

Fusion bayésienne d’images hyperspectrales astronomiques

Matthieu PETREMAND¹, Christophe COLLET¹, André JALOBÉANU²

¹Laboratoire des Sciences de l’Image, de l’Informatique et de la Télédétection
UMR CNRS 7005, Bd Sébastien Brant, BP 10413, 67412 Illkirch Cedex, France

²Centro de Geofísica
Colégio Luís António Verney, Rua Romão Ramalho, 59, 7000 Évora, Portugal
c.collet@unistra.fr, petremand@lsiit.u-strasbg.fr
jalobeanu@uevora.pt

Résumé – L’imagerie hyperspectrale en astronomie offre l’opportunité d’étudier des objets célestes résolus spatialement et spectralement. Dans le cas du futur spectrographe intégral de champ (IFS) MUSE (Multi Unit Spectroscopic Explorer), chaque nuit d’acquisition génèrera de nombreuses observations brutes hyperspectrales de grande taille (1.2 Go de données capteur par image brute), centrées sur la même zone du ciel, et dont l’analyse conjointe reste problématique à cause de conditions d’acquisition variables chaque nuit (atmosphère, décalages, etc.). Dans cet article, nous présentons une méthode visant à fusionner l’ensemble de ces observations hétérogènes en considérant la variabilité naturelle des paramètres d’acquisition. Nous proposons de réaliser cette fusion dans le cadre bayésien qui, en plus d’une approche statistique rigoureuse, permet l’estimation des incertitudes associées à chaque pixel fusionné. Ce nouvel algorithme est validé sur des cubes de données simulés de petite taille, démontrant, pour ce cas, la validité de l’approche. Le passage à l’échelle est en cours de développement.

Abstract – The hyperspectral astronomical imagery gives the ability to study spectrally and spatially resolved objects. In the case of the next integral-field spectrograph (IFS) MUSE (Multi Unit Spectroscopic Explorer), each survey will produce large hyperspectral raw observations (1.2 GB of sensor data each), centered on the same sky area. The joint analysis of observations at different times remains problematic because of varying acquisition conditions (atmosphere, shifts, etc.). In this paper, we present a method aiming at fusing a set of several raw observations with respect to varying acquisition parameters. We propose to use the Bayesian framework which ensures a rigorous approach while yielding uncertainties associated to each fused pixel. This new algorithm is validated on small-size simulated data cubes, and its extension to large scale data is under process.

1 Introduction

L’imagerie hyperspectrale astronomique permet l’étude d’objets distants avec des instruments dont les résolutions spatiale et spectrale sont en constante augmentation. Cet accroissement du nombre d’échantillons disponibles dans les cubes hyperspectraux générés s’accompagne logiquement d’une explosion du volume de données à traiter et à analyser. Dans le cas de l’IFS MUSE [1], une observation brute (capteur) hyperspectrale occupe environ 1.2 Go et sa version reconstruite (x, y, λ) , où (x, y) est une position spatiale et λ une longueur d’onde, est de taille $300 \times 300 \times 4000$ pixels. L’étude d’objets lointains nécessite des sessions d’acquisition de plusieurs dizaines d’heures (jusqu’à 80 pour MUSE) généralement découpées en poses courtes (d’une heure pour MUSE) étalées sur plusieurs nuits et évitant ainsi une trop grande accumulation de rayons cosmiques venant frapper aléatoirement les capteurs et polluer l’observation en cours. Finalement, de telles sessions produisent de nombreuses observations hyperspectrales brutes de la même portion du ciel, multipliant la quantité de données à manipuler et traiter (jusqu’à 96 Go par session MUSE). L’analyse conjointe de ces nombreuses acquisitions reste souvent

problématique car chacune d’entre elles est obtenue sous des conditions atmosphériques différentes conduisant à des variations spatiales et spectrales des résolutions et des grilles d’échantillonnage. Une version reconstruite et fusionnée de cet ensemble hétérogène est généralement préférée pour l’analyse scientifique et synthétise, sous la forme d’un seul cube (de taille $300 \times 300 \times 4000$ pixels), toute l’information induite par la diversité des conditions d’observation.

