajczyk & Schmid, 2005)

Différents descripteurs de points d'intérêt

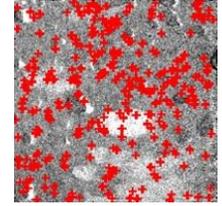


Scale-invariant feature transform- DoG
+SIFT (Lowe 04)

Détecteur	DoG	Fast-Hes	Fast-Hes	Hes-Lap	Har-Lap
Descripteur	Sift	Surf	Brief	Daisy	Sift-Spin
Réf.	Lowe04	Bay 06	Calonder10	Tola10	Zhang07
SIFT Lowe04	SURF Bay06	GLOH Mikolajczyk05	CS-LBP Heikkilä09	DAISY Tola10	

Robotique

Reconnaissance de texture à partir de points d'intérêt visuels



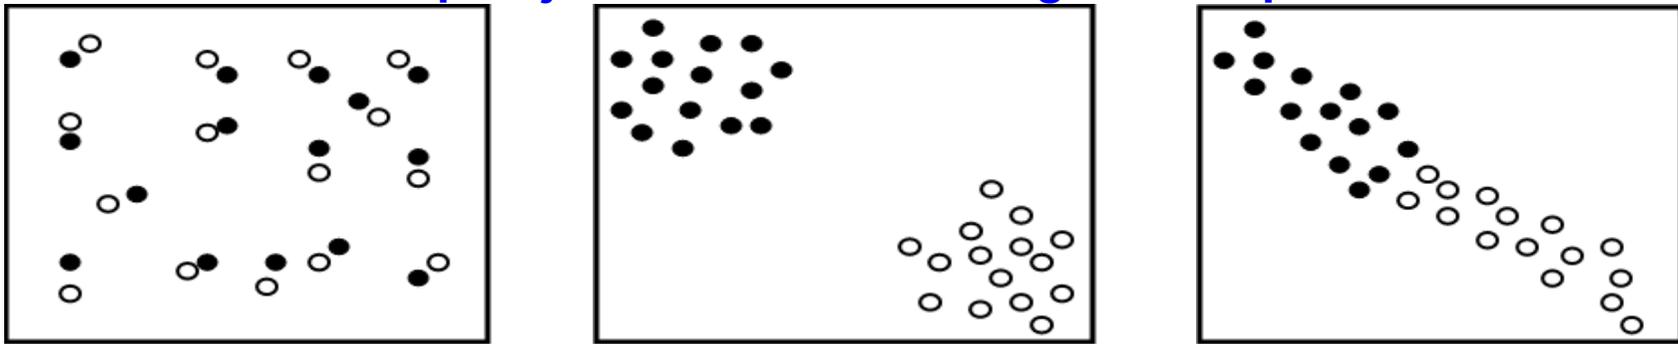
■ Principe : image = ensemble de points d'intérêt

- *Classification des points d'intérêt puis « vote » au niveau image* [eg, Lazebnik, 05]
- *Descripteurs globaux à partir de statistiques des caractéristiques des points d'intérêt :*
 - *Histogramme de catégories de points d'intérêt* Bags-of-Keypoints [e.g., Csurka et al., 04]
 - *Statistiques spatiales d'ensemble de points d'intérêt* [Nguyen et al., 2010]

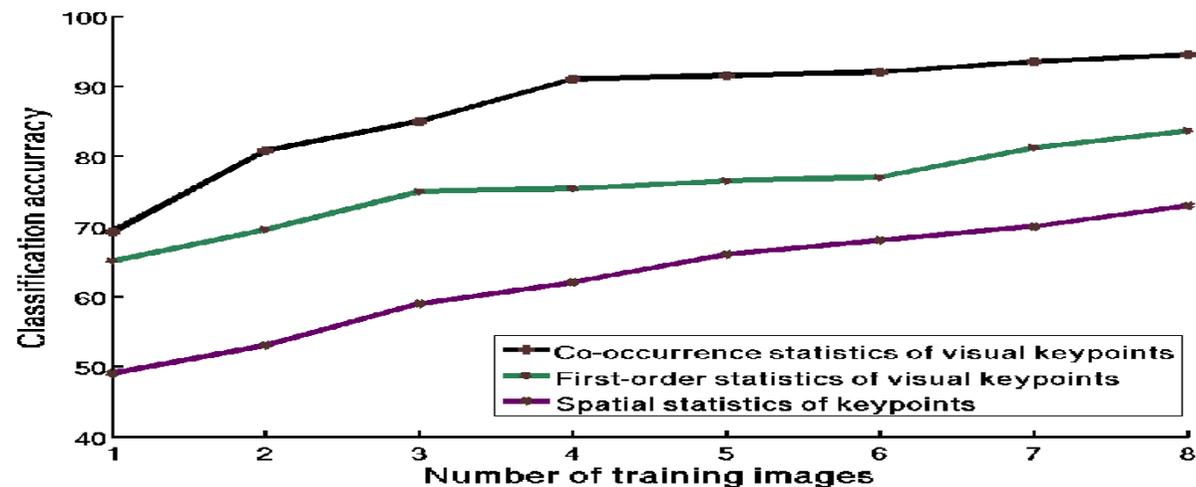
Reconnaissance de texture à partir de points d'intérêt visuels

■ Que peut apporter l'information spatiale ?

Exemple "jouet" avec deux catégories de points



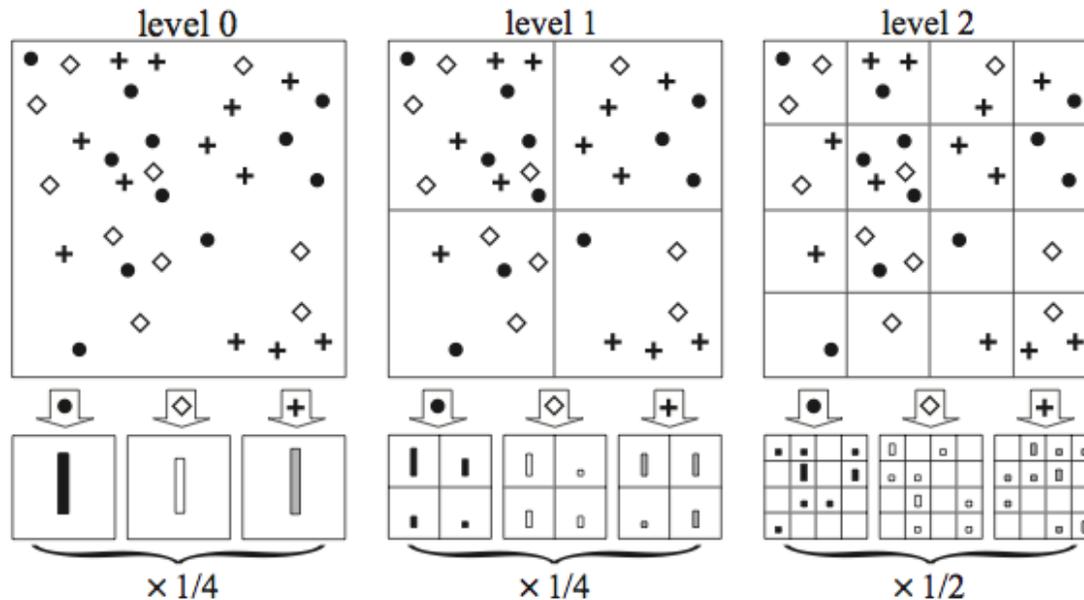
Base de données
UIUC



Comment caractériser l'information spatiale des ensembles de points d'intérêt?

■ Approches proposées pour la reconnaissance d'objets

- E.g., mise en correspondance de graphe de points d'intérêt (Ozuysal et al. 2007)
- E.g., pyramide spatiale (Lazebnik et al., 2006)



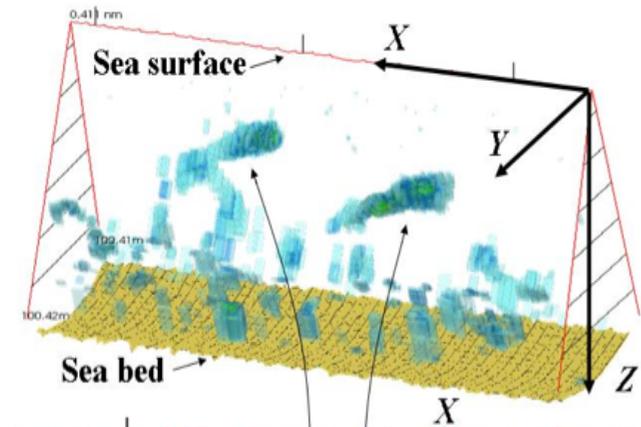
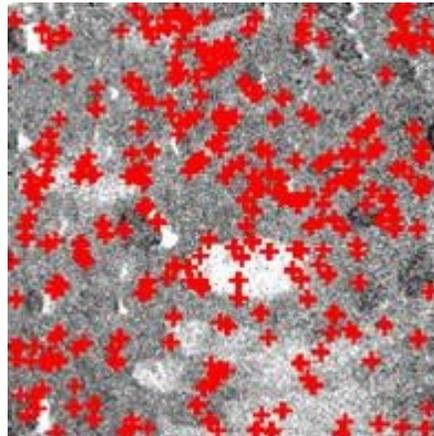
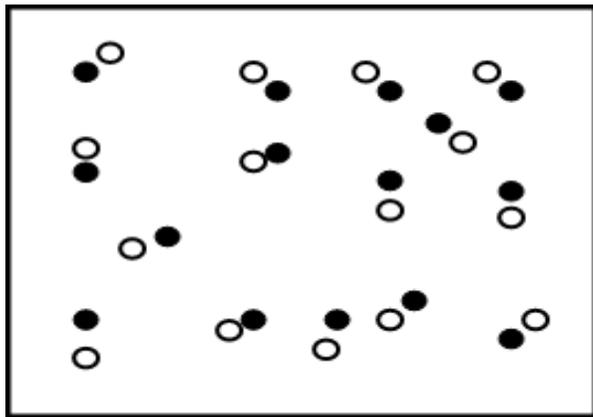
Calcul de sacs de mot pour différents partitionnements de l'image

Quid des aspects d'invariance géométrique?

Approche proposée

■ Principe :

- **Image = ensemble de signatures/objets élémentaires** vue comme la réalisation d'une processus ponctuel



- Formellement, un ensemble de signatures $\{s_i, m_i\}$ est la réalisation d'un processus ponctuel S , où chaque position s_i est associée à une marque (signature) discrète M_i .



Processus ponctuels [Stoyan et al., 2000]

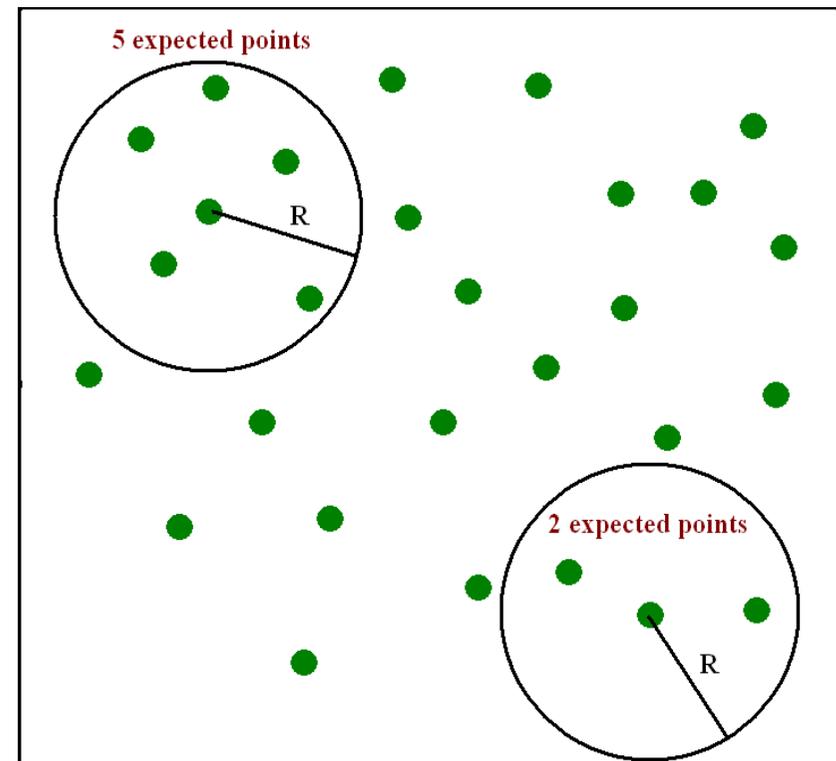
Un *processus ponctuel* \mathbf{S} est défini comme un sous-ensemble aléatoire fini d'une région bornée du plan $B \subset \mathbb{R}^2$, une réalisation est un ensemble de points $s = \{s_1, \dots, s_n\}$ contenus dans B .

- Moment d'ordre 1 (densité):

$$\mu(B) = E\{\#B\} = \int_B \rho(s) ds$$

- Moment du second-ordre (corrélation):

$$\begin{aligned} \mu^{(2)}(B_1 \times B_2) &= E\left\{ \sum_{s_1, s_2 \in \mathcal{S}} I_{B_1}(s_1) I_{B_2}(s_2) \right\} \\ &= \int_{B_1 \times B_2} \rho^{(2)}(s_1, s_2) ds_1 ds_2 \end{aligned}$$



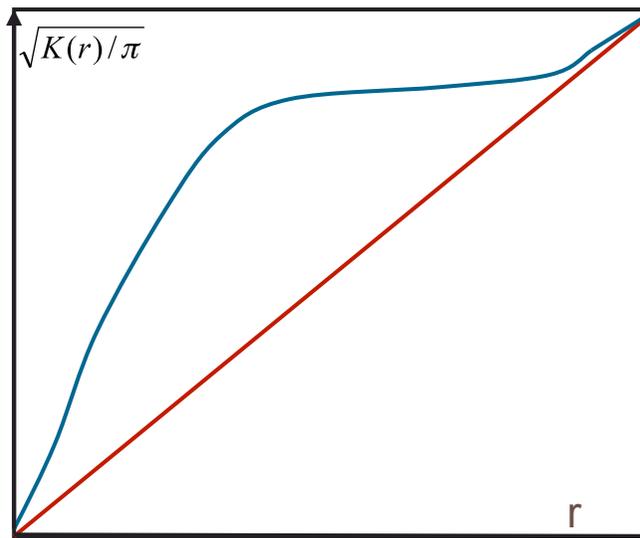
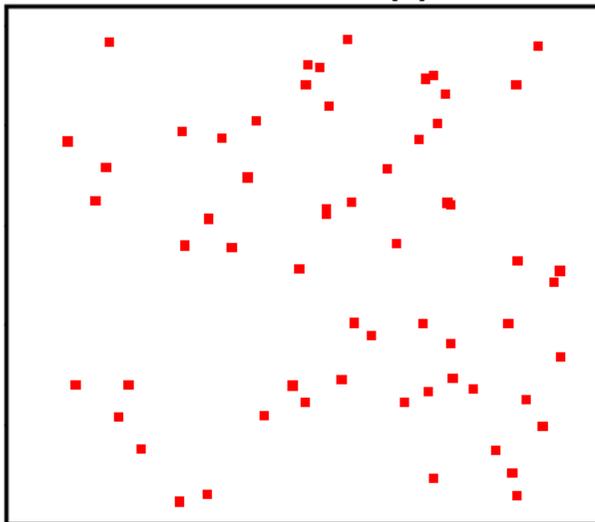
Statistiques descriptives second-ordre

❖ *Fonction K de Ripley (Ripley81) :*

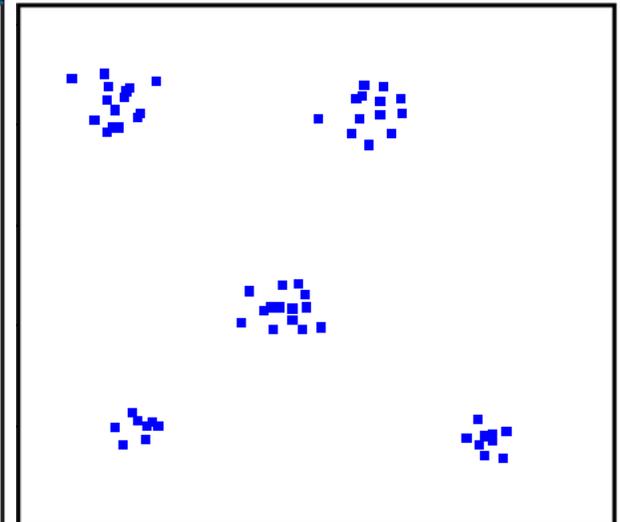
$$K(r) = \lambda^{-2} E [\mathbb{I}(s_1)\mathbb{I}(s_2) | \|s_1 - s_2\| \leq R]$$

où la densité moyenne $\lambda = \mu(B)/|B|$

Poissonien : $K(r) = \pi r^2$



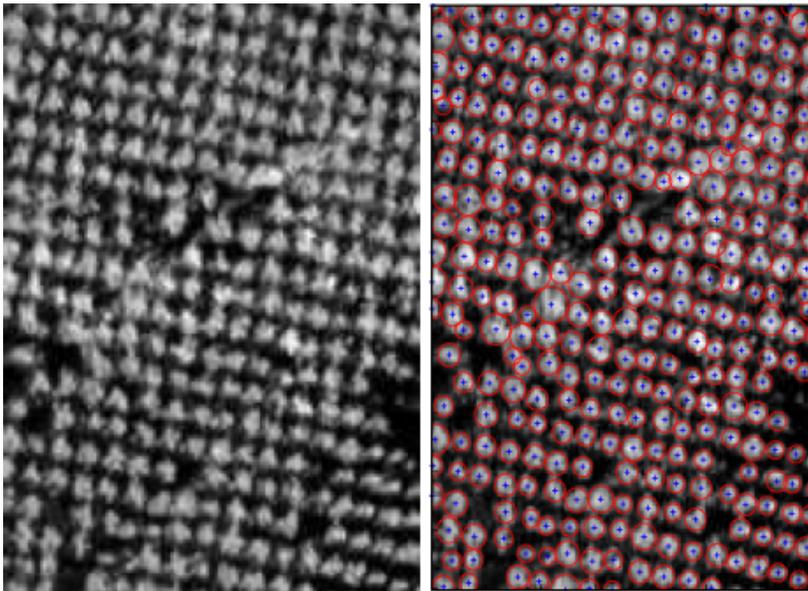
Cluster



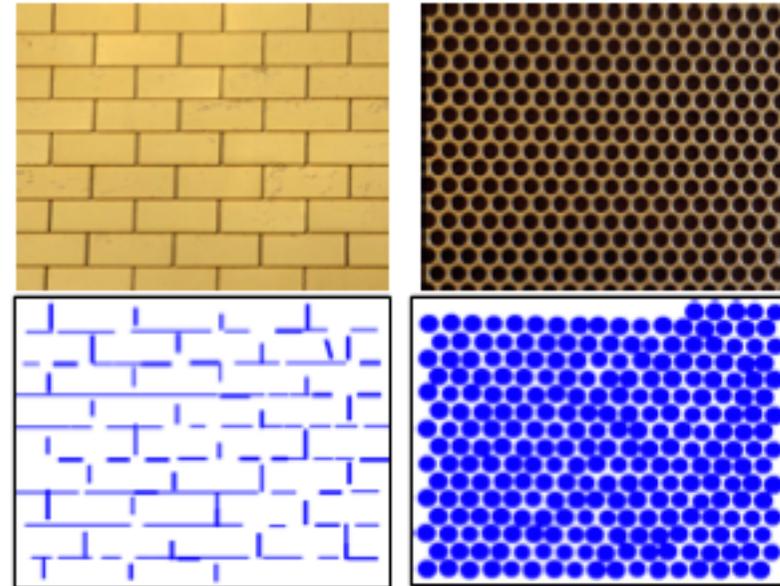


Processus ponctuels et traitements d'images [e.g., Descombres et al.]

