

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Une approche inverse pour la reconstruction de données multidimensionnelles hétérogènes

Ferréol Soulez^{1,2}

¹Laboratoire Hubert Curien
Université Jean Monnet
St Etienne

²Centre de Recherche Astrophysique de Lyon
Université Claude Bernard Lyon I
Ecole Normale Supérieure de Lyon

11 décembre 2008

Introduction

Problèmes inverses

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Introduction

Qu'est ce qu'un problème inverse ?

Introduction

Problèmes inverses

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Soit un modèle m reliant, aux erreurs e près, les paramètres x et les données y :

$$y = m(x) + e$$

Problème inverse

Quel sont les meilleurs paramètres x compte tenu des données y et du modèle m ?

Il peut y avoir beaucoup de paramètres (e.g. $\gtrsim 10^6$) et même plus de paramètres que de mesures : $N_x \gtrsim N_y$.

Un problème inverse est en général **mal-conditionné** (solution instable) ou même **mal-posé** (plusieurs ou aucune solutions).

Qu'est ce qu'un problème inverse ?

Introduction

Problèmes inverses

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Déconvolution
Aveugle

Conclusion

Soit un modèle m reliant, aux erreurs e près, les paramètres x et les données y :

$$y = m(x) + e$$

Problème inverse

Quel sont les meilleurs paramètres x compte tenu des données y et du modèle m ?

Il peut y avoir beaucoup de paramètres (e.g. $\gtrsim 10^6$) et même plus de paramètres que de mesures : $N_x \gtrsim N_y$.

Un problème inverse est en général mal-conditionné (solution instable) ou même mal-posé (plusieurs ou aucune solutions).

Qu'est ce qu'un problème inverse ?

Introduction

Problèmes inverses

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Soit un modèle m reliant, aux erreurs e près, les paramètres x et les données y :

$$y = m(x) + e$$

Problème inverse

Quel sont les meilleurs paramètres x compte tenu des données y et du modèle m ?

Il peut y avoir beaucoup de paramètres (e.g. $\gtrsim 10^6$) et même plus de paramètres que de mesures : $N_x \gtrsim N_y$.

Un problème inverse est en général **mal-conditionné** (solution instable) ou même **mal-posé** (plusieurs ou aucune solutions).

Qu'est ce qu'un problème inverse ?

Introduction

Problèmes inverses

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Soit un modèle m reliant, aux erreurs e près, les paramètres x et les données y :

$$y = m(x) + e$$

Problème inverse

Quel sont les meilleurs paramètres x compte tenu des données y et du modèle m ?

Il peut y avoir beaucoup de paramètres (e.g. $\gtrsim 10^6$) et même plus de paramètres que de mesures : $N_x \gtrsim N_y$.

Un problème inverse est en général **mal-conditionné** (solution instable) ou même **mal-posé** (plusieurs ou aucune solutions).

Qu'est ce qu'un problème inverse ?

Introduction

Problèmes inverses

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Déconvolution
Aveugle

Conclusion

Soit un modèle m reliant, aux erreurs e près, les paramètres x et les données y :

$$y = m(x) + e$$

Problème inverse

Quel sont les meilleurs paramètres x compte tenu des données y et du modèle m ?

Il peut y avoir beaucoup de paramètres (e.g. $\gtrsim 10^6$) et même plus de paramètres que de mesures : $N_x \gtrsim N_y$.

Un problème inverse est en général **mal-conditionné** (solution instable) ou même **mal-posé** (plusieurs ou aucune solutions).

Qu'est ce qu'un problème inverse ?

Introduction

Problèmes inverses

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Déconvolution
Aveugle

Conclusion

Soit un modèle m reliant, aux erreurs e près, les paramètres x et les données y :

$$y = m(x) + e$$

Problème inverse

Quel sont les meilleurs paramètres x compte tenu des données y et du modèle m ?

Il peut y avoir beaucoup de paramètres (e.g. $\gtrsim 10^6$) et même plus de paramètres que de mesures : $N_x \gtrsim N_y$.

Un problème inverse est en général **mal-conditionné** (solution instable) ou même **mal-posé** (plusieurs ou aucune solutions).

Qu'est ce qu'un problème inverse ?

Introduction

Problèmes inverses

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Déconvolution
Aveugle

Conclusion

Soit un modèle m reliant, aux erreurs e près, les paramètres x et les données y :

$$y = m(x) + e$$

Problème inverse

Quel sont les meilleurs paramètres x compte tenu des données y et du modèle m ?

Il peut y avoir beaucoup de paramètres (e.g. $\gtrsim 10^6$) et même plus de paramètres que de mesures : $N_x \gtrsim N_y$.

Un problème inverse est en général **mal-conditionné** (solution instable) ou même **mal-posé** (plusieurs ou aucune solutions).

Qu'est ce qu'un problème inverse ?

Introduction

Problèmes inverses

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Soit un modèle m reliant, aux erreurs e près, les paramètres x et les données y :

$$y = m(x) + e$$

Problème inverse

Quel sont les meilleurs paramètres x compte tenu des données y et du modèle m ?

Il peut y avoir beaucoup de paramètres (e.g. $\gtrsim 10^6$) et même plus de paramètres que de mesures : $N_x \gtrsim N_y$.

Un problème inverse est en général **mal-conditionné** (solution instable) ou même **mal-posé** (plusieurs ou aucune solutions).

Introduction

Holographie numérique

Holographie
numérique : Maximum
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats
expérimentaux

Résumé

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Holographie numérique

La localisation de micro-particules holographie numérique

Introduction

Holographie numérique

Holographie numérique : Maximum de Vraisemblance

Restriction de l'espace des paramètres

Cas d'une d'une seule particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats expérimentaux

Résumé

Déconvolution

Déconvolution multidimensionnelle

Deconvolution Aveugle

Conclusion

- **But : localisation en 3D de micro-particules en mouvement.**
- L'holographie permet d'enregistrer de l'information 3D en une seule acquisition.
- Le montage de l'holographie en ligne :

Dans le cas dilué, le modèle de formation est approximativement linéaire :

$$y = \sum_z 2 \mathbf{R}_z \cdot x_z + e.$$

La localisation de micro-particules holographie numérique

Introduction

Holographie numérique

Holographie numérique : Maximum de Vraisemblance

Restriction de l'espace des paramètres

Cas d'une d'une seule particule

Détection
Intérêt de W

Particules multiples
Algorithme

Simulations

Résultats expérimentaux

Résumé

Déconvolution

Déconvolution multidimensionnelle

Deconvolution Aveugle

Conclusion

- But : localisation en 3D de micro-particules en mouvement.
- L'holographie permet d'enregistrer de l'information 3D en une seule acquisition.
- Le montage de l'holographie en ligne :

Dans le cas dilué, le modèle de formation est approximativement linéaire :

$$y = \sum_z 2 \mathbf{R}_z \cdot \mathbf{x}_z + e.$$

La localisation de micro-particules holographie numérique

Introduction

Holographie numérique

Holographie numérique : Maximum de Vraisemblance

Restriction de l'espace des paramètres

Cas d'une d'une seule particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats expérimentaux

Résumé


Déconvolution

Déconvolution multidimensionnelle

Deconvolution Aveugle

Conclusion

- But : localisation en 3D de micro-particules en mouvement.
- L'holographie permet d'enregistrer de l'information 3D en une seule acquisition.
- Le montage de l'holographie en ligne :



Dans le cas dilué, le modèle de formation est approximativement linéaire :

$$y = \sum_z 2 \mathbf{R}_z \cdot x_z + e.$$

La localisation de micro-particules holographie numérique

Introduction

Holographie numérique

Holographie numérique : Maximum de Vraisemblance

Restriction de l'espace des paramètres

Cas d'une d'une seule particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats expérimentaux

Résumé



Déconvolution

Déconvolution multidimensionnelle

Deconvolution Aveugle

Conclusion

- But : localisation en 3D de micro-particules en mouvement.
- L'holographie permet d'enregistrer de l'information 3D en une seule acquisition.
- Le montage de l'holographie en ligne :



Dans le cas dilué, le modèle de formation est approximativement linéaire :

$$y = \sum_z 2 \mathbf{R}_z \cdot x_z + e.$$

La localisation de micro-particules holographie numérique

Introduction

Holographie numérique

Holographie numérique : Maximum de Vraisemblance

Restriction de l'espace des paramètres

Cas d'une d'une seule particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats expérimentaux

Résumé



Déconvolution

Déconvolution multidimensionnelle

Deconvolution Aveugle

Conclusion

- But : localisation en 3D de micro-particules en mouvement.
- L'holographie permet d'enregistrer de l'information 3D en une seule acquisition.
- Le montage de l'holographie en ligne :



Dans le cas dilué, le modèle de formation est approximativement linéaire :

$$y = \sum_z 2 \mathbf{R}_z \cdot x_z + e.$$

La localisation de micro-particules holographie numérique

Introduction

Holographie numérique

Holographie numérique : Maximum de Vraisemblance

Restriction de l'espace des paramètres

Cas d'une d'une seule particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats expérimentaux

Résumé



Déconvolution

Déconvolution multidimensionnelle

Deconvolution Aveugle

Conclusion

- But : localisation en 3D de micro-particules en mouvement.
- L'holographie permet d'enregistrer de l'information 3D en une seule acquisition.
- Le montage de l'holographie en ligne :



Dans le cas dilué, le modèle de formation est approximativement linéaire :

$$\mathbf{y} = \sum_z 2 \mathbf{R}_z \cdot \mathbf{x}_z + \mathbf{e}.$$

Codage de l'information 3D

Introduction

Holographie numérique

Holographie numérique : Maximum de Vraisemblance

Restriction de l'espace des paramètres

Cas d'une d'une seule particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats expérimentaux

Résumé


Déconvolution

Déconvolution multidimensionnelle


Déconvolution Aveugle

Conclusion

depth = 50.0 μm / radius = 5.0 μm



depth = 300.0 μm / radius = 1.0 μm



Centre de la figure de diffraction \rightarrow position latérale

Modulation d'amplitude et fréquence \rightarrow rayon & profondeur

Codage de l'information 3D

Introduction

Holographie numérique

Holographie numérique : Maximum de Vraisemblance

Restriction de l'espace des paramètres

Cas d'une d'une seule particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats expérimentaux

Résumé


Déconvolution

Déconvolution multidimensionnelle


Déconvolution Aveugle

Conclusion

depth = 50.0 μm / radius = 5.0 μm



depth = 300.0 μm / radius = 1.0 μm



Centre de la figure de diffraction \rightarrow position latérale

Modulation d'amplitude et fréquence \rightarrow rayon & profondeur

Solution au sens du maximum de vraisemblance

Introduction

Holographie
numérique

Holographie
numérique : Maximum
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats
expérimentaux

Résumé

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Solution au problème inverse : le maximum de vraisemblance.

$$\begin{aligned}\mathbf{x}^{\text{ML}} &= \arg \max_{\mathbf{x}} \Pr(\mathbf{y}|\mathbf{x}), \\ &= \arg \min_{\mathbf{x}} -\log(\Pr(\mathbf{y}|\mathbf{x})),\end{aligned}$$

Dans le cas d'une approximation gaussienne centrée des erreurs :

$$\mathbf{x}^{\text{ML}} = \arg \min_{\mathbf{x}} \left\{ [\mathbf{m}(\mathbf{x}) - \mathbf{y}]^T \cdot \mathbf{C}_e^{-1} \cdot [\mathbf{m}(\mathbf{x}) - \mathbf{y}] \right\}$$

\mathbf{C}_e^{-1} : covariance des erreurs.

Solution au sens du maximum de vraisemblance

Introduction

Holographie
numérique

Holographie
numérique : Maximum
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats
expérimentaux

Résumé

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Solution au problème inverse : le maximum de vraisemblance.

$$\begin{aligned}\mathbf{x}^{\text{ML}} &= \arg \max_{\mathbf{x}} \Pr(\mathbf{y}|\mathbf{x}), \\ &= \arg \min_{\mathbf{x}} -\log(\Pr(\mathbf{y}|\mathbf{x})),\end{aligned}$$

Dans le cas d'une approximation gaussienne centrée des erreurs :

$$\mathbf{x}^{\text{ML}} = \arg \min_{\mathbf{x}} \left\{ [\mathbf{m}(\mathbf{x}) - \mathbf{y}]^T \cdot \mathbf{C}_e^{-1} \cdot [\mathbf{m}(\mathbf{x}) - \mathbf{y}] \right\}$$

\mathbf{C}_e^{-1} : covariance des erreurs.

Maximum de vraisemblance : Holographie numérique

Introduction

Holographie numérique

Holographie numérique : Maximum de Vraisemblance

Restriction de l'espace des paramètres

Cas d'une d'une seule particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats expérimentaux

Résumé

Déconvolution

Déconvolution multidimensionnelle

Deconvolution Aveugle

Conclusion

la solution au sens du maximum de vraisemblance

\mathbf{x}^{MV} solution de :

$$4 (\mathbf{I} + \mathbf{R}_{2z}) \cdot \mathbf{x}^{\text{MV}} = \mathbf{R}_z \cdot \mathbf{y} .$$

- $(\mathbf{I} + \mathbf{R}_{2z})$ n'est pas inversible.
- Classiquement l'opérateur de restitution est approché par \mathbf{H}_z ,
 - ▶ Apparition d'images jumelles.

Comment contourner ce problème ?

- ▶ Restriction de l'espace des paramètres,
- ▶ Nouvel espace défini à partir d'informations *a priori*.

Maximum de vraisemblance : Holographie numérique

Introduction

Holographie numérique

Holographie numérique : Maximum de Vraisemblance

Restriction de l'espace des paramètres

Cas d'une d'une seule particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats expérimentaux

Résumé

Déconvolution

Déconvolution multidimensionnelle

Déconvolution Aveugle

Conclusion

la solution au sens du maximum de vraisemblance

\mathbf{x}^{MV} solution de :

$$4 (\mathbf{I} + \mathbf{R}_{2z}) \cdot \mathbf{x}^{\text{MV}} = \mathbf{R}_z \cdot \mathbf{y} .$$

- $(\mathbf{I} + \mathbf{R}_{2z})$ n'est pas inversible.
- Classiquement l'opérateur de restitution est approché par \mathbf{H}_z ,
 - ▶ Apparition d'images jumelles.

Comment contourner ce problème ?

- ▶ Restriction de l'espace des paramètres,
- ▶ Nouvel espace défini à partir d'informations *a priori*.

