

# Estimation des paramètres de processus ponctuels marqués dans le cadre de l'extraction d'objets en imagerie de télédétection \*

Florent CHATELAIN<sup>1</sup>, Xavier DESCOMBES<sup>2</sup>, Josiane ZERUBIA<sup>2</sup>

<sup>1</sup>Gipsa-lab, Département Image et Signal  
 Domaine Universitaire - BP 46 - 38402 Saint Martin d'Herès cedex, France

<sup>2</sup>Équipe-Projet Ariana, INRIA Sophia Antipolis - Méditerranée  
 2004, routes des Lucioles - BP93 - 06902 Sophia Antipolis cedex, France

florent.chatelain@gipsa-lab.inpg.fr,  
 xavier.descombes@sophia.inria.fr, josiane.zerubia@sophia.inria.fr

**Résumé** – L'article étudie le problème de l'estimation des paramètres d'un processus ponctuel marqué modélisant un réseau d'objets dans une image. L'objectif est de mettre en œuvre des méthodes d'extraction automatique des objets dans des images de télédétection. L'estimation du paramètre qui correspond au poids de l'énergie qui définit le processus est menée dans le cas de données incomplètes, où la configuration des objets dans l'image n'est pas connue. Le paramètre qui pondère l'énergie, ainsi que la configuration des objets, sont alors estimés conjointement. Ces travaux montrent la possibilité d'estimer certains paramètres des processus étudiés, et ouvrent la voie à des méthodes d'extraction automatique des objets.

**Abstract** – This communication addresses the problem of estimating the parameters of a family of marked point processes. These processes are of interest in extraction of object networks from remote sensing images. They are defined from an energy term, which is adjusted by a weight parameter. An estimation procedure of the weight parameter associated with the process energy is studied within the framework of missing data, where the configuration of the objects to be extracted is unknown. Therefore, parameter estimation and object extraction are performed jointly. The application to unsupervised detection of objects is finally discussed.

## 1 Introduction

Des modèles de processus ponctuels marqués ont été récemment appliqués avec succès à des problèmes d'extraction d'objets en télédétection [7, 3]. Un avantage majeur de ces modèles est de s'affranchir de l'approche pixellique : les contraintes géométriques et les interactions spatiales sont ainsi directement prises en compte au niveau des objets. Il est alors possible de modéliser de fortes interactions entre les objets à travers les paramètres du modèle. Pour un problème d'extraction donné, la valeur de ces paramètres dépend évidemment de l'image traitée. Jusqu'à présent, les méthodes d'extraction proposées nécessitent de calibrer à la main ces paramètres. Afin d'obtenir des méthodes d'extraction d'objets entièrement non-supervisées, il s'avère donc nécessaire de développer des méthodes d'estimation des paramètres en question.

## 2 Processus ponctuels marqués

Un objet  $x = (u, m)$  que l'on cherche à extraire peut être défini par sa position  $u$  dans l'image  $\mathcal{W}$ , et par une marque  $m \in \mathcal{M}$ . Dans notre cas, cette marque correspond aux caractéristiques géométriques de l'objet, par exemple son rayon

dans le cas d'objets circulaires. La configuration  $\mathbf{x}$  du réseau d'objets que l'on cherche à extraire peut alors être modélisée comme une réalisation d'un processus ponctuel marqué défini sur  $\mathcal{W} \times \mathcal{M}$ . On s'intéresse ici à des modèles de processus ponctuels marqués utilisés afin d'extraire des objets surfaciques tels que des houppiers [7] ou des flamants roses [3]. Ces processus sont définis par leur densité par rapport à une mesure de Poisson de référence. Dans la suite,  $\mathbf{y}$  désigne la radiométrie de l'image observée. En empruntant des notations issues de la physique statistique, la densité du processus peut s'exprimer sous forme énergétique. L'énergie du processus est alors formée par la somme de deux termes : 1) une énergie d'attache aux données notée  $U_{\theta}^d(\mathbf{x}, \mathbf{y})$ , qui reflète l'adéquation entre une configuration d'objets  $\mathbf{x}$  et les données observées  $\mathbf{y}$  et 2) une énergie *a priori* notée  $U_{\theta}^p(\mathbf{x})$  qui traduit les connaissances dont on dispose sur la structure de la configuration  $\mathbf{x}$  recherchée. Ceci conduit à l'expression suivante de la densité du processus :

$$f_{\theta}(\mathbf{x}|\mathbf{y}) = \frac{\exp[-\alpha(U_{\theta}^d(\mathbf{x}, \mathbf{y}) + U_{\theta}^p(\mathbf{x}))]}{c(\theta)}, \quad (1)$$

où  $\alpha$  est le paramètre qui pondère l'énergie,  $\theta$  désigne le vecteur des paramètres du modèle ( $\alpha$  compris), et  $c(\theta)$  est la constante de normalisation dont l'expression est en générale inconnue. Pour une valeur donnée des paramètres  $\theta$ , la configuration recher-