- Modèles a priori (modèle de Gibbs) pour la détection de structures géométriques (couplage modèle d'apparence et a priori géométrique)



[Descombres, 2004]



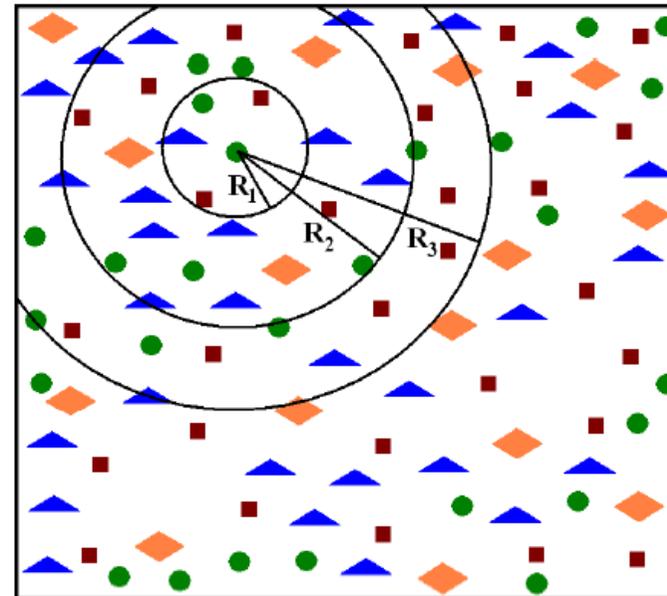
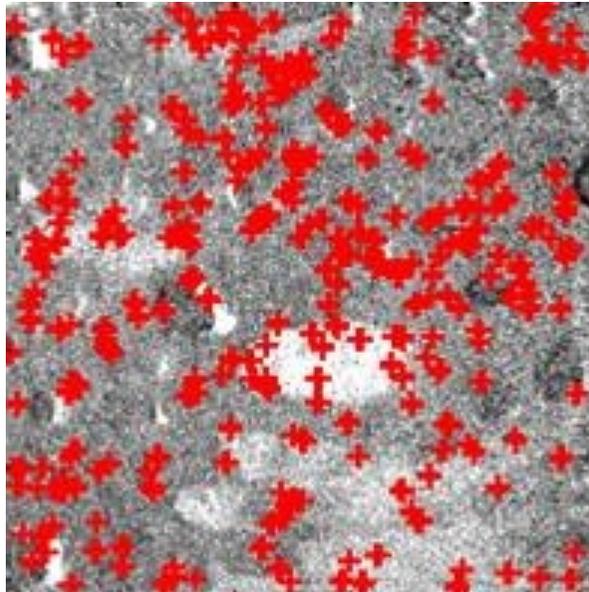
[Lafarge et al., 2010]



Statistiques descriptives de processus ponctuels et ensemble de points d'intérêt

■ Processus ponctuel marqué

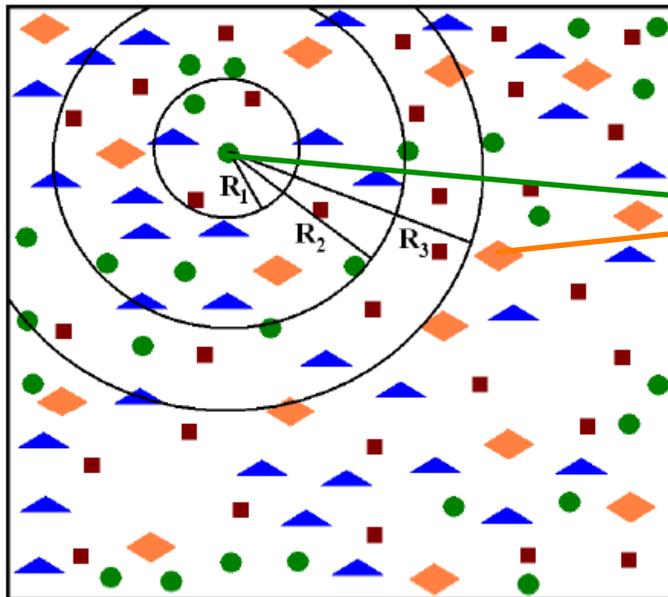
- Définition de **marques discrètes** (catégories de points d'intérêt)
- **Statistiques spatiales d'ordre 2** (cooccurrence de paires de catégories de points d'intérêt)





Statistiques descriptives de processus ponctuels et ensemble de points d'intérêt

■ Cooccurrences spatiales de points d'intérêt



$$\alpha_{i,j}^{(2)}(r) = E \left\{ \sum_h \sum_{l \neq h} \delta_i(m_h) \delta_j(m_l) \mathbb{I}(\|s_h - s_l\| \leq r) \right\}$$

Marques discrètes

Calcul du descripteur pour toutes les paires de points d'intérêt et différentes valeurs de rayon r

■ Complexité

- **BoF** : N (nombre de catégories de points d'intérêt)
- **SSC** : $N \times N r^2$ (nombre de rayons) (**Réduction à $N \times N r$**)



Statistiques descriptives de processus ponctuels et ensemble de points d'intérêt

■ Prises en compte des effets de bord

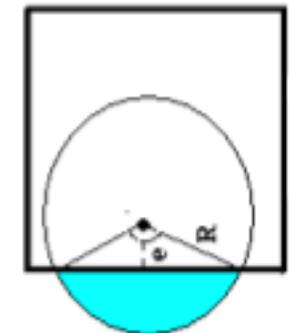
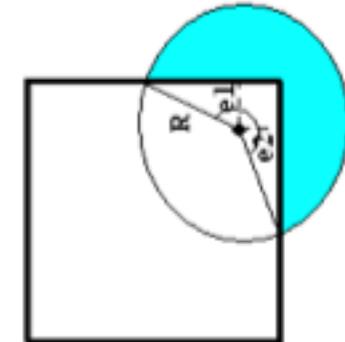
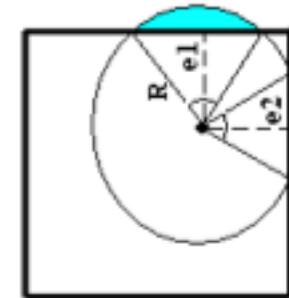
- Correction du biais d'estimation du aux effets de bords

$$\alpha_{i,j}^{(2)}(r) = E \left\{ \sum_h \sum_{l \neq h} \delta_i(m_h) \delta_j(m_l) \mathbb{I}(\|s_h - s_l\| \leq r) \right\}$$



$$\Gamma_{ij}^I(r) = \frac{1}{N} \sum_{p=1}^N \frac{1}{A(s_p)} \sum_{j=1, j \neq i}^N \delta_i(m_p) \delta_j(m_q) \mathbb{I}[\|s_p - s_q\| \leq r]$$

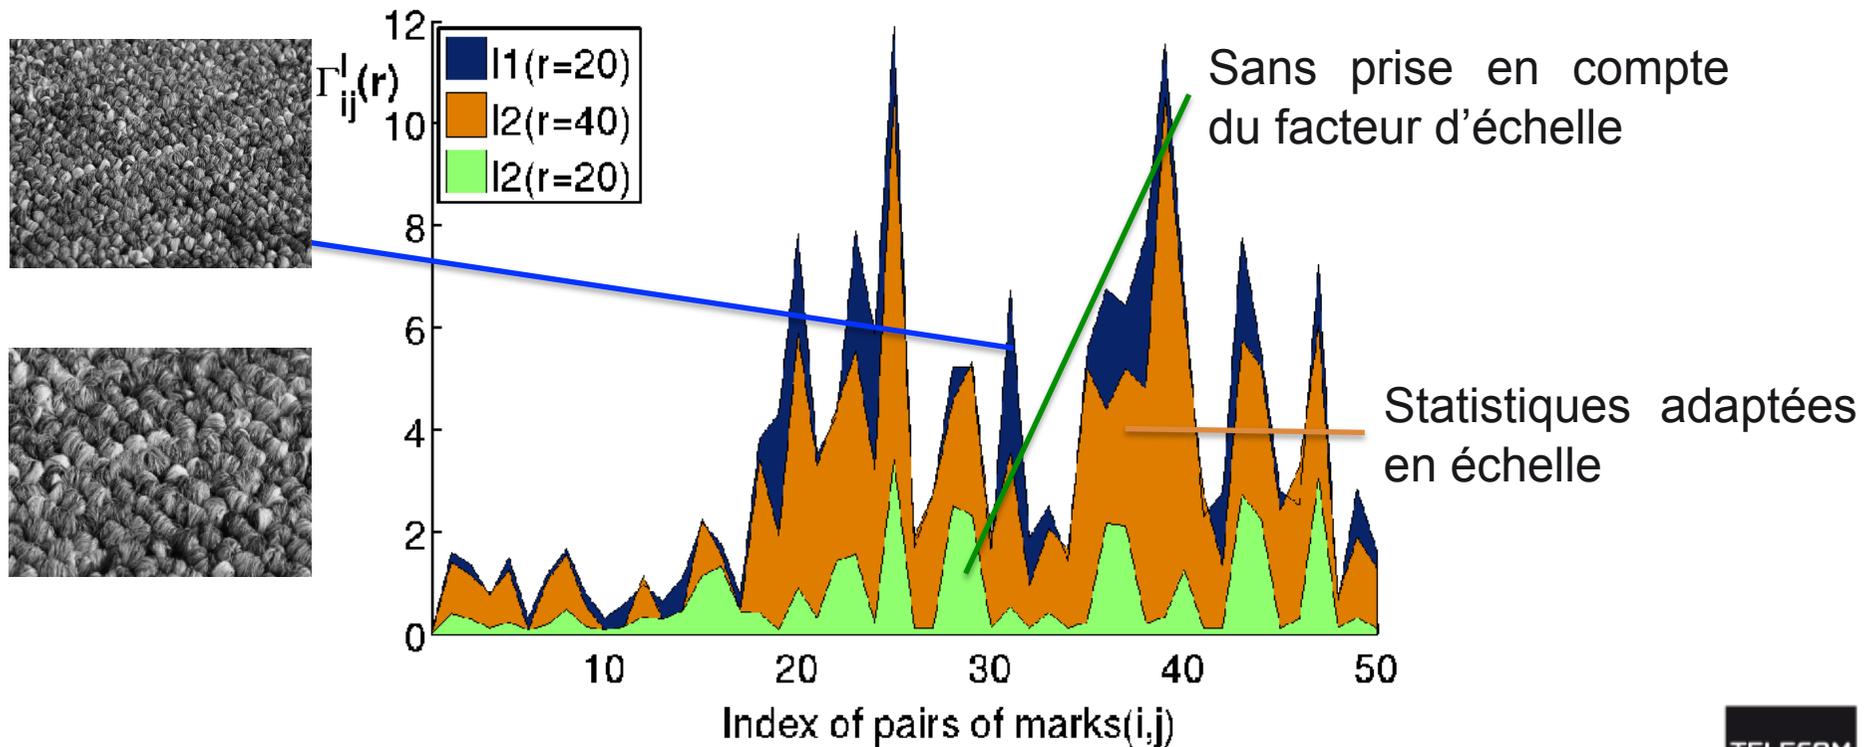
Prise en compte du domaine observé effectif autour de chaque point



Propriétés d'invariance

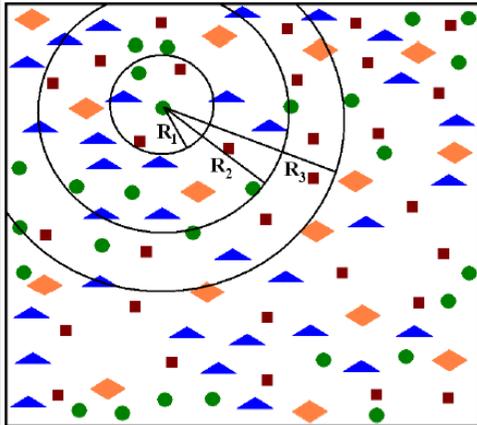
■ Invariance héritée des descripteurs de points d'intérêt

- Invariance de contraste et rotation
- Invariance en échelle à partir d'une correction d'un facteur d'échelle





De statistiques descriptives à des modèles probabilistes



**Moment d'ordre 1
(densité)**

(~ nombre d'évènements par classe = sacs de mots visuels)

**Moment du second-ordre
(corrélation)**

$$\mu_{ij}^{(2)}(r) = E \left\{ \sum_{[s_1; m_1], [s_2; m_2] \in \psi}^{\#} \delta_i(m_1) \delta_j(m_2) 1_{(\|s_1 - s_2\| \leq r)} \right\}$$

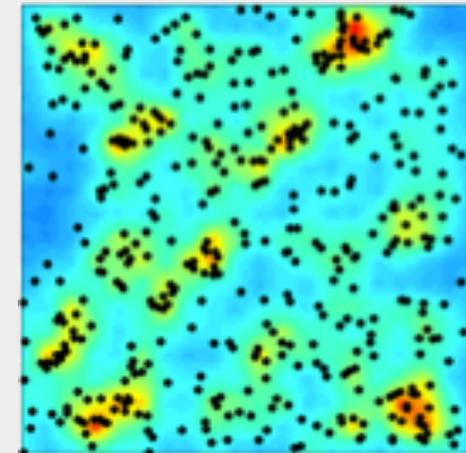
statistiques descriptives

$$\left\{ \mu_{ij}^{(2)}(r) \right\}$$

Modèles de Cox log-gaussiens

$$\{S_1, \dots, S_N\} | Y_1, \dots, Y_N$$

Covariance de $\log(Y_i)$





De statistiques descriptives à des modèles probabilistes

- **Modèle de Cox log-gaussien** : modèle de Poisson d'intensité aléatoire

$$\{S_1, \dots, S_N\} | Y_1, \dots, Y_N$$

avec $Z = \{\log(Y_1), \dots, \log(Y_N)\}$ un champ gaussien multivarié

$$E(Z_i) = \mu_i \text{ et } Cov [Z_i(s), Z_j(s_2)] = c_{ij} (\|s_1 - s_2\|)$$

- **Relation avec les statistiques d'ordre 1 et 2**

$$\mu_i(B) = E [N(B)] = \int_B \rho_i(s) ds = \exp \left[\mu_i + \frac{1}{2} c_{ii}(0) \right]$$

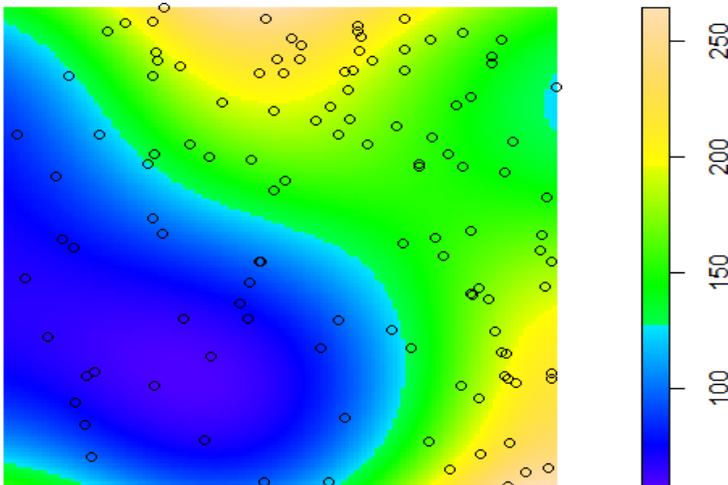
$$\alpha_{ij}^{(2)}(R) = E [\mathbb{I}_i(s_1) \mathbb{I}_j(s_2) | \|s_1 - s_2\| \leq R] = 2\pi \int_0^R g_{ij}(r) r dr$$

$$g_{ij}(r) = \exp [c_{ij}(r)]$$

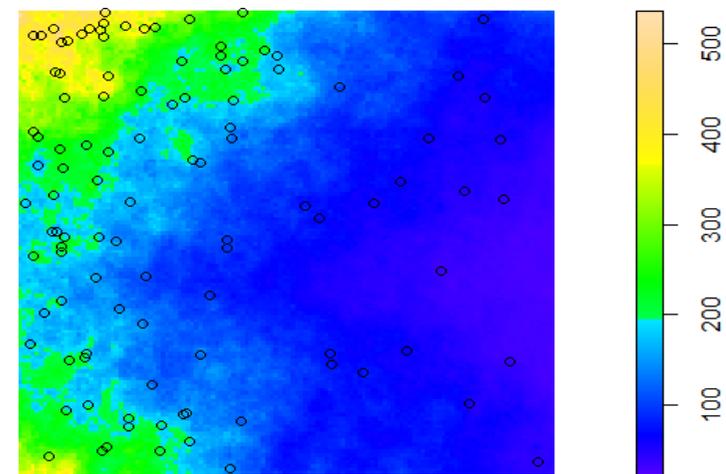


De statistiques descriptives à des modèles probabilistes

- **Modèles de Cox log-gaussien** : choix du modèle de covariance



Gaussien : $L(r) = \sigma \exp(-(r/\beta)^2)$



Hyperbolique : $L(r) = \sigma(1+r/\beta)^{-1}$

- **Estimation des paramètres de la fonction de covariance**

$$\min \int_0^R [L_{\sigma_{ij}, \beta_{ij}}(r) - c_{ij}(r)]^2 dr$$

Vecteur descripteur proposé :

$$(\lambda_i, \sigma_{ij}, \beta_{ij})$$

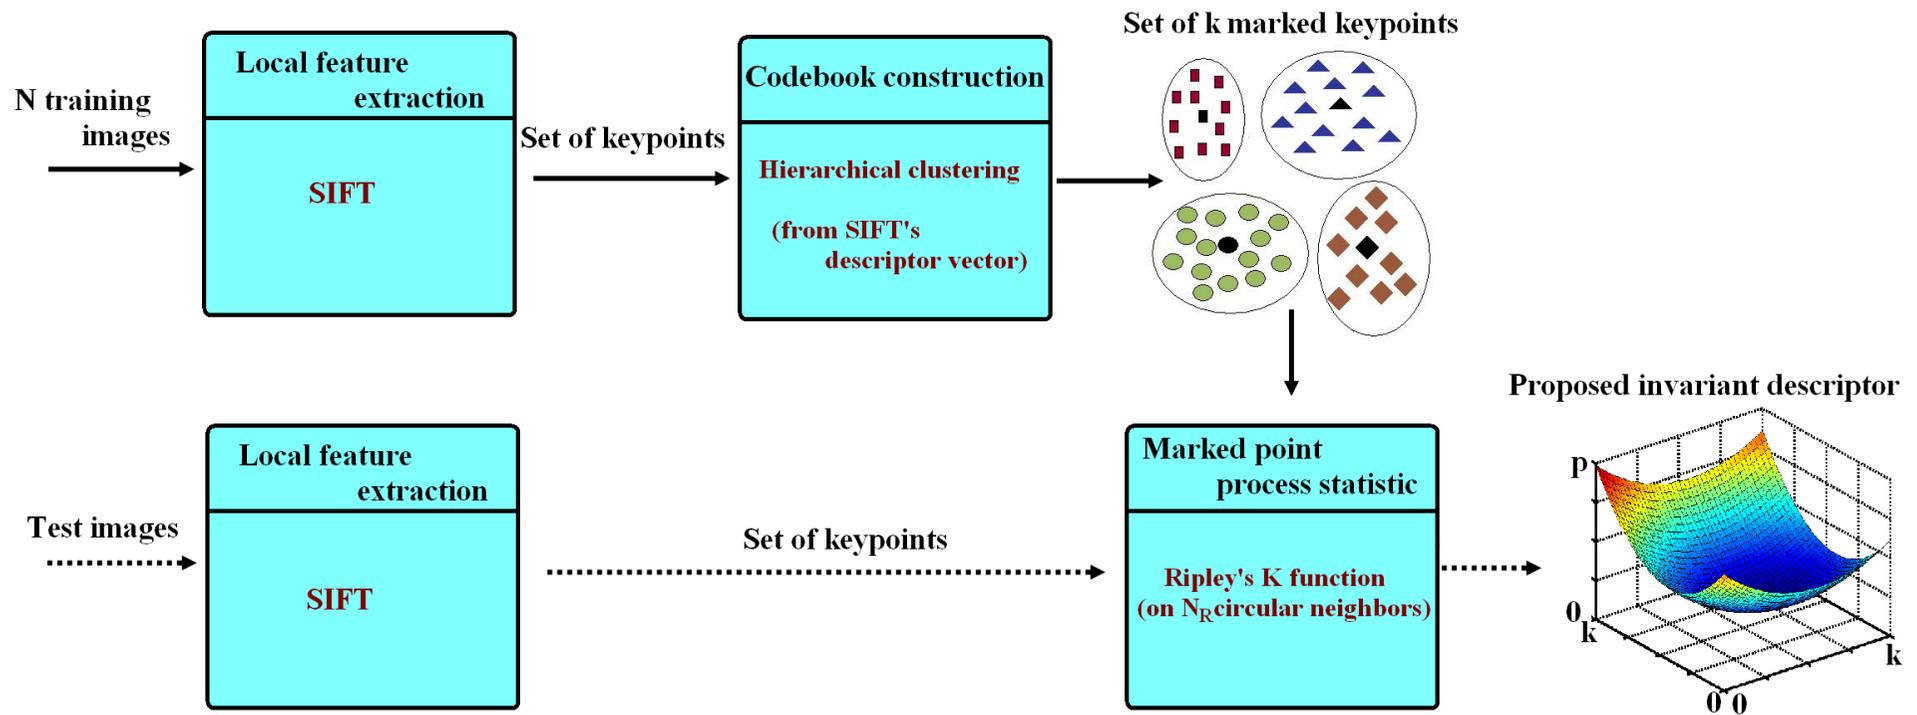


Schéma proposée

d'ensemble

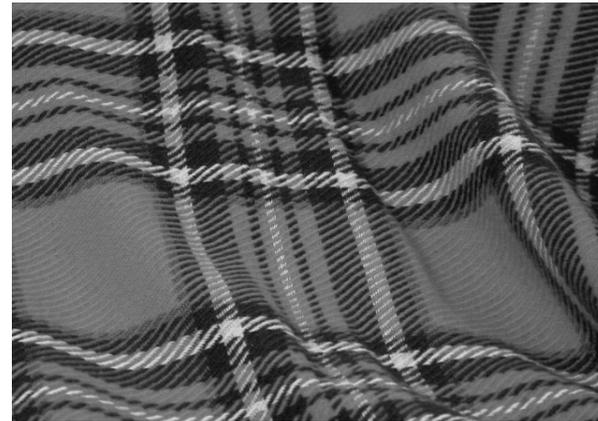
de

l'approche



Classification des textures naturelles

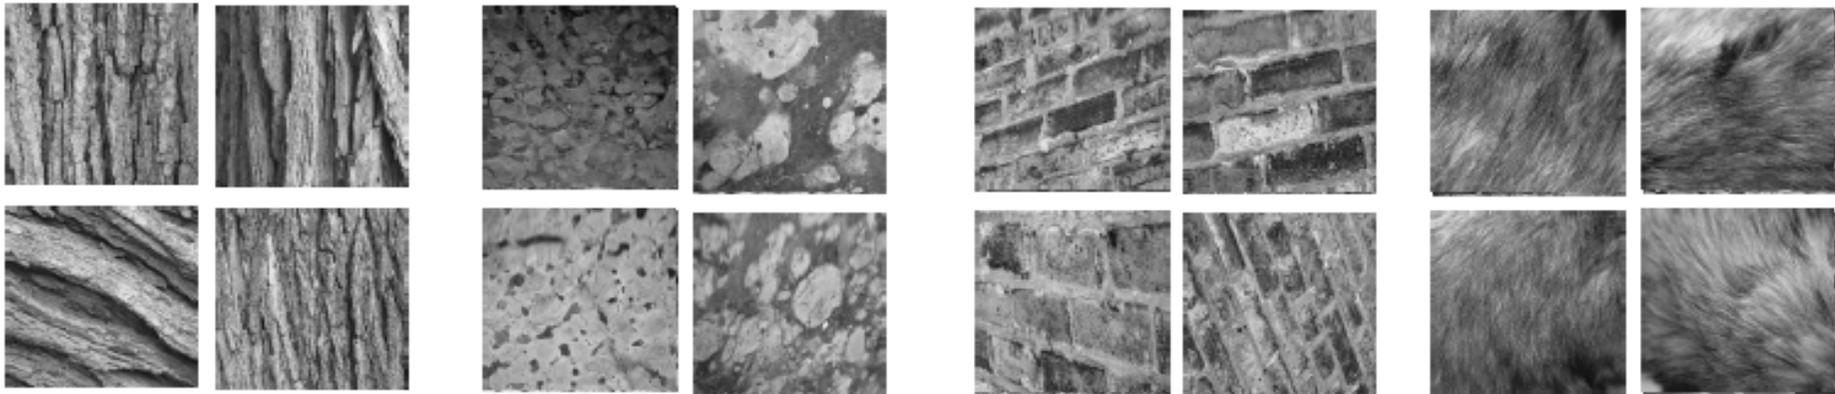
25 classes de textures UIUC [Lazebnik05]; 40 images de 640x480 pixels par classe.



~~Classification~~

Classification des textures naturelles

25 classes de textures UIUC [Lazebnik05]; 40 images de 640x480 pixels par classe.

