

Problèmes inverses


Ferréol Soulez

Centre de Recherche Astronomique de Lyon
Université Claude Bernard Lyon I
École Normale Supérieure de Lyon

Master 2 AIMA / Télécom St Étienne / IOGS 2020

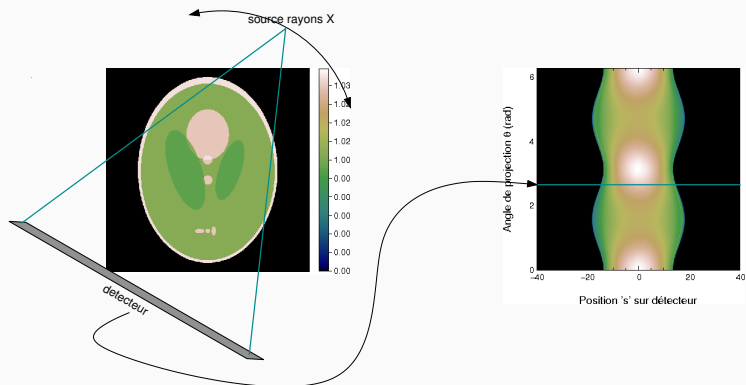
Introduction

Exemple 1 : Convolution



- **observables**: image floue,
- **variables d'intérêt**: image nette,
- **modèle**: convolution par la réponse impulsionnelle (PSF).

Exemple 2 : Tomographie



- **observables:** projections,
- **variables d'intérêt:** image de coupe,
- **modèle:** transformée de Radon.

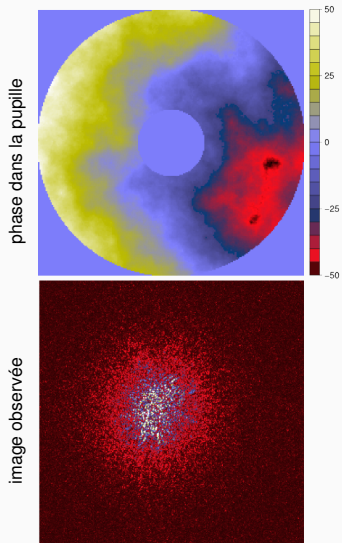
Exemple 3 : Dynamique galactique

- **observables** : distribution des vitesses




- **modèle physique** : dynamique disque galactique mince,
- **variables d'intérêt** : distribution des orbites et cinématique du gaz.

Exemple 4 : Reconstruction de phase






- **observables** : image dans le plan focal,
- **modèle physique** : optique de Fourier,
- **variables d'intérêt** : phase dans le plan pupille

Exemple 5 : Interférométrie optique




- **observables** : Mesures dans l'espace de Fourier (V2 + clotures),
- **modèle physique** : optique de Fourier + corps noir
- **variables d'intérêt** : température et flux du disque
- **résultats** : Herbig Be HD98922 (PIONIER/VLTI, 2012):
 - flux relatif du disque: 0.66 ,
 - température du disque: 1654 K .

