

Extraction de réseaux linéiques à partir d’images satellitaires par processus Markov objet

Caroline LACOSTE¹, Xavier DESCOMBES¹, Josiane ZERUBIA¹, Nicolas BAGHDADI²

¹ARIANA, projet commun CNRS/INRIA/UNSA
INRIA Sophia Antipolis, 2004 route des Lucioles, BP 93, 06902 Sophia Antipolis cedex, France

²BRGM
3 avenue Claude-Guillemain, BP 6009, 45060 Orléans, France
Caroline.Lacoste@inria.fr, Xavier.Descombes@inria.fr, Josiane.Zerubia@inria.fr,
n.baghdadi@brgm.fr

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 satellitaires. Nous modélisons le réseau linéique présent dans l’image par un processus Markov objet. La densité de ce processus a été construite de façon à exploiter au mieux la topologie du réseau recherché et les propriétés radiométriques des données. Un algorithme de type Monte Carlo par chaînes de Markov à sauts réversibles est proposé pour l’optimisation. Les résultats expérimentaux obtenus pour différentes images révèlent la capacité du modèle à fournir un réseau continu, avec de faibles taux d’omissions et de fausses alarmes.

Abstract – This paper presents a method of unsupervised extraction of line networks, such as road networks or hydrographical networks, from satellite images. A line network is modeled by a Markov object process. The process density is built so that the topology of the considered line network and the radiometric properties of data is exploited as far as possible. Optimization is realized by simulated annealing using a reversible jump Monte Carlo Markov chain algorithm. Experimental results on satellite images show the ability of the model in providing continuous line network, with low rates of omissions and false alarms.

1 Introduction

L’étendue des surfaces à cartographier et les délais de mise à jour font de l’extraction des réseaux linéiques à partir d’images satellitaires un enjeu important. De nombreuses méthodes ont été développées pour répondre à ce problème difficile, notamment pour le cas particulier des réseaux routiers. Une première catégorie de méthodes propose une optimisation locale, reposant par exemple sur des détections de contours [5] ou des opérateurs morphologiques [11]. L’inconvénient majeur de ces techniques est leur sensibilité au bruit. Nous nous sommes donc intéressés au second type de méthodes qui reposent sur une optimisation globale, comme la programmation dynamique dans [1, 2], les contours actifs dans [8, 10], ou des stratégies issues de la théorie des jeux [3]. La plupart de ces méthodes sont semi-automatiques : un opérateur doit fournir des points de contrôle. Le gain de productivité apporté par ces méthodes est faible par rapport au travail d’extraction mené par un expert. Un autre choix consiste à initialiser l’algorithme par une première détection obtenue par une optimisation locale, comme par exemple dans [13] où une détection non supervisée de structures linéaires initialise un algorithme d’optimisation globale fondé sur une modélisation par champs de Markov sur graphe. Mais cela est très sensible à la qualité de la pré-détection. Afin de définir un algorithme complètement automatique, ne reposant pas sur la combinaison de plusieurs traitements sur l’image considérée, nous proposons une modélisation du réseau linéique par un processus Markov objet, c’est-à-dire une configuration aléatoire d’objets (qui sont ici des segments) dont le nombre est

lui-même une variable aléatoire. En effet, les modèles liés à ce type de processus [14] permettent de bénéficier des propriétés des approches stochastiques, du type champs de Markov, tout en manipulant des contraintes géométriques fortes. Outre les contraintes topologiques du réseau intégrées dans le modèle *a priori*, décrit dans le paragraphe 2, les propriétés radiométriques des données sont prises en compte dans un terme d’attache aux données, décrit dans le paragraphe 3. L’optimisation est réalisée par recuit simulé sur un algorithme de type Monte Carlo, explicité dans le paragraphe 4. Enfin, le paragraphe 5 présente les résultats obtenus sur deux types de réseaux : un réseau routier et un réseau hydrographique.

