

# Emulation stochastique haute-résolution d’images texturées de la surface de l’océan à partir d’observations satellitaires

Brahim BOUSSIDI<sup>1</sup>, Emmanuelle AUTRET<sup>2</sup>, Bertrand CHAPRON<sup>2</sup>, Ronan FABLET<sup>1</sup>

<sup>1</sup>Télécom Bretagne ; UMR LabSTICC  
Technopôle Brest-Iroise, 29238 Brest cedex, France

<sup>2</sup>Ifremer/LOS  
Technopôle Brest-Iroise, 29280 Plouzané cedex, France

brahim.boussidi@telecom-bretagne.eu, ronan.fablet@telecom-bretagne.eu,  
autret@ifremer.fr, chapron@ifremer.fr

**Résumé** – Cet article traite de la super-résolution d’images texturées, c.à.d. de la simulation d’images texturées à haute-résolution à partir d’une image basse-résolution. Le domaine d’application envisagé est l’émulation haute-résolution de champs géophysiques à la surface de l’océan à partir d’observations satellitaires basse-résolution. Les classes de texture considérées présentent des caractéristiques spécifiques en termes de régularité géométrique, et nous portons notre intérêt sur des modèles stochastiques de textures, notamment des processus d’Orstein-Uhlenbeck, qui permettent de formuler des contraintes ou connaissances explicites sur la géométrie des textures. Nous illustrons l’application de ces modèles à la super-résolution de champs haute-résolution de température de surface de l’océan à partir d’une observation basse-résolution.

**Abstract** – This paper addresses stochastic geometry-driven image models and its application to super-resolution issues for sea surface geophysical fields remotely sensed from space. Whereas most stochastic image models rely on some priors on the distribution of grey-level configurations (e.g., patch-based models, Markov priors, multiplicative cascades,...), we here focus on geometric priors. We aim at simulating texture samples while controlling high-resolution geometrical features. In this respect, we introduce a stochastic model for texture orientation fields stated as a 2D Orstein-Uhlenbeck process. We show that this process resorts in the stationary case to priors on orientation statistics. We exploit this model to state image super-resolution as a geometry-driven variational minimization, where the geometry is sampled from the proposed conditional 2D stochastic model. We demonstrate the relevance of this approach for real images associated with the remote sensing of ocean surface dynamics.

## 1 Introduction

Le développement de l’observation satellitaire de l’océan a considérablement fait évoluer notre connaissance et compréhension des dynamiques océaniques à l’échelle globale, et a également mis en évidence l’importance des processus dits de submésos-échelle et méso-échelle [16]. Dans ce contexte, différentes technologies de capteurs satellitaires sont opérationnels et diffèrent notamment dans l’échantillonnage spatio-temporel réalisé. A titre d’exemple, pour l’observation de la température à la surface de la mer, les capteurs micro-onde fournissent des images avec des résolutions spatiales de l’ordre de quelques dizaines de kilomètres, alors que les capteurs dans des longueurs visibles fournissent des images dites haute-résolution, c.à.d. avec une résolution spatiale de l’ordre de quelques kilomètres. Ces capteurs diffèrent également dans leur sensibilité à la couverture nuageuse, les capteurs haute-résolution pouvant présenter des taux de données manquantes extrêmement élevés. Les problématiques d’interpolation de données manquantes sont donc des enjeux opérationnels importants. On peut notamment citer des travaux récents visant à combiner des observations à différentes résolutions [2]. Il est toutefois à noter que la modélisa-

tion inter-échelle de ces images géophysiques restent très peu explorée. Il s’agit de l’objet de cet article qui vise plus particulièrement à formuler des modèles de super-résolution basés sur une information de texture pour simuler des images haute-résolution conditionnellement à une image basse-résolution. Les classes de texture considérées présentent des caractéristiques spécifiques en termes de régularité géométrique, et nous portons notre intérêt sur des modèles stochastiques de textures formulant des contraintes ou connaissances explicites sur la géométrie des textures.

