



Détection de feux de forêt par analyse statistique de la radiométrie d'images satellitaires

Florent Lafarge, Xavier Descombes, Josiane Zerubia

► To cite this version:

Florent Lafarge, Xavier Descombes, Josiane Zerubia. Détection de feux de forêt par analyse statistique de la radiométrie d'images satellitaires. RR-5369, INRIA. 2004, pp.32. inria-00070634

HAL Id: inria-00070634

<https://inria.hal.science/inria-00070634>

Submitted on 19 May 2006

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.

Détection de feux de forêt par analyse statistique de la radiométrie d'images satellitaires

Florent Lafarge — Xavier Descombes — Josiane Zerubia

N° 5369

Novembre 2004

_____ Thème COG _____



*apport
de recherche*



Détection de feux de forêt par analyse statistique de la radiométrie d'images satellitaires

Florent Lafarge , Xavier Descombes , Josiane Zerubia

Thème COG — Systèmes cognitifs
Projet Ariana

Rapport de recherche n° 5369 — Novembre 2004 — 32 pages

Résumé : Nous proposons, dans ce rapport, une méthode de détection des feux de forêt par imagerie satellitaire fondée sur la théorie des champs aléatoires. L'idée consiste à modéliser l'image par une réalisation d'un champ gaussien afin d'en extraire, par une analyse statistique, les éléments étrangers pouvant correspondre aux feux. Le canal IRT (InfraRouge Thermique) contient des longueurs d'onde particulièrement sensibles à l'émission de chaleur. L'intensité d'un pixel d'une image IRT est donc d'autant plus forte que la température de la zone associée à ce pixel est élevée. Les feux de forêt peuvent alors être caractérisés par des pics d'intensité sur ce type d'images. Nous proposons une méthode de classification non supervisée et automatique fondée sur la théorie des champs gaussiens. Pour ce faire, nous modélisons dans un premier temps l'image par une réalisation d'un champ gaussien. Les zones de feux, minoritaires et de fortes intensités sont considérées comme des éléments étrangers à ce champ : ce sont des événements rares. Ensuite, par une analyse statistique, nous déterminons un jeu de probabilités définissant, pour une zone donnée de l'image, un degré d'appartenance au champ gaussien, et par complémentarité aux zones potentiellement en feux.

Mots-clés : télédétection, feux de forêt, champ gaussien, événement rare, cluster, DT-caractéristique, pic d'intensité

Fire forest detection by statistical analysis of the radiometry of satellite images

Abstract: We present in this report a method for forest fire detection in satellite images based on random field theory. The idea is to model the image as a realization of a gaussian field in order to extract the rare events, which are potential fires, by a statistical analysis.

The TIR (Thermal InfraRed) channel has a wavelength sensitive to the emission of heat : the higher the heat of a area, the higher the intensity of the corresponding pixel of the image. Then a forest fire can be characterized by peak intensity in TIR images. We present an fully automatic unsupervised classification method based on Gaussian field theory. First we model the image as a realization of a Gaussian field. The fire areas, which have high intensity and are supposed to be a minority, are considered as foreign elements of that field : they are rare events. Then we determine by a statistical analysis a set of probabilities which characterizes the degree of belonging to the Gaussian field of a small area of the image. So, we estimate the probability that the area is a potential fire.

Key-words: forest fire, remote sensing, Gaussian field, rare event, cluster, DT-characteristique, peak intensity

Table des matières

1	Introduction	4
2	Champs aléatoires	5
2.1	Définitions et propriétés	5
2.2	Les champs gaussiens	6
2.3	Ensemble d'excursion et DT-caractéristique	7
2.4	Espérance de la DT-caractéristique	8
3	Prétraitements	10
3.1	Test de normalité	10
3.2	distribution unimodale par K-moyennes itérée	12
3.3	Spécification d'histogramme	14
3.4	Résultats	16
4	Etude statistique sur l'appartenance d'un "cluster" à un champ gaussien	19
4.1	Pics d'intensité	19
4.2	Extension spatiale	21
4.3	Seuillage contextuel	23
5	Résultats	25
6	Conclusion et perspectives	26

1 Introduction

Les dégâts résultant des incendies de forêts présentent des conséquences très néfastes sur l'environnement. La détection des feux constitue un des enjeux majeurs dans cette lutte contre les incendies de forêt. Il y a encore dix ans, les méthodes de détection étaient principalement fondées sur des techniques terrestres et aériennes à travers notamment les patrouilles terrestres, les tours de guêt, la surveillance vidéo ou bien encore les avion de surveillance. Ces méthodes ont cependant une couverture limitée et exigent des moyens humains importants. A travers le développement technologique, l'homme apporte des solutions de plus en plus efficaces dans la lutte contre les feux de forêt. Aujourd'hui, ses espoirs se concentrent sur les technologies spatiales apportées par les satellites. L'enjeu est notamment de détecter les feux de forêt grâce à l'imagerie satellitaire.

Dans ce domaine, les méthodes de détection existantes sont principalement fondées sur des analyses radiométriques d'images thermiques et moyen infrarouge. Des algorithmes tels que le CFDA ("Canadian Fire Detection Algorithm") basé sur les travaux de Flannigan et Vonder Haar [Flannigan et Haar, 1986], permettent, par des jeux de tests sur des mesures et des seuillages, d'obtenir de bons résultats quant à la détection des feux. Cependant, la plupart de ces méthodes nécessitent des connaissances a priori sur les capteurs employés, les caractéristiques du satellite ou bien encore les spécificités du terrain observé.

Nous proposons une nouvelle méthode de détection de feux de forêt qui n'utilise pas ces connaissances a priori. Cette méthode permet, en effet, de détecter les feux de manière totalement automatique à partir d'images thermiques moyenne résolution. La seule contrainte de cette méthode réside dans l'hypothèse suivante : les feux doivent être des événements rares dans l'image (c'est-à-dire très minoritaires en terme de pixels : cette contrainte signifie, entre autre, que la résolution de l'image ne doit pas être trop fine). Cette méthode est fondée sur la théorie des champs aléatoires. Nous modélisons les images par des champs gaussiens afin d'en extraire, par une analyse statistique, les éléments étrangers pouvant correspondre au feux de forêt. Une approche comparable a été développée en IRM fonctionnelle par K.J. Friston, K.J. Worsley et J.B. Poline. Nous nous sommes appuyés sur ces travaux en imagerie

médicale, notamment sur [Friston *et al.*, 1994] et [Poline *et al.*, 1997] pour proposer cette nouvelle technique de détection de feu.

Cette étude a été réalisée dans le cadre d'un contrat avec Alcatel Space Cannes. Les images étudiées proviennent du satellite BIRD, fournies par l'Agence Spatiale Allemande (DLR) à Alcatel Space Cannes. Elles représentent le Portugal durant le mois de mai 2003 à une résolution de 300 mètres.