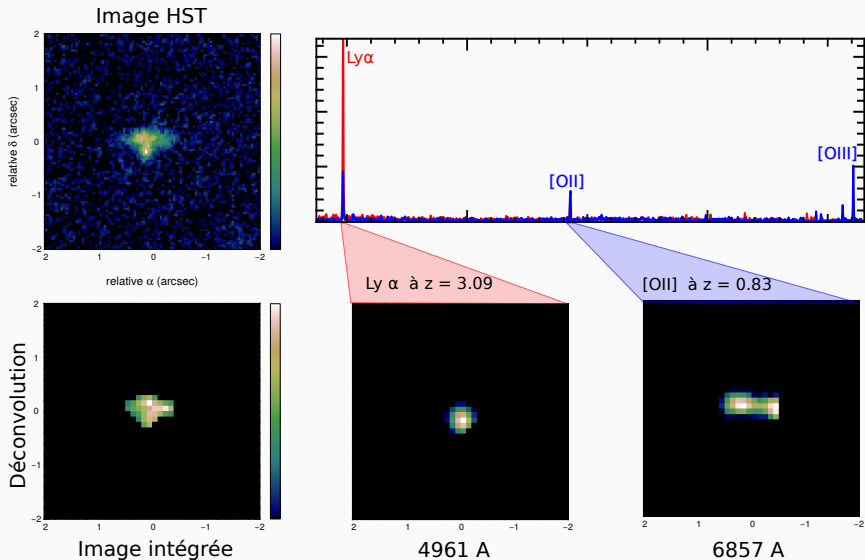
Exemple 6 : Fusion de données



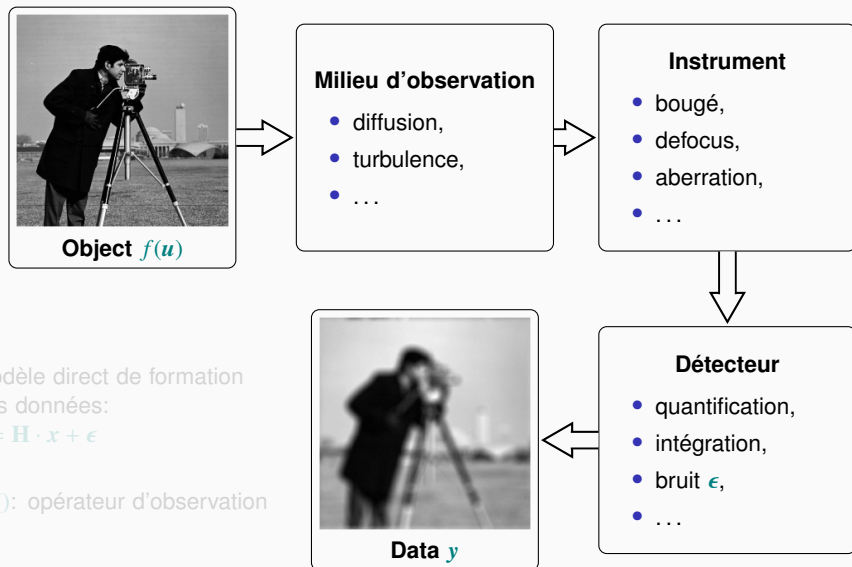
Exemple 6 : Fusion de données



Exemple 6 : Fusion de données



Modèle d'observation

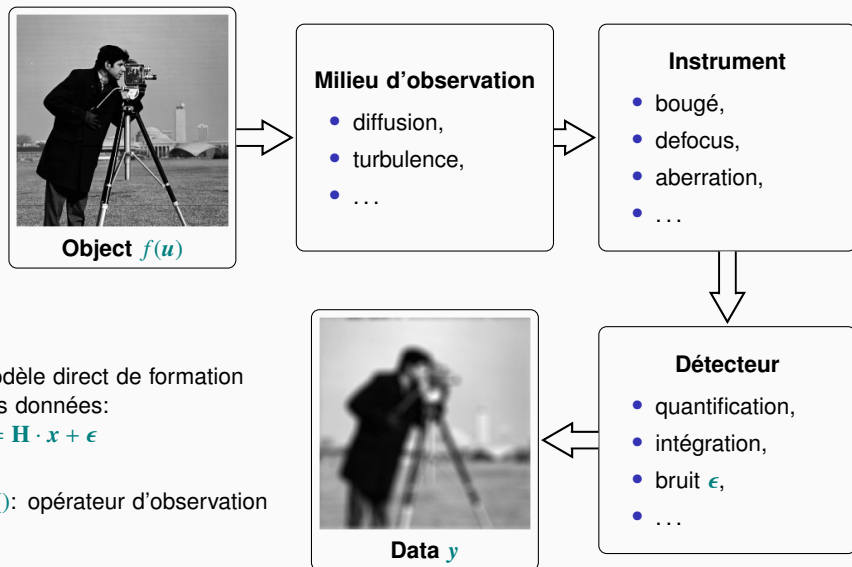


Modèle direct de formation
des données:

$$y = \mathbf{H} \cdot x + \epsilon$$

$\mathcal{H}()$: opérateur d'observation

Modèle d'observation



Modèle direct de formation
des données:

$$y = \mathbf{H} \cdot x + \epsilon$$

$\mathcal{H}()$: opérateur d'observation

Qu'est-ce qu'un problème inverse ?

- Des observables disponibles et modélisables :

$$\boxed{\mathbf{y} = \mathcal{H}(\mathbf{x}) + \mathbf{e}} \quad \Leftarrow \quad \text{le } \mathbf{mod\grave{e}le\ direct}$$

- les données $\mathbf{y} \in \mathbb{R}^M$;
 - le modèle $\mathcal{H}: \mathbb{R}^N \mapsto \mathbb{R}^M$;
 - les variables d'intérêt $\mathbf{x} \in \mathbb{R}^N$;
 - les erreurs $\mathbf{e} \in \mathbb{R}^M$.
- **Objectif** : Retrouver les meilleurs paramètres \mathbf{x} compte tenu des données \mathbf{y} et du modèle \mathcal{H} .
 - **Étapes** :
 - Construire et analyser le modèle.
 - Établir un critère pour discriminer les meilleurs paramètres.
 - Élaborer une stratégie pour trouver la solution.

Qu'est-ce qu'un problème inverse ?

- Des observables disponibles et modélisables :

$$\boxed{\mathbf{y} = \mathcal{H}(\mathbf{x}) + \mathbf{e}} \quad \Leftarrow \quad \text{le } \mathbf{mod\grave{e}le\ direct}$$

- les données $\mathbf{y} \in \mathbb{R}^M$;
 - le modèle $\mathcal{H}: \mathbb{R}^N \mapsto \mathbb{R}^M$;
 - les variables d'intérêt $\mathbf{x} \in \mathbb{R}^N$;
 - les erreurs $\mathbf{e} \in \mathbb{R}^M$.
- **Objectif** : Retrouver les meilleurs paramètres \mathbf{x} compte tenu des données \mathbf{y} et du modèle \mathcal{H} .
 - **Étapes** :
 - Construire et analyser le modèle.
 - Établir un critère pour discriminer les meilleurs paramètres.
 - Élaborer une stratégie pour trouver la solution.

Qu'est-ce qu'un problème inverse ?

- Des observables disponibles et modélisables :

$$\boxed{y = \mathcal{H}(x) + e} \quad \Leftarrow \quad \text{le } \textit{modèle direct}$$

- les données $y \in \mathbb{R}^M$;
 - le modèle $\mathcal{H}: \mathbb{R}^N \mapsto \mathbb{R}^M$;
 - les variables d'intérêt $x \in \mathbb{R}^N$;
 - les erreurs $e \in \mathbb{R}^M$.
- **Objectif** : Retrouver les meilleurs paramètres x compte tenu des données y et du modèle \mathcal{H} .
 - **Étapes** :
 - Contruire et analyser le modèle.
 - Établir un critère pour discriminer les meilleurs paramètres.
 - Élaborer une stratégie pour trouver la solution.

1. modèle linéaire :

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

- intégrale de Fredholm du 1^{er} ordre (transformée de Radon, de Fourier, convolution, ...)
- base de fonctions ;

2. modèle non-linéaire :

$$y = \mathcal{H}(x) + e$$

- tout ou partie du noyau $h(r, s)$ à retrouver : déconvolution aveugle, synthèse spectrale, ...
 - mesures de corrélation (à 2 ou 3 points)
 - restauration de phase : cristallographie, clôtures de phases (interférométrie), ...
- ⇒ unicité ?

1. modèle linéaire :

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

- intégrale de Fredholm du 1^{er} ordre (transformée de Radon, de Fourier, convolution, ...)
- base de fonctions ;

2. modèle non-linéaire :

$$y = \mathcal{H}(x) + e$$

- tout ou partie du noyau $h(r, s)$ à retrouver : déconvolution aveugle, synthèse spectrale, ...
 - mesures de corrélation (à 2 ou 3 points)
 - restauration de phase : cristallographie, clôtures de phases (interférométrie), ...
- ⇒ unicité ?

Le modèle direct linéaire

Discrétisation de l'objet

$f(\mathbf{u})$ décrit par un nombre fini de paramètres \mathbf{x} en utilisant la base $b_n(\mathbf{u})$:

$$f(\mathbf{u}) \approx \sum_n x_n b_n(\mathbf{u}).$$

Erreur de discrétisation : $\|f - \sum_n x_n b_n\|_2^2 > 0$.

Échantillonnage par le détecteur

Distribution d'intensité $g(s)$ échantillonnée par le détecteur:

$$y_m = \int g(s) c_m(s) ds + e_m,$$

- $c_m(s)$: fonction d'intégration sur le pixel n
- e_m : bruit additif de variance σ_m .

Discrétisation de l'objet

$f(\mathbf{u})$ décrit par un nombre fini de paramètres \mathbf{x} en utilisant la base $b_n(\mathbf{u})$:

$$f(\mathbf{u}) \approx \sum_n x_n b_n(\mathbf{u}).$$

Erreur de discrétisation : $\|f - \sum_n x_n b_n\|_2^2 > 0$.