Les méthodes actuellement utilisées au sein de la communauté astronomique pour la reconstruction et la fusion de telles images se limitent généralement à combiner et moyenner les pixels des observations sans prendre en compte la variabilité des paramètres d’acquisition. C’est notamment le cas des méthodes basées sur des interpolations simples (linéaires ou cubiques) ainsi que celui de la méthode du Drizzle [2] qui tend à augmenter le flou présent dans les observations. Dans cet article, nous proposons une approche alternative qui consiste à décrire précisément le modèle de formation des observations (cf. section 2) puis à l’inverser dans un contexte bayésien [4] afin de produire une image fusionnée dont les résolutions spatiale et spectrale sont limitées par l’utilisation des fonctions B-spline [3] (cf. section 3). Contrairement aux méthodes directes,

cette approche inverse permet d'envisager un résultat plus cohérent grâce à la prise en compte des paramètres d'acquisition propres à chaque observation. En plus d'une estimation statistique de l'image fusionnée, l'approche bayésienne permet d'obtenir les incertitudes associées à chaque pixel fusionné sous la forme d'une matrice de covariance inverse (matrice de précision). Celle-ci peut être ultérieurement exploitée pour des traitements sur l'image fusionnée comme une déconvolution ou des calculs d'astrométrie et de photométrie. Cette nouvelle approche est primordiale si l'on veut tirer pleinement parti de la quantité et de l'hétérogénéité des données disponibles et doit être correctement conçue afin de pouvoir s'appliquer, dans un second temps, à des données hyperspectrales de grande taille. Son application à l'imagerie astronomique 2D a déjà été précédemment étudiée et validée [5] mais ne peut être directement transposée au cas hyperspectral à cause de la complexité et de la taille des observations manipulées. Nous validons donc la méthode sur des données simulées de petite taille ($32 \times 32 \times 32$ pixels), la comparons à une méthode d'interpolation cubique classique (cf. section 4) et présentons les conclusions et perspectives associées à ce travail dans la section 5. L'algorithme de fusion proposé est présenté dans le cadre de la fusion de données MUSE¹ mais peut s'appliquer à tous types d'observations hyperspectrales, avant tout pré-traitement, dès lors que l'accès à leurs paramètres d'acquisition est possible.

2 Modèle génératif des données

2.1 Modèle direct

Le modèle direct décrit formellement l'ensemble des perturbations qui dégradent la vérité-terrain observée $T(x, y, \lambda)$, de résolutions spectrale et spatiale infinies, et aboutissent à sa i -ème version limitée en fréquence, décalée, échantillonnée et bruitée (*i.e.* observée) Y^i . Durant l'acquisition, l'atmosphère et l'optique de l'instrument agissent comme des filtres passe-bas dont les fréquences de coupure varient selon $u = (x, y, \lambda)$. L'impact de ces deux systèmes sur T est modélisé par les noyaux de convolution 3D h_u^i appelés PSF (Point Spread Function). La version convoluée de T est ensuite échantillonnée sur la grille u_p^i mettant en correspondance une position u de l'espace modèle à chaque pixel p de l'espace capteur. Ce maillage tridimensionnel inclut tous les paramètres géométriques de l'observation (orientation et pointage du télescope, chemin optique dans l'instrument) ainsi que la diffraction atmosphérique qui introduit un décalage spatial de la grille dépendant de λ . Enfin, un bruit gaussien centré d'écart-type σ_p^i perturbe l'acquisition et conduit à l'équation d'observation finale (où \star est le produit de convolution) :

$$Y_p^i = \underbrace{(T \star h_{u_p^i}^i)}_{I_p^i} (u_p^i) + B_p^i \text{ avec } B_p^i \sim \mathcal{N}(0, \sigma_p^i) \quad (1)$$

¹Ce travail a été partiellement financé par l'Agence Nationale de la Recherche (ANR) dans le cadre du projet DAHLIA BLAN08-2_319811

Ce modèle génératif des observations montre clairement que, pour chaque observation brute Y^i , le bruit, la résolution ainsi que la grille d'échantillonnage varieront spatialement, spectralement et dans le temps entre chaque session d'acquisition.

