

# Segmentation spatio-temporelle et suivi dynamique des fouillis radar

## Motion-based Segmentation and Tracking of Dynamic Radar Clutters

par Frédéric BARBARESCO, Johan LAMBERT, Carole LAMBERT

THOMSON-CSF Airsys  
7, rue des Mathurins  
F-92223 Bagneux cedex

### *résumé et mots clés*

Cet article traite de la classification et de l'estimation spatiale « à court terme » des fouillis radar (reconnaissance du type de fouillis et pistage de ses paramètres de déplacement et de déformation). Pour ce faire, nous utilisons des algorithmes de segmentations spatiale et spatio-temporelle statistiques pour la localisation différenciée entre fouillis « statiques » et fouillis « dynamiques », ainsi que l'utilisation, soient conjointement des techniques de contours actifs et de filtrage de Kalman, soient des méthodes de modélisation hiérarchique des déformations pour le suivi dynamique des fouillis homogènes. Ce procédé peut avoir différentes applications : une synthèse de l'environnement par une classification dynamique des fouillis permettant la gestion automatique du radar tant à l'émission (modes du radar) qu'à la réception (traitement du signal et des données, pistage), ainsi que l'estimation « à court terme » de l'évolution de certains phénomènes atmosphériques sévères (orages, fronts de pluie intense, grêle, neige compacte, ...) pour une gestion optimisée et sécurisée du trafic aérien civil.

**Segmentation spatio-temporelle, Contours actifs, Modèle hiérarchique de déformation, Fouillis radar, Suivi d'objets déformables.**

### *abstract and key words*

This paper deals with radar clutter classification and spatial short term forecasting (clutter types recognition and tracking of shifting and geometrical deformation parameters). This functionality is provided by use of, spatial and spatio-temporal statistical segmentation to differentiate static clutter from dynamic ones, and either snakes technics together with kalman filter or hierarchical deformation model methods to forecast homogenous clutters. This process could have numerous applications : dynamic classification of clutters provides an environment synthesis used to operate automatic radar management of both emission modes and reception algorithms alike (signal and data processing, tracking), as well as short term forecasting of harsh atmospheric disturbance (storm, lashing rain clouds, hail storm, powder snow clouds, ...) for an optimal and secure civil air traffic management.

Motion-based segmentation, Active contours, Hierarchical deformation model, Radar clutters, Tracking of dynamic shapes.

## 1. problématique radar

Dans une première problématique radar, les méthodes de segmentation spatio-temporelle et de suivi dynamique des fouillis radar s'inscrivent dans une approche plus globale d'autorégulation intelligente des radar 3D de veille longue portée pour la défense aérienne. Ces radars 3D sont chargés de la veille de l'espace aérien sur plusieurs centaines de kilomètres. Or, il est fréquent dans cet espace que soient présents des fouillis naturels (atmosphériques :

nuage, pluie, ... et topographiques : sol, mer, bâtiments en zone proche, ...) mais aussi des brouilleurs actifs ou passifs. Les radars doivent alors mettre en place des modes spécifiques (mode émission, séquençement et paramètres des pincesaux, traitement du signal et des données, pistage), adaptés à l'environnement rencontré. Ces opérations nécessitent la présence d'un opérateur radar expérimenté, chargé de choisir par secteur azimutal, le mode de fonctionnement du radar, qu'il considère adapté, selon l'expertise qu'il fait de la visualisation présente de la vidéo du PPI, et de son impression globale sur le fonctionnement du radar au travers du pistage des plots extraits. Les modes qu'il utilise ont

## Segmentation spatio-temporelle

été préalablement établis par des experts qui les ont construits au regard d'une définition synthétique des différentes situations envisageables. L'opérateur doit également gérer les missions qui lui sont attribuées par des centres opérationnels, qui possèdent une connaissance du contexte général d'un pays ou d'une région. Nous allons voir que notre approche permet de suppléer à l'opérateur humain dans sa fonction d'analyse/synthèse de l'environnement avec une précision plus fine et une possibilité d'estimation d'évolutions des phénomènes rencontrés.

Une autre problématique radar concerne la gestion des flux du trafic aérien civil, qui ne peut être optimisée en temps réel que par un routage des aéronefs en fonction des conditions météorologiques présentes et leurs estimations d'évolution à court terme (de 20 minutes à 1 heure). Pour optimiser les flux et augmenter la sécurité des vols, il serait souhaitable de pouvoir prévoir des routes, pour éviter les phénomènes météorologiques sévères, de façon concertée entre les pilotes et les centres de gestion des flux aériens. En effet, ces phénomènes diminuent la sécurité des vols (foudre, turbulences, givre, visibilité limitée, arrêt du moteur par ingestion massive d'eau de pluie) et, du fait du déroutage autonome des avions par leur commandant, ils induisent un engorgement du trafic par les retards qu'ils occasionnent, sans parler des problèmes d'accrochage dont ils augmentent le risque.

Nous ne développerons dans la suite que la première problématique concernant l'analyse/synthèse de l'environnement fouillis pour l'optimisation de la gestion radar.

### 1.1. radar intelligent

Une approche systémique du radar intelligent [1] synthétise le problème en une autorégulation d'un système complexe, immergé dans un environnement contraignant, et qui doit s'adapter en gérant l'accomplissement synchrone (à l'échelle de temps du radar) d'objectifs endogènes (objectifs tactiques : améliorer l'état interne du radar, améliorer le ratio signal sur bruit ou Pd sur Pfa, ...) aux regard d'objectifs exogènes (objectifs stratégiques : missions synthétiques fournies par les centres multisenseurs : veille, désignation de zones d'intérêt, stratégie CCME, évaluation de l'environnement ou des cibles, mesures de performances, ...) conditionnant l'évolution diachrone (à l'échelle de temps des centres opérationnels) du système. En terme de radariste, rendre le radar intelligent (latin intelligere : comprendre, faculté de connaître, de comprendre et de s'adapter facilement), c'est à la fois suppléer l'opérateur dans son rôle d'analyse globale de l'environnement radar et intégrer dans le fonctionnement du système la capacité d'expertise décisionnelle du spécialiste de la construction des modes radar. Un radar intelligent perçoit (analyse de l'environnement), interprète (synthèse de l'environnement), réfléchit (construction d'un mode radar), agit (mise en oeuvre du mode), apprend à court terme (création de nouvelles lois de fonctionnement) et devra dans l'avenir adapter sa stratégie (ensemble de décisions

prises en fonction d'hypothèses de comportement de l'adversaire dans une conjoncture déterminée).

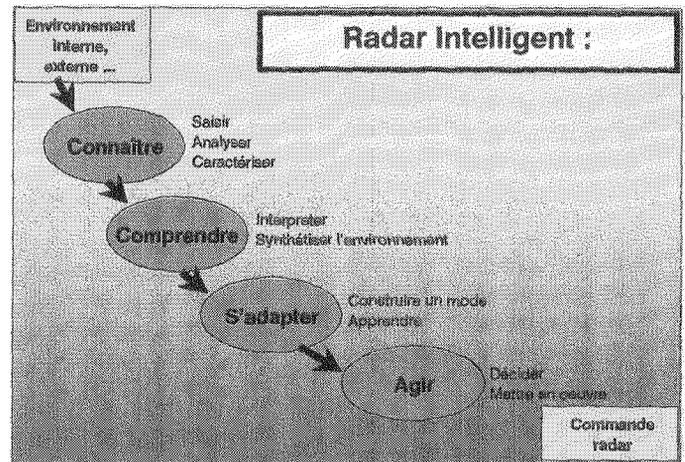


Figure 1. – Schéma de l'approche systémique du radar.

### 1.2. analyse / synthèse de l'environnement radar

Notre problématique se ramène à deux problématiques de base : saisir la situation pour mieux la connaître (l'observation) et modifier la situation pour mieux se rapprocher des objectifs (l'intervention). Notre propos, dans ces pages, est d'étudier le premier module : l'observation de l'environnement radar.

Ce module demande de traiter, en premier lieu, l'information à une échelle qui permette de mesurer les corrélations spatio-temporelles des phénomènes rencontrés. Aussi, les données analysées ne le sont pas à la résolution de la case-distance du radar mais à une résolution plus grossière. Sur ces séquences d'images descriptives du fouillis, nous classifions dynamiquement les fouillis selon leurs types (sol, mer, nuages, ...). Pour ce faire, nous utilisons trois types d'informations : le mouvement des fouillis dans les images, les caractéristiques spatiales des fouillis et les caractéristiques Doppler des fouillis. La première étape consiste à segmenter les fouillis en deux classes distinctes : fouillis dynamiques (possédant un mouvement spatial cohérent) et fouillis statiques (stationnaires spatialement). Dans chaque élément des classes « fouillis dynamiques » et « fouillis statiques », on effectue à la suite une segmentation spatiale statistique pour différencier les fouillis homogènes spatialement. Il reste alors à classifier par types de fouillis.

Pour ce faire, on utilise les informations doppler brutes, délivrées par case distance, prélevées dans chaque élément homogène de fouillis. Possédant la classification des fouillis en fonction de leur comportement dynamique, l'information Doppler déduite des données brutes correspondantes va nous permettre de classifier les différents types de fouillis dynamiques (nuages, orages, ...) et

de fouillis statiques (sol, mer, infrastructures, ...). L'information Doppler synthétique doit être une représentation des échantillons bruts dans un espace de paramètres exploitables par des méthodes d'analyse de données (ex : espace engendré par les valeurs propres complexes de la matrice autocorrélation, les coefficients de réflexion normalisés, les coefficients cepstraux, les paramètres du modèle autorégressif, ...).

Une fois chaque élément de fouillis étiqueté, il s'agit de suivre dynamiquement ces fouillis pour conserver leur étiquette et les valider temporellement, et pour pouvoir prévoir leur évolution spatiale à court terme pour les fouillis dynamiques. Pour ce faire, on peut utiliser deux approches différentes : une approche par contours actifs et filtrage de Kalman et une approche par modèles de déformations hiérarchiques. Cette connaissance synthétique de l'environnement radar (fouillis segmentés et étiquetés dynamiquement) permet d'envisager une commande adaptative du radar, et elle permet également, pour les fouillis dynamiques, d'estimer l'évolution spatiale à court terme (application par les centres opérationnels pour une exploitation de gestion des missions et des risques).

Dans le chapitre 2, nous allons détailler chacune des techniques constituant la segmentation spatio-temporelle des fouillis (segmentation statistique spatio-temporelle, segmentation statistique spatiale et la classification doppler).