Échantillonnage par le détecteur

Distribution d'intensité $g(\mathbf{s})$ échantillonnée par le détecteur:

$$y_m = \int g(\mathbf{s}) c_m(\mathbf{s}) d\mathbf{s} + e_m,$$

- $c_m(\mathbf{s})$: fonction d'intégration sur le pixel n
- e_m : bruit additif de variance σ_m .

Distribution d'intensité $g(\mathbf{s})$ échantillonnée par le détecteur:

$$\begin{aligned}y_m &= \int \left(\int \mathcal{H}(\mathbf{s}, \mathbf{u}) \sum_n x_n b_n(\mathbf{u}) d\mathbf{u} \right) c_m(\mathbf{s}) d\mathbf{s} + e_m \\ &= \sum_n x_n \iint \mathcal{H}(\mathbf{s}, \mathbf{u}) b_n(\mathbf{u}) c_m(\mathbf{s}) d\mathbf{s} d\mathbf{u} + e_m \\ \mathbf{y} &= \mathbf{H} \cdot \mathbf{x} + \mathbf{e},\end{aligned}$$

avec l'opérateur (matrice):

$$H_{m,n} = \iint \mathcal{H}(\mathbf{s}, \mathbf{u}) b_n(\mathbf{u}) c_m(\mathbf{s}) d\mathbf{s} d\mathbf{u},$$

et le terme d'erreur \mathbf{e} incluant les erreurs de discrétisation.

Pour une intégrale de Fredholm $g(s) = \int \mathcal{H}(s, \mathbf{u}) f(\mathbf{u}) d\mathbf{u}$, l'estimation de $f(\mathbf{u})$ étant données $g(s)$ et $\mathcal{H}(s, \mathbf{u})$ est un **problème mal posé**.

Conditions d'hadamard

Un problème est *bien posé* si et seulement si sa solution z :

- existe $z \in \text{Im}(\mathcal{H})$,
- est unique $\text{Ker}(\mathcal{H}) = \{0\}$,
- est stable $\|*\| z - z' \rightarrow 0 \Rightarrow \|\mathcal{H}(z) - \mathcal{H}(z')\| \rightarrow 0$.

Pour une intégrale de Fredholm $g(s) = \int \mathcal{H}(s, \mathbf{u}) f(\mathbf{u}) d\mathbf{u}$, l'estimation de $f(\mathbf{u})$ étant données $g(s)$ et $\mathcal{H}(s, \mathbf{u})$ est un **problème mal posé**.

Conditions d'hadamard

Un problème est *bien posé* si et seulement si sa solution \mathbf{z} :

- existe $\mathbf{z} \in \text{Im}(\mathcal{H})$,
- est unique $\text{Ker}(\mathcal{H}) = \{0\}$,
- est stable $\|\cdot\| \mathbf{z} - \mathbf{z}' \rightarrow 0 \Rightarrow \|\mathcal{H}(\mathbf{z}) - \mathcal{H}(\mathbf{z}')\| \rightarrow 0$.

Pseudo inverse:

Pour un problème discret $\mathbf{y} = \mathbf{H} \cdot \mathbf{x}$, le problème inverse possède toujours une inverse généralisée:

Moore-Penrose pseudo inverse

$$\mathbf{H}^\dagger = (\mathbf{H}^T \cdot \mathbf{H})^{-1} \cdot \mathbf{H}^T$$

$$\mathbf{H}^\dagger = \mathbf{H}^T \cdot (\mathbf{H} \cdot \mathbf{H}^T)^{-1}$$

si des valeurs propres λ_i de $\mathbf{H}^T \cdot \mathbf{H}$ sont nulles on admet $\lambda_i^{-1} = 0$ (moindre norme).
La solution vérifie:

$$\mathbf{z} = \mathbf{H}^\dagger \cdot \mathbf{y} \Rightarrow \begin{cases} \|\mathbf{z}\|_2^2 \leq \|\mathbf{x}\|_2^2, \forall \mathbf{x} \\ \|\mathbf{H} \cdot \mathbf{z} - \mathbf{y}\|_2^2 \leq \|\mathbf{H} \cdot \mathbf{x} - \mathbf{y}\|_2^2, \forall \mathbf{x} \end{cases}$$

Problème mal conditionné

Valeurs singulières σ de \mathbf{H} :

$$\begin{aligned}\mathbf{H} \mathbf{u}_n &= \sigma_n \mathbf{v}_n \\ \mathbf{H}^* \mathbf{v}_n &= \sigma_n \mathbf{u}_n,\end{aligned}$$

Pour une petite perturbation additive $\delta \mathbf{y} = \varepsilon \mathbf{v}_n$ des données, la perturbation correspondante sur les paramètres $\delta \mathbf{x}$ est donnée par:

$$\begin{aligned}\mathbf{H} \cdot \delta \mathbf{x} &= \delta \mathbf{y} \\ &= \varepsilon \mathbf{v}_n, \\ &= \varepsilon \sigma_n^{-1} \sigma_n \mathbf{v}_n, \\ &= \varepsilon \sigma_n^{-1} \mathbf{H} \cdot \mathbf{u}_n, \\ \delta \mathbf{x} &= \varepsilon \sigma_n^{-1} \mathbf{u}_n.\end{aligned}$$

La perturbation est amplifiée par $\frac{\|\delta \mathbf{x}\|}{\|\delta \mathbf{y}\|} = \sigma_n^{-1} \Rightarrow$ **le système est instable**

La stabilité est quantifiée par le conditionnement $C(\mathbf{H}) = \frac{|\sigma_{\max}|}{|\sigma_{\min}|}$

Valeurs singulières σ de \mathbf{H} :

$$\begin{aligned}\mathbf{H} \mathbf{u}_n &= \sigma_n \mathbf{v}_n \\ \mathbf{H}^* \mathbf{v}_n &= \sigma_n \mathbf{u}_n,\end{aligned}$$

Pour une petite perturbation additive $\delta \mathbf{y} = \varepsilon \mathbf{v}_n$ des données, la perturbation correspondante sur les paramètres $\delta \mathbf{x}$ est donnée par:

$$\begin{aligned}\mathbf{H} \cdot \delta \mathbf{x} &= \delta \mathbf{y} \\ &= \varepsilon \mathbf{v}_n, \\ &= \varepsilon \sigma_n^{-1} \sigma_n \mathbf{v}_n, \\ &= \varepsilon \sigma_n^{-1} \mathbf{H} \cdot \mathbf{u}_n, \\ \delta \mathbf{x} &= \varepsilon \sigma_n^{-1} \mathbf{u}_n.\end{aligned}$$