2.2 Schéma de rééchantillonnage

Dans le modèle proposé, nous faisons l'hypothèse que tous les signaux observés (les Y^i) sont à bande limitée puisque le contenu haute-fréquence de T a été irrémédiablement perdu durant le processus d'acquisition. Il est donc peu judicieux de reconstruire T à partir des observations Y^i mais plutôt préférable, au sein de l'algorithme de fusion, d'en reconstruire une version limitée en fréquence F obtenue par filtrage : $F = T \star \varphi$ où φ est un noyau séparable 3D déterminant totalement la résolution de F . Nous avons retenu la fonction B-spline d'ordre 3 comme étant un bon compromis entre précision et complexité pour la modélisation de φ [3]. En effet, elle possède un support fini de petite taille impliquant un coût calculatoire faible lors d'interpolations et l'image F ainsi filtrée est une bonne approximation d'un signal à bande limitée. Grâce à la théorie de l'interpolation [3], F peut être approchée par une somme discrète de noyaux B-spline pondérés par les coefficients d'interpolation L_m :

$$F(u) \simeq \sum_m L_m \varphi(u - m), \quad m \in \mathbb{Z}^3 \quad (2)$$

La cible de l'algorithme de fusion sera finalement la version discrète de F définie par $X = s \star L$ (s étant la discrétisation de φ tel que $s(m) = \varphi(m)$) sachant que le signal continu peut être totalement reconstruit par interpolation à partir de ses échantillons discrets. X correspond alors à une observation idéale obtenue avec un télescope de résolution supérieure ou égale à celles présentes dans les observations et modélisé par sa PSF φ constante spatialement et spectralement.

Une seconde hypothèse consiste à considérer les PSF h_u^i comme étant limitées en fréquence, *i.e.* pouvant également s'écrire sous la forme d'une somme pondérée de noyaux B-spline. Sous cette hypothèse, I_p^i (Eq. 1) peut se reformuler :

$$I_p^i = \sum_m L_m \alpha_{pm}^i \quad \text{avec} \quad \alpha_{pm}^i = h_{u_p^i}^i(u_p^i - m) \quad (3)$$

où α_p^i est l'ensemble des coefficients de rendu associés au pixel p totalement déduits des paramètres d'observation h_u^i et u_p^i . α_p^i correspond donc aux contributions des points m de l'espace modèle au pixel p , s'interprète comme un opérateur de flou appliqué à L et contient, théoriquement, autant de coefficients que de points dans l'espace modèle. Pour une observation brute MUSE, ceci représenterait environ 750 Po de coefficients qui sont pour la plupart négligés dans la pratique car rapidement très faibles (1.2 Go après seuillage). Leur nombre dépend de la taille des PSF ainsi que de l'échantillonnage retenu pour l'espace modèle qui est, pour l'instant, déduit de la plus forte résolution disponible dans le jeu de données à fusionner. Par souci de clarté, la notation matricielle où un caractère gras représente une matrice est adoptée pour le reste de l'article.

3 Fusion de données hyperspectrales

3.1 Modèle inverse

La méthode de fusion proposée consiste à inférer une estimation \hat{L} des coefficients L à partir de l'ensemble $\{Y^i, \alpha^i\}$ puis à en déduire une image fusionnée estimée \hat{X} par la relation $\hat{X} = \hat{S}\hat{L}$ où S est l'opérateur symétrique B-spline. Nous proposons de résoudre ce problème inverse dans le cadre statistique bayésien [4] en maximisant la probabilité *a posteriori* suivante (avec hypothèse d'indépendance des observations) :

$$P(L|\{Y^i\}, \omega) \propto \prod_i P(Y^i|L) \times P(L|\omega) \quad (4)$$

où $P(Y^i|L)$ est un terme d'attache aux données (vraisemblance) et $P(L|\omega)$ un *a priori* pondéré par ω .

L'expression de la vraisemblance est déduite des équations 1 et 3 et s'écrit $Y^i|L \sim \mathcal{N}(\alpha^i L, P^i)$ où P^i est la matrice de précision diagonale définie par $P^i(p, p) = 1/\sigma_p^{i2}$.