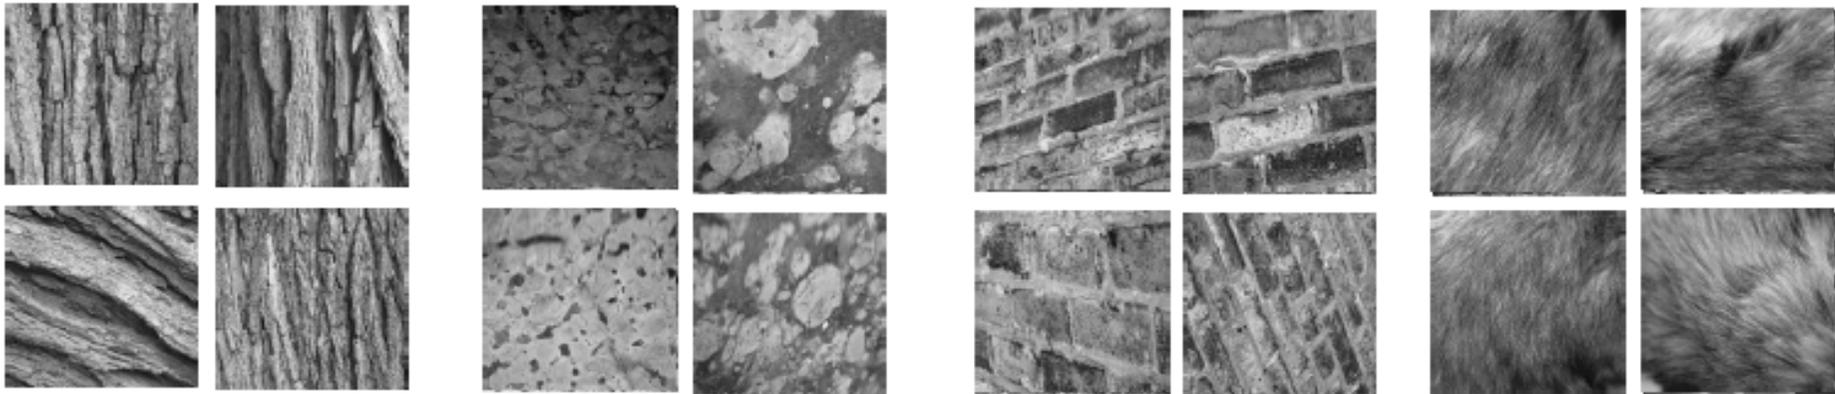


N_t	DoG +Sift[22]	FH +Surf[20]	FH +Brief[21]	(Hes-Lap) +Daisy[23]	(Har-Lap) +(Sift-Spin)[12]
1	75.21±1.75	75.05±1.94	75.43±1.71	75.18±1.69	74.85±1.87
5	91.96±1.13	90.73±1.11	91.42±1.23	92.13±1.19	91.15±1.41
10	95.42±0.71	95.15±0.91	95.22±0.85	95.47±1.08	95.23±0.72
15	96.87±0.65	96.14±0.63	96.43±0.51	96.75±0.58	96.37±0.61
20	97.84±0.32	96.75±0.41	97.25±0.34	97.67±0.35	97.14±0.37

Taux moyens et écarts types de bonne classification

Classification des textures naturelles

25 classes de textures UIUC [Lazebnik05]; 40 images de 640x480 pixels par classe.



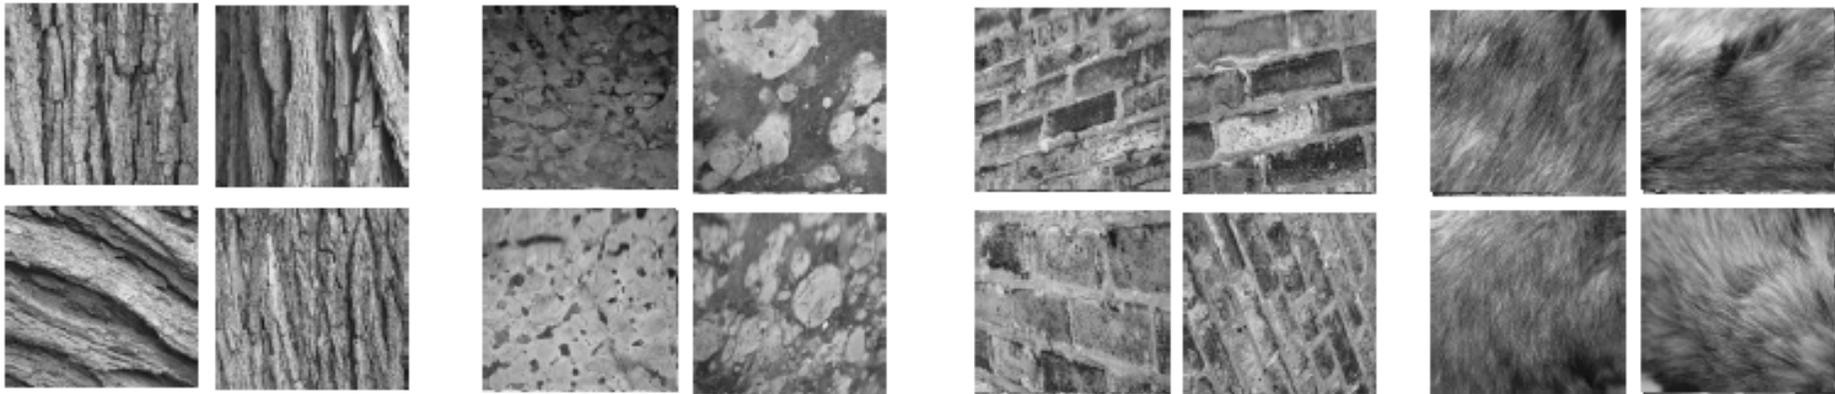
	sans procédure d'adaptation d'échelle	sans procédure de réduction la taille	modèle complète
1	73.27±2.05	75.65± 1.82	75.21±1.75
5	89.12±1.27	91.67± 1.15	91.96±1.13
10	94.76±1.11	95.15±0.75	95.42±0.71
15	95.12±0.81	96.27±0.71	96.87±0.65
20	95.89±0.54	97.12±0.35	97.84±0.32

N_t	Gaussian	Cardinal sine	Hyperbolique
1	75.21±1.75	75.15±1.67	75.03±1.81
5	91.96±1.13	91.63±1.17	91.32±1.19
10	95.42±0.71	95.35±0.75	94.72±0.85
15	96.87±0.65	96.17±0.63	95.43±0.71
20	97.84±0.32	97.15±0.42	96.85±0.38

Taux moyens et écarts types de bonne classification

Classification des textures naturelles

25 classes de textures UIUC [Lazebnik05]; 40 images de 640x480 pixels par classe.



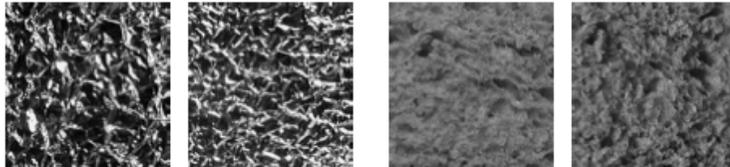
N_t	1	5	10	15	20
Filtre de Gabor [6]	31.22±3.14	45.14±2.54	57.37±1.93	61.25±1.52	67.78±1.28
Matrice de Cooc. [7]	45.33±3.03	61.58±2.14	70.67±1.72	73.85±1.34	80.12±1.30
SDM[8]	67.25±2.75	76.38±2.15	81.12±1.45	86.35±1.20	91.28±1.15
Ling[9]	67.62±2.93	78.42±2.33	84.14±1.72	86.38±1.25	91.87±1.38
Xu[10]	61.14±2.90	83.33±2.07	89.68±1.65	91.34±1.45	93.85±1.31
Zhang[11]	72.53±2.45	88.62±1.33	93.17±1.15	95.33±0.98	96.67±0.93
SSC[98]	75.66±1.65	91.67±0.93	94.33±0.78	96.54±0.53	97.34±0.25
LGCM	75.21±1.75	91.96±1.13	95.42±0.71	96.87±0.65	97.84±0.32

Taux moyens et écarts types de bonne classification



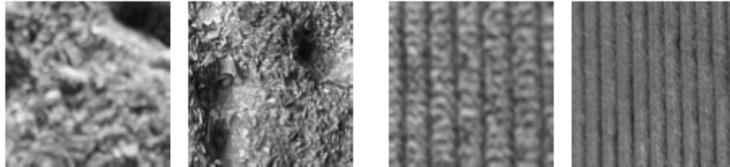
Classification des textures naturelles

Base de textures KTH-Tips



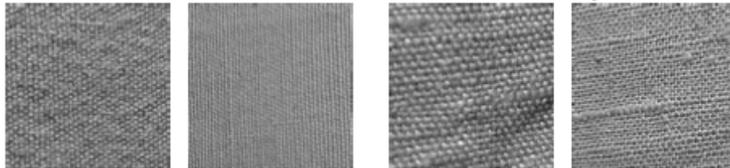
Crumpled aluminum foil

Brown bread



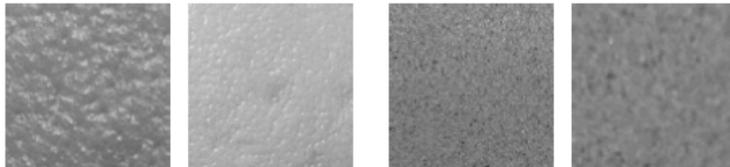
Cracker

Corduroy



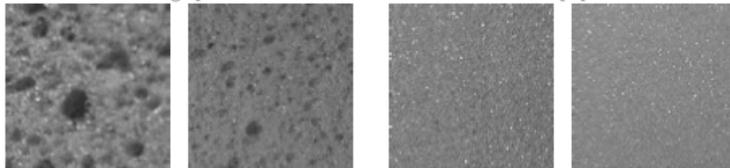
Linen

Cotton



Orange peel

Sandpaper



Sponge

Styrofoam

10 classes de textures
81 images de 200x200 pixels par classe

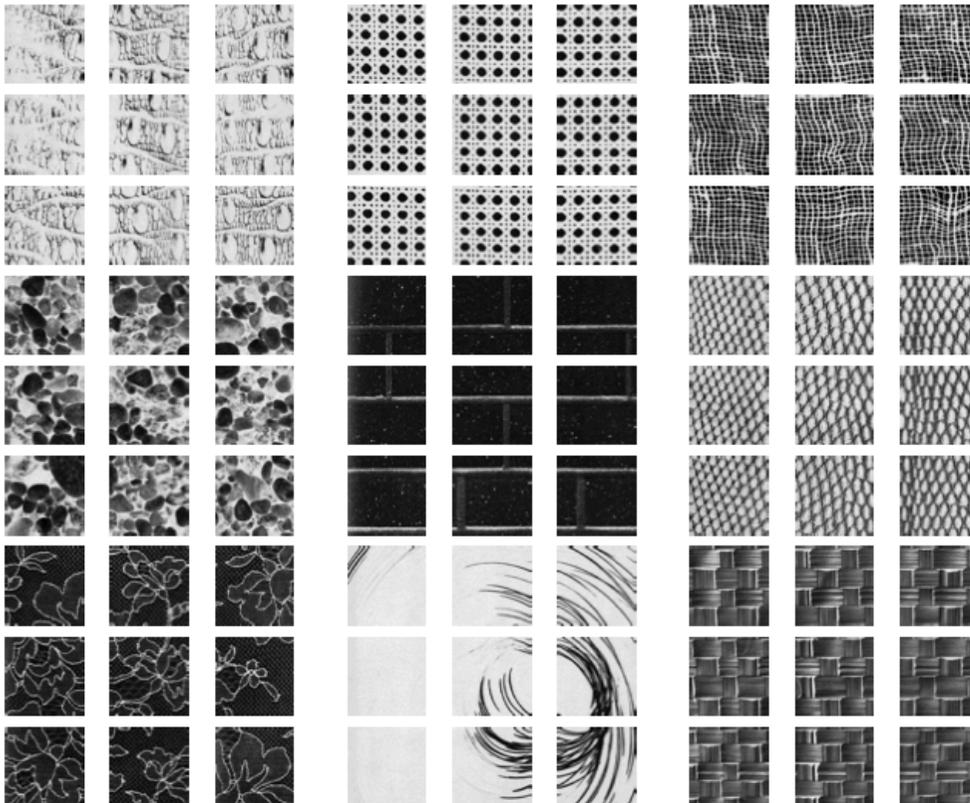
Variabilité de contraste et échelle

N_t	1	3
Filtre de Gabor [6]	78.52±1.72	85.14 ± 1.41
Matrice de Cooc. [7]	75.42±1.73	83.22±1.04
SDM[8]	83.16±1.50	92.78 ± 0.91
Ling[9]	84.33 ± 1.63	93.17 ± 0.87
Xu[10]	85.95 ± 0.91	93.41 ± 0.73
Zhang[11]	86.63 ± 1.05	94.34 ± 0.43
SSC[98]	87.67±0.81	95.67±0.33
LGCM	88.81±0.92	96.14±0.41



Classification des textures naturelles

Textures de Brodatz :



111 classes de textures
9 images de 170x170 par classe

Variabilité de contraste et échelle

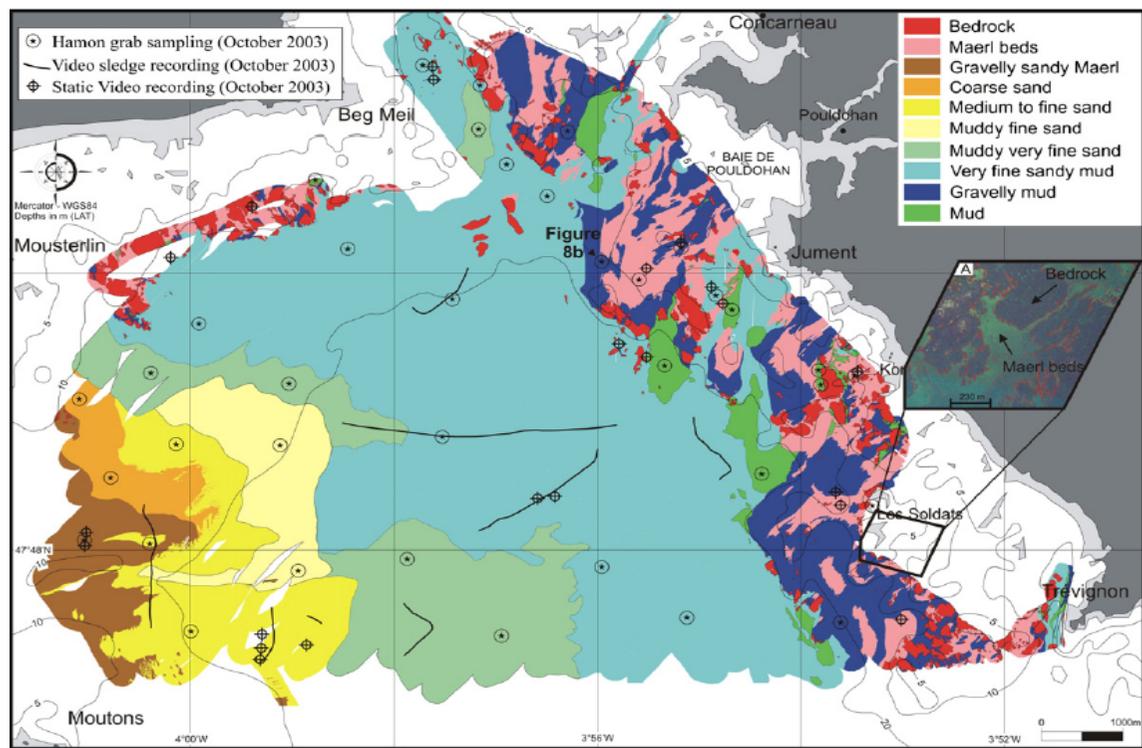
N_t	1	3
Filtre de Gabor [6]	78.52±1.72	85.14 ± 1.41
Matrice de Cooc. [7]	75.42±1.73	83.22±1.04
SDM[8]	83.16±1.50	92.78 ± 0.91
Ling[9]	84.33 ± 1.63	93.17 ± 0.87
Xu[10]	85.95 ± 0.91	93.41 ± 0.73
Zhang[11]	86.63 ± 1.05	94.34 ± 0.43
SSC[98]	87.67±0.81	95.67±0.33
LGCM	88.81±0.92	96.14±0.41



Application à l'imagerie sonar des fonds marins

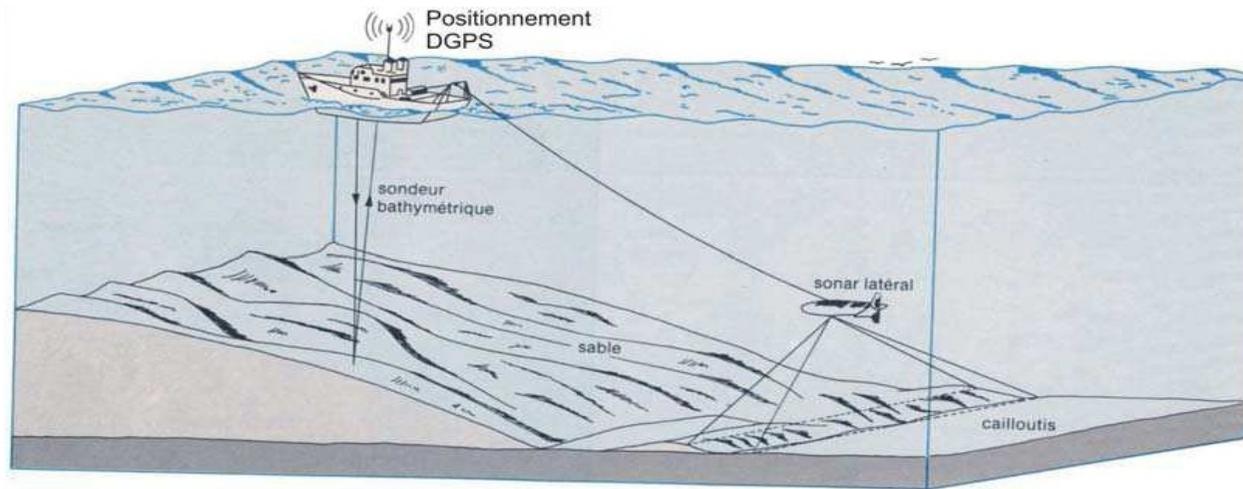


Présentation

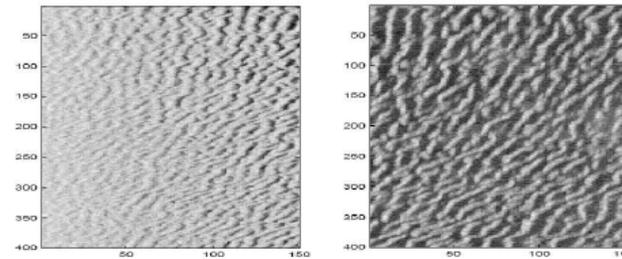
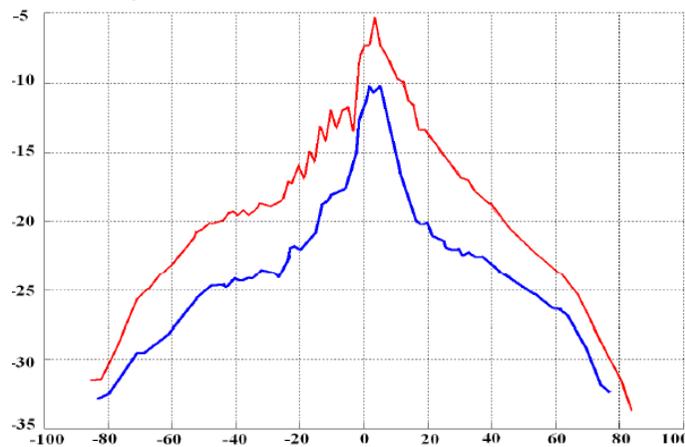


Projet REBENT (Ifremer) sur les habitats benthiques côtiers (baie Concarneau).

Images sonars de DF1000



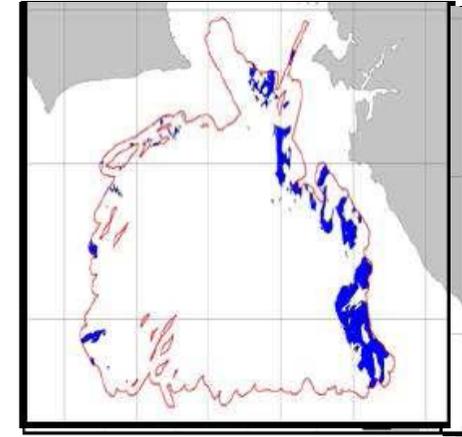
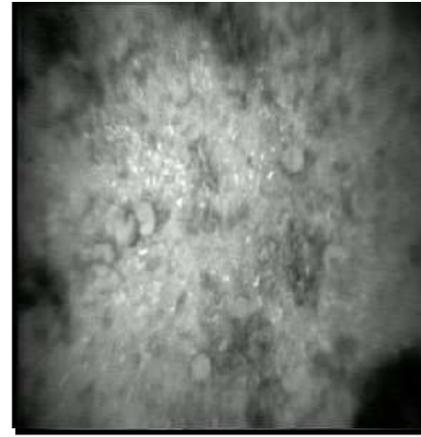
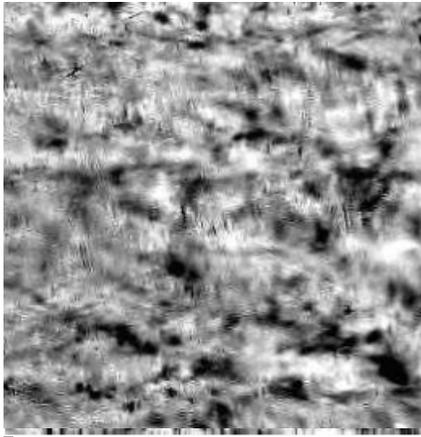
- L'intensité de l'écho rétro-diffusé (BS - Backscattering Strength) dépend de l'angle d'incidence θ_{inc} de l'onde acoustique avec le fond marin.



Base de données des textures sonars

- **6 classes** d'images sonars du fond marin.
- **40 images de 256x256 pixels par classe** avec des valeurs différentes d'angles d'incidence, d'échelles et de niveaux moyens d'écho rétrodiffusé.