2 Modèle a priori

Nous modélisons le réseau linéique par un processus Markov objet dans lequel les objets sont des segments interagissant entre eux et décrits par trois variables aléatoires correspondant à leur centre, leur longueur et leur orientation. Ce type de processus peut être spécifié par une densité par rapport à un processus de Poisson uniforme. Ce dernier est un processus complètement aléatoire (les points, longueurs et orientations sont uniformément et indépendamment distribués) dont le nombre d’objets présents dans l’image suit une loi de Poisson. Les interactions entre objets distincts sont prises en compte au travers de la densité *a priori* h_p , ce qui nous permet d’injecter des contraintes sur la topologie du réseau. Un premier modèle de ce type, le modèle “Candy”, a été développé par R. Stolica pour

l'extraction du réseau routier [12]. Nous proposons une amélioration de ce modèle, appelée "Quality Candy", 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 [7].

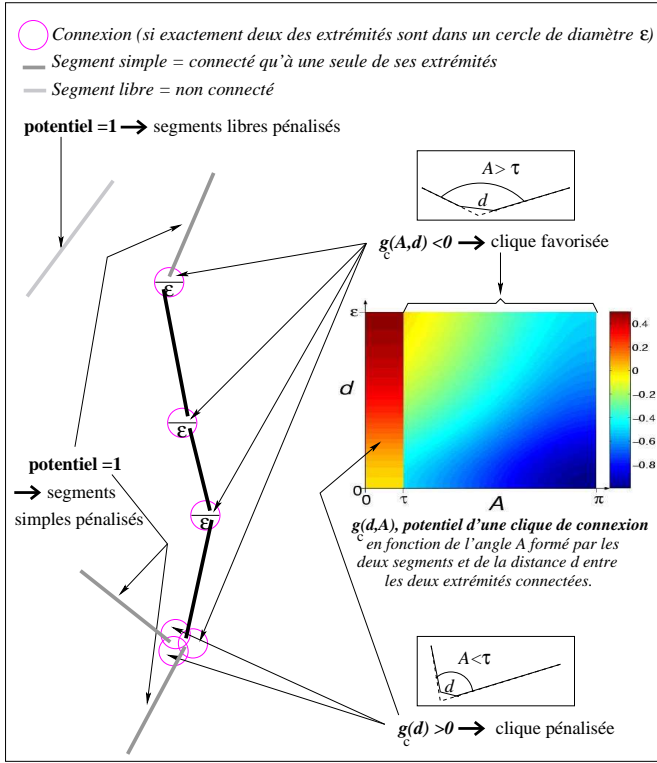


FIG. 1 – Relation de connexion

La première interaction considérée est la connexion de deux segments (définie à une constante ϵ près). La figure 1 décrit cette relation et les potentiels qui y sont associés. Les segments non connectés ou connectés par une seule de leurs extrémités sont pénalisés afin de favoriser un réseau continu. La faible courbure et la proximité des extrémités connectées sont favorisées au travers d'un potentiel associé à chaque clique de connexion, défini à partir d'une fonction mesurant la qualité de la clique considérée.

De plus, une relation de proximité est définie afin d'éviter une agrégation de segments. Le potentiel correspondant aux paires de segments vérifiant cette relation pénalise les segments dont les centres et orientations sont trop proches (potentiel positif) et interdit les segments parallèles trop proches (potentiel infini).

La densité $h_p(S)$, associée à la configuration de segment S , s'écrit alors sous la forme :

$$h_p(S) \propto \beta^n \exp(-\omega_1 n_f - \omega_2 n_s - \omega_3 \sum_{p \in C} g_c(p) - \omega_4 \sum_{p \in O} g_p(p)) \quad (1)$$

où les $\omega_i, i=1..4$ sont des poids positifs, $\beta > 0$ est l'intensité du processus, n le nombre total segments, n_f le nombre de segments libres, n_s le nombre de segments simple, C (resp. O) l'ensemble des paires de segments connectés (resp. en relation de proximité) et g_c (resp. g_p) la fonction de potentiel correspondant à la connexion (resp. la proximité). Cette densité spécifie