Le chapitre 3 traitera des deux méthodes envisagées pour le suivi dynamique des fouillis radar (contours actifs et filtrage de Kalman ou modèle hiérarchique de déformation).

## 2. segmentation spatio-temporelle des fouillis

L'information la plus pertinente dans une première étape de classification des fouillis, consiste à différencier les fouillis dynamiques des fouillis statiques sur une séquence d'images fouillis. Les classes, par rapport au mouvement, étant établies, on segmente en sous classes les fouillis en fonction de leur homogénéité spatiale. Enfin dans chaque zone homogène spatialement, et identifiée « dynamique » ou « statique », on prélève des échantillons doppler bruts, pour caractériser son comportement doppler moyen. Par cette dernière analyse, on attribue à chaque élément de fouillis une étiquette : « atmosphérique sévère » ou « atmosphérique moyen » pour les fouillis dynamiques et « sol » ou « mer » pour les fouillis statiques.

### 2.1. segmentation statistique des fouillis mobiles

La segmentation spatio-temporelle que nous avons utilisée s'inscrit dans un cadre statistique unifié par une approche marko-

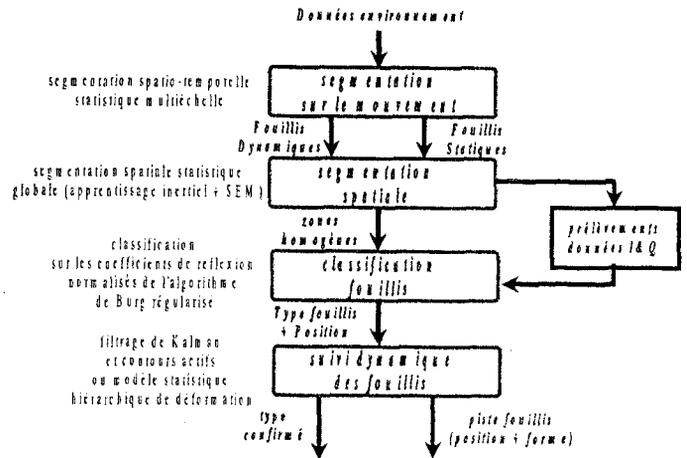


Figure 2. – Algorithme de l'analyse de l'environnement radar.

viennne : modélisation statistique de l'image dynamique basée sur des modèles multiéchelles. L'algorithme utilisé pour les fouillis radar a été développé à l'INRIA par P. Perez et F. Heitz [2][3]. Leur méthode appréhende le problème de la segmentation spatio-temporelle par une approche stochastique, sur l'hypothèse de base que l'observation peut être modélisée par un champ de Markov aléatoire gaussien. Ceci permet d'appliquer le théorème de Hammersley-Clifford et de ramener l'estimation du Maximum A Posteriori (MAP) à une détermination de minimum d'énergie. Cette énergie s'exprime en fonction de potentiels, dont le choix permet de conférer des propriétés *a priori* sur le champs d'étiquettes (2 étiquettes : 0 pour les fouillis statiques et 1 pour les fouillis dynamiques, ou champs d'étiquettes en fonction du vecteur déplacement). Le problème est étendu au cas multigrille du calcul de la fonction d'énergie globale, et est résolu par une stratégie pyramidale multiéchelle descendante associée à un algorithme de relaxation déterministe ICM (Iterative Conditional Mode), qui est une approximation du MAP.

Le critère d'optimisation est donc celui du Maximum A Posteriori (MAP) :

$$\hat{e} = \arg \max_e [p(E = e/O = o)]$$

avec  $e$  : étiquette ( $e = 0$  : objet statistique;  $e = 1$  : objet mobile) et  $o$  : observation.

Le théorème de Hammersley et Clifford (hypothèse que  $(E, O)$  forment un champ de Markov) nous permettent d'affirmer que la probabilité conjointe s'écrit :

$$\begin{cases} p(e, o) = \frac{1}{Z} \cdot e^{-U(e, o)} \\ U(e, o) = \sum_{c \in C} V_c(e, o) \\ Z = \sum_{(e, o)} e^{-U(e, o)} \end{cases}$$

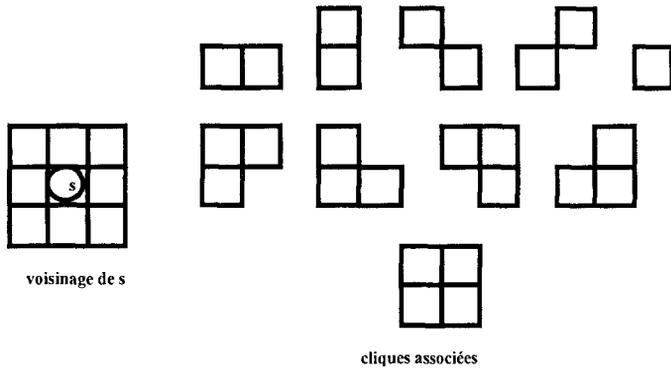
avec :

- $C$  : ensemble des cliques associées au système de voisinage  $G$
- $c$  : cliques sous-ensembles de sites mutuellement voisins

## Segmentation spatio-temporelle

- $V_c$  : fonction de potentiel localement définie sur la clique  $c$  (exprime les interactions locales entre les différentes variables de la clique)

Exemple : cliques pour un voisinage d'ordre 2 :



Le théorème de Bayes permet alors d'écrire :

$$\begin{aligned} \hat{e} &= \arg \max_e [p(e/o)] = \arg \max_e \left[ \frac{p(e, o)}{p(o)} \right] \\ &= \arg \min_e [U(e, o)] \\ &= \arg \min_e [U_1(e, o) + U_2(e)] \end{aligned}$$

Pour notre application, la détection de mouvement repose sur l'analyse des variations de la fonction de luminance entre les instants  $t - dt$  et  $t$  sur l'image de fouillis. Les observations seront les valeurs absolues des différences inter-images :

$$\bar{o}_t = \|I_t(s) - I_{t-dt}(s)\|, s \text{ étant un pixel.}$$

A ces observations quantitatives sont ajoutées des observations symboliques binaires :

$$\bar{o}_t(s) \in \{0, 1\}$$

Celles-ci indiquent la présence ou l'absence de variations significatives de luminance au site  $s$  entre les instants  $t - dt$  et  $t$ . Elles sont obtenues par un détecteur de changement, simple seuillage de la différence de luminance sur une fenêtre  $A$  de taille  $n$  donnée. On peut décomposer l'énergie globale en trois termes :

$$U(e_t, o_t, o_{t+dt}, \bar{o}_t, \overline{o_{t+dt}}) = U_{11}(e_t, o_t, o_{t+dt}) + U_{12}(e_t, \bar{o}_t, \overline{o_{t+dt}}) + U_2(e_t)$$

L'énergie  $U_2$  correspond à une énergie de voisinage, et se décompose en somme de potentiels sur les cliques  $C$  engendrées par un système de 8 - connexité.

$$U_2(e_t) = \sum_{o \in C} V_c(e_t)$$

Le choix de potentiels permet de conférer des propriétés *a priori* sur le champ d'étiquettes. Dans cette application, nous

recherchons des masques de mouvement compacts, à l'image des objets mobiles dont ils sont la projection dans le plan image. On attribue pour cela un potentiel non nul aux seules cliques binaires. Il s'agit d'un potentiel à deux niveaux, indépendant de l'orientation des cliques :

$$U_1(e_t, o_t, o_{t+dt}, \bar{o}_t, \overline{o_{t+dt}}) = U_{11}(e_t, o_t, o_{t+dt}) + U_{12}(e_t, \bar{o}_t, \overline{o_{t+dt}})$$

$U_{11}$  exprime le lien entre les variations temporelles de luminance et les étiquettes.  $U_{12}$  permet d'éviter la prise en compte des zones d'occlusion aux bords des masques.

Dans la version multiéchelle, on introduit des coefficients de pondération de l'énergie de voisinage permettant de prendre en compte le niveau de résolution auquel on se trouve. L'énergie de voisinage à l'échelle  $i$  sera donnée par :

$$U_2^i = \sum_{o \in C} V_c^i(e_t^i)$$

où un système de 8 - connexité est considéré. Pour les autres énergies :

$$U_{11}^i(e_t^i, o_t, o_{t+dt}) \quad \text{et} \quad U_{12}^i(e_t^i, \bar{o}_t, \overline{o_{t+dt}})$$

et on profite de toute l'information disponible, c'est-à-dire au niveau de résolution le plus fin.

De cette segmentation spatio-temporelle statistique multiéchelle des fouillis, on isole les fouillis dynamiques des fouillis statiques. Cet algorithme a été parallélisé [4][5] et implanté sur une machine parallèle THOMSON-CSF AIRSYS : CAMARO (machine MIMD).

## 2.2. segmentation statistique spatiale

Avant de classifier les fouillis par type sur leurs caractéristiques doppler, on les segmente spatialement par une méthode statistique [6][7][8][9]. Nous avons utilisé la segmentation spatiale statistique globale par champs de Markov et son extension au cas flou : la segmentation contextuelle statistique floue. L'approche statistique, contrairement à l'approche par texture, n'utilise qu'un seul attribut (la valeur du pixel) et s'attache à modéliser des lois qui vont régir le regroupement des pixels. Ces lois sont paramétrées et la classification non-supervisée des pixels s'effectue en deux temps : estimation des paramètres puis segmentation. Dans notre application, l'estimation des paramètres est effectuée par une estimation du type SEM (Stochastic Estimation of the Maximum) et la segmentation globale détermine pour chaque site, la classe la plus probable conditionnellement à l'observation de l'image globale. L'algorithme SEM part de paramètres de modèle grossiers (voire quelconques) et à partir de ceux-ci, associe chaque observation à une classe par tirage aléatoire selon la loi conditionnelle à l'observation, dite loi *a posteriori*. En calculant les paramètres sur les observations de ces nouvelles classes, on affine les paramètres du

modèle et en répétant itérativement ces opérations, on affine conjointement la répartition des échantillons en classes en maximisant la vraisemblance à chaque étape. Les études actuelles, dans ce domaine, tentent d'intégrer une reconnaissance automatique des lois statistiques paramétrées présentes dans l'image, grâce à l'utilisation de tests statistiques adaptés [31]. On peut également étendre cette méthode aux statistiques d'ordre supérieur.