Maximum de vraisemblance : Holographie numérique

Introduction

Holographie numérique

Holographie numérique : Maximum de Vraisemblance

Restriction de l'espace des paramètres

Cas d'une d'une seule particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats expérimentaux

Résumé

Déconvolution

Déconvolution multidimensionnelle

Deconvolution Aveugle

Conclusion

la solution au sens du maximum de vraisemblance

\mathbf{x}^{MV} solution de :

$$4 (\mathbf{I} + \mathbf{R}_{2z}) \cdot \mathbf{x}^{\text{MV}} = \mathbf{R}_z \cdot \mathbf{y} .$$

- $(\mathbf{I} + \mathbf{R}_{2z})$ n'est pas inversible.
- Classiquement l'opérateur de restitution est approché par \mathbf{H}_z ,
 - ▶ Apparition d'images jumelles.

Comment contourner ce problème ?

- ▶ Restriction de l'espace des paramètres,
- ▶ Nouvel espace défini à partir d'informations *a priori*.

Maximum de vraisemblance : Holographie numérique

Introduction

Holographie numérique

Holographie numérique : Maximum de Vraisemblance

Restriction de l'espace des paramètres

Cas d'une d'une seule particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats expérimentaux

Résumé

Déconvolution

Déconvolution multidimensionnelle

Deconvolution Aveugle

Conclusion

la solution au sens du maximum de vraisemblance

\mathbf{x}^{MV} solution de :

$$4 (\mathbf{I} + \mathbf{R}_{2z}) \cdot \mathbf{x}^{\text{MV}} = \mathbf{R}_z \cdot \mathbf{y} .$$

- $(\mathbf{I} + \mathbf{R}_{2z})$ n'est pas inversible.
- Classiquement l'opérateur de restitution est approché par \mathbf{H}_z ,
 - ▶ Apparition d'images jumelles.

Comment contourner ce problème ?

- ▶ Restriction de l'espace des paramètres,
- ▶ Nouvel espace défini à partir d'informations *a priori*.

Maximum de vraisemblance : Holographie numérique

Introduction

Holographie numérique

Holographie numérique : Maximum de Vraisemblance

Restriction de l'espace des paramètres

Cas d'une d'une seule particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats expérimentaux

Résumé

Déconvolution

Déconvolution multidimensionnelle

Deconvolution Aveugle

Conclusion

la solution au sens du maximum de vraisemblance

\mathbf{x}^{MV} solution de :

$$4 (\mathbf{I} + \mathbf{R}_{2z}) \cdot \mathbf{x}^{\text{MV}} = \mathbf{R}_z \cdot \mathbf{y} .$$

- $(\mathbf{I} + \mathbf{R}_{2z})$ n'est pas inversible.
- Classiquement l'opérateur de restitution est approché par \mathbf{H}_z ,
 - ▶ Apparition d'images jumelles.

Comment contourner ce problème ?

- ▶ Restriction de l'espace des paramètres,
- ▶ Nouvel espace défini à partir d'informations *a priori*.

Maximum de vraisemblance : Holographie numérique

Introduction

Holographie numérique

Holographie numérique : Maximum de Vraisemblance

Restriction de l'espace des paramètres

Cas d'une d'une seule particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats expérimentaux

Résumé

Déconvolution

Déconvolution multidimensionnelle

Deconvolution Aveugle

Conclusion

la solution au sens du maximum de vraisemblance

\mathbf{x}^{MV} solution de :

$$4 (\mathbf{I} + \mathbf{R}_{2z}) \cdot \mathbf{x}^{\text{MV}} = \mathbf{R}_z \cdot \mathbf{y} .$$

- $(\mathbf{I} + \mathbf{R}_{2z})$ n'est pas inversible.
- Classiquement l'opérateur de restitution est approché par \mathbf{H}_z ,
 - ▶ Apparition d'images jumelles.

Comment contourner ce problème ?

- ▶ Restriction de l'espace des paramètres,
- ▶ Nouvel espace défini à partir d'informations *a priori*.

Maximum de vraisemblance : Holographie numérique

Introduction

Holographie numérique

Holographie numérique : Maximum de Vraisemblance

Restriction de l'espace des paramètres

Cas d'une d'une seule particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats expérimentaux

Résumé

Déconvolution

Déconvolution multidimensionnelle

Deconvolution Aveugle

Conclusion

la solution au sens du maximum de vraisemblance

\mathbf{x}^{MV} solution de :

$$4 (\mathbf{I} + \mathbf{R}_{2z}) \cdot \mathbf{x}^{\text{MV}} = \mathbf{R}_z \cdot \mathbf{y} .$$

- $(\mathbf{I} + \mathbf{R}_{2z})$ n'est pas inversible.
- Classiquement l'opérateur de restitution est approché par \mathbf{H}_z ,
 - ▶ Apparition d'images jumelles.

Comment contourner ce problème ?

- ▶ Restriction de l'espace des paramètres,
- ▶ Nouvel espace défini à partir d'informations *a priori*.

Holographie numérique : restriction de l'espace des paramètres

Introduction

Holographie numérique

Holographie numérique : Maximum de Vraisemblance

Restriction de l'espace des paramètres

Cas d'une d'une seule particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats expérimentaux

Résumé

Déconvolution

Déconvolution multidimensionnelle

Deconvolution Aveugle

Conclusion

Hypothèses :

- 1 Particules observées sont *a priori* sphériques ;
- 2 Modèle analytique de la figure de diffraction d'une particule P_i , dépendant de peu de paramètres (coordonnées (x_i, y_i, z_i) et rayon (r_i)) :

$$m_i(x', y') = \frac{r_i}{\rho_i(x', y')} J_1\left(\frac{2\pi r_i \rho_i(x', y')}{\lambda z_i}\right) \sin\left(\frac{\pi \rho_i^2(x', y')}{\lambda z_i}\right)$$

$$\text{où } \rho_i(x', y') = \sqrt{(x' - x_i)^2 + (y' - y_i)^2}$$

- 3 L'hologramme : combinaison linéaire de ces figures de diffraction.

$$\mathbf{y} = \sum_i^{\text{particules}} \mathbf{m}_i + \mathbf{e}.$$

Holographie numérique : restriction de l'espace des paramètres

Introduction

Holographie numérique

Holographie numérique : Maximum de Vraisemblance

Restriction de l'espace des paramètres

Cas d'une d'une seule particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats expérimentaux

Résumé

Déconvolution

Déconvolution multidimensionnelle

Deconvolution Aveugle

Conclusion

Hypothèses :

- 1 Particules observées sont *a priori* sphériques ;
- 2 Modèle analytique de la figure de diffraction d'une particule P_i , dépendant de peu de paramètres (coordonnées (x_i, y_i, z_i) et rayon (r_i)) :

$$m_i(x', y') = \frac{r_i}{\rho_i(x', y')} J_1\left(\frac{2\pi r_i \rho_i(x', y')}{\lambda z_i}\right) \sin\left(\frac{\pi \rho_i^2(x', y')}{\lambda z_i}\right)$$

$$\text{où } \rho_i(x', y') = \sqrt{(x' - x_i)^2 + (y' - y_i)^2}$$

- 3 L'hologramme : combinaison linéaire de ces figures de diffraction.

$$\mathbf{y} = \sum_i^{\text{particules}} \mathbf{m}_i + \mathbf{e}.$$

Holographie numérique : restriction de l'espace des paramètres

Introduction

Holographie numérique

Holographie numérique : Maximum de Vraisemblance

Restriction de l'espace des paramètres

Cas d'une d'une seule particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats expérimentaux

Résumé

Déconvolution

Déconvolution multidimensionnelle

Déconvolution Aveugle

Conclusion

Hypothèses :

- 1 Particules observées sont *a priori* sphériques ;
- 2 Modèle analytique de la figure de diffraction d'une particule P_i , dépendant de peu de paramètres (coordonnées (x_i, y_i, z_i) et rayon (r_i)) :

$$m_i(x', y') = \frac{r_i}{\rho_i(x', y')} J_1\left(\frac{2\pi r_i \rho_i(x', y')}{\lambda z_i}\right) \sin\left(\frac{\pi \rho_i^2(x', y')}{\lambda z_i}\right)$$

$$\text{où } \rho_i(x', y') = \sqrt{(x' - x_i)^2 + (y' - y_i)^2}$$

- 3 L'hologramme : combinaison linéaire de ces figures de diffraction.

$$y = \sum_i^{\text{particules}} m_i + e.$$

Holographie numérique : restriction de l'espace des paramètres

Introduction

Holographie numérique

Holographie numérique : Maximum de Vraisemblance

Restriction de l'espace des paramètres

Cas d'une d'une seule particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats expérimentaux

Résumé

Déconvolution

Déconvolution multidimensionnelle

Déconvolution Aveugle

Conclusion

Hypothèses :

- 1 Particules observées sont *a priori* sphériques ;
- 2 Modèle analytique de la figure de diffraction d'une particule P_i , dépendant de peu de paramètres (coordonnées (x_i, y_i, z_i) et rayon (r_i)) :

$$m_i(x', y') = \frac{r_i}{\rho_i(x', y')} J_1\left(\frac{2\pi r_i \rho_i(x', y')}{\lambda z_i}\right) \sin\left(\frac{\pi \rho_i^2(x', y')}{\lambda z_i}\right)$$

$$\text{où } \rho_i(x', y') = \sqrt{(x' - x_i)^2 + (y' - y_i)^2}$$

- 3 L'hologramme : combinaison linéaire de ces figures de diffraction.

$$\mathbf{y} = \sum_i^{\text{particules}} \mathbf{m}_i + \mathbf{e}.$$

Détection d'une seule particule

Introduction

Holographie
numérique

Holographie
numérique : Maximum
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats
expérimentaux

Résumé

Déconvolution

Déconvolution
multidimen-
sionnelle


Deconvolution
Aveugle

Conclusion

- Estimation des paramètres $\mathbf{p} = \{x, y, z, r\}$ minimisant le critère :

$$\mathcal{P}(\mathbf{p}) = \sum_{k=\text{pixels}} (m_k(\mathbf{p}) - y_k)^2$$

- A $\{r, z\}$ fixés, évaluation rapide par FFT de la carte du critère $\mathcal{P}(\mathbf{p})$.



données.

Détection d'une seule particule

Introduction

Holographie
numérique

Holographie
numérique : Maximum
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats
expérimentaux

Résumé

Déconvolution

Déconvolution
multidimen-
sionnelle


Deconvolution
Aveugle

Conclusion

- Estimation des paramètres $\mathbf{p} = \{x, y, z, r\}$ minimisant le critère :

$$\mathcal{P}(\mathbf{p}) = \sum_{k=\text{pixels}} (m_k(\mathbf{p}) - y_k)^2$$

- A $\{r, z\}$ fixés, évaluation rapide par FFT de la carte du critère $\mathcal{P}(\mathbf{p})$.



$\mathcal{P}(\mathbf{p})$ à $\{r, z\}$ fixés.

Particule hors champs

Introduction

Holographie
numérique

Holographie
numérique : Maximum
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats
expérimentaux

Résumé


Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

- particule en dehors du champ du capteur,
- Evaluation de \mathcal{P} dans le champ,
- Repliement.



données tronquées

Particule hors champs

Introduction

Holographie
numérique

Holographie
numérique : Maximum
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats
expérimentaux

Résumé


Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

- particule en dehors du champ du capteur,
- Evaluation de \mathcal{P} dans le champ,
- Repliement.



zoom

Particule hors champs

Introduction

Holographie
numérique

Holographie
numérique : Maximum
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats
expérimentaux

Résumé


Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

- particule en dehors du champ du capteur,
- Evaluation de \mathcal{P} dans le champ,
- Repliement.



\mathcal{P} (zoom)

Particule hors champs

Introduction

Holographie
numérique

Holographie
numérique : Maximum
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats
expérimentaux

Résumé


Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

- particule en dehors du champ du capteur,
- Evaluation de \mathcal{P} dans le champ,
- **Repliement.**



\mathcal{P} (zoom)

Particule hors champs

Introduction

Holographie
numérique

Holographie
numérique : Maximum
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats
expérimentaux

Résumé

Déconvolution


Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Padding

Remplacement des valeurs
manquantes avant le calcul du
critère.



données (padding)

Particule hors champs

Introduction

Holographie
numérique

Holographie
numérique : Maximum
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats
expérimentaux

Résumé

Déconvolution


Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Padding

Remplacement des valeurs
manquantes avant le calcul du
critère.



\mathcal{P} (padding)

Particule hors champs

Introduction

Holographie
numérique

Holographie
numérique : Maximum
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats
expérimentaux

Résumé

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Carte de poids


- $w \sim \text{diag}(C_e^{-1})$:

$$w_k = \begin{cases} \frac{1}{\sigma_k^2} & k^{\text{ième}} \text{ pixel mesuré,} \\ 0 & \text{sinon.} \end{cases}$$

- Le critère \mathcal{P} devient :

$$\mathcal{P} = \sum_k^{\text{pixels}} w_k (m_k - y_k)^2 .$$

- Cas général : données
manquantes.



données tronquées

Particule hors champs

Introduction

Holographie
numérique

Holographie
numérique : Maximum
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats
expérimentaux

Résumé

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Carte de poids


- $w \sim \text{diag}(C_e^{-1})$:

$$w_k = \begin{cases} \frac{1}{\sigma_k^2} & k^{\text{ième}} \text{ pixel mesuré,} \\ 0 & \text{sinon.} \end{cases}$$

- Le critère \mathcal{P} devient :

$$\mathcal{P} = \sum_k^{\text{pixels}} w_k (m_k - y_k)^2 .$$

- Cas général : données
manquantes.



