

Détection de feux de forêt par analyse statistique d'évènements rares à partir d'images infrarouges thermiques

Forest fire detection by statistical analysis of rare events from thermal infrared images

F. Lafarge¹, X. Descombes¹, J. Zerubia¹, S. Mathieu²

¹ Projet Ariana, commun INRIA - I3S, 2004 route des Lucioles - BP93, 06902 Sophia Antipolis, Cedex France

² Alcatel Alenia Space 100, boulevard du Midi - BP99, 06156 Cannes La Bocca Cedex France

Florent.Lafarge@inria.fr, Xavier.Descombes@inria.fr, Josiane.Zerubia@inria.fr, Sandrine.Mathieu@alcatelaleniaspace.com

Manuscrit reçu le 8 mars 2005

Résumé et mots clés

Le canal IRT (InfraRouge Thermique) contient des longueurs d'onde particulièrement sensibles à l'émission de chaleur. Les feux de forêt peuvent alors être caractérisés par des pics d'intensité sur des images IRT. Nous proposons une méthode automatique de détection des feux de forêt par imagerie satellitaire fondée sur la théorie des champs aléatoires. Pour ce faire, nous cherchons à modéliser 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 évènements 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.

Champ gaussien, évènement rare, cluster, DT-caractéristique, pic d'intensité.

Abstract and key words

The TIR (Thermal InfraRed) channel owns wave lengths sensitive to the emission of heat. So the higher the heat of an area, the higher the intensity of the corresponding pixel of the image. Then the forest fire can be characterize by intensity peak on that kind of images. We present a fully automatic method of forest fire detection in satellite images based on the random field theory. First we model the image by 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 a degree of belonging to the Gaussian field of a small area of the image. By complementarity, we estimate the probability that this area is a potential fire.

Gaussian field, rare event, cluster, DT-characteristic, intensity peak.

Remerciements

Les trois premiers auteurs remercient Alcatel Alenia Space pour le soutien financier partiel de ce travail, ainsi que l'Agence Spatiale Allemande (DLR) pour la fourniture des données BIRD.

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 la lutte contre les incendies de forêt. À travers le développement technologique, l'homme apporte des solutions de plus en plus efficaces dans la lutte contre les feux de forêt. 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 ») fondé 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. Il existe également des approches hybrides, par exemple [Li *et al.*, 2005], couplant des données thermiques avec des informations de nature variée. On peut enfin citer des travaux fondés sur la détection de fumées à partir d'images satellitaires du spectre visible [Lafarge *et al.*, 2005] ou par surveillance vidéo [Ugur Toreyin *et al.*, 2005]. Cependant, la plupart de ces méthodes nécessitent soit une base d'apprentissage, soit des connaissances *a priori* sur les capteurs employés, les caractéristiques du satellite ou bien encore les spécificités du terrain observé.

Nous proposons ici 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. Sa seule contrainte 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 cherchons à modéliser les images par des champs gaussiens afin d'en extraire, par une analyse statistique, les éléments étrangers pouvant correspondre aux 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 leurs travaux en imagerie médicale, notamment sur [Worsley *et al.*, 1992], [Friston *et al.*, 1994] et [Poline *et al.*, 1997] pour proposer cette nouvelle méthode de détection de feu.

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 de dimension 2. Pour des informations complémentaires, le lecteur est invité à consulter [Adler, 1981].

2.1. Définitions et propriétés

Définition 1

Soient (Ω, \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** .

Nous appelons alors l'ensemble des 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 n entier strictement positif, et pour tout $B \in \mathcal{B}^n$ (où \mathcal{B} est la tribu borélienne de \mathbb{R}), la famille des \mathcal{F}_d distributions (« Finite Dimensional »). Cette dernière est également appelée famille des marginales du champ X .

Définition 2

Un champ aléatoire X de dimension N est dit **stationnaire d'ordre k** 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 champs aléatoire X de dimension N est dit **stationnaire** s'il est stationnaire d'ordre k pour tout k entier strictement positif.

En imagerie 2D, la stationnarité d'un champs aléatoire signifie que les ensembles des variables aléatoires indicés par un ensemble des pixels seront distribués suivant la même loi quelque soit la translation spatiale.

Définition 3

Un champ aléatoire X 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 $t = s = t^*$.

Définition 4

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

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

X_i est alors appelée la **ms dérivée partielle** (« mean square ») de X en t par rapport à t_i (la limite étant prise au sens de L_2).

