

Assimilation d’images et de structures

Nicolas PAPADAKIS^{1,2}, Vincent CHABOT², Alexandros MAKRIS^{2,3}, Maëlle NODET^{2,3} Arthur VIDARD²

¹Institut de Mathématiques de Bordeaux, 351 Cours de la Libération, 33401 Talence cedex, France

²Équipe MOISE, Laboratoire Jean Kuntzmann/Inria Rhône-Alpes,
51 rue des Mathématiques, Campus de St Martin d’hères, BP 53, 38041 Grenoble cedex 09, France

³Université Joseph Fourier, Grenoble, France

nicolas.papadakis@math.u-bordeaux1.fr, vincent.chabot@inria.fr
alexandros.makris@imag.fr maelle.nodet@imag.fr patrick.vidard@inria.fr

Résumé – Ces travaux traitent de l’assimilation des structures contenues dans les images satellite de l’océan. Il s’agit de modéliser les liens entre les déformations spatio-temporelles des structures (filaments, vortex...) contenues dans les images avec les variables physiques des modèles numériques de l’océan. Les images sont classiquement assimilées au niveau du pixel. Les méthodes présentées dans cet article s’intéressent à l’assimilation dans des espaces relatifs à la nature des structures observées dans les images. De nouvelles approches basées sur des espaces d’observation et métriques adaptées aux structures sont proposées pour assimiler les images.

Abstract – This paper reviews some recent works on assimilation of structures contained in satellite images of the ocean. Image assimilation consists in controlling the state of a numerical model using the spatio-temporal information of image sequences. The main issue is to measure the difference between an ideal image provided by the model and a satellite image. We therefore propose different kind of metrics between images that allow a better assimilation of image structure information.

1 Introduction

La résolution et la fréquence d’acquisition des images d’observation de la terre augmentent actuellement de manière vertigineuse avec les données fournies par les nouveaux satellites haute résolution. Les images de l’océan sont une source de données primordiale pour les modèles de prévision en géophysique, car on ne dispose que de très peu de données in situ sur ces larges étendues d’eau. Depuis quelques années, au sein de l’équipe MOISE, nous nous intéressons à l’utilisation de séquences d’images satellites dans le processus d’assimilation de données [20]. Ces séquences peuvent fournir de nombreuses informations sur les dynamiques océanique et atmosphérique, mais sont actuellement sous exploitées par les systèmes d’assimilation qui n’utilisent pas directement l’évolution spatio-temporelle des structures contenues dans les séquences d’images satellite.

L’assimilation de données consiste à calibrer un modèle numérique par comparaison des variables de ce modèle avec des observations externes du système considéré [13], la balance entre prédiction numérique et observations étant réalisée à partir d’a priori statistiques sur les erreurs de chacun. La comparaison est classiquement modélisée par une distance L^2 lorsque l’on observe directement une variable du modèle numérique, ce qui est par exemple le cas pour des modèles atmosphériques couplés à des images satellite de pression du haut des nuages [12]. Dans le cas d’images mesurant indirectement les variables du modèle (couleur de l’eau, nuages), il existe des approches indirectes d’assimilation, qui consistent à extraire des infor-

mations des images (structures, déplacements) puis à les utiliser dans un deuxième temps comme observation du modèle [15]. Des méthodes utilisant la relation du flot optique afin de lier directement les déformations de séquences d’images aux variables physiques des modèles ont également été proposées [16, 7, 8] mais leur application reste limitée car les modèles de flot optique ne permettent pas de capturer la totalité de la dynamique réelle du système étudié.

Ces travaux montrent néanmoins que l’information utile des images est principalement présente dans les structures (fronts, vortex, filaments, nuages...) caractérisées par des gradient spatiaux importants. Dans ce contexte, une distance L^2 pixel à pixel ne permet pas de prendre en compte la notion de distance entre structures. La définition d’espaces d’observation et de distances permettant de mieux représenter la physique contenue dans les images et de modéliser les déplacements de structures est donc un point d’étude clé pour l’amélioration des modèles de prévision. Récemment, les ensembles de lignes de niveaux ont été utilisés afin d’analyser l’évolution des structures contenues dans les images satellite. Ceci concerne notamment les nuages pour les modèles atmosphériques [16, 19] ou des fronts contenus dans des cartes de SST (Sea Surface Temperature) pour des images de l’océan [3]. De telles approches permettent également de reconstituer des cartes de SST occultées par des nuages dans un formalisme variationnel d’assimilation de données [2]. Le couplage de ce type d’information avec les variables des modèles numériques reste néanmoins un objectif assez lointain.