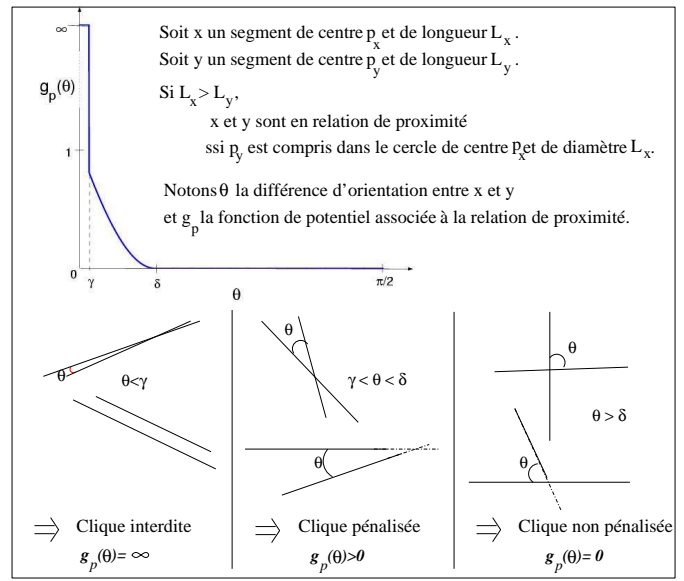


FIG. 2 – Relation de proximité

un processus Markov objet localement stable (cf. [7]), ce qui garantit la convergence ergodique de l'algorithme décrit dans le paragraphe 4.

3 Terme d'attache aux données

Pour le calcul du terme d'attache aux données, nous associons à chaque segment de la configuration un masque de pixels comme le montre la figure 3. Ces masques sont considérés




FIG. 3 – Masque de pixels associé à un segment

en adéquation avec les données si les deux hypothèses suivantes sont vérifiées. Premièrement, la variation de niveau de gris entre l'ensemble de pixels V_i correspondant à un segment s_i et les deux régions adjacentes et colinéaires à ce segment (prises à une distance d fixée de ce segment pour permettre une variation de la largeur du réseau) est importante. Deuxièmement, le niveau de gris de l'ensemble V_i est homogène, ce qui revient à dire que les bandes internes correspondent à des échantillons de même moyenne. Ces deux hypothèses sont évaluées conjointement, à partir de tests de Student entre les différentes régions associées à un segment. Un potentiel δ_i , dépendant directement de la réponse aux tests, est associé à chaque segment. Ceci définit le terme d'attache aux données :

$$h_d(S) \propto \exp(-\gamma_d \sum_{s_i \in S} \delta_i) \quad (2)$$

où γ_d est un poids positif et constant.

4 Optimisation

Afin d'extraire le réseau linéique présent dans les données, nous avons à estimer la configuration de segments qui maximise la densité complète du processus f :

$$\hat{X} = \arg \max_{S \in \bigcup_{n=0}^{\infty} \Omega_n} \underbrace{f(S)}_{h_p(S)h_d(S)} \quad (3)$$

où Ω_n est l'ensemble des configurations composées de n segments et $h_p(S)$, $h_d(S)$ sont données par les équations (1) et (2). L'optimisation se fait par un recuit simulé qui consiste à simuler successivement des processus définis par $f^{1/T}$, T diminuant pas à pas vers zéro. L'algorithme choisi pour simuler les processus Markov objets est un algorithme de type Monte Carlo par chaînes de Markov à sauts réversibles [4, 6, 9], qui consiste à simuler une chaîne de Markov avec une dynamique de Metropolis-Hastings-Green. Cet algorithme itératif ne dépend pas de l'état initial. Le recuit simulé peut donc être initialisé avec la configuration vide. A chaque étape, une perturbation (naissance d'un objet, perturbation d'un objet ...) est proposée selon un noyau de proposition. La perturbation est acceptée avec une probabilité donnée par le taux de Green. Ce taux est calculé de telle sorte que la condition d'équilibre minutieux soit vérifiée, condition sous laquelle l'algorithme converge vers la mesure du processus.