La modélisation et la simulation des textures a fait l’objet de très nombreuses contributions et d’avancées importantes depuis une dizaine d’années. On peut notamment citer les modèles markoviens, les modèles basé-exemple, les modèles de cascades multiplicatives [5, 8, 12, 15]. Récemment, différents modèles ont également proposé spécifiquement pour la super-résolution de textures [4, 6, 11, 12]. Ces différents modèles reposent sur une modélisation explicite (modèles de Markov, cascades multiplicatives,...) ou implicites (modèles basé-patch) du champ scalaire 2D représentant l’image. Il est largement connu que les caractéristiques de géométrie et de contraste sont potentiellement des caractéristiques indépendantes des images, dans

le sens où la géométrie des images est invariante au contraste [17]. Toutefois, à notre connaissance, les modèles pré-cités ne formulent pas explicitement d'a priori sur la géométrie des textures. Les cascades multiplicatives et les modèles fractaux [5] le prennent uniquement partiellement en compte à travers la caractérisation d'une dimension fractale et/ou d'un spectre multifractal. En particulier, dans le cas de la super-résolution de texture, il apparaît important d'appréhender la non-stationnarité du conditionnement entre basse et haute résolutions.

Nous proposons ici de développer une modélisation stochastique des textures exploitant des connaissances a priori explicites sur la géométrie des textures considérées, notamment en termes de variabilité de la régularité géométrique locale des lignes de niveaux.

## 2 Modèle stochastique de la géométrie des images

### 2.1 Modèle proposé

Dans le prolongement de travaux antérieurs qui ont montré l'intérêt de modéliser les lignes de niveaux d'une image comme des réalisations de marches aléatoires pour les classes de textures considérées [1, 3], nous faisons l'hypothèse que les lignes de niveaux d'une image peuvent être modélisées comme des réalisations d'une marche aléatoire à pas constant définie par le processus Orstein-Uhlenbeck process [7] :

$$d\theta(t) = -\gamma(\theta(t) - \theta_0) dt + \sigma dW(t) \quad (1)$$

où  $\theta(t)$  est la direction de déplacement au temps  $t$  et  $\theta_0$  un biais directionnel.  $dW(t)$  est un processus brownien 1D. L'un des intérêts de ce modèle relativement simple est que l'on peut caractériser la distribution stationnaire du processus  $\theta$  qui est défini par l'équation de Fokker-Plank associé au processus Orstein-Uhlenbeck [7]. En particulier, les paramètres  $\gamma$  et  $\sigma$  contrôlent explicitement la géométrie de la trajectoire, notamment en termes de variabilité autour du biais directionnel et de régularité locale de la trajectoire. Nous illustrerons par une analyse statistique sur des données réelles la pertinence de ce modèle stochastique géométrique pour les lignes de niveaux des images texturées considérées.

Nous proposons ici d'étendre ce modèle pour modéliser le champ des orientations locales d'une image, champ qui définit la géométrie conjointe des lignes de niveaux de l'image. Nous notons ce champ  $\theta$ . Pour une image  $I$ , le champ d'orientation  $\theta$  est tel que  $(-\sin \theta \ \cos \theta)^t = \nabla I / \|\nabla I\|$  où  $\nabla I$  est le gradient de  $I$ . Ceci nous conduit à considérer le modèle suivant :

$$d\theta(p) = -\gamma(\theta(p) - \theta_0(p)) dp + \sigma dW(p) \quad (2)$$

où  $W$  est une surface brownienne 2D et  $\theta_0$  un champ d'orientations de référence. Comme précédemment, les paramètres  $\gamma$  et  $\sigma$  permettent de contrôler la régularité du champ d'orientation  $\theta$ . Etant donné ce modèle stochastique du champ des orientations, nous pouvons formuler un modèle d'image de telle manière à reconstruire une image dont les lignes de niveau seront