VERITE TERRAIN

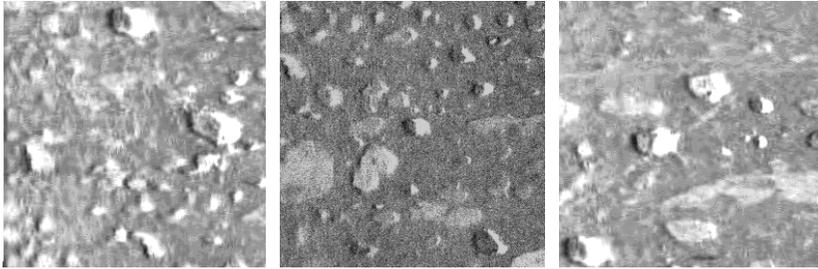


Les sonars utilisés sont des sonars à balayage

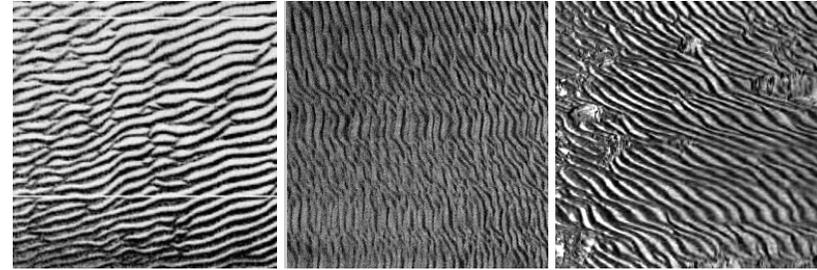


Variabilité des textures sonars

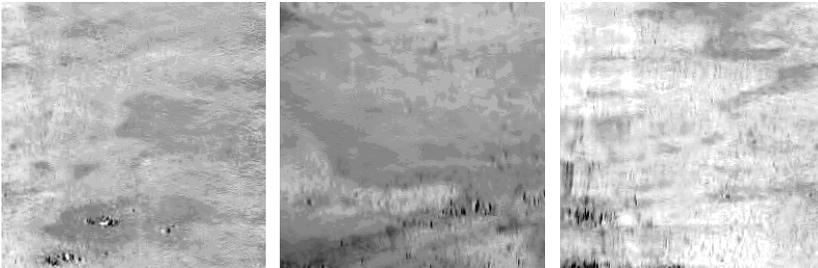
Class1: Sandy mud



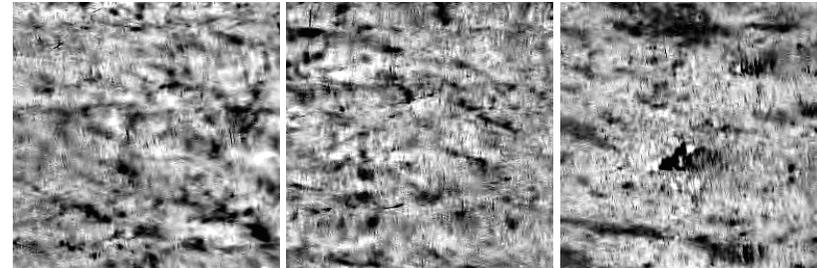
Class4: Gravely Sand



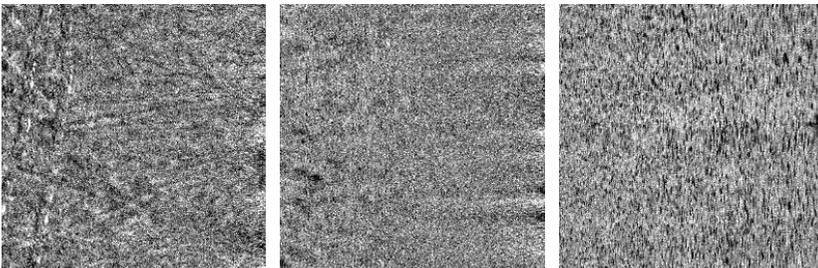
Class2: Mud



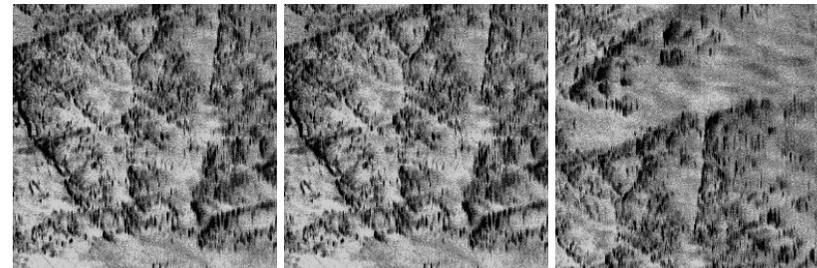
Class5: Mixed sediment



Class3: Sand



Class6 : Rock

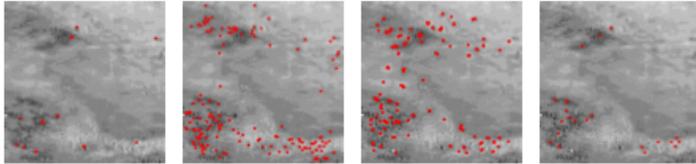


Rebent, Ifremer, capteur DF 1000, 100kHz

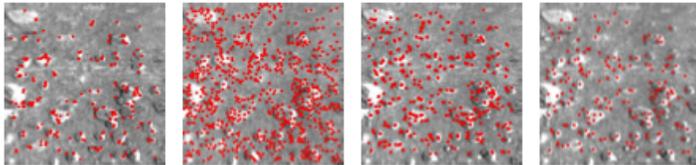


Textures sonars : détection de points d'intérêt

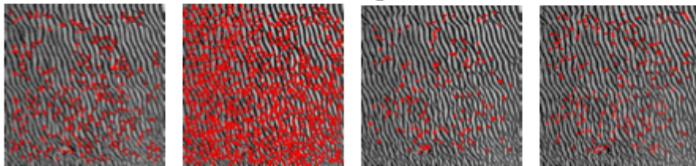
La vase :



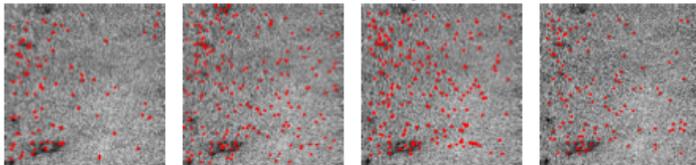
La vase sableuse :



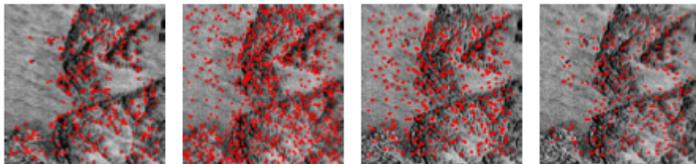
Le maërl sablo-graveleux :



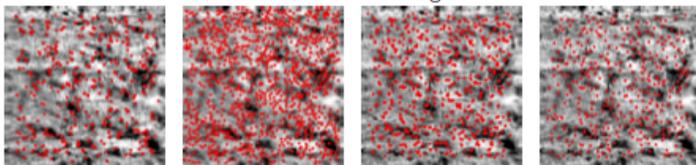
Le sable fin à moyen :



Le substratum rocheux :



Les sédiments mélangés :



(a) Har-Lap

(b) DoG

(c) Hes-Lap

(d) FH

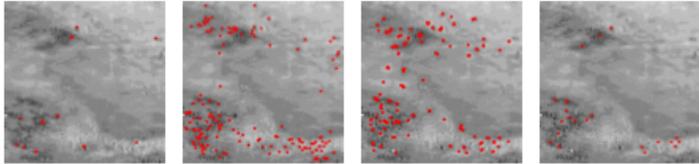
	DoG	FH	(Har-Lap)	(Hes-Lap)
La vase	334.85	35.125	20.925	182.325
La vase sableuse	670.5	166.65	230.95	534.65
Le maërl sablo-graveleux	1777.275	297.975	476.425	400.3
Le sable fin à moyen	377.525	143.825	205.55	368.5
Le substratum rocheux	1070.7	307.65	573.75	775.65
Les sédiments mélangés	1350.175	353.525	554.85	834.525
Moyen global	930	217.45	344	516

	DoG+Sift	FH+Surf	(Har-Lap) +(Sift-Spin)	(Hes-Lap) +Daisy	FH+Brief
1 image	73.85±1.75	71.15±1.91	72.67±1.95	73.67±1.52	74.85±1.65
3 images	82.95±1.13	79.95±1.41	82.31±1.55	82.35±1.23	81.62±1.28
5 images	91.34±0.72	90.17±1.37	91.05±1.31	91.24±0.81	90.84±1.13
8 images	93.87±0.61	92.08±0.82	92.12±0.95	92.75±0.73	92.07±1.11
10 images	97.14±0.37	95.67±0.51	96.12±0.62	96.63±0.47	95.92±0.59

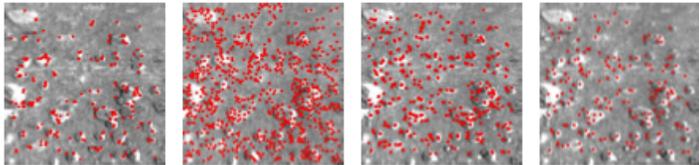


Textures sonars : détection de points d'intérêt

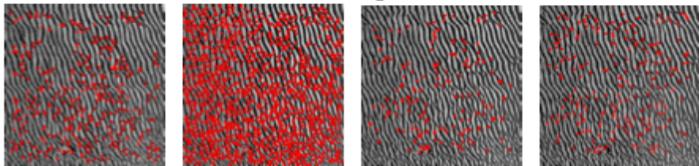
La vase :



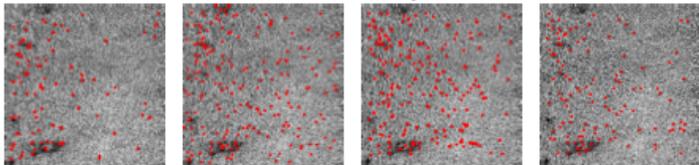
La vase sableuse :



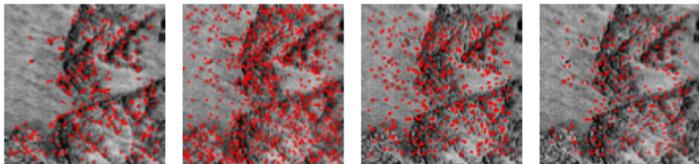
Le maërl sablo-graveleux :



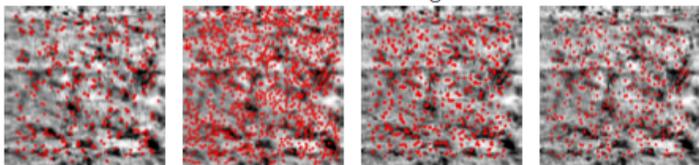
Le sable fin à moyen :



Le substratum rocheux :



Les sédiments mélangés :



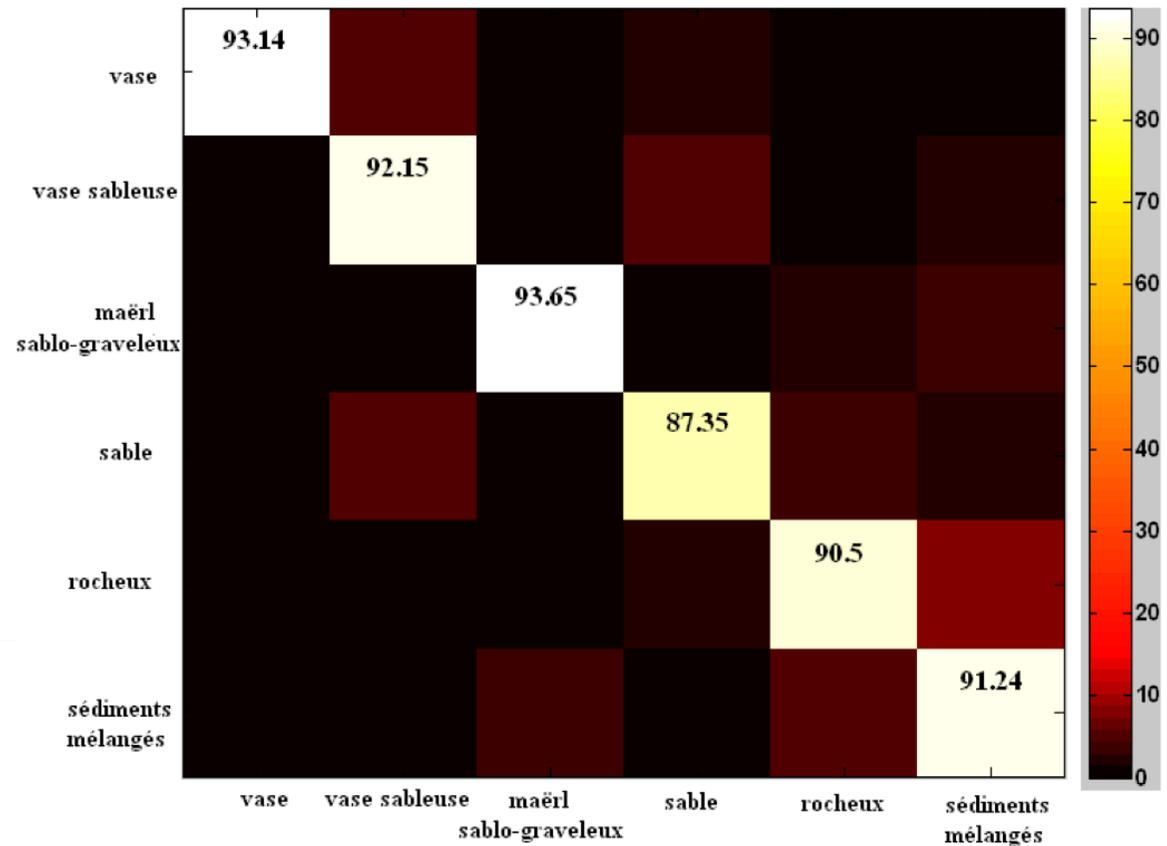
(a) Har-Lap

(b) DoG

(c) Hes-Lap

(d) FH

N_t	1	3	5	8	10
Filtre de Gabor [6]	51.71±3.24	55.34±2.84	59.27±1.97	62.53±1.72	69.81±1.48
Matrice de Cooc. [7]	62.13±3.17	69.72±2.44	72.15±1.53	76.22±1.41	81.21±1.27
SDM[8]	67.15±2.55	76.27±2.08	85.42±1.56	90.35±1.42	92.03±1.21
Ling[9]	66.83±2.33	78.12±2.21	85.27±1.83	90.68±1.35	91.92±1.24
Xu[10]	67.54±2.49	79.33±2.11.	87.12±1.91	90.14±1.63	91.85±1.12
Zhang[11]	73.33±2.17	82.62±1.83	90.67±1.15	93.43±0.91	94.25±0.73
SSC[98]	74.57±1.69	83.23±1.19	91.17±1.08	93.25±0.58	96.67±0.35
LGCM	73.85±1.75	82.95±1.13	91.34±0.72	93.87±0.61	97.14±0.37





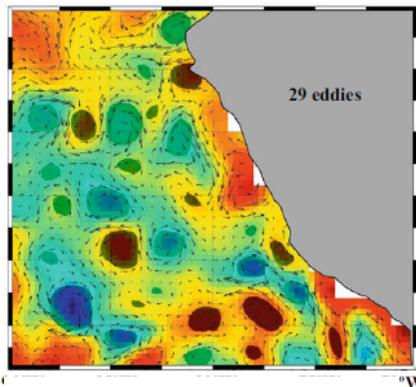
Images et ensemble de signatures locales : extension perspectives



Images et ensemble de signatures locales

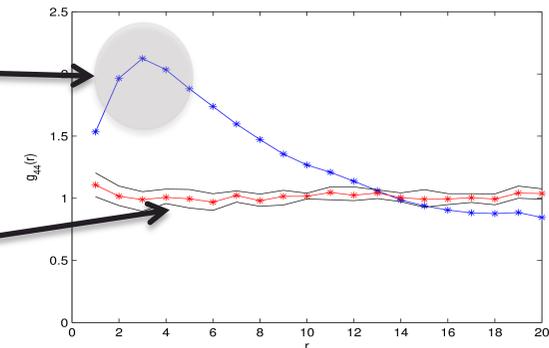
■ Extension/perspectives :

- Application à différents types d'objets/signatures élémentaires (e.g., régions « élémentaires », déformations élémentaires, formes, ...) et imagerie (e.g. SAR) [IEEE TGRS 2012, IEEE GRSL 2012, CJFAS 2012]



Agrégation
(attraction)

Distribution aléatoire
(Poisson)



Covariance spatiale

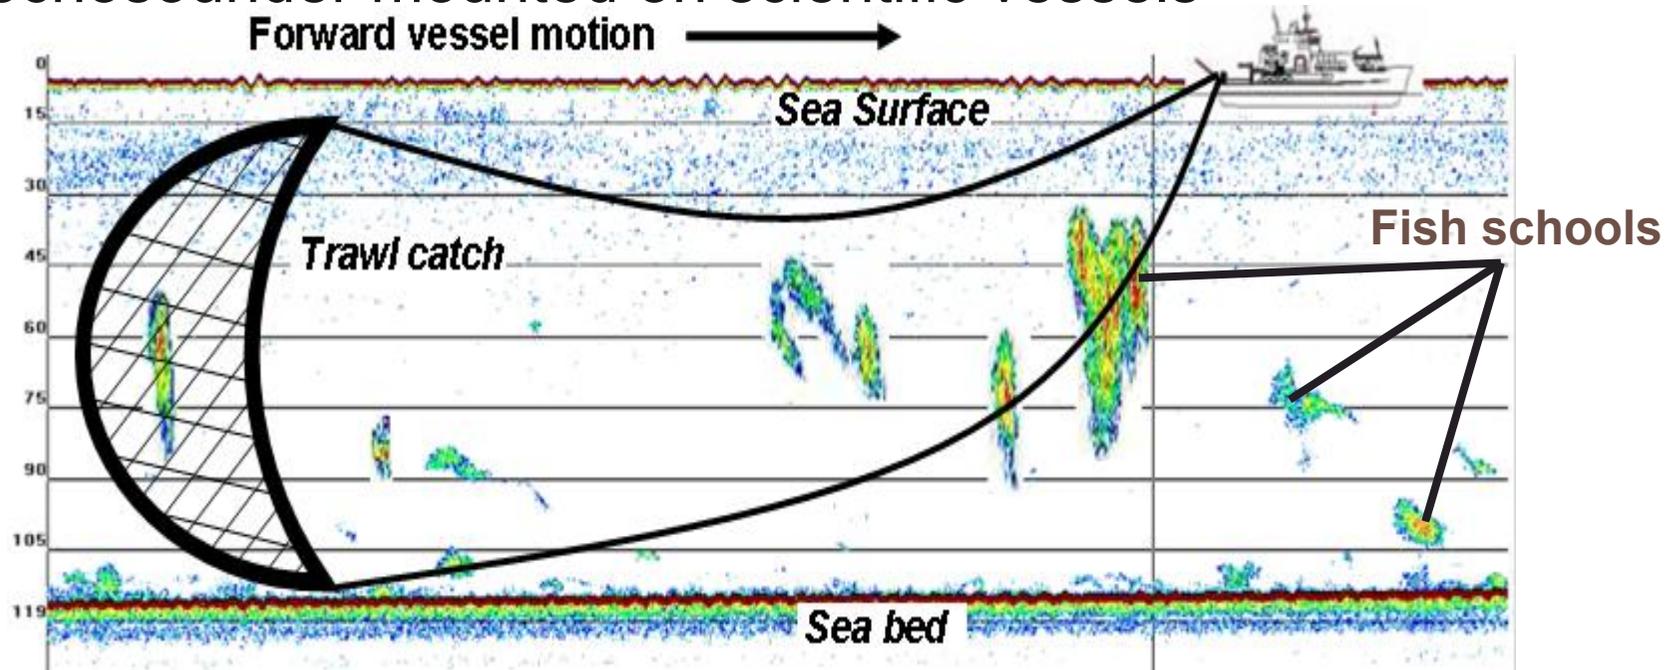
- Exploitation de la modélisation probabiliste (simulation, test d'ajustement, définition de distance entre modèles)
- Application comme a priori ou modèle d'observation pour des problèmes inverses: eg segmentation d'images [cf. lien avec Karoui et al. 2011], assimilation variationnelle (Ba et al. en prep)



Application to « scene classification » in fisheries acoustics

■ Context

- Acoustic-based monitoring of the water column using echosounder mounted on scientific vessels



- Objectives: monitoring of pelagic fish stocks (e.g., sardines, anchovies, tunas,.....)

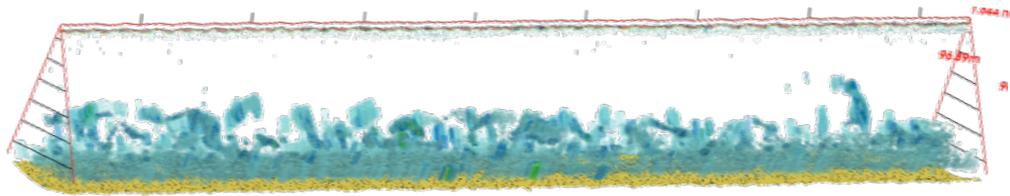


Application to fisheries acoustics

■ Associated image processing/pattern recognition issues

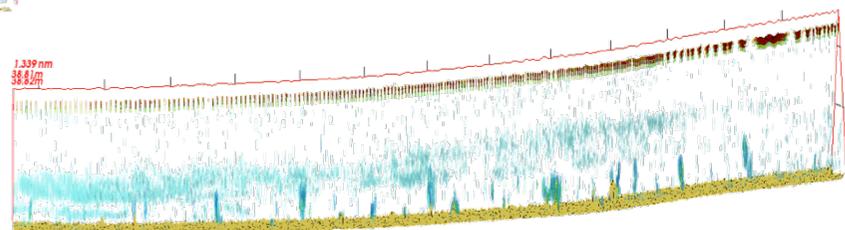
- Species-based school classification

- Spatial school organization characterization as a marker of “ecological behaviour” (e.g., species-specific, related to species mixtures or stages of life (juvenile vs. adults))



e.g., sardine schools

e.g., dense anchovy-horse mackerel mixture



Are fish schools statistics discriminative features for species mixtures and/or school organization?