### 2.3. classification doppler

Chaque élément de fouillis de mouvement « dynamique » ou « statique » et de répartition spatiale homogène est analysé par un prélèvement d'informations doppler brutes. Différents types de paramètres caractéristiques peuvent être calculés pour analyser le comportement doppler du fouillis à l'échelle de la case-distance : les valeurs propres complexes de la matrice d'autocorrélation, les coefficients de réflexion normalisés, les coefficients cepstraux, les paramètres du modèle autorégressif... Ces paramètres, étant donné le faible nombre d'échantillons dans la rafale représentative de la case distance, ont été calculés par un algorithme de Burg régularisé [10] pour réduire les fluctuations d'origines diverses (identification de l'ordre du modèle : inconsistance des tests statistiques sur peu d'échantillons, bruit de calcul, propagation d'erreur, ...). L'étude statistique (et segmentation par l'algorithme des C-moyennes floues [11]) de ces paramètres permet de déterminer des seuils sur leur variation d'amplitude pour déterminer le type du fouillis et l'étiqueter en fonction de ses caractéristiques doppler, qui sont à rapprocher du phénomène physique étudié.

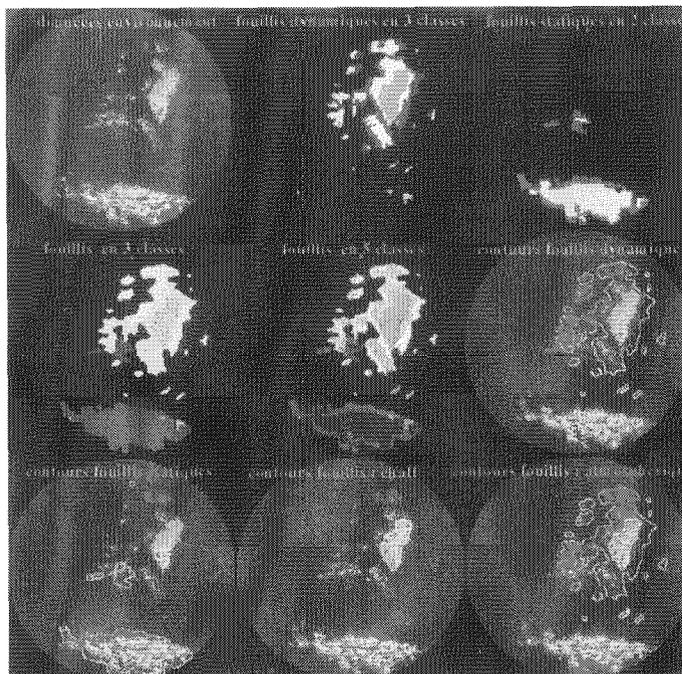


Figure 3. – Résultats de segmentation spatio-temporelle.

Ces images proviennent du PAC (Processeur Anti Clutter). Le PAC fait apparaître différents fouillis : fouillis de type statique (Pyrénées en bas et fouillis de sol proche au centre) et différents fouillis de type dynamique (fouillis atmosphériques). Les images successives montrent les résultats de la segmentation spatio-temporelle et spatiale. Les dernières images représentent les contours issus de la segmentation superposés à l'image de PAC.

## 3. suivi dynamique des fouillis

Une fois que les fouillis ont été étiquetés et identifiés en tant que fouillis dynamiques ou statiques, il faut pouvoir les suivre dynamiquement et que leur classification par type s'actualise automatiquement. Le suivi dynamique des fouillis permet également une confirmation dans le temps de la classe du fouillis en réitérant l'analyse doppler sur des échantillons et en pondérant ces résultats dans le temps. Le dernier avantage du suivi dynamique des fouillis réside dans la possibilité de prévoir à court terme leur évolution (déplacement et déformations), ce qui constitue une information très intéressante pour les centres opérationnels, qui peuvent l'exploiter pour gérer les missions et les risques.

Le problème consiste à segmenter des fouillis homogènes au sens du mouvement mais dont les contours peuvent subir des déformations. On se ramène au suivi d'objets déformables 2D. Il existe alors deux grandes familles d'algorithmes pour résoudre cette question : l'approche contours actifs et filtrage de Kalman et l'approche par modèles hiérarchique de déformation.

### 3.1. contours actifs et filtrage de Kalman

Le but de cette partie de l'étude est de proposer un algorithme capable d'effectuer le suivi d'objets déformables dans une séquence d'images radar. Nous avons choisi d'appliquer une première méthode fondée sur les contours actifs et le filtrage de Kalman, inspirée des travaux réalisés à l'INRIA par C. Labit et L. Bonnaud [18]. La méthode des contours actifs repose sur la représentation des contours par des courbes fermées. A partir d'un contour initial (qui est une approximation de la solution), cette méthode permet d'extraire rapidement les contours exacts de l'objet. Le filtrage de Kalman permettra quant à lui de prévoir la position et la forme de l'objet que l'on doit suivre. Ces deux méthodes combinées vont nous permettre de pister des objets mobiles dont la forme varie le long d'une séquence d'images.

#### 3.1.1. modèle de mouvement

Afin de modéliser le mouvement des fouillis, nous avons choisi d'utiliser un modèle affine simplifié. Le déplacement d'un objet

## Segmentation spatio-temporelle

sera décrit comme suit :

$$\vec{d} = \begin{pmatrix} x \\ y \end{pmatrix} = \begin{pmatrix} t_x \\ t_y \end{pmatrix} + \begin{vmatrix} k & -\theta \\ \theta & k \end{vmatrix} \cdot \begin{pmatrix} x - x_g \\ y - y_g \end{pmatrix}$$

$(x_g, y_g)$  étant les coordonnées du barycentre de la région dont on détermine le mouvement.

On a donc un modèle à 4 paramètres  $t_x, t_y, \theta, k$ , qui permet une description de mouvements tels que des translations, des rotations et des grossissements. Ce modèle permet de décrire une classe assez large de mouvements, il représente un bon compromis entre fidélité et simplicité.

### 3.1.2. algorithme de suivi

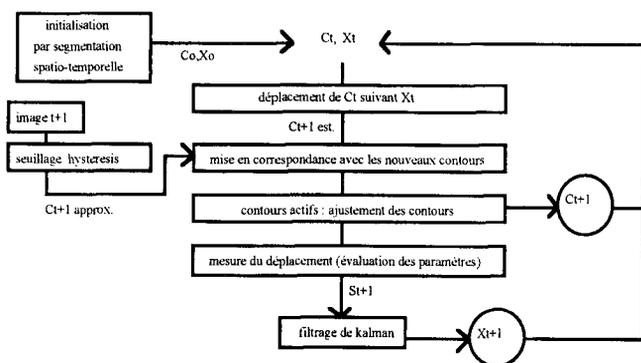


Figure 4. – Algorithme de suivi.

Le but de cet algorithme est de pister des fouillis en mouvement. On associe donc naturellement un vecteur  $x_t$  de paramètres de mouvement (translation, dilatation, rotation) à chaque fouillis dynamique. Une segmentation spatio-temporelle multi-résolution appliquée aux trois premières images fournit les masques des fouillis en mouvement dans la deuxième et la troisième image. Par association des objets de ces deux masques binaires, on détermine une mesure initiale du déplacement de chaque fouillis dynamique. On la note  $x_0$ . On utilise cette mesure pour initialiser les paramètres de mouvement de chaque objet. Dans la suite, afin de simplifier, on va décrire le principe de fonctionnement pour un fouillis donné.

Au début de l'étape  $t + 1$ , on dispose du contour  $C_t$  du fouillis dans l'image précédente et d'une estimation de ses paramètres de mouvement, notée  $x_{t+1/t}$  (vecteur estimé à  $t + 1$ , connaissant  $t$ ). Si on déplace  $C_t$  de  $x_{t+1/t}$ , on obtient un contour estimé  $C_{t+1est}$  de l'objet dans l'image  $t + 1$ . Par simple seuillage par hystérésis on détermine alors une image binaire approximative des objets de l'image  $t + 1$  et leurs contours  $C_{t+1approx}$ . Par mise en correspondance de  $C_{t+1approx}$  et de  $C_{t+1est}$  on réajuste la position du contour estimé sur sa réelle position. Le contour actif va permettre de recalculer  $C_{t+1est}$  sur les contours exacts du fouillis. On dispose alors de  $C_{t+1}$ . Reste à mesurer le vecteur déplacement entre  $C_{t+1}$  et  $C_t$ . Cette mesure alimente le filtre de

Kalman qui peut alors fournir une estimation du vecteur  $x_{t+2/t+1}$  déplacement. Ces trois dernières phases de l'algorithme sont décrites dans les chapitres suivants.

### 3.1.3. contours actifs

Les contours d'une image sont caractérisés par les points où la norme du gradient a une valeur élevée. On peut déterminer les contours d'un objet par seuillage de la norme du gradient. Le choix du seuil pose alors un problème : un seuil bas entraînera un grand nombre de points détectés non-représentatifs des contours (bruit, contours secondaires), un seuil haut donnera des contours morcelés...

La méthode des contours actifs présente une solution intéressante au problème de détermination des contours d'un objet donné. Nous allons nous intéresser au modèle présenté initialement par Kass *et al* [12] sous le nom de *snake* et qui se base sur la représentation des contours par des courbes régulières. On obtient alors une caractérisation forte des contours de l'objet.

#### Formalisme mathématique

Un snake  $v$  se définit de façon générale comme une courbe paramétrée :

$$\Omega = [0, 1] \rightarrow \mathbf{IR}^2$$

$$v \mapsto v(s) = (x(s), y(s))$$

Ces courbes devront caractériser les points de contour de l'image. Cette caractérisation s'obtient par minimisation d'une fonctionnelle dont la définition est étroitement liée aux points de contours. Ainsi, en notant  $I(i, j)$  le niveau de gris de l'image au pixel  $(i, j)$ , la fonctionnelle caractérisant les points de contour est :

$$E_{contour} = - \int |\nabla I(i, y)|$$

La minimisation de cette fonctionnelle caractérisera les points dont la norme du gradient est maximale, ce qui est la définition même des points de contour. Mais la définition du modèle à partir de cette seule fonctionnelle serait trop dépendante du calcul du gradient de l'image, celui-ci étant très sensible à la présence de bruit dans l'image. On va donc restreindre l'ensemble des courbes minimisant la fonctionnelle  $E_{contour}$  en contraignant la solution à posséder une certaine régularité. On cherche donc à minimiser la fonctionnelle :

$$E(v) = \frac{1}{2} \int_{\Omega} w_1(s) \left( \frac{\partial v}{\partial s} \right)^2 + w_2(s) \left( \frac{\partial^2 v}{\partial s^2} \right)^2 ds + \int_{\Omega} P(v) ds$$

où  $P = -|\nabla I|^2$ . Un minimum de  $E$  représente un compromis entre régularité de la courbe et localisation des points de contour. En faisant l'analogie entre  $E$  et l'énergie de déformation d'un matériau élastique, on peut donner une interprétation des termes  $w_1$  et  $w_2$ . Le premier représente la résistance de la courbe à l'élongation et le second sa résistance à la flexion.