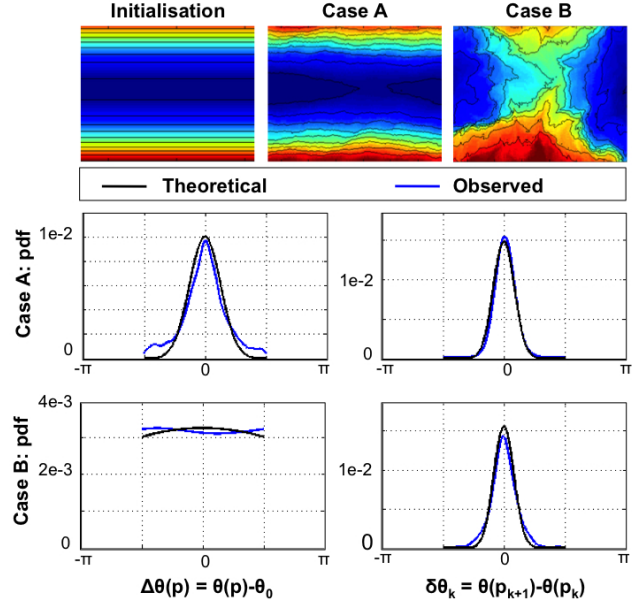


FIGURE 1 – Simulations du modèle stochastique proposé (Eq.3) dans le cas stationnaire : première ligne, initialisation considérée (gauche), simulation pour le jeu de paramètres A (milieu), simulation pour le jeu de paramètres B (droite); deuxième ligne, distribution des écarts angulaires à la direction de référence, ici horizontale (gauche) et le long des lignes de niveau (droite) pour les jeux de paramètres A; troisième ligne, similaire à la deuxième ligne pour le jeu de paramètres B. Les statistiques d'orientation des simulations (bleu,-) sont comparées aux distributions stationnaires théoriques (noir,-). Les jeux de paramètre considérés sont les suivants :  $\gamma = 0.6$  and  $\sigma = 0.3$  pour le cas A, et  $\gamma = 5e - 3$  et  $\sigma = 0.4$  pour le cas B.

en tout point tangentes au champ d'orientation. Formellement, ce modèle s'exprime de la manière suivante :

$$\begin{cases} d\theta(p) = -\gamma(\theta(p) - \theta_{LR}(p)) dp + \sigma dW(p) \\ \tilde{I} = \arg \min_I \int \|\langle \nabla I(p), u_{\theta}(p) \rangle\| dp \end{cases} \quad (3)$$

Etant donné une simulation du modèle stochastique de champs d'orientation, la minimisation variationnelle est résolue par une méthode classique de descente de gradient [9]. Nous fournissons en Fig.1 des exemples de simulations de ce modèle pour deux jeux de paramètres  $\gamma$  et  $\sigma$ .

### 2.2 Application à la super-résolution

Dans l'application considérée, le champ d'orientation  $\theta$  modélise le champ d'orientations de l'image haute-résolution et  $\theta_0$  correspond au champ d'orientations de l'image basse-résolution. Comme illustré en Fig.1, on peut remarquer que la variabilité géométrique de la haute-résolution autour de la basse-résolution n'est pas en général stationnaire. En particulier, dans les zones de gradient fort, il est attendu une faible variabilité de  $\theta$  autour de  $\theta_0$ , alors que cette variabilité peut être très forte dans

des zones de faible gradient. Cette observation, confirmée par une analyse statistique (non illustrée ici), nous conduit à proposer de formuler les paramètres  $\gamma$  et  $\sigma$  comme des fonctions du gradient à basse-résolution :

$$\begin{cases} \gamma(p) = \gamma_0 \|\nabla I_{BR}(p)\|^\nu \\ \sigma(p) = \sigma_0 \|\nabla I_{BR}(p)\|^{-\beta} \end{cases} \quad (4)$$

où  $I_{BR}$  est l'image basse-résolution.  $\gamma_0$ ,  $\sigma_0$ ,  $\nu$  et  $\beta$  sont des scalaires positifs.