Application to fisheries acoustics

■ Proposed approach

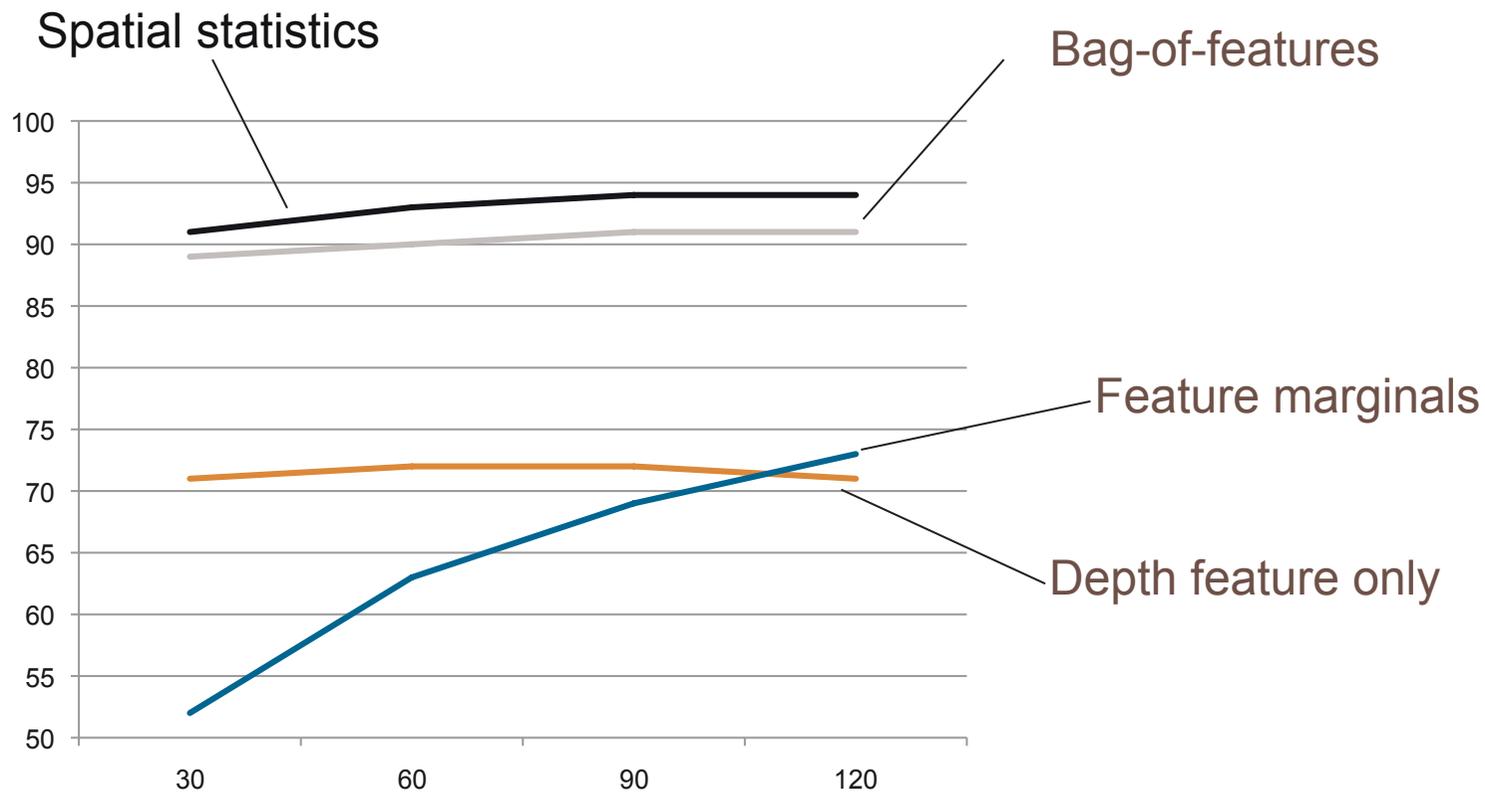
- **Step 1:** thresholding-based extraction of fish schools
- **Step 2:** extraction of school features (geometric and acoustics features, 20-dimensional feature vector)
- **Step 3:** extraction of feature clusters from a given school datasets
- **Step 4:** computation of descriptive second-order spatial statistics of echograms
- **Step 5:** echogram classification from computed statistics



Application to fisheries acoustics

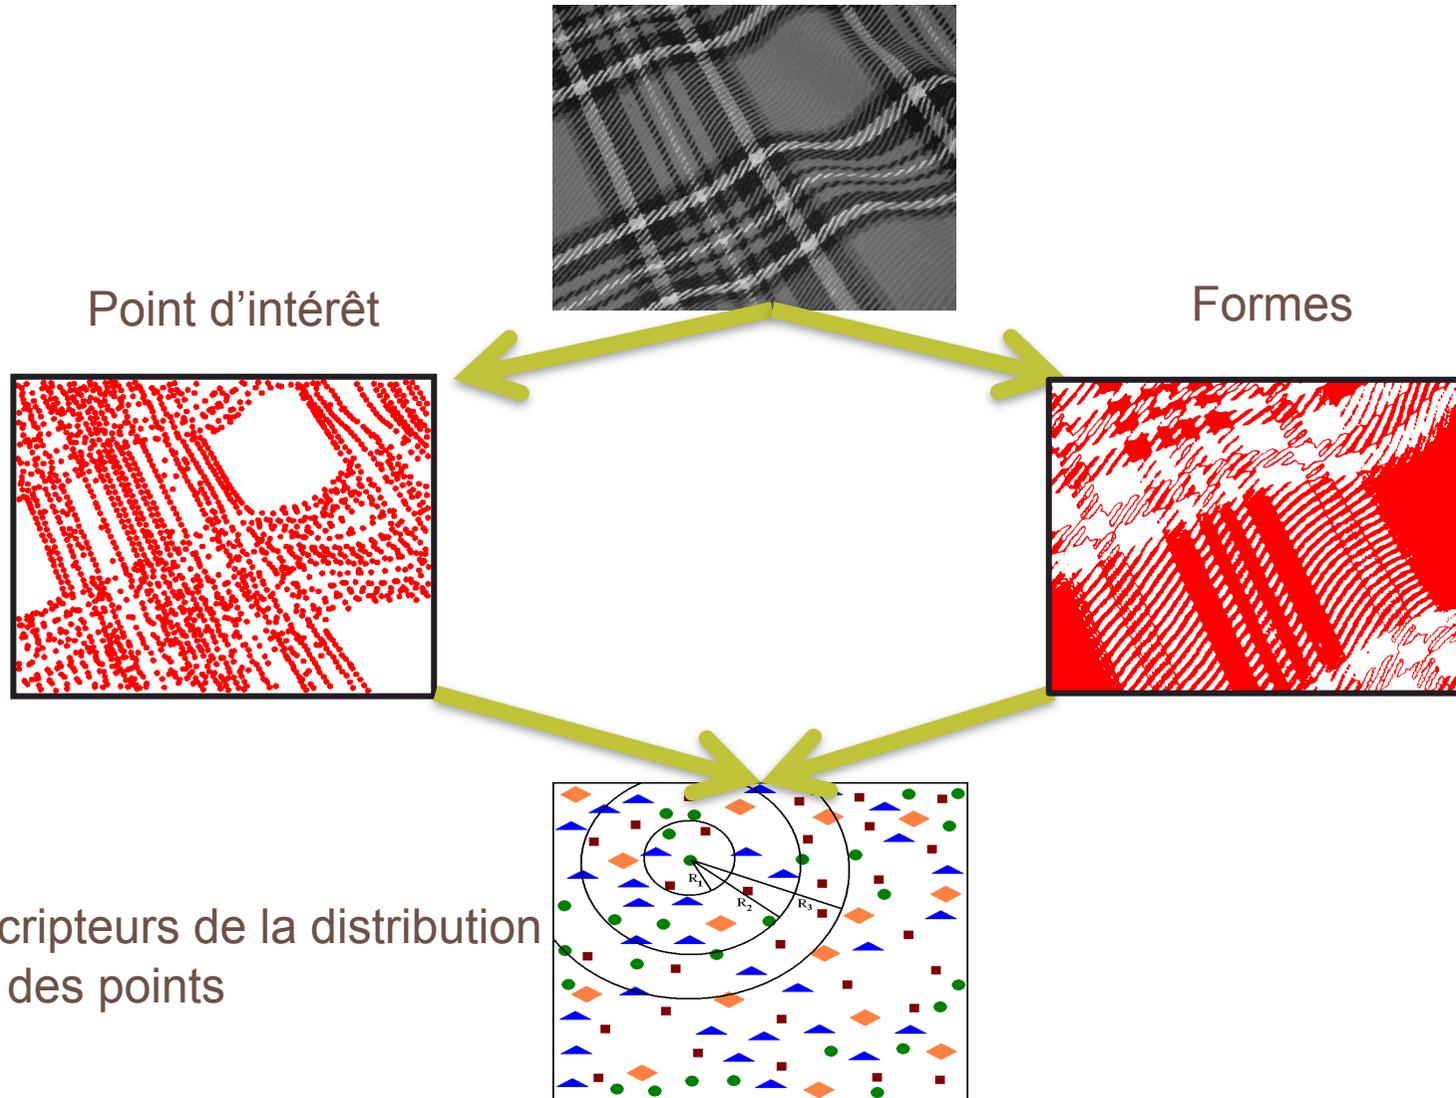
■ Results

- Processed dataset: 3 classes, 50 echograms per class
- Classifier: random forest





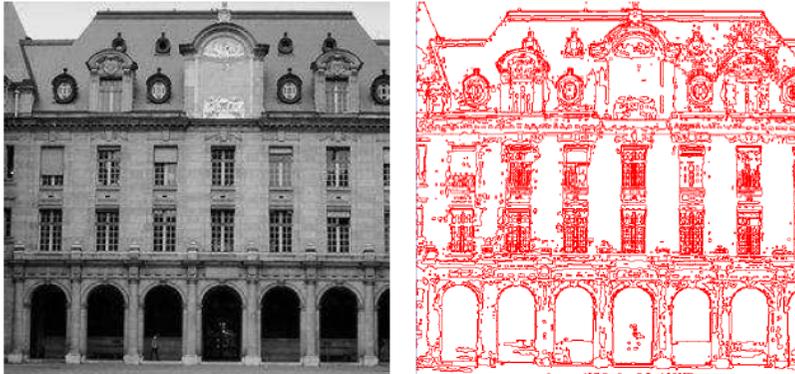
Description d'une image à partir de l'ensemble de ces formes « principales » (Xia et al. 2010)



Formes (1/2)



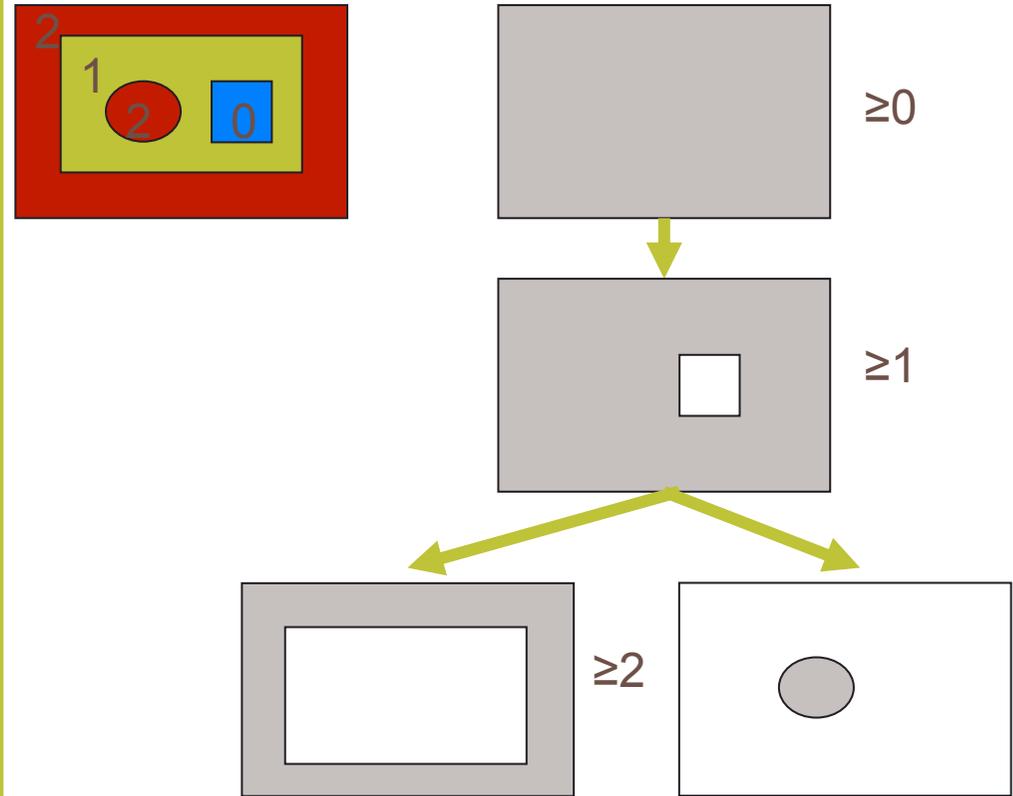
Détection de formes



Représentation d'une image par les lignes de niveau

$$\begin{cases} \chi^{\geq \lambda}(u) = \{x \in X, u(x) \geq \lambda\} \\ \chi_{\leq \mu}(u) = \{x \in X, u(x) \leq \mu\} \end{cases}$$

Ensembles de niveaux inférieurs et supérieurs



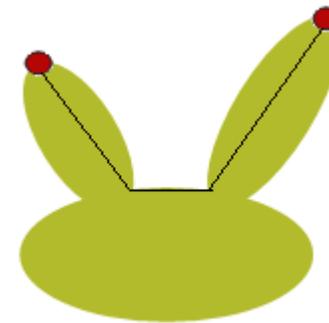
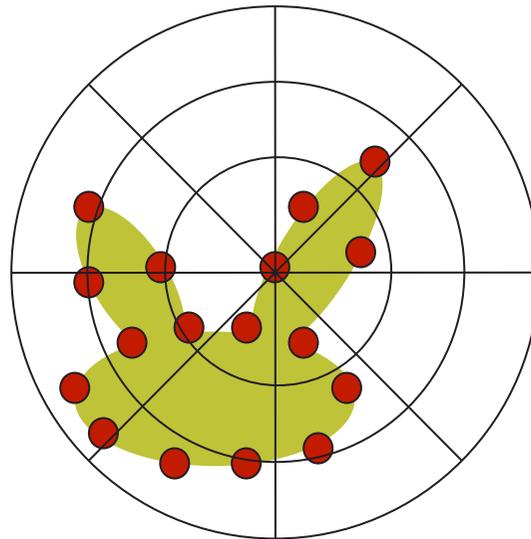
Un arbre de l'ensemble de niveaux supérieurs
Fast Level-Set Transform -FLST (Caselles99)

Formes (2/2)

Description invariante de formes

Le descripteur « inner-distance shape context » IDSC (Ling05):

$$h_i(k) = E_{j \neq i} \left\{ x_j : \langle d(x_j, x_i), \theta(x_j, x_i) \rangle \in bin(k) \right\}$$



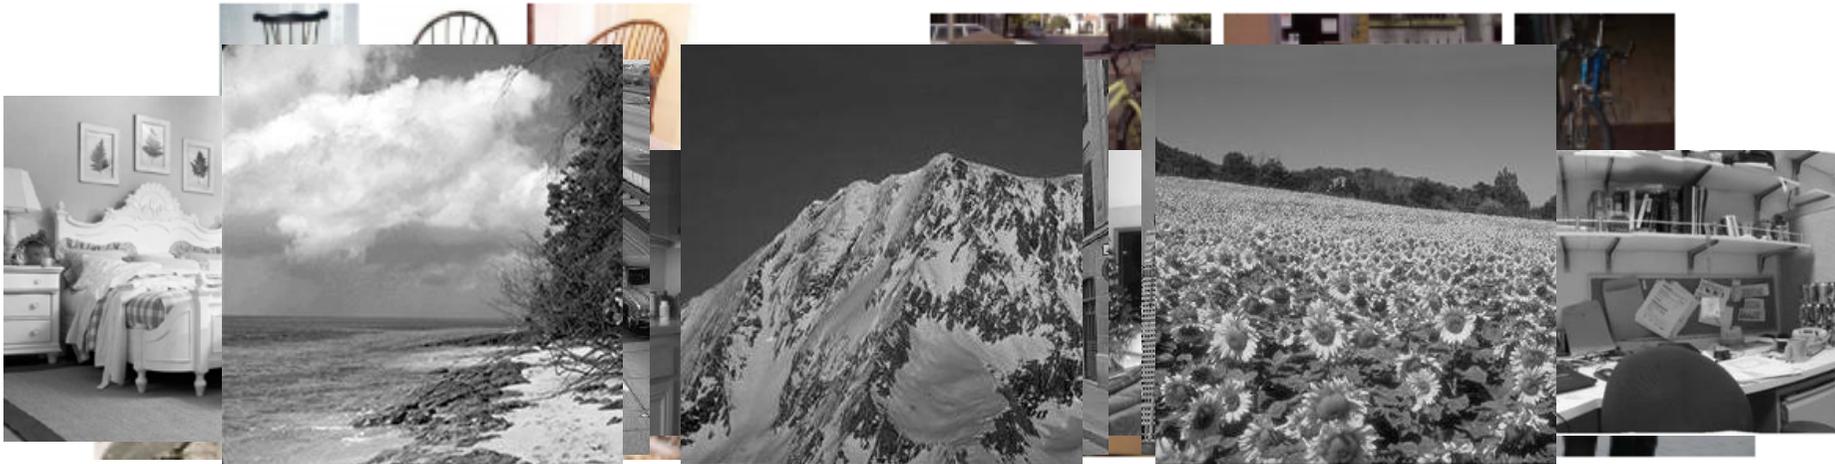
inner-distance $d(x_j, x_i)$

Classification des images naturelles



Images de scène naturelle

- ❖ 15 classes de scènes naturelles, chaque classe contient 210 à 410 images:



Caltech-101 [Fei-Fei 04]

[Lazebnik06] [Opelt 04]

Modèle hiérarchique bayésien (Fei-Fei 05)	74,8%
Pyramide spatiale de mots visuels (Lazebnik06)	81,4%
Corrélogramme spatial (Liu 07)	81,72%
Modèle de Cox log-Gaussien	82,9%

Références

- David Lowe, University of British Columbia, <http://www.cs.ubc.ca/~lowe/425/slides/5-Texture.ppt>
- J.Zhang et al. “Local features and kernels for classification of texture and object categories: a comprehensive study”. IJCV, 73(2), p.213–238, 2007.
- **Applications de la géométrie stochastique à l'analyse d'images.** *F. Chatelain, X. Descombes, F. Lafarge, C. Lantuéjoul, R. Minlos, M. Schmitt, M. Sigelle, R. Stoica and E. Zhizhina.* Publ. Hermes, Ed. X. Descombes, 2011. 
- Papiers : ECCV'2010, CVPR'2011, ICIP'2011, <http://perso.telecom-bretagne.eu/ronanfablet/> (thèse H.G. Nguyen)

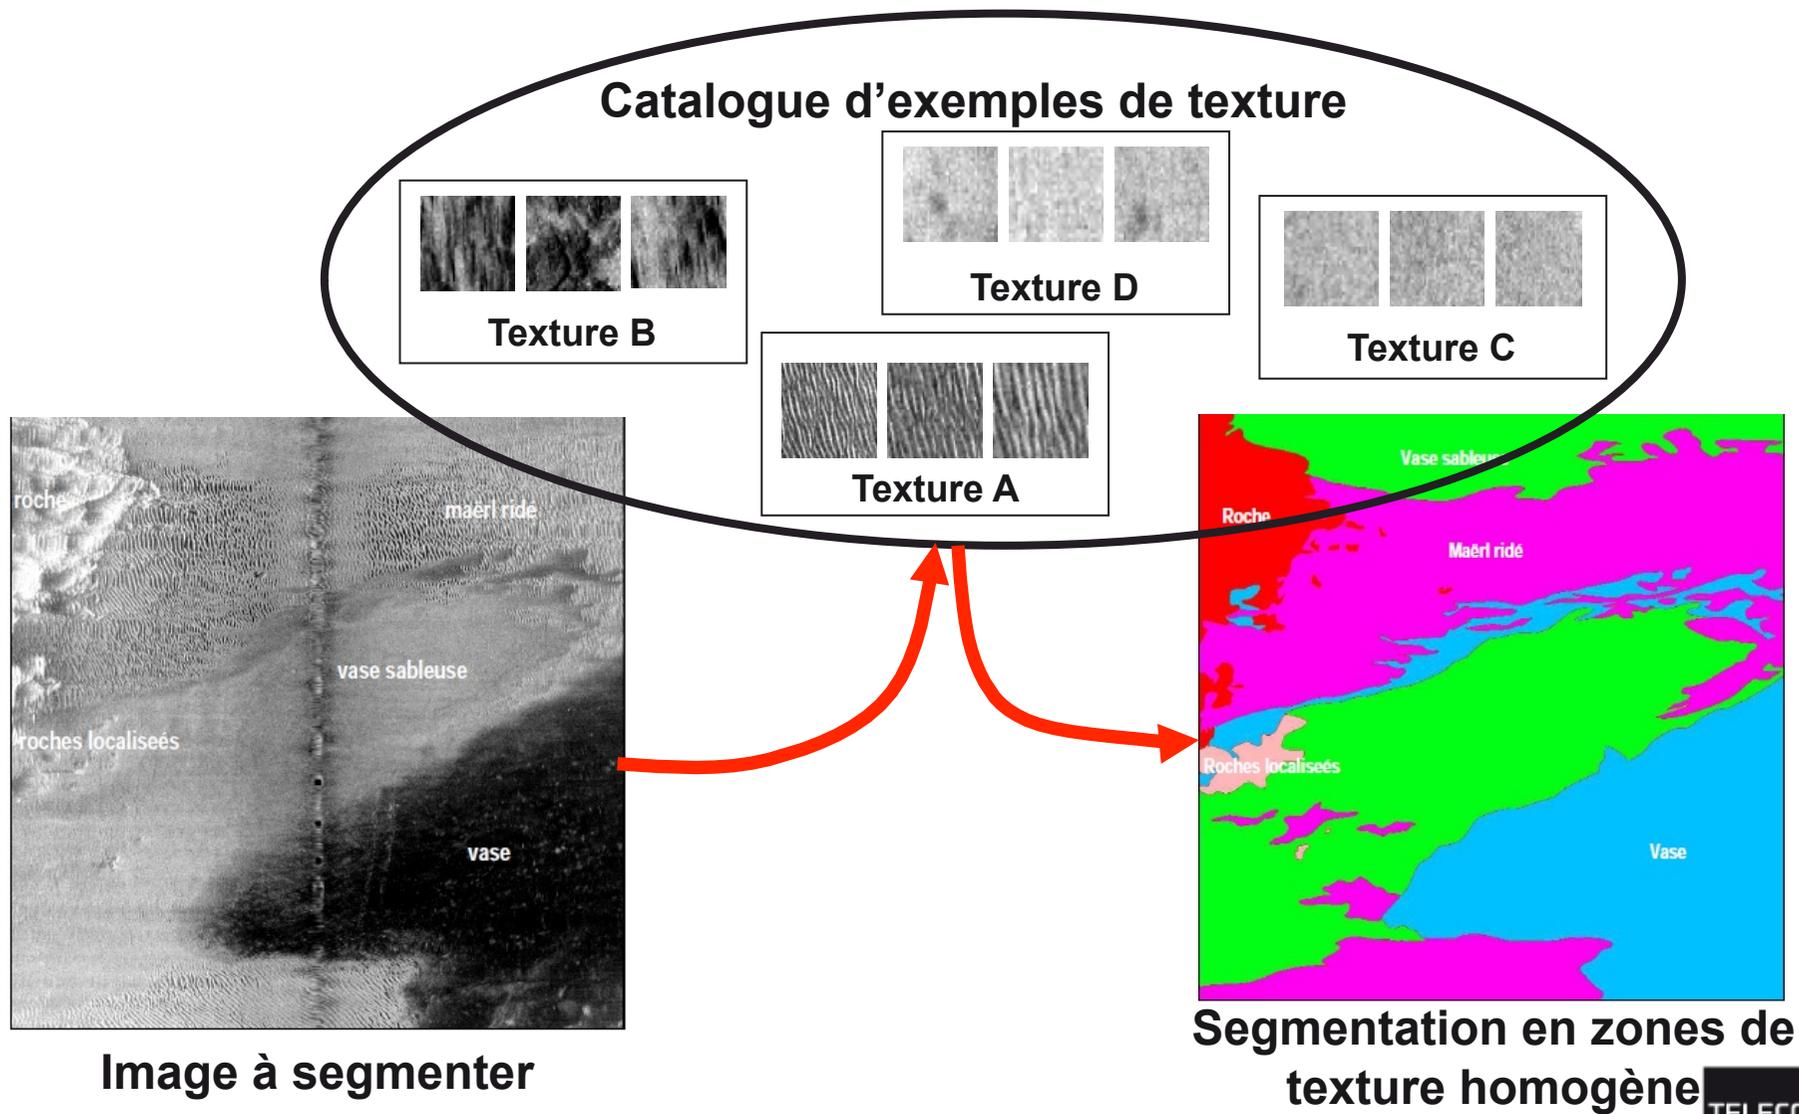


Segmentation de texture : le match Markov vs. Level-Set





Segmentation basée texture supervisée





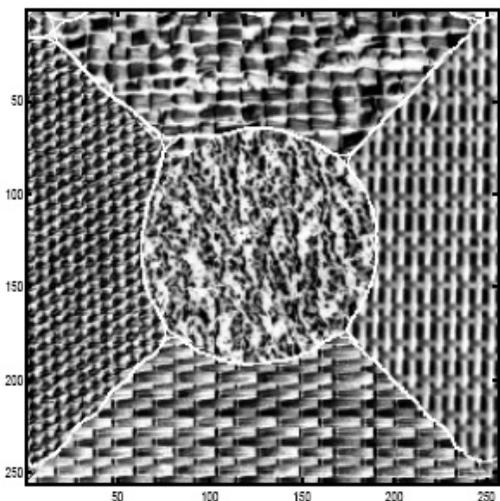
Quelles spécificités pour la segmentation basée texture?