2 Champs aléatoires

Dans cette partie, nous rappelons quelques principes de la théorie des champs aléatoires. Nous nous penchons, en particulier, sur les champs gaussiens. Pour des informations complémentaires, le lecteur est invité à consulter [Adler, 1981].

2.1 Définitions et propriétés

Définition 1 Soient $(\Omega, \mathcal{F}, P)$ un espace probabilisé complet et T un espace topologique.

Un **champ aléatoire** à valeurs réelles est une application mesurable $X : \Omega \rightarrow \mathbb{R}^T$. Si $T \subset \mathbb{R}^N, N \in \mathbb{N}$, X est appelée **champs aléatoire de dimension N** .

A partir de cette définition, nous obtenons un ensemble de mesures $F_{t_1, \dots, t_n}$ définies par $F_{t_1, \dots, t_n}(B) = P((X(t_1), \dots, X(t_n)) \in B)$ pour tout $B \in \mathcal{B}^n$, où $\mathcal{B}$ est la tribu borélienne engendrée par les ouverts de $\mathbb{R}$. L'ensemble de toutes ces mesures est appelé la famille des $\mathcal{F}_d$ distributions.

Définition 2 Un champ aléatoire $X(t)$ de dimension N est dit **homogène** si $\forall \tau, t_1, \dots, t_k \in \mathbb{R}^N$, le vecteur $(X(t_1), \dots, X(t_k))$ a même loi que le vecteur $(X(t_1 + \tau), \dots, X(t_k + \tau))$

Un champ aléatoire homogène est aussi dit stationnaire. En imagerie 2D, la stationnarité d'un champs aléatoire signifie qu'un ensemble de pixels d'une image sera distribué selon la même loi par translation spatiale.

Définition 3 Un champ aléatoire $X(t)$ de dimension N est **continu** au point $t^* \in \mathbb{R}^N$ ssi sa fonction de covariance $R(s, t) = E[(X(s) - E[X(s)])(X(t) - E[X(t)])]$ est

continue au point $t = s = t^*$.

Si $R(s, t)$ est continue en tout point $s=t$, alors $X(t)$ est continu.

Définition 4 Si $\frac{\partial^2 R(s, t)}{\partial s_i \partial t_i}$ existe et est finie au point $(t, t) \in \mathbb{R}^{2N}$,

alors $X_i(t) = \lim_{h \rightarrow 0} \frac{X(t+h\delta_i) - X(t)}{h}$ existe

$X_i(t)$ est alors appelée la ms dérivée partielle (“mean square”) de $X(t)$ en t par rapport à t_i .

Si elle existe pour tout $t \in \mathbb{R}^N$ et par rapport à chaque t_i , alors $X(t)$ possède une ms dérivée.

La fonction de covariance de $X_i(t)$ est alors donnée par $\frac{\partial^2 R(s, t)}{\partial s_i \partial t_i}$.

Quand un champ aléatoire est homogène, il est relativement simple de prouver qu’il est alors ms différenciable. Nous allons particulièrement nous intéresser à une famille de champs aléatoires, les champs gaussiens. Cette classe de champs est très utilisée dans les applications liées à la théorie des champs aléatoires car elle permet d’avoir des formules explicites et spécifiques utiles pour comparer la théorie à l’expérimental.

2.2 Les champs gaussiens

Définition 5 Une variable aléatoire à valeur réelle X est dit gaussienne (ou normalement distribuée) si elle a une espérance $\mu = E[X]$ finie, une variance $\sigma^2 = E[(X - \mu)^2]$ et une fonction de distribution donnée par

$$F_X(x) = P(X \leq x) = \int_{-\infty}^x (2\pi\sigma^2)^{-\frac{1}{2}} \exp\left[-\frac{(x-\mu)^2}{2\sigma^2}\right] dx$$

Définition 6 Un vecteur aléatoire $X = (X_1, \dots, X_n)$ à valeur dans $(\mathbb{R}^n, \mathcal{B}(\mathbb{R}^d))$ est appelé vecteur gaussien si pour tout $\alpha = (\alpha_1, \dots, \alpha_n)$ dans $\mathbb{R}^n$, le produit scalaire $\langle \alpha, X \rangle = \sum_{i=1}^n \alpha_i X_i$ est une variable aléatoire réelle gaussienne.

Dans ce cas, la densité de probabilité du vecteur X de dimension n est donnée par :

$$f_X(x) = (2\pi)^{-\frac{n}{2}} |V|^{-\frac{1}{2}} \exp\left[-\frac{1}{2}(x - \mu)V^{-1}(x - \mu)^T\right]$$

où

$$\mu = (E(X_i))_{i \in [1, n]}$$

$$V = (E[(X_i - \mu_i)(X_j - \mu_j)])_{(i, j) \in [1, n]^2}$$

Définition 7 On appelle *champ aléatoire gaussien*, un champ aléatoire dont les $\mathcal{F}_d$ distributions sont des vecteurs gaussiens.

Les $\mathcal{F}_d$ distributions d'un processus gaussien à valeurs réelles sont complètement déterminées une fois que la fonction de moyenne $\mu(t) = E[X(t)]$ et la fonction de covariance $R(s, t) = E[(X(s) - EX(s))(X(t) - EX(t))]$ sont spécifiées.

Propriété 1 Si un champ gaussien à valeurs réelles a une fonction de moyenne constante et une fonction de covariance $R(s, t)$ dépendant uniquement de $s - t$, alors le champ est homogène.

2.3 Ensemble d'excursion et DT-caractéristique

Définition 8 Soit $F(t) : \mathbb{R}^N \rightarrow \mathbb{R}$ une fonction. $\forall u \in \mathbb{R}$ et $S \subset \mathbb{R}^N$, on définit l'ensemble d'excursion de la fonction F au dessus du seuil u dans S par :
 $A_u(F, S) = \{t \in S : F(t) \geq u\}$




FIG. 1 – Ensembles d'excursion d'un champ de dimension 2 pour deux seuils différents

En terme d'imagerie, A_u représente l'ensemble des clusters d'une image au seuil u , c'est-à-dire l'ensemble des surfaces définies, dans l'espace 3D, par l'intersection

entre la silhouette de l'image (i.e. la surface dont la cote correspond à l'intensité des pixels de l'image) et le plan d'ordonnée u . Nous allons définir un outil permettant de quantifier le nombre d'ensembles connexes d'un ensemble d'excursion (c'est-à-dire, en imagerie, le nombre de "clusters" pour un seuil donné). Il s'agit de la *DT caractéristique*.

Définition 9 Soit $F : \mathbb{R}^N \rightarrow \mathbb{R}$, une fonction régulière sur un ensemble compact $S \subset \mathbb{R}^N$.