**Programmation dynamique**

L'approche par programmation dynamique a été formalisée par le mathématicien américain Richard Bellman dans les années 50 : on lui doit l'énoncé du principe d'optimalité :

Principe d'optimalité de Bellman

« Une politique optimale a la propriété qu'à un instant donné, quelles que soient les décisions précédentes, les décisions qui restent à prendre constituent la politique optimale pour l'état résultant des décisions précédentes. »

La programmation dynamique s'appuie sur cette propriété et permet de simplifier les problèmes dans lesquels l'optimisation résulte d'une suite de décisions (processus de décisions à étapes).

On définit  $(\nu_i)_{i \in [0, n-1]}$  les points du snake.

La formulation de l'énergie que le snake doit minimiser, une fois discrétisée, est la suivante :

$$E(\nu) = \sum_{i=0}^{n-1} E_{int}(\nu_i) + E_{ext}(\nu_i)$$

avec

$$E_{int}(\nu_i) = \frac{(w_1 |\nu_i - \nu_{i-1}|^2 + w_2 |\nu_{i+1} - 2\nu_i + \nu_{i-1}|^2)}{2}$$

et  $E_{ext}(\nu_i)$  définie par la valeur du gradient de l'image au point  $\nu_i$ .

Chaque  $\nu_i$  peut prendre 9 positions (figure 5) et on a un snake de  $n$  points. La minimisation pourrait être accomplie par calcul de toutes les combinaisons des positions des  $(\nu_i)$ , soient  $9^n$  possibilités. La programmation dynamique fournit une solution beaucoup plus optimale.

Nous remarquons que la minimisation de  $E(\nu)$  peut être vue comme un processus de décisions à  $n$  étapes. Partant du premier point du contour, le problème de la minimisation peut être ramené au choix d'une décision parmi un ensemble fini de 9 décisions possibles à chacune des étapes d'un ensemble fini d'étapes  $(i_0, i_1, \dots, i_{n-1})$ .

On fait l'analogie avec le problème suivant :

$$E_{totale} = E_1(\nu_1, \nu_2, \nu_3) + \dots + E_{n-2}(\nu_{n-2}, \nu_{n-1}, \nu_n)$$

où

$$E_{i-1}(\nu_{i-1}, \nu_i, \nu_{i+1}) = E_{ext}(\nu_i) + E_{int}(\nu_{i-1}, \nu_i, \nu_{i+1})$$

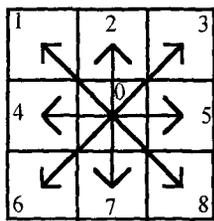


Figure 5. - Déplacements possibles en 8 connexités.

On définit les fonctions  $s_i(\nu_{i+1}, \nu_{i+2})$ , la minimisation s'effectue en trois phases :

$$s_1(\nu_2, \nu_3) = \min_{\nu_1} E_1(\nu_1, \nu_2, \nu_3) \tag{1}$$

$$s_i(\nu_{i+1}, \nu_i) = \min_{\nu_{i-1}} s_{i-1}(\nu_i, \nu_{i-1}) + E_{i-1}(\nu_{i+1}, \nu_i, \nu_{i-1}) \tag{2}$$

$$\min_{\nu_1, \dots, \nu_n} E(\nu_1, \dots, \nu_n) = \min_{\nu_n, \nu_{n-1}} s_{n-2}(\nu_n, \nu_{n-1}) + E_{n-2}(\nu_{n-2}, \nu_{n-1}, \nu_n) \tag{3}$$

Pour tout les couples  $(\nu_2, \nu_3)$  (81 possibilités), on trouve  $\nu_1$  tel que  $E_1$  soit minimale. Cette position de  $\nu_1$  est conservée ainsi que la valeur de l'énergie correspondante qui donne la valeur de  $s_1(\nu_2, \nu_3)$ . Ainsi si on connaît les positions de  $\nu_2$  et de  $\nu_3$ , qui donnent une valeur minimale, la position de  $\nu_1$  est imposée. Ensuite, on propage l'algorithme (phase (2)). La terminaison (phase (3)) permet de déterminer les positions de  $\nu_{n-1}$  et de  $\nu_n$  qui minimisent l'énergie totale. On est alors en mesure de déterminer le contour de minimum d'énergie par propagation rétrograde, la position de  $\nu_n$  et de  $\nu_{n-1}$  imposant celle de  $\nu_{n-2}$  et ainsi de suite.

**Amélioration du modèle**

Dans la pratique on fournit à l'algorithme un contour initial qui constitue une approximation grossière du contour à déterminer et ce contour va se caler sur les gradients de l'image en conservant une forme assez régulière. Pour rendre l'algorithme moins sensible à l'initialisation, nous avons utilisé un modèle ballon. Le snake se déplace déjà sous l'action d'une force qui l'attire vers les contours de l'objet (dérivée de  $E_{ext}$ ) et de deux forces régularisantes (dérivées de  $E_{int}$ ). Nous ajoutons une force d'expansion qui va faire gonfler le contour [14]. Cette force est portée par les normales sortantes du snake. Elle permet, quand l'initialisation du snake est à l'intérieur de l'objet dont on veut détecter les contours, d'éviter que le snake ne se recroqueville sur lui-même.

La convolution avec un filtre gaussien permet d'élargir le champ d'attraction des points de fort gradient.

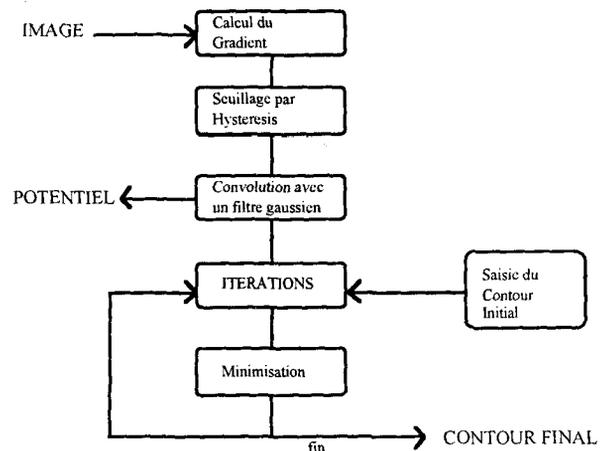


Figure 6. - Algorithme de contour actifs.

On peut faire également la remarque que chaque point du snake, comme nous l'avons vu précédemment, ne peut se déplacer que d'un point par itération. Par conséquent, plus le contour initial est loin de la solution désirée et plus l'algorithme sera long à converger.

Résultats

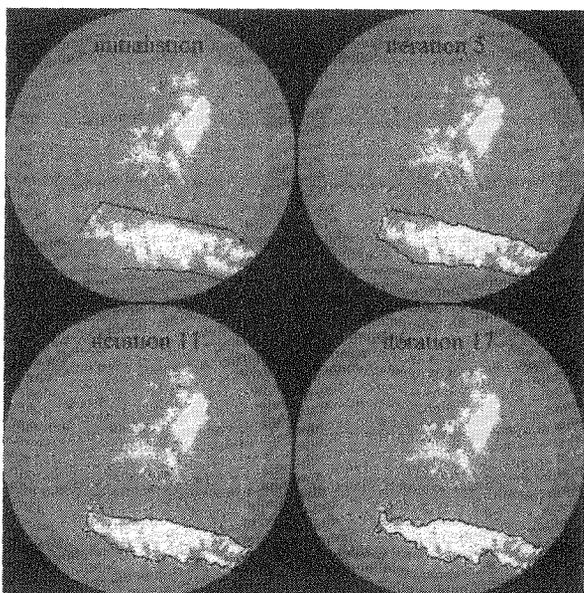


Figure 7. – Contours actifs à différentes itérations.

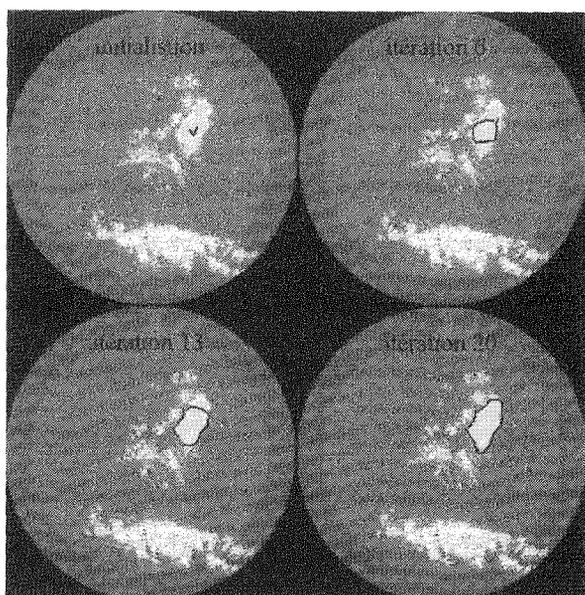


Figure 8. – Illustration du modèle ballon.

On lance l'algorithme de contours actifs sur une image PAC. Dans le premier cas, le contour initial est donné autour du fouillis correspondant aux Pyrénées. La convergence est obtenue en 90 secondes. Les contours obtenus sont assez fidèles aux contours

irréguliers du fouillis. On peut remarquer un bon comportement malgré une initialisation assez éloignée du contour recherché.

Sur le second exemple, on donne une initialisation à l'intérieure du contour recherché. Ce cas illustre l'effet du modèle ballon. L'initialisation est très grossière et ne contient que trois points. La convergence est obtenue en 30 secondes (le nombre de points à traiter est inférieur à celui du premier cas). Le fouillis dont on détermine les contours est un fouillis mobile. Il correspond à un fouillis atmosphérique intense. C'est celui que nous allons pister grâce à l'algorithme de suivi dans la suite de l'étude. On remarque que ce fouillis étant très homogène, il ne contient pas de contours parasites. Il est donc intéressant de donner une initialisation à l'intérieure de ses contours car une initialisation externe amènerait le snake à être attiré par des contours de petits nuages secondaires ou par des contours dus au bruit.