Segmentation basée couleur



Segmentation basée mouvement

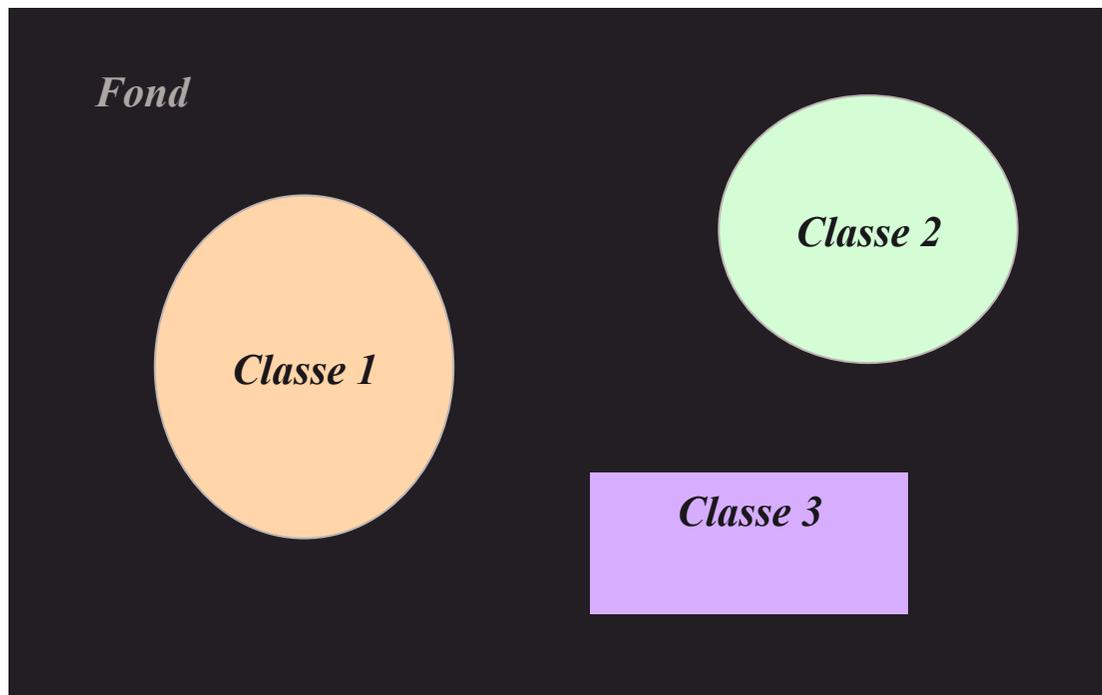


Segmentation basée texture

Absence de « mesure » locale de texture

Segmentaton “au niveau pixel”

Etiquetage (classification) des pixels de l’image vis-à-vis de classes (eg, type d’objets, fond,.....)



Formalisation

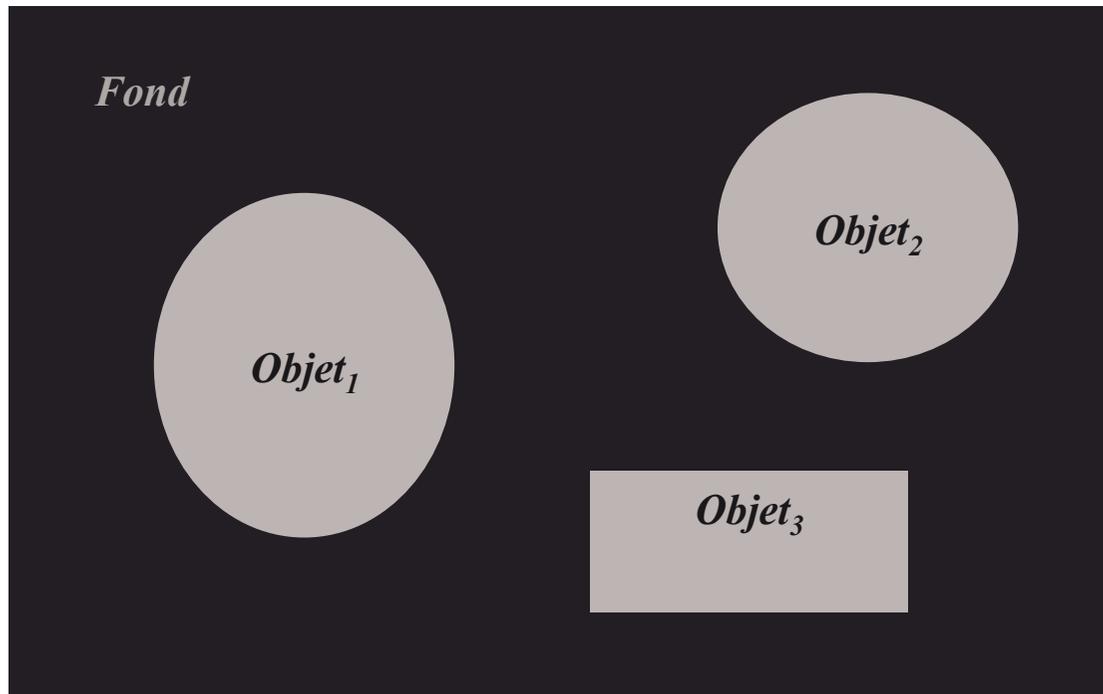
$$e = \{e_p\}_{p \in \mathcal{R}}$$

$$\forall p, e_p = \{1, \dots, N\}$$

**Eg, segmentation markovienne
=> A priori au niveau pixel**

Segmentation “au niveau région”

Recherche de la partition de l'image ou de la vidéo en régions d'intérêt (objets, fond)



Formalisation

$$\Omega = \cup_k \Omega_k$$

Eg, segmentation variationnelle

=> A priori/modélisation au niveau région



Principe général de la segmentation

Minimisation d'une fonctionnelle

Formulation markovienne

Niveau pixel

$$\min_e U_{data}(I, e) + U_{prior}(e)$$

Formulation variationnelle

Niveau région

$$\min_e U_{data}(I, \Omega) + U_{prior}(\Omega)$$

Spécification du modèle :

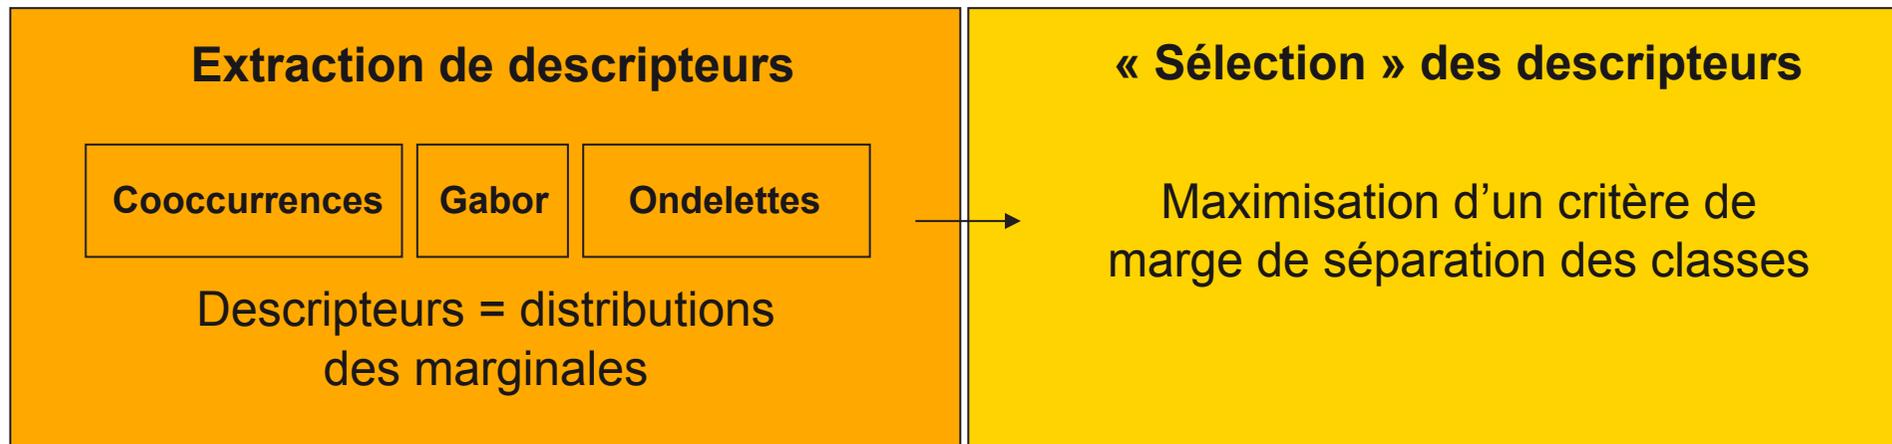
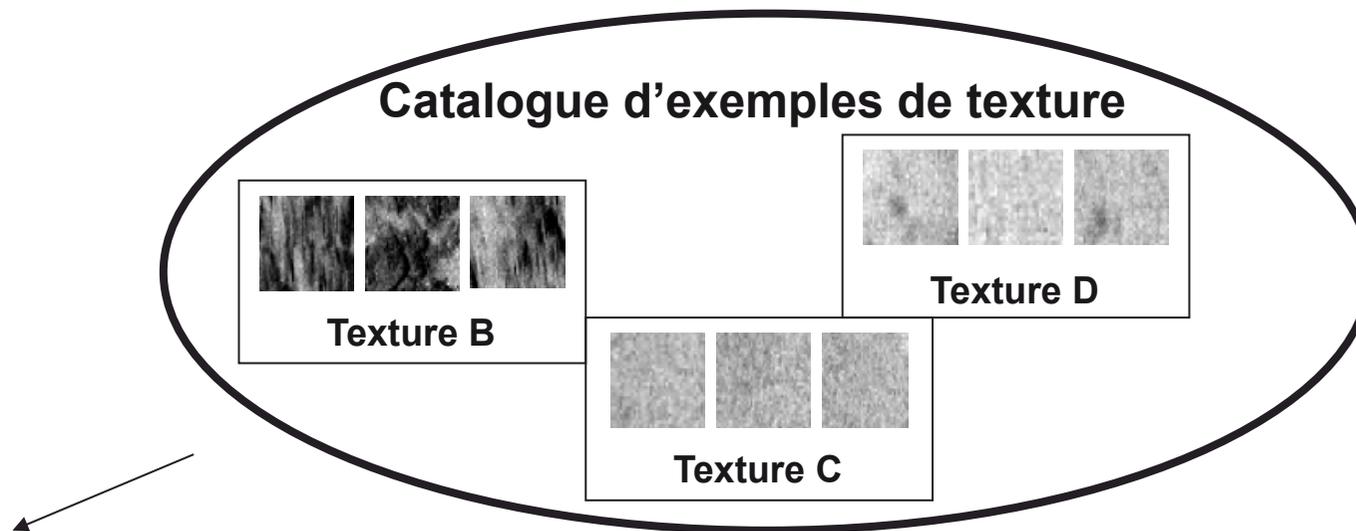
1. Exprimer le terme d'attache aux données U_{data}
2. Spécifier l'a priori U_{prior}



Mesure des similarité basée texture



Apprentissage d'une mesure de similarité





Apprentissage d'une mesure de similarité

❖ Descripteurs

$$T_k \longrightarrow Q(T_k) = (Q_f(T_k))_{f \in \mathcal{F}}$$

Type et paramètres du descripteur

Distribution/histogrammes

❖ Mesure de similarité

$$KL_w(T, R) = \sum_f w_f KL(Q_f(T), Q_f(R))$$

avec $KL(\alpha, \beta) = \int \alpha(u) \log \frac{\alpha(u)}{\beta(u)} du$

Sélection des caractéristiques discriminantes

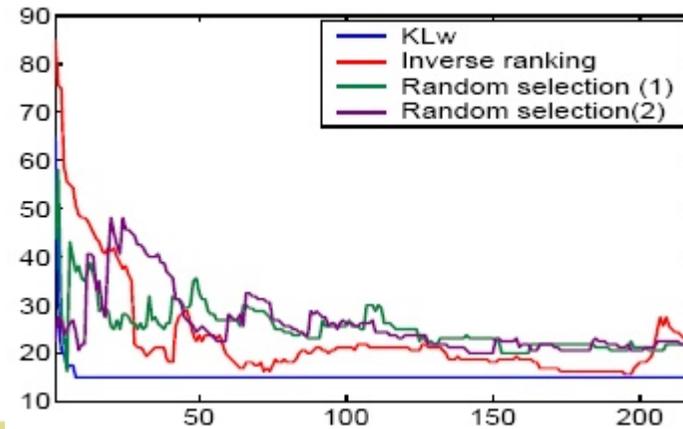
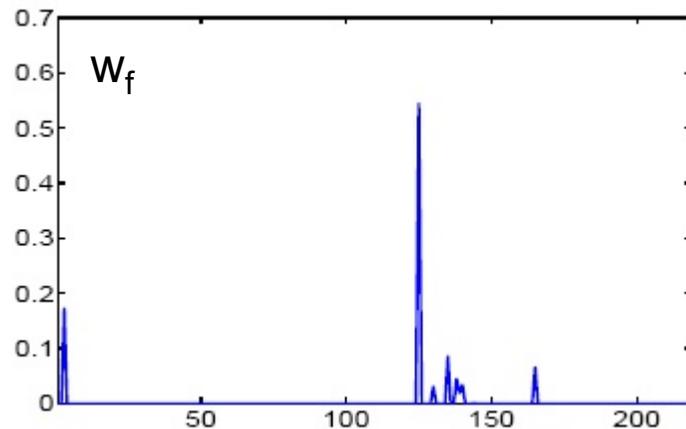
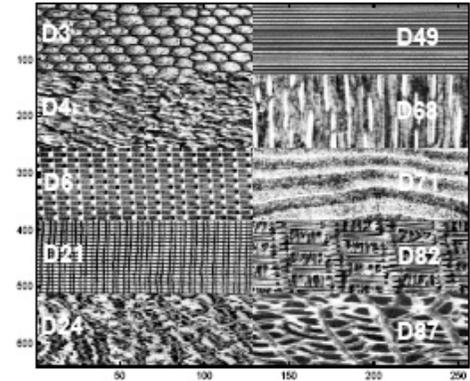
Apprentissage d'une mesure de similarité

❖ Résultats

❖ Cooccurrences : $\Theta = \left\{ k \frac{\pi}{4} \right\}_k$ et $\sigma = \left\{ \frac{\sqrt{2}}{2^k} \right\}_k$
(121 distributions)

❖ Gabor : $\Theta = \left\{ k \frac{\pi}{8} \right\}_k$ et $D = \{1, \dots, 10\}_k$
(50 distributions)

❖ Ondelettes : 2 niveaux de decompositions, 3 ondelettes
(Haar, Duabechies, Coiflet) (48 distributions)

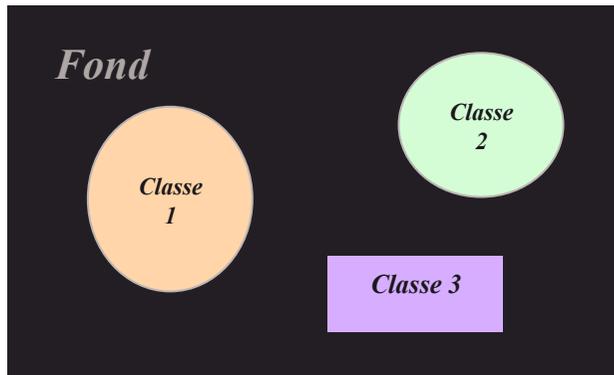




**Segmentation basée
texture : une première
approche au niveau pixel**



Segmentation markovienne



$$\min_e U_{data}(I, e) + U_{prior}(e)$$

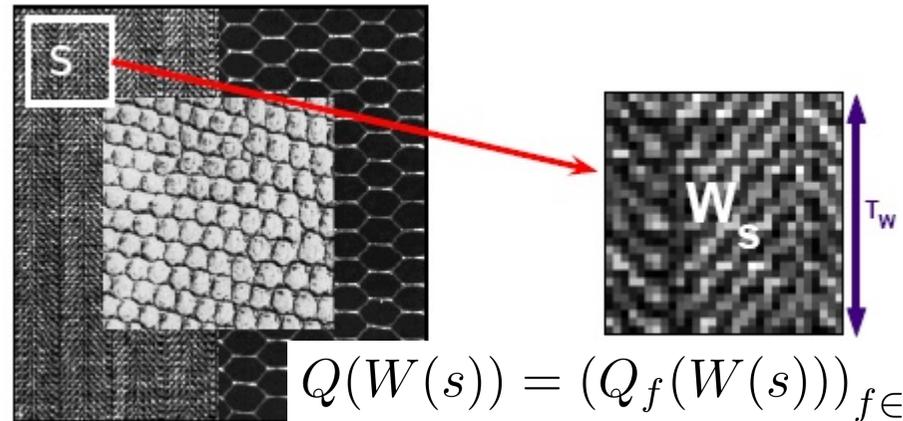
Modélisation markovienne

$$P(e|I) \propto P(I|e)P(e)$$

$$U_{data}(e, I) = -\log P(I|e)$$

$$U_{prior}(e) = -\log P(e)$$

Caractérisation local de l'information de texture



$$Q(W(s)) = (Q_f(W(s)))_{f \in \mathcal{F}}$$

Décomposition des énergies en somme de potentiels

$$U_{data}(I, e) = \sum_p U_{data}(e(p), W(p))$$

$$U_{prior}(e) = \sum_{p,q} U_{prior}(e(p), e(q))$$



Segmentation markovienne

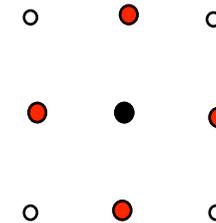
Formulation du modèle

$$U_{data}(I, e) = \sum_p U_{data}(e(p), W(p))$$

Modèle connu pour la classe e(p)

$$U_{prior}(e) = \sum_{p,q \text{ voisins}} U_{prior}(e(p), e(q))$$

4-voisinage



Critère de segmentation

MAP $\arg \max_e P(e|I) = \arg \min_e U_{data}(e, I) + U_{prior}(e)$

MPM $\arg \max_k P(e(p) = k|I)$

Résolution : algorithme ECI

Segmentation markovienne

❖ Résultats

- ❖ Régularisation spatiale d'une classification indépendante des pixels via le terme a priori

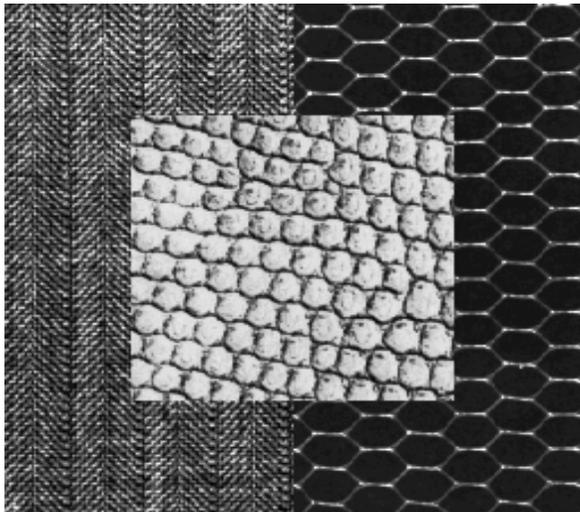
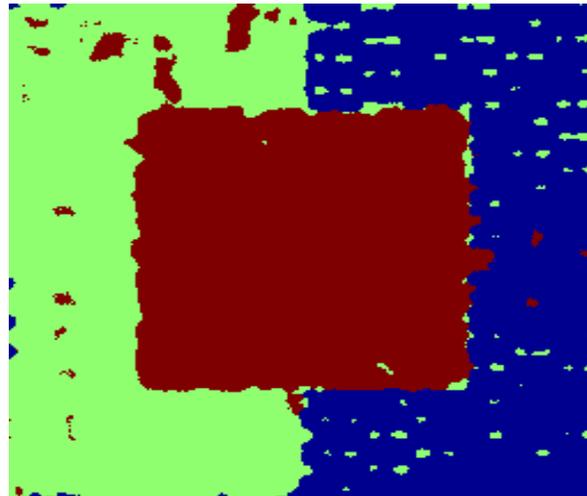
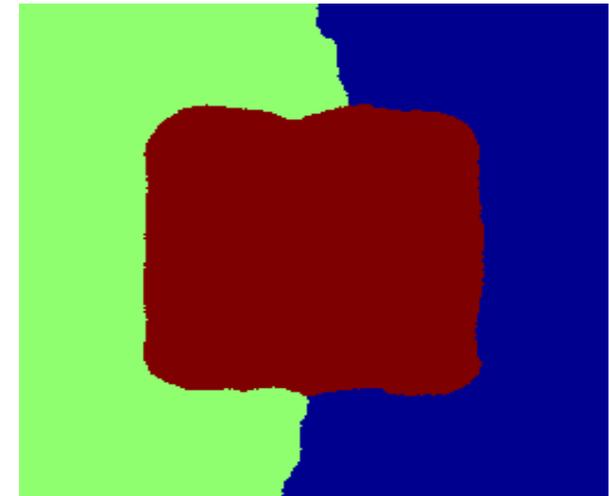


Image texturée



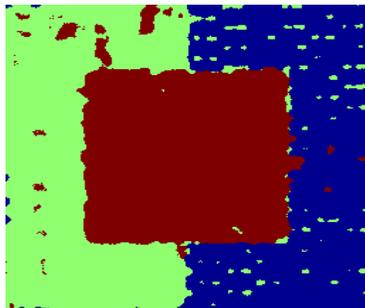
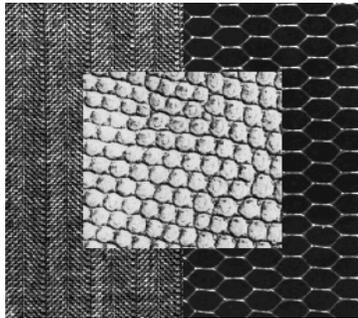
Classification indépendante des pixels



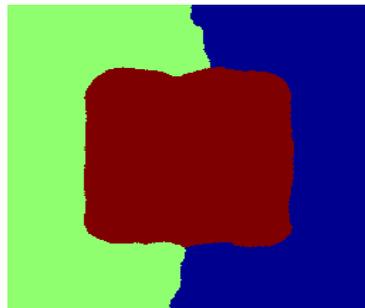
Apport de la régularisation spatiale

Segmentation markovienne

❖ Résultats



initialisation



Segmentation
markovienne

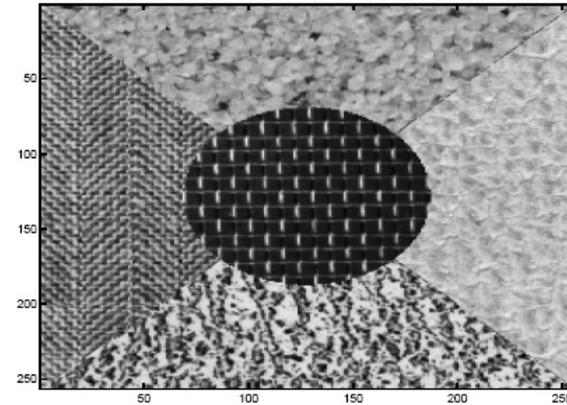
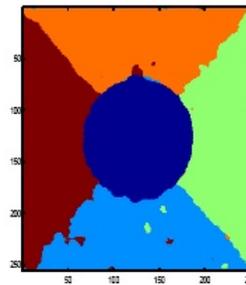
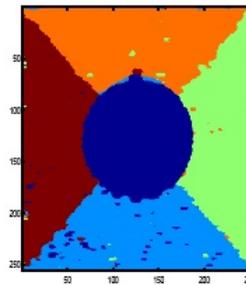


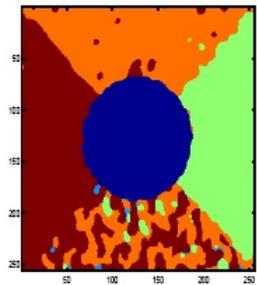
Figure 6: 5-Brodatz texture mosaic (D6, D24, D16, D92 and D29).