La perturbation est amplifiée par $\frac{\|\delta \mathbf{x}\|}{\|\delta \mathbf{y}\|} = \sigma_n^{-1} \Rightarrow$ **le système est instable**

La stabilité est quantifiée par le conditionnement $C(\mathbf{H}) = \frac{|\sigma_{\max}|}{|\sigma_{\min}|}$

Problème mal conditionné

Valeurs singulières σ de \mathbf{H} :

$$\begin{aligned}\mathbf{H} \mathbf{u}_n &= \sigma_n \mathbf{v}_n \\ \mathbf{H}^* \mathbf{v}_n &= \sigma_n \mathbf{u}_n,\end{aligned}$$

Pour une petite perturbation additive $\delta \mathbf{y} = \varepsilon \mathbf{v}_n$ des données, la perturbation correspondante sur les paramètres $\delta \mathbf{x}$ est donnée par:

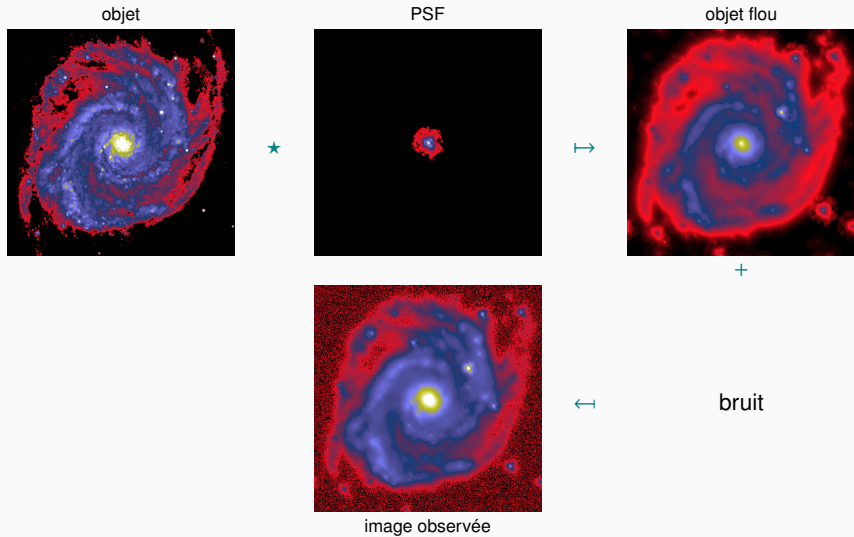
$$\begin{aligned}\mathbf{H} \cdot \delta \mathbf{x} &= \delta \mathbf{y} \\ &= \varepsilon \mathbf{v}_n, \\ &= \varepsilon \sigma_n^{-1} \sigma_n \mathbf{v}_n, \\ &= \varepsilon \sigma_n^{-1} \mathbf{H} \cdot \mathbf{u}_n, \\ \delta \mathbf{x} &= \varepsilon \sigma_n^{-1} \mathbf{u}_n.\end{aligned}$$

La perturbation est amplifiée par $\frac{\|\delta \mathbf{x}\|}{\|\delta \mathbf{y}\|} = \sigma_n^{-1} \Rightarrow$ **le système est instable**

La stabilité est quantifiée par le conditionnement $C(\mathbf{H}) = \frac{|\sigma_{\max}|}{|\sigma_{\min}|}$

Naive deconvolution

Simulation de M51



Convolution

On suppose la PSF invariante par translation (isoplanétisme).

$$\mathbf{h} = \begin{bmatrix} h_0 \\ h_1 \\ h_2 \\ \vdots \\ h_{-2} \\ h_{-1} \end{bmatrix}$$

PSF

$$\mathbf{H} = \begin{bmatrix} h_0 & h_{-1} & h_{-2} & \dots & h_{-N} \\ h_1 & h_0 & h_{-1} & \ddots & h_{-N+1} \\ h_2 & h_1 & h_0 & \ddots & h_{-N+2} \\ \vdots & \ddots & \ddots & \ddots & \vdots \\ h_{N-2} & h_{N-3} & h_{N-2} & \ddots & h_{-1} \\ h_{N-1} & h_{N-2} & h_{N-3} & \dots & h_0 \end{bmatrix}$$

matrice de convolution
Card(\mathbf{h}) = $2N$

$$\mathbf{H}_{\text{circ}} = \begin{bmatrix} h_0 & h_{-1} & h_{-2} & \dots & h_1 \\ h_1 & h_0 & h_{-1} & \ddots & h_2 \\ h_2 & h_1 & h_0 & \ddots & h_3 \\ \vdots & \ddots & \ddots & \ddots & \vdots \\ h_{-2} & h_{-3} & h_{-4} & \ddots & h_{-1} \\ h_{-1} & h_{-2} & h_{-3} & \dots & h_0 \end{bmatrix}$$

approximation circulante
Card(\mathbf{h}) = N

approximation circulante

\mathbf{H}_{circ} est diagonalisable dans l'espace de Fourier $\mathbf{H} = \mathbf{F}^{-1} \text{diag}(\widehat{\mathbf{h}}) \mathbf{F}$ avec $\widehat{\mathbf{h}} = \mathbf{F} \mathbf{h}$.

Inversion directe

Si le bruit est négligeable, l'inversion directe est une division dans l'espace de Fourier:

$$\widehat{x}_k^{(\text{direct})} = \frac{\widehat{y}_k}{\widehat{h}_k} = \widehat{x}_k + \frac{\widehat{n}_k}{\widehat{h}_k}$$

On a donc:

$$\mathbf{x}^{(\text{direct})} = \text{FFT}^{-1} \left(\begin{array}{c} \text{FFT} \left(\begin{array}{c} \text{Image of a galaxy} \\ \text{Image of noise} \end{array} \right) \end{array} \right) = \text{Image of noisy galaxy}$$

Inversion directe


Si le bruit est négligeable, l'inversion directe est une division dans l'espace de Fourier:

$$\widehat{x}_k^{(\text{direct})} = \frac{\widehat{y}_k}{\widehat{h}_k} = \widehat{x}_k + \frac{\widehat{n}_k}{\widehat{h}_k}$$

On a donc:



$$\mathbf{x}^{(\text{direct})} = \text{FFT}^{-1} \left(\begin{array}{c} \text{FFT} \left(\begin{array}{c} \text{Image of a galaxy} \\ \text{Image of noise} \end{array} \right) \end{array} \right) = \text{Image of noisy galaxy}$$

