

Déconvolution d'images satellitaires : modèles et estimation de paramètres

TAIMA 99

André Jalobeanu, Laure Blanc-Féraud, Josiane Zerubia

Ariana - projet commun CNRS/INRIA/UNSA

Unité de recherche INRIA Sophia Antipolis

2004, route des Lucioles, B.P. 93, 06902 Sophia Antipolis Cedex

mail : Prénom.Nom@inria.fr – web : www.inria.fr/ariana

Tél : 0 492 387 857 – Fax : 0 492 387 643

Introduction

Les dégradations subies par les images satellitaires consistent en une convolution par un opérateur H (correspondant à du flou), et un bruit N additif, blanc et gaussien, de variance σ^2 (lié au bruit du capteur). Elles sont supposées connues. Nous utilisons un modèle de régularisation introduisant une fonction φ , qui interdit l'amplification du bruit lors de la déconvolution tout en préservant les discontinuités de l'image cherchée. Ce modèle variationnel admet deux hyperparamètres λ et δ , qui sont estimés de manière automatique. Nous utilisons pour cela l'estimateur du maximum de vraisemblance appliqué à l'image observée. Nous devons générer des échantillons, images dont la probabilité tient compte des données observées et de l'a priori imposé. Cette probabilité faisant intervenir l'opérateur de convolution, il est très difficile d'utiliser un échantillonneur classique (Gibbs [2] ou Metropolis). Nous avons développé un algorithme d'échantillonnage basé sur les résultats obtenus dans [3], pour lequel nous utilisons une transformée en cosinus. Nous présentons ici un nouvel algorithme de déconvolution, rapide, qui est dérivé de cette méthode d'échantillonnage, et qui permet en même temps de restaurer l'image dégradée et d'estimer les hyperparamètres.



image originale
©CNES



image observée



image restaurée
(hyperparamètres estimés)

Position du problème

Nous utilisons pour la restauration une méthode variationnelle [1], qui consiste à minimiser un critère U traduisant l'attache aux données et le modèle de régularisation.

$$U(X, \lambda, \delta) = \|Y - HX\|^2/2\sigma^2 + \lambda^2 \sum_{i,j} [\varphi(D_x X_{ij}/\delta) + \varphi(D_y X_{ij}/\delta)]$$

Y est l'image observée, X la solution, $D_{x,y}X_{ij}$ représentent la différence entre deux pixels voisins au pixel (i, j) dans les directions x et y , et les réels λ et δ sont les *hyperparamètres*. La fonction φ est *non quadratique*, choisie de manière à lisser le bruit tout en préservant les contours. Pour traiter le problème de minimisation en X et l'estimation des paramètres λ et δ , nous utilisons un développement semi-quadratique [3] de la fonction φ :

$\varphi(u) = \arg \inf_{b \in \mathbb{R}} [(b-u)^2 + \psi(b)]$. Cela permet de remplacer la minimisation de $U(X)$ en X par la minimisation de $U^*(X, B^x, B^y)$ en X, B^x et B^y où B^x et B^y sont des variables auxiliaires associées aux gradients de l'image selon les colonnes et les lignes. L'intérêt de cette forme semi-quadratique est d'obtenir une forme quadratique lorsque B^x et B^y sont fixés.

Lorsque les conditions aux bords sont périodiques, les opérateurs de dérivation D_k et de convolution H sont des matrices circulantes par blocs et le terme quadratique est diagonalisé par une FFT. On préfère imposer des conditions de symétrie aux bords de l'image, ce qui évite l'introduction de discontinuités arbitraires dans le signal résultant. On montre alors que la FFT sur l'image symétrisée est équivalente à une DCT (transformée en cosinus) sur l'image d'origine. Les opérateurs sont alors étendus à des images de taille quadruple, symétrisées par rapport aux lignes et aux colonnes, et diagonalisés par la FFT. Le temps de calcul reste le même car le volume de données à traiter est constant.