3.1.4. mesure du déplacement

La mesure du déplacement entre  $C_{t+1}$  et  $C_t$  sera réalisée par estimation des paramètres  $(t_x, t_y, \theta, k)$ . La translation correspond au déplacement du centre de gravité entre les deux contours. Le déplacement dû aux contours actifs (correspondant essentiellement aux modifications de la forme, c'est-à-dire rotation  $\theta$  et divergence  $k$ ) n'a aucune raison de s'inscrire dans le modèle de mouvement que nous avons choisi. Nous avons utilisé l'algorithme de Métropolis [23] qui permet d'estimer  $k$  et  $\theta$ . Le principe en est simple : on fait subir à  $C_t$  des rotations et des grossissements de valeurs aléatoires jusqu'à obtenir une bonne approximation de  $C_{t+1}$ . On dispose alors d'une estimation de  $k$  et  $\theta$ .

3.1.5. filtrage de Kalman

Le filtrage de Kalman est fondé sur la représentation d'un système par un vecteur d'état. Le but du filtrage est de prédire l'état du système à partir de mesures bruitées.

Le modèle mathématique du système est donné par l'équation différentielle suivante :

$$x_{t+1} = A_t x_t + w_t \quad \text{Dynamique bruitée du système}$$

L'état de ce système est observé par des mesures liées à l'état  $x_t$  par l'équation :

$$s_t = H_t x_t + \nu_t \quad \text{Mesures bruitées}$$

On a en outre :

- $E[\nu_t] = 0$
- $E[w_t] = 0$
- $E[\nu_{t_1} \nu_{t_2}^T] = R \delta_{t_1 t_2}$   $R$  étant la matrice de bruit de mesure
- $E[w_{t_1} w_{t_2}^T] = Q \delta_{t_1 t_2}$   $Q$  étant la matrice de bruit de modèle
- $E[\nu_t w_t^T] = 0$

Nous avons choisi de filtrer les paramètres de mouvement. Notre vecteur d'état est donc :

$$x_t = \left[ t_x \quad t_y \quad \theta \quad k \quad \frac{dt_x}{dt} \quad \frac{dt_y}{dt} \quad \frac{d\theta}{dt} \quad \frac{dk}{dt} \right]^T$$

On considère que seuls les paramètres de mouvement sont observables. On a donc une matrice d'observation  $H$  :

$$H = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \end{pmatrix}$$

On considère en outre que les dérivées secondes des paramètres sont des bruits blancs.

La matrice  $A$  est constante et vaut :

$$A = \begin{pmatrix} 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{pmatrix}$$

L'estimée de  $x_t$  connaissant  $s_1, \dots, s_t$  sera noté  $x_{t/t}$  et la matrice de covariance de l'erreur d'estimation à l'instant  $k$  sera noté  $P_{t/t}$ .

$$x_{t/t} = E[x_t / s_1 \dots s_t]$$

$$P_{t/t} = E[(x_t - x_{t/t})(x_t - x_{t/t})^T / s_1 \dots s_t]$$

De même, on notera :

$$x_{t+1/t} = E[x_{t+1} / s_1 \dots s_t]$$

$$P_{t+1/t} = E[(x_{t+1} - x_{t+1/t})(x_{t+1} - x_{t+1/t})^T / s_1 \dots s_t]$$

et enfin

$$x_{t+1/t+1} = E[x_{t+1} / s_1 \dots s_{t+1}]$$

$$P_{t+1/t+1} = E[(x_{t+1} - x_{t+1/t+1})(x_{t+1} - x_{t+1/t+1})^T / s_1 \dots s_{t+1}]$$

Les équations de Kalman sont les suivantes :

$$\begin{cases} K_t = P_{t/t-1} H^T (R + H P_{t/t-1} H^T)^{-1} \\ x_{t/t} = x_{t/t-1} + K_t (s_t - H x_{t/t-1}) \\ P_{t/t} (I - K_t H) P_{t/t-1} \\ \\ \begin{cases} x_{t+1/t} = A x_{t/t} \\ P_{t+1/t} = A P_{t/t} A^T + Q \end{cases} \end{cases}$$

Les trois premières équations constituent les équations de filtrage et les deux dernières, les équations de prédiction.  $K_t$  est appelé gain de Kalman. On remarque qu'il pondère la différence entre la valeur mesurée à l'instant  $t$  et la valeur estimée (erreur d'estimation).

### 3.1.6. résultats



Figure 9. - Suivi d'un fouillis décomposé en différentes phases.

Cette série de 5 imagerie illustre les différentes étapes du suivi. La première imagerie représente l'image  $t$  d'une séquence d'images radar avec les contours de l'unique objet en mouvement obtenus par l'algorithme de suivi. L'imagerie suivante est l'image  $t+1$  de la séquence. Le but est de déterminer les contours du fouillis mobile dans cette image. Dans l'imagerie 3 on a superposé les contours du fouillis au temps  $t$  avec l'image  $t+1$ . L'imagerie 4 montre cette fois les contours estimés du fouillis mobile. Ils proviennent de la déformations des contours aux temps  $t$  par des paramètres fournis par le filtre de Kalman. On remarque que cette estimation est assez satisfaisante pour la position et l'angle du fouillis. Par contre, le fouillis réel est plus gros que prévu. Les contours actifs sont alors lancés et permettent de compenser cette erreur d'estimation. La mesure du mouvement entre les contours au temps  $t$  et les nouveaux contours va alimenter le filtre de Kalman qui tiendra compte de son erreur pour donner une estimation plus juste au tour précédent. La figure suivante montre le résultat du pistage sur le fouillis mobile tout au long de la séquence d'images.

Malgré l'évolution assez irrégulière du fouillis, ce dernier est bien suivi. On note cependant quelques imperfections sur les contours. Ceci est dû au fait que pour ces images on se limite à 10 itérations de snake et le contour n'a pas le temps de converger. Si on

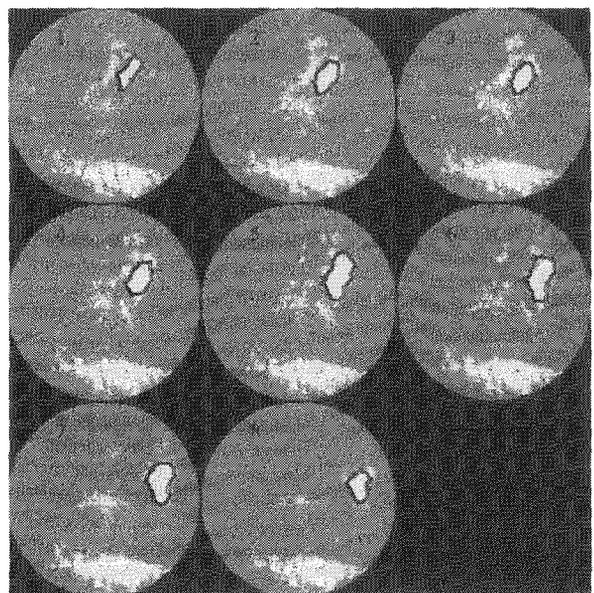


Figure 10. - Illustration du suivi sur 8 images consécutives.

laisse trop de liberté aux contours actifs, la forme du fouillis est beaucoup plus fidèlement détectée, mais les grandes variations de forme rendent la mesure du déplacement difficile et pénalisent la prédiction de Kalman.

### 3.2. suivi de fouillis radar : une approche hiérarchique statistique

La méthode présentée dans cette partie est une adaptation de l'étude menée à l'INRIA par C. Kervrann et F. Heitz [19]. L'approche est statistique hiérarchique et repose sur un modèle déformable.

#### 3.2.1. présentation du modèle

Les modèles déformables sont des modèles mathématiques qui caractérisent les formes et leurs variations. Ces modèles peuvent être utilisés pour l'analyse de divers types d'images, dès lors que l'on doit caractériser, reconstruire ou suivre des objets déformables. Depuis les premiers travaux de Kass, Witkin et Terzopoulos sur les contours actifs (ou snakes), les modèles déformables connaissent un regain d'intérêt. D'abord utilisées pour segmenter des images statiques, les méthodes fondées sur ces modèles sont maintenant adaptées pour le suivi d'images. Une large gamme d'articles a été publiée depuis quelques années, offrant de nombreuses solutions pertinentes.

L'étude menée à l'INRIA par C. Kervrann et F. Heitz dont s'inspire la méthode que nous avons utilisée s'inscrit dans ce mouvement et offre une solution robuste, insensible au bruit et aux occlusions. Cependant les auteurs précisent nettement que cette dernière est destinée au suivi d'objets déformables de types articulés ou élastiques, et non aux fluides. Dans certains cas, une adaptation apparaît nécessaire (cumulonimbus, orages).

Nous utilisons une représentation polygonale de l'objet : le contour est approximé par  $n$  points représentatifs reliés par des segments de droites. La position de ces  $n$  points caractérise donc une configuration particulière de l'objet.

L'approche étant hiérarchique, on répertorie les déformations selon deux classes : les déformations globales qui dégagent grossièrement la forme de l'objet et les déformations locales qui affinent le contour de l'objet de façon précise.

Les déformations globales sont de deux types : des déformations géométriques (translation  $t$ , rotation  $\theta$ , échelle  $k$ ) et des déformations modales qui rendent compte des distorsions spécifiques de

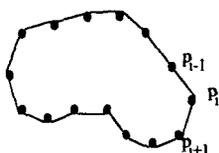


Figure 11. – Représentation polygonale de l'objet.

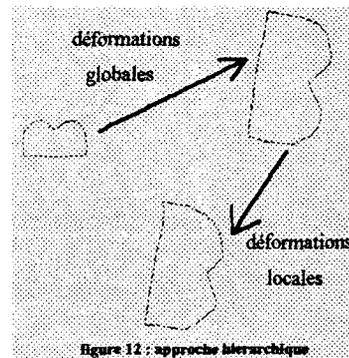


Figure 12. – Approche hiérarchique.

l'objet suivi. Ces déformations modales sont obtenues grâce à une décomposition de Karhunen Loeve sur les distorsions observées dans une population représentative appelée ensemble d'apprentissage.

Chaque forme de l'ensemble d'apprentissage est représentée par un vecteur de  $n$  points étiquetés. Notons  $\mathbf{x}_i$  le vecteur représentant la  $i$ ème forme de l'ensemble d'apprentissage :

$$\mathbf{x}_i = (x_{i1}, y_{i1}, x_{i2}, y_{i2}, \dots, x_{ik}, y_{ik}, \dots, x_{in}, y_{in})^t$$

La forme moyenne  $\mathbf{x}^*$  est alors définie par :

$$\mathbf{x}^* = \frac{1}{N} \sum_{i=1}^N \mathbf{x}_i$$

où  $N$  représente le nombre de formes constituant l'ensemble.