Le choix de l'*a priori* $P(L|\omega)$ est d'importance car il permet de contrôler l'inévitable amplification du bruit pendant l'inversion bayésienne. Bien qu'il puisse être sélectionné parmi une grande variété de modèles complexes [6], le caractère quelconque (taille, forme...) des objets présents dans la scène nous a amené à utiliser, dans un premier temps, une régularisation quadratique simple (*a priori* de douceur) et de faible coût calculatoire au regard de la taille des données à traiter :

$$P(L|\omega) \propto \exp(-(\omega \|DSL\|^2)) \quad (5)$$

où D est l'opérateur de dérivée première. L'hyper-paramètre ω est fixé dans l'algorithme mais son estimation automatique, complexifiée par le gigantisme des données, est en cours d'investigation. Le maximum de l'équation 4 est déterminé en minimisant, par l'algorithme du gradient conjugué, la fonction d'énergie associée $U(L) = -\log P(L|\{Y^i\}, \omega)$ dont le gradient est donné par :

$$\nabla_L U = \underbrace{\sum_i \alpha^{iT} P^i \alpha^i}_\alpha L + 2\omega QL - \underbrace{\sum_i \alpha^{iT} P^i Y^i}_\Lambda \quad (6)$$

avec $Q = SD^T DS$. Le pré-calcul des matrices α^f et Λ^f permet d'alléger l'évaluation du gradient à chaque itération de l'algorithme d'optimisation et d'écrire le modèle direct simplifié suivant :

$$\Lambda^f = \alpha^f L + \mathcal{N}(0, \alpha^f) \quad (7)$$

car la minimisation de $U(L)$ revient à inférer \hat{L} à partir de l'équation 7 en utilisant l'*a priori* défini dans l'équation 5. Λ^f est ainsi affectée d'un flou caractérisé par la matrice α^f et déconvolué pendant l'inversion pour conduire à \hat{L} puis \hat{X} .

3.2 Estimation des incertitudes

Les incertitudes associées à chaque pixel fusionné \hat{X}_m peuvent être utilisées afin d'améliorer de futurs traitements sur \hat{X} . Par

exemple, l'amplification du bruit sur \hat{X} durant le processus d'inversion à cause de l'*a priori* simple utilisé pourrait être réduit dans une étape de débruitage s'appuyant sur les incertitudes disponibles. L'expression de la matrice de précision Σ_X^{-1} associée à \hat{X} est obtenue en approchant la distribution *a posteriori* $X|\{Y^i\}, \omega$ par une fonction gaussienne autour de son optimum. Dans ce cas, Σ_X^{-1} est définie par :

$$\Sigma_X^{-1} = \nabla_X^2 U(X) = S^{-1} \alpha^f S^{-1} + 2\omega D^T D \quad (8)$$

La matrice de covariance Σ_X est estimée par des inversions locales de Σ_X^{-1} (en considérant uniquement le voisinage proche de chaque pixel [5]) car l'inversion complète de cette matrice de grande taille, bien que creuse, reste inenvisageable.

4 Résultats préliminaires

Dans un premier temps, la méthode de fusion est validée sur 4 observations brutes de petite taille, générées à partir d'une vérité-terrain T paramétrique composée d'étoiles (objets ponctuels) et de galaxies (objets diffus). La taille de l'espace de reconstruction est $32 \times 32 \times 32$ pixels et les paramètres d'observations sont résumés dans le tableau 1. La figure 1 présente les résultats de fusion obtenus avec l'inversion bayésienne ainsi qu'une méthode d'interpolation B-spline. Ceux-ci sont comparés avec l'image idéale X (obtenue en convoluant T par φ) et une version ré-arrangée (sans reconstruction) de Y^1 en un cube (x, y, λ) .

Y	PSF spatiale (λ_0, λ_1)	PSF spectrale (λ_0, λ_1)	Décalages (x, y)
1	(1.5, 2.1)	(1.7, 1.8)	(0, 0)
2	(1.6, 2.24)	(1.5, 1.6)	(-0.3, -0.6)
3	(1.7, 2.38)	(1.8, 1.9)	(1.1, 0.3)
4	(1.5, 2.1)	(1.6, 1.7)	(0.3, 0.9)

TAB. 1: Paramètres d'acquisition pour chaque observation. Les largeurs à mi-hauteur (en pixel) des PSF sont données pour les deux extrémités du spectre λ_0 et λ_1 et augmentent linéairement en fonction de λ . Les décalages spatiaux sont en pixel.

