



HAL
open science

Extraction automatique des réseaux linéiques à partir d'images satellitaires et aériennes par processus Markov objet

Caroline Lacoste, Xavier Descombes, Josiane Zerubia, Nicolas Baghdadi

► **To cite this version:**

Caroline Lacoste, Xavier Descombes, Josiane Zerubia, Nicolas Baghdadi. Extraction automatique des réseaux linéiques à partir d'images satellitaires et aériennes par processus Markov objet. Bulletin - Société Française de Photogrammétrie et de Télédétection, 2003, 170, pp.13-22. hal-02924089

HAL Id: hal-02924089

<https://hal.inrae.fr/hal-02924089>

Submitted on 27 Aug 2020

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

See discussions, stats, and author profiles for this publication at: <https://www.researchgate.net/publication/236882132>

Extraction automatique des réseaux linéiques à partir d'images satellitaires et aériennes par processus Markov objets

Article in *Revue Francaise de Photogrammetrie et de Teledetection* · January 2003

CITATIONS

8

READS

139

4 authors, including:



[Xavier Descombes](#)

National Institute for Research in Computer Science and Control

269 PUBLICATIONS 4,010 CITATIONS

[SEE PROFILE](#)



[Josiane Zerubia](#)

National Institute for Research in Computer Science and Control

450 PUBLICATIONS 9,928 CITATIONS

[SEE PROFILE](#)



[Nicolas Baghdadi](#)

French National Institute for Agriculture, Food, and Environment (INRAE)

410 PUBLICATIONS 5,888 CITATIONS

[SEE PROFILE](#)

Some of the authors of this publication are also working on these related projects:



Hyperspectral imaging of skin erythema [View project](#)



remote sensing [View project](#)

Lacoste C., Descombes X., Zerubia J., and **Baghdadi N.**, 2003. Extraction automatique des réseaux linéiques à partir d'images satellitaires et aériennes par processus Markov objets. *Bulletin de la SFPT (Société Française de Photogrammétrie et de Télédétection)*, no. 170, pp. 13-22.

EXTRACTION AUTOMATIQUE DES RESEAUX LINEIQUES A PARTIR D'IMAGES SATELLITAIRES ET AERIENNES PAR PROCESSUS MARKOV OBJET

Caroline LACOSTE^{*}, Xavier DESCOMBES^{*}, Josiane ZERUBIA^{*}, Nicolas BAGHDADI[†]

^{*} INRIA - Sophia Antipolis
2004, route des Lucioles - BP 93
06902 Sophia Antipolis cedex - FRANCE
E-mail : Prénom.Nom@inria.fr
Tél. : 04.92.38.78.57 - Fax : 04.92.38.76.43

[†] BRGM
3, avenue Claude-Guillemin - BP 6009
45060 Orléans - FRANCE
E-mail : n.baghdadi@brgm.fr
Tél. : 02.38.64.32.02 - Fax : 02.38.64.36.89

Résumé

Cet article présente une méthode d'extraction non supervisée des réseaux linéiques, tels que les réseaux routiers ou les réseaux hydrographiques, à partir d'images moyenne ou haute résolution. Nous modélisons le réseau linéique présent dans la scène observée par un processus Markov objet, où les objets sont des segments interagissant entre eux. Le modèle *a priori*, appelé « Quality Candy », est construit de façon à exploiter au mieux la topologie du réseau recherché, au travers de potentiels définis à partir de la qualité de chaque interaction. Les propriétés radiométriques des données sont prises en compte au travers d'un terme d'attache aux données défini à partir de tests statistiques. Nous proposons deux techniques pour calculer ce terme, l'une précise, l'autre efficace. L'optimisation est réalisée par un recuit simulé avec un algorithme de type Monte Carlo par chaîne de Markov à sauts réversibles. Afin d'accélérer la convergence de l'algorithme, nous proposons des noyaux de proposition pertinents. Les résultats de l'extraction, obtenus pour chaque technique à partir d'images provenant de différents capteurs, sont évalués quantitativement par rapport à des extractions manuelles.

Mots clés : Extraction de réseaux linéiques, imagerie haute résolution, processus ponctuels, méthodes MCMC à sauts réversibles.

Abstract

This article presents a method for the unsupervised extraction of line networks (for example, road and hydrographical networks) from satellite and aerial images of medium and high resolution. We model the line network in the observed scene by a Markov object process, where the objects are interacting line segments. The prior model, the "Quality Candy" model, is designed to exploit as fully as possible the topological properties of the network under consideration, while the radiometrical properties of the network are modelled using a data term based on statistical tests. Two techniques are used to compute this term, one accurate and the other efficient. Optimization is performed using simulated annealing with a RJMCMC algorithm. We accelerate convergence of the algorithm by using appropriate proposition kernels. The results obtained on images coming from different sensors are quantitatively evaluated with respect to manually generated ground truth.

Keywords : Line network extraction, high resolution image processing, point processes, RJMCMC.

1. Introduction

Le but de cette étude est de fournir un algorithme d'extraction des réseaux linéiques à partir d'images satellitaires ou aériennes haute résolution, dont l'application finale serait la

production de données géographiques. L'enjeu est important : plus de la moitié du globe reste à cartographier. De nombreuses méthodes ont été développées pour répondre à ce problème difficile, notamment pour le cas particulier des réseaux routiers. Deux catégories de

méthodes sont proposées dans la littérature. Les premières reposent sur une optimisation locale reposant, par exemple, sur des détections de contours [Graffigne & Herlin, 1989], des opérateurs morphologiques [Serendero, 1989] ou encore des opérateurs dédiés à l'extraction de routes [Duda & Hart, 1973]. L'inconvénient majeur d'un tel choix pour l'optimisation est son importante sensibilité au bruit, en particulier pour les images haute résolution dans lesquelles un bruit géométrique inhérent à la scène observée (par exemple, dû à la présence d'arbres à proximité des routes) vient s'ajouter au bruit du capteur. Afin de réduire cette sensibilité au bruit, certains auteurs proposent d'utiliser des techniques multi-résolutions, par exemple en fusionnant le résultat de l'extraction de l'axe central à basse résolution, moins sensible au bruit géométrique, avec le résultat de l'extraction des bordures de route à haute résolution fournissant une meilleure localisation du réseau [Heipke et al., 1995 ; Baumgartner et al., 1996]. La seconde catégorie de méthodes correspond à des méthodes d'optimisation globales, comme la programmation dynamique dans [Fischler et al., 1981 ; Barzohar & Cooper, 1996 ; Merlet & Zerubia, 1996], les contours actifs dans [Neuenschwander et al., 1997], ou des stratégies issues de la théorie des jeux [Geman & Jedynak, 1996]. La plupart de ces algorithmes correspondent à des extractions semi-automatiques du réseau : un opérateur doit fournir des points de contrôle. Le gain de productivité apporté par les techniques semi-automatiques étant faible par rapport au travail d'extraction mené par un expert, nous souhaitons établir une technique d'extraction des réseaux linéiques complètement automatique. Un premier choix consiste à initialiser l'algorithme par une pré-détection obtenue par une optimisation locale, comme par exemple dans [Tupin et al., 1998] où une détection des structures linéaires initialise un champs de Markov sur graphe. Mais cela reste très sensible à la qualité de la pré-détection. Là encore, les approches multi-résolutions peuvent s'avérer efficaces, comme dans [Laptev et al., 2000] où une pré-détection de l'axe central des routes réalisée à basse résolution permet d'initialiser un algorithme d'extraction de routes fondé sur des contours actifs (« ribbon snakes »).