\mathcal{P} avec matrice de poids W

Particule hors champs

Introduction

Holographie
numérique

Holographie
numérique : Maximum
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection

Intérêt de \mathbf{W}

Particules multiples

Algorithme

Simulations

Résultats
expérimentaux

Résumé

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Carte de poids


- $\mathbf{w} \sim \text{diag}(\mathbf{C}_e^{-1})$:

$$w_k = \begin{cases} \frac{1}{\sigma_k^2} & k^{\text{ième}} \text{ pixel mesuré,} \\ 0 & \text{sinon.} \end{cases}$$

- Le critère \mathcal{P} devient :

$$\mathcal{P} = \sum_k^{\text{pixels}} w_k (m_k - y_k)^2 .$$

- Cas général : données
manquantes.



données

Particule hors champs

Introduction

Holographie
numérique

Holographie
numérique : Maximum
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats
expérimentaux

Résumé

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Carte de poids


- $w \sim \text{diag}(C_e^{-1})$:

$$w_k = \begin{cases} \frac{1}{\sigma_k^2} & k^{\text{ième}} \text{ pixel mesuré,} \\ 0 & \text{sinon.} \end{cases}$$

- Le critère \mathcal{P} devient :

$$\mathcal{P} = \sum_k^{\text{pixels}} w_k (m_k - y_k)^2 .$$

- Cas général : données
manquantes.



carte de poids W

Cas particules multiples

Introduction

Holographie
numérique

Holographie
numérique : Maximisation
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection
Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats
expérimentaux

Résumé

Déconvolution


Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Cas des hologrammes de plusieurs particules :

- Calcul du critère \mathcal{P} en supposant une seule particule,
- Critère non-convexe,
- **Un problème d'optimisation globale.**



données réelles

Quels sont les N particules de paramètres $((x^n, y^n, z^n, r^n))$ qui modélisent le mieux les données ?

$$\mathcal{P}' = \sum_k^{\text{pixels}} w_k \left(\sum_n^{\text{particules}} m_k^n - y_k \right)^2$$

Cas particules multiples

Introduction

Holographie
numérique

Holographie
numérique : Maximisation
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection
Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats
expérimentaux

Résumé

Déconvolution


Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Cas des hologrammes de plusieurs
particules :

- Calcul du critère \mathcal{P} en supposant une seule particule,
- Critère non-convexe,
- Un problème d'optimisation globale.



carte de \mathcal{P}

Quels sont les N particules de paramètres $((x^n, y^n, z^n, r^n))$ qui modélisent le mieux les données ?

$$\mathcal{P}' = \sum_k^{\text{pixels}} w_k \left(\sum_n^{\text{particules}} m_k^n - y_k \right)^2$$

Cas particules multiples

Introduction

Holographie
numérique

Holographie
numérique : Maximisation
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection
Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats
expérimentaux

Résumé

Déconvolution


Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Cas des hologrammes de plusieurs
particules :

- Calcul du critère \mathcal{P} en supposant une seule particule,
- Critère non-convexe,
- Un problème d'optimisation globale.



carte de \mathcal{P}

Quels sont les N particules de paramètres $((x^n, y^n, z^n, r^n))$ qui modélisent le mieux les données ?

$$\mathcal{P}' = \sum_k^{pixels} w_k \left(\sum_n^{particules} m_k^n - y_k \right)^2$$

Cas particules multiples

Introduction

Holographie
numérique

Holographie
numérique : Maximisation
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection
Intérêt de W

Particules multiples
Algorithme

Simulations

Résultats
expérimentaux

Résumé

Déconvolution


Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Cas des hologrammes de plusieurs
particules :

- Calcul du critère \mathcal{P} en supposant une seule particule,
- Critère non-convexe,
- **Un problème d'optimisation globale.**



carte de \mathcal{P}

Quels sont les N particules de paramètres $((x^n, y^n, z^n, r^n)$ qui modélisent le mieux les données ?

$$\mathcal{P}' = \sum_k^{pixels} w_k \left(\sum_n^{particules} m_k^n - y_k \right)^2$$

Un algorithme itératif

Introduction

Holographie
numérique

Holographie
numérique : Maximum
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats
expérimentaux

Résumé

Déconvolution


Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Résolution du problème d'optimisation par un algorithme glouton à trois étapes :

- 1 Détection,
- 2 Ajustement précis,
- 3 Soustraction aux résidus de la figure de diffraction de la particule courante,



Convergence atteinte en cas de détection de particule aberrante.

Un algorithme itératif

Introduction

Holographie numérique

Holographie numérique : Maximum de Vraisemblance

Restriction de l'espace des paramètres

Cas d'une d'une seule particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats expérimentaux

Résumé

Déconvolution


Déconvolution multidimensionnelle

Deconvolution Aveugle

Conclusion

Résolution du problème d'optimisation par un algorithme glouton à trois étapes :

- 1 Détection,
- 2 Ajustement précis,
- 3 Soustraction aux résidus de la figure de diffraction de la particule courante,



Convergence atteinte en cas de détection de particule aberrante.

Un algorithme itératif

Introduction

Holographie numérique

Holographie numérique : Maximum de Vraisemblance

Restriction de l'espace des paramètres

Cas d'une d'une seule particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats expérimentaux

Résumé

Déconvolution


Déconvolution multidimensionnelle

Deconvolution Aveugle

Conclusion

Résolution du problème d'optimisation par un algorithme glouton à trois étapes :

- 1 Détection,
- 2 Ajustement précis,
- 3 Soustraction aux résidus de la figure de diffraction de la particule courante,



Convergence atteinte en cas de détection de particule aberrante.

Un algorithme itératif

Introduction

Holographie
numérique

Holographie
numérique : Maximum
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats
expérimentaux

Résumé

Déconvolution


Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Résolution du problème d'optimisation par un algorithme glouton à trois étapes :

- 1 Détection,
- 2 Ajustement précis,
- 3 Soustraction aux résidus de la figure de diffraction de la particule courante,



Convergence atteinte en cas de détection de particule aberrante.

Un algorithme itératif

Introduction

Holographie numérique

Holographie numérique : Maximum de Vraisemblance

Restriction de l'espace des paramètres

Cas d'une d'une seule particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats expérimentaux

Résumé

Déconvolution


Déconvolution multidimensionnelle

Deconvolution Aveugle

Conclusion

Résolution du problème d'optimisation par un algorithme glouton à trois étapes :

- 1 Détection,
- 2 Ajustement précis,
- 3 Soustraction aux résidus de la figure de diffraction de la particule courante,



Convergence atteinte en cas de détection de particule aberrante.

Résultats sur des simulations

Introduction

Holographie
numérique

Holographie
numérique : Maximum
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection

Intérêt de W

Particules multiples
Algorithme

Simulations

Résultats
expérimentaux

Résumé


Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle


Conclusion

Précisions sur les positions latérales.



$\Delta x = \Delta y \approx 0.3\mu\text{m}$ ($\approx 1/20^{\text{ième}}$ de
pixel).

Précisions sur la profondeur.



$\Delta z < 1\mu\text{m}$ ($< 1/6^{\text{ième}}$ de pixel).

Résultats expérimentaux

Introduction

Holographie
numérique

Holographie
numérique : Maximum
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection
Intérêt de W

Particules multiples
Algorithme

Simulations

Résultats
expérimentaux

Résumé

Déconvolution


Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Conditions expérimentales

- Impulsion **laser** de 7 ns à $\lambda = 0.532 \mu\text{m}$.
- **camera** CCD 12-bit avec 1280×1024 pixels de taille $6.7 \times 6.7 \mu\text{m}$.
- Gouttelettes générées par un **injecteur** piézo-électrique à 1000 Hz placé à environ 25 cm de la caméra.



Expérience conduite par C. Fournier et C. Goepfert au
Laboratoire de Mécanique des Fluides et Acoustique à Lyon.

Détection hors-champ (0)

Introduction

Holographie
numérique

Holographie
numérique : Maximum
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

**Résultats
expérimentaux**


Résumé

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion



Détection hors-champ (1)

Introduction

Holographie
numérique

Holographie
numérique : Maximum
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

**Résultats
expérimentaux**



Résumé

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion



Détection hors-champ (2)

Introduction

Holographie
numérique

Holographie
numérique : Maximum
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

**Résultats
expérimentaux**



Résumé

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion



Détection hors-champ (3)

Introduction

Holographie
numérique

Holographie
numérique : Maximum
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

**Résultats
expérimentaux**



Résumé

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion



Détection hors-champ (4)

Introduction

Holographie
numérique

Holographie
numérique : Maximum
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

**Résultats
expérimentaux**



Résumé

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion



Détection hors-champ (5)

Introduction

Holographie
numérique

Holographie
numérique : Maximum
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

**Résultats
expérimentaux**



Résumé

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion



Détection hors-champ (6)

Introduction

Holographie
numérique

Holographie
numérique : Maximum
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

**Résultats
expérimentaux**



Résumé

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion



Détection hors-champ(7)

Introduction

Holographie
numérique

Holographie
numérique : Maximum
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

**Résultats
expérimentaux**



Résumé

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion



Détection hors-champ(10)

Introduction

Holographie
numérique

Holographie
numérique : Maximum
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

**Résultats
expérimentaux**



Résumé

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion



Détection hors-champ(18)

Introduction

Holographie
numérique

Holographie
numérique : Maximum
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

**Résultats
expérimentaux**



Résumé

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion



Statistiques sur 200 hologrammes

Introduction

Holographie
numérique

Holographie
numérique : Maximum
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

**Résultats
expérimentaux**


Résumé

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion



Représentation 3D du jet de gouttelettes.

Résumé

Introduction

Holographie
numérique

Holographie
numérique : Maximum
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats
expérimentaux

Résumé

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Algorithme

- résolution itérative du problème d'optimisation global ;
- détection au sens du maximum de vraisemblance ;
- optimisation locale des paramètres (précision sous-pixel) ;

Bénéfices

- gain en précision d'un facteur 5 ;
- détection hors-champ :
 - ▶ surface utile 4×4 plus large que le détecteur ;
 - ▶ précision équivalente dans et hors-champ.

Résumé

Introduction

Holographie
numérique

Holographie
numérique : Maximum
de Vraisemblance

Restriction de
l'espace des
paramètres

Cas d'une d'une seule
particule

Détection

Intérêt de W

Particules multiples

Algorithme

Simulations

Résultats
expérimentaux

Résumé

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Algorithme

- résolution itérative du problème d'optimisation global ;
- détection au sens du maximum de vraisemblance ;
- optimisation locale des paramètres (précision sous-pixel) ;

Bénéfices

- gain en précision d'un facteur 5 ;
- détection hors-champ :
 - ▶ surface utile 4×4 plus large que le détecteur ;
 - ▶ précision équivalente dans et hors-champ.

Introduction

Holographie
numérique

Déconvolution

MV

Restriction de
l'espace des
paramètres

Approche Maximum a
posteriori

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Déconvolution

Le problème de la déconvolution

Introduction

Holographie
numérique

Déconvolution

MV

Restriction de
l'espace des
paramètres

Approche Maximum a
posteriori

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Une déformation linéaire :

$$\mathbf{y} = \mathbf{H} \cdot \mathbf{x} + \mathbf{e} .$$

Le problème de la déconvolution

Introduction

Holographie
numérique

Déconvolution

MV

Restriction de
l'espace des
paramètres

Approche Maximum a
posteriori

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Une déformation linéaire :

$$y = \mathbf{H} \cdot \mathbf{x} + e .$$



Objet

Le problème de la déconvolution

Introduction

Holographie
numérique

Déconvolution

MV

Restriction de
l'espace des
paramètres

Approche Maximum a
posteriori

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle


Conclusion

Une déformation linéaire :

$$y = \mathbf{H} \cdot x + e .$$



Objet



PSF

Le problème de la déconvolution

Introduction

Holographie
numérique

Déconvolution

MV

Restriction de
l'espace des
paramètres

Approche Maximum a
posteriori

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion


Une déformation linéaire :

$$y = \mathbf{H} \cdot x + e.$$



Objet

*



PSF

+ Bruit

Le problème de la déconvolution

Introduction

Holographie
numérique

Déconvolution

MV

Restriction de
l'espace des
paramètres

Approche Maximum a
posteriori

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Une déformation linéaire :

$$y = \mathbf{H} \cdot x + e .$$




Objet


*



PSF



+ Bruit



Données

Déconvolution : Maximum de vraisemblance

Introduction

Holographie
numérique

Déconvolution

MV

Restriction de
l'espace des
paramètres

Approche Maximum a
posteriori

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

La solution au sens du maximum de vraisemblance est
identique à l'inversion directe :

Déconvolution : Maximum de vraisemblance

Introduction

Holographie
numérique

Déconvolution

MV

Restriction de
l'espace des
paramètres

Approche Maximum a
posteriori

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

La solution au sens du maximum de vraisemblance est identique à l'inversion directe :

$$\mathbf{x}^{\text{ML}} = \text{FFT}^{-1} \left(\begin{array}{c} \text{FFT} \left(\begin{array}{c} \text{Image} \end{array} \right) \\ \hline \text{FFT} \left(\begin{array}{c} \text{Image} \end{array} \right) \end{array} \right)$$

Déconvolution : Maximum de vraisemblance

Introduction

Holographie
numérique

Déconvolution

MV

Restriction de
l'espace des
paramètres

Approche Maximum a
posteriori

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

La solution au sens du maximum de vraisemblance est identique à l'inversion directe :

$$\mathbf{x}^{\text{ML}} = \text{FFT}^{-1} \left(\begin{array}{c} \text{FFT} \left(\begin{array}{c} \text{Image of a person with a camera on a tripod} \end{array} \right) \\ \hline \text{FFT} \left(\begin{array}{c} \text{Black image} \end{array} \right) \end{array} \right) = \begin{array}{c} \text{Grayscale image} \end{array}$$

Déconvolution : Restriction de l'espace des paramètres

Introduction

Holographie
numérique

Déconvolution

MV

**Restriction de
l'espace des
paramètres**

Approche Maximum a
posteriori

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

En imposant des contraintes de
positivité

En coupant les fréquences trop
élevées (ici $u_c = 40$ frequels).

Déconvolution : Restriction de l'espace des paramètres

Introduction

Holographie
numérique

Déconvolution

MV

Restriction de
l'espace des
paramètres

Approche Maximum a
posteriori

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion



En imposant des contraintes de
positivité

En coupant les fréquences trop
élevées (ici $u_c = 40$ frequels).

Déconvolution : Restriction de l'espace des paramètres

Introduction

Holographie numérique

Déconvolution

MV

Restriction de l'espace des paramètres

Approche Maximum a posteriori

Déconvolution multidimensionnelle

Deconvolution Aveugle

Conclusion



En imposant des contraintes de positivité



En coupant les fréquences trop élevées (ici $u_c = 40$ frequels).