Les variations de forme au sein de l'ensemble d'apprentissage sont caractérisées par les vecteurs déplacement :

$$d\mathbf{x}_i = \mathbf{x}_i - \mathbf{x}^*$$

Pour caractériser les distorsions de l'objet par rapport à la forme moyenne, on est donc obligé de connaître  $2n$  paramètres. Un changement de base habile peut nous permettre de concentrer l'information dans seulement quelques paramètres. La base utilisée est celle de Karhunen Loeve. La matrice de changement de base  $P = (\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_{2n})$  est obtenue par diagonalisation de la matrice de covariance des déplacements (notée  $S$ ). Le vecteur des déplacements  $\mathbf{b}$  dans cette nouvelle base est donné par :

$$\mathbf{b} = P^t d\mathbf{x} = P^t (\mathbf{x} - \mathbf{x}^*)$$

Les vecteurs propres de  $S$  associés aux plus grandes valeurs propres correspondent aux modes de variation les plus significatifs (car les valeurs propres sont en fait les variances des déplacements). Ainsi il est possible de ne retenir que les principaux modes de variations en ne conservant que les  $m$  vecteurs propres les plus significatifs. On obtient :

$$\mathbf{x} = \mathbf{x}^* + P_m \mathbf{b}_m$$

avec

$$P_m = (p_1, p_2, \dots, p_m) \text{ et } b_m = (b_1, b_2, \dots, b_m)^t.$$

En utilisant la transformation de Karhunen Loeve, on a donc la possibilité de représenter une grande partie des distorsions par quelques paramètres de contrôle  $b_1, b_2, \dots, b_m$  (au lieu de  $2n$  dans la base canonique). Généralement, très peu de modes (de 5 à 7) restituent plus de 90% de l'information en termes de distorsion.

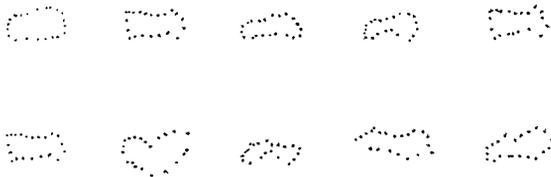


Figure 13. – Ensemble d'apprentissage utilisé.

Par exemple, en utilisant l'ensemble d'apprentissage de la figure 13 lors de la décomposition modale, 6 modes contiennent plus de 95% de l'information pertinente concernant les distorsions observées sur la population représentative.

valeurs propres	$\lambda_k / \sum_{i=1}^N \lambda_i \times 100\%$	$\sum_{i=1}^k \lambda_i / \sum_{i=1}^N \lambda_i \times 100\%$
$\lambda_1 = 671,5$	46,5%	46,5%
$\lambda_2 = 303$	20,9%	67,4%
$\lambda_3 = 196,1$	13,6%	81%
$\lambda_4 = 102,6$	7,1%	88,1%
$\lambda_5 = 70,7$	4,9%	93%
$\lambda_6 = 49,2$	3,4%	96,4%
$\lambda_7 = 25,7$	2,2%	98,2%
$\lambda_8 = 19,8$	1,4%	98,6%
$\lambda_9 = 3,7$	0,2%	99,8%
$\lambda_{10} = 2,6$	0,2%	100%

On peut visualiser l'effet des principaux modes de distorsion en appliquant diverses valeurs de paramètres modaux au prototype moyen. Pour  $-3\sqrt{\lambda_k} \leq b_k \leq 3\sqrt{\lambda_k}$ , on obtient les distorsions représentées dans la figure 14.

Finalement, si on considère l'ensemble des déformations globales (géométriques et modales) appliquées à un prototype initial  $x^*$ , le modèle global  $X^*$  s'écrit :

$$X^* = M(k, \theta)(x^* + Pm b_m) + T$$

Pour compléter le modèle on ajoute des déformations locales  $t$  modélisées par un processus Gauss-Markov de moyenne nulle.

$$X = X^* + t = M(k, \theta)(x^* + Pm b_m) + T + t$$

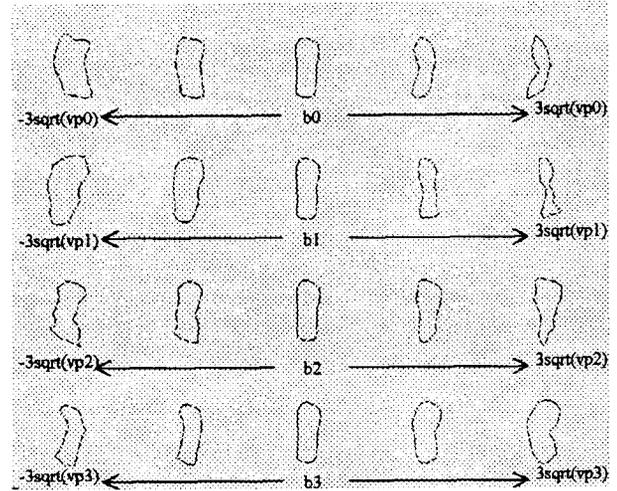


Figure 14. – Effet des principaux modes de distorsions globales.

### 3.2.2. estimation bayésienne

Reste à construire un cadre bayésien en vue de l'estimation des paramètres du modèle  $\lambda = (k, \theta, t_x, t_y, b_1, b_2, \dots, b_m)^t$  et  $t = (t_1, t_2, \dots, t_{2n})^t$ .

L'hypothèse statistique que nous avons émise induit la probabilité a priori suivante :

$$p(X) = \frac{1}{C} \exp -\frac{1}{2}(X - X^*)^t R^{-1}(X - X^*)$$

où  $R$  désigne la matrice de corrélation de  $t$  et  $X = X^* + t$ .

On a donc

$$p(O, X) = p(O/X) \frac{1}{C} \exp -\frac{1}{2}(X - X^*)^t R^{-1}(X - X^*)$$

La dernière étape de l'analyse consiste donc à établir le lien entre les observations et le modèle via la probabilité  $p(O/X)$ .

Cette probabilité a été définie par C. Kervrann et F. Heitz de la façon suivante :

$$p(O/X) = \frac{1}{C'} \exp - \left( \sum_{s \in R^-} |O(s) - 1| + \sum_{s \in R^+} |O(s) - 0| \right)$$

où  $R^-$  désigne l'intérieur du prototype  $X$ ,  $R^+$  l'extérieur et  $O(s)$  l'observation au pixel  $s$ . Idéalement  $O(s) = 1$  si  $s$  appartient à l'objet suivi et  $O(s) = 0$  sinon.

La principale caractérisation d'un nuage d'orage étant sa forte intensité, il apparaît judicieux de n'utiliser qu'un simple seuillage par hystérésis pour déterminer l'observation  $O(s)$ . Les seuils haut et bas sont déterminés de façon heuristique grâce à un échantillon d'images radar. Si l'intensité du nuage orageux diminue au cours du temps, les valeurs des seuils sont modifiées d'une image à la suivante.

### 3.2.3. optimisation

Le critère du Maximum A Posteriori (MAP) peut être utilisé pour estimer la configuration optimale. Dans ce cas, la probabilité *a posteriori*  $p(\mathbf{X}/O)$  proportionnelle au produit  $p(O/\mathbf{X})p(\mathbf{X})$  doit être maximisée :

$$(\mathbf{X}_{opt}, \lambda_{opt}) = \arg \max_{\mathbf{x}, \lambda} p(O/\mathbf{X}) p_{\lambda}(\mathbf{X})$$

Le couple estimé  $(\mathbf{x}_e, \lambda_e)$  vérifiant le critère précédent est le maximum global de  $P(\mathbf{X} = \mathbf{x}, O = o / \lambda)$  en  $(\mathbf{x}, \lambda)$ . Un problème d'estimation simultanée se produit. S. Lakshamanan et H. Derin se sont intéressés à ce cas. Ils ont proposé une solution partiellement optimale fondée sur le critère suivant :

$$\begin{aligned} \mathbf{x}_e &= \arg \max_{\mathbf{x}} p(\mathbf{X} = \mathbf{x}, O = o / \lambda_e) \\ \lambda_e &= \arg \max_{\lambda} p(\mathbf{X} = \mathbf{x}_e, O = o / \lambda) \end{aligned}$$

On introduit une énergie duale de la probabilité à maximiser  $U_{\lambda}(O, \mathbf{X})$  telle que :

$$p(O, \mathbf{X}) = \frac{1}{Z} \exp -U_{\lambda}(O, \mathbf{X})$$

où  $Z$  est la fonction de répartition.

La procédure d'estimation peut ainsi se résumer de la façon suivante :

**Initialisation de la configuration du modèle :  $\mathbf{X}_{opt} = \mathbf{x}$**

**Répéter**

- estimation du paramètre global  $\lambda$  grâce à une relaxation stochastique

$$\lambda_{opt} = \operatorname{argmin}_{\lambda} U_{\lambda}(O, \mathbf{X}_{opt})$$

- estimation de la configuration du modèle  $\mathbf{X}$  grâce à une relaxation déterministe.

$$\mathbf{X}_{opt} = \operatorname{argmin}_{\mathbf{X}=\mathbf{X}^*+\mathbf{t}} U_{\lambda_{opt}}(O, \mathbf{X})$$

**Fin répéter**

L'algorithme utilisé pour la relaxation stochastique est celui de Métropolis, pour la relaxation déterministe l'algorithme ICM (Iterated Conditional Modes) a été implanté.

En combinant de cette manière relaxation déterministe et stochastique, on tire un profit maximum de chaque méthode. En effet, les algorithmes d'optimisation déterministes permettent une convergence rapide, mais sont connus pour leur sensibilité face aux

problèmes de minima locaux. La première phase stochastique permet au modèle de se positionner dans une configuration proche du minimum global d'énergie sans être trop coûteuse en temps de calcul grâce au nombre restreint de paramètres de contrôle. Ainsi elle fournit une bonne initialisation pour la relaxation déterministe. Les  $2n$  paramètres locaux sont alors estimés précisément (la bonne initialisation écarte le problème des minima locaux) et rapidement grâce à la mise en place de l'algorithme ICM.

En pratique, une seule itération dans la boucle d'optimisation suffit.