Nous nous plaçons dans un cadre stochastique, ce qui nous permet de bénéficier de la robustesse au bruit des approches de type champs de Markov et des outils associés à ce type de méthodes : des estimateurs, des algorithmes d'exploration de l'espace d'état qui s'avèrent très utiles dès que cet espace est grand. Plus précisément, nous modélisons le réseau linéique par un processus Markov objet comme cela a été proposé dans [Stoica, 2001], c'est-à-dire une configuration aléatoire d'objets dans un compact de \mathfrak{R}^d dont le nombre d'objets est lui-même une variable aléatoire. Les objets de ce processus sont des segments interagissant entre eux et décrits par trois variables aléatoires correspondant à leur centre, leur longueur et leur orientation.

Le fait de travailler avec des objets plutôt qu'avec des pixels nous permet d'introduire implicitement un *a priori* fort sur la forme de l'objet à extraire et d'être ainsi moins sensible au bruit que les méthodes pixeliques. De plus, la définition d'interactions entre ces segments nous permet d'introduire un *a priori* sur l'agencement des segments dans la scène en manipulant des contraintes géométriques fortes.

Le chapitre 2 décrit la construction du modèle d'extraction de réseaux linéiques, composé du modèle *a priori* « Quality Candy » (amélioration du modèle « Candy » proposé dans [Stoica, 2001]), défini en 2.2, et d'un terme d'attache aux données reposant sur des tests statistiques dont deux techniques de calcul sont données en 2.3. La méthode d'optimisation est présentée dans le chapitre 3. Finalement, le chapitre 4 fournit les résultats de l'extraction sur différentes images et une évaluation de ces résultats par rapport à une extraction manuelle.

2. Modélisation

2.1. Densité du processus

Nous cherchons à définir un processus de points marqués (les points étant les centres des segments de la réalisation du processus S et les marques associées correspondant à leurs orientations et leurs longueurs) dans lequel les points interagissent entre eux afin d'injecter dans le modèle une connaissance *a priori* sur l'agencement des segments dans l'espace. Un tel processus peut être spécifié par une densité f par rapport à un processus uniforme de Poisson, processus ponctuel marqué complètement aléatoire (les points et les marques sont indépendamment et uniformément distribués) et dont le nombre d'objets suit une loi de Poisson. Outre les contraintes géométriques exprimées dans la densité *a priori* h_p , les propriétés radiométriques des données sont prises en compte dans un terme d'attache aux données h_d . La densité non normalisée (la constante de normalisation est inconnue du fait de la grande taille de l'espace d'état) du modèle complet, f , s'écrit alors comme le produit de la densité *a priori* h_p et du terme d'attache aux données h_d :

$$f(S) \propto h_p(S) h_d(S)$$

où S est une réalisation du processus.

2.2. Model *a priori*

Un premier modèle fondé sur les processus ponctuels marqués, le modèle « Candy » (dont un rappel est donné en 2.2.1), a été proposé dans [Stoica 2001] pour l'extraction du réseau routier. Nous proposons une amélioration de ce modèle, appelée « Quality Candy » et définie en 2.2.2, qui prend en compte la « qualité » de chaque interaction entre objets de façon continue. Cela amène à une meilleure modélisation de la courbure, des jonctions du réseau et des intersections [Lacoste et al., 2002].

2.2.1. Modèle « Candy »

Ce modèle est fondé sur trois relations possibles entre deux segments : la connexion, une relation de proximité et une relation de mauvaise orientation.

La relation de connexion est définie à une constante ε près car une connexion exacte est de probabilité nulle sous la mesure de Poisson. Deux segments vérifient cette relation si la différence entre (exactement) deux de leur extrémités est inférieure à ε . La relation de connexion permet de définir trois états possibles pour chaque segment comme cela est illustré par la figure 1.

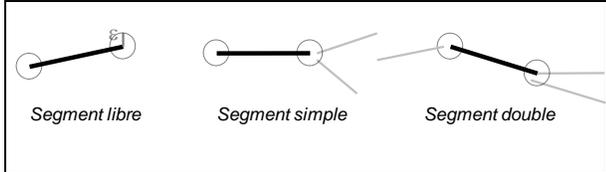


Figure 1 : Trois états dérivant de la relation de connexion

L'état de chaque segment de la configuration intervient dans la densité. Ainsi, les segments libres (i.e. non connectés) et les segments simples (i.e. connectés par une seule de leurs extrémités) sont pénalisés par un potentiel constant et positif afin de favoriser un réseau continu.

La relation de proximité est définie afin d'éviter une agrégation de segments. Deux segments vérifient cette relation si leurs centres se situent à une distance inférieure à la demi-longueur du segment le plus long. Un potentiel positif (constant) est assigné aux paires de segments vérifiant cette relation et dont la différence d'orientation est inférieure à un certain seuil.

La dernière relation (mauvaise orientation) est introduite afin de contrôler la courbure du réseau. Cette relation concerne les paires de segments dont les centres sont situés à une distance supérieure à la plus grande des demi-longueurs de ces deux segments et dont les extrémités sont assez proches. Dans ce cas, ils sont dit mal-orientés si leur différence d'orientation est supérieure à un certain seuil.

L'énergie du « Candy » modèle U_C est finalement une somme pondérée du nombre de segments libres n_l , du nombre de segments simples n_s , du nombre de paires de segments vérifiant la relation de proximité et ayant des orientations trop proches n_p et du nombre de paires de segments mal orientés n_o . La densité *a priori* h_C s'écrit alors de la façon suivante :

$$h_C(S) \propto \beta^n \exp - \underbrace{[\omega_1 n_l + \omega_2 n_s + \omega_3 n_p + \omega_4 n_o]}_{U_C}$$

où les ω_i sont des poids constants et positifs, n est le nombre total de segments dans la configuration S et β est un facteur d'intensité du processus qui permet de réguler le nombre total de points.

2.2.2 Modèle « Quality Candy »

Ce modèle est une extension du modèle « Candy » obtenu en remplaçant les potentiels d'interaction constants par des fonctions mesurant la qualité des interactions. Deux interactions entre segments interviennent dans ce modèle. La connexion entre deux segments, qui sera en général favorisée, est définie de la même façon que précédemment avec la condition supplémentaire que les deux segments forment un angle grave afin d'accélérer l'optimisation (cette deuxième condition est retirée pour l'extraction de réseaux très sinueux). Nous reprenons la relation de proximité intervenant dans le modèle initial (paragraphe 2.2.1) qui sera plus ou moins pénalisée dans la densité *a priori*.