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

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

Quand un champ aléatoire est stationnaire, il est possible de prouver que ce champ est alors ms différentiable. 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 spécifiques et explicites, 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.

En d'autres termes, un champ est gaussien si toute combinaison linéaire de marginales de ce champ est gaussienne. Les \mathcal{F}_d distributions (ou marginales) 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 $R(s, t) = E[(X(s) - E[X(s)])(X(t) - E[X(t)])]$ sont spécifiées.

2.3. Ensemble d'excursion et DT-caractéristique

Définition 8

Soit $F : \mathbb{R}^N \rightarrow \mathbb{R}$ une fonction mesurable. $\forall u \in \mathbb{R}$ et S , un sous-ensemble mesurable de \mathbb{R}^N , on définit l'**ensemble d'excursion** de la fonction F au dessus du seuil u dans S par :

$$A_u(F, S) = \{t \in S : F(t) \geq u\}$$

Nous allons définir un outil permettant de quantifier le nombre d'ensembles connexes au nombre de trous près 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 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 $\chi(A_u)$, définit 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 exactement k valeurs propres négatives.

La DT caractéristique d'un ensemble d'excursion est égale à la




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

caractéristique d'Euler aux effets de bords près (c'est-à-dire quand l'ensemble d'excursion $A_u(F, S)$ est disjoint de ∂S). Cela signifie géométriquement que la DT caractéristique $\chi(A_u)$ représente le nombre de composantes connexes de A_u moins le nombre de trous. Il est à noter que $\chi(A_u)$ est indépendante du choix de x_N .

2.4. Espérance de la DT-caractéristique

Définition 10

On appelle **module de continuité** d'un champ X , défini sur un compact, la fonction

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

Propriété 1

Soient X un champ aléatoire gaussien stationnaire de moyenne nulle sur S , ensemble compact et convexe de \mathbb{R}^N . On suppose que X a des dérivées partielles continues presque partout 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 (c'est-à-dire qu'il n'existe aucune relation affine presque sûre entre les composantes de cette distribution jointe). On note λ , la mesure de Lebesgue de S . De plus, si les modules de continuité de X_i et X_{ij} (X_{ij} représentant les dérivées partielles au second ordre du champ X) satisfont la condition $P(\max_{i,j} [w_i(h), w_{ij}(h)] > \epsilon) = o(h^N)$ quand $h \downarrow 0$ et $\forall \epsilon > 0$

Alors, l'espérance de la DT caractéristique de l'ensemble d'excursion $A = A_u(X, S)$ est donnée par :

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

où $\sigma^2 = E(X^2(t))$, $a_j = \frac{(2j)!}{j!2^j}$, et Λ est la matrice $N \times N$ de covariance des dérivées partielles de X , c'est-à-dire $\Lambda = \text{var}((X_j)_{j \in [1, N]})$.



Pour plus de détails sur les démonstrations de cette propriété, le lecteur est invité à consulter [Adler, 1981] et [Worsley, 1994]. En particulier, pour un champ gaussien stationnaire de dimension 2, l'espérance de la DT caractéristique est donné par :

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

En terme d'imagerie, cette propriété nous permet d'estimer l'espérance du nombre de «clusters» au seuil u pour une image modélisée par un champ gaussien. Afin d'utiliser ce théorème dans le domaine de l'imagerie, les hypothèses de la propriété 1 doivent être vérifiées. En particulier, une image doit pouvoir être modélisable par une réalisation d'un champ gaussien stationnaire. Pour ce faire, on approxime un champ gaussien en rendant les marginales gaussiennes. Ceci constitue une approximation acceptable dans la mesure où la matrice de covariance n'intervient que de façon très secondaire dans l'algorithme que nous proposons. Ainsi, pour qu'une image soit modélisable par une réalisation d'un champ gaussien stationnaire, une condition suffisante sera, par approximation, que les marginales du champ soient gaussiennes, en d'autres termes, que la distribution des intensités des pixels de cette image suive une loi normale (cela revient à avoir une distribution normale de l'histogramme de l'image).

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 une série de prétraitements afin que ces images aient une distribution normale.