Approche bayesienne : Maximum a posteriori

Introduction

Holographie
numérique

Déconvolution

MV

Restriction de
l'espace des
paramètres

Approche Maximum a
posteriori

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Solution qui maximise la probabilité du modèle étant donné les mesures :

$$\mathbf{x}_{\text{MAP}} = \arg \max_{\mathbf{x}} \Pr(\mathbf{x} | \mathbf{y})$$

Approche bayesienne : Maximum a posteriori

Introduction

Holographie
numérique

Déconvolution

MV

Restriction de
l'espace des
paramètres

Approche Maximum a
posteriori

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Solution qui maximise la probabilité du modèle étant donné les mesures :

$$\mathbf{x}_{\text{MAP}} = \arg \max_{\mathbf{x}} \Pr(\mathbf{x} | \mathbf{y})$$
$$\Pr(\mathbf{x} | \mathbf{y}) = \frac{\Pr(\mathbf{y} | \mathbf{x}) \Pr(\mathbf{x})}{\Pr(\mathbf{y})} \quad (\text{théorème de Bayes})$$

Approche bayesienne : Maximum a posteriori

Introduction

Holographie
numérique

Déconvolution

MV

Restriction de
l'espace des
paramètres

Approche Maximum a
posteriori

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Solution qui maximise la probabilité du modèle étant donné les mesures :

$$\mathbf{x}_{\text{MAP}} = \arg \max_{\mathbf{x}} \Pr(\mathbf{x} | \mathbf{y})$$

$$\Pr(\mathbf{x} | \mathbf{y}) = \frac{\Pr(\mathbf{y} | \mathbf{x}) \Pr(\mathbf{x})}{\Pr(\mathbf{y})} \quad (\text{théorème de Bayes})$$

$$-\log \Pr(\mathbf{x} | \mathbf{y}) = -\log \Pr(\mathbf{y} | \mathbf{x}) - \log \Pr(\mathbf{x}) + \log \Pr(\mathbf{y})$$

Approche bayesienne : Maximum a posteriori

Introduction

Holographie
numérique

Déconvolution

MV

Restriction de
l'espace des
paramètres

Approche Maximum a
posteriori

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Solution qui maximise la probabilité du modèle étant donné les mesures :

$$\mathbf{x}_{\text{MAP}} = \arg \max_{\mathbf{x}} \Pr(\mathbf{x} | \mathbf{y})$$

$$\Pr(\mathbf{x} | \mathbf{y}) = \frac{\Pr(\mathbf{y} | \mathbf{x}) \Pr(\mathbf{x})}{\Pr(\mathbf{y})} \quad (\text{théorème de Bayes})$$

$$-\log \Pr(\mathbf{x} | \mathbf{y}) = -\log \Pr(\mathbf{y} | \mathbf{x}) - \log \Pr(\mathbf{x}) + \log \Pr(\mathbf{y})$$

$$\mathbf{x}_{\text{MAP}} = \arg \min_{\mathbf{x}} \left\{ \underbrace{-\log \Pr(\mathbf{y} | \mathbf{x})}_{\text{}} \underbrace{-\log \Pr(\mathbf{x})}_{\text{}} \right\}$$

Approche bayesienne : Maximum a posteriori

Introduction

Holographie
numérique

Déconvolution

MV

Restriction de
l'espace des
paramètres

Approche Maximum a
posteriori

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Solution qui maximise la probabilité du modèle étant donné les mesures :

$$\mathbf{x}_{\text{MAP}} = \arg \max_{\mathbf{x}} \Pr(\mathbf{x} | \mathbf{y})$$

$$\Pr(\mathbf{x} | \mathbf{y}) = \frac{\Pr(\mathbf{y} | \mathbf{x}) \Pr(\mathbf{x})}{\Pr(\mathbf{y})} \quad (\text{théorème de Bayes})$$

$$-\log \Pr(\mathbf{x} | \mathbf{y}) = -\log \Pr(\mathbf{y} | \mathbf{x}) - \log \Pr(\mathbf{x}) + \log \Pr(\mathbf{y})$$

$$\mathbf{x}_{\text{MAP}} = \arg \min_{\mathbf{x}} \underbrace{-\log \Pr(\mathbf{y} | \mathbf{x})}_{f_{\text{data}}(\mathbf{x})} - \log \Pr(\mathbf{x})$$

Approche bayesienne : Maximum a posteriori

Introduction

Holographie
numérique

Déconvolution
MV

Restriction de
l'espace des
paramètres

Approche Maximum a
posteriori

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Solution qui maximise la probabilité du modèle étant donné les mesures :

$$\mathbf{x}_{\text{MAP}} = \arg \max_{\mathbf{x}} \Pr(\mathbf{x} | \mathbf{y})$$

$$\Pr(\mathbf{x} | \mathbf{y}) = \frac{\Pr(\mathbf{y} | \mathbf{x}) \Pr(\mathbf{x})}{\Pr(\mathbf{y})} \quad (\text{théorème de Bayes})$$

$$-\log \Pr(\mathbf{x} | \mathbf{y}) = -\log \Pr(\mathbf{y} | \mathbf{x}) - \log \Pr(\mathbf{x}) + \log \Pr(\mathbf{y})$$

$$\mathbf{x}_{\text{MAP}} = \arg \min_{\mathbf{x}} \left\{ \underbrace{-\log \Pr(\mathbf{y} | \mathbf{x})}_{f_{\text{data}}(\mathbf{x})} \underbrace{-\log \Pr(\mathbf{x})}_{f_{\text{prior}}(\mathbf{x})} \right\}$$

Approche bayesienne : Maximum a posteriori

Introduction

Holographie
numérique

Déconvolution
MV

Restriction de
l'espace des
paramètres

Approche Maximum a
posteriori

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Solution qui maximise la probabilité du modèle étant donné les mesures :

$$\mathbf{x}_{\text{MAP}} = \arg \max_{\mathbf{x}} \Pr(\mathbf{x} | \mathbf{y})$$

$$\Pr(\mathbf{x} | \mathbf{y}) = \frac{\Pr(\mathbf{y} | \mathbf{x}) \Pr(\mathbf{x})}{\Pr(\mathbf{y})} \quad (\text{théorème de Bayes})$$

$$-\log \Pr(\mathbf{x} | \mathbf{y}) = -\log \Pr(\mathbf{y} | \mathbf{x}) - \log \Pr(\mathbf{x}) + \log \Pr(\mathbf{y})$$

$$\mathbf{x}_{\text{MAP}} = \arg \min_{\mathbf{x}} \left\{ \underbrace{-\log \Pr(\mathbf{y} | \mathbf{x})}_{f_{\text{data}}(\mathbf{x})} \quad \underbrace{-\log \Pr(\mathbf{x})}_{f_{\text{prior}}(\mathbf{x})} \right\}$$

$$= \arg \min_{\mathbf{x}} f_{\text{post}}(\mathbf{x})$$

Maximum a posteriori

Introduction

Holographie
numérique

Déconvolution
MV

Restriction de
l'espace des
paramètres

Approche Maximum a
posteriori

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

$f_{\text{post}}(\mathbf{x})$ = fonction pénalisante **a posteriori** :

$$f_{\text{post}}(\mathbf{x}) = f_{\text{data}}(\mathbf{x}) + f_{\text{prior}}(\mathbf{x})$$

$f_{\text{data}}(\mathbf{x})$ = terme de **vraisemblance** (attache aux données) :
modèle linéaire :

$$\begin{aligned} f_{\text{data}}(\mathbf{x}) &= \frac{1}{2} (\mathbf{y} - \mathbf{m}(V\mathbf{x}))^T \cdot \mathbf{C}_e^{-1} \cdot (\mathbf{y} - \mathbf{m}(\mathbf{x})), \\ &= \frac{1}{2} \sum_{k=\text{Pixels}} w_k (y_k - m(\mathbf{x})_k)^2. \end{aligned}$$

$f_{\text{prior}}(\mathbf{x})$ = terme de **régularisation** (a priori) :

$$f_{\text{prior}}(\mathbf{x}) = \mu \times \Omega(\mathbf{x}).$$

Maximum a posteriori

Introduction

Holographie
numérique

Déconvolution
MV

Restriction de
l'espace des
paramètres

Approche Maximum a
posteriori

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

$f_{\text{post}}(\mathbf{x})$ = fonction pénalisante **a posteriori** :

$$f_{\text{post}}(\mathbf{x}) = f_{\text{data}}(\mathbf{x}) + f_{\text{prior}}(\mathbf{x})$$

$f_{\text{data}}(\mathbf{x})$ = terme de **vraisemblance** (attache aux données) :

modèle linéaire :

$$\begin{aligned} f_{\text{data}}(\mathbf{x}) &= \frac{1}{2}(\mathbf{y} - \mathbf{m}(V\mathbf{x}))^T \cdot \mathbf{C}_e^{-1} \cdot (\mathbf{y} - \mathbf{m}(\mathbf{x})), \\ &= \frac{1}{2} \sum_{k=\text{Pixels}} w_k (y_k - m(\mathbf{x})_k)^2. \end{aligned}$$

$f_{\text{prior}}(\mathbf{x})$ = terme de **régularisation** (a priori) :

$$f_{\text{prior}}(\mathbf{x}) = \mu \times \Omega(\mathbf{x}).$$

Maximum a posteriori

Introduction

Holographie
numérique

Déconvolution
MV

Restriction de
l'espace des
paramètres

Approche Maximum a
posteriori

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

$f_{\text{post}}(\mathbf{x})$ = fonction pénalisante **a posteriori** :

$$f_{\text{post}}(\mathbf{x}) = f_{\text{data}}(\mathbf{x}) + f_{\text{prior}}(\mathbf{x})$$

$f_{\text{data}}(\mathbf{x})$ = terme de **vraisemblance** (attache aux données) :

modèle linéaire :

$$\begin{aligned} f_{\text{data}}(\mathbf{x}) &= \frac{1}{2}(\mathbf{y} - \mathbf{m}(V\mathbf{x}))^T \cdot \mathbf{C}_e^{-1} \cdot (\mathbf{y} - \mathbf{m}(\mathbf{x})), \\ &= \frac{1}{2} \sum_{k=\text{Pixels}} w_k (y_k - m(\mathbf{x})_k)^2. \end{aligned}$$

$f_{\text{prior}}(\mathbf{x})$ = terme de **régularisation** (a priori) :

$$f_{\text{prior}}(\mathbf{x}) = \mu \times \Omega(\mathbf{x}).$$

Régularisation spatiale

Introduction

Holographie
numérique

Déconvolution
MV

Restriction de
l'espace des
paramètres

Approche Maximum a
posteriori

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

A priori de lissage, contraintes sur les gradients spatiaux :

$$\Omega_{\text{spatial}}(\mathbf{x}) = \sum_r \sum_{k' \in V_k} \varphi \left(\frac{x_k - x_{k'}}{d(k, k')} \right),$$

- V_k : voisinage spatial du pixel k ,
- $d(k, k')$: distance entre les pixels k .

φ est une norme :

- norme quadratique,
- Préservation des contours : norme $\ell_2 - \ell_1$

$$\varphi(t; \eta) = 2 \eta^2 \left(\frac{|t|}{\eta} - \log \left(1 + \frac{|t|}{\eta} \right) \right),$$

Régularisation spatiale

Introduction

Holographie
numérique

Déconvolution
MV

Restriction de
l'espace des
paramètres

Approche Maximum a
posteriori

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

A priori de lissage, contraintes sur les gradients spatiaux :

$$\Omega_{\text{spatial}}(\mathbf{x}) = \sum_r \sum_{k' \in V_k} \varphi\left(\frac{x_k - x_{k'}}{d(k, k')}\right),$$

- V_k : voisinage spatial du pixel k ,
- $d(k, k')$: distance entre les pixels k .

φ est une norme :

- norme quadratique,
- Préservation des contours : norme $\ell_2 - \ell_1$

$$\varphi(t; \eta) = 2 \eta^2 \left(\frac{|t|}{\eta} - \log \left(1 + \frac{|t|}{\eta} \right) \right),$$

Régularisation spatiale

Introduction

Holographie
numérique

Déconvolution
MV

Restriction de
l'espace des
paramètres

Approche Maximum a
posteriori

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

A priori de lissage, contraintes sur les gradients spatiaux :

$$\Omega_{\text{spatial}}(\mathbf{x}) = \sum_r \sum_{k' \in V_k} \varphi \left(\frac{x_k - x_{k'}}{d(k, k')} \right),$$

- V_k : voisinage spatial du pixel k ,
- $d(k, k')$: distance entre les pixels k .

φ est une norme :

- norme quadratique,
- Préservation des contours : norme $\ell_2 - \ell_1$

$$\varphi(t; \eta) = 2 \eta^2 \left(\frac{|t|}{\eta} - \log \left(1 + \frac{|t|}{\eta} \right) \right),$$

Régularisation spatiale

Introduction

Holographie
numérique

Déconvolution
MV

Restriction de
l'espace des
paramètres

Approche Maximum a
posteriori

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

A priori de lissage, contraintes sur les gradients spatiaux :

$$\Omega_{\text{spatial}}(\mathbf{x}) = \sum_r \sum_{k' \in V_k} \varphi \left(\frac{x_k - x_{k'}}{d(k, k')} \right),$$

- V_k : voisinage spatial du pixel k ,
- $d(k, k')$: distance entre les pixels k .

φ est une norme :

- norme quadratique,
- Préservation des contours : norme $\ell_2 - \ell_1$

$$\varphi(t; \eta) = 2 \eta^2 \left(\frac{|t|}{\eta} - \log \left(1 + \frac{|t|}{\eta} \right) \right),$$

Résultats simulation

Introduction

Holographie
numérique

Déconvolution

MV

Restriction de
l'espace des
paramètres

Approche Maximum a
posteriori

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion



Données simulées.



Vérité.

Résultats simulation

Introduction

Holographie
numérique

Déconvolution

MV

Restriction de
l'espace des
paramètres

Approche Maximum a
posteriori

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion



Régularisation quadratique.



Régularisation
avec norme $\ell_2 - \ell_1$.