La faible courbure et la proximité des extrémités connectées sont favorisées au travers d'un potentiel associé à chaque clique de connexion (\equiv paire de segments connectés). Celui-ci est défini pour deux segments connectés s_i et s_j comme la moyenne de deux fonctions, l'une concernant la différence d'orientation τ_{ij} entre s_i et s_j et l'autre la distance d_{ij} entre les deux extrémités connectées :

$$g_c(s_i, s_j) = \frac{g_\tau(\tau_{ij}) + g_\varepsilon(d_{ij})}{2}$$

avec

$$g_\tau(\tau_{ij}) = \begin{cases} -\sigma_\tau(|\tau_{ij}|) & \text{si } |\tau_{ij}| < \tau \\ 1 & \text{sinon} \end{cases}$$

$$g_\varepsilon(d_{ij}) = -\sigma_\varepsilon(d_{ij})$$

La fonction g_τ , qui concerne la différence d'orientation, donne un poids attractif (\equiv négatif) aux paires de segments dont la différence d'orientation est inférieure à un seuil τ et un poids répulsif (\equiv positif) dans le cas contraire. Notons que cette expression correspond au cas où la connexion est définie pour des angles graves ; dans le cas où les connexions à angle aigus doivent être considérées, il suffit d'assigner la valeur répulsive (égale à 1) aux paires de segments connectés formant un angle aigu. La fonction g_ε , qui concerne la distance entre les extrémités connectées, est quant à elle toujours attractive. Le potentiel en résultant $g_c(s_i, s_j)$ est du même signe que $g_\tau(\tau_{ij})$ comme cela est illustré par la figure 2. Les termes attractifs sont donnés par une fonction de qualité σ_M , fonction croissante définie sur $[0, M]$ à valeurs dans $[0, 1]$ (M étant égal à τ pour le terme concernant l'orientation et à ε pour celui concernant la distance entre les extrémités connectées).

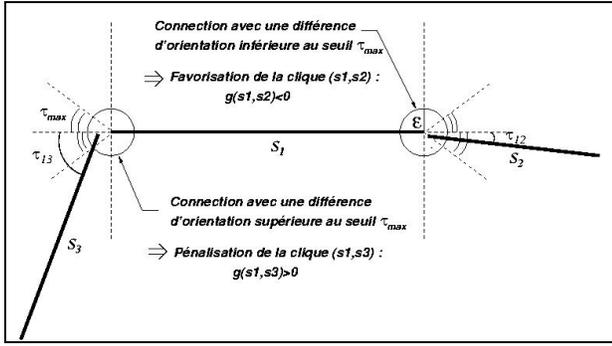


Figure 2 : Potentiel de la relation de connexion

Le potentiel correspondant aux paires de segments vérifiant la relation de proximité pénalise les segments dont les centres et orientations sont trop proches (potentiel positif) et interdit les segments parallèles trop proches (potentiel infini). L'expression de ce potentiel est donnée par l'équation suivante pour deux segments s_i et s_j concernés par cette relation dont la différence d'orientation est égale à τ_{ij} :

$$g_p(s_i, s_j) = \begin{cases} \infty, & \text{si } \tau_{ij} < \gamma \\ 1 - \sigma_{\left(\frac{\pi}{2} - \delta\right)}(\tau_{ij}), & \text{si } \gamma < \tau_{ij} < \delta \\ 0, & \text{si } \tau_{ij} > \delta \end{cases}$$

Les différents cas possibles pour des segments vérifiant cette relation sont illustrés dans la figure 3.

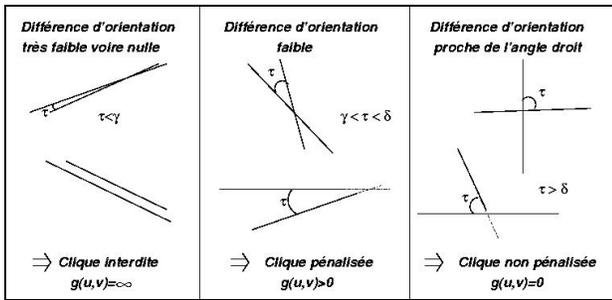


Figure 3 : Potentiel de la relation de proximité

Finalement, nous écrivons la densité sous forme exponentielle où l'énergie correspondante U_p est une somme pondérée des nombres de segments libres et de segments simples présents dans la configuration S et des potentiels correspondants aux paires de segments en interaction. Nous avons donc :

$$h_p(S) \propto \beta^n \exp - \underbrace{\left[\omega_1 n_l + \omega_2 n_s + \omega_3 \sum_{p \in C} g_c(p) + \omega_4 \sum_{p \in P} g_p(p) \right]}_{U_p}$$

où n , n_l , n_s et β sont définis comme précédemment, g_c (resp. g_p) le potentiel associé aux paires de segments appartenant à C (resp. P) désignant l'ensemble des cliques de connexion

(resp. proximité). Cette densité définit un processus de Markov par rapport à la relation \sim définie par :

$$s \sim s' \Leftrightarrow d(p_s - p_{s'}) \leq 2(L_{\max} + \varepsilon)$$

où p_s (resp. $p_{s'}$) est le centre du segment s (resp. s'), d la distance euclidienne dans \mathcal{R}^2 et L_{\max} la longueur maximale d'un segment. Autrement dit, la probabilité locale d'un segment s sachant le reste de la configuration ne dépend que des segments dont le centre est appartenir à la boule de centre p_s et de rayon égal à $2(L_{\max} + \varepsilon)$. De plus, ce processus Markov objet est localement stable (la preuve est donnée dans [Lacoste et al., 2002]) ce qui garantit la convergence ergodique de l'algorithme de chaînes de Markov à sauts réversibles défini dans le chapitre 3.

2.3. Terme d'attache aux données

Le terme d'attache aux données est construit sur les deux hypothèses suivantes :

- H_1 : le niveau de gris du réseau est localement homogène.
- H_2 : la variation du niveau de gris entre le réseau et le fond de l'image à proximité est importante.

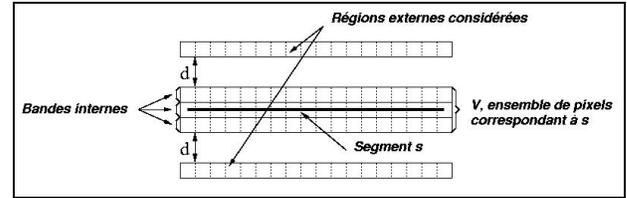


Figure 4 : Régions considérées pour l'évaluation de H_1 et H_2

Afin d'évaluer la validité de l'hypothèse d'homogénéité H_1 pour un segment donné s de la configuration, nous considérons l'ensemble de pixels V correspondant à s dans l'image, qui est composé d'un nombre fixé n_b de bandes correspondant à la largeur (fixe) du réseau recherché comme cela est illustré en figure 4. Considérant les valeurs des pixels de chaque région comme un échantillon d'une population, un t-test de Student est utilisé pour déterminer si les moyennes de niveau de gris sur deux bandes distinctes sont significativement différentes. La valeur statistique utilisée pour évaluer l'homogénéité de s est alors le maximum des t-tests entre deux bandes internes :

$$T_1(s) = \max_{j, k \in \{1, \dots, n_b\}, j \neq k} [ttest(b_j, b_k)]$$

Notons que, si le réseau présent dans l'image ne fait qu'un pixel de largeur, ce test ne pourra pas être effectué et la valeur 1 sera assignée à $T_1(s)$.