3.1. Test de normalité

Avant de détailler les prétraitements à réaliser, il s'agit de mettre en place un test de normalité sur la distribution des pixels de l'image afin d'avoir un degré de certitude quant au bon fonctionnement des prétraitements qui seront réalisés dans la suite. Il existe plusieurs tests de normalité [Sprent, 1993], comme le test de Kolmogorov-Smirnov, le test de Lin et Mulhokar ou bien encore le test de Shapiro-Wilks. Nous utiliserons le test de Kolmogorov-Smirnov, test particulièrement précis pour un nombre d'échantillons important (supérieure à une centaine), ce qui est le cas des images que nous traitons.

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 $F(x)$.

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

Nous comparons alors ϵ à des valeurs critiques tabulées selon la taille de l'échantillon et le niveau de signification voulu du test (c'est-à-dire le risque de commettre une erreur – appelé également «p-value» en analyse statistique). 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 rejetterons donc l'hypothèse que la distribution de l'image soit gaussienne, avec une probabilité de 0.01 de se tromper si l'écart maximum observé ϵ est supérieur ou égal à la valeur critique $\frac{1.63}{\sqrt{n}}$.




Figure 2. Test de Kolmogorov-Smirnov.

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.

3.2 Distribution unimodale par « K-moyennes » itérées

Les images satellitaires possèdent, bien souvent, plusieurs classes dominantes (mer, terre, nuages,...), ce qui rend leur distribution multimodale. La première étape consiste à rendre la distribution de l'image unimodale : Il s'agit de 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 (zone dont l'intensité thermique est plus forte que celle de la mer, ou d'autres modes dans le cas des pays à risque, *i.e.* pays au climat relativement « sec »). L'hypothèse selon laquelle les feux de forêt doivent être des événements rares (c'est-à-dire très minoritaires en termes de pixels dans l'image) assure l'impossibilité pour les feux de forêt de constituer eux-même un mode.

Nous utilisons l'algorithme des « K-moyennes » pour séparer les différents modes de l'image. Pour des informations complémentaires, le lecteur est invité à consulter [Pratt, 1991] et [Cocquerez et Philipp, 1995]. Plus précisément, nous proposons d'utiliser cet algorithme dans le cas où $K = 2$, *i.e.* pour deux classes, et de manière itérée. Comme nous souhaitons conserver le mode de l'image qui a la plus forte intensité moyenne, nous allons éliminer, par un principe semblable à la dichotomie, les classes de moyenne d'intensité les plus faibles. À chaque itération de cette méthode, nous séparons l'image en deux classes en utilisant l'algorithme des « K-moyennes » à deux classes et nous gardons la classe de moyenne d'intensité la plus élevée. Nous




Figure 3. Algorithme des « K-moyennes » à 2 classes itérées.

testons alors si la classe conservée suit une distribution unimodale en nous intéressant à la monotonie de la distribution. Avec une marge de tolérance relativement faible, nous accepterons le test si la distribution admet un unique maxima local, c'est-à-dire si la distribution est monotone croissante puis monotone décroissante.

Algorithmes (« K-moyennes » itéré à 2 classes)

répéter

Classifier les observations selon l'algorithme du « K-moyennes » 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.

3.3. Régularisation de la classe obtenue

Dans un second temps, la classe obtenue par l'algorithme du « K-moyennes itéré à 2 classes » est régularisée : nous cherchons alors à connexionner cette classe par morphologie mathématique. Une fermeture puis une ouverture morphologiques [Soille, 2003] sont réalisées afin de faire disparaître les petits éléments isolés de cette classe et de « reboucher les petits trous ». Ce traitement nous permet également de récupérer les pixels de faible intensité en « rebouchant les petits trous » présents dans la classe « terre », c'est-à-dire à récupérer la queue de la distribution.

3.4. Spécification d'histogramme

Après avoir rendu la distribution unimodale et régularisé la classe correspondante, nous allons rendre cette distribution gaussienne par une spécification d'histogramme. Cette transformation 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. 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 distribution de référence n'est pas algorithmiquement calculable en tout point. La transformation d'histogramme obtenue est alors une fonction croissante

continue composée de fonctions affines. Chacune 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 d'une gaussienne par fonctions affines facilement acceptée par le test de Kolmogorov-Smirnov. 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.




Figure 4. (a) : image BIRD du Portugal, canal IRT[®] DLR, 300 mètres de résolution
 (b) : image après conservation de la classe « terre » (c) : image après régularisation
 (d) : image normalisée après spécification d'histogramme
 (e)-(f)-(g)-(h) : histogrammes respectifs




Figure 5. (a)-(b)-(c)-(d) : extraits respectifs de la figure 1.