On définit la **DT caractéristique** ("Differential Topology") de l'ensemble d'excursion $A_u(F, S)$ par le nombre $\chi(A_u)$, défini par :

$$\chi(A_u) = (-1)^{N-1} \sum_{k=0}^{N-1} (-1)^k \chi_k(A_u)$$

où $\chi_k(A_u)$ représente le nombre de points $t \in S$ tel que :

- $F(t) = u$
- $\frac{\partial F}{\partial x_i}(t) = 0$, $\forall i \in [1, N-1]$
- $\frac{\partial F}{\partial x_N}(t) > 0$
- $D(t) = \left(\frac{\partial^2 F}{\partial x_i \partial x_j}(t) \right)_{i,j \in [1, N-1]}$ a k valeurs propres négatives.

2.4 Espérance de la DT-caractéristique

Définition 10 On appelle module de continuité d'un champ X , la fonction

$$w : h \rightarrow w(h) = \sup_{\|t-s\| < h} |X(t) - X(s)|$$

Propriété 2 Soient $X(t)$, $t \in \mathbb{R}^N$ un champ aléatoire gaussien homogène de moyenne nulle sur S , ensemble compact et convexe de $\mathbb{R}^N$ dont le bord ∂S a une mesure de Lebesgue nulle. On suppose que X a des dérivées partielles presque sûrement continues jusqu'au second ordre, avec des variances finies dans un voisinage de S , et que la distribution jointe de X et de ses dérivées partielles est non dégénérée. On note $\phi(x, x_1, \dots, x_N, z)$, la densité jointe de $X, X_1, \dots, X_N, Z$ où Z est le vecteur de

longueur $\frac{N(N-1)}{2}$ contenant les coefficients de la matrice triangulaire supérieure de $D(t)$ pris à la suite suivant les colonnes. On note λ , la mesure de Lebesgue de S .

De plus, si les modules de continuité de X_i et X_{ij} satisfont la condition

$$P(\max_{i,j} [w_i(h), w_{ij}(h)] > \epsilon) = o(h^N) \text{ quand } h \downarrow 0 \text{ et } \forall \epsilon > 0.$$

Alors,

$$\bullet E(\chi_k(A_u)) = \lambda(S)(-1)^k \int_{x_N > 0} \int x_N (\det D) \phi(u, 0, \dots, 0, x_N, z) dx_N dz.$$

où la seconde intégrale est définie pour tout $z \in \mathbb{R}^{\frac{N(N-1)}{2}}$ pour lesquels D a k valeurs propres négatives.

et

$$\bullet E(\chi(A_u)) = \lambda(S)(-1)^{N-1} \int_{x_N > 0} \int_{z \in \mathbb{R}^{\frac{N(N-1)}{2}}} x_N (\det D) \phi(u, 0, \dots, 0, x_N, z) dx_N dz.$$

Propriété 3 Soient $X(t)$ un champ aléatoire gaussien homogène de $\mathbb{R}^N$ de moyenne nulle et S un ensemble de $\mathbb{R}^N$ satisfaisant les conditions de la propriété précédente. Alors, l'espérance de la DT caractéristique de l'ensemble d'excursion $A = A_u(X, S)$ est donnée par :

$$E\chi(A) = \lambda(S)(2\pi)^{\frac{N+1}{2}} |\Lambda|^{\frac{1}{2}} \sigma^{-(2N-1)} \exp\left(-\frac{u^2}{2\sigma^2}\right) \sum_{j=0}^{\lfloor \frac{N-1}{2} \rfloor} (-1)^j a_j \sigma^{2j} C_{N-1}^{2j} u^{N-1-2j}.$$

$$\text{où } \sigma^2 = E(X^2(t)), \Lambda \text{ est la matrice de covariance de } X_j(t), \text{ et } a_j = \frac{(2j)!}{j!2^j}.$$

Pour plus de détails sur les démonstrations de ces deux propriétés, le lecteur est invité à consulter [Adler, 1981].

En particulier, pour un champ aléatoire gaussien de dimension 2, l'espérance de la DT caractéristique est donné par :

$$E\chi(A) = \lambda(S)(2\pi)^{\frac{3}{2}} |\Lambda|^{\frac{1}{2}} \sigma^{-3} \exp\left(-\frac{u^2}{2\sigma^2}\right) \quad (1)$$

Nous pouvons adapter ce théorème dans le domaine de l'imagerie. Pour cela, les hypothèses de la propriété 2 doivent être vérifiées :

- La continuité des dérivées partielles jusqu'au second ordre du champ ainsi que la négligeabilité à l'ordre N des maxima de leur module de continuité (ce qui est plus fort) signifient, en terme d'imagerie, que l'image doit avoir une certaine homogénéité dans l'intensité de ses pixels (i.e. un certain lissage) et notamment qu'elle ne doit pas être trop bruitée.

- Pour qu'une image soit modélisable par une réalisation d'un champ gaussien homogène, il faut que la distribution des intensités des pixels de cette image suive une loi normale (cela revient à avoir une distribution normale de l'histogramme).

En terme d'imagerie, cette propriété nous permet de quantifier le nombre moyen de clusters au seuil u pour une image modélisée par un champ gaussien.

3 Prétraitements

L'étude réalisée dans cette partie s'appuie sur la théorie des champs aléatoires gaussiens dont nous venons de voir certaines propriétés. Pour que nous puissions utiliser ces dernières, les données, c'est-à-dire les images TIR des feux, doivent pouvoir être modélisées par des champs gaussiens. Nous allons donc appliquer plusieurs prétraitements afin que les images sur lesquelles nous travaillons aient une distribution gaussienne.

3.1 Test de normalité

Une image est assimilable à un champ gaussien si les pixels de cette image sont distribués selon une loi normale. Il s'agit donc de réaliser un test de normalité sur la distribution des pixels de l'image afin d'avoir un degré de certitude quant à la modélisation de l'image par un champ gaussien. Il existe plusieurs tests de normalité [Sprent, 1993], comme le test de Kolmogorov-Smirnov, le test de Lin et Mulholkar ou bien encore le test de Shapiro-Wilks. Nous utiliserons le test de Kolmogorov-Smirnov, test particulièrement précis pour les échantillons de taille importante, c'est-à-dire, dans notre cas pour les grosses images.

Test de Kolmogorov-Smirnov

Le test de Kolmogorov-Smirnov est fondé sur la comparaison de la fonction cumulative de fréquence $N(x)$ pour l'échantillon (c'est-à-dire le nombre d'observations inférieures à x sur le nombre d'observations totales) avec la fonction de répartition $F(x)$ d'une loi normale pour la population (c'est-à-dire la probabilité qu'une observation soit inférieure à x). De manière plus précise, nous déterminons l'écart maximum ϵ en valeur absolue entre $N(x)$ et $F(x)$.

$$\epsilon = \max_{x \in \mathbf{R}} |N(x) - F(x)|$$

Nous comparons alors ϵ à des valeurs critiques tabulées selon la taille de l'échantillon et le niveau de signification voulu du test. En particulier, pour des échantillons de taille n supérieure à 35 et pour un niveau de signification égal à 0.01, la valeur critique est approximée par $\frac{1.63}{\sqrt{n}}$.