Deux bandes externes colinéaires à ce segment s sont ensuite considérées pour l'évaluation de la validité de l'hypothèse de contraste H_2 . Afin de permettre une légère variabilité de la largeur du réseau, celles-ci se situent à une

distance d (fixée) de V comme le montre la figure 4. La valeur choisie pour ce test est le minimum des t-tests entre V et chacune des bandes externes :

$$T_2(s) = \min_{l \in \{1,2\}} [t_{est}(R_l, V)]$$

Ces deux hypothèses sont évaluées conjointement à partir du rapport entre les valeurs T_1 et T_2 , avec la condition que T_1 soit supérieure à 1 pour ne pas favoriser excessivement les régions très homogènes. On a donc :

$$t_s = \frac{T_2(s)}{\max[1, T_1(s)]}$$

Nous procédons ensuite à un seuillage empirique de t_s et une conversion de $[0, \infty]$ vers $[-1, 1]$ de cette valeur statistique pour obtenir le potentiel correspondant au segment s :

$$g_d(s) = \begin{cases} 1, & \text{si } t_s < S_1 \\ 1 - 2 \frac{t_s - S_1}{S_2 - S_1}, & \text{si } S_1 < t_s < S_2 \\ -1, & \text{si } t_s > S_2 \end{cases}$$

L'énergie d'attache U_d aux données est alors la somme des potentiels associés à chacun des segments de la configuration S multipliée par un poids positif ω_d traduisant le degré de confiance accordé aux données. Ceci définit complètement le terme d'attache aux données :

$$h_d(S) \propto \exp - \underbrace{\omega_d \sum_{s \in S} g_d(s)}_{U_d}$$

Nous avons donc construit un terme d'attache aux données reposant sur des hypothèses à la fois réalistes et assez générales pour représenter différents types de réseaux. Celles-ci sont évaluées de façon fiable puisque les tests statistiques utilisés sont particulièrement adaptés à des problèmes d'inférence fondés sur de petits échantillons (ce qui est notre cas lorsque les segments considérés sont de petite taille).

Cependant, cela reste très coûteux en temps de calcul dans le cas où un calcul est fait à chaque proposition d'un nouvel élément, l'algorithme d'optimisation proposé au chapitre 3 n'ayant pas de mémoire et nécessitant souvent quelques millions de propositions de nouveaux éléments. Nous proposons donc de réaliser un pré-calcul des potentiels pour des segments de longueur minimale, positionnés en chaque pixel de l'image, pour un nombre fixé d'orientations. Pour chaque orientation de cet espace discrétisé, nous assignons à chaque pixel p de l'image le potentiel du segment de cette orientation contenant p qui répond le mieux aux tests statistiques (\equiv potentiel minimal). Pour un segment s d'orientation θ de la configuration S , le potentiel d'attache aux données est défini par la somme des valeurs pré-calculées

(pour l'orientation $\tilde{\theta}$ de l'espace discrétisé la plus proche de θ) sur l'ensemble V des pixels correspondant à s :

$$\tilde{g}_d(s) = \sum_{p \in V} \min_{s' \in C_{\tilde{\theta}} / p \in s'} [g_d(s')]$$

où $C_{\tilde{\theta}}$ correspond à l'ensemble des segments d'orientation $\tilde{\theta}$ et de longueur minimale. L'expression du terme d'attache aux données est finalement la même que précédemment en remplaçant g_d par \tilde{g}_d . Notons que cette méthodologie est moins précise que la précédente puisqu'une seule longueur de segment est considérée pour les tests statistiques et que l'on doit souvent se résoudre à un petit nombre d'orientations pour espérer gagner nettement en temps de calcul. Néanmoins, cette méthode peut s'avérer très efficace si l'on y associe un noyau de proposition pertinent comme cela est décrit dans le chapitre suivant.

3. Optimisation

3.1. Optimisation par recuit simulé

Afin d'extraire le réseau linéique à partir de l'image dont nous disposons, nous cherchons une configuration qui maximise la densité f du processus définie dans les paragraphes précédents. C'est un problème non convexe dont l'optimisation directe est impossible du fait de la grande taille de l'espace d'état Ω , défini par :

$$\Omega = \bigcup_{i=0}^{\infty} \Omega_i$$

où Ω_i est l'ensemble des configurations composé de i segments positionnés dans le compact de \mathfrak{R}^2 correspondant à la zone observée et dont les longueurs et orientations sont des variables définies dans $[L_{\min}, L_{\max}] \times [0, 2\pi]$.

Nous proposons donc d'estimer ce maximum en utilisant un recuit simulé. Cet algorithme permet d'accéder aux pics de la densité en simulant successivement des processus définis par la densité f à la puissance $1/T$, la « température » T diminuant pas à pas vers zéro. Les simulations successives sont réalisées par l'algorithme d'échantillonnage décrit dans le paragraphe suivant. Au début de l'algorithme (température élevée), le processus se rapproche du processus uniforme : il n'est donc pas très sélectif. Cela permet de passer d'un mode à l'autre de la densité assez facilement. Plus la température diminue, plus les configurations ayant une densité élevée sont favorisées. Enfin, pour une température nulle la densité du processus correspond à des diracs au niveau des maxima globaux de la densité.

Une preuve de convergence est donné dans [Lieshout, 1993] pour une décroissance logarithmique de la température T , mais en pratique nous utilisons une décroissance géométrique afin d'accélérer la convergence de l'algorithme.

3.2. Algorithme d'échantillonnage

L'échantillonnage des distributions des processus spécifiés par une densité non normalisée $f^{1/T}$ est réalisé par un algorithme de type Monte Carlo par chaîne de Markov (MCMC). En effet, les méthodes MCMC permettent de simuler à partir d'une distribution π connue à un facteur constant près (constante de normalisation inconnue). Leur principe est le suivant : on construit une chaîne de Markov discrète $\{S_t\}$ ayant un espace d'état Ω et une distribution stationnaire π . La chaîne est conçue pour être ergodique, c'est-à-dire que la distribution de probabilité sur Ω converge asymptotiquement vers π indépendamment de l'initialisation. De plus, ses transitions correspondent à des perturbations simples de structures sur Ω et sont donc simples à simuler. Nous pouvons donc échantillonner selon π de la façon suivante : partir d'un d'état arbitraire dans Ω , simuler la chaîne pendant un nombre d'itérations N suffisamment grand. A partir de N , les échantillons successifs sont distribués suivant une loi proche de π . Il est important de noter que cet algorithme itératif ne dépend pas de l'état initial : l'initialisation du recuit simulé pourra donc être la configuration vide.