Explication




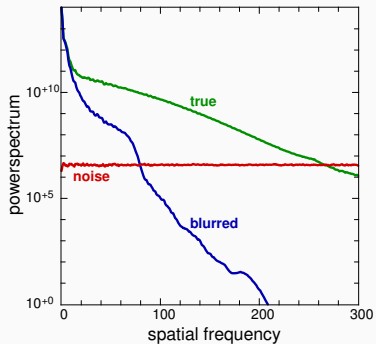
→ inversion directe: *amplification du bruit*

Explication



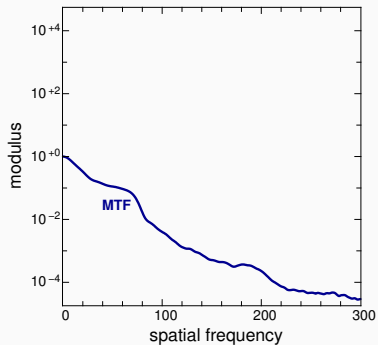

→ inversion directe: *amplification du bruit*

Explication




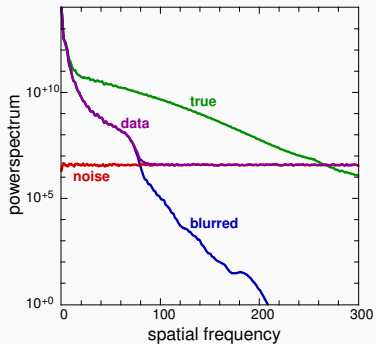
→ inversion directe: *amplification du bruit*

Explication



→ inversion directe: *amplification du bruit*

Explication




→ inversion directe: *amplification du bruit*

Troncature en fréquences


On peut essayer d'éviter l'amplification du bruit en introduisant une fréquence de coupure

u_{cut} :

$$\widehat{x}_k^{(\text{cut})} = \begin{cases} \widehat{y}_k / \widehat{h}_k & \text{si } |u_k| < u_{\text{cut}} \\ 0 & \text{sinon} \end{cases}$$



\mapsto
(with $u_{\text{cut}} = 80$ frequels)



Filtre de Wiener

Le filtre de Wiener est dérivé des hypothèses suivantes:

- l'estimation \mathbf{x}_{MMSE} de l'objet vrai \mathbf{x} est donné par une transformation linéaire des données \mathbf{y} :

$$\mathbf{x}_{\text{MMSE}} \equiv \tilde{\mathbf{G}} \cdot \mathbf{y}$$

Rationale: Cela peut être vu comme l'approximation au premier ordre du mapping $\mathbf{y} \mapsto \mathbf{x}_{\text{MMSE}}$.

- les paramètres de cette transformation sont tel que l'erreur quadratique moyenne (MSE) par rapport à l'objet vrai \mathbf{x} est minimale:

$$\tilde{\mathbf{G}} = \arg \min_{\mathbf{G}} E \left\{ \frac{1}{2} \left\| \underbrace{\mathbf{G} \cdot \mathbf{y}}_{\text{estimator}} - \mathbf{x} \right\|^2 \right\}$$

→ *linear minimum mean squared error (LMMSE) estimator!*

seems magic!

Le filtre de Wiener est dérivé des hypothèses suivantes:

- l'estimation \mathbf{x}_{MMSE} de l'objet vrai \mathbf{x} est donné par une transformation linéaire des données \mathbf{y} :

$$\mathbf{x}_{\text{MMSE}} \equiv \tilde{\mathbf{G}} \cdot \mathbf{y}$$

Rationale: Cela peut être vu comme l'approximation au premier ordre du mapping $\mathbf{y} \mapsto \mathbf{x}_{\text{MMSE}}$.

- les paramètres de cette transformation sont tel que l'erreur quadratique moyenne (MSE) par rapport à l'objet vrai \mathbf{x} est minimale:

$$\tilde{\mathbf{G}} = \arg \min_{\mathbf{G}} E \left\{ \frac{1}{2} \left\| \underbrace{\mathbf{G} \cdot \mathbf{y}}_{\text{estimator}} - \mathbf{x} \right\|^2 \right\}$$

→ **linear minimum mean squared error (LMMSE) estimator!**

seems magic!

Le filtre de Wiener est dérivé des hypothèses suivantes:

- l'estimation \mathbf{x}_{MMSE} de l'objet vrai \mathbf{x} est donné par une transformation linéaire des données \mathbf{y} :

$$\mathbf{x}_{\text{MMSE}} \equiv \tilde{\mathbf{G}} \cdot \mathbf{y}$$

Rationale: Cela peut être vu comme l'approximation au premier ordre du mapping $\mathbf{y} \mapsto \mathbf{x}_{\text{MMSE}}$.

- les paramètres de cette transformation sont tel que l'erreur quadratique moyenne (MSE) par rapport à l'objet vrai \mathbf{x} est minimale:

$$\tilde{\mathbf{G}} = \arg \min_{\mathbf{G}} E \left\{ \frac{1}{2} \left\| \underbrace{\mathbf{G} \cdot \mathbf{y}}_{\text{estimator}} - \mathbf{x} \right\|^2 \right\}$$

→ **linear minimum mean squared error (LMMSE) estimator!**

seems magic!

$$\tilde{\mathbf{G}} = \arg \min_{\mathbf{G}} \mathbb{E} \left\{ \frac{1}{2} \|\mathbf{G} \cdot \mathbf{y} - \mathbf{x}\|^2 \right\} \Leftrightarrow \left. \frac{\partial \mathbb{E} \left\{ \frac{1}{2} \|\mathbf{G} \cdot \mathbf{y} - \mathbf{x}\|^2 \right\}}{\partial \mathbf{G}} \right|_{\mathbf{G}=\tilde{\mathbf{G}}} = 0$$

$$\begin{aligned} \frac{\partial \mathbb{E} \left\{ \frac{1}{2} \|\mathbf{G} \cdot \mathbf{y} - \mathbf{x}\|^2 \right\}}{\partial \mathbf{G}} &= \frac{1}{2} \mathbb{E} \left\{ \frac{\partial \|\mathbf{G} \cdot \mathbf{y} - \mathbf{x}\|^2}{\partial \mathbf{G}} \right\} \\ &= \frac{1}{2} \mathbb{E} \left\{ 2 (\mathbf{G} \cdot \mathbf{y} - \mathbf{x}) \cdot \mathbf{y}^T \right\} \\ &= \mathbb{E} \left\{ \mathbf{G} \cdot \mathbf{y} \cdot \mathbf{y}^T \right\} - \mathbb{E} \left\{ \mathbf{x} \cdot \mathbf{y}^T \right\} \\ &= \mathbf{G} \cdot \mathbb{E} \left\{ \mathbf{y} \cdot \mathbf{y}^T \right\} - \mathbb{E} \left\{ \mathbf{x} \cdot \mathbf{y}^T \right\} \end{aligned}$$