Dans notre cas, la taille de l'échantillon correspond au nombre de pixels de l'image et est donc nettement supérieur à 35. Nous utiliserons donc la valeur $\frac{1.63}{\sqrt{n}}$ pour approximer la valeur critique pour un niveau de signification égal à 0.01.

Nous rejeterons donc l'hypothèse que le champ soit gaussien, avec une probabilité de 0.01 de se tromper si l'écart maximum observé ϵ est supérieur ou égal à la valeur critique $\frac{1.63}{\sqrt{n}}$.

Par ailleurs, nous restreignons le calcul de l'écart maximum observé ϵ à $x \in [\mu - 3\sigma, \mu + 3\sigma]$ où μ et σ sont respectivement la moyenne et la variance de la loi normale à laquelle nous comparons notre échantillon. Cela ne change pas la pertinence du test car, pour une loi normale, plus de 99% des observations de l'échantillon se situent dans l'intervalle $[\mu - 3\sigma, \mu + 3\sigma]$. Cette restriction permet de ne pas tenir compte des observations correspondants aux feux de forêts dans le test de Kolmogorov-Smirnov, observations ayant des valeurs extrêmes et que nous considérons étrangères au champ gaussien.




FIG. 2 – Test de Kolmogorov-Smirnov

3.2 distribution unimodale par K-moyennes itérée

Les images satellitaires possèdent, bien souvent, plusieurs classes dominantes (mer, terre, nuages,...), ce qui rend leur distribution multimodale. Dans ces conditions, il est impossible de modéliser les données par un champ gaussien dont la distribution est unimodale. Il faut donc séparer les différents modes de l'image pour n'en conserver qu'un : celui le plus proche de la modélisation des feux de forêts, c'est-à-dire celui qui aura l'intensité moyenne la plus élevée. Sur l'image, ce mode correspond à la terre ou à une partie de la terre.

Nous utilisons l'algorithme du "K-means" pour séparer les différents modes de l'image. Selon le domaine d'application, cet algorithme de classification non supervisée peut être appelé de différentes manières : méthode de Lloyd, moyennes mobiles, nuées dynamiques ou bien encore algorithme ISODATA.

L'algorithme du "K-means" consiste à calculer la partition optimale de l'ensemble des observations en N_c sous-ensembles, chaque sous-ensemble (ou classe) étant représenté par un noyau.

On note :

$\mathbf{E}$, l'ensemble des observations

Π , l'ensemble des partitions π de $\mathbf{E}$ en K classes $(C_1, \dots, C_K)$

$g = (g_1, \dots, g_K)$ un ensemble de K noyaux, où g_i est le noyau de la classe C_i

$W(\pi, g)$, un critère qui mesure l'adéquation entre une partition π et l'ensemble des noyaux g

Le but de l'algorithme est alors de chercher la partition π et la représentation g associée qui minimise le critère W . En d'autre terme, nous recherchons le couple (π^*, g^*) tel que :

$$(\pi^*, g^*) = \arg \min_{(\pi, g)} W(\pi, g)$$

Nous utilisons ici l'algorithme du "K-means" dans le cas où les noyaux ont comme mode de représentation le centre d'inertie de la classe C_i . Le critère d'adéquation s'écrit alors :

$$W(\pi, g) = \sum_{i=1}^K \sum_{x \in C_i} d^2(x, g_i)$$

où d représente la distance euclidienne. W est donc la variance intraclasse, c'est-à-dire la somme des variances de chaque classe.

Algorithme 1 (“K-means”) .

Initialisation aléatoire d'un ensemble g_o de K noyaux, c'est-à-dire des K centres d'inertie.

répéter

Classifier les observations selon le centre g_i le plus proche, $i \in (1, K)$

Mettre à jour les centres d'inertie g_i , $i \in (1, K)$

jusqu'à ce que les centres d'inertie g_i n'évoluent plus.

La démonstration de la convergence de cet algorithme s'effectue en montrant qu'à chaque itération de l'algorithme, le critère W diminue, et, puisqu'il y a un nombre fini de classifications possibles, on atteint forcément un point de convergence. Pour des informations complémentaires, le lecteur est invité à consulter [Pratt, 1991] et [Cocquerez et Philipp, 1995].

L'algorithme du “K-means” nécessite la connaissance du nombre de classes. Or, nous souhaiterions pouvoir séparer les différents modes d'une image de manière automatique. [Lorette, 1999] a modifié l'algorithme du “K-means” de sorte que le nombre de classes soit déterminé automatiquement. Pour cela, un terme entropique sur la probabilité a priori des classes a été ajouté au critère d'adéquation W . Le nombre de classes K devient alors un paramètre que le terme entropique ajouté cherchera à minimiser. Cette méthode a cependant l'inconvénient de n'être pas totalement automatique car elle fait intervenir un paramètre d'ajustement entre le terme entropique et le critère d'adéquation. Nous n'utiliserons donc pas cette méthode.

Nous proposons d'utiliser l'algorithme du K-means à deux classes de manière itérée. Comme nous souhaitons conserver le mode de l'image qui à la plus forte intensité moyenne, nous allons éliminer, par un principe semblable à la dichotomie, les classes de moyenne d'intensité les plus faibles. A chaque itération de cette méthode, nous séparons l'image en deux classes en utilisant l'algorithme du “K-means” à deux

classes et nous gardons la classe de moyenne d'intensité la plus élevée. Nous testons alors si la classe conservée suit une distribution unimodale.

Le test utilisé pour tester l'unimodalité de la distribution est un test de normalité de type Kolmogorov-Smirnov ayant une tolérance relativement forte.

Algorithme 2 (“K-means” itéré à 2 classes) .

répéter

Classifier les observations selon l'algorithme du “K-means” à 2 classes

Conserver la classe ayant la moyenne d'intensité la plus élevée

jusqu'à ce que le test d'unimodalité de la classe conservée soit accepté.

Par cet algorithme, nous extrayons donc un masque de l'image originale correspondant à un ensemble de pixels sur lesquels nous travaillerons par la suite et que nous nommerons sous-image résultante du “K-means” itéré à 2 classes.

Nous réalisons sur cette sous-image obtenue une fermeture, puis une ouverture par morphologie mathématique [Soille, 2003], afin d'améliorer sa connexité, c'est-à-dire en faisant disparaître les petits éléments isolés du masque et en rebouchant les trous présents dans le masque. Cette fermeture nous permet également d'améliorer la normalité de la distribution : nous récupérons, en effet, la queue de la gaussienne de la distribution de la sous-image.

Cependant, malgré l'utilisation de ces prétraitements, le test de normalité de Kolmogorov-Smirnov est rejeté. En effet, la sous-image obtenue par ces prétraitements a bien une distribution unimodale mais qui n'a pas une forme gaussienne.