3.5. Résultats

Les résultats présentés sur les figures 4 et 5 montrent les différentes étapes dans le prétraitement de l'image. Que ce soit lors de la séparation des modes de l'image par l'algorithme des « K-moyennes » itérées 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.

4. Étude statistique sur l'appartenance d'un « cluster » à un champ gaussien

L'image a subi un certain nombre de prétraitements afin de vérifier les conditions nécessaires admises pour pouvoir l'approximer par une réalisation d'un champ gaussien. Cependant, certains pixels de forte intensité sont présents dans cette image, représentant des feux de forêt. Les prétraitements effectués dans la partie précédente n'ont pas affecté le caractère « anormal » de ces pixels relativement au reste de l'image. 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 H_0).

Pour résumer, nous considérons notre image comme 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 H_1).

Nous allons, dans ce cas, pouvoir utiliser les résultats de la théorie des champs gaussiens, et particulièrement la formule (1) afin d'établir des lois probabilistes sur l'appartenance d'un « cluster » à un champ gaussien. La probabilité d'appartenance d'un « cluster » à un champ gaussien représente la probabilité d'occurrence de ce « cluster » pris à un certain seuil, dans une réalisation d'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

Dans un premier temps, 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) :

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

où

m_t est le nombre de « clusters » au seuil t moins les trous

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 :

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

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 fonction de l'intensité maximale sur ce « cluster ». 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 :

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

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 par la suite, 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

S

Dans un second temps, nous fournissons une estimation de la probabilité d'appartenance d'un «cluster» à une réalisation d'un champ gaussien en fonction, cette fois-ci, 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 [Friston *et al.*, 1994]:

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

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, 1989] 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):

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

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.

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

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

n_t suit donc une loi exponentielle de paramètre $\lambda_t =$

$$\frac{(2\pi)^{\frac{3}{2}} |\Lambda|^{\frac{1}{2}} t \exp -\frac{t^2}{2}}{\Phi(-t)}. \text{ La loi de } n_t \text{ est donc :}$$

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

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

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

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 l'appartenance d'un «cluster» $C_t^{S_0}$ pris au seuil t à une réalisation d'un champ gaussien G_r , en fonction de sa surface S_0 . Nous avons en effet:

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

En pratique, on calcule Λ en utilisant les estimateurs empiriques des variances et covariances des dérivées du champ. 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 seuils $T = (t_{-n}, \dots, t_0, \dots, t_m)$ qui permettra d'établir une famille de «clusters» pour un pic d'intensité présentant des risques (voir figure 6). 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.

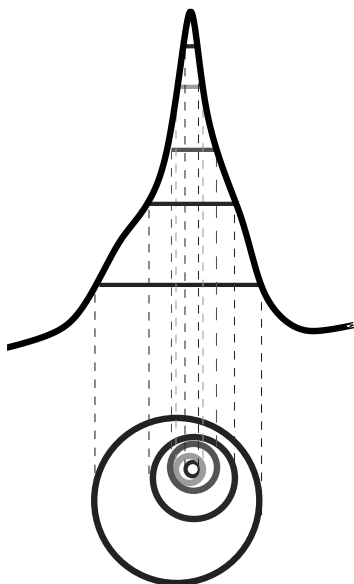


Figure 6. Exemple d'un pic d'intensité tabulé par différents seuils (en haut) et clusters associés à ces seuils (en bas).

Comme toute image a, au préalable, subi une série de prétraitements rendant sa 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 2

- 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 convaincants : le taux de détection des feux est supérieur à 85 % et le taux de fausses alarmes est quasiment nul pour une probabilité limite de 0,01 et sur une large gamme d'images BIRD.

Sur la figure 7, les «clusters» acceptés avec une probabilité limite de 0,05 sont représentés en blanc. Le résultat obtenu apparaît très correct comparativement à la vérité de terrain associée, fournie par Alcatel Space. En effet, cette dernière fait état de 16 feux répartis dans le centre du Portugal. Sur ces 16 feux, nous en détectons 15 (14 feux détectés avec $p_l = 0,01$ + 1 feu détecté avec $p_l = 0,05$). Par ailleurs, l'algorithme a détecté un feu qui n'existe pas sur la vérité de terrain : il n'y a donc qu'une seule fausse alarme pour $p_l = 0,05$. Nous pouvons remarquer qu'une probabilité limite fixée à 0,01 revoie des résultats eux aussi très bons (14 feux détectés sur 16 pour un taux de fausse alarme nul) et encore plus fiables. Enfin, en terme de temps de calcul, l'algorithme a mis deux minutes sur un P4-2Ghz pour une image 4000×1000 pixels. Il est à noter que, sur les vérités de terrain, de résolution très moyenne, les feux ont été volontairement grossis afin de pouvoir les distinguer de manière convenable.