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données

Régularisation
séparable

Démosaïçage

Données
multi-spectrales

Deconvolution
Aveugle

Conclusion

Déconvolution multidimensionnelle

Formation de données multidimensionnelles

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données

Régularisation
séparable


Démosaïçage

Données
multi-spectrales

Déconvolution
Aveugle

Conclusion

Exemple, séquence video (x,z,t) :



Régularisation séparable

Introduction

Holographie numérique

Déconvolution

Déconvolution multidimensionnelle

Formation des données

Régularisation séparable

Démosaïçage

Données multi-spectrales

Deconvolution Aveugle

Conclusion

Idée :

Régularisation séparable suivant les dimensions de l'objet :

$$f_{\text{prior}}(\mathbf{x}) = f_{\text{spatial}}(\mathbf{x}) + f_{\text{spectral}}(\mathbf{x}) + f_{\text{temporel}}(\mathbf{x})$$

Une régularisation spatiale

$$f_{\text{spatial}}(\mathbf{x}) = \sum_{\lambda,t} \alpha_{\lambda,t} \Omega_{\text{spatial}}(\mathbf{x}_{\lambda,t})$$

Une régularisation spectrale

$$f_{\text{spectral}}(\mathbf{x}) = \sum_{k,t} \beta_{k,t} \Omega_{\text{spectral}}(\mathbf{x}_{k,t})$$

Une régularisation temporelle

$$f_{\text{temporel}}(\mathbf{x}) = \sum_{\lambda,k} \mu_{\lambda,k} \Omega_{\text{temporel}}(\mathbf{x}_{\lambda,k})$$

Régularisation séparable

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données

Régularisation
séparable

Démosaïçage

Données
multi-spectrales

Deconvolution
Aveugle

Conclusion

Idée :

Régularisation séparable suivant les dimensions de l'objet :

$$f_{\text{prior}}(\mathbf{x}) = f_{\text{spatial}}(\mathbf{x}) + f_{\text{spectral}}(\mathbf{x}) + f_{\text{temporel}}(\mathbf{x})$$

Une régularisation spatiale

$$f_{\text{spatial}}(\mathbf{x}) = \sum_{\lambda,t} \alpha_{\lambda,t} \Omega_{\text{spatial}}(\mathbf{x}_{\lambda,t})$$

Une régularisation spectrale

$$f_{\text{spectral}}(\mathbf{x}) = \sum_{k,t} \beta_{k,t} \Omega_{\text{spectral}}(\mathbf{x}_{k,t})$$

Une régularisation temporelle

$$f_{\text{temporel}}(\mathbf{x}) = \sum_{\lambda,k} \mu_{\lambda,k} \Omega_{\text{temporel}}(\mathbf{x}_{\lambda,k})$$

Régularisation séparable

Idée :

Régularisation séparable suivant les dimensions de l'objet :

$$f_{\text{prior}}(\mathbf{x}) = f_{\text{spatial}}(\mathbf{x}) + f_{\text{spectral}}(\mathbf{x}) + f_{\text{temporel}}(\mathbf{x})$$

Une régularisation spatiale

$$f_{\text{spatial}}(\mathbf{x}) = \sum_{\lambda,t} \alpha_{\lambda,t} \Omega_{\text{spatial}}(\mathbf{x}_{\lambda,t})$$

Une régularisation spectrale

$$f_{\text{spectral}}(\mathbf{x}) = \sum_{k,t} \beta_{k,t} \Omega_{\text{spectral}}(\mathbf{x}_{k,t})$$

Une régularisation temporelle

$$f_{\text{temporel}}(\mathbf{x}) = \sum_{\lambda,k} \mu_{\lambda,k} \Omega_{\text{temporel}}(\mathbf{x}_{\lambda,k})$$

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données

Régularisation
séparable

Démosaïçage

Données
multi-spectrales

Deconvolution
Aveugle

Conclusion

Régularisation séparable

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données

Régularisation
séparable

Démosaïçage

Données
multi-spectrales

Deconvolution
Aveugle

Conclusion

Idée :

Régularisation séparable suivant les dimensions de l'objet :

$$f_{\text{prior}}(\mathbf{x}) = f_{\text{spatial}}(\mathbf{x}) + f_{\text{spectral}}(\mathbf{x}) + f_{\text{temporel}}(\mathbf{x})$$

Une régularisation spatiale

$$f_{\text{spatial}}(\mathbf{x}) = \sum_{\lambda,t} \alpha_{\lambda,t} \Omega_{\text{spatial}}(\mathbf{x}_{\lambda,t})$$

Une régularisation spectrale

$$f_{\text{spectral}}(\mathbf{x}) = \sum_{k,t} \beta_{k,t} \Omega_{\text{spectral}}(\mathbf{x}_{k,t})$$

Une régularisation temporelle

$$f_{\text{temporel}}(\mathbf{x}) = \sum_{\lambda,k} \mu_{\lambda,k} \Omega_{\text{temporel}}(\mathbf{x}_{\lambda,k})$$

Mosaïçage

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données

Régularisation
séparable

Démosaïçage

Données
multi-spectrales

Deconvolution
Aveugle

Conclusion

Pour la plupart de capteurs couleurs :
Capteurs monochromes où chaque pixel
code une des trois couleurs RVB
disposés généralement selon le motif de
bayer.

$$y = \mathbf{B} \cdot x .$$

	B	G	B	
R	G	R	G	R
G	B	G	B	G
R	G	R	G	R
	B	G	B	

Mosaïçage

Pour la plupart de capteurs couleurs :
Capteurs monochromes où chaque pixel
code une des trois couleurs RVB
disposés généralement selon le motif de
bayer.

$$y = \mathbf{B} \cdot \mathbf{x}.$$

	B	G	B	
R	G	R	G	R
G	B	G	B	G
R	G	R	G	R
	B	G	B	



Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données

Régularisation
séparable

Démosaïçage

Données
multi-spectrales

Deconvolution
Aveugle



Conclusion

Mosaïçage

Pour la plupart de capteurs couleurs :
Capteurs monochromes où chaque pixel
code une des trois couleurs RVB
disposés généralement selon le motif de
bayer.

	B	G	B	
R	G	R	G	R
G	B	G	B	G
R	G	R	G	R
	B	G	B	

$$y = B \cdot x .$$



Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données

Régularisation
séparable

Démosaïçage

Données
multi-spectrales

Deconvolution
Aveugle

Conclusion

Modèle de formation de l'image

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données

Régularisation
séparable

Démosaïçage

Données
multi-spectrales

Deconvolution
Aveugle

Conclusion




Image d'origine

$$y = \mathbf{B} \cdot \mathbf{H} \cdot x + e .$$

- **Objet : x**
- Convolution par la PSF : \mathbf{H}
- Projection d'après la matrice de Bayer : \mathbf{B}
- Bruit additif : e
- Image observée : y

Modèle de formation de l'image



$$y = \mathbf{B} \cdot \mathbf{H} \cdot x + e .$$

- Objet : x
- Convolution par la PSF : \mathbf{H}
- Projection d'après la matrice de Bayer : \mathbf{B}
- Bruit additif : e
- Image observée : y

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données

Régularisation
séparable


Démosaïçage

Données
multi-spectrales

Deconvolution
Aveugle

Conclusion

Modèle de formation de l'image



$$y = \mathbf{B} \cdot \mathbf{H} \cdot x + e .$$

- Objet : x
- Convolution par la PSF : \mathbf{H}
- Projection d'après la matrice de Bayer : \mathbf{B}
- Bruit additif : e
- Image observée : y

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données

Régularisation
séparable


Démosaiçage

Données
multi-spectrales

Deconvolution
Aveugle

Conclusion

Modèle de formation de l'image



$$y = \mathbf{B} \cdot \mathbf{H} \cdot x + e .$$

- Objet : x
- Convolution par la PSF : \mathbf{H}
- Projection d'après la matrice de Bayer : \mathbf{B}
- Bruit additif : e
- Image observée : y

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données

Régularisation
séparable


Démosaiçage

Données
multi-spectrales

Deconvolution
Aveugle

Conclusion

Modèle de formation de l'image



$$y = \mathbf{B} \cdot \mathbf{H} \cdot x + e .$$

- Objet : x
- Convolution par la PSF : \mathbf{H}
- Projection d'après la matrice de Bayer : \mathbf{B}
- Bruit additif : e
- Image observée : y

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données

Régularisation
séparable


Démosaïçage

Données
multi-spectrales

Deconvolution
Aveugle

Conclusion

Modèle de formation de l'image



$$y = \mathbf{B} \cdot \mathbf{H} \cdot x + e .$$

- Objet : x
- Convolution par la PSF : \mathbf{H}
- Projection d'après la matrice de Bayer : \mathbf{B}
- Bruit additif : e
- Image observée : y

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données

Régularisation
séparable

Démosaiçage

Données
multi-spectrales

Deconvolution
Aveugle

Conclusion

Bayer : régularisation spectrale

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données

Régularisation
séparable

Démosaïçage

Données
multi-spectrales

Deconvolution
Aveugle

Conclusion

D'après Gunturk (2002), les hautes fréquences de chaque canal spectral sont très corrélées entre-elles.

Fonction de régularisation :

$$\Omega_{\text{spectral}}(\mathbf{x}) = \|\mathbf{P} \cdot (\mathbf{x}^R - \mathbf{x}^V)\|_2^2 + \|\mathbf{P} \cdot (\mathbf{x}^R - \mathbf{x}^B)\|_2^2 + \|\mathbf{P} \cdot (\mathbf{x}^B - \mathbf{x}^V)\|_2^2,$$

avec \mathbf{P} : un filtre passe-haut.

Bayer : régularisation spectrale

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données

Régularisation
séparable

Démosaïçage

Données
multi-spectrales

Déconvolution
Aveugle

Conclusion

D'après Gunturk (2002), les hautes fréquences de chaque canal spectral sont très corrélées entre-elles.

Fonction de régularisation :

$$\Omega_{\text{spectral}}(\mathbf{x}) = \|\mathbf{P} \cdot (\mathbf{x}^R - \mathbf{x}^V)\|_2^2 + \|\mathbf{P} \cdot (\mathbf{x}^R - \mathbf{x}^B)\|_2^2 + \|\mathbf{P} \cdot (\mathbf{x}^B - \mathbf{x}^V)\|_2^2,$$

avec \mathbf{P} : un filtre passe-haut.



Originale



Originale




Floue (PSNR = 29.8dB)



Originale



Floue (PSNR = 29.8dB)




Observations



Originale



Floue (PSNR = 29.8dB)



Observations




Interpolation (-0.5dB)



Originale



Floue (PSNR = 29.8dB)



Observations



Interpolation (-0.5dB)




Interpolation +
Déconvolution (+2.9dB)



Originale



Floue (PSNR = 29.8dB)



Observations



Interpolation (-0.5dB)



Interpolation +
Déconvolution (+2.9dB)



Déconvolution Jointe
(+5.6dB)

Résultats expérimentaux

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données

Régularisation
séparable

Démosaiçage

Données
multi-spectrales

Deconvolution
Aveugle

Conclusion



Interpolation de
l'image défocalisée

Photo manuellement défocalisée

Déconvolution aveugle, psf reconstruite de 8 pixels de diamètre

Résultats expérimentaux

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données

Régularisation
séparable

Démosaiçage

Données
multi-spectrales

Deconvolution
Aveugle

Conclusion



Interpolation de
l'image défocalisée



Déconvolution Jointe

Photo manuellement défocalisée

Déconvolution aveugle, psf reconstruite de 8 pixels de diamètre

Résultats expérimentaux

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données

Régularisation
séparable

Démosaïçage

Données
multi-spectrales

Deconvolution
Aveugle

Conclusion



Interpolation de
l'image défocalisée



Déconvolution Jointe



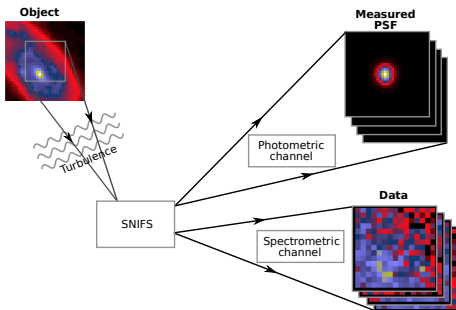
Mise au point
et réglages
automatiques

Photo manuellement défocalisée

Déconvolution aveugle, psf reconstruite de 8 pixels de diamètre

Supernovæ Factory

Étude des Supernovæ de type Ia pour la cosmologie utilisant SNIFS, un spectrographe intégral de champ.



- PSF (32×32) estimées d'après les poses photométriques,
- Données (15×15),
- 798λ de 3200\AA à 5096\AA ,
- Bas flux : bruit de Poisson.

⇒ Reconstruction d'un objet au minimum de taille ($32 \times 32 \times 798$) (3 inconnues pour 1 donnée).

Collaboration : S. Bongard (LBNL, LPNHE), E. Pécontal (CRAL).

Introduction

Holographie numérique

Déconvolution

Déconvolution multidimensionnelle

Formation des données

Régularisation séparable

Démosaïçage


Données multi-spectrales

Deconvolution Aveugle

Conclusion

Supernovæ Factory

Étude des Supernovæ de type Ia pour la cosmologie utilisant SNIFS, un spectrographe intégral de champ.



- PSF (32×32) estimées d'après les poses photométriques,
- Données (15×15),
- 798λ de 3200\AA à 5096\AA ,
- Bas flux : bruit de Poisson.

⇒ Reconstruction d'un objet au minimum de taille ($32 \times 32 \times 798$) (3 inconnues pour 1 donnée).

Collaboration : S. Bongard (LBNL, LPNHE), E. Pécontal (CRAL).

Introduction

Holographie numérique

Déconvolution

Déconvolution multidimensionnelle

Formation des données

Régularisation séparable

Démosaïçage


Données multi-spectrales

Déconvolution Aveugle

Conclusion

Supernovæ Factory

Étude des Supernovæ de type Ia pour la cosmologie utilisant SNIFS, un spectrographe intégral de champ.



- PSF (32×32) estimées d'après les poses photométriques,
- Données (15×15),
 - 798λ de 3200\AA à 5096\AA ,
 - Bas flux : bruit de Poisson.

⇒ Reconstruction d'un objet au minimum de taille ($32 \times 32 \times 798$) (3 inconnues pour 1 donnée).

Collaboration : S. Bongard (LBNL, LPNHE), E. Pécontal (CRAL).

Introduction

Holographie numérique

Déconvolution

Déconvolution multidimensionnelle

Formation des données

Régularisation séparable

Démosaïçage


Données multi-spectrales

Déconvolution Aveugle

Conclusion

Supernovæ Factory

Étude des Supernovæ de type Ia pour la cosmologie utilisant SNIFS, un spectrographe intégral de champ.



- PSF (32×32) estimées d'après les poses photométriques,
- Données (15×15),
- 798λ de 3200\AA à 5096\AA ,
- Bas flux : bruit de Poisson.

⇒ Reconstruction d'un objet au minimum de taille ($32 \times 32 \times 798$) (3 inconnues pour 1 donnée).

Collaboration : S. Bongard (LBNL, LPNHE), E. Pécontal (CRAL).

Introduction

Holographie numérique

Déconvolution

Déconvolution multidimensionnelle

Formation des données

Régularisation séparable

Démosaïçage


Données multi-spectrales

Déconvolution Aveugle

Conclusion

Supernovæ Factory

Étude des Supernovæ de type Ia pour la cosmologie utilisant SNIFS, un spectrographe intégral de champ.



- PSF (32×32) estimées d'après les poses photométriques,
- Données (15×15),
- 798λ de 3200\AA à 5096\AA ,
- Bas flux : bruit de Poisson.

⇒ Reconstruction d'un objet au minimum de taille ($32 \times 32 \times 798$) (3 inconnues pour 1 donnée).

Collaboration : S. Bongard (LBNL, LPNHE), E. Pécontal (CRAL).

Introduction

Holographie numérique

Déconvolution

Déconvolution multidimensionnelle

Formation des données

Régularisation séparable

Démosaïçage


Données multi-spectrales

Déconvolution Aveugle

Conclusion

Supernovæ Factory

Étude des Supernovæ de type Ia pour la cosmologie utilisant SNIFS, un spectrographe intégral de champ.



- PSF (32×32) estimées d'après les poses photométriques,
- Données (15×15),
- 798λ de 3200\AA à 5096\AA ,
- Bas flux : bruit de Poisson.

⇒ Reconstruction d'un objet au minimum de taille ($32 \times 32 \times 798$) (3 inconnues pour 1 donnée).