### 3.2.4. changement de rôle des déformations locales et base récurrente

L'intérêt principal de la méthode réside dans la décomposition modale. Grâce à très peu de paramètres, on peut contrôler les distorsions de l'objet, avec comme contrainte que ces déformations soient spécifiques à l'objet. C'est précisément ce point qui est très intéressant lorsqu'on suit un objet qui tolère toujours le même type de distorsions (un organe par exemple), dans ce cas l'algorithme est robuste vis-à-vis des occlusions car la relaxation modale donne une estimation de la configuration de l'objet analogue à celles rencontrées dans l'ensemble d'apprentissage, la partie cachée est donc restituée. Les déformations locales quant à elles affinent la description et ne peuvent pas changer la forme globale de l'objet. Cette qualité de la méthode est pour nous un défaut. De plus, un fouillis admet un grand nombre de distorsions possibles et on ne peut pas affirmer que les distorsions recherchées sont présentes dans l'ensemble d'apprentissage. Il faut donc « repenser » l'algorithme.

Dans le cas où la distorsion est tout à fait singulière et donc inconcue de l'ensemble d'apprentissage, les déformations modales ne pourront donner qu'une estimation très grossière de la configuration de l'objet. Dans ce cas, les déformations locales doivent être capables de corriger les erreurs d'estimation de la forme globale. L'adjectif « local » ne convient plus exactement au type de déformation dont nous avons besoin.

Rappelons qu'initialement les déformations locales sont modélisées grâce à des processus markoviens tels que :

$$\begin{aligned} p(\mathbf{t}) &= \frac{1}{C} \exp -\frac{1}{2} \mathbf{t}^t R^{-1} \mathbf{t} \\ &= \frac{1}{C} \exp -\frac{1}{2} \sum_{i=1}^{2n} \left( \frac{1}{\varepsilon_i^2} (t_i - t_{i-1})^2 + \frac{1}{\sigma_i^2} t_i^2 \right) \end{aligned}$$

C. Kervrann et F. Heitz ont imposé  $\sigma_i^2 = 4$  et  $\varepsilon_i^2 = 1$ . D'après l'expression générale de la probabilité on peut comprendre l'influence de ces paramètres sur le modèle. Ils permettent de régler l'importance que l'on veut donner aux déformations locales. En effet, par construction, de grands  $t_i$  sont peu probables, à moins que  $\sigma_i^2$  soit suffisamment élevé, de même un point de la forme ne peut pas avoir un comportement local très différent de son voisin

sauf si  $\varepsilon_i^2$  est grand. Motivés par ces remarques, nous avons choisi d'introduire des  $\sigma_i^2$  et des  $\varepsilon_i^2$  élevés.

Cependant tolérer de grands  $\sigma_i^2$  et  $\varepsilon_i^2$  permet d'améliorer la précision du contour, mais introduit des artefacts. En effet, le fait d'accepter des distorsions locales importantes est moins contraignant pour le modèle, les points ont une grande capacité de déplacement et finalement les zones de positions possibles pour deux points voisins se recouvrent. Les formes obtenues de cette manière peuvent donc présenter des croisements de points. Il y a donc un compromis à gérer ici.

Si l'on accepte des grosses distorsions locales, le prototype obtenu ne peut plus être considéré comme une combinaison des formes de l'ensemble d'apprentissage. C'est une nouvelle forme qui peut être utilisée pour compléter la base d'apprentissage. Cette mise à jour permet de disposer d'une gamme d'apprentissage adaptée à l'évolution de l'objet. En effet, on peut retrouver le même type de distorsions sur plusieurs images successives et une fois la déformation « apprise » il sera très facile de la retrouver dans le reste de la séquence.

L'algorithme finalement implanté compte tenu des remarques précédentes, est décrit dans la figure 15.

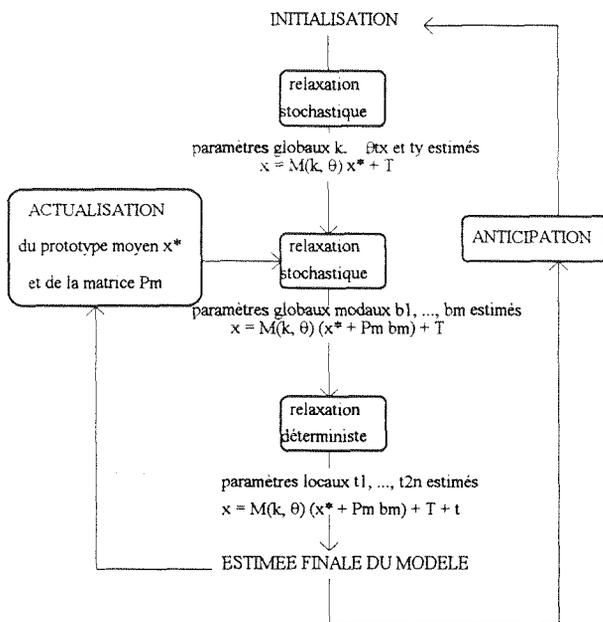


Figure 15. – Algorithme implémenté.

### 3.2.5. résultats

Les essais réalisés sur une séquence de 10 images radar en considérant un modèle à 21 points représentatifs et une base d'apprentissage comprenant 10 formes donnent les résultats suivants :

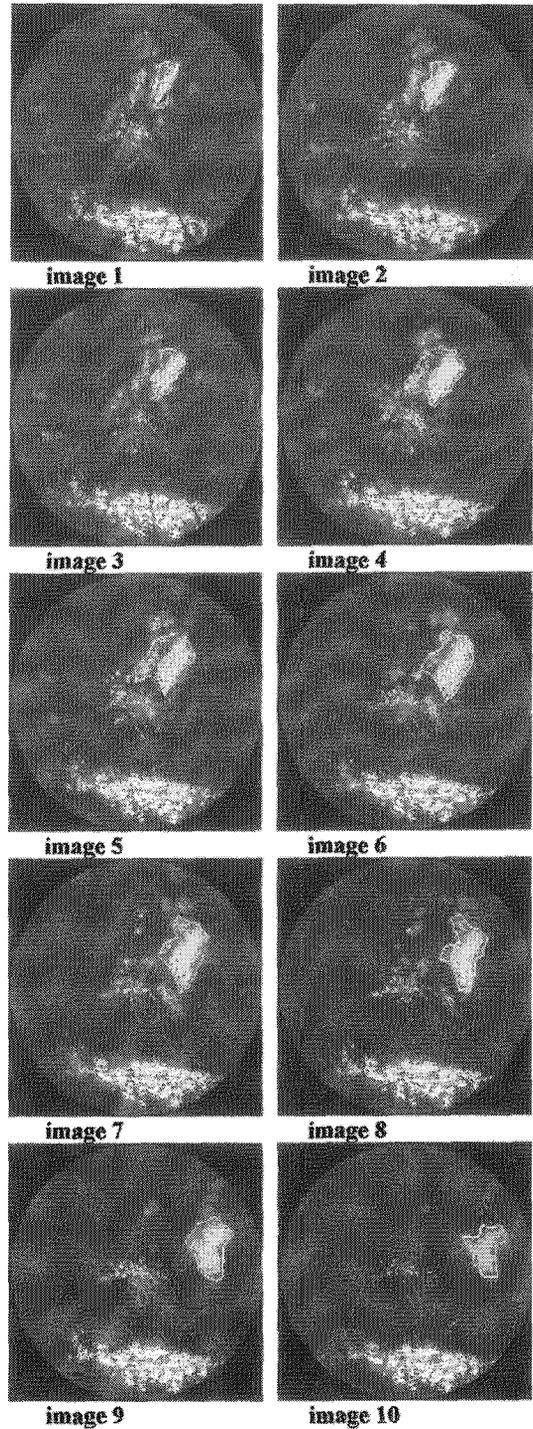


Figure 16. – Suivi sur une séquence de 10 images.

Le temps d'exécution pour la séquence entière est de 1288 secondes.

La séquence de test est toujours la même. Elle présente deux fouillis principaux : un fixe et un mobile. Le fouillis fixe correspond aux Pyrénées. Le fouillis mobile est pisté avec succès. Les contours obtenus à chaque itération sont fidèles et on peut remarquer

qu'ils incluent à partir de l'image 4 un nuage secondaire qui vient fusionner avec le fouillis principal.

Les différentes étapes du traitement d'une image sont illustrées par les images suivantes :

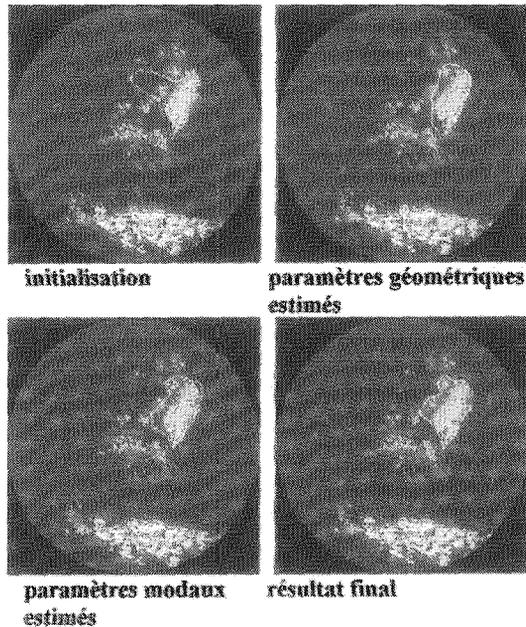


Figure 17. – Différentes étapes de traitement.

On donne une initialisation très mauvaise du fouillis mobile. L'estimation des paramètres géométriques permet de déterminer une forme grossière du fouillis. L'estimation des paramètres modaux, qui tiennent compte de l'aspect général des fouillis tout au long de la séquence, permet alors d'affiner les contours. La dernière étape permet enfin d'obtenir des contours relativement fidèles.

### 3.2.6. limites et perspectives

Comme nous avons pu le constater sur les images test, les résultats sont satisfaisants. Cependant la méthode présente quelques défauts.

Premièrement, la phase d'apprentissage est à la fois délicate, longue et déterminante pour la suite. La précision du suivi dépend fortement du choix des formes basiques et des points caractéristiques. Une perspective intéressante serait de rendre automatique cette étape de manière à réduire le temps de préparation et les risques de mauvais choix. L'approximation polygonale constitue bien sûr un premier pas dans cette voie. L'utilisation de l'algorithme proposé par Cootes pour aligner un ensemble de forme est une deuxième étape envisageable dans ce sens.

Deuxièmement, il est important de bien garder à l'esprit que la précision du suivi connaît une limite inhérente au modèle choisi : le nombre de points du modèle. En effet, le contour retourné n'est qu'une approximation qui peut être grossière lorsque l'objet suivi est complexe. Il est évidemment possible d'augmenter le

nombre de points d'approximation, mais ceci au détriment du temps de calcul. Cependant pour la séquence test, le choix de 21 points a répondu de manière satisfaisante à ce compromis : le résultat visuel est correct pour un temps d'exécution moyen de 2 minutes, donc largement inférieur à la limite tolérable (acquisition des images toutes les 15 minutes). Cela dit, si les contraintes de temps se faisaient plus fortes, il serait intéressant de diminuer le temps d'exécution grâce à une analyse multi-échelle.