\* Les auteurs remercient le CNES pour le soutien financier partiel de ce travail qui a été réalisé lorsque le premier auteur était post-doctorant dans l'EPI Ariana de l'INRIA.

chée est alors celle qui maximise la vraisemblance  $f_{\theta}$ , ou de manière équivalente qui minimise l'énergie du processus :

$$\hat{\mathbf{x}} = \arg \min U_{\theta}^d(\mathbf{x}, \mathbf{y}) + U_{\theta}^p(\mathbf{x}). \quad (2)$$

Cette optimisation est classiquement effectuée à l'aide de méthodes de simulation et d'optimisation stochastiques de type recuit simulé. On peut déjà remarquer que le paramètre  $\alpha$  est homogène à l'inverse d'une température. Par conséquent, la valeur de ce paramètre sera déterminante lors de l'étape d'extraction par recuit simulé.

## 2.1 Attache aux données

Plusieurs modèles d'attache aux données ont été proposés afin d'extraire des objets surfaciques. Ces modèles, exploitent les différences entre les niveaux radiométriques des objets et du fond de l'image. On rappelle ici les grandes lignes de deux modèles qualifiés de "bayésien" et "détecteur" et introduits respectivement dans [6] et [7, 3].

**Modèle bayésien :** ce modèle résulte d'une formulation probabiliste du problème direct : on modélise donc la vraisemblance  $\mathcal{L}(\mathbf{y}|\mathbf{x})$  des observations  $\mathbf{y}$  conditionnellement à une configuration donnée  $\mathbf{x}$  d'objets. L'image est partitionnée en deux classes : la classe  $C_o$  des pixels qui appartiennent aux objets, et la classe  $C_f$  des pixels qui appartiennent au fond. Conditionnellement à leur appartenance à une classe donnée, les distributions des pixels sont supposées identiques et indépendantes. L'énergie d'attache aux données a finalement pour expression

$$U_{\theta}^d(\mathbf{x}, \mathbf{y}) = -\log \mathcal{L}(\mathbf{y}|\mathbf{x}). \quad (3)$$

Pour une configuration d'objet  $\mathbf{x}$  donnée, l'énergie d'attache aux données associée à un objet  $u$  s'exprime alors comme :

$$U_{\theta}^d(u|\mathbf{x}) = \begin{cases} U_{\theta}^d(\mathbf{x}) - U_{\theta}^d(\mathbf{x} \setminus \{u\}) & \text{si } u \in \mathbf{x}, \\ U_{\theta}^d(\mathbf{x} \cup \{u\}) - U_{\theta}^d(\mathbf{x}) & \text{sinon.} \end{cases} \quad (4)$$

La vraisemblance  $\mathcal{L}(\mathbf{y}|\mathbf{x})$  peut finalement être modélisée comme un mélange de deux gaussiennes :

$$\mathcal{L}(\mathbf{y}|\mathbf{x}) = \prod_{y \in C_o} f(y; m_o, \sigma_o^2) \prod_{y \in C_f} f(y; m_f, \sigma_f^2), \quad (5)$$

où  $f(\cdot; m, \sigma^2)$  étant la densité de probabilité de loi normale de moyenne  $m$  et de variance  $\sigma^2$ . Il est important de remarquer que les paramètres de ces lois peuvent être directement estimés à partir d'un algorithme de type  $k$ -means à deux classes. De plus, au vu de l'équation (1) la densité du processus, par rapport à la mesure d'un processus de Poisson de référence, correspond, lorsque  $\alpha = 1$ , dans un cadre bayésien à une densité  $a$  *posteriori*, et  $\hat{\mathbf{x}}$  représente alors l'estimateur classique du maximum  $a$  *posteriori*.