Collaboration : S. Bongard (LBNL, LPNHE), E. Pécontal (CRAL).

Introduction

Holographie numérique

Déconvolution

Déconvolution multidimensionnelle

Formation des données

Régularisation séparable

Démosaïçage

Données multi-spectrales

Déconvolution Aveugle

Conclusion

Supernovæ Factory : terme de vraisemblance

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données

Régularisation
séparable

Démosaïçage

Données
multi-spectrales

Deconvolution
Aveugle

Conclusion

Dépend de la nature du bruit,

Bruit de Poisson \approx Bruit gaussien non-stationnaire

$$\sigma_{k,\lambda}^2 = \gamma(\mathbf{H} \cdot \mathbf{x})_{k,\lambda} + \sigma_{\text{CCD}}^2 \approx \gamma \max(y_{k,\lambda}, 0) + \sigma_{\text{CCD}}^2$$

γ : facteur de quantification

σ_{CCD}^2 : variance de bruits additifs gaussiens (e.g. bruit de lecture).

$$f_{\text{data}}(\mathbf{x}) = \sum_k \sum_{\lambda} \underbrace{w_{k,\lambda}}_{\text{poids}} \left[\underbrace{(\mathbf{H} \cdot \mathbf{x})_{k,\lambda}}_{\text{modèle}} - \underbrace{y_{k,\lambda}}_{\text{donnée}} \right]^2$$

$$w_{k,\lambda} = \text{diag } \mathbf{C}_e^{-1} = \begin{cases} \frac{1}{\sigma_{k,\lambda}^2} & \text{si le pixel } \{k, \lambda\} \text{ est mesuré,} \\ 0 & \text{sinon.} \end{cases}$$

Supernovæ Factory : terme de vraisemblance

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données

Régularisation
séparable

Démosaïçage

Données
multi-spectrales

Deconvolution
Aveugle

Conclusion

Dépend de la nature du bruit,

Bruit de Poisson \approx Bruit gaussien non-stationnaire

$$\sigma_{k,\lambda}^2 = \gamma(\mathbf{H} \cdot \mathbf{x})_{k,\lambda} + \sigma_{\text{CCD}}^2 \approx \gamma \max(y_{k,\lambda}, 0) + \sigma_{\text{CCD}}^2$$

γ : facteur de quantification

σ_{CCD}^2 : variance de bruits additifs gaussiens (e.g. bruit de lecture).

$$f_{\text{data}}(\mathbf{x}) = \sum_k \sum_{\lambda} \underbrace{w_{k,\lambda}}_{\text{poids}} \left[\underbrace{(\mathbf{H} \cdot \mathbf{x})_{k,\lambda}}_{\text{modèle}} - \underbrace{y_{k,\lambda}}_{\text{donnée}} \right]^2$$

$$w_{k,\lambda} = \text{diag } \mathbf{C}_e^{-1} = \begin{cases} \frac{1}{\sigma_{k,\lambda}^2} & \text{si le pixel } \{k, \lambda\} \text{ est mesuré,} \\ 0 & \text{sinon.} \end{cases}$$

Supernovæ Factory : terme de vraisemblance

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données

Régularisation
séparable

Démosaïçage

Données
multi-spectrales

Deconvolution
Aveugle

Conclusion

Dépend de la nature du bruit,

Bruit de Poisson \approx Bruit gaussien non-stationnaire

$$\sigma_{k,\lambda}^2 = \gamma(\mathbf{H} \cdot \mathbf{x})_{k,\lambda} + \sigma_{\text{CCD}}^2 \approx \gamma \max(y_{k,\lambda}, 0) + \sigma_{\text{CCD}}^2$$

γ : facteur de quantification

σ_{CCD}^2 : variance de bruits additifs gaussiens (e.g. bruit de lecture).

$$f_{\text{data}}(\mathbf{x}) = \sum_k \sum_{\lambda} \underbrace{w_{k,\lambda}}_{\text{poids}} \left[\underbrace{(\mathbf{H} \cdot \mathbf{x})_{k,\lambda}}_{\text{modèle}} - \underbrace{y_{k,\lambda}}_{\text{donnée}} \right]^2$$

$$w_{k,\lambda} = \text{diag } \mathbf{C}_e^{-1} = \begin{cases} \frac{1}{\sigma_{k,\lambda}^2} & \text{si le pixel } \{k, \lambda\} \text{ est mesuré,} \\ 0 & \text{sinon.} \end{cases}$$

Supernovæ Factory : terme de vraisemblance

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données

Régularisation
séparable

Démosaïçage

Données
multi-spectrales

Deconvolution
Aveugle

Conclusion

Dépend de la nature du bruit,

Bruit de Poisson \approx Bruit gaussien non-stationnaire

$$\sigma_{k,\lambda}^2 = \gamma(\mathbf{H} \cdot \mathbf{x})_{k,\lambda} + \sigma_{\text{CCD}}^2 \approx \gamma \max(y_{k,\lambda}, 0) + \sigma_{\text{CCD}}^2$$

γ : facteur de quantification

σ_{CCD}^2 : variance de bruits additifs gaussiens (e.g. bruit de lecture).

$$f_{\text{data}}(\mathbf{x}) = \sum_k \sum_{\lambda} \underbrace{w_{k,\lambda}}_{\text{pois}} \left[\underbrace{(\mathbf{H} \cdot \mathbf{x})_{k,\lambda}}_{\text{modèle}} - \underbrace{y_{k,\lambda}}_{\text{donnée}} \right]^2$$

$$w_{k,\lambda} = \text{diag } \mathbf{C}_e^{-1} = \begin{cases} \frac{1}{\sigma_{k,\lambda}^2} & \text{si le pixel } \{k, \lambda\} \text{ est mesuré,} \\ 0 & \text{sinon.} \end{cases}$$

Supernovæ Factory : terme de vraisemblance

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données

Régularisation
séparable

Démosaïçage

Données
multi-spectrales

Deconvolution
Aveugle

Conclusion

Dépend de la nature du bruit,

Bruit de Poisson \approx **Bruit gaussien non-stationnaire**

$$\sigma_{k,\lambda}^2 = \gamma(\mathbf{H} \cdot \mathbf{x})_{k,\lambda} + \sigma_{\text{CCD}}^2 \approx \gamma \max(y_{k,\lambda}, 0) + \sigma_{\text{CCD}}^2$$

γ : facteur de quantification

σ_{CCD}^2 : variance de bruits additifs gaussiens (e.g. bruit de lecture).

$$f_{\text{data}}(\mathbf{x}) = \sum_k \sum_{\lambda} \underbrace{w_{k,\lambda}}_{\text{poids}} \left[\underbrace{(\mathbf{H} \cdot \mathbf{x})_{k,\lambda}}_{\text{modèle}} - \underbrace{y_{k,\lambda}}_{\text{donnée}} \right]^2$$

$$w_{k,\lambda} = \text{diag } \mathbf{C}_e^{-1} = \begin{cases} \frac{1}{\sigma_{k,\lambda}^2} & \text{si le pixel } \{k, \lambda\} \text{ est mesuré,} \\ 0 & \text{sinon.} \end{cases}$$

Supernovæ Factory : terme de vraisemblance

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données

Régularisation
séparable

Démosaïçage

Données
multi-spectrales

Deconvolution
Aveugle

Conclusion

Dépend de la nature du bruit,

Bruit de Poisson \approx **Bruit gaussien non-stationnaire**

$$\sigma_{k,\lambda}^2 = \gamma(\mathbf{H} \cdot \mathbf{x})_{k,\lambda} + \sigma_{\text{CCD}}^2 \approx \gamma \max(y_{k,\lambda}, 0) + \sigma_{\text{CCD}}^2$$

γ : facteur de quantification

σ_{CCD}^2 : variance de bruits additifs gaussiens (e.g. bruit de lecture).

$$f_{\text{data}}(\mathbf{x}) = \sum_k \sum_{\lambda} \underbrace{w_{k,\lambda}}_{\text{poids}} \left[\underbrace{(\mathbf{H} \cdot \mathbf{x})_{k,\lambda}}_{\text{modèle}} - \underbrace{y_{k,\lambda}}_{\text{donnée}} \right]^2$$

$$w_{k,\lambda} = \text{diag } \mathbf{C}_e^{-1} = \begin{cases} \frac{1}{\sigma_{k,\lambda}^2} & \text{si le pixel } \{k, \lambda\} \text{ est mesuré,} \\ 0 & \text{sinon.} \end{cases}$$

Supernovæ Factory : terme de vraisemblance

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données

Régularisation
séparable

Démosaïçage

Données
multi-spectrales

Déconvolution
Aveugle

Conclusion

Dépend de la nature du bruit,

Bruit de Poisson \approx Bruit gaussien non-stationnaire

$$\sigma_{k,\lambda}^2 = \gamma(\mathbf{H} \cdot \mathbf{x})_{k,\lambda} + \sigma_{\text{CCD}}^2 \approx \gamma \max(y_{k,\lambda}, 0) + \sigma_{\text{CCD}}^2$$

γ : facteur de quantification

σ_{CCD}^2 : variance de bruits additifs gaussiens (e.g. bruit de lecture).

$$f_{\text{data}}(\mathbf{x}) = \sum_k \sum_{\lambda} \underbrace{w_{k,\lambda}}_{\text{poids}} \left[\underbrace{(\mathbf{H} \cdot \mathbf{x})_{k,\lambda}}_{\text{modèle}} - \underbrace{y_{k,\lambda}}_{\text{donnée}} \right]^2$$

$$w_{k,\lambda} = \text{diag } \mathbf{C}_e^{-1} = \begin{cases} \frac{1}{\sigma_{k,\lambda}^2} & \text{si le pixel } \{k, \lambda\} \text{ est mesuré,} \\ 0 & \text{sinon.} \end{cases}$$

Supernovæ Factory : régularisation spectrale

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données

Régularisation
séparable

Démosaïçage

Données
multi-spectrales

Deconvolution
Aveugle

Conclusion

Dynamique très différente d'une longueur d'onde à l'autre :

Deux difficultés :

- Etablir une régularisation efficace,
- Régler les hyper-paramètres.

Constat

Les structures spatiales de chaque image x_λ sont proches,
 \approx les spectres de chaque pixel x_k sont proches à une
constante multiplicative près.

Régularisation spectrale

Le rapport entre le spectre de chaque pixel x_k et le spectre
moyen des données (SED) est \approx constant :

$$\Omega_{\text{spectral}}(\mathbf{x}_k) = \left(\frac{x_{r,\lambda+\Delta\lambda}}{\text{SED}_{\lambda+\Delta\lambda}} - \frac{x_{r,\lambda}}{\text{SED}_\lambda} \right)^2,$$

Supernovæ Factory : régularisation spectrale

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données

Régularisation
séparable

Démosaïçage

Données
multi-spectrales

Deconvolution
Aveugle

Conclusion

Dynamique très différente d'une longueur d'onde à l'autre :

Deux difficultés :

- Etablir une régularisation efficace,
- Régler les hyper-paramètres.

Constat

Les structures spatiales de chaque image x_λ sont proches,
 \approx les spectres de chaque pixel x_k sont proches à une
constante multiplicative près.

Régularisation spectrale

Le rapport entre le spectre de chaque pixel x_k et le spectre
moyen des données (SED) est \approx constant :

$$\Omega_{\text{spectral}}(\mathbf{x}_k) = \left(\frac{x_{r,\lambda+\Delta\lambda}}{\text{SED}_{\lambda+\Delta\lambda}} - \frac{x_{r,\lambda}}{\text{SED}_\lambda} \right)^2,$$

Supernovæ Factory : régularisation spectrale

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données

Régularisation
séparable

Démosaïçage

Données
multi-spectrales

Deconvolution
Aveugle

Conclusion

Dynamique très différente d'une longueur d'onde à l'autre :

Deux difficultés :

- Etablir une régularisation efficace,
- Régler les hyper-paramètres.

Constat

Les structures spatiales de chaque image x_λ sont proches,
 \approx les spectres de chaque pixel x_k sont proches à une
constante multiplicative près.

Régularisation spectrale

Le rapport entre le spectre de chaque pixel x_k et le spectre
moyen des données (SED) est \approx constant :

$$\Omega_{\text{spectral}}(\mathbf{x}_k) = \left(\frac{x_{r,\lambda+\Delta\lambda}}{\text{SED}_{\lambda+\Delta\lambda}} - \frac{x_{r,\lambda}}{\text{SED}_\lambda} \right)^2,$$

Supernovæ Factory : régularisation spectrale

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données

Régularisation
séparable

Démosaïçage

Données
multi-spectrales

Deconvolution
Aveugle

Conclusion

Dynamique très différente d'une longueur d'onde à l'autre :

Deux difficultés :

- Etablir une régularisation efficace,
- Régler les hyper-paramètres.

Constat

Les structures spatiales de chaque image x_λ sont proches,
 \approx les spectres de chaque pixel x_k sont proches à une
constante multiplicative près.

Régularisation spectrale

Le rapport entre le spectre de chaque pixel x_k et le spectre
moyen des données (SED) est \approx constant :

$$\Omega_{\text{spectral}}(\mathbf{x}_k) = \left(\frac{x_{r,\lambda+\Delta\lambda}}{\text{SED}_{\lambda+\Delta\lambda}} - \frac{x_{r,\lambda}}{\text{SED}_\lambda} \right)^2,$$

Supernovæ Factory : régularisation spectrale

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données

Régularisation
séparable

Démosaïçage

Données
multi-spectrales

Déconvolution
Aveugle

Conclusion

Dynamique très différente d'une longueur d'onde à l'autre :

Deux difficultés :

- Etablir une régularisation efficace,
- Régler les hyper-paramètres.

Constat

Les structures spatiales de chaque image x_λ sont proches,
 \approx les spectres de chaque pixel x_k sont proches à une
constante multiplicative près.

Régularisation spectrale

Le rapport entre le spectre de chaque pixel x_k et le spectre
moyen des données (SED) est \approx constant :

$$\Omega_{\text{spectral}}(\mathbf{x}_k) = \left(\frac{x_{r,\lambda+\Delta\lambda}}{\text{SED}_{\lambda+\Delta\lambda}} - \frac{x_{r,\lambda}}{\text{SED}_\lambda} \right)^2,$$

Supernovæ Factory : régularisation spectrale

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données

Régularisation
séparable

Démosaïçage

Données
multi-spectrales

Déconvolution
Aveugle

Conclusion

Dynamique très différente d'une longueur d'onde à l'autre :

Deux difficultés :

- Etablir une régularisation efficace,
- Régler les hyper-paramètres.

Constat

Les structures spatiales de chaque image x_λ sont proches,
 \approx les spectres de chaque pixel x_k sont proches à une
constante multiplicative près.