Étant donné ce modèle stochastique des champs d'orientation des images à haute-résolution, nous formulons le problème de la simulation d'une image texturée haute-résolution  $\tilde{I}$  conditionnellement à une image basse-résolution  $I_{BR}$  comme suit :

$$\begin{cases} d\theta(p) = -\gamma(p) (\theta(p) - \theta_{LR}(p)) dp + \sigma(p) dW(p) \\ \tilde{I} = \arg \min_I \int \|\langle \nabla I(p), u_\theta(p) \rangle\| dp \\ \text{Subject to } I_{BR} = \mathcal{P}[\tilde{I}] \end{cases} \quad (5)$$

où  $W$  est une surface brownienne,  $\theta_{BR}$  le champ d'orientation de l'image basse-résolution et  $\mathcal{P}$  le projecteur sur l'espace des images basse-résolution, qui garantit que la version basse-résolution de l'image simulée est bien l'observation basse-résolution  $I_{BR}$ . La mise en oeuvre de ce modèle procède en deux étapes : i) la simulation du champ d'orientation haute-résolution, ii) la résolution du problème variationnel qui garantit que les lignes de niveaux de l'image  $I$  sont localement alignés avec le champ d'orientations simulé  $\theta$ . Cette deuxième étape est similaire au problème traité dans [9].

### 3 Résultats

Nous fournissons en Fig.2 une illustration des résultats obtenus par le modèle proposé (Fig.1) pour la simulation haute-résolution de champs de température à la surface de la mer à partir d'une observation satellitaire basse-résolution. L'intérêt du modèle proposé est de pouvoir simuler des images de température réalistes en garantissant des propriétés géométriques de régularité locale, tout en retrouvant (sans que cela soit explicitement formulé par le modèle) des caractéristiques spectrales, multifractales et de non-gaussianité. En particulier, cette exemple pointe l'importance d'une modélisation non-stationnaire conditionnée par l'observation à basse-résolution pour bien appréhender les différences de variabilité inter-échelle entre des zones de forts et faibles gradients.

Un deuxième exemple est fourni en Fig.2 qui compare le modèle proposé à des modèles de simulation fournis d'une part par un modèle gaussien avec une covariance spatiale fournie par la covariance empirique de l'image haute-résolution et d'autre part un modèle basée uniquement sur les marginales de la différence entre l'image basse-résolution et l'image haute-résolution. Alors que le modèle gaussien garantit de reproduire la densité

spectrale de l'image haute-résolution, le deuxième modèle garantit de se conformer à la non-gaussianité de l'image haute-résolution. Cet exemple illustre clairement que ces conditions prises séparément ne permettent pas de reproduire des images haute-résolution réalistes et motive l'approche considérée ici.