Un point intéressant de cet algorithme est que le noyau de proposition peut se décomposer en plusieurs noyaux, chacun correspondant à un mouvement réversible [6]. Bien qu'il soit suffisant de définir une "naissance et mort uniformes" [4], il est important de définir des perturbations pertinentes pour accélérer la convergence de la chaîne de Markov. Par exemple, nous définissons des petites perturbations comme la translation ou la rotation d'un objet. De plus, nous introduisons un mouvement associé à la relation de connexion (une "naissance et mort dans un voisinage") qui va dans le sens du modèle puisque les objets sont sensés être connectés. Le noyau de proposition choisi est donc composé de cinq noyaux équiprobables : "naissance et mort uniformes", "naissance et mort dans un voisinage", rotation, translation et dilatation.

5 Résultats

Nous avons testé notre modèle sur deux types de réseau : le réseau routier et le réseau hydrographique. L'extraction est réalisée à partir de deux images satellitaires (FIG. 4) pour lesquelles nous disposons d'un réseau de référence extrait manuellement sous forme de vecteurs, ce qui nous permet d'évaluer quantitativement les résultats. Les segments fournis par notre algorithme sont mis en correspondance avec les vecteurs de la référence et permettent une évaluation de la longueur des branches omises, de la longueur des branches correspondant à une surdétection, du rapport R_a entre la longueur L_a^d des segments détectés qui ont été appariés avec des branches du réseau de référence et la longueur L_a^v des ces branches, des longueurs appariées ainsi qu'une distance D_a entre les branches appariées définie à partir de l'aire comprise entre ces branches. Le tableau 1 fournit ces quantités.

La première image (FIG. 4(a)) est une image SPOT Panchro (256 × 256 pixels) de 10 m de résolution comprenant un réseau

TAB. 1 – Évaluation quantitative de l'extraction (FIG. 4)

	Réseau 1 (c)	Réseau 2 (f)
Référence	9.8 km	57.6 km
Détection	11.2 km	51.9 km
Omissions	0.4 km ~ 4.5 %	7.9 km ~ 13.7 %
Surdétections	2.0 km ~ 20.1 %	5.5 km ~ 9.6 %
R_a	$L_a^d \sim 98.1\% L_a^v$	$L_a^d \sim 93.4\% L_a^v$
D_a	10 m ~ 1.0 pixels	30 m ~ 1.5 pixels

routier. Les routes principales sont rectilignes et contrastent nettement avec le fond de l'image. Par contre, le réseau secondaire est sinueux et certaines parties présentent un très faible contraste (l'extraction manuelle en est rendue délicate). Le résultat, obtenu en moins de 5 minutes avec un processeur pentium de puissance 1 GHz, correspond à un réseau continu et avec un taux d'omissions inférieur à cinq pour cent mais aussi un taux de surdétection de l'ordre de vingt pour cent. Ces importantes surdétections sont à modérer par le fait que l'image présente effectivement des structures linéiques au niveau de ces surdétections. Peut-être est-ce la référence qui comporte des omissions? Une évaluation fondée sur plusieurs extractions manuelles aurait sans doute été meilleure.

La deuxième image (FIG. 4(b)) est une image SPOT XS2 (674 × 682 pixels) de 20 m de résolution de la Guinée-Conakry 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". Les résultats (obtenus en 40 minutes) 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.

6 Conclusion

Nous avons proposé une méthode d'extraction complètement automatique des réseaux linéiques à partir d'images satellitaires. Le modèle proposé est particulièrement approprié au cas du réseau routier : le potentiel sur la relation de connexion nous permet d'obtenir un réseau de faible courbure et continu. Ce modèle s'adapte aussi au cas des réseaux plus sinueux de façon encourageante. L'optimisation a été réalisée par un algorithme de type Monte Carlo, construit de façon à accélérer la convergence de l'algorithme par l'ajout de perturbations pertinentes. Cette modélisation stochastique nous permet d'envisager de travailler dans un cadre de fusion de données afin d'améliorer la qualité du réseau extrait. De plus, nous prévoyons d'étendre cette modélisation à d'autres objets plus complexes tels que les lignes brisées qui s'adaptent mieux au cas sinueux.