Rappelons que la distribution π d'un processus Markov objet est définie sur un espace d'état Ω de dimension variable, le nombre d'objets étant une variable aléatoire. La chaîne de Markov $\{S_t\}$ est donc construite de façon à pouvoir réaliser de petits sauts entre les espaces Ω_i . L'algorithme choisi est alors de type Monte Carlo par chaîne de Markov à sauts réversibles suivant une dynamique de Metropolis-Hasting-Green [Green, 1995 ; Robert, 1996]. A chaque itération, une transition de l'état courant S vers un nouvel état S' est proposée suivant un noyau de proposition Q (défini dans la partie 3.3.). La transition est acceptée avec une probabilité $\alpha(S, S')$. Celle-ci est calculée de façon à vérifier la réversibilité de la chaîne (condition d'équilibre minutieux) qui implique la stationnarité et permet ainsi la convergence vers la mesure stationnaire de la chaîne π .

La condition d'équilibre minutieux est donnée par l'équation suivante :

$$\int_A \int_B \pi(dS)P(S, dS') = \int_B \int_A \pi(dS')P(S', dS)$$

où A et B sont deux boréliens quelconques de Ω et P le noyau de transition de la chaîne (défini à partir du noyau de proposition Q et de la probabilité d'acceptation α). Pour vérifier cette condition, il suffit de vérifier que :

$$\int_A \int_B \pi(dS)Q(S, dS')\alpha(S, S') = \int_B \int_A \pi(dS')Q(S', dS)\alpha(S', S)$$

En supposant que πQ ait une densité finie D par rapport à une mesure symétrique sur $\Omega \times \Omega$, cette condition peut s'écrire sous la forme :

$$\alpha(S, S')D(S, S') = \alpha(S', S)D(S', S)$$

Une solution est alors de poser $\alpha(S, S') = \min\{1, R(S, S')\}$ où $R(S, S')$ (taux de Green) est défini comme le rapport suivant :

$$R(S, S') = \frac{D(S', S)}{D(S, S')}$$

3.3. Noyau de proposition

Un point intéressant de cet algorithme est que le noyau de proposition Q peut être décomposé en plusieurs sous-noyaux, chacun correspondant à un mouvement réversible (afin que le calcul du taux de Green soit rendu possible) comme cela a été initialement proposé dans [Green, 1995]. En effet, bien qu'il soit suffisant de définir un noyau de type « naissance et mort » uniforme [Robert, 1996] (c'est-à-dire ajout ou suppression aléatoire d'un segment dans la configuration), il est important de définir des transformations pertinentes pour accélérer la convergence de la chaîne de Markov. Par exemple, un mouvement simple d'un segment sera plus efficace qu'une mort suivi d'une naissance, surtout vers la fin de l'optimisation (le réseau est alors déjà bien positionné dans l'espace : les petites perturbations du réseau sont alors très pertinentes). Ainsi nous définissons trois transformations symétriques de ce type : rotation, translation et modification de la longueur d'un segment. De plus, étant donné que les segments du réseau sont supposés être connectés, nous avons introduit une « naissance et mort » dans un voisinage par rapport à la relation de connexion. Plus précisément, la naissance consiste à choisir aléatoirement une extrémité e de segment dans la configuration, à proposer une extrémité du nouveau segment dans la boule de rayon ε et de centre e et de générer la longueur et l'orientation de ce nouveau segment de façon uniforme dans $[L_{\min}, L_{\max}] \times [0, 2\pi]$. La mort associée consiste à retirer un segment de la configuration, uniformément parmi les segments connectés de la configuration. Le calcul du taux de Green correspondant est donné dans [Lacoste, Descombes, Zerubia, 2002]. Ces cinq premiers sous-noyaux définissent le noyau 1, utilisé pour chacune des applications présentées dans le chapitre 4.

Enfin, le pré-calcul des potentiels de l'attache aux données peut être combiné à une « naissance et mort » non homogène. En effet, il suffit de stocker pour chaque pixel et chaque orientation de la discrétisation, le potentiel correspondant au segment dont le centre est positionné en ce pixel. Nous obtenons ainsi, pour chaque orientation, une carte qui correspond à une naissance non homogène : plus le potentiel associé à un pixel sera faible, plus la probabilité de proposer le centre d'un segment à l'intérieur de ce pixel sera forte. La procédure est alors la suivante : la longueur et l'orientation du nouveau segment sont tirées uniformément dans l'espace des marques ($[L_{\min}, L_{\max}] \times [0, \pi]$) ; le centre du segment est alors tiré selon la carte correspondant à l'orientation la plus proche. Pour la mort, un segment est

retiré uniformément de la configuration. Notons que cette différence de symétrie est contrebalancée par le taux de Green qui dépend de la carte correspondant à l'orientation la plus proche du segment considéré. Ce dernier sous-noyau vient s'ajouter au cinq premiers pour former le noyau 2, utilisé dans le cas où nous procédons à un pré-calcul de l'attache aux données.

4. Résultats

4.1. Evaluation quantitative

Afin de mieux comparer les résultats fournis par différents algorithmes, il est important de définir des mesures de performances quantitatives par rapport à un réseau de référence (extraction manuelle, vérité terrain ou carte géographique), comme cela est proposé dans [Harvey, 1999 ; Sampère, 2001]. De plus, ces mesures quantitatives peuvent être intégrées dans un système de mise à jour cartographique automatique. Par exemple, dans [Hivernat et al., 1999], une qualification automatique des résultats permet d'améliorer itérativement la qualité d'une mise en correspondance entre un réseau routier issu d'une carte et un réseau extrait d'une image satellitaire, avant de fournir des informations utiles pour la mise à jour cartographique.

Pour chacun des résultats présentés dans les paragraphes suivants, nous proposons une évaluation quantitative des résultats par rapport à un réseau de référence extrait manuellement. Les segments fournis par notre algorithme sont mis en correspondance avec les branches de la référence (fournie sous forme de lignes brisées). Un segment est apparié à la référence si chacune de ces extrémités est à une distance du réseau de référence inférieure à un seuil fixé par l'utilisateur (on pourra prendre, par exemple, un seuil égal à dix pixels). Cet appariement est illustré par la figure 5. Cela permet le calcul de la longueur des tronçons omis, de celle des branches ne correspondant pas à la réalité et d'une distance entre les tronçons appariés, égale à l'aire comprise entre ces tronçons divisée par la longueur des tronçons de la référence qui ont été appariés. Les trois critères d'évaluation du réseau extrait sont les pourcentages d'omission et de sur-détection par rapport à la longueur totale du réseau de référence, et une erreur géométrique correspondant à la distance entre les tronçons appariés ainsi calculée.