3.3 Spécification d'histogramme

Après avoir rendu la distribution unimodale en sélectionnant une sous-image, nous allons rendre cette distribution gaussienne par une spécification d'histogramme.

La spécification d'histogramme consiste à rendre la distribution d'intensité d'une image voisine d'une distribution spécifiée à l'avance. Afin de conserver la position et le sens des transitions présentes dans l'image initiale, on choisit une transformation croissante. La distribution de référence est, dans notre cas, une distribution gaussienne.

Soit A l'image initiale, R l'image de référence et B l'image transformée. La transformation d'intensité est notée T . Les images sont considérées ici comme des




FIG. 3 – Algorithme du “K-means” à 2 classes itéré

ensembles de réalisations de variables aléatoires absolument continues notées respectivement A , R et B . Ces variables aléatoires sont caractérisées par leurs densités de probabilité f_A , f_R , f_B , et leurs fonctions de répartition F_A , F_R , F_B . On suppose que f_R est non nulle sur l'intervalle $]r_{min}, r_{max}[$.

Soit $a \in]a_{min}, a_{max}[$, l'intensité d'un pixel dans l'image initiale A et $b=T(a)$, l'intensité correspondante dans l'image transformée. Nous cherchons alors la transformation T telle que pour $a \in]a_{min}, a_{max}[$, nous ayons :

$$F_B(T(a)) = F_A(a)$$

Or, nous voulons avoir $F_B = F_R$. Puisque F_R est inversible sur $]r_{min}, r_{max}[$, nous prendrons :

$$T = F_R^{-1} \circ F_A$$

Pour obtenir des informations complémentaires, le lecteur est invité à consulter [Cocquerez et Philipp, 1995]. En pratique, nous réalisons une quantification sur les niveaux d'intensité de l'image initiale car la transformation F_R n'est pas algorithmiquement calculable en tout point. La transformation T obtenue est alors une fonction croissante continue constituée de fonctions affines. Chaque une de ces fonctions correspond à la transformation affine d'un intervalle d'intensité. De cette manière, la distribution obtenue n'est pas exactement normale, mais est une approximation par fonctions affines d'une gaussienne. Cela dit, quand on prend un pas de quantification relativement petit, nous obtenons de très bons résultats, et le test de Kolmogorov-Smirnov est facilement accepté.

Une dernière étape consiste à centrer et à réduire cette distribution normale afin de simplifier les théorèmes utilisés ultérieurement ainsi que les calculs qui en découlent. Nous avons donc, à la fin des prétraitements, une image dont les modes de faible intensité moyenne sont masqués, et dont la partie non masquée est unimodale distribuée selon une loi normale centrée réduite.

3.4 Résultats

Les résultats présentés sur les figures 5 et 6 montrent les différentes étapes dans le prétraitement de l'image. Que ce soit lors de la classification des modes de l'image par l'algorithme du "K-means itéré" à 2 classes ou lors de la spécification d'histogramme, un test de normalité de type Kolmogorov-Smirnoff est effectué afin de valider la qualité du prétraitement. Le critère d'acceptation du test est, au fil des prétraitements, de plus en plus fin.




FIG. 4 – Synthèse des prétraitements effectués

Il est à noter que, sur la figure 6, l'histogramme de l'image finale, c'est-à-dire l'histogramme de l'image masquée obtenue suite à la spécification d'histogramme a




FIG. 5 – **A gauche** : image BIRD du Portugal, canal thermique (©DLR). **A droite** : image BIRD resultante de l'algorithme du "K-means itéré" à 2 classes, c'est-à-dire avec la mer et les nuages masqués.




FIG. 6 – **En haut à gauche** : masque obtenu suite à l’algorithme du “K-means itéré” à 2 classes. **En haut à droite** : masque amélioré obtenu après fermeture et ouverture sur le masque de gauche. **Au centre à gauche** : histogramme de l’image initiale. **Au centre à droite** : histogramme de l’image masquée. **En bas à gauche** : histogramme de l’image masquée par le masque amélioré. **En bas à droite** : histogramme de l’image masquée obtenue suite à la spécification d’histogramme.

été translaté et étendu par rapport aux autres histogrammes, et ce afin de pouvoir mieux juger visuellement de la normalité de la distribution.

4 Etude statistique sur l'appartenance d'un "cluster" à un champ gaussien

Nous venons de transformer l'image afin de pouvoir la modéliser par une réalisation d'un champ gaussien. Cependant, certains pixels de forte intensité sont présents dans cette image : ils représentent des feux de forêt. Les prétraitements effectués dans la partie précédente n'ont pas affecté ces pixels. Ainsi, il est légitime de considérer l'image comme l'union d'un champ gaussien et d'un ensemble étranger à ce champ : les feux de forêt. Le champ gaussien est un ensemble de pixels très majoritaire, que nous pouvons considérer comme le fond de l'image. Les feux de forêt sont, eux, représentés par des ensembles de pixels de taille relativement petite par rapport aux dimensions de l'image ; ils sont surtout très rares (hypothèse H0).

Pour résumer, nous considérons notre image formée de 2 classes : la première, qui représente la quasi-totalité de l'image et qui est modélisée par un champ gaussien correspond au fond de l'image - La deuxième, très minoritaire, correspond aux éléments étrangers au champ, c'est-à-dire à des pixels rares qui présentent une discontinuité par rapport à la régularité du fond de l'image.

Nous considérons, par ailleurs, que ces pixels rares ayant de fortes intensités ne peuvent représenter que des feux de forêt, cela signifie que les seuls événements naturels ou artificiels pouvant expliquer une intensité thermique très élevée sur une surface terrestre sont forcément un feu de forêt (hypothèse H1).

Nous allons, dans ce cas, pouvoir utiliser les résultats de la théorie des champs aléatoires, et particulièrement la formule (1) afin d'établir des lois probabilistes sur l'appartenance d'un cluster à un champ gaussien. Nous pourrions alors estimer si un ensemble connexe de pixels appartient au fond de l'image ou, par négation, appartient à l'ensemble des pixels représentant les feux de forêt.

4.1 Pics d'intensité

Nous allons estimer l'appartenance d'un cluster à une réalisation d'un champ gaussien en fonction de l'intensité maximale des pixels de ce cluster.

Nous rappelons qu'à un certain seuil t donné, l'espérance du nombre de clusters d'une image modélisable par un champ gaussien centré réduit est donnée par la formule

(1) :

$$E[m_t] = S(2\pi)^{\frac{3}{2}} |\Lambda|^{\frac{1}{2}} \exp - \frac{t^2}{2} \quad (2)$$

où

m_t est le nombre de clusters au seuil t

S est le nombre de pixels de l'image

Λ est la matrice de covariance des dérivées de l'image.