Dans cet article, en suivant l’approche proposée dans [20], nous portons notre attention sur l’assimilation d’images de concentration d’un traceur passif transporté par un modèle numérique simplifié de l’océan. Le but de ce travail est de contrôler l’état d’un modèle Shallow Water 2D (vitesses moyennées sur la verticale et hauteur d’eau) à partir des séquences d’images observées. Le lien entre les observations et les variables de vitesse du modèle est ainsi implicitement obtenu par l’équation de transport du traceur passif. Nous travaillons actuellement dans le cadre d’expériences jumelles, où le but est de retrouver l’état connu d’un scénario synthétique créé par le modèle à partir d’observation de l’image du traceur. L’erreur Root Mean Square (RMS) entre les estimations et les valeurs connues des variables du modèle sert de critère de validation des différentes approches.

Plusieurs stratégies sont proposées pour assimiler les structures contenues dans la séquence d’images. Elles concernent premièrement l’assimilation directe des images dans l’espace des pixels, puis la réduction de dimension par une assimilation dans l’espace des coefficients d’ondelettes. Une approche multi-résolution permet en effet de capturer les phénomènes physiques à différentes échelles. La robustesse de telles approches par rapport au bruit des données est alors étudiée. Dans un second temps, une assimilation en deux phases tenant compte de la position des structures sera abordée. Enfin, en considérant les images comme des densités, nous présentons succinctement l’intérêt de la distance de Wasserstein comme métrique entre images dans le cadre de l’assimilation.

2 Stratégies d’assimilation des images

2.1 Assimilation directe

Afin de comparer l’image du traceur du modèle avec les images observées, l’approche la plus naturelle est une comparaison L^2 pixel à pixel. Au vu de la grande dimension des images satellite ($>10^6$ pixels), des comparaisons dans des espaces d’ondelettes ou curvelettes [20] ont été introduites par l’équipe MOISE. En seuillant la valeur des coefficients après transformation en curvelettes ou ondelettes, la dimension de l’espace des observations est réduite et les structures contenues dans les images sont également mieux représentées. La définition d’une matrice de covariance des erreurs d’observation est néanmoins assez délicate dans de tels espaces. Le passage d’une matrice de covariance dans la base des pixels à une base d’ondelettes implique en effet des allocations mémoires conséquentes et un coût de calcul important [11]. Dans [10], nous avons proposé une comparaison des gradients des images, représentation plus robuste au bruit et décrivant de manière adaptée la géométrie des structures observées. L’information pertinente donnée par les gradients étant assez éparse dans les images, la dimension de l’espace d’observation peut aussi être réduite dans ce cas et la modélisation de la matrice de covariance des erreurs d’observation reste simple. Afin de déterminer la robustesse de ces approches, nous étudions leur com-

portement dans des cas synthétiques pour différentes classes de bruits : additif gaussien indépendant (voir Figure 1) ou spatialement corrélé, bruit multiplicatif. Les résultats de l’assimilation pour différents opérateurs de comparaison entre images sont présentés dans le Tableau 1. Ils montrent la robustesse des opérateurs basés sur les gradients pour des hypothèses de bruit relativement élevés.

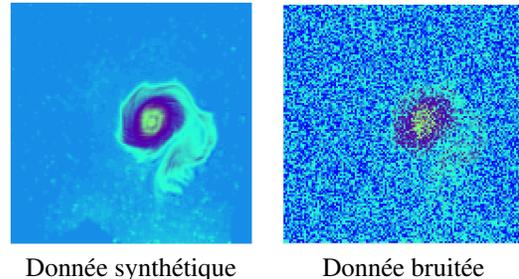


FIGURE 1 – Images utilisées pour l’assimilation. A gauche scénario parfait, à droite : pire scénario de bruit additif Gaussien (SNR = 6.8 dB).

| SNR | 6.8 | 12.3 | 26.2 | 32.3 | 46.3 |
|----------|--------------|--------------|--------------|-------------|-------------|
| Curvelet | 76.3% | 35.4% | 12.9% | 7.0% | 6.3% |
| Wavelet | 62.3% | 40.2% | 13.0% | 7.5% | 6.0% |
| Pixels | 63.2% | 32.9% | 11.5% | 6.5% | 6.0% |
| Gradient | 58.0% | 31.6% | 11.5% | 7.4% | 5.0% |

TABLE 1 – Ratio d’erreur RMS entre les vitesses estimées après assimilation et les vitesses données en initialisation, pour des bruits additifs Gaussien d’amplitudes décroissantes.