Pour des résultats complémentaires sur d'autres images, le lecteur est invité à consulter [Lafarge *et al.*, 2004]. Il pourra également y trouver des résultats obtenus en utilisant des couples de probabilité limite différents, résultats montrant 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 traite des images infrarouge thermique à moyenne résolution. Elle s'appuie sur la théorie des champs





Figure 7. **En haut** : Extrait du résultat obtenu sur l'image BIRD(© DLR, 300 mètres de résolution) du 04/05/2003 en canal thermique (clusters blancs : $p_l = 0.05$).
En bas : Vérité de terrain associée.

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 serait possible de compléter cette étude par une analyse topographique des pics d'intensité, dans le but de distinguer les zones en feu et les zones brûlées encore chaudes. Les pics d'intensité ont, en effet, une forme assez caractéristique comme nous le montre la figure 8. Sur cette figure, nous pouvons voir que le pic est constitué de deux parties. Dans la partie de droite (zone en gris foncé), 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 gris clair), 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.




Figure 8. Pic d'intensité d'un feu extrait de l'image BIRD du Portugal du 14/05/03.

Références

- [Alder, 1981] R.J. ALDER, *The Geometry of Random Fields*, Wiley, 1981.
- [Cocquerez et Philipp, 1995] J.P. COCQUEREZ, S. PHILIPP, editors, *Analyse d'images : filtrage et segmentation*, Masson, 1995.
- [Flannigan et Haar, 1986] M. FLANNIGAN, T. VONDER HAAR, «Forest fire monitoring using NOAA satellite AVHRR», *Canadian Journal of Forest Research*, 16: 975-982, 1996.
- [Friston et al., 1994] K.J. FRISTON, K.J. WORSLEY, R.S.J. FRACKOWIAK, J.C. MAZZIOTTA, A.C. EVANS, «Assessing the significance of focal activations using their spatial extent», *Hum. Brain Map.*, 1: 214-220, 1994.
- [Lafarge et al., 2004] F. LAFARGE, X. DESCOMBES, J. ZERUBIA, Détection de feux de forêt par analyse statistique de la radiométrie d'images satellitaires, Rapport de recherche 5369, INRIA, France, Décembre 2004.
- [Lafarge et al., 2005] F. LAFARGE, X. DESCOMBES, J. ZERUBIA, Textural kernel for SVM classification in remote sensing : Application to forest fire detection and urban area extraction, *In Proc. IEEE International Conference on Image Processing*, Gênes, Septembre 2005.
- [Li et al., 2005] Y. LI, A. VODACEK, R.L. KREMENS, A.E. ONONYE, C. TANG, A hybrid contextual approach to wildland fire detection using multispectral imagery, *IEEE Trans. Geoscience and Remote Sensing*, 43: 2115-2126, 2005.
- [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, 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, 2nd edition, 2003.
- [Sprenst, 1993] P. SPRENT, *Applied nonparametric statistical methods*, Chapman and Hall, 1993.
- [Ugur Toreyin et al., 2005] B. UGUR TOREYIN, Y. DEDEOGLU, A. ENIS CETIN, Wavelet based real-time smoke detection in video, *In Proc. European Signal Processing Conference*, Antalya, Turquie, septembre 2005.
- [Worsley et al., 1992] K.J. WORSLEY, S. MARRETT, P. NEELIN, A.C. EVANS, A three-dimensional statistical analysis for CBF activation studies in human brain, *Journal of Cerebral Blood Flow and Metabolism*, 12: 900-918, 1992.
- [Worsley, 1994] K.J. WORSLEY, «Local maxima and the expected Euler characteristic of excursion sets of χ^2 , F and t fields», *Advances in Applied Probability*, 26: 13-42, 1994.