Pour la même image, l'espérance du nombre de clusters au seuil $t + H_0$ est :

$$E[m_{t+H_0}] = S(2\pi)^{\frac{3}{2}} |\Lambda|^{\frac{1}{2}} \exp - \frac{(t + H_0)^2}{2}$$

En considérant un cluster pris au seuil t et ayant un pic d'intensité $x_0 = t + H_0$ (c'est-à-dire un cluster dont le pixel ayant l'intensité maximale vaut $t + H_0$), nous pouvons, en fonction des deux expressions précédentes, établir la probabilité d'appartenance de ce cluster à une réalisation du champ gaussien. En effet, cette probabilité est le quotient de $E[m_{t+H_0}]$ par $E[m_t]$, c'est-à-dire le nombre moyen de clusters au seuil $t + H_0$ divisé par le nombre moyen de clusters au seuil t . H_0 représente l'amplitude entre le seuil t et le pic d'intensité x_0

Par ailleurs, la probabilité qu'un cluster, pris au seuil t et ayant un pic d'intensité égal à $t + H_0$, appartienne à la réalisation d'un champ gaussien équivaut à la probabilité qu'un cluster pris au seuil t ait un pic d'intensité supérieure ou égale à $t + H_0$. Ainsi, si nous notons $C_t^{H_0}$, un cluster pris au seuil t et ayant un pic d'intensité égal à $t + H_0$ et G_r , une réalisation du champ gaussien associé, nous avons :

$$P(C_t^{x_0} \in G_r) = \frac{E[m_{t+H_0}]}{E[m_t]} = \left(1 + \frac{H_0}{t}\right) e^{-(tH_0 + \frac{H_0^2}{2})} \quad (3)$$

Nous pouvons également exprimer cette probabilité avec la valeur du pic d'intensité du cluster $x_0 = t + H_0$. Dans ce cas, nous obtenons la formule suivante :

$$P(C_t^{x_0} \in G_r) = \frac{x_0}{t} e^{\frac{t^2 - x_0^2}{2}} \quad (4)$$

Pour nous référer à cette probabilité dans la suite de ce mémoire, nous la notons P_H . Il est intéressant d'observer le comportement de P_H en fonction du seuil t , connaissant la valeur du pic d'intensité x_0 . $P_{x_0}(t)$ pour $t > 0$ est une fonction décroissante de $t = 0^+$ à $t = 1$ où $P_{x_0}(1) = x_0 e^{-\frac{(x_0^2-1)}{2}}$, puis $P_{x_0}(t)$ est croissante jusqu'en $t = +\infty$ où $P_{x_0} \rightarrow 1$.

Nous pouvons en conclure qu'il existe, à x_0 fixé, un seuil optimum t^* qui minimise P_H , c'est-à-dire la probabilité que le cluster appartienne à une réalisation du champ gaussien. Dans ce cas, $P_{x_0}(t^* = 1) = x_0 e^{-\frac{(x_0^2-1)}{2}}$.

En inversant le raisonnement et en attribuant à $P_{x_0}(t^* = 1)$ une valeur relativement faible p , nous obtenons une valeur pour x_0 particulièrement intéressante puisque les clusters pris au seuil t et dont le maximum d'intensité est au moins égal à x_0 auront une probabilité p d'appartenir au champ gaussien. Numériquement, pour un champ gaussien centré réduit, ce seuil de séparation est approximativement de 3.04, de 3.57 et de 4.21 pour une probabilité p respectivement de 0.05, de 0.01 et de 0.001.

4.2 Extension spatiale

Après avoir estimé la probabilité d'appartenance d'un cluster à une réalisation d'un champ gaussien en fonction du maximum de son pic d'intensité, nous allons, dans cette partie, fournir une estimation équivalente qui est fonction de la surface du cluster.

Soient m_t le nombre de clusters au seuil t , N_t le nombre de pixels d'intensité supérieure à t et enfin n_t , le nombre de pixels d'un cluster au seuil t . Ces trois variables sont liées par la relation suivante :

$$E[n_t] = \frac{E[N_t]}{E[m_t]} \quad (5)$$

Nous cherchons à établir une loi sur n_t , c'est-à-dire à pouvoir estimer la probabilité qu'un cluster pris à un seuil t ait une certaine surface n_0 .

[Nosko, 1969] a établi expérimentalement que n_t suivait une distribution exponentielle. Or, une loi exponentielle est complètement définie par son paramètre qui représente l'inverse de l'espérance de la variable aléatoire. Pour définir la loi de n_t , Il nous suffit donc d'estimer l'espérance de n_t .

Il est relativement évident d'établir l'espérance de N_t ; la distribution des pixels suivant une loi normale, nous aurons :

$$E[N_t] = S \int_t^\infty (2\pi)^{-\frac{1}{2}} e^{-\frac{x^2}{2}} dx = S \cdot \Phi(-t) \quad (6)$$

où S est le nombre de pixels de l'image.

L'espérance de m_t est, elle, donnée par la formule (1) :

$$E[m_t] = S(2\pi)^{\frac{3}{2}} |\Lambda|^{\frac{1}{2}} \exp\left(-\frac{t^2}{2}\right)$$

où

m_t est le nombre de clusters au seuil t

S est le nombre de pixels de l'image

Λ est la matrice de covariance des dérivées de l'image.

Ainsi, nous en déduisons une approximation de l'espérance de n_t :

$$E[n_t] = \frac{E[N_t]}{E[m_t]} = \frac{\Phi(-t)}{(2\pi)^{\frac{3}{2}} |\Lambda|^{\frac{1}{2}} \exp\left(-\frac{t^2}{2}\right)} \quad (7)$$

n_t suit donc une loi exponentielle de paramètre $\lambda_t = \frac{(2\pi)^{\frac{3}{2}} |\Lambda|^{\frac{1}{2}} \exp\left(-\frac{t^2}{2}\right)}{\Phi(-t)}$. La loi de n_t est donc :

$$P(n_t = x) = \lambda_t e^{-\lambda_t x} \quad (8)$$

En particulier, la probabilité qu'un cluster pris au seuil t ait une surface supérieure à une certaine surface S_0 est donnée par :

$$P(n_t \geq S_0) = e^{-\lambda_t S_0} = e^{\frac{(2\pi)^{\frac{3}{2}} |\Lambda|^{\frac{1}{2}} S_0 \exp(-\frac{t^2}{2})}{\Phi(-t)}} \quad (9)$$

De la même façon que dans la partie précédente où nous connaissions les pics d'intensité des clusters, nous allons pouvoir, à partir de cette probabilité, estimer la probabilité d'appartenance d'un cluster $C_t^{S_0}$ pris au seuil t et ayant une surface S_0 à une réalisation d'un champ gaussien G_r . Nous avons en effet :

$$P(C_t^{S_0} \in G) = P(n_t \geq S_0) = e^{-\lambda_t S_0} = e^{\frac{(2\pi)^{\frac{3}{2}} |\Lambda|^{\frac{1}{2}} S_0 \exp(-\frac{t^2}{2})}{\Phi(-t)}} \quad (10)$$

Pour nous référer à cette probabilité dans la suite du mémoire, nous la notons P_S . Comme P_H , cette probabilité ne dépend pas du nombre de pixels total de l'image.