**Modèle détecteur :** l'énergie  $U_{\theta}^d$  associée à une configuration d'objets  $\mathbf{x}$  est obtenue comme la somme des énergies locales associées à chaque objet  $u$  de cette configuration :

$$U_{\theta}^d(\mathbf{x}, \mathbf{y}) = \sum_{x \in \mathbf{x}} U_d(x|\mathbf{y}), \quad (6)$$

où  $U_{\theta}^d(x) \in [-1, 1]$ . Cette énergie locale est définie à partir d'une mesure de contraste, notée  $d(\mathcal{O}(x), \mathcal{B}(x))$ , entre les distributions des pixels  $\mathcal{O}(x)$  de l'objet  $x$  et celles des pixels  $\mathcal{B}(x)$  situés à la frontière extérieure de l'objet [7, 3]. Ceci permet de mieux prendre en compte les propriétés morphologiques des objets par rapport au modèle bayésien. Finalement, cette mesure de contraste est ramenée sur l'intervalle  $[-1, 1]$  à l'aide d'une fonction de qualité paramétrée par un seuil  $d_0$  :

$$Q(d) = \begin{cases} 1 - \left(\frac{d}{d_0}\right)^{\frac{1}{3}} & \text{si } d < d_0, \\ \exp\left(-\frac{d-d_0}{3d_0}\right) - 1 & \text{sinon,} \end{cases} \quad (7)$$

L'énergie associée à un objet  $x$  s'obtient donc comme :

$$U_{\theta}^d(x, \mathbf{y}) = Q(d(\mathcal{O}(x), \mathcal{B}(x))). \quad (8)$$

## 2.2 A priori

Dans les problèmes qui nous intéressent, l'ajout d'un terme *a priori* est nécessaire afin de régulariser le problème inverse d'extraction des objets et d'aboutir à une solution unique et stable. On introduit ici un processus d'interaction par paire de type "hard-core" tel que les configurations où deux objets se recouvrent trop sont interdites, les autres configurations n'étant pas pénalisées. Formellement, on obtient pour toute configuration  $\mathbf{x} = \{x_1, \dots, x_n\}$  que  $U_{\theta}^d(\mathbf{x}) = \sum_{1 \leq i < j \leq n} t(x_i, x_j)$  où

$$t_s(x_i, x_j) = \begin{cases} 0 & \text{si } \frac{\text{Aire}(x_i \cap x_j)}{\min(\text{Aire}(x_i), \text{Aire}(x_j))} < s, \\ +\infty & \text{sinon.} \end{cases} \quad (9)$$

Le paramètre  $s$  représente donc la proportion maximale de recouvrement entre deux objets de la configuration. Un tel *a priori* permet d'éviter de détecter plusieurs fois le même objet. Dans la suite, ce paramètre est fixé de manière déterministe à  $s = \frac{1}{2}$  puisque deux objets qui ont plus de la moitié de leurs pixels en commun localisent, *a priori*, un seul et même objet de l'image.

## 3 Estimation des paramètres

On s'intéresse, dans ce paragraphe, à l'estimation des paramètres des familles de processus décrits dans la partie précédente, la configuration  $\mathbf{x}$  des objets dans l'image  $\mathcal{W}$  étant inconnue. La difficulté majeure à surmonter provient du fait que le constante de normalisation  $c(\theta)$  de la densité du processus définie en (1) dépend des paramètres à estimer. Or le calcul de cette constante s'avère impossible d'un point de vue analytique et très compliqué d'un point de vue numérique.

Des méthodes d'approximation de la vraisemblance par échantillonnage d'importance et méthodes de Monte Carlo ont été proposées [4, 5]. Ces méthodes ont été utilisées avec succès dans le cas de l'interpolation ou de l'extrapolation de processus ponctuels [8]. Dans ce cas, les données cachées correspondent à la configuration des objets sur une région de l'image, les données observées correspondant à la configuration des objets