Similarité
optimisée



Cooccurrences



Gabor



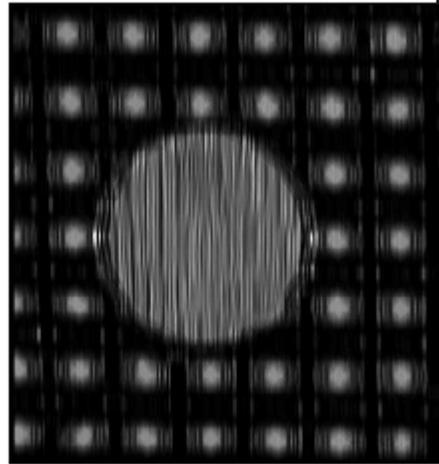
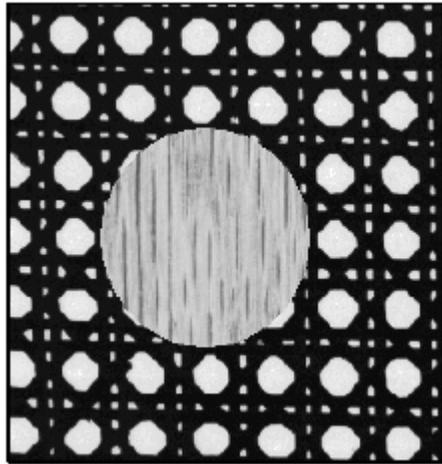
**Segmentation basée
texture : une première
approche au niveau pixel**



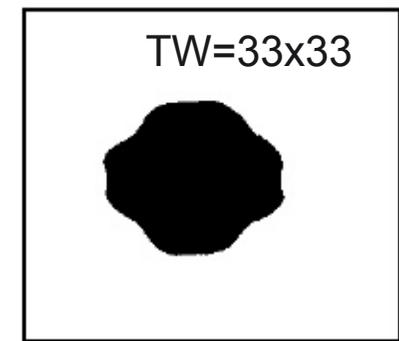
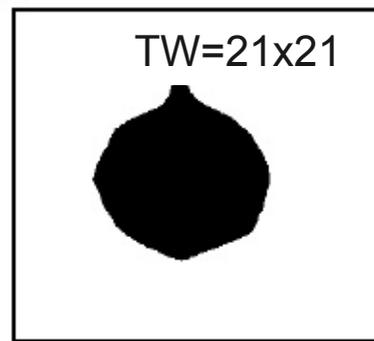
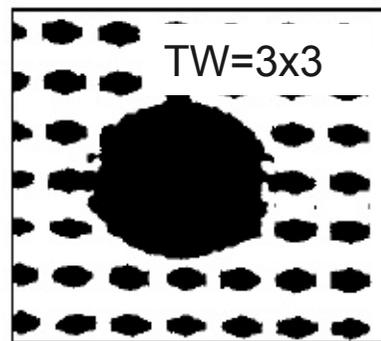
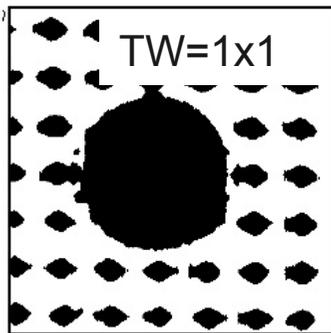
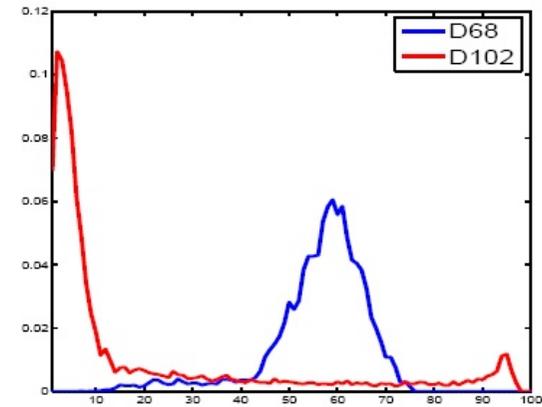


Limite des approches basées sur des critères au niveau pixel

❖ Un exemple



Descripteurs de Gabor

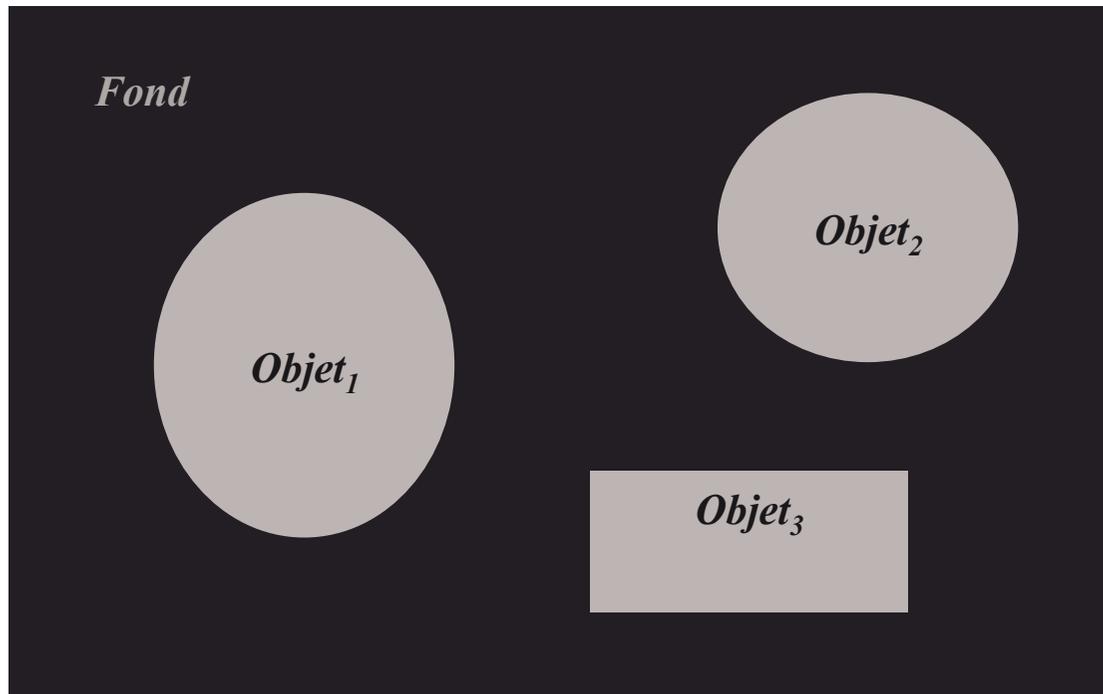


Résultats de segmentation avec différentes tailles de fenêtre d'analyse



Segmentation basée région

Recherche de la partition de l'image ou de la vidéo en régions d'intérêt (objets, fond)



Formalisation

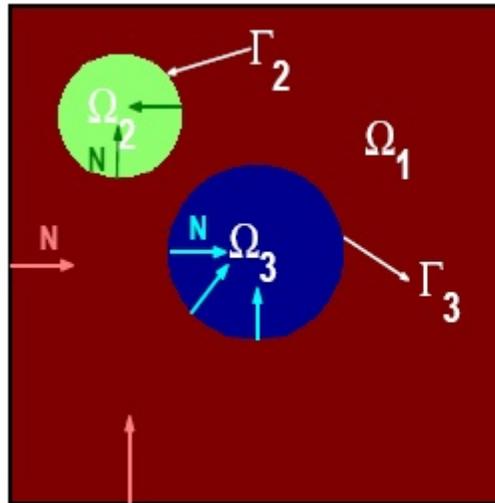
$$\Omega = \cup_k \Omega_k$$

Intérêt : manipulation explicite des régions



Formulation variationnelle classique

Modèle



$$\Rightarrow \begin{cases} \frac{\partial \Gamma_k(s, t)}{\partial t} \\ \Gamma_k(s, 0) = \Gamma_0 \end{cases}$$

Critère : minimiser $E(\{\Omega_k\}) = E_1(\{\Omega_k\}) + E_2(\{\Omega_k\}) + E_3(\{\Omega_k\})$

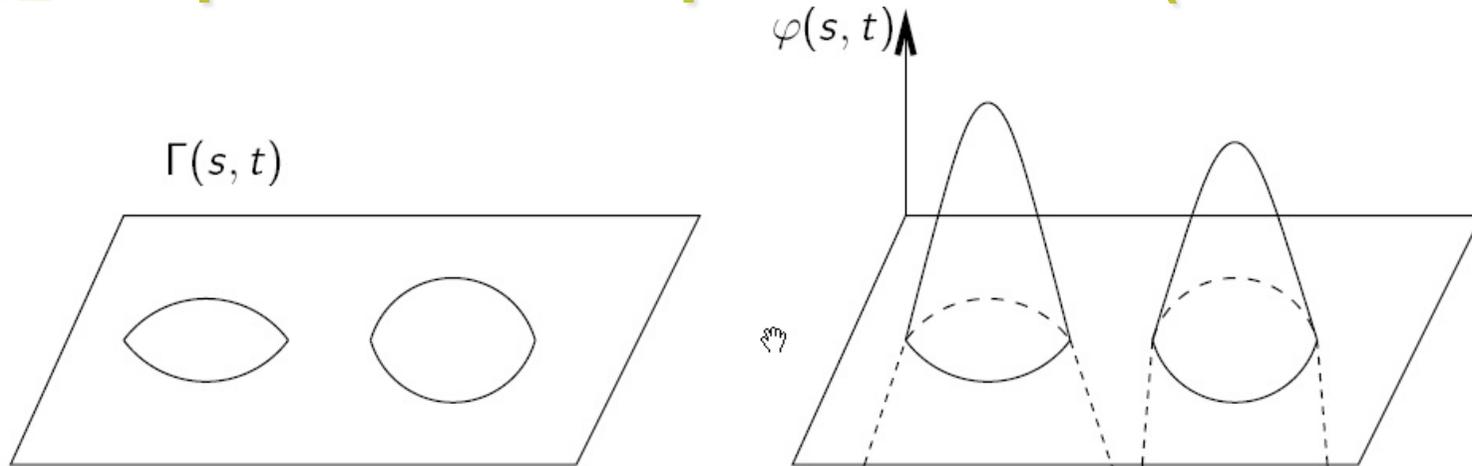
$$E_1(\{\Omega_k\}) = - \sum_k \int_{\Omega} H_{\alpha}(\Phi_k(s)) \log p_{k,s} ds \quad \text{Terme d'attache aux données}$$

$$E_2(\{\Omega_k\}) = -\lambda_2 \sum_k |\Gamma_k| \quad \text{Terme de régularisation}$$

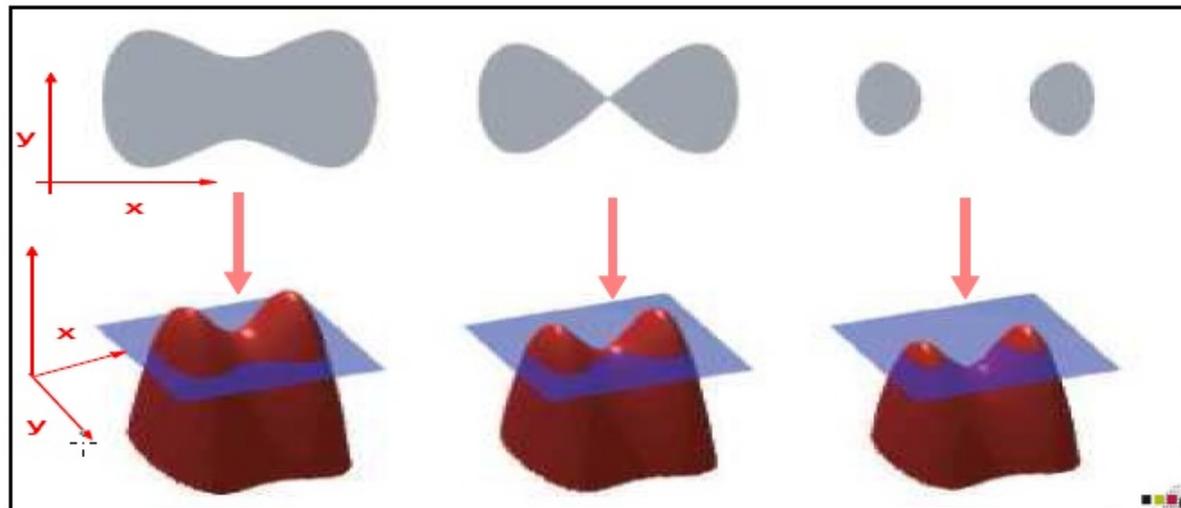
$$E_3(\{\Omega_k\}) = -\lambda_3 \sum_k \int_{\Omega} (1 - H_{\alpha}(\Phi_k(s)))^2 ds \quad \text{Condition de partition}$$



Implémentation par Level set (Sethian'96)



$$\frac{\partial \Gamma(s, t)}{\partial t} = V(s, t) \dot{N} \longleftrightarrow \frac{\partial \Phi(s, t)}{\partial t} = V(s, t) |\nabla \Phi(s, t)|$$





Formulation variationnelle classique

Equation d'évolution (Euler-Lagrange)

$$\frac{\partial \phi_k(s, t)}{\partial t} = \frac{\partial \phi_k^1(s, t)}{\partial t} + \frac{\partial \phi_k^2(s, t)}{\partial t} + \frac{\partial \phi_k^3(s, t)}{\partial t}$$

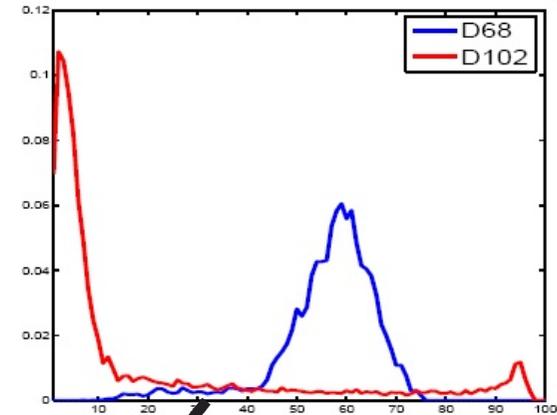
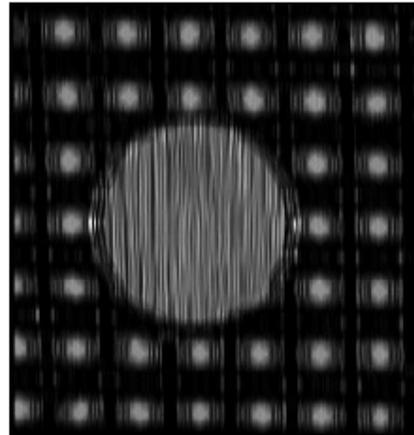
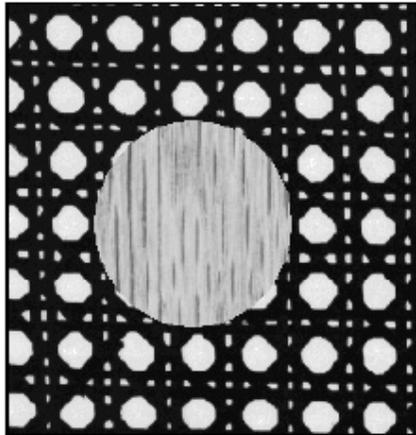
$$\frac{\partial \phi_k^1(s, t)}{\partial t} = -(\log p_{k,s}) |\nabla \phi(s, t)|$$

$$\frac{\partial \phi_k^2(s, t)}{\partial t} = \lambda_2 \operatorname{div} \left(\frac{\nabla \phi_k(s, t)}{|\nabla \phi(s, t)|} \right) |\nabla \phi(s, t)|$$

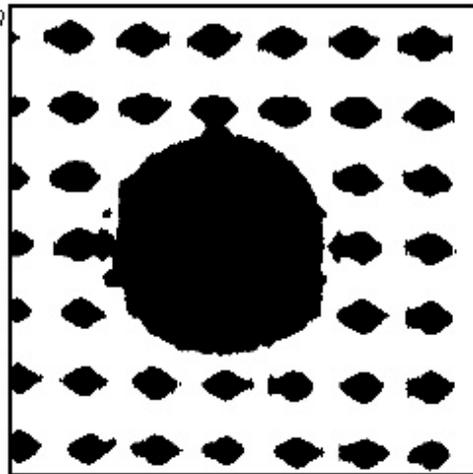
$$\frac{\partial \phi_k^3(s, t)}{\partial t} = \lambda_3 \left(\sum_k H_\alpha(\phi_k(s, t)) - 1 \right) |\nabla \phi(s, t)|$$

Formulation variationnelle classique

❖ Exemple d'application



Distribution des coefficients de Gabor



$$\frac{\partial \phi_k^1(s, t)}{\partial t} = -(\log p_{k,s}) |\nabla \phi(s, t)|$$



Formulation variationnelle “région”

❖ Formulations “région” du terme d’attaches aux données

❖ Prise en compte de la mesure de similarité

$$E_1 (\{\Omega_k\}) = - \sum_k |\Omega_k| KL_w [Q^k, Q(\Omega_k)]$$

Modèle de la classe k

Descripteurs de texture
de la région Ω_k

❖ Nécessité d’utiliser des outils de dérivation spécifiques pour calculer le gradient de cette fonctionnelle (le critère dépend des domaines $\{\Omega_k\}$)

❖ Dérivé de forme [Jehan-Besson, 2002]



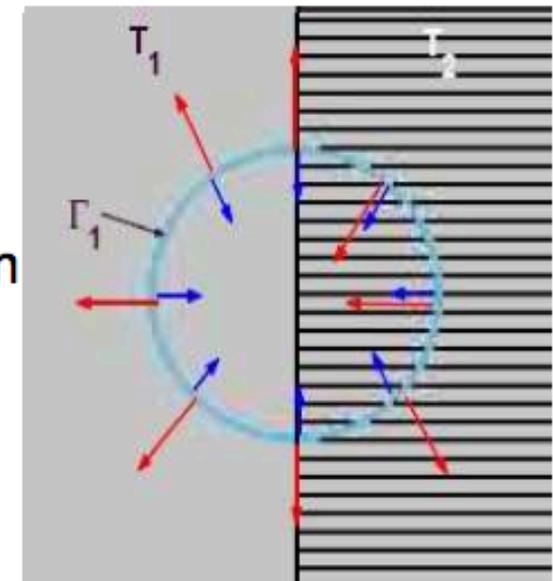
Formulation variationnelle “région”

❖ Interprétation de la dynamique du terme région

$$\frac{\partial \phi_k^1(s, t)}{\partial t} = \left[-KL_w(Q^k, Q(\Omega_k)) - \sum_f w_f^2 \left(\left(\frac{Q_f^k}{Q_f(\Omega_k)} * g_{\sigma_f} \right) (s) - 1 \right) \right] |\nabla \phi(s, t)|$$

Terme global de contraction
« constant spatialement »

Terme local
Participation du point s à la similarité globale de la région



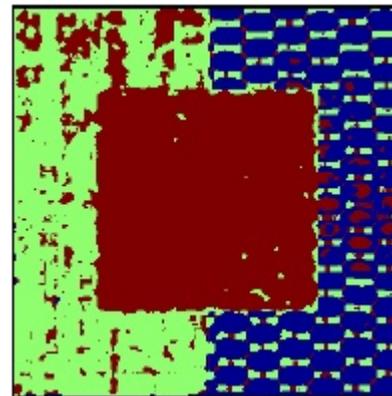
Terme classique

$$\frac{\partial \phi_k^1(s, t)}{\partial t} = -(\log p_{k,s}) |\nabla \phi(s, t)|$$

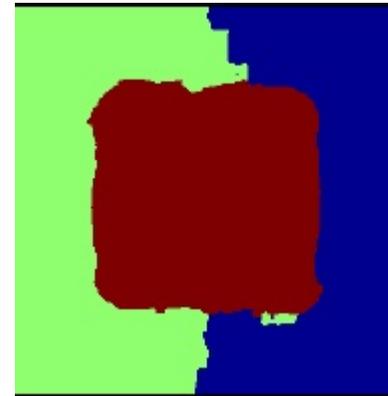


Formulation variationnelle “région”

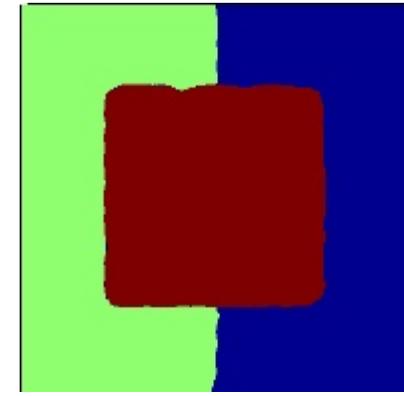
❖ Résultats



Initialisation MV
(descripteur $Q(W_s)$)

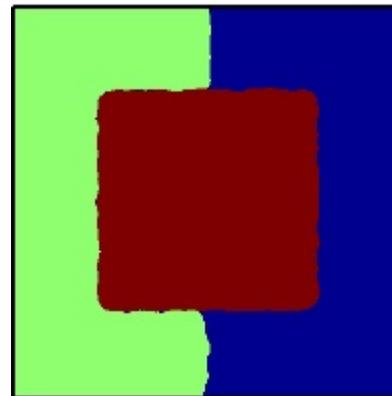


500 itérations



1000 itérations

Résultat pour une
initialisation
arbitraire



**Robustesse vis-à-vis du schéma
d'initialisation**

**Pas dépendance à une fenêtre
local d'analyse**





Synthèse : segmentation bayésienne vs. Segmentation variationnelle



Synthèse

Segmentation markovienne

Modélisation discrète : $\{e, I\}$

Minimisation d'une énergie :

$$\sum_p U_d(e(p), W(p)) + \sum_{(p,q)} U_r(e(p), e(q))$$

Optimisation stochastique

Segmentation variationnelle «classique»