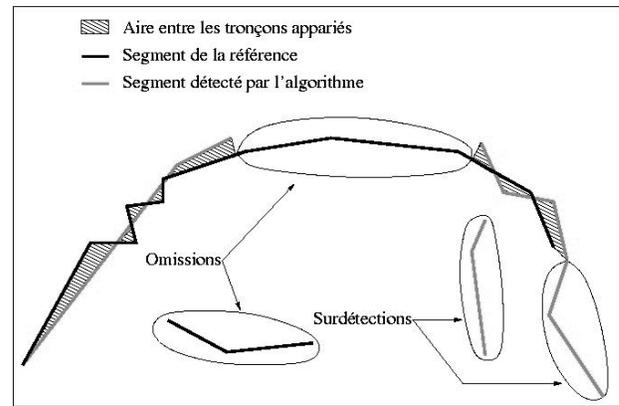


Figure 5 : Mise en correspondance du réseau extrait par l'algorithme avec le réseau de référence

4.2. Extraction du réseau routier

Nous avons tout d'abord appliqué notre méthode d'extraction non supervisée du réseau linéaire au cas le plus largement étudié dans la littérature, celui de l'extraction du réseau routier. Ce type de réseau se caractérise généralement par une faible courbure, de longues branches bien distinctes, continues et reliées entre elles. Le modèle *a priori* que nous avons défini dans le paragraphe 2.2 semble donc bien adapté à ce type de détection, grâce à une pénalisation des segments non connectés ou connectés qu'à une seule de leurs extrémités, une favorisation des segments connectés à angle large de façon continue et une pénalisation des segments proches dont l'orientation est similaire.



Figure 6 : Image aérienne de la région d'Altkirch en Alsace (1784x1304 pixels, résolution : 50 cm)

L'image sur laquelle a été réalisée l'extraction est une image aérienne de la région d'Altkirch en Alsace fournie par l'IGN et présentée en figure 6. La haute résolution de cette image (50 cm) induit un bruit géométrique, beaucoup plus difficile à prendre en compte dans les modèles pixéliques usuels que les bruits provenant du capteur. En effet, certains arbres interfèrent avec la bonne détection de certaines portions de

route ; certains champs sont de même niveau de gris que les routes ; et les textures de certains champs répondent aux tests statistiques définis dans le paragraphe 2.3. On voit là tout l'intérêt d'avoir un bon a priori.

Nous avons testé sur cette image les deux techniques de calcul de l'attache aux données : l'une sans pré-calcul, supposée fournir un résultat plus précis, et l'autre reposant sur le pré-calcul décrit en 2.3. Chacun de ces modèles a tout d'abord été optimisé par le même algorithme d'optimisation dont le noyau de proposition est le noyau 1 donné dans le chapitre précédent et constitué d'une « naissance et mort » homogène, de mouvements simples (rotation, translation, dilatation), et d'une « naissance et mort » dans un voisinage. Dans le cas d'un pré-calcul de l'attache aux données, nous pouvons définir une « naissance et mort » non homogène construite sur ce pré-calcul. Nous avons donc ensuite utilisé, dans ce cas, le noyau 2, composé des transformations du noyau 1 et de la « naissance et mort » non homogène, pour l'optimisation de la densité.

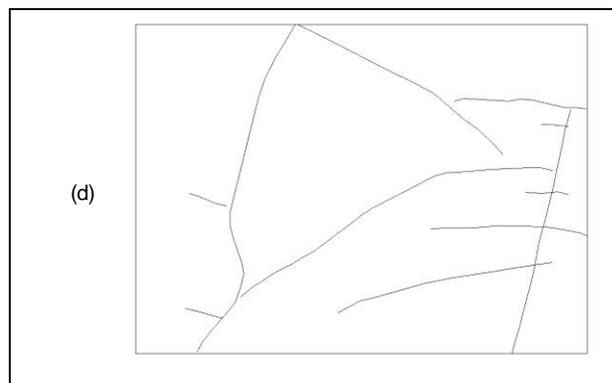
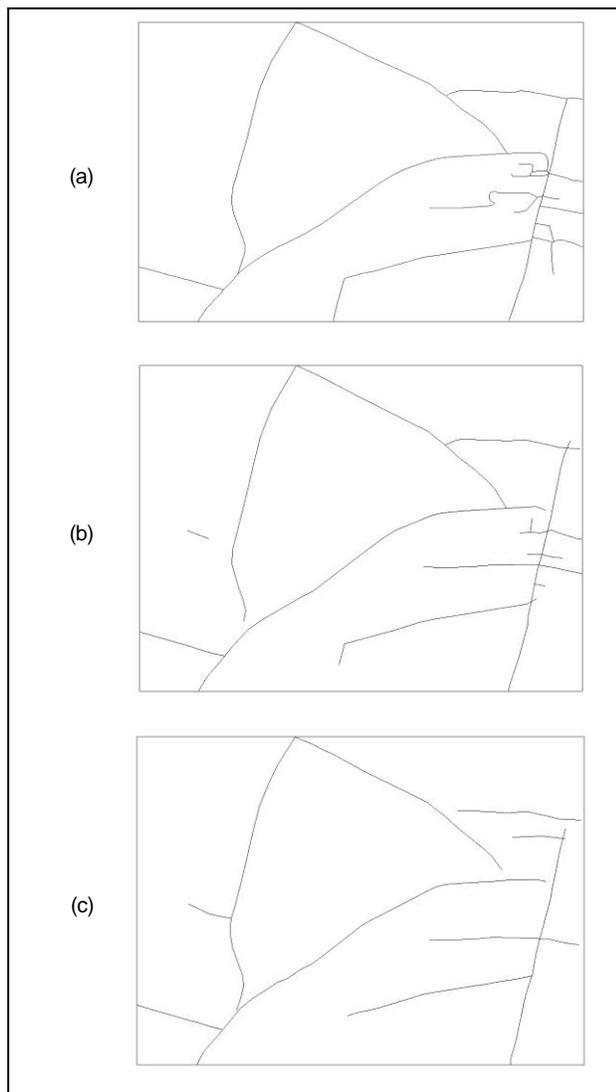


Figure 7 : Résultats de l'extraction sur une image aérienne (Figure 6) - (a) Référence (extraction manuelle) - (b) Réseau obtenu sans pré-calcul, avec le noyau 1 - (c) Réseau obtenu avec pré-calcul, avec le noyau 1 - (d) Réseau obtenu avec pré-calcul, avec le noyau 2.