### Références

- [1] Ba, S., et al. Statistical descriptors of ocean regimes from the geometric regularity of Sea Surface Temperature observations. *IEEE GRSL*, 9(5) :951-955,2012.
- [2] Ba et al. Interpolation variationnelle de séquences multimodales d'images satellitaires de l'océan. *Traitement du Signal*, 29(3-5) :433-440, 2013.
- [3] Bernard, D., Boffetta, G., Celani, A., Falkovich, G. Conformal invariance in two-dimensional turbulence. *Nature Physics*, 2(2) : 124-128, 2006
- [4] Byung Tae Oh, Jay Kuo, C.-C. Super-resolution texture synthesis using stochastic PAR/NL model. *JVCR*, 23(7) :995-1007, 2012.
- [5] Chainais, P. Infinitely Divisible Cascades to Model the Statistics of Natural Images. *IEEE TPAMI*, 29(12) :2105-2119, 2007.
- [6] Chainais, P. Koenig, E., Delouille, V., Hochedez, J.-F. Virtual super resolution of textured images using multifractal stochastic processes. *JMIV*, 39(1) :28-44, 2011.
- [7] Codling, E.A., Plank, M.J., Benhamou, S. Random walk models in biology. *J. R. Soc. Interface*, 5 :813-834, 2008.
- [8] Efros, A.A., Freeman, W.T. Image Quilting for Texture Synthesis and Transfer. *Proc. ACM SIGGRAPH*, 2001.
- [9] Fablet, R., Pujolle, S., Chessel, A., Benzinou, A., Cao F. 2D Image-based reconstruction of shape deformation of biological structures using a level-set representation. *CVIU*, 111(3) :295-306, 2008.
- [10] Fattal, R. Image upsampling via imposed edge statistics. *Proc. ACM SIGGRAPH*, 26(3) :95-102, 2007.
- [11] Freeman, W.T., Jones, T.R., Pasztor, E.C. Example-based super-resolution. *IEEE Comp. Graph. App.*, 22(2) :56-65, 2002.
- [12] Freeman, W.T., Liu, C. Markov Random Fields for Super-resolution and Texture Synthesis. In A. Blake, P. Kohli, and C. Rother, eds., *Advances in Markov Random Fields for Vision and Image Processing*, Chapter 10. MIT Press, 2011.
- [13] Galerne, B., Gousseau, Y., Morel, J., 2011. Random phase textures : Theory and synthesis. *IEEE TIP*, 20(1), 257-267.
- [14] Glasner, D., Bagon, S., Irani, M. Super-resolution from a single image. *Proc. ICCV*, 2009.
- [15] Heeger, D.J., Bergen, J.R. Pyramid Based Texture Analysis/Synthesis. *Proc. ACM SIGGRAPH*, 229-238, 1995.
- [16] Lapeyre, G., Klein, P. Dynamics of the upper oceanic layers in terms of surface quasigeostrophy theory. *J. Phys. Ocean.*, 36 :165-176, 2006.
- [17] Monasse, P., Guichard, F. Fast Computation of a Contrast Invariant Image Representation. *IEEE TIP*, 9 :860-872, 2000.