Enfin, la gamme des distorsions de certains fouillis est très large et malgré les modifications apportées à l'algorithme initial, les paramètres modaux de contrôle de la forme ne permettent pas toujours d'estimer la configuration du modèle. Un ensemble d'apprentissage beaucoup plus étendu que celui que nous avons utilisé (10 prototypes) serait peut-être à même d'améliorer sensiblement les résultats.

## 4. conclusion

Des généralisations restent à étudier, concernant en particulier le changement de topologie du fouillis [24] [25] [26] [27] [28] (fusion de nuage ou séparation en plusieurs morceaux; dans ce cas on appliquera une formulation Hamilton-Jacobienne aux contours actifs plutôt qu'une formulation Euler-Lagrangienne), la parallélisation des algorithmes, l'introduction de la notion de contours multirésolution pour accélérer les algorithmes de contours actifs, l'extension à des données 3D, l'analyse doppler [29] [30] etc ...

Cette étude s'inscrit dans une réflexion plus vaste sur les capteurs intelligents. Malgré l'évolution des matériels, les systèmes de gestion centralisée multisenseur s'orientent de plus en plus vers une communication synthétique avec les senseurs par un échange de données symboliques (envoi de missions vers le senseur, accomplissement autonome de la mission par le senseur en fonction de son environnement et des ses potentialités propres, réémission vers le centre d'informations synthétiques : « vision synthétique » de son environnement, pistes fouillis, pistes cibles, paramètres d'identification des cibles, ...). La gestion multisenseur des systèmes futurs passe par une gestion tactique (intelligente et autonome) de chacun des senseurs, pour décharger les centres multisenseurs de tâches qui ne leur sont pas dévolues et les recentrer vers une gestion stratégique des senseurs.

Enfin, l'application de ces techniques de suivi d'objets déformables aux fouillis radar sont utilisables dans le cadre de la prédiction à court terme des phénomènes météorologiques pour l'optimisation de la gestion centralisée des flux du trafic aérien civil en présence de perturbations atmosphériques sévères, dangereuses pour la sécurité des vols.

## BIBLIOGRAPHIE

- [1] F. Barbaresco, B. Monnier, « Radar intelligent (approche systémique et cognitive) : expériences et perspectives », *Colloque International radar 94*, Paris, Mai 1994, pp. 246-250.

- [2] F. Heitz, P. Perez, P. Bouthemy, « Constrained multiscale Markov random fields and analysis of visual motion », *INRIA*, rapport de recherche n°1615, Février 1992.
- [3] F. Heitz, P. Perez, « Une approche multiéchelle à l'analyse d'images par champs markoviens », *INRIA*, rapport de recherche n°1477, Juillet 1991.
- [4] F. Heitz, S. Jufresa, E. Menin, T. Priol, « Parallélisation d'un algorithme de détection de mouvement sur une architecture MIMD », *INRIA*, rapport de recherche n°1738, Juillet 1992.
- [5] F. Barbaresco, F. Giersh, « Segmentation spatio-temporelle statistique des fouillis radar, implantation temps-réel sur machine parallèle CAMARO », soumission au *XVème colloque GRETSI*, Juan-les-Pins, 1995.
- [6] H. Caillol, A. Hillion, W. Pieczynski, « Segmentation contextuelle non supervisée d'images utilisant une modélisation statistique floue », soumission à publication *IEEE*.
- [7] W. Pieczynski, « Statistical image segmentation », *Machine Graphics and Vision*, vol. 1, n°1/2, pp. 261-268.
- [8] P. Masson, W. Pieczynski, « SEM algorithm and unsupervised segmentation of satellite images », *IEEE Trans on GRS*, vol. 31, n°3, pp. 618-633.
- [9] J. Zhang, « The mean field theory in EM procedures for Markov random fields », *IEEE Trans on SP*, vol. 40, n°10, October 1992.
- [10] F. Barbaresco, « Algorithme de Burg régularisé, comparaison avec l'algorithme de Burg-MFE (Minimum Free Energy) », soumission au *XVème colloque GRETSI*, Juan-les-Pins, 1995.
- [11] R.L. Cannon, J. Dave, V. Bezdek, « Efficient implementation of the fuzzy C-means clustering algorithms », *IEEE Trans on PAMI*, vol. 8, n°2, March 1986.
- [12] M. Kass, A. Witkin, D. Terzopoulos, « Snakes : active contour models », *International Journal of Computer Vision*, vol. 1, 1987.
- [13] L. Cohen, « On active contour models », *INRIA*, rapport de recherche n°1075, 1989.
- [14] L. Cohen, « Finite-element methods for active contour models and balloons for 2D and 3D images », *IEEE Trans on PAMI*, vol. 15, n°11, Nov. 1993.
- [15] A. Amini, T. Weymouth, R. Jain, « Using dynamic programming for solving variational problems in vision », *IEEE Trans on PAMI*, vol. 12, n°9, Sept. 1990, pp. 855-867.
- [16a] R. Malladi, J. Sethian, B. Vermuri, « Shape modelling with front propagation : a level set approach », *IEEE Trans on PAMI*, vol. 17, n°2, Feb. 1995.
- [16b] S. Osher, J.A. Sethian, « Fronts propagating with curvature-dependent speed : algorithms based on Hamilton-Jacobi formulations », *Journal of Computational Physics* 79, 1988, pp. 12-49.
- [17] V. Caselles, F. Catte, T. Coll, F. Dibos, « A geometric model for active contours in image processing », rapport interne n°9210, CEREMADE, Université Paris-Dauphine.
- [18] L. Bonnaud, C. Labit, « Etude d'algorithmes de suivi temporel de segmentation basée sur le mouvement pour la compression de séquence d'images », *INRIA*, rapport de recherche n°2253, Janv. 1994.
- [19] C. Kervrann, F. Heitz, « A hierarchical statistical framework for the segmentation of deformable objects in image sequences », *INRIA*, rapport de recherche n°2133, Dec. 1993.
- [20] D. Terzopoulos, D. Metaxos, « Dynamic 3D models with local and global deformations : deformable superquadrics », *IEEE Trans on PAMI*, vol. 13, n°7, July 1991.
- [21] S. Mallat, « A theory for multiresolution signal decomposition : the wavelets representation », *IEEE Trans on PAMI*, vol. 11, n°7, July 1989, pp. 674-693. [23] S. Lakshmanan, H. Derin, « Simultaneous parameter estimation and segmentation so Gibbs random fields using simulated annealing », *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 11, n°8, août 1989.
- [24] J. Sethian, R. Malladi, B. Venturi, « Shape modeling with front propagation : a level set approach, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 17, n°2, février 1995.
- [25] J.A. Sethian, « A fast marching level method for monotonically advancing fronts », *Proc. Nat. Acad. Sci.*, 93 (4), 1996.
- [26] L.D. Cohen and R. Kimmel, « Global minimum for active contour models : A minimal path approach », *Ceremade TR9612* In part in CV PR'96, San Francisco, USA, and ICAOS'96, Paris, June 1996.
- [27] L.D. Cohen, R. Kimmel, « Fast Marching the global Minimum of Active Contours », *ICIP 96*, vol. I, sept. 1996, pp. 473-476.
- [28] F. Barbaresco, S. Bonney, J. Lambert, B. Nonnier, « Motion-Based Segmentation and Tracking of Dynamic Radar Clutter », *ICIP 96*, vol. III, Sept. 1996, pp. 923-926.
- [29] F. Barbaresco, « Super-resolution spectrum analysis Regularization : Burg, Capon and Ago-Antagonistic Algorithms », *EUSPICO-96*, Trieste, pp. 2005-2008.
- [30] F. Barbaresco, « Recursive Eigende Composition via autoregressive Analysis and Ago-antagonistic Regularization », *ICASSP-97*, Munich.
- [31] N. Giordana & W. Pieczynski, « Unsupervised Segmentation of Multisensor Images Using Generalized Hidden Markov Field », *ICIP-96*, pp. 987-990, Lausanne.

Manuscrit reçu le 25 novembre 1995.

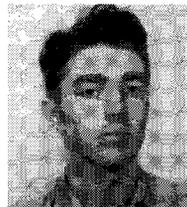
#### LES AUTEURS

Carole LAMBERT



Carole Lambert est née le 13 décembre 1971 à Laon. Elle est Ingénieur diplômée de l'Institut National des Télécommunications en 1995 avec une spécialisation « traitement d'images ». Les travaux présentés dans cet article ont été réalisés lors d'un stage de 5 mois chez Thomson-CSF AIRSYS service RD/RAN, centre de Bagneux. Elle est maintenant Ingénieur Réalisatrice chez Dassault Électronique pour la société de service MTB. Elle travaille sur les systèmes embarqués temps réel.

Johan LAMBERT



Johan Lambert est né le 17 novembre 1971 à Thionville. Il est diplômé de l'Institut National des Télécommunications en 1995 avec une spécialisation « traitement d'images ». Les travaux présentés dans cet article ont été réalisés lors d'un stage de 5 mois chez Thomson-CSF AIRSYS service RD/RAN, centre de Bagneux. Il est aujourd'hui Ingénieur d'Études pour la société SYSECA et il travaille au sein du même service de Thomson-CSF AIRSYS sur le traitement d'images météorologiques.

Frédéric BARBARESCO



Frédéric Barbaresco est né le 25 mai 1966 à Nantes, ingénieur diplômé de l'École Supérieure d'Électricité (SUPELEC) en 91, option « automatique » et de l'Institut National de Télécommunications (INT EVRY) en 89 section « communication et traitement du signal ». Il est depuis 5 ans ingénieur d'études dans la section « Fusion » de la filière « Algorithmie et Nouveaux Concepts (RAN) » de la TBU « Radar Development (RD) » de Thomson-CSF AIRSYS. Ses travaux portent sur l'application de la théorie de la commande des « systèmes complexes » pour la régulation « intelligente » des radars multifonctions pour la Défense aérienne et le champs de bataille (utilisation de l'intelligence artificielle, du traitement d'images, du traitement du signal et des données et de la fusion dans un cadre Systémique). Son domaine de recherche concerne également l'analyse spectrale haute résolution, dans le cadre duquel il a déposé un brevet sur la « régularisation de l'algorithme de Burg » et la « décomposition en sous-espaces propres récursives ».