Les objets reconstruits par interpolation cubique révèlent toujours la présence de flou en comparaison du résultat obtenu par la fusion bayésienne, particulièrement dans la bande 26 où les résolutions spectrale et spatiale sont les plus faibles (cf. images 3D et spectres intégrés de la figure 1). En effet, contrairement aux méthodes directes qui combinent les pixels des observations, la méthode proposée intègre tous les paramètres d'acquisition dans un modèle génératif dont l'inversion équivaut à déconvoluer Λ^f dans un espace de résolution constante. Toutefois, avec la régularisation simple mise en œuvre ici, les plus hautes fréquences spatiales et spectrales des objets ponctuels ne peuvent être totalement reconstruites par la fusion bayésienne et l'amplification du bruit reste imparfaitement contrôlée pendant la déconvolution, notamment sur les objets diffus à plus faible signal sur bruit. Le flou spectral a bien été compensé dans la fusion bayésienne mais reste présent dans le cube interpolé, comme le montre les spectres intégrés de la figure 1.

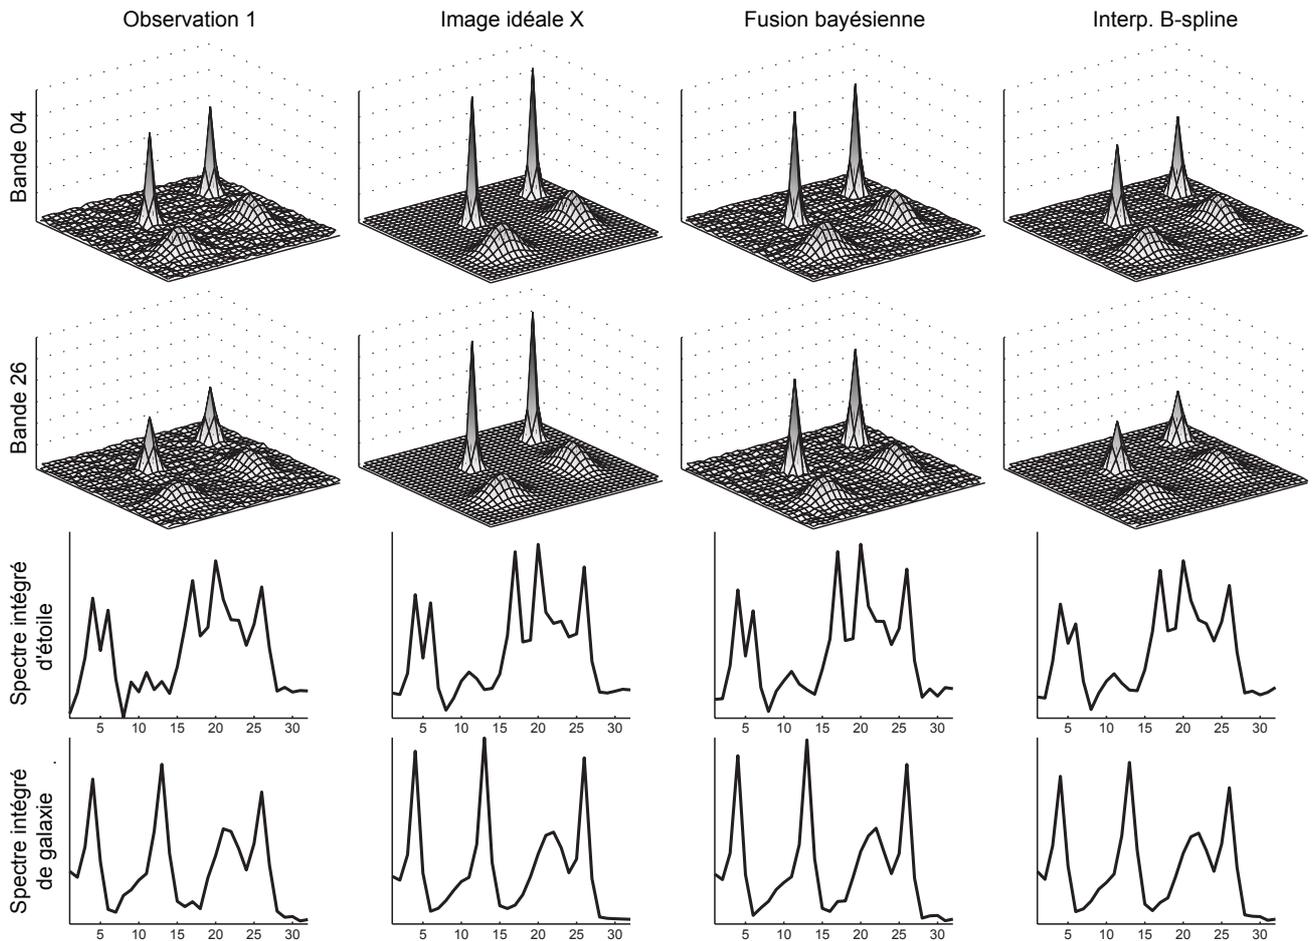


FIG. 1: Résultats de fusion pour : Y^1 ré-arrangée en un cube (x, y, λ) , l'image idéale X , la fusion bayésienne et l'interpolation B-spline. Les bandes 4 et 26, à forte et faible résolution respectivement, sont présentées ainsi que les spectres intégrés spatialement sur les deux types d'objets présents dans la simulation. Dans la figure, les axes d'intensité sont identiques pour les imagettes d'une même ligne.

La fusion complète des 4 observations (excepté le calcul des covariances) sur un ordinateur de bureau (Intel Core 2, Quad Processor 2.50 GHz, 4 GB of RAM) a pris environ 10 min.

5 Conclusion et perspectives