2.2 Assimilation en deux temps

L’état des modèles numériques est classiquement décrit à partir d’une représentation eulérienne, où l’intensité des variables est calculée en chaque point d’une grille discrète. Afin de gérer d’éventuels mauvais positionnements des structures lors d’une assimilation séquentielle des données (e.g. avec un filtre de Kalman d’Ensemble), une approche en deux temps a été proposée dans [18]. Il s’agit ici de distinguer les erreurs de position avec celles d’intensité dans un formalisme Bayésien intégrant de nouvelles variables représentant les erreurs de position de l’état. Plus précisément, cette méthode consiste à premièrement recalculer la position des structures de l’état par rapport aux observations, puis à corriger l’intensité des variables avec un processus classique d’assimilation. Le champ continu de recalage est estimé de manière dense.

Dans [14], nous avons proposé d’utiliser des outils de vision par ordinateur afin d’estimer le champ de déplacement permettant de réaliser le recalage de l’état. La principale contribution de ce travail est de détecter et d’apparier les structures du traceur du modèle avec celles des images observées. Pour cela, nous utilisons les descripteurs locaux SURF [5] afin d’obtenir une représentation de plus haut niveau du contenu des images. L’apparence globale des structures détectées peut va-

rier de manière significative au cours du temps, et donc entre deux images successives. Les descripteurs SURF, basés sur les gradients locaux des images, permettent de préserver l'information géométrique (filaments, vortex...). Les descripteurs calculés sur l'image du modèle sont alors comparés avec les descripteurs estimés sur l'image observée. En travaillant dans l'espace des structures détectées, qui est de très faible dimension, des méthodes telles que le filtrage particulaire peuvent être utilisées pour réaliser l'appariement entre descripteurs. On obtient ainsi une estimation précise des erreurs de positions des différentes structures. Le recalage de l'état du modèle est alors réalisé de manière robuste en interpolant les vecteurs locaux d'appariement des structures. Les expériences sur le modèle Shallow Water 2D, présentées dans la Figure 2, montrent qu'une telle approche permet de faire converger beaucoup plus rapidement un filtre de Kalman d'Ensemble, dans le cas d'erreurs importantes dans la position des structures. La Figure 3 illustre enfin qu'avec la correction des positions des structures, les erreurs sont aussi plus rapidement diminuées sur les composantes de la vitesse du modèle, même si la correction est réalisée uniquement sur la hauteur d'eau.

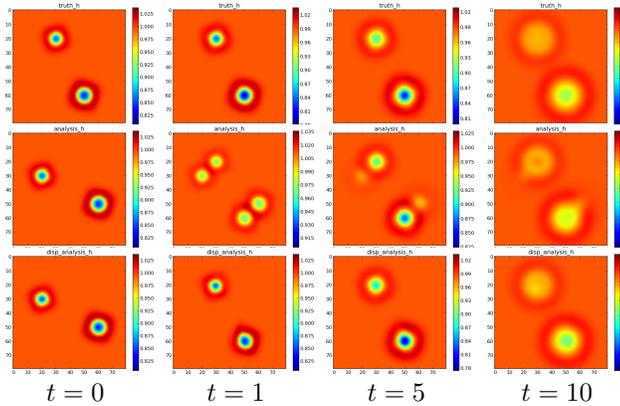


FIGURE 2 – Évolution de la hauteur d'eau du modèle Shallow Water. Haut : observation. Milieu : assimilation sans alignement de l'état. Bas : assimilation avec alignement de l'état. Comme indiqué sur la première colonne, la position initiale des structures est erronée. La correction de la position des structures permet une convergence plus rapide de la méthode d'assimilation séquentielle.

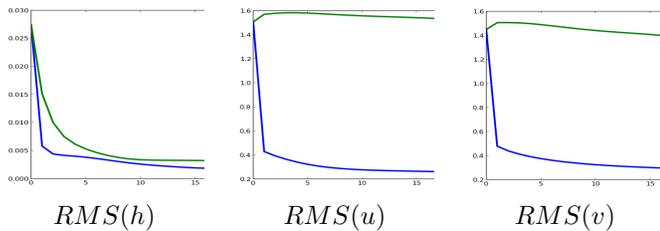


FIGURE 3 – Évolution de l'erreur RMS sur 15 pas de temps pour l'ensemble des composantes du modèle (la hauteur d'eau h et les composantes de la vitesse u et v). Les courbes bleues et vertes représentent respectivement l'évolution de l'erreur avec et sans correction des positions des structures.