4.3 Seuillage contextuel

Les équations (4) et (10) nous permettent d'estimer la probabilité d'appartenance d'un cluster à une réalisation d'un champ gaussien de deux manières différentes : la première par une information sur la valeur du pic d'intensité du cluster ; la deuxième par une information sur la surface du cluster. Il s'agit alors d'utiliser ces deux estimations afin de dégager une loi d'appartenance au champ gaussien qui soit pertinente.

Dans notre cas, cette loi de décision consiste à *accepter le cluster comme élément étranger à une réalisation du champ gaussien si* la probabilité P_H est inférieure à une certaine probabilité limite p_l *ou si* P_H est supérieure à p_l et P_S est inférieure à p_l .

La probabilité limite p_l s'apparente alors à une "p-value", c'est-à-dire à la probabilité de commettre une erreur dans notre estimation. Par cette loi de décision, nous testons l'appartenance d'un cluster à un champ gaussien par la probabilité P_H ; si

le test est rejeté, nous accordons une deuxième chance en testant cette fois-ci par la probabilité P_S .

En résumé, par cette méthode, nous examinons un cluster et nous estimons sa probabilité d'appartenance au fond gaussien de l'image : cela permet de réaliser des analyses locales sur des clusters. Nous allons maintenant proposer un algorithme général utilisant cette méthode pour estimer l'existence de feux de forêt sur une image. Comme tout cluster est relatif à un seuil, nous allons définir une famille de seuil $T = (t_{-n}, \dots, t_0, \dots, t_m)$ qui permettra d'établir une famille de clusters pour un pic d'intensité présentant des risques (voir figure 7). Nous appliquerons alors la loi de décision sur P_S et P_H pour chacun des clusters. Les clusters pris à des seuils élevés, et donc ayant de petites surfaces, auront une probabilité plus élevée d'être des feux que les clusters pris à des seuils faibles et de grandes surfaces. Cela paraît normal : plus nous nous éloignons des pics d'intensité est plus la probabilité d'être en présence de feux de forêt est faible.




FIG. 7 – Exemple d'un pic d'intensité tabulé par différents seuils (en haut) et clusters associés à ces seuils (en bas)

Comme toute image a, au préalable, subi un prétraitement visant à la normaliser suivant une distribution normale centrée réduite, la famille de seuils $T = (t_{-n}, \dots, t_0, \dots, t_m)$ ne dépend pas de l'image. Nous imposerons au seuil médian t_0 de cette famille la valeur 3,57. Comme nous l'avons vu dans la partie 4.1, cette valeur assure, par la probabilité P_H , avec un degré de certitude très élevé, que les clusters pris à partir d'un seuil ayant cette valeur ont des chances de ne pas appartenir au fond gaussien de l'image. En résumé, les clusters pris à partir de cette valeur sont des zones de feux potentielles. La famille de seuils T est ainsi construite autour de t_0 . Nous étendons plus ou moins la famille T par des seuils supérieurs et inférieurs à t_0 en fonction de la qualité du résultat recherché. Dans notre algorithme, nous prendrons T composé de 4 éléments : $T = (t_{-1} = 3.2, t_0 = 3.57, t_1 = 6, t_2 = 9)$. Pour chaque pic d'intensité de l'image apparaissant comme des zones de feux potentielles, nous déterminons donc une famille de clusters possédant chacun un couple de probabilités P_S et P_H . Nous faisons alors ressortir tous les clusters de l'image qui sont acceptés par la loi de décision.

Algorithme 3 .

- *fixer la probabilité limite p_l de la loi de décision*
- *établir l'ensemble des clusters pris au seuil t_0*
- ***pour chacun de ces clusters,***
étendre le cluster à une famille de clusters relativement à l'ensemble de seuils T .
pour chaque élément de cette famille, établir P_S et P_H
- *garder les clusters acceptés par la loi de décision.*

5 Résultats

Les résultats obtenus sont présentés sur les figures 9 et 8 . Les clusters acceptés ont été répertoriés en trois catégories : en jaune, les clusters acceptés avec une probabilité limite $p_l = 0.01$; en bleu les clusters acceptés avec une probabilité limite $p_l = 0.05$ et enfin en rouge, les clusters acceptés avec une probabilité limite $p_l = 0.1$. Cela signifie que les zones en jaune, par exemple, n'appartiennent pas au fond de l'image et ce avec un degré de certitude de 99%. En tenant compte de l'hypothèse (H1), nous pouvons affirmer que ces zones sont des feux de forêt à 99%.

Sur la figure 8, le résultat obtenu apparaît très correct comparativement à la vérité de terrain associée, fournie par Alcatel Space. En effet, cette dernière fait état de 14 feux répartis dans le centre du Portugal. Sur ces 14 feux, nous en détectons 12

(11 feux détectés avec $p_l = 0.01$ + 1 feu détecté avec $p_l = 0.05$). Par ailleurs, l'algorithme n'a pas détecté de feux qui n'existe pas sur la vérité de terrain : le nombre de fausses alarmes est donc nul. Enfin, en terme de temps de calcul, l'algorithme a mis 136 secondes sur un P4-2Ghz pour une image 4000×1000 pixels.

Les résultats obtenus sur la figure 9 sont eux aussi très bons. Cependant, les vérités de terrains associées ne sont pas d'une bonne qualité, et il apparait difficile de caractériser ces résultats par un taux de détection et un taux de fausses alarmes, comme ce fut le cas avec la figure 8.



La figure 10 représente les résultats obtenus en utilisant des couples de probabilité limite différents. Cette série de résultats nous montre qu'une probabilité limite $p_l = 0.05$ est nécessaire pour obtenir des résultats d'une fiabilité reconnue en terme de certitude des feux détectés.

6 Conclusion et perspectives

La méthode présentée concerne les images thermiques à moyenne résolution. Elle s'appuie sur la théorie des champs aléatoires afin d'extraire, par une analyse statistique, des éléments étrangers au champ gaussien modélisant l'image. Cette méthode, complètement automatique, a donné de très bons résultats concernant aussi bien le taux de détection des feux que le taux de fausses alarmes. L'algorithme développé permet de fournir des résultats en quelques minutes sur des images de quelques millions de pixels.

Cette méthode pourrait cependant être développée d'avantage. Il est notamment possible d'améliorer la loi de décision régissant la détection du feu afin de la rendre plus robuste. Il est surtout possible de compléter cette méthode par une analyse topographique des pics d'intensité, dans le but de distinguer les zones en feu et les zones brûlées encore chaudes.