sur le reste de l'image. Ce type d'algorithme permet ainsi d'estimer les paramètres d'interaction du processus tout en prenant en compte l'influence des objets non observés. Cependant, le cas étudié, i.e. l'extraction d'objets, se révèle être plus complexe. En effet, les données observées ne correspondent pas à une configuration du processus sur une zone de l'image, mais se limitent à la radiométrie de l'image. Par conséquent, afin d'estimer par Monte-Carlo, il s'avère nécessaire de simuler conjointement une configuration  $\mathbf{x}$  et la radiométrie  $\mathbf{y}$  associée. Outre les difficultés inhérentes aux méthodes d'estimation par maximum de vraisemblance approchée par Monte Carlo, on se heurte alors à des difficultés rédhibitoires. Tout d'abord, simuler la radiométrie  $\mathbf{y}$  nécessite de disposer d'une modélisation probabiliste du problème direct. Ceci peut être fait en considérant, par exemple, le modèle (5) présenté dans le cadre bayésien. Néanmoins, si ce modèle probabiliste s'avère suffisant afin d'extraire les objets des l'image, il demeure encore trop grossier pour estimer les paramètres, les statistiques simulées étant trop différentes de celles observées. Mis à part dans le cas d'images synthétiques simulées selon le modèle probabiliste du problème direct<sup>1</sup>. Par conséquent, des méthodes d'estimation spécifiques doivent être considérées.

### 3.1 Pseudo-vraisemblance d'un processus ponctuel

Le concept de pseudo-vraisemblance se généralise au cas des processus ponctuels marqués. Pour une configuration d'objets  $\mathbf{x}$  donnée, on obtient alors l'expression suivante de la pseudo-vraisemblance :

$$\text{PL}(\theta; \mathbf{x}, \mathbf{y}) = \left[ \prod_{x_i \in \mathbf{x}} \lambda_\theta(x_i) \right] \exp \left\{ - \int_{\mathcal{W} \times \mathcal{M}} \lambda_\theta(u) \Lambda(du) \right\}, \quad (10)$$

où  $\Lambda(\cdot)$  est la mesure de l'intensité du processus de Poisson de référence d'intensité unité ( $\Lambda(\mathcal{W} \times \mathcal{M}) = 1$ ) et

$$\lambda_\theta(u) = \exp \left[ -\alpha \left( U_\theta^d(u, \mathbf{y}) - \sum_{x_i \in \mathbf{x} | x_i \neq u} t(u, x_i) \right) \right], \quad (11)$$

représente l'intensité conditionnelle de Papangelou. Différents schémas d'intégration peuvent finalement être employés afin d'obtenir, à partir de (10), une expression numérique de la pseudo-vraisemblance [1].

### 3.2 Approximation de l'algorithme Expectation-Maximization (EM)

Lorsque la configuration  $\mathbf{x}$  des objets est inconnue, il n'est pas possible d'obtenir une expression analytique explicite de la vraisemblance  $f_\theta(\mathbf{y})$  ou de la pseudo-vraisemblance associée

<sup>1</sup>Même dans le cas d'images synthétiques simulées selon une modélisation probabiliste du problème direct, ces statistiques sont sensiblement différentes. La configuration  $\mathbf{x}$  simulée à partir de l'image observée  $\mathbf{y}$  n'est jamais parfaitement ajustée sur les objets de l'image, contrairement au cas où les observations  $\mathbf{y}$  sont simulées à partir d'une configuration  $\mathbf{x}$ .

aux seules observations  $\mathbf{y}$ . Des algorithmes de type EM qui exploitent la connaissance dont on dispose sur la vraisemblance étendue  $f_\theta(\mathbf{x}, \mathbf{y})$ , i.e. la vraisemblance jointe des données observées  $\mathbf{y}$  et des données manquantes  $\mathbf{x}$ , offre des alternatives intéressantes. Cependant, chaque itération de l'algorithme EM nécessiterait de calculer l'espérance suivante :

$$Q(\theta, \theta^k; \mathbf{y}) = E_{\theta^k} [\log f_\theta(X, Y) | Y = \mathbf{y}]. \quad (12)$$

Puisque la constante de normalisation  $c(\theta)$  n'est pas connue, ce calcul, même numérique, s'avère impossible. On considère donc une approximation stochastique de l'algorithme EM proposée dans [2] sous le nom SEM. De plus, nous proposons dans ce travail d'approcher la densité  $f_\theta(\mathbf{x}|\mathbf{y})$ , dont la constante de normalisation est inconnue, par la pseudo-vraisemblance. Cette approximation est motivée par, au moins, deux raisons : 1) pour une configuration  $\mathbf{x}$  donnée, la pseudo-vraisemblance est une fonction d'inférence proche de la vraisemblance (la pseudo-vraisemblance correspond, par exemple, à la vraisemblance dans le cas d'un processus de Poisson), 2) dans le cas des données complètes, les estimateurs du maximum de vraisemblance et de pseudo-vraisemblance ont des performances similaires pour les processus qui nous intéressent. Chaque itération de l'algorithme ainsi obtenu, se décompose alors en trois