Florent **Lafarge**

Florent Lafarge a obtenu un DEA de mathématiques appliquées à l'université Paul Sabatier de Toulouse en 2004. Depuis, il réalise un doctorat à l'INRIA Sophia Antipolis et à l'IGN, respectivement au sein du projet Ariana et du laboratoire Matis. Ses travaux de thèse portent sur la reconstruction en 3D de zones urbaines. Ses thèmes de recherche concernent les modélisations stochastiques pour l'analyse d'image et la reconstruction en 3D par stéréovision.



Xavier **Descombes**

Xavier Descombes a obtenu son doctorat à l'ENST Paris en 1993. Il a ensuite rejoint l'université de Leuven en 1995, le projet PASTIS à l'INRIA en 1996 et l'Institut Max Planck pour les Neurosciences en 1997. Il est à l'INRIA Sophia Antipolis depuis novembre 1997 dans le projet Ariana. Il a obtenu l'habilitation à diriger des recherches en 2004. Parallèlement, il enseigne à Supaero et à l'ESINSA. Son domaine de recherche concerne les modélisations stochastiques pour l'analyse d'image et plus particulièrement l'utilisation des champs de Markov et des processus ponctuels marqués en télédétection. Il est auteur ou co-auteur de plus de 100 articles dans des journaux et conférences internationales.



Josiane **Zerubia**

Josiane Zerubia est chercheur permanent à l'INRIA depuis 1989. Elle est directrice de recherche depuis 1995, a été responsable du projet PASTIS (INRIA Sophia Antipolis) de 1995 à 1997 et est responsable du projet ARIANA (projet commun CNRS/INRIA/UNSA) depuis 1998. Elle est également professeur à Sup'Aero depuis 1999. Auparavant, elle était à l'institut de traitement des signaux et des images de l'université de Californie du Sud à Los Angeles en tant que Post-doctorante. Elle a également travaillé comme chercheur au Lassy (Université de Nice et CNRS) entre 1984 et 1988, au laboratoire de recherche de Hewlett Packard en France et à Palo Alto entre 1982 et 1984. Elle a obtenu un diplôme d'ingénieur de l'ENSIEG, Grenoble, en 1981, un doctorat d'ingénieur en 1986, un doctorat d'Université en 1988 et une habilitation à diriger des recherches en 1994. Elle est « fellow » de l'IEEE et membre du comité technique IEEE BISP. Elle a été membre du comité technique IEEE IMDSP de 1997 à 2003, éditrice associée de IEEE Trans. IP de 1998 à 2002, co-éditrice invitée d'un numéro spécial de IEEE Trans. PAMI en 2003, et membre du board of governors de la société IEEE SP de 2002 & 2004. Elle est actuellement adjointe à l'éditrice en chef de IEEE Trans. IP et membre du comité éditorial de IJCV et de la revue de la SFPT. Elle a été co-présidente de 3 workshops (EMMCVPR'01, Sophia Antipolis, France, IPRM'02, Moscou, Russie, et EMMCVPR'03, Lisbonne, Portugal), présidente du workshop Pixels et Cités (Marne la Vallée, France, 2003) et co-présidente des sessions spéciales de la conférence IEEE ICASSP 2006 (Toulouse, France). Son domaine d'intérêt est le traitement des images, en utilisant des modèles stochastiques ou variationnels. Elle travaille également sur l'estimation de paramètres et les techniques d'optimisation.



Sandrine **Mathieu-Marni**

Après un Master en « géosciences et géotechniques », Sandrine Mathieu-Marni a obtenu le grade de docteur « Méthodes physique en télédétection » en 1994 à l'INRIA (Institut National de Recherche en Informatique et Automatique). Elle a été Assistant Chercheur à l'Université du Maryland (USA), dans le département UMIACS, dans l'équipe d'A. Rosenfeld et R. Chelappa sur la reconnaissance automatique de cibles et la classification d'occupation des sols par « dé-mélange » (un-mixing). Elle a développé la librairie de programmes „Cocktail“ pour la classification par dé-mélange qui est disponible dans plus de 20 instituts de recherche internationaux et industries. Elle a déposé un brevet sur la correction automatique de photographies numériques avec la société « Livepicture développement ». Elle a rejoint le département Observation et Sciences d'Alcatel Space de Cannes en 2000. Ses études et travaux actuels concernent la fusion de données 2D et 3D pour l'interprétation de scènes. Elle est responsable des activités du service liées aux données hyperspectrales (images et bases de données).