Perspectives Cette méthode pourrait cependant être développée d'avantage. Il est notamment possible d'améliorer la loi de décision régissant la détection du feu afin de la rendre plus robuste. Il est surtout possible de compléter cette méthode par une analyse topographique des pics d'intensité, dans le but de distinguer les zones en feu et les zones brûlées encore chaudes.



RR n°

FIG. 8 – **En haut** :Extrait du résultat obtenu sur l'image BIRD du 04/05/2003 en canal thermique (clusters jaune : $p_l = 0.01$; bleu : $p_l = 0.05$ et rouge : $p_l = 0.1$). **En bas** : Vérité de terrain associée.




FIG. 9 – **A gauche** : Extraits du résultat obtenu sur l'image BIRD du 14/05/2003 en canal thermique (clusters jaune : $p_l = 0.01$; bleu : $p_l = 0.05$ et rouge : $p_l = 0.1$). **A droite** : Vérités de terrain associées




FIG. 10 – Extraits de résultats obtenus en utilisant des couples de probabilité limite différents.

- (a) clusters jaune : $p_l = 0.01$; bleu : $p_l = 0.05$ et rouge : $p_l = 0.1$
- (b) clusters jaune : $p_l = 0.001$; bleu : $p_l = 0.05$ et rouge : $p_l = 0.3$
- (c) clusters jaune : $p_l = 0.1$; bleu : $p_l = 0.2$ et rouge : $p_l = 0.3$
- (d) clusters jaune : $p_l = 0.0001$; bleu : $p_l = 0.001$ et rouge : $p_l = 0.01$

Lois de décision Parmi les lois de décision qui peuvent être appliquées, nous en retenons principalement deux. La première consiste à garder le maximum entre P_S et P_H . Cette loi de décision est très restrictive vis-à-vis de la détection des feux de forêt : nous gardons, en effet, la probabilité ayant le moins de chance d'être un feu. Cela permet d'avoir un taux de fausse alarme particulièrement bas.

A l'inverse, la deuxième loi de décision consiste à garder le minimum entre P_S et P_H . Cela nous donne un taux de détection des feux très élevé.

Selon l'application de cette méthode, nous utiliserons l'une ou l'autre. Par exemple, dans un cas préventif, il paraît nécessaire d'utiliser le minimum quitte à être en présence de surdétections. D'autres lois de décision peuvent être imaginées, des lois qui constitueraient des intermédiaires entre le choix du maximum et du minimum.

Une loi de décision particulièrement intéressante serait la loi de probabilité jointe de P_H et P_S . Cependant, cette dernière est, en pratique, difficile à appliquer.

Différentiation entre front de feux et zones brûlées Dans notre étude, nous avons cherché à détecter les feux de forêt sans faire de distinction entre les zones en flamme (i.e. les fronts de feux) et les zones venant d'être brûlées et donc encore chaudes. Il est envisageable d'essayer de différencier ces deux types de zones par une étude topographique des pics d'intensité. Ces derniers ont, en effet, une forme assez caractéristique comme nous le montre la figure 11. Sur cette figure, nous pouvons voir que le pic est constitué de deux parties. Dans la partie de droite (zone en rouge/orange), l'intensité est très forte et assez discontinue par rapport aux intensités voisines : c'est le front de feux. Dans la partie de gauche (zone en bleu ciel), l'intensité est plus modérée et diminue de manière assez continue quand on s'éloigne du front de feux : cela correspond aux zones venant d'être brûlées par le feu. Nous pouvons ainsi, en étudiant la topographie d'un pic d'intensité distinguer le front de feu des zones brûlées. Nous pouvons même en déduire le sens de propagation du feu par l'alignement de ces deux types de zones.




FIG. 11 – Pic d'intensité d'un feu extrait de l'image BIRD du Portugal du 14/05/03

Références

- [Adler, 1981] R.J. Adler. *The Geometry of Random Fields*. Wiley, 1981.
- [Cocquerez et Philipp, 1995] J.P. Cocquerez et S. Philipp, editors. *Analyse d'images : filtrage et segmentation*. Masson, 1995.
- [Flannigan et Haar, 1986] M. Flannigan et T. Vonder Haar. Forest fire monitoring using NOAA satellite AVHRR. *Canadian Journal of Forest Research*, 16 :975–982, 1986.
- [Friston *et al.*, 1994] K.J. Friston, K.J. Worsley, R.S.J Frackowiak, J.C Mazziotta et A.C. Evans. Assessing the significance of focal activations using their spatial extent. *Hum. Brain Map.*, 1 :214–220, 1994.
- [Lorette, 1999] A. Lorette. *Analyse de texture par méthodes markoviennes et par morphologie mathématique : application à l'analyse des zones urbaines sur des images satellitales*. Thèse de Doctorat, Université de Nice-Sophia Antipolis, 1999.
- [Nosko, 1969] V.P. Nosko. Local structure of Gaussian random fields in the vicinity of high level shines. *Soviet Mathematics : Doklady*, 10 :1481–1484, 1969.

- [Poline *et al.*, 1997] J-B. Poline, K.J. Worsley, A.C. Evans et K.J. Friston. Combining spatial extent and peak intensity to test for activations in functional imaging. *Neuroimage*, 5 :83–96, 1997.
- [Pratt, 1991] W.K. Pratt. *Digital Image Processing*. Wiley, 1991.
- [Soille, 2003] P. Soille. *Morphological Image Analysis*. Springer-Verlag, Heidelberg, 2nd edition, 2003.
- [Sprent, 1993] P. Sprent. *Applied nonparametric statistical methods*. Chapman and Hall, 1993.

Remerciements

Les auteurs remercient Alcatel Space Cannes pour le soutien financier partiel de ce travail, ainsi que l’agence spatiale allemande (DLR) pour la fourniture des données BIRD.



Unité de recherche INRIA Sophia Antipolis
2004, route des Lucioles - BP 93 - 06902 Sophia Antipolis Cedex (France)

Unité de recherche INRIA Futurs : Parc Club Orsay Université - ZAC des Vignes
4, rue Jacques Monod - 91893 ORSAY Cedex (France)

Unité de recherche INRIA Lorraine : LORIA, Technopôle de Nancy-Brabois - Campus scientifique
615, rue du Jardin Botanique - BP 101 - 54602 Villers-lès-Nancy Cedex (France)

Unité de recherche INRIA Rennes : IRISA, Campus universitaire de Beaulieu - 35042 Rennes Cedex (France)

Unité de recherche INRIA Rhône-Alpes : 655, avenue de l'Europe - 38334 Montbonnot Saint-Ismier (France)

Unité de recherche INRIA Rocquencourt : Domaine de Voluceau - Rocquencourt - BP 105 - 78153 Le Chesnay Cedex (France)

Éditeur
INRIA - Domaine de Voluceau - Rocquencourt, BP 105 - 78153 Le Chesnay Cedex (France)
<http://www.inria.fr>
ISSN 0249-6399