$$\tilde{\mathbf{G}} = \mathbb{E} \left\{ \mathbf{x} \cdot \mathbf{y}^T \right\} \cdot \mathbb{E} \left\{ \mathbf{y} \cdot \mathbf{y}^T \right\}^{-1}$$

$$\tilde{\mathbf{G}} = \arg \min_{\mathbf{G}} \mathbb{E} \left\{ \frac{1}{2} \|\mathbf{G} \cdot \mathbf{y} - \mathbf{x}\|^2 \right\} \Leftrightarrow \left. \frac{\partial \mathbb{E} \left\{ \frac{1}{2} \|\mathbf{G} \cdot \mathbf{y} - \mathbf{x}\|^2 \right\}}{\partial \mathbf{G}} \right|_{\mathbf{G}=\tilde{\mathbf{G}}} = 0$$

$$\begin{aligned} \frac{\partial \mathbb{E} \left\{ \frac{1}{2} \|\mathbf{G} \cdot \mathbf{y} - \mathbf{x}\|^2 \right\}}{\partial \mathbf{G}} &= \frac{1}{2} \mathbb{E} \left\{ \frac{\partial \|\mathbf{G} \cdot \mathbf{y} - \mathbf{x}\|^2}{\partial \mathbf{G}} \right\} \\ &= \frac{1}{2} \mathbb{E} \left\{ 2 (\mathbf{G} \cdot \mathbf{y} - \mathbf{x}) \cdot \mathbf{y}^T \right\} \\ &= \mathbb{E} \left\{ \mathbf{G} \cdot \mathbf{y} \cdot \mathbf{y}^T \right\} - \mathbb{E} \left\{ \mathbf{x} \cdot \mathbf{y}^T \right\} \\ &= \mathbf{G} \cdot \mathbb{E} \left\{ \mathbf{y} \cdot \mathbf{y}^T \right\} - \mathbb{E} \left\{ \mathbf{x} \cdot \mathbf{y}^T \right\} \end{aligned}$$

$$\tilde{\mathbf{G}} = \mathbb{E} \left\{ \mathbf{x} \cdot \mathbf{y}^T \right\} \cdot \mathbb{E} \left\{ \mathbf{y} \cdot \mathbf{y}^T \right\}^{-1}$$

$$\tilde{\mathbf{G}} = \arg \min_{\mathbf{G}} \mathbb{E} \left\{ \frac{1}{2} \|\mathbf{G} \cdot \mathbf{y} - \mathbf{x}\|^2 \right\} \Leftrightarrow \left. \frac{\partial \mathbb{E} \left\{ \frac{1}{2} \|\mathbf{G} \cdot \mathbf{y} - \mathbf{x}\|^2 \right\}}{\partial \mathbf{G}} \right|_{\mathbf{G}=\tilde{\mathbf{G}}} = 0$$

$$\begin{aligned} \frac{\partial \mathbb{E} \left\{ \frac{1}{2} \|\mathbf{G} \cdot \mathbf{y} - \mathbf{x}\|^2 \right\}}{\partial \mathbf{G}} &= \frac{1}{2} \mathbb{E} \left\{ \frac{\partial \|\mathbf{G} \cdot \mathbf{y} - \mathbf{x}\|^2}{\partial \mathbf{G}} \right\} \\ &= \frac{1}{2} \mathbb{E} \left\{ 2 (\mathbf{G} \cdot \mathbf{y} - \mathbf{x}) \cdot \mathbf{y}^T \right\} \\ &= \mathbb{E} \left\{ \mathbf{G} \cdot \mathbf{y} \cdot \mathbf{y}^T \right\} - \mathbb{E} \left\{ \mathbf{x} \cdot \mathbf{y}^T \right\} \\ &= \mathbf{G} \cdot \mathbb{E} \left\{ \mathbf{y} \cdot \mathbf{y}^T \right\} - \mathbb{E} \left\{ \mathbf{x} \cdot \mathbf{y}^T \right\} \end{aligned}$$

$$\tilde{\mathbf{G}} = \mathbb{E} \left\{ \mathbf{x} \cdot \mathbf{y}^T \right\} \cdot \mathbb{E} \left\{ \mathbf{y} \cdot \mathbf{y}^T \right\}^{-1}$$

Hypothèses

- Bruit centré: $E\{e\} = 0$,
- Objet centré: $E\{x\} = 0$,
- Le bruit et l'objet sont mutuellement indépendants: $Cov(x, e) = 0$

- $E\{y\} = E\{H \cdot y + e\} = H \cdot E\{y\} + E\{e\} = 0$

- $E\{x \cdot y^T\} = \underbrace{Cov(x, y)}_{C_{xy}}$

- $E\{y \cdot y^T\} = \underbrace{Cov(y)}_{C_y}$

-

$$\tilde{G} = C_{xy} \cdot C_y^{-1}$$

Hypothèses

- Bruit centré: $E\{e\} = 0$,
- Objet centré: $E\{x\} = 0$,
- Le bruit et l'objet sont mutuellement indépendants: $Cov(x, e) = 0$

- $E\{y\} = E\{H \cdot y + e\} = H \cdot E\{y\} + E\{e\} = 0$

- $E\{x \cdot y^T\} = \underbrace{Cov(x, y)}_{C_{x,y}}$

- $E\{y \cdot y^T\} = \underbrace{Cov(y)}_{C_y}$

-

$$\tilde{G} = C_{x,y} \cdot C_y^{-1}$$

Filtre de Wiener: dérivation

$$\begin{aligned}E\{y \cdot y^T\} &= E\{(\mathbf{H} \cdot \mathbf{x} + e) \cdot (\mathbf{H} \cdot \mathbf{x} + e)^T\} \\&= E\{\mathbf{H} \cdot \mathbf{x} \cdot \mathbf{x}^T \cdot \mathbf{H}^T\} + E\{e \cdot e^T\} \\&\quad + E\{\mathbf{H} \cdot \mathbf{x} \cdot e^T\} + E\{e \cdot \mathbf{x}^T \cdot \mathbf{H}^T\} \\&= \mathbf{H} \cdot E\{\mathbf{x} \cdot \mathbf{x}^T\} \cdot \mathbf{H}^T + E\{e \cdot e^T\} \\&= \mathbf{H} \cdot \mathbf{C}_x \cdot \mathbf{H}^T + \mathbf{C}_e\end{aligned}$$

$$\begin{aligned}E\{\mathbf{x} \cdot y^T\} &= E\{\mathbf{x} \cdot (\mathbf{H}\mathbf{x} + e)^T\} \\&= E\{\mathbf{x} \cdot \mathbf{x}^T \cdot \mathbf{H}^T\} + E\{\mathbf{x} \cdot e^T\} \\&= E\{\mathbf{x} \cdot \mathbf{x}^T\} \cdot \mathbf{H}^T + E\{\mathbf{x}\} \cdot E\{e^T\} \\&= \mathbf{C}_x \cdot \mathbf{H}^T\end{aligned}$$