Dans cet article, nous avons présenté et validé une nouvelle méthode de fusion de données brutes hyperspectrales basée sur l'inversion, dans un cadre bayésien, du modèle direct de formation des observations. Ce dernier englobe tous les paramètres d'acquisition associés à chaque image Y^i garantissant ainsi une optimalité supérieure à celle accessible par les méthodes classiques d'interpolation actuellement utilisées en astronomie pour la reconstruction de cubes hyperspectraux. Les incertitudes associées à chaque pixel fusionné sont disponibles et leur utilisation pour des traitements ultérieurs (débruitage, visualisation, photométrie...) justifiée. En plus du choix d'un modèle *a priori* plus robuste, la détection et la suppression des rayons cosmiques pendant l'inversion du modèle sont actuellement étudiés afin d'éviter la fusion de pixels aberrants. Enfin,

dans le cas de MUSE, des hypothèses simplificatrices (*e.g.* PSF constantes dans le champ et séparables) ont permis de simplifier le calcul et le stockage des matrices α^i et α^f et de débiter l'implémentation du passage à l'échelle de l'algorithme.

Références

- [1] F. Laurent, F. Henault, E. Renault, R. Bacon, et J.P. Dubois, *Design of an integral field unit for MUSE, and results from prototyping*, Publications of the Astronomical Society of the Pacific, vol. 118, pp. 1564-1573, 2006.
- [2] A. S. Fruchter et R. N. Hook, *Drizzle : a method for the linear reconstruction of undersampled images*, Publications of the Astronomical Society of the Pacific, vol. 114, pp. 144-152, 2001.
- [3] P. Thévenaz, T. Blu, et M. Unser, *Interpolation revisited*, IEEE Trans. on Med. Imaging, vol. 19, pp. 739-758, 2000.
- [4] A. Gelman, J. B. Carlin, H. S. Stern, et D. B. Rubin, *Bayesian Data Analysis, Second Edition*, Chapman & Hall, 2003.
- [5] A. Jalobeanu, J. A. Gutiérrez, et E. Slezak, *Multisource data fusion and super-resolution from astronomical images*, Statistical Methodology, vol. 5, pp. 361-372, Jul 2008.
- [6] J.-L. Starck, F. Murtagh and J. M. Fadili, *Sparse image and signal processing : wavelets, curvelets, morphological diversity*, Cambridge University Press, 2010.