Réglage des hyper-paramètres

- Hyper-paramètres spatiaux α_λ normalisés par le flux
moyen dans l'image x_λ .
- Tous les spectres x_k suivent le même *a priori* :
hyper-paramètres sur les spectres β_k constant.

Simulations Supernovæ Factory

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données

Régularisation
séparable

Démosaïçage

**Données
multi-spectrales**

Deconvolution
Aveugle

Conclusion

Simulations Supernovæ Factory

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données


Régularisation
séparable

Démosaïçage

**Données
multi-spectrales**

Deconvolution
Aveugle

Conclusion



Données (3975Å)

Simulations Supernovæ Factory

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données


Régularisation
séparable

Démosaïçage


**Données
multi-spectrales**

Deconvolution
Aveugle

Conclusion



Données (3975Å)



reconstruction

Simulations Supernovæ Factory

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données


Régularisation
séparable

Démosaïçage


**Données
multi-spectrales**

Deconvolution
Aveugle


Conclusion



Données (3975Å)



reconstruction



vérité

Simulations Supernovæ Factory

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Formation des
données


Régularisation
séparable

Démosaiçage


Données
multi-spectrales

Deconvolution
Aveugle


Conclusion




Données (3975Å)



reconstruction




vérité




- bleu : Données
- rouge : Reconstruction
- noir : Vérité

Extrapolation du champ.




Reconstruction (3975Å)




Vérité

Extrapolation du champ.




Reconstruction (3975Å)




Vérité

Extrapolation du champ.




Reconstruction (3975Å)




Vérité

Extrapolation du champ.




Reconstruction (3975Å)




Vérité

Extrapolation du champ.




Reconstruction (3975Å)




Vérité

Extrapolation du champ.



Reconstruction (3975Å)



Vérité

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

**Deconvolution
Aveugle**

Coronarographie

Microscopie
Confocale

Microscopie
conventionnelle

Conclusion

Deconvolution Aveugle

Déconvolution Aveugle

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Coronarographie
Microscopie
Confocale
Microscopie
conventionnelle

Conclusion

PSF h et objet x inconnus

Estimer h et x d'après les données y :
Déconvolution aveugle.

Critère à minimiser

$$f_{\text{post}}(\mathbf{x}, \mathbf{h}) = f_{\text{data}}(\mathbf{x}, \mathbf{h}; \mathbf{y}) + f_{\text{prior}}(\mathbf{x}) + f_{\text{prior}}(\mathbf{h}) .$$

Régularisation sur la PSF

Régularisation séparable :

$$f_{\text{prior}}(\mathbf{h}) = f_{\text{spatial}}(\mathbf{h}) + f_{\text{spectral}}(\mathbf{h}) + f_{\text{temporel}}(\mathbf{h})$$

Déconvolution Aveugle

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Coronarographie
Microscopie
Confocale
Microscopie
conventionnelle

Conclusion

PSF h et objet x inconnus

Estimer h et x d'après les données y :
Déconvolution aveugle.

Critère à minimiser

$$f_{\text{post}}(\mathbf{x}, \mathbf{h}) = f_{\text{data}}(\mathbf{x}, \mathbf{h}; \mathbf{y}) + f_{\text{prior}}(\mathbf{x}) + f_{\text{prior}}(\mathbf{h}).$$

Régularisation sur la PSF

Régularisation séparable :

$$f_{\text{prior}}(\mathbf{h}) = f_{\text{spatial}}(\mathbf{h}) + f_{\text{spectral}}(\mathbf{h}) + f_{\text{temporel}}(\mathbf{h})$$

Déconvolution Aveugle

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Coronarographie
Microscopie
Confocale
Microscopie
conventionnelle

Conclusion

PSF \mathbf{h} et objet \mathbf{x} inconnus

Estimer \mathbf{h} et \mathbf{x} d'après les données \mathbf{y} :
Déconvolution aveugle.

Critère à minimiser

$$f_{\text{post}}(\mathbf{x}, \mathbf{h}) = f_{\text{data}}(\mathbf{x}, \mathbf{h}; \mathbf{y}) + f_{\text{prior}}(\mathbf{x}) + f_{\text{prior}}(\mathbf{h}) .$$

Régularisation sur la PSF

Régularisation séparable :

$$f_{\text{prior}}(\mathbf{h}) = f_{\text{spatial}}(\mathbf{h}) + f_{\text{spectral}}(\mathbf{h}) + f_{\text{temporel}}(\mathbf{h})$$

Déconvolution Aveugle

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Coronarographie
Microscopie
Confocale
Microscopie
conventionnelle

Conclusion

PSF \mathbf{h} et objet \mathbf{x} inconnus

Estimer \mathbf{h} et \mathbf{x} d'après les données \mathbf{y} :
Déconvolution aveugle.

Critère à minimiser

$$f_{\text{post}}(\mathbf{x}, \mathbf{h}) = f_{\text{data}}(\mathbf{x}, \mathbf{h}; \mathbf{y}) + f_{\text{prior}}(\mathbf{x}) + f_{\text{prior}}(\mathbf{h}).$$

Régularisation sur la PSF

Régularisation séparable :

$$f_{\text{prior}}(\mathbf{h}) = f_{\text{spatial}}(\mathbf{h}) + f_{\text{spectral}}(\mathbf{h}) + f_{\text{temporel}}(\mathbf{h})$$

Déconvolution Aveugle

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Coronarographie
Microscopie
Confocale
Microscopie
conventionnelle

Conclusion

PSF \mathbf{h} et objet \mathbf{x} inconnus

Estimer \mathbf{h} et \mathbf{x} d'après les données \mathbf{y} :
Déconvolution aveugle.

Critère à minimiser

$$f_{\text{post}}(\mathbf{x}, \mathbf{h}) = f_{\text{data}}(\mathbf{x}, \mathbf{h}; \mathbf{y}) + f_{\text{prior}}(\mathbf{x}) + f_{\text{prior}}(\mathbf{h}).$$

Régularisation sur la PSF

Régularisation séparable :

$$f_{\text{prior}}(\mathbf{h}) = f_{\text{spatial}}(\mathbf{h}) + f_{\text{spectral}}(\mathbf{h}) + f_{\text{temporel}}(\mathbf{h})$$

Déconvolution Aveugle

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Coronarographie
Microscopie
Confocale
Microscopie
conventionnelle

Conclusion

PSF \mathbf{h} et objet \mathbf{x} inconnus

Estimer \mathbf{h} et \mathbf{x} d'après les données \mathbf{y} :
Déconvolution aveugle.

Critère à minimiser

$$f_{\text{post}}(\mathbf{x}, \mathbf{h}) = f_{\text{data}}(\mathbf{x}, \mathbf{h}; \mathbf{y}) + f_{\text{prior}}(\mathbf{x}) + f_{\text{prior}}(\mathbf{h}).$$

Régularisation sur la PSF

Régularisation séparable :

$$f_{\text{prior}}(\mathbf{h}) = f_{\text{spatial}}(\mathbf{h}) + f_{\text{spectral}}(\mathbf{h}) + f_{\text{temporel}}(\mathbf{h})$$

Régularisation de la PSF

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Coronarographie
Microscopie
Confocale
Microscopie
conventionnelle

Conclusion

Régularisation spatiale

- 1 Identique à la régularisation spatiale,
- 2 Si l'on dispose d'une forme *a priori* $p(\theta)$:

$$\Omega_{\text{spatial}}(\mathbf{h}_{\lambda,t}) = (\mathbf{h}_{\lambda,t} - p(\theta))^T \cdot \mathbf{W} \cdot (\mathbf{h}_{\lambda,t} - p(\theta)),$$

où \mathbf{W} est une matrice de poids.

Régularisation temporelle et spectrale

PSF variant continuellement (temporellement ou spectralement) :

$$\text{e.g. } \Omega_{\text{temporel}}(\mathbf{h}) = \|2\mathbf{h}_t - \mathbf{h}_{t-1} - \mathbf{h}_{t+1}\|_2^2.$$

Contraintes strictes sur la PSF

- Contrainte de normalisation,
- Contraintes de positivité.

Régularisation de la PSF

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Coronarographie
Microscopie
Confocale
Microscopie
conventionnelle

Conclusion

Régularisation spatiale

- 1 Identique à la régularisation spatiale,
- 2 Si l'on dispose d'une forme *a priori* $p(\theta)$:

$$\Omega_{\text{spatial}}(\mathbf{h}_{\lambda,t}) = (\mathbf{h}_{\lambda,t} - p(\theta))^T \cdot \mathbf{W} \cdot (\mathbf{h}_{\lambda,t} - p(\theta)),$$

où \mathbf{W} est une matrice de poids.

Régularisation temporelle et spectrale

PSF variant continuellement (temporellement ou spectralement) :

$$\text{e.g. } \Omega_{\text{temporel}}(\mathbf{h}) = \|2\mathbf{h}_t - \mathbf{h}_{t-1} - \mathbf{h}_{t+1}\|_2^2.$$

Contraintes strictes sur la PSF

- Contrainte de normalisation,
- Contraintes de positivité.

Régularisation de la PSF

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Coronarographie
Microscopie
Confocale
Microscopie
conventionnelle

Conclusion

Régularisation spatiale

- 1 Identique à la régularisation spatiale,
- 2 Si l'on dispose d'une forme *a priori* $p(\theta)$:

$$\Omega_{\text{spatial}}(\mathbf{h}_{\lambda,t}) = (\mathbf{h}_{\lambda,t} - \mathbf{p}(\theta))^T \cdot \mathbf{W} \cdot (\mathbf{h}_{\lambda,t} - \mathbf{p}(\theta)),$$

où \mathbf{W} est une matrice de poids.

Régularisation temporelle et spectrale

PSF variant continuellement (temporellement ou spectralement) :

$$\text{e.g. } \Omega_{\text{temporel}}(\mathbf{h}) = \|2\mathbf{h}_t - \mathbf{h}_{t-1} - \mathbf{h}_{t+1}\|_2^2.$$

Contraintes strictes sur la PSF

- Contrainte de normalisation,
- Contraintes de positivité.

Régularisation de la PSF

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Coronarographie

Microscopie
Confocale

Microscopie
conventionnelle

Conclusion

Régularisation spatiale

- 1 Identique à la régularisation spatiale,
- 2 Si l'on dispose d'une forme *a priori* $\mathbf{p}(\theta)$:

$$\Omega_{\text{spatial}}(\mathbf{h}_{\lambda,t}) = (\mathbf{h}_{\lambda,t} - \mathbf{p}(\theta))^T \cdot \mathbf{W} \cdot (\mathbf{h}_{\lambda,t} - \mathbf{p}(\theta)),$$

où \mathbf{W} est une matrice de poids.

Régularisation temporelle et spectrale

PSF variant continuellement (temporellement ou spectralement) :

$$\text{e.g. } \Omega_{\text{temporel}}(\mathbf{h}) = \|\mathbf{2h}_t - \mathbf{h}_{t-1} - \mathbf{h}_{t+1}\|_2^2.$$

Contraintes strictes sur la PSF

- Contrainte de normalisation,
- Contraintes de positivité.

Régularisation de la PSF

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Coronarographie

Microscopie
Confocale

Microscopie
conventionnelle

Conclusion

Régularisation spatiale

- 1 Identique à la régularisation spatiale,
- 2 Si l'on dispose d'une forme *a priori* $p(\theta)$:

$$\Omega_{\text{spatial}}(\mathbf{h}_{\lambda,t}) = (\mathbf{h}_{\lambda,t} - \mathbf{p}(\theta))^T \cdot \mathbf{W} \cdot (\mathbf{h}_{\lambda,t} - \mathbf{p}(\theta)),$$

où \mathbf{W} est une matrice de poids.

Régularisation temporelle et spectrale

PSF variant continuellement (temporellement ou spectralement) :

$$\text{e.g. } \Omega_{\text{temporel}}(\mathbf{h}) = \|2\mathbf{h}_t - \mathbf{h}_{t-1} - \mathbf{h}_{t+1}\|_2^2.$$

Contraintes strictes sur la PSF

- Contrainte de normalisation,
- Contraintes de positivité.

Minimisation alternée

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Coronarographie

Microscopie

Confocale

Microscopie
conventionnelle

Conclusion

Minimisation alternée du critère $f_{\text{post}}(\mathbf{x}, \mathbf{h})$:

- 1 Initialisation de la PSF avec son *a priori* $\mathbf{h}^{(0)} = \mathbf{p}$,
- 2 estimation de l'objet optimal $\mathbf{x}^{(k+1)}$ étant donné la PSF $\mathbf{h}^{(k)}$,
- 3 estimation de la PSF optimale $\mathbf{h}^{(k+1)}$ étant donné $\mathbf{x}^{(k+1)}$,
- 4 répéter les étapes 2 et 3 jusqu'à convergence.

Le solution dépend du point de départ :

- PSF Si l'on dispose d'une PSF *a priori* : $\mathbf{h}^{(0)} = \mathbf{p}$,
- Objet $\mathbf{x}^{(0)}$ doit permettre un bonne estimation de la PSF $\mathbf{h}^{(1)}$.

Minimisation alternée

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Coronarographie

Microscopie

Confocale

Microscopie
conventionnelle

Conclusion

Minimisation alternée du critère $f_{\text{post}}(\mathbf{x}, \mathbf{h})$:

- 1 Initialisation de la PSF avec son *a priori* $\mathbf{h}^{(0)} = \mathbf{p}$,
- 2 estimation de l'objet optimal $\mathbf{x}^{(k+1)}$ étant donné la PSF $\mathbf{h}^{(k)}$,
- 3 estimation de la PSF optimale $\mathbf{h}^{(k+1)}$ étant donné $\mathbf{x}^{(k+1)}$,
- 4 répéter les étapes 2 et 3 jusqu'à convergence.

Le solution dépend du point de départ :

- PSF Si l'on dispose d'une PSF *a priori* : $\mathbf{h}^{(0)} = \mathbf{p}$,
- Objet $\mathbf{x}^{(0)}$ doit permettre un bonne estimation de la PSF $\mathbf{h}^{(1)}$.

Minimisation alternée

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Coronarographie

Microscopie
Confocale
Microscopie
conventionnelle

Conclusion

Minimisation alternée du critère $f_{\text{post}}(\mathbf{x}, \mathbf{h})$:

- 1 Initialisation de la PSF avec son *a priori* $\mathbf{h}^{(0)} = \mathbf{p}$,
- 2 estimation de l'objet optimal $\mathbf{x}^{(k+1)}$ étant donné la PSF $\mathbf{h}^{(k)}$,
- 3 estimation de la PSF optimale $\mathbf{h}^{(k+1)}$ étant donné $\mathbf{x}^{(k+1)}$,
- 4 répéter les étapes 2 et 3 jusqu'à convergence.