Filtre de Wiener (LMMSE)

$$\begin{aligned}\tilde{\mathbf{G}} &= \mathbf{C}_{x,y} \cdot \mathbf{C}_y^{-1} \\&= \mathbf{C}_x \cdot \mathbf{H}^T \cdot (\mathbf{H} \cdot \mathbf{C}_x \cdot \mathbf{H}^T + \mathbf{C}_e)^{-1} \\&= (\mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H} + \mathbf{C}_x^{-1})^{-1} \cdot \mathbf{H}^T \cdot \mathbf{C}_e^{-1}\end{aligned}$$

Pas besoin de connaître \mathbf{x} et e uniquement leurs deux premiers moments statistiques: $E\{\mathbf{x}\}$, \mathbf{C}_x , $E\{e\}$ and \mathbf{C}_e .

Filtre de Wiener: dérivation

$$\begin{aligned}E\{y \cdot y^T\} &= E\{(\mathbf{H} \cdot \mathbf{x} + e) \cdot (\mathbf{H} \cdot \mathbf{x} + e)^T\} \\&= E\{\mathbf{H} \cdot \mathbf{x} \cdot \mathbf{x}^T \cdot \mathbf{H}^T\} + E\{e \cdot e^T\} \\&\quad + E\{\mathbf{H} \cdot \mathbf{x} \cdot e^T\} + E\{e \cdot \mathbf{x}^T \cdot \mathbf{H}^T\} \\&= \mathbf{H} \cdot E\{\mathbf{x} \cdot \mathbf{x}^T\} \cdot \mathbf{H}^T + E\{e \cdot e^T\} \\&= \mathbf{H} \cdot \mathbf{C}_x \cdot \mathbf{H}^T + \mathbf{C}_e\end{aligned}$$

$$\begin{aligned}E\{\mathbf{x} \cdot y^T\} &= E\{\mathbf{x} \cdot (\mathbf{H}\mathbf{x} + e)^T\} \\&= E\{\mathbf{x} \cdot \mathbf{x}^T \cdot \mathbf{H}^T\} + E\{\mathbf{x} \cdot e^T\} \\&= E\{\mathbf{x} \cdot \mathbf{x}^T\} \cdot \mathbf{H}^T + E\{\mathbf{x}\} \cdot E\{e^T\} \\&= \mathbf{C}_x \cdot \mathbf{H}^T\end{aligned}$$

Filtre de Wiener (LMMSE)

$$\begin{aligned}\tilde{\mathbf{G}} &= \mathbf{C}_{x,y} \cdot \mathbf{C}_y^{-1} \\&= \mathbf{C}_x \cdot \mathbf{H}^T \cdot (\mathbf{H} \cdot \mathbf{C}_x \cdot \mathbf{H}^T + \mathbf{C}_e)^{-1} \\&= (\mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H} + \mathbf{C}_x^{-1})^{-1} \cdot \mathbf{H}^T \cdot \mathbf{C}_e^{-1}\end{aligned}$$

Pas besoin de connaître \mathbf{x} et e uniquement leurs deux premiers moments statistiques: $E\{\mathbf{x}\}$, \mathbf{C}_x , $E\{e\}$ and \mathbf{C}_e .

Filtre de Wiener: dérivation

$$\begin{aligned}E\{y \cdot y^T\} &= E\{(\mathbf{H} \cdot \mathbf{x} + e) \cdot (\mathbf{H} \cdot \mathbf{x} + e)^T\} \\&= E\{\mathbf{H} \cdot \mathbf{x} \cdot \mathbf{x}^T \cdot \mathbf{H}^T\} + E\{e \cdot e^T\} \\&\quad + E\{\mathbf{H} \cdot \mathbf{x} \cdot e^T\} + E\{e \cdot \mathbf{x}^T \cdot \mathbf{H}^T\} \\&= \mathbf{H} \cdot E\{\mathbf{x} \cdot \mathbf{x}^T\} \cdot \mathbf{H}^T + E\{e \cdot e^T\} \\&= \mathbf{H} \cdot \mathbf{C}_x \cdot \mathbf{H}^T + \mathbf{C}_e\end{aligned}$$

$$\begin{aligned}E\{\mathbf{x} \cdot y^T\} &= E\{\mathbf{x} \cdot (\mathbf{H}\mathbf{x} + e)^T\} \\&= E\{\mathbf{x} \cdot \mathbf{x}^T \cdot \mathbf{H}^T\} + E\{\mathbf{x} \cdot e^T\} \\&= E\{\mathbf{x} \cdot \mathbf{x}^T\} \cdot \mathbf{H}^T + E\{\mathbf{x}\} \cdot E\{e^T\} \\&= \mathbf{C}_x \cdot \mathbf{H}^T\end{aligned}$$

Filtre de Wiener (LMMSE)

$$\begin{aligned}\tilde{\mathbf{G}} &= \mathbf{C}_{x,y} \cdot \mathbf{C}_y^{-1} \\&= \mathbf{C}_x \cdot \mathbf{H}^T \cdot (\mathbf{H} \cdot \mathbf{C}_x \cdot \mathbf{H}^T + \mathbf{C}_e)^{-1} \\&= (\mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H} + \mathbf{C}_x^{-1})^{-1} \cdot \mathbf{H}^T \cdot \mathbf{C}_e^{-1}\end{aligned}$$

Pas besoin de connaître \mathbf{x} et e uniquement leurs deux premiers moments statistiques: $E\{\mathbf{x}\}$, \mathbf{C}_x , $E\{e\}$ and \mathbf{C}_e .