Les réseaux extraits par les trois méthodologies ainsi que le réseau de référence extrait manuellement sont donnés en figure 7, le tableau 1 donne l'évaluation quantitative correspondante et le tableau 2 les temps de calcul. Les résultats sont globalement très satisfaisants en terme de sur-détection et de précision : nous obtenons moins de 5% de sur-détection dans les trois cas et les branches bien détectées sont à une distance moyenne du réseau de l'ordre de deux ou trois pixels. Cependant, nous observons un taux d'omission important : de l'ordre de 16% pour le cas sans pré-calcul et plus de 20% dans les deux autres cas. La figure 7 révèle que se sont en majorité les routes secondaires qui ont été omises. Cela peut s'expliquer par le fait que ces routes sont courtes et d'une courbure plus importante qu'au niveau des grands axes routiers, ce qui ne correspond pas au modèle *a priori* choisi. Remarquons aussi que la détection est difficile au niveau des intersections à angle aigu : ceci est dû à la pénalisation de la relation de proximité, à laquelle vient s'ajouter une mauvaise réponse aux tests statistiques mesurant le contraste avec le fond et l'homogénéité interne dans certaines zones de croisements de routes présentes dans cette image. Comparativement, c'est le modèle sans pré-calcul qui donne les meilleurs résultats mais le temps de calcul est relativement important : 23 minutes contre 19 minutes avec pré-calcul et le même noyau, et seulement 14 minutes quand nous ajoutons la naissance selon les cartes pré-calculées. Dans le cas d'un pré-calcul, ces résultats montrent qu'il est très intéressant d'utiliser le pré-calcul de l'attache aux données pour proposer de façon pertinente la naissance d'un segment puisque les résultats (c) et (d) sont d'une qualité équivalente à la fois visuellement et quantitativement.

	(b)	(c)	(d)
Omission	704 m 16.2 % de (a)	1028 m 23.7 % de (a)	965 m 22.3 % de (a)

Surdétection	152 m 3.5 % de (a)	194 m 4.5 % de (a)	131 m 3.0 % de (a)
Distance	0.8 m ~1.6 pixels	1.6 m ~ 3.2 pixels	1.7 m ~ 3.3 pixels

Tableau 1 : Evaluation quantitative des réseaux extraits (Figure 7) par rapport à la référence

	(b)	(c)	(d)
Pré-calculs (min)	0	8	8
Recuit simulé (min)	23	11	6
Temps de calcul total (min)	23	19	14

Tableau 2 : Temps de calcul de l'extraction du réseau routier (Figure 7)

4.3. Extraction du réseau hydrographique

Nous présentons enfin les résultats de l'algorithme proposé sur une image satellitaire SPOT (de résolution 20 m) de la Guinée-Conakry fournie par le BRGM, où l'item cartographique recherché est le réseau hydrographique. Ce dernier est repérable par les arbres présents au niveau des rives des rivières, d'où l'appellation de forêts galeries. L'image traitée est donnée en figure 8. De même que pour l'image précédente, nous disposons sur cette image d'une référence sous forme de lignes brisées, extraite manuellement par un expert du BRGM.

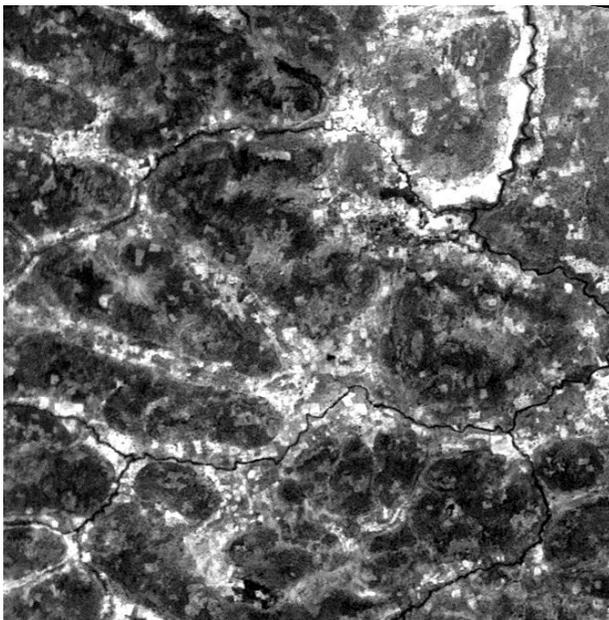


Figure 8 : Image SPOT de la Guinée-Conakry (674 × 682 pixels, résolution : 20 m)

Les résultats pour chacune des trois méthodologies sont donnés dans la figure 9 et l'évaluation quantitative dans le tableau 3. Les résultats sont prometteurs puisque nous obtenons un réseau continu, avec des taux de surdétection et d'omission inférieurs à quinze pour cent malgré la difficulté de l'image (présence de zones peu contrastées, réseau très sinueux). Cependant, l'effet de lissage du potentiel de la clique de connexion, très utile dans le cas de l'extraction du réseau routier, présente ici un inconvénient puisque cela fournit un réseau moins sinueux que la vérité terrain. Ici, tous les résultats sont de qualité équivalente mais le temps de calcul, donné par le tableau 4, est nettement plus faible dans le cas d'un pré-calcul. Cela peut s'expliquer par le fait que la longueur moyenne d'un segment est très proche de la longueur minimale utilisée pour le pré-calcul. L'approximation est donc beaucoup moins grossière que dans le cas de la première application.

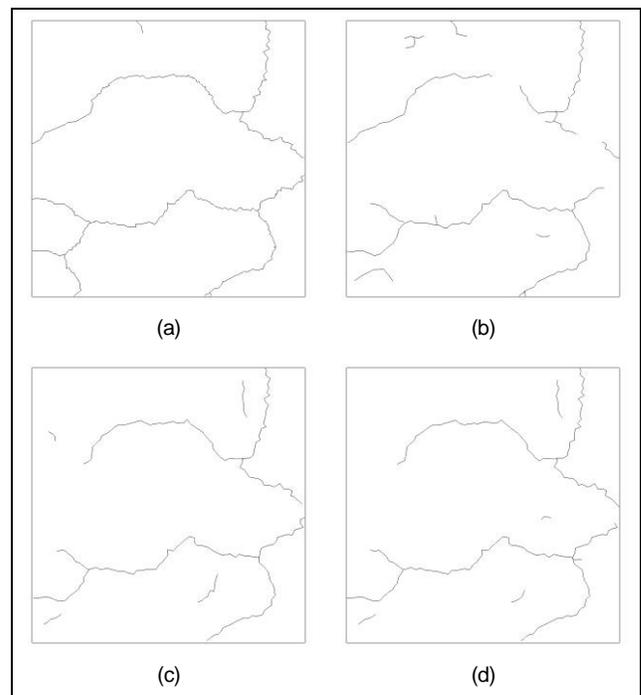


Figure 9 : Résultats de l'extraction sur une image SPOT (Figure 8) - (a) Référence (extraction manuelle) - (b) Réseau obtenu sans pré-calcul, avec le noyau 1 - (c) Réseau obtenu avec pré-calcul, avec le noyau 1 - (d) Réseau obtenu avec pré-calcul, avec le noyau 2

	(b)	(c)	(d)
Omission	7605 m 13.2 % de (a)	8935 m 15.5 % de (a)	7988 m 13.9 % de (a)
Surdétection	5342 m 9.3 % de (a)	5460 m 9.5 % de (a)	5021 m 8.7 % de (a)