2.3 Transport optimal

Afin de définir une métrique entre images permettant de prendre en compte les déplacements de structures, des méthodes basées sur l'estimation du flot optique ont été proposées dans [16, 7, 8]. Ces approches nécessitent la calibration d'un paramètre de régularisation du champ de déplacement dont la valeur optimale est inconnue. Des a priori dépendant des valeurs physiques sous-jacentes du modèle peuvent être utilisés, mais la calibration reste relativement empirique. Notons enfin que le calcul du flot optique entre deux images n'est pas symétrique et qu'on ne peut donc pas définir une norme à partir de cet outil. En considérant les images comme des densités, une solution est d'utiliser la distance de Wasserstein qui mesure le transport minimal permettant de déplacer une densité vers une autre. Les récentes avancées théoriques [1, 21] et numériques [6, 9, 17] dans le domaine du transport optimal permettent ainsi d'envisager d'utiliser cette métrique pour comparer deux images. Le calcul de la distance et du plan de transport associé est néanmoins très coûteux en pratique et des études numériques sont nécessaires pour une future application.

La distance de Wasserstein possède néanmoins des propriétés pertinentes pour le calcul de distances entre images. En effet, lorsque le support des densités contenues dans les deux images est disjoint, une métrique classique, pixel à pixel, n'est pas capable de mesurer la distance séparant les supports ; la distance entre structures est alors mal estimée. Dans les Figures 4 at 5, nous illustrons les chemins géodésiques associés à la distance L^2 et à la distance de Wasserstein entre deux densités, pour deux scénarios de translations d'amplitudes différentes.

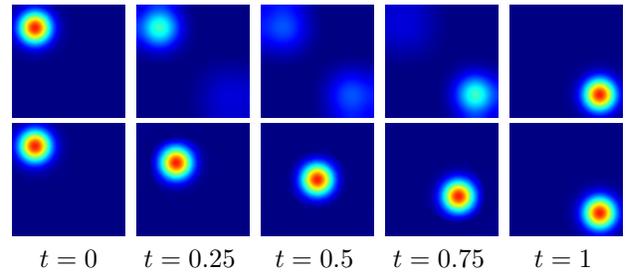


FIGURE 4 – Interpolation entre deux densités. Ligne du haut : chemin géodésique de L^2 . Ligne du bas : chemin géodésique de l'espace de Wasserstein. Distance $L^2 = 0.0657$, Distance de Wasserstein = 44.39.

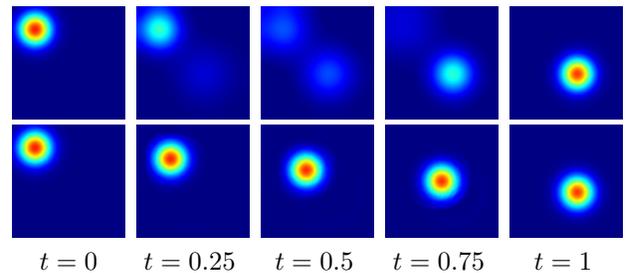


FIGURE 5 – Interpolation entre deux densités. Ligne du haut : chemin géodésique de L^2 . Ligne du bas : chemin géodésique de l'espace de Wasserstein. Distance $L^2 = 0.0645$, Distance de Wasserstein = 20.26.

La valeur de la distance L^2 est pratiquement la même pour les deux scénarios, puisque le support des deux densités est disjoint. L'utilisation du transport optimal permet en revanche de mieux mesurer l'écart entre les supports des deux densités, puisque le rapport entre les distances de Wasserstein estimées sur les deux scénarios est de l'ordre de 2.

Le transport optimal pouvant être estimé pour des espaces munies de variétés Riemaniennes [17], il est également envisageable de travailler dans des domaines à géométries complexes, ce qui serait impossible avec des méthodes telles que le flot optique. Comme l'illustre la Figure 6, ceci permet de mieux tenir compte de la réalité physique et du réel écart entre deux images. Nos travaux portent désormais sur la dérivation (numérique ou analytique) de la distance de Wasserstein, afin d'explicitier l'opérateur adjoint lié à cette métrique dans le cadre de l'assimilation de données.

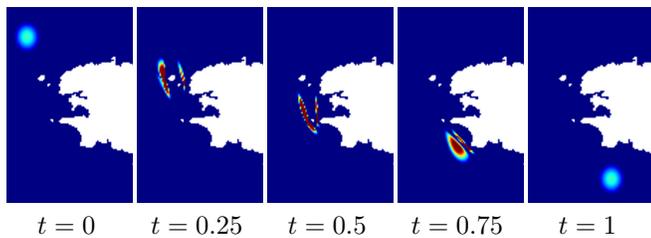


FIGURE 6 – Chemin géodésique associé à la distance de Wasserstein dans un domaine complexe (en blanc).