Estimation des hyperparamètres

Les résultats de la restauration dépendent beaucoup de la valeur de λ et δ . Nous avons développé une méthode stochastique pour les estimer. Celle-ci est basée sur le *maximum de vraisemblance*.

Les hyperparamètres que nous utilisons sont ceux qui maximisent la vraisemblance de λ et δ , calculée avec l'image observée Y [5] : $(\hat{\lambda}, \hat{\delta}) = \arg \max_{\lambda, \delta} P(Y | \lambda, \delta)$.

En se plaçant dans un cadre bayésien [2], on montre que cette probabilité est proportionnelle à Z_Y/Z_X , où Z_X et Z_Y sont les constantes de normalisation correspondant aux distributions a priori et a posteriori $P(X | \lambda, \delta)$ et $P(Y | X, \lambda, \delta)$. Ces constantes ne sont pas calculables directement. En revanche, il est possible d'estimer les dérivées de la log-vraisemblance par une méthode de Monte Carlo. En considérant que les images sont des champs de Markov [2], on génère deux chaînes de Markov d'images obéissant aux distributions a priori et a posteriori. On utilise pour cela un échantillonneur de Geman et Yang [3] modifié (avec une DCT comme pour l'algorithme de restauration, voir [4]).

En calculant la moyenne empirique des dérivées de l'énergie U par rapport à λ et δ sur les échantillons ainsi fabriqués, on obtient une valeur estimée des dérivées de la vraisemblance, et l'on utilise une méthode de descente (gradient à pas constant) pour maximiser la $-\log$ -vraisemblance.

L'algorithme d'estimation

L'estimation et la restauration sont *simultanées*, car l'algorithme d'échantillonnage de la distribution a posteriori est initialisé avec l'image restaurée avec les paramètres courants. On répète en effet les étapes suivantes :

- calcul de \hat{X} par restauration de Y avec (λ_n, δ_n) ,
- estimation des dérivées ∇_λ et ∇_δ de $\log P(Y | \lambda, \delta)$ par échantillonnage dans le plan DCT,
- calcul de $(\lambda_{n+1}, \delta_{n+1}) = (\lambda_n - \alpha \nabla_\lambda, \delta_n - \alpha \nabla_\delta)$, avec α constante positive.

Au bout de 5 à 10 itérations, l'image \hat{X} converge vers le résultat de la déconvolution avec les hyperparamètres qui maximisent la vraisemblance $P(Y | \lambda, \delta)$.

Temps de calcul

Restauration : image $512 \times 512 \rightarrow 100 \text{ op.pixel}^{-1} + 140 \text{ op.pixel}^{-1} \text{iter}^{-1}$ ($\simeq 10$ itérations)

Estimation : $6500 \text{ op.pixel}^{-1} \text{iter}^{-1}$ ($\simeq 5$ itérations)

Estimation + restauration : Nouvel algorithme rapide d'estimation, total $1440 \text{ op.pixel}^{-1}$

Références

- [1] **P. Charbonnier, L. Blanc-Féraud, G. Aubert, M. Barlaud** : *Deterministic edge-preserving regularization in computed imaging*, IEEE Trans. Image Proc., Vol 6, No 2, pp 298-311, Feb. 1997.
- [2] **S. Geman, D. Geman** : *Stochastic relaxation, Gibbs distributions, and the Bayesian restoration of images*, IEEE Trans. Patt. Anal. Machine intell., Vol 6, No 6, pp 721-741, Nov. 1984.
- [3] **D. Geman, C. Yang** : *Nonlinear image recovery with half-quadratic regularization and FFTs*, IEEE Trans. Image Proc., Vol 4, No 7, pp 932-946, Jul. 1995.
- [4] **A. Jalobeanu, L. Blanc-Féraud, J. Zerubia** : *Estimation d'hyperparamètres pour la restauration d'images satellitaires par une méthode « MCMCML »*, Rapport de Recherche INRIA No 3469, Août 1998.
- [5] **L. Younes** : *Parametric inference for imperfectly observed Gibbsian fields*, Prob. Th. Fields, No 82, pp 625-645, Springer-Verlag, 1989.