étapes :

- 1) Simulation d'une configuration  $\mathbf{x}^{(k)}$  conditionnellement aux observations  $\mathbf{y}$ , et selon le processus de paramètre  $\theta^k$ ,
- 2) Calcul de l'estimateur  $\hat{Q}(\theta, \theta^k; \mathbf{y}) = \log \text{PL}(\theta; \mathbf{x}^{(k)}, \mathbf{y})$ ,
- 3) Maximisation :  $\theta^{k+1} = \arg \max_{\theta} \hat{Q}(\theta, \theta^k; \mathbf{y})$ .

## 4 Simulations

Dans la suite, on se limite à l'estimation du paramètre de pondération  $\theta \equiv \alpha$  de l'énergie du modèle. La valeur de ce paramètre, qui est homogène à l'inverse d'une température, est déterminante lors de l'extraction des objets. En effet, en l'absence de pondération (i.e.  $\alpha = 1$ ), la plage de températures pour lesquelles l'algorithme de recuit simulé permet d'extraire les données est fortement dépendante de l'image traitée et de l'énergie d'attache aux données utilisée. L'estimation de ce paramètre permet ainsi de s'affranchir de l'étape de calibration manuelle des températures, la plage pouvant être normalisée autour de la température unité.

### 4.1 Initialisation de l'algorithme SEM

Afin d'éviter de converger vers un maximum local de la vraisemblance, il est important de choisir dans l'algorithme SEM une valeur initiale  $\alpha_0$  suffisamment proche de la valeur théorique de l'estimateur du maximum de vraisemblance de  $\alpha$ . Pour ce faire, on introduit la fonction suivante :

$$I(\alpha) = \int_S \lambda_\theta(u; \emptyset, \mathbf{y}) \Lambda(du),$$

où  $\lambda_\theta(u; \emptyset, \mathbf{y})$  est l'intensité de Papangelou, introduite à l'éq. (11). Pour une valeur  $\alpha$  donnée,  $I(\alpha)$  représente alors le nombre moyen d'objets en l'absence d'interaction. On note  $\beta > 1$  le nombre exact d'objets à extraire. Par construction, la fonction  $I(\cdot)$  est strictement convexe et l'équation  $I_\beta(\alpha) = \beta$  admet une unique solution  $\alpha_0$  sur l'intervalle  $[0, +\infty[$ . La valeur  $\alpha_0$  serait alors une valeur pertinente afin d'initialiser l'algorithme SEM. Une réalisation du logarithme de la fonction  $I(\cdot)$  est représenté Fig. 1. On peut vérifier que la fonction  $I(\cdot)$  croît exponentiellement. Par conséquent, même pour des valeurs  $\beta' \gg \beta$  largement surestimées du nombre d'objets dans l'image, la racine de la fonction  $I(\cdot) - \beta'$  est très proche de la valeur  $\alpha_0$ . Ceci conduit à adopter le schéma suivant afin de déterminer la valeur initiale  $\alpha_0$  :

- 1) Surestimation grossière du nombre d'objets  $\beta_0 \geq 1$  (on peut, par exemple, choisir le nombre maximal d'objets qui peuvent être contenus dans l'image traitée)
- 2) Calcul de la racine  $\alpha_0$  de la fonction  $\alpha \mapsto I(\alpha) - \beta_0$ . Cette étape est réalisée numériquement par une méthode de type Newton-Raphson.




FIG. 1 – Exemple de réalisation de  $\log_{10}(I(\alpha))$  en fonction de  $\alpha$  pour le modèle détecteur.

## 4.2 Résultats numériques

Les valeurs initiales et finales des températures utilisées pour le recuit sont fixées respectivement à  $T_{\max} = 2$  et  $T_{\min} = 0.1$  dans ces simulations. On considère une image synthétique présentée Fig. 1 composée de 60 objets de formes quasi-circulaires. Les objets du processus sont de formes circulaires et représentés sur les figures par des cercles rouges. Les figures 2(a) et 2(b) représentent les résultats de l'estimation du paramètre  $\alpha$  respectivement pour l'énergie d'attache aux données bayésienne ( $\hat{\alpha} = 7.2 \times 10^{-4}$ ) et celle détecteur ( $\hat{\alpha} = 37.9345$ ). On peut noter la grande disparité entre les deux estimées, due aux différences de dynamique entre les deux modèles d'attache aux données. On peut également remarquer que les configurations simulées au cours de l'estimation SEM sont déjà proches de la configuration optimale. Finalement, les résultats d'extraction des objets sont obtenus après recuit simulé à partir des estimés du paramètre  $\alpha$  et sont représentés Fig. 2(c) dans le cas bayésien et Fig. 2(d) dans le cas détecteur. Tous les objets, hormis ceux situés quasiment hors de l'image, sont correctement extraits.