3 Perspectives

Les différentes approches présentées dans ce papier soulignent l'intérêt de l'assimilation des structures contenues dans les images. Les expériences réalisées se sont néanmoins focalisées sur des expériences jumelles synthétiques. La prochaine étape de nos travaux concernera donc l'application des méthodes développées à des modèles numériques plus avancés couplée avec l'utilisation de données réelles.

Remerciements Le premier auteur est soutenu par le pôle MSTIC de l'Université Joseph Fourier, le programme LEFE/MANU du CNRS et le programme SWOT/Océan du CNES.

Références

- [1] L. Ambrosio, N. Gigli et G. Savaré, *Gradient Flows : In Metric Spaces and in the Space of Probability Measures*. Lectures in Mathematics. ETH Zürich, 2005.
- [2] S. Ba et R. Fablet. *Variational data assimilation for missing data interpolation in SST images*. IEEE Int. Conf. on Image Processing (ICIP'10), 2010.
- [3] S. Ba, T. Corpetti, B. Chapron et R. Fablet. *Variational front tracking in Sea Surface Temperature images*. IEEE Int. Conf. on Image Processing (ICIP'10), 2010.
- [4] S.O. Ba, R. Fablet, E. Autret, B. Chapron. *Statistical descriptors of ocean regimes from the geometric regularity of Sea Surface Temperature observations*. IEEE Geoscience and Remote Sensing Letters, 9(5) : 851-854, 2012.
- [5] H. Bay, A. Ess and, T. Tuytelaars et L. J. Van Gool *Speeded-Up Robust Features (SURF)*. Computer Vision and Image Understanding, 110(3) : 346-359, 2008.
- [6] J.-D. Benamou et Y. Brenier. *A computational fluid mechanics solution of the Monge-Kantorovich mass transfer problem*. Numerische Mathematik, 84 :375-393, 2000.
- [7] D. Béréziat et I. Herlin. *Solving ill-posed Image Processing problems using Data Assimilation*. Numerical Algorithms 56(2) : 219-252, 2011.
- [8] S. Beyou, A. Cuzol, S. Gorthi et É. Mémin *Weighted ensemble transform Kalman filter for image assimilation*. Tellus A: Dynamic Meteorology and Oceanography, 2013.
- [9] A. Bouharguane, E. Maitre, É. Oudet et N. Papadakis. *Multiphysics optimal transportation and image analysis*. Submitted to ESAIM : M2AN, 2012.
- [10] V. Chabot, N. Papadakis, M. Nodet et A. Vidard. *Impact of data noise on the assimilation of image structures*. Submitted to Tellus A, 2013.
- [11] V. Chabot, M. Nodet, A. Vidard. et N. Papadakis. *Assimilation directe de séquences d'images de traceur passif : application aux équations de Saint-Venant*. Colloque GRETSI, 2013.
- [12] T. Corpetti, P. Héas, É. Mémin et N. Papadakis. *Pressure image assimilation for atmospheric motion estimation*. Tellus Series A, 61(1) :160-178, 2009.
- [13] F-X. Le Dimet et O. Talagrand. *Variational algorithms for analysis and assimilation of meteorological observations : theoretical aspects*. Tellus, pages 97 – 110, 1986.
- [14] A. Makris et N. Papadakis *Data assimilation with state alignment using high-level image structures detection*. Int. Conf. on Computer Vision in Remote Sensing (CVRS'12), 2012.
- [15] Y. Michel *Displacing potential vorticity structures by the assimilation of pseudo-observations*. Monthly Weather Review, 139(2) : 549-565, 2011.
- [16] N. Papadakis. *Assimilation de données image : application au suivi de courbes et de champs de vecteurs*. PhD thesis, Université de Rennes I, 2007.
- [17] N. Papadakis, G. Peyré et É. Oudet *Optimal transport with proximal splitting*. ArXiv e-prints 1304.5784, 2013.
- [18] S. Ravela, K. Emanuel et D. McLaughlin. *Data assimilation by field alignment*. Physica D : Nonlinear Phenomena, 230(1-2) : 127 - 145, 2007.
- [19] C. Thomas, T. Corpetti et É. Mémin. *Data Assimilation for Convective Cells Tracking on Meteorological Image Sequences*. IEEE Trans. on Geosciences and Remote Sensing, 48(8) :3162-3177, 2010.
- [20] O. Titaud, A. Vidard, I. Souopgui et F.-X. Le Dimet. *Assimilation of image sequences in numerical models*. Tellus A, 62(1) :30-47, 2010.
- [21] C. Villani. *Optimal transport : old and new*. Grundlehren der mathematischen Wissenschaften, Springer, 2009.