Références

- [1] M. Barzohar et D. B. Cooper. Automatic finding of main roads in aerial images by using geometric-stochastic mo-

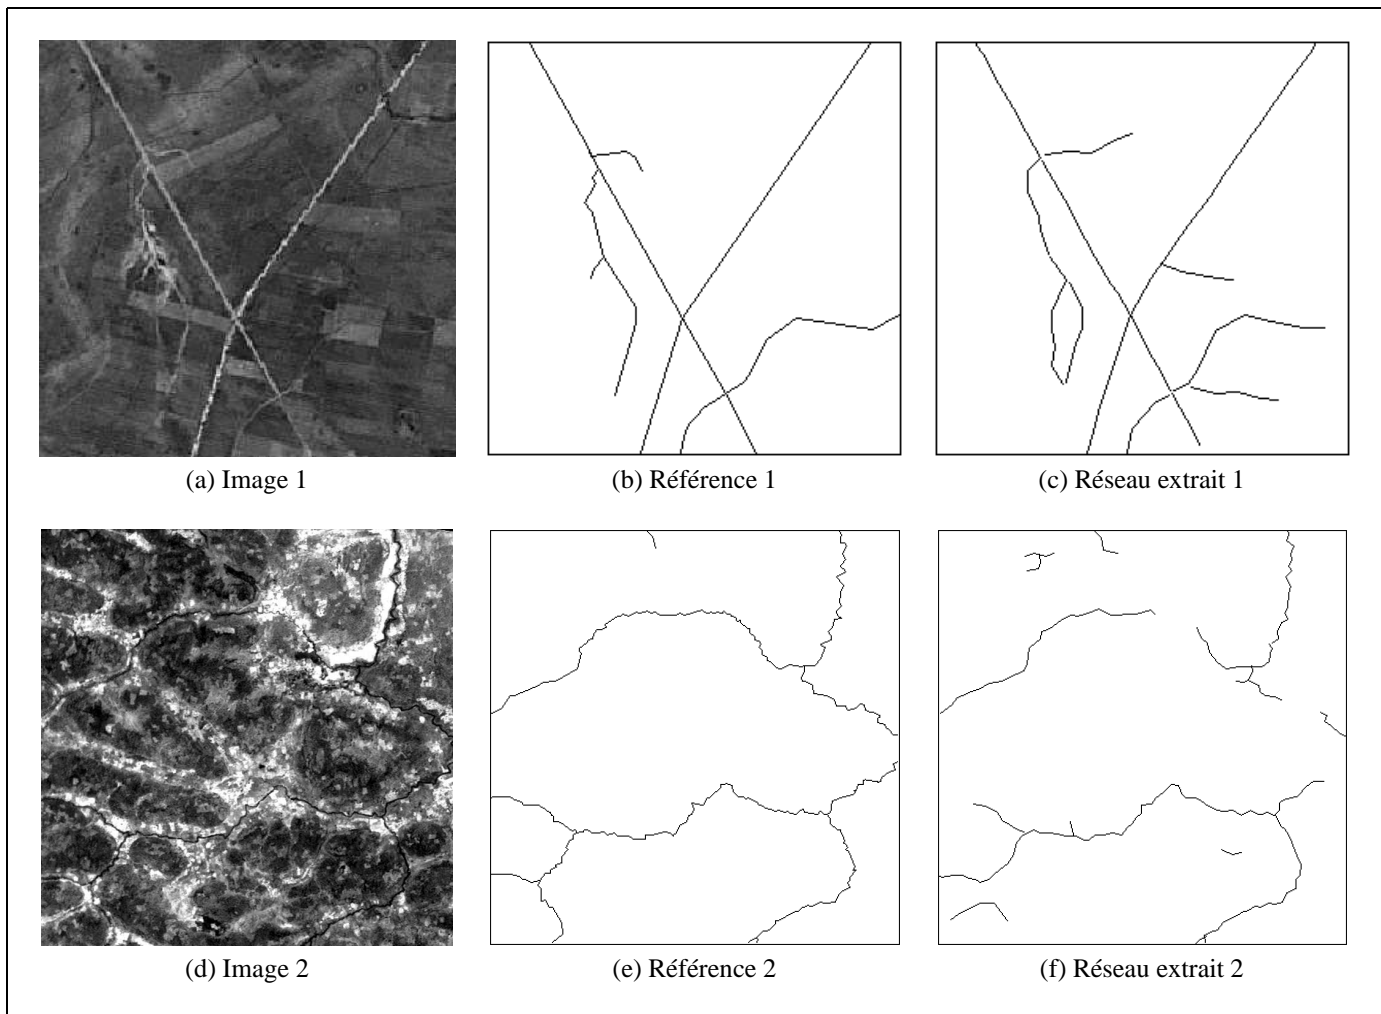


FIG. 4 – Résultats de l'extraction du réseau routier (c) à partir d'une image SPOT de 256×256 pixels (a) dont le réseau de référence est donné en (b) et de l'extraction du réseau hydrographique (f) à partir d'une image SPOT de 674×682 pixels (d) dont le réseau de référence (extrait par un expert du BRGM) est donné en (e).

- dels and estimation. *IEEE Trans. on PAMI*, 18 - 2:707–721, 1996.
- [2] M. A. Fischler, J. M. Tenenbaum, et H. C. Wolf. Detection of roads and linear structures in low-resolution aerial imagery using a multisource knowledge integration technique. *Computer Graphics and Image Processing*, 15:201–223, 1981.
- [3] D. Geman et B. Jedynak. An active testing model for tracking roads in satellite images. *IEEE Trans. on PAMI*, 18:1–14, 1996.
- [4] C. J. Geyer et J. Møller. Simulation and likelihood inference for spatial point process. *Scandinavian Journal of Statistics, Series B*, 21:359–373, 1994.
- [5] C. Graffigne et I. Herlin. Modélisation de réseaux pour l'imagerie satellite SPOT. *RFIA*, 1989.
- [6] P.J. Green. Reversible jump Markov chain Monte-Carlo computation and Bayesian model determination. *Biometrika*, 57:97–109, 1995.