Distance	25.1 m ~1.3 pixels	27.4 m ~ 1.4 pixels	26.9 m ~ 1.3 pixels
----------	-----------------------	------------------------	------------------------

Tableau 3 : Evaluation quantitative des réseaux extraits (Figure 9) par rapport à la référence

	(b)	(c)	(d)
Pré-calculs (min)	0	3	3
Recuit simulé (min)	40	11	5
Temps de calcul total (min)	40	14	8

Tableau 4 : Temps de calcul de l'extraction des forêts galeries (Figure 9)

5. Conclusion et perspectives

Nous avons proposé dans cet article une méthode d'extraction du réseau linéique sous forme de vecteurs, complètement automatique, à partir d'images aériennes ou satellitaires. Le modèle *a priori* « *Quality Candy* » est particulièrement approprié au cas de l'extraction du réseau routier. En effet, l'utilisation de coefficients relatifs à la qualité pour la relation de connexion conduit à l'obtention d'un réseau de faible courbure et continu. Ce modèle s'adapte de façon encourageante au cas des réseaux plus sinueux comme cela a été montré par les résultats obtenus sur les forêts galeries. De plus, le terme d'attache aux données proposé peut être utilisé pour différents types de données. L'optimisation a été réalisée par un recuit simulé grâce à un algorithme de type Monte Carlo par chaîne de Markov à sauts réversibles, reposant sur un noyau de proposition construit de façon à accélérer la convergence de l'algorithme par l'ajout de perturbations allant dans le sens du modèle. Les résultats ont montré l'intérêt d'utiliser un pré-calcul de l'attache aux données en terme d'efficacité, notamment lorsqu'il est combiné avec une naissance dépendant de ce pré-calcul. Une légère perte en qualité est cependant observée lors de l'utilisation de ce pré-calcul.

Cette modélisation stochastique nous permet d'envisager de travailler dans un cadre de fusion de données et donc de bénéficier de l'apport de plusieurs sources (données multi-capteurs, multi-bandes, ou multi-dates) afin d'améliorer la qualité du réseau extrait par l'algorithme. Nous envisageons également d'étendre cette modélisation à des objets plus complexes tels que les lignes brisées qui s'adaptent plus facilement au cas des réseaux sinueux. A plus long terme, nous prévoyons une modélisation complète de la scène observée, via l'introduction de différents types d'objets dans le modèle, correspondant par exemple aux routes, rivières, maisons et arbres présents dans l'image.

Remerciements

Les auteurs souhaitent remercier H. Le Men de l'IGN pour la fourniture de l'image aérienne présentée dans cet article ainsi que ses commentaires sur l'évaluation des résultats. Le premier auteur remercie le BRGM pour un soutien financier partiel de sa thèse.

Références

- M. Barzohar et D.B. Cooper (1996), Automatic finding of main roads in aerial images by using geometric-stochastic models and estimation, *IEEE trans. PAMI*, vol. 18, pp.707-721.
- A. Baumgartner, C. Steger, C. Wiedmann, H. Mayer, W. Eckstein et H. Ebner (1996), Update of roads in GIS from aerial imagery: verification and multiresolution extraction, *Archives of Photogrammetry and Remote Sensing*, vol. 31, N° 3, pp. 53-58.
- R.O. Duda et P.E Hart (1973), *Pattern Classification and Scene Analysis*, John Wiley & Sons, NY, USA.
- M.A. Fischler, J.M. Tenenbaum et H.C. Wolf (1981), Detection of roads and linear structures in low-resolution aerial imagery using a multisource knowledge integration technique, *Computer Graphics and Image Processing*, vol. 15, pp. 201-223.
- D. Geman et B. Jedynek (1996), An active testing model for tracking roads in satellite images, *IEEE trans. PAMI*, vol.18, pp.1-14.
- C. Graffigne et I. Herlin (1989), Modélisation de Réseaux pour l'imagerie Satellite SPOT, *7eme Congrès de Reconnaissance des Formes et Intelligence Artificielle*, Paris.
- P.J. Green (1995), *Reversible Jump Markov Chain Monte-Carlo Computation and Bayesian Model Determination*, *Biometrika*, vol. 57, pp. 97-109.
- W. A. Harvey (1999), Performance evaluation for road extraction, *Bulletin SFPT*, N° 153, pp. 79-87.
- C. Heipke, C. Steger et R. Multhammer (1995), A hierarchical approach to automatic road extraction from aerial imagery, *Photogrammetric Techniques with Scene Analysis and Machine Vision II*, D.M. McKeown et I.J. Dowman Ed., *Proc. SPIE*, N° 2486, pp. 222-231.
- C. Hivernat, S. Randriamasy, X. Descombes et J. Zerubia (1999), Qualification automatique des résultats d'une mise en correspondance de réseaux routiers en vue de la mise à jour cartographique, *Bulletin SFPT*, N° 153, pp. 91-93.
- C. Lacoste, X. Descombes et J. Zerubia (2002), A Comparative study of point processes for line network extraction in remote sensing, Rapport de Recherche INRIA, N°4516, http://www-sop.inria.fr/ariana/personel/Caroline.Lacoste/rr_02.ps.gz.

I. Laptev, T. Lindeberg, W. Eckstein, C. Steger et A. Baumgartner (2000), Automatic extraction of roads from aerial images based on scale space and snakes, *Machine Vision and Applications*, vol. 12, N° 153, pp. 23-31.

M.N.M. van Lieshout (1993), Stochastic annealing for nearest-neighbour point processes with application to object recognition, Rapport de Recherche, N° BS-R9306, CWI, Pays-Bas.

N. Merlet et J. Zerubia (1996), New prospects in line detection by dynamic programming, *IEEE trans. PAMI*, vol. 18, N° 4, pp. 426-431.

W. M. Neuenschwander, P. Fua, L. Iverson, G. Székely et O. Kubler (1997), Ziplock snakes, *International Journal of Computer Vision*, vol. 25, N° 3, pp. 191-201.

C. Robert (1996), *Simulations de Monte-Carlo par Chaînes de Markov*, Economica.

J.-P. Sampère (2001), Evaluation de l'utilisation de données supermode SPOT5 pour la mise à jour de BD IGN, *Bulletin SFPT*, N° 164, pp. 96-105.

M. A. Serendero (1989), *Extraction d'informations symboliques en imagerie SPOT : réseaux de communication et agglomérations*, Thèse de Doctorat, Université de Nice Sophia-Antipolis

R. Stoica (2001), *Processus ponctuels pour l'extraction des réseaux linéiques dans les images satellitaires et aériennes*, Thèse de Doctorat, Université de Nice Sophia-Antipolis.

F. Tupin, H. Maitre, J.-F. Mangin, J.-M. Nicolas et E. Pechersky (1998), Detection of linear features in SAR images: Application to road network extraction, *IEEE Trans. on Geoscience and Remote Sensing*, vol. 36, N° 2, pp. 434-453.