Le solution dépend du point de départ :

- PSF Si l'on dispose d'une PSF *a priori* : $\mathbf{h}^{(0)} = \mathbf{p}$,
- Objet $\mathbf{x}^{(0)}$ doit permettre une bonne estimation de la PSF $\mathbf{h}^{(1)}$.

Minimisation alternée

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Coronarographie

Microscopie
Confocale
Microscopie
conventionnelle

Conclusion

Minimisation alternée du critère $f_{\text{post}}(\mathbf{x}, \mathbf{h})$:

- 1 Initialisation de la PSF avec son *a priori* $\mathbf{h}^{(0)} = \mathbf{p}$,
- 2 estimation de l'objet optimal $\mathbf{x}^{(k+1)}$ étant donné la PSF $\mathbf{h}^{(k)}$,
- 3 estimation de la PSF optimale $\mathbf{h}^{(k+1)}$ étant donné $\mathbf{x}^{(k+1)}$,
- 4 répéter les étapes 2 et 3 jusqu'à convergence.

Le solution dépend du point de départ :

- PSF Si l'on dispose d'une PSF *a priori* : $\mathbf{h}^{(0)} = \mathbf{p}$,
- Objet $\mathbf{x}^{(0)}$ doit permettre une bonne estimation de la PSF $\mathbf{h}^{(1)}$.

Minimisation alternée

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Coronarographie

Microscopie

Confocale

Microscopie
conventionnelle

Conclusion

Minimisation alternée du critère $f_{\text{post}}(\mathbf{x}, \mathbf{h})$:

- 1 Initialisation de la PSF avec son *a priori* $\mathbf{h}^{(0)} = \mathbf{p}$,
- 2 estimation de l'objet optimal $\mathbf{x}^{(k+1)}$ étant donné la PSF $\mathbf{h}^{(k)}$,
- 3 estimation de la PSF optimale $\mathbf{h}^{(k+1)}$ étant donné $\mathbf{x}^{(k+1)}$,
- 4 répéter les étapes 2 et 3 jusqu'à convergence.

Le solution dépend du point de départ :

- PSF Si l'on dispose d'une PSF *a priori* : $\mathbf{h}^{(0)} = \mathbf{p}$,
- Objet $\mathbf{x}^{(0)}$ doit permettre une bonne estimation de la PSF $\mathbf{h}^{(1)}$.

Minimisation alternée

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Coronarographie

Microscopie

Confocale

Microscopie
conventionnelle

Conclusion

Minimisation alternée du critère $f_{\text{post}}(\mathbf{x}, \mathbf{h})$:

- 1 Initialisation de la PSF avec son *a priori* $\mathbf{h}^{(0)} = \mathbf{p}$,
- 2 estimation de l'objet optimal $\mathbf{x}^{(k+1)}$ étant donné la PSF $\mathbf{h}^{(k)}$,
- 3 estimation de la PSF optimale $\mathbf{h}^{(k+1)}$ étant donné $\mathbf{x}^{(k+1)}$,
- 4 répéter les étapes 2 et 3 jusqu'à convergence.

Le solution dépend du point de départ :

- **PSF** Si l'on dispose d'une PSF *a priori* : $\mathbf{h}^{(0)} = \mathbf{p}$,
- **Objet** $\mathbf{x}^{(0)}$ doit permettre une bonne estimation de la PSF $\mathbf{h}^{(1)}$.

Minimisation alternée

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Coronarographie

Microscopie

Confocale

Microscopie
conventionnelle

Conclusion

Minimisation alternée du critère $f_{\text{post}}(\mathbf{x}, \mathbf{h})$:

- 1 Initialisation de la PSF avec son *a priori* $\mathbf{h}^{(0)} = \mathbf{p}$,
- 2 estimation de l'objet optimal $\mathbf{x}^{(k+1)}$ étant donné la PSF $\mathbf{h}^{(k)}$,
- 3 estimation de la PSF optimale $\mathbf{h}^{(k+1)}$ étant donné $\mathbf{x}^{(k+1)}$,
- 4 répéter les étapes 2 et 3 jusqu'à convergence.

Le solution dépend du point de départ :

- **PSF** Si l'on dispose d'une PSF *a priori* : $\mathbf{h}^{(0)} = \mathbf{p}$,
- **Objet** $\mathbf{x}^{(0)}$ doit permettre une bonne estimation de la PSF $\mathbf{h}^{(1)}$.

Minimisation alternée

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Coronarographie

Microscopie

Confocale

Microscopie
conventionnelle

Conclusion

Minimisation alternée du critère $f_{\text{post}}(\mathbf{x}, \mathbf{h})$:

- 1 Initialisation de la PSF avec son *a priori* $\mathbf{h}^{(0)} = \mathbf{p}$,
- 2 estimation de l'objet optimal $\mathbf{x}^{(k+1)}$ étant donné la PSF $\mathbf{h}^{(k)}$,
- 3 estimation de la PSF optimale $\mathbf{h}^{(k+1)}$ étant donné $\mathbf{x}^{(k+1)}$,
- 4 répéter les étapes 2 et 3 jusqu'à convergence.

Le solution dépend du point de départ :

- **PSF** Si l'on dispose d'une PSF *a priori* : $\mathbf{h}^{(0)} = \mathbf{p}$,
- **Objet** $\mathbf{x}^{(0)}$ doit permettre une bonne estimation de la PSF $\mathbf{h}^{(1)}$.

Estimation d'un objet initial

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Coronarographie

Microscopie
Confocale

Microscopie
conventionnelle

Conclusion

Exemple sur deux types de flou.



Flou disque.



Flou gaussien.

Estimation d'un objet initial

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Coronarographie
Microscopie
Confocale
Microscopie
conventionnelle

Conclusion

Idée : "Calibrer" la PSF sur les bords francs.

Segmenter les données pour mettre en évidence les bords francs.



Objet initial proposé ($x^{(0)}$).

Estimation d'un objet initial

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Coronarographie


Microscopie

Confocale


Microscopie
conventionnelle

Conclusion

Résultats sur deux types de flou.



Coupe de la PSF (disque).



Coupe de la PSF (gaussienne).

-- Première itération ($h^{(1)}$), --- Convergence ($h^{(fin)}$), — Verité.

Séquence vidéo coronarographique

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle


Coronarographie

Microscopie
Confocale

Microscopie
conventionnelle

Conclusion

Examen radiologique des artère coronaires :



(Observation effectuée par A. Gressard and R. Dauphin à l'hôpital de la Croix-Rousse)

Réglage des hyper-paramètres

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Coronarographie

Microscopie
Confocale
Microscopie
conventionnelle

Conclusion

Quelques constats à propos des données présentées :

La statistique du bruit et la dynamique sont constants :

→ Les hyper-paramètres spatiaux sur la PSF et l'objet sont constants.

La statistique du bruit et la dynamique sont invariants spatialement :

→ Les hyper-paramètres temporels sur la PSF et l'objet sont spatialement invariants.

Le mouvement de l'objet est très rapide :

Pas de contrainte temporelle sur l'objet.

Seuls trois hyper-paramètres doivent être estimés :

Hyper-paramètres spatiaux et temporels pour la PSF,
Hyper-paramètre spatial pour l'objet.

Réglage des hyper-paramètres

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Coronarographie

Microscopie
Confocale
Microscopie
conventionnelle

Conclusion

Quelques constats à propos des données présentées :

La statistique du bruit et la dynamique sont constants :

→ Les hyper-paramètres spatiaux sur la PSF et l'objet sont constants.

La statistique du bruit et la dynamique sont invariants spatialement :

→ Les hyper-paramètres temporels sur la PSF et l'objet sont spatialement invariants.

Le mouvement de l'objet est très rapide :

Pas de contrainte temporelle sur l'objet.

Seuls trois hyper-paramètres doivent être estimés :

Hyper-paramètres spatial et temporel pour la PSF,
Hyper-paramètre spatial pour l'objet.

Réglage des hyper-paramètres

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Coronarographie

Microscopie
Confocale
Microscopie
conventionnelle

Conclusion

Quelques constats à propos des données présentées :

La statistique du bruit et la dynamique sont constants :

→ Les hyper-paramètres spatiaux sur la PSF et l'objet sont constants.

La statistique du bruit et la dynamique sont invariants spatialement :

→ Les hyper-paramètres temporels sur la PSF et l'objet sont spatialement invariants.

Le mouvement de l'objet est très rapide :

Pas de contrainte temporelle sur l'objet.

Seuls trois hyper-paramètres doivent être estimés :

Hyper-paramètres spatial et temporel pour la PSF,
Hyper-paramètre spatial pour l'objet.

Réglage des hyper-paramètres

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Coronarographie

Microscopie
Confocale
Microscopie
conventionnelle

Conclusion

Quelques constats à propos des données présentées :

La statistique du bruit et la dynamique sont constants :

→ Les hyper-paramètres spatiaux sur la PSF et l'objet sont constants.

La statistique du bruit et la dynamique sont invariants spatialement :

→ Les hyper-paramètres temporels sur la PSF et l'objet sont spatialement invariants.

Le mouvement de l'objet est très rapide :

Pas de contrainte temporelle sur l'objet.

Seuls trois hyper-paramètres doivent être estimés :

Hyper-paramètres spatiaux et temporels pour la PSF,
Hyper-paramètre spatial pour l'objet.

Réglage des hyper-paramètres

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Coronarographie

Microscopie
Confocale
Microscopie
conventionnelle

Conclusion

Quelques constats à propos des données présentées :

La statistique du bruit et la dynamique sont constants :

→ Les hyper-paramètres spatiaux sur la PSF et l'objet sont constants.

La statistique du bruit et la dynamique sont invariants spatialement :

→ Les hyper-paramètres temporels sur la PSF et l'objet sont spatialement invariants.

Le mouvement de l'objet est très rapide :

Pas de contrainte temporelle sur l'objet.

Seuls trois hyper-paramètres doivent être estimés :

Hyper-paramètres spatial et temporel pour la PSF,
Hyper-paramètre spatial pour l'objet.

Réglage des hyper-paramètres

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Coronarographie

Microscopie
Confocale
Microscopie
conventionnelle

Conclusion

Quelques constats à propos des données présentées :

La statistique du bruit et la dynamique sont constants :

→ Les hyper-paramètres spatiaux sur la PSF et l'objet sont constants.

La statistique du bruit et la dynamique sont invariants spatialement :

→ Les hyper-paramètres temporels sur la PSF et l'objet sont spatialement invariants.

Le mouvement de l'objet est très rapide :

Pas de contrainte temporelle sur l'objet.

Seuls trois hyper-paramètres doivent être estimés :

Hyper-paramètres spatial et temporel pour la PSF,
Hyper-paramètre spatial pour l'objet.

Réglage des hyper-paramètres

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Déconvolution
Aveugle

Coronarographie

Microscopie
Confocale
Microscopie
conventionnelle

Conclusion

Quelques constats à propos des données présentées :

La statistique du bruit et la dynamique sont constants :

→ Les hyper-paramètres spatiaux sur la PSF et l'objet sont constants.

La statistique du bruit et la dynamique sont invariants spatialement :

→ Les hyper-paramètres temporels sur la PSF et l'objet sont spatialement invariants.


Le mouvement de l'objet est très rapide :

Pas de contrainte temporelle sur l'objet.

Seuls trois hyper-paramètres doivent être estimés :

Hyper-paramètres spatial et temporel pour la PSF,
Hyper-paramètre spatial pour l'objet.


Déconvolution aveugle de séquences coronarographiques.



(Observation effectuée par A. Gressard and R. Dauphin à l'hôpital de la Croix-Rousse)

Microscopie Confocale

Observation de mitochondries d'une cellule cardiaque
Non-Beating HL-1 en microscopie confocale à fluorescence.



(Expérience effectuée par S. Pelloux et Y. Tourneur)

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Coronarographie

Microscopie
Confocale

Microscopie
conventionnelle

Conclusion

Microscopie conventionnelle

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle


Coronarographie

Microscopie
Confocale

**Microscopie
conventionnelle**

Conclusion

Observation d'une cellule ciliée épithéliale au microscope conventionnel.



(Expérience effectuée par B. Chhin et Y. Tourneur)

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Conclusion

Conclusion & Perspectives

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

Résumé

- Succès de l'approche inverse en déconvolution aveugle comme en holographie,
- Extrapolation et/ou interpolation effective de l'objet.

Conclusion : intérêt de l'approche inverse

- Adaptation à de nombreux types d'applications,
- Prise en compte de l'ensemble du système d'observation,
- Utilise la totalité des données disponibles.

Perspectives

- Accélération de la résolution numérique (préconditionnement, parallélisation. . .),
- Automatisation des réglages des hyper-paramètres,
- Prise en compte de modèle plus complexes.

Conclusion & Perspectives

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Déconvolution
Aveugle

Conclusion

Résumé

- Succès de l'approche inverse en déconvolution aveugle comme en holographie,
- Extrapolation et/ou interpolation effective de l'objet.

Conclusion : intérêt de l'approche inverse

- Adaptation à de nombreux types d'applications,
- Prise en compte de l'ensemble du système d'observation,
- Utilise la totalité des données disponibles.

Perspectives

- Accélération de la résolution numérique (préconditionnement, parallélisation...),
- Automatisation des réglages des hyper-paramètres,
- Prise en compte de modèle plus complexes.

Conclusion & Perspectives

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Déconvolution
Aveugle

Conclusion

Résumé

- Succès de l'approche inverse en déconvolution aveugle comme en holographie,
- Extrapolation et/ou interpolation effective de l'objet.

Conclusion : intérêt de l'approche inverse

- Adaptation à de nombreux types d'applications,
- Prise en compte de l'ensemble du système d'observation,
- Utilise la totalité des données disponibles.

Perspectives

- Accélération de la résolution numérique (préconditionnement, parallélisation. . .),
- Automatisation des réglages des hyper-paramètres,
- Prise en compte de modèle plus complexes.

Introduction

Holographie
numérique

Déconvolution

Déconvolution
multidimen-
sionnelle

Deconvolution
Aveugle

Conclusion

MERCI

Merci à Jean-Marie, Eric, Catherine, Loïc, Corinne, Renaud, Françoise, Michel, Isabelle, Clémentine, Xavier, Sébastien, Emmanuel, Yves, Alain, Raphaël, Julien, Jérôme, Rolf, Thierry, Nathalie, Cécile, Hervé, Jacques, Alain, Florent, Viktor, Lionel, Moctar, Christophe, aux membres de ce jury, évidemment à mes parents et beau-parents, aux amis rencontrés en conférence, aux personnes que j'ai inévitablement oubliées mais qui se reconnaîtront, à vous tous d'être venu ...

Et surtout à Raphaëlle et Martin.