- [7] C. Lacoste, X. Descombes, et J. Zerubia. A comparative study of point processes for line network extraction in remote sensing. Rapport de recherche INRIA No. 4516, 2002.
- [8] W. M. Neuenschwander, P. Fua, L. Iverson, G. Székely, et O. Kubler. Ziplock snakes. *International Journal of Computer Vision*, 25(3):191–201, 1997.
- [9] C. Robert. *Simulations de Monte-Carlo par Chaînes de Markov*. Economica, 1996.
- [10] M. Rochery, I. Jermin, et J. Zerubia. Etude d'une nouvelle classe de contours actifs pour la détection de routes dans les images de télédétection. *GRETSI*, 2003.
- [11] M. A. Serendero. Extraction d'informations symboliques en imagerie spot: Réseaux de communication et agglomérations. *Thèse de Doctorat - Université de Nice Sophia-Antipolis*, 1989.
- [12] R. Stoica, X. Descombes, et J. Zerubia. Road extraction in remote sensed images using a stochastic geometry framework. *Proc. MaxEnt*, 2000.
- [13] F. Tupin, H. Maitre, J-F. Mangin, J-M. Nicolas, et E. Pechersky. Detection of linear features in SAR images: Application to road network extraction. *IEEE Trans. on Geoscience and Remote Sensing*, 36(2):434–453, 1998.
- [14] M.N.M. van Lieshout. *Markov Point Processes and their Applications*. Imperial College Press, 2000.