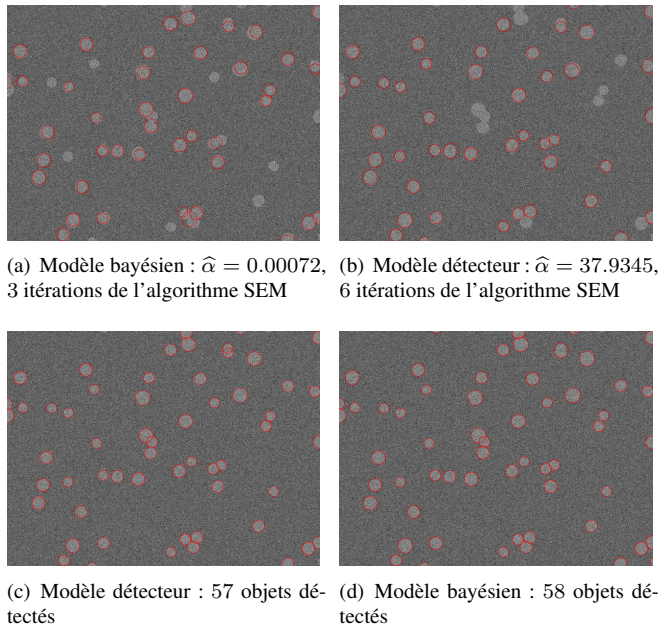


FIG. 2 – Estimation SEM et extraction des objets par recuit simulé à partir des estimés du paramètre  $\alpha$

## 5 Conclusions

Une méthode d'estimation du paramètre qui pondère l'énergie d'un processus ponctuel marqué a été proposée. L'estimation de ce paramètre permet de normaliser la plage de températures utilisée afin d'extraire un réseau d'objets par recuit simulé. Les résultats présentés illustrent, pour différents modèles d'attache aux données, l'intérêt de la méthode d'estimation proposée. En vue d'une extraction entièrement automatique, cette méthode pourrait être appliquée à d'autres paramètres du modèle, en introduisant des lois statistiques a priori sur la distribution des paramètres à estimer.

## Références

- [1] A. Baddeley et R. Turner : Practical maximum pseudolikelihood for spatial point patterns (with discussion). *Australian and New Zealand Journal of Statistics*, 42(3): 283–322, septembre 2000.
- [2] G. Celeux et D. Diebolt : The SEM algorithm : a probabilistic teacher algorithm derived from the EM algorithm for the mixture problem. *Computational Statistics Quarterly*, 2(1):73–82, 1985.
- [3] S. Descamps, X. Descombes, A. Béchet et J. Zerubia : Automatic flamingo detection using a multiple birth and death process. *In Proc. IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2008.
- [4] C. Geyer : *Stochastic Geometry - Likelihood and Computation*, chapitre Likelihood inference for spatial point process. Chapman and Hall/CRC, 1999.
- [5] J. Møller et R. P. Waagepetersen : *Statistical Inference and Simulation for Spatial Point Processes*. Chapman and Hall/CRC, Boca Raton, 2004.
- [6] G. Perrin, X. Descombes et J. Zerubia : A marked point process model for tree crown extraction in plantations. *In Proc. IEEE International Conference on Image Processing (ICIP)*, Genova, septembre 2005.
- [7] G. Perrin, X. Descombes et J. Zerubia : 2d and 3d vegetation resource parameters assessment using marked point processes. *In Proc. International Conference on Pattern Recognition (ICPR)*, Hong-Kong, août 2006.
- [8] M. N. M. van Lieshout et A. J. Baddeley : Extrapolating and interpolating spatial patterns. In A. B. Lawson et D. G. T. Denison, éditeurs : *Spatial cluster modelling*. CRC Press/Chapman and Hall, Boca Raton, 2002.