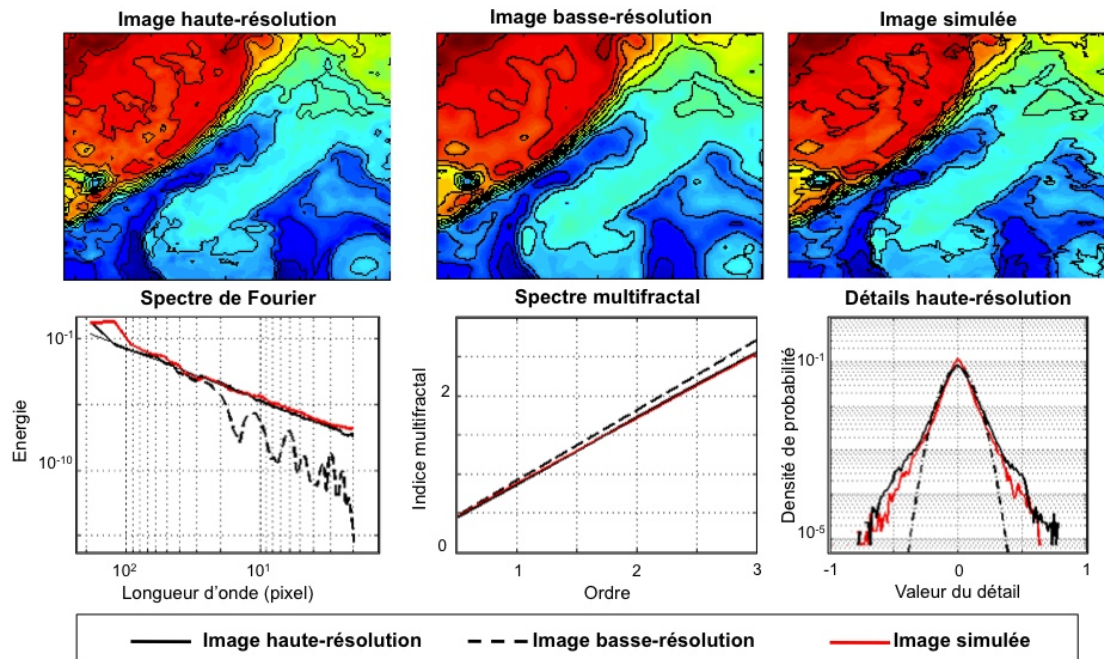


FIGURE 2 – **Simulation haute-résolution d’un champ de température à partir d’une observation basse-résolution** : image réelle haute-résolution (première ligne, droite), image basse-résolution (sous-échantillonnage d’un facteur 16 horizontalement et verticalement ; première ligne, centre), image haute-résolution simulée (première ligne, droite), densité spectrale des images (deuxième ligne, gauche), spectre multifractal des images (deuxième ligne, centre), distribution marginale de la différence entre images haute et basse résolution mettant en évidence la non-gaussianité des images réelles et simulées (deuxième ligne, droite).

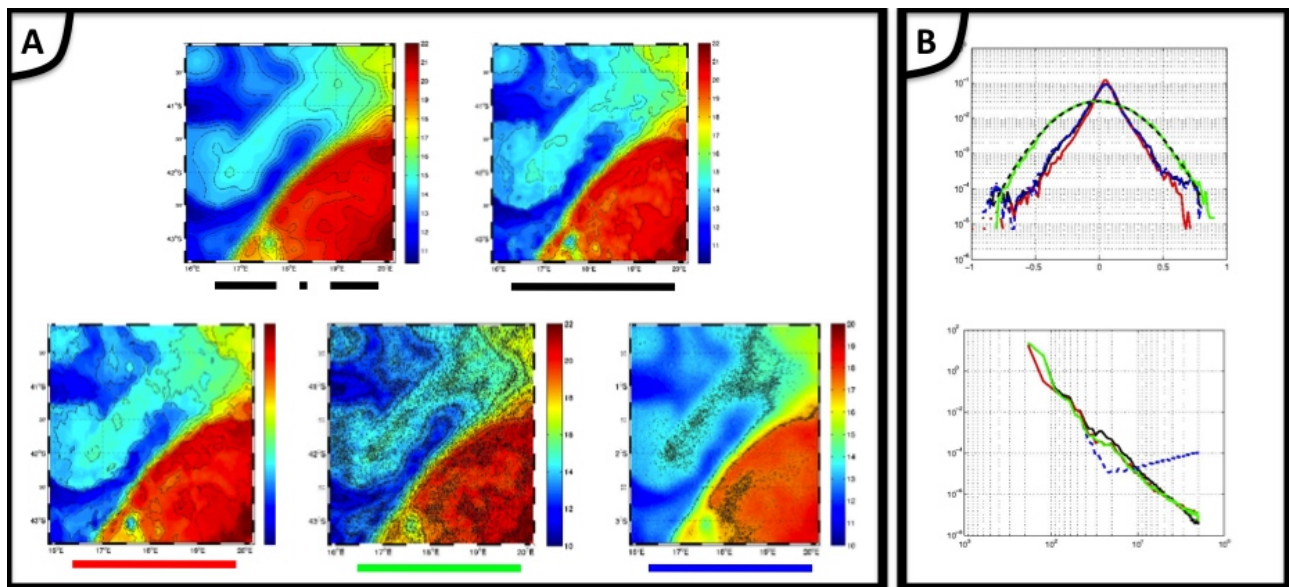


FIGURE 3 – **Comparaison de modèles de simulation haute-résolution d’un champ de température à partir d’une observation basse-résolution** : nous comparons, dans l’encadré A, de gauche à droite et haut en bas, les observations basse-résolution et haute-résolution, la simulation par le modèle proposée, une simulation par un modèle de champ gaussien dont la covariance est la covariance empirique de l’image haute-résolution [13] et une simulation dont le modèle sous-jacent est donné par la distribution empirique des marginales des détails haute-résolution. L’encadré B compare pour chaque image les distributions des détails haute-résolution (i.e., la différence entre l’image haute-résolution et l’image basse-résolution) et les densités spectrales radiales.