Modélisation continue : $\{\varphi, I\}$

Minimisation d'une énergie :

$$\int_{\Omega} \sum_k H_{\alpha}(\Phi_k) U_d(k, W(p)) ds + \lambda \sum_k \int_{\Omega} \delta_{\alpha}(\Phi_k) |\nabla \Phi_k| ds$$

Optimisation par descente de gradient

Critère formellement différents mais numériquement proches :

Segmentation markovienne ~ discrétisation du critère continu

Interprétation bayésienne du critère variationnel

Synthèse :

Segmentation markovienne

Modélisation discrète : $\{e, l\}$

Minimisation d'une énergie :

$$\sum_p U_d(e(p), W(p)) + \sum_{(p,q)} U_r(e(p), e(q))$$

Segmentation Variationnelle « région »

Modélisation continue : $\{\varphi, l\}$

Minimisation d'une énergie :

$$\sum_k |\Omega_k| D(Q^k, Q(\Omega_k)) + \lambda \sum_k \int_{\Omega} \delta(\Phi_k) |\nabla \Phi_k| ds$$

Critères formellement différents

Estimation des hyper-paramètres

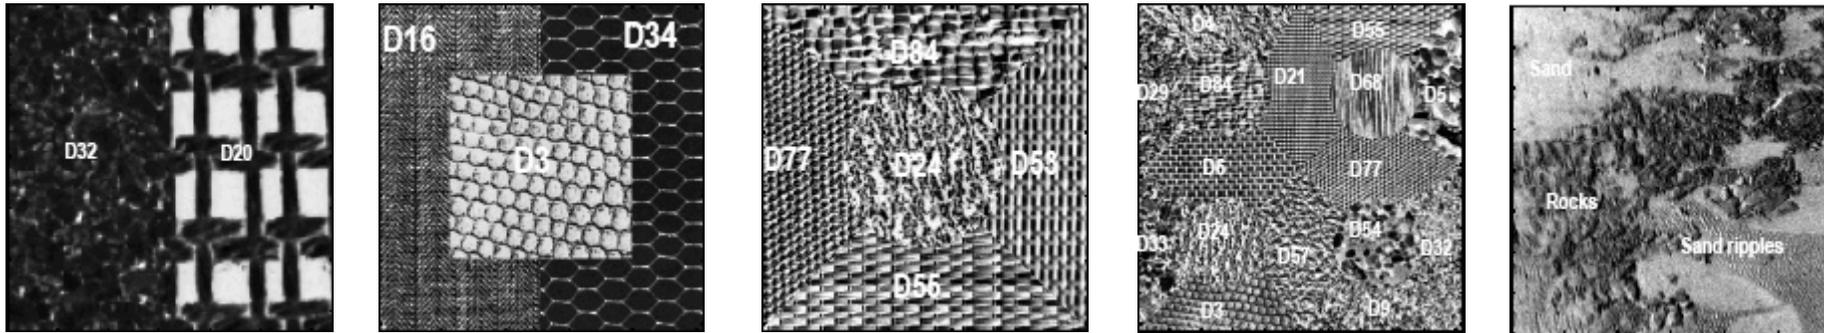
Algorithmes discrets rapides
(graph cuts)

Ajustement empirique de la pondération
des termes d'énergie

Possibilité d'ajouter des a priori au
niveau région sur la fonction φ

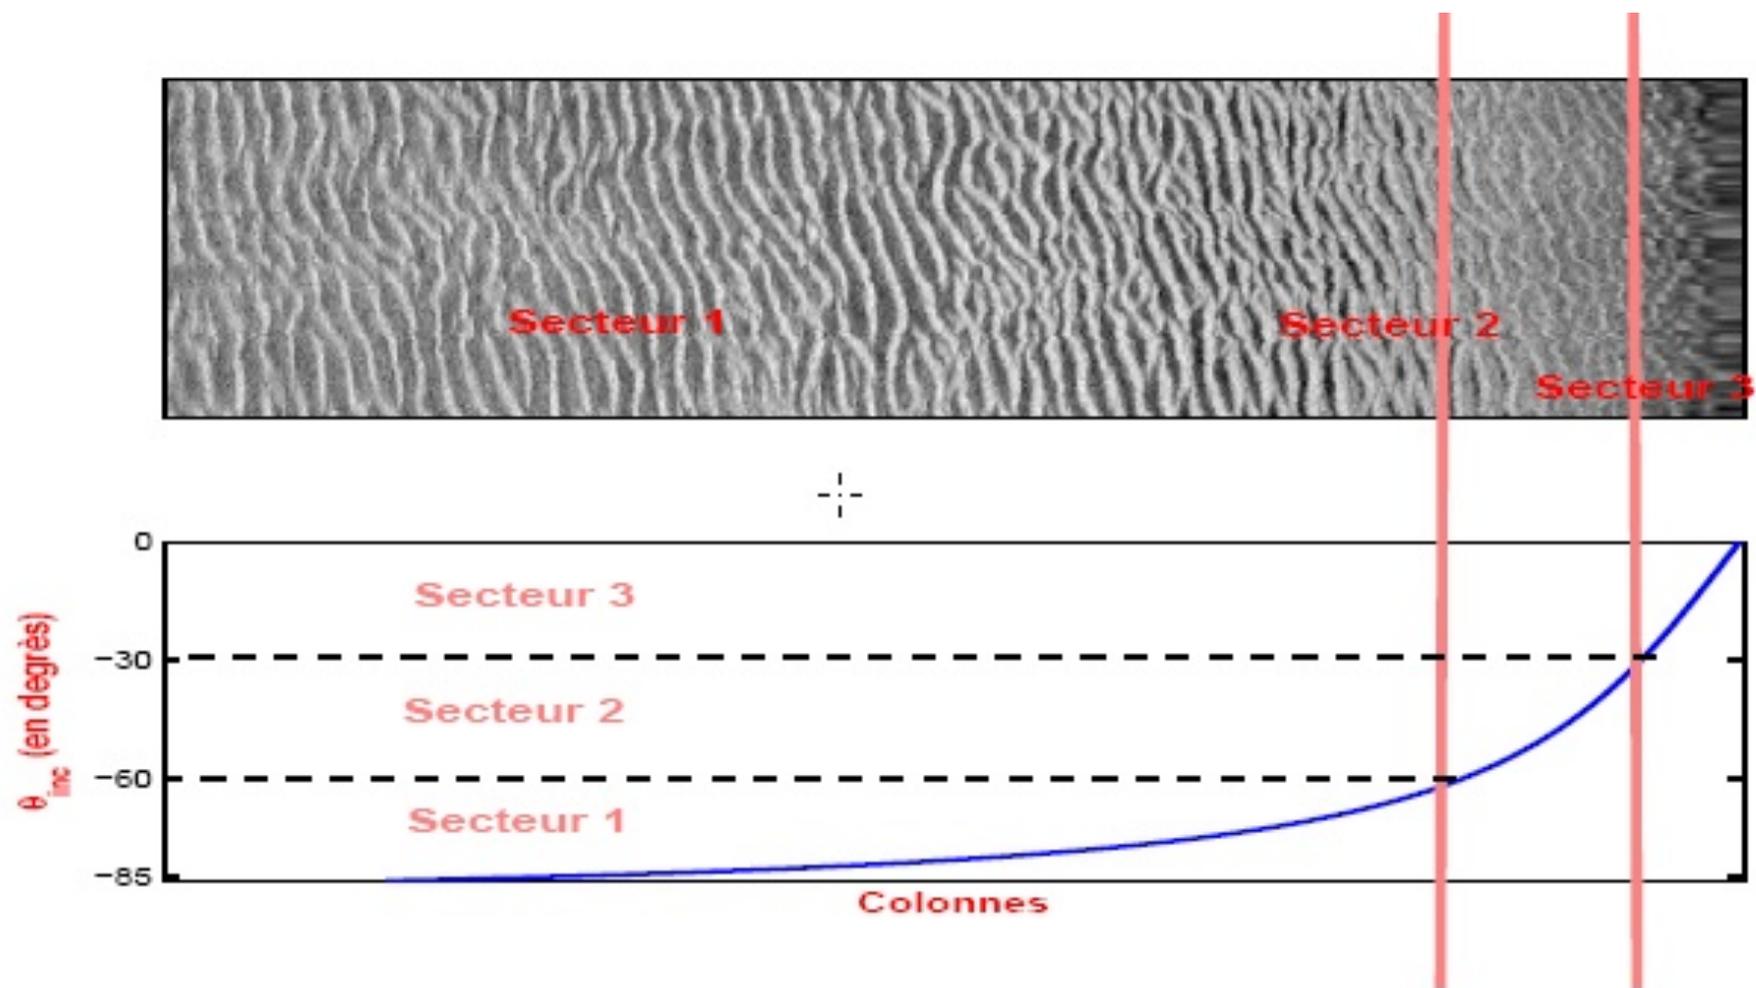
Comparaison expérimentale

Images de test



	$Var_{Heiler}: T_W = 3 \times 3$	$Var_{Heiler}: T_W = 9 \times 9$	$Var_{Heiler}: T_W = 33 \times 33$	$Var_{classic}$	$Var_{proposed}$	Randen
I1	$\tau = 7\%$	$\tau = 6\%$	$\tau = 10\%$	$\tau = 11\%$	$\tau = 2.7\%$	-
I2	$\tau = 9\%$	$\tau = 5\%$	$\tau = 4.6\%$	$\tau = 2\%$	$\tau = 0.9\%$	-
I3	$\tau = 70\%$	$\tau = 30\%$	$\tau = 7\%$	$\tau = 3\%$	$\tau = 4.9\%$	$\tau = 8.2\%$
I4	$\tau = 80\%$	$\tau = 70\%$	$\tau = 19\%$	$\tau = 63\%$	$\tau = 13.9\%$	$\tau = 37.2\%$
I5	$\tau = 25\%$	$\tau = 13\%$	$\tau = 13\%$	$\tau = 13.5\%$	$\tau = 7.5\%$	-

Mise en évidence de la robustesse du critère « région » pour segmenter des images sur la base de l'information de texture



Partition du secteur angulaire





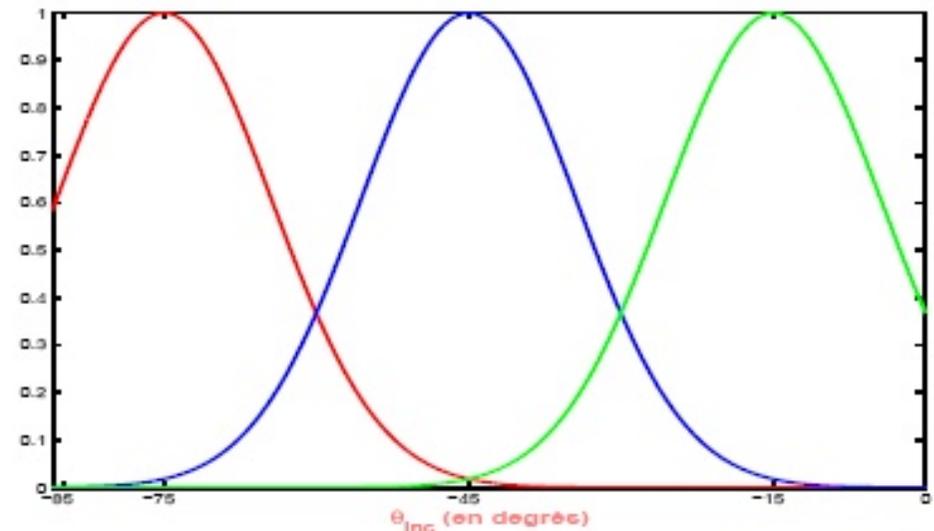
Prise en compte des caractéristiques des images sonar

$$T_k \Rightarrow Q^k = \left\{ Q_{f,\theta_j}^k \right\}_{j=1:3, f=1:F, k=1:K} \quad \text{et } KL_w \Rightarrow KL_w^\ominus,$$

$$KL_w^\ominus(Q^k, D(T^\theta)) = \sum_{j=1}^J \sum_{f=1}^F w_{\theta,\theta_j} w_f^2 KL(Q_{f,\theta_j}^k, D_f(T^\theta)),$$

avec:

$$w_{\theta,\theta_j} = g_{\sigma_j}(\theta_j - \theta) / \sum_{j=1}^J g_{\sigma_j}(\theta_j - \theta)$$



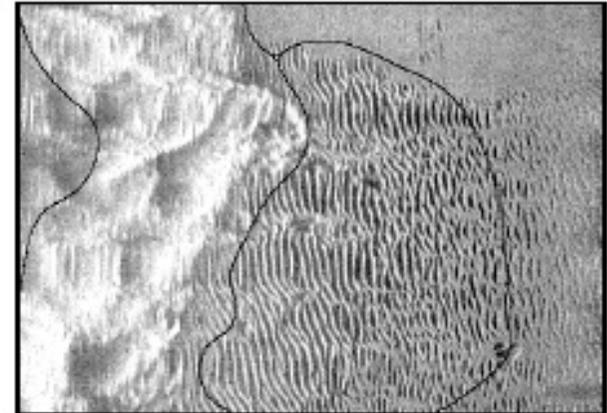
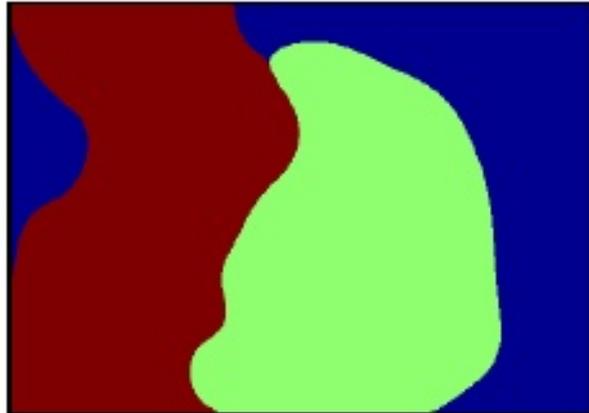
Pondération angulaire



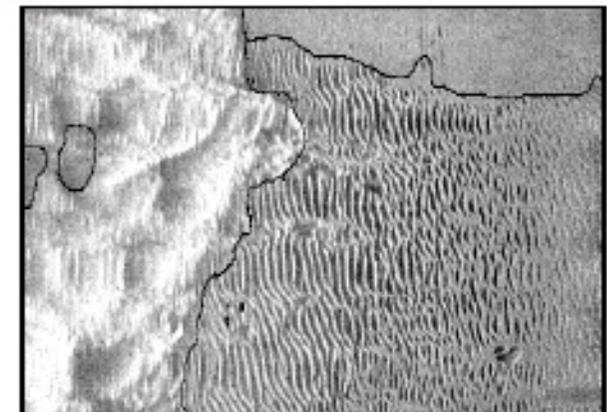
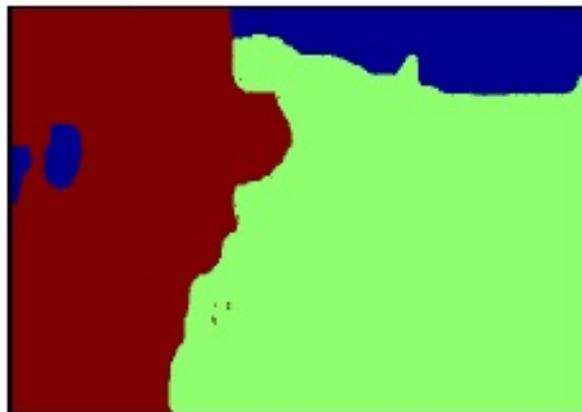
Segmentation des images sonar

❖ Résultats

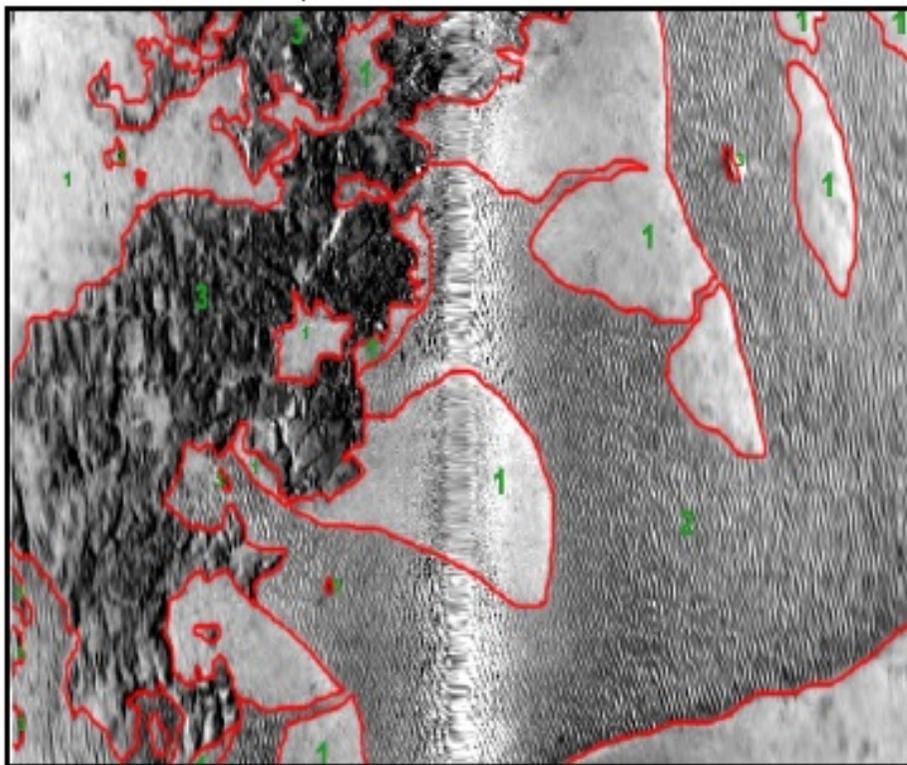
Application directe



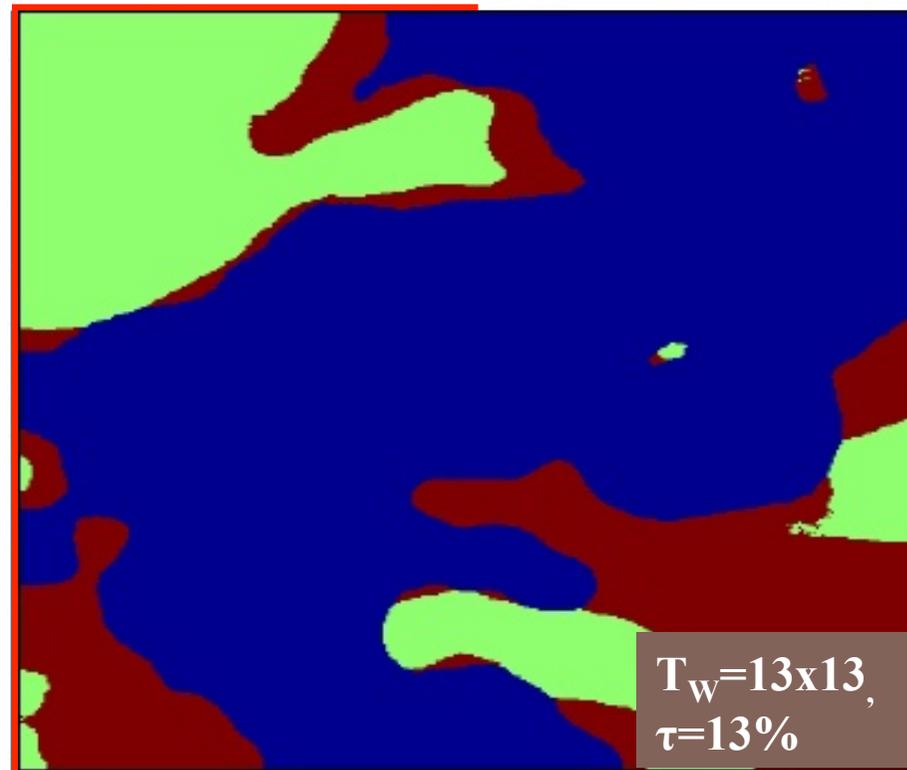
Prise en compte de la dépendance angulaire



Résultats



Reference: expert interpretation



Segmentation ($\tau=6.9\%$)

Remerciements

- Joint work with I. Karoui, R. Lefort, H. G. Nguyen, J.M. Boucher (Telecom Bretagne), J.M. Augustin, A. Erhold (Ifremer)





Références



Références

- ❖ [Snakes: Active contour models](#), M Kass, A Witkin, D Terzopoulos - International journal of computer vision, 1988
- ❖ [Markov random fields: theory and application](#), R Chellappa, A Jain - Boston: Academic Press, 1993
- ❖ **Level Set Methods and Fast Marching Methods**, J A Sethian, 1996
- ❖ Jehan –Besson et al. **Shape Gradient for Image and Video Segmentation** Mathematical Models in Computer Vision: The Handbook, Springer 2005
- ❖ Karoui et al., Variational region-based segmentation using multiple texture statistics. IEEE Trans. on Image Processing, 30(3):3146-3156, 2011.

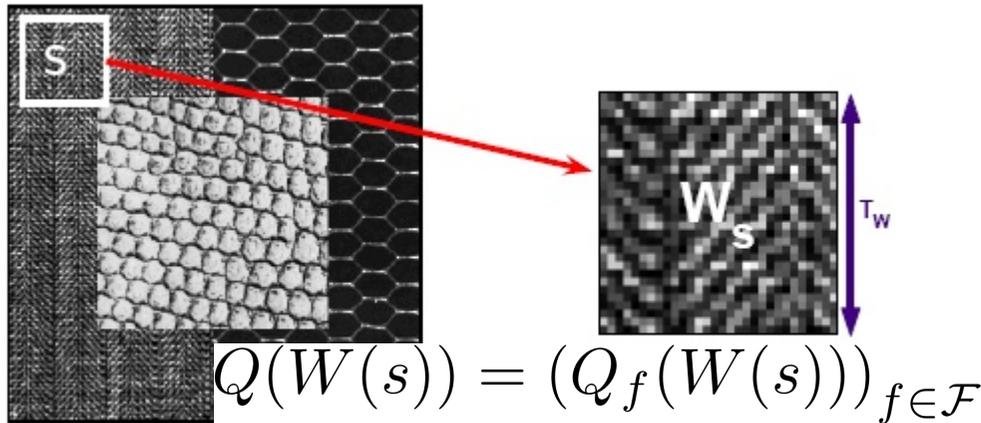
<http://perso.telecom-bretagne.eu/ronanfablet>



Formulation variationnelle classique

❖ Formulations alternatives

- ❖ Prise en compte d'une fenêtre autour de chaque pixel => modification de l'observation en chaque point



Choix de la taille de la fenêtre d'analyse ?

$$E_1(\{\Omega_k\}) = - \sum_k \int_{\Omega} H_{\alpha}(\phi_k(s)) \log p_{k,s} ds$$

$$\rightarrow E_1(\{\Omega_k\}) = - \sum_k \int_{\Omega} H_{\alpha}(\phi_k(s)) \log p_k(Q(W_s)) ds$$