- Ce qui nous intéresse c'est de trouver les paramètres \mathbf{x} correspondant aux mesures donc il faut comparer \mathbf{x}_{MMSE} et \mathbf{x} , en moyennant au sens des erreurs \mathbf{e} seulement :

$$\langle \mathbf{x}_{\text{MMSE}} \rangle_{\mathbf{e}} = \tilde{\mathbf{G}} \cdot \mathbf{H} \cdot \mathbf{x}$$

soit

$$\begin{aligned} \langle \mathbf{x}_{\text{MMSE}} \rangle_{\mathbf{e}} &= \tilde{\mathbf{G}} \cdot \mathbf{H} \cdot \mathbf{x} \\ &= \mathbf{R}_{\text{MMSE}} \cdot \mathbf{x} \end{aligned}$$

où

$$\mathbf{R}_{\text{MMSE}} \equiv \tilde{\mathbf{G}} \cdot \mathbf{H}$$

est l'**opérateur de résolution** (Backus & Gilbert, 1968) ;

nous avons vu que :

$$\langle \mathbf{x}_{\text{MMSE}} \rangle_e = \mathbf{R}_{\text{MMSE}} \cdot \mathbf{x}$$

avec

$$\begin{aligned} \mathbf{R}_{\text{MMSE}} &= \tilde{\mathbf{G}} \cdot \mathbf{H} \\ &= \mathbf{C}_x \cdot \mathbf{H}^T \cdot (\mathbf{H} \cdot \mathbf{C}_x \cdot \mathbf{H}^T + \mathbf{C}_e)^{-1} \cdot \mathbf{H} \\ &= (\mathbf{C}_x^{-1} + \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H})^{-1} \cdot \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H} \\ &= \mathbf{I} - (\mathbf{C}_x^{-1} + \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H})^{-1} \cdot \mathbf{C}_x^{-1} \end{aligned}$$

on remarque que :

1. $\mathbf{R}_{\text{MMSE}} \neq \mathbf{I}$ donc \mathbf{x}_{MMSE} est **biaisé** au sens où $\langle \mathbf{x}_{\text{MMSE}} \rangle_e \neq \mathbf{x}$
2. le filtrage par \mathbf{R}_{MMSE} est responsable d'une **atténuation** (i.e. $\mathbf{R}_{\text{MMSE}} \leq \mathbf{I}$) ;

Hypothèses:

- **H** est une **convolution** circulante: $\mathbf{H} = \mathbf{F}^{-1} \cdot \text{diag}(\widehat{\mathbf{h}}) \cdot \mathbf{F}$,
- les variables aléatoires x et e sont centrées: $E\{x\} = 0$ et $E\{e\} = 0$,
- le bruit e est stationnaire et de densité spectrale de puissance $E\{|\widehat{e}|^2\}$:
 $\mathbf{C}_e = \mathbf{F}^{-1} \cdot \text{diag}(E\{|\widehat{e}|^2\}) \cdot \mathbf{F}$,
- on connaît *a priori* la densité spectrale de puissance de l'objet $E\{|\widehat{x}|^2\}$:
 $\mathbf{C}_x = \mathbf{F}^{-1} \cdot \text{diag}(E\{|\widehat{x}|^2\}) \cdot \mathbf{F}$.

Filtre de Wiener: Fourier

Le filtre de Wiener est $\widetilde{\mathbf{G}}$ est une convolution et prend une forme très simple dans l'espace de Fourier:

$$\widehat{x}_k^{(\text{Wiener})} = \widehat{g}_k \widehat{y}_k = \frac{\widehat{h}_k^*}{\widehat{h}_k|^2 + \frac{E\{|\widehat{e}_k|^2\}}{E\{|\widehat{x}_k|^2\}}} \widehat{y}_k$$

Filtre de Wiener: déconvolution

Hypothèses:

- **H** est une **convolution** circulante: $\mathbf{H} = \mathbf{F}^{-1} \cdot \text{diag}(\widehat{\mathbf{h}}) \cdot \mathbf{F}$,
- les variables aléatoires **x** et **e** sont centrées: $E\{x\} = 0$ et $E\{e\} = 0$,
- le bruit **e** est stationnaire et de densité spectrale de puissance $E\{|\widehat{e}|^2\}$:
 $\mathbf{C}_e = \mathbf{F}^{-1} \cdot \text{diag}(E\{|\widehat{e}|^2\}) \cdot \mathbf{F}$,
- on connaît *a priori* la densité spectrale de puissance de l'objet $E\{|\widehat{x}|^2\}$:
 $\mathbf{C}_x = \mathbf{F}^{-1} \cdot \text{diag}(E\{|\widehat{x}|^2\}) \cdot \mathbf{F}$.

Filtre de Wiener: Fourier

Le filtre de Wiener est $\widetilde{\mathbf{G}}$ est une convolution et prend une forme très simple dans l'espace de Fourier:

$$\widehat{x}_k^{(\text{Wiener})} = \widehat{g}_k \widehat{y}_k = \frac{\widehat{h}_k^*}{\widehat{h}_k|^2 + \frac{E\{|\widehat{e}_k|^2\}}{E\{|\widehat{x}_k|^2\}}} \widehat{y}_k$$

Filtre de Wiener: déconvolution

Hypothèses:

- **H** est une **convolution** circulante: $\mathbf{H} = \mathbf{F}^{-1} \cdot \text{diag}(\widehat{\mathbf{h}}) \cdot \mathbf{F}$,
- les variables aléatoires **x** et **e** sont centrées: $E\{x\} = 0$ et $E\{e\} = 0$,
- le bruit **e** est stationnaire et de densité spectrale de puissance $E\{\widehat{e}^2\}$:
 $\mathbf{C}_e = \mathbf{F}^{-1} \cdot \text{diag}(E\{\widehat{e}^2\}) \cdot \mathbf{F}$,
- on connaît *a priori* la densité spectrale de puissance de l'objet $E\{\widehat{x}^2\}$:
 $\mathbf{C}_x = \mathbf{F}^{-1} \cdot \text{diag}(E\{\widehat{x}^2\}) \cdot \mathbf{F}$.

Filtre de Wiener: Fourier

Le filtre de Wiener est $\widehat{\mathbf{G}}$ est une convolution et prend une forme très simple dans l'espace de Fourier:

$$\widehat{x}_k^{(\text{Wiener})} = \widehat{g}_k \widehat{y}_k = \frac{\widehat{h}_k^*}{\widehat{h}_k|^2 + \frac{E\{\widehat{e}_k|^2\}}{E\{\widehat{x}_k|^2}}} \widehat{y}_k$$

Filtre de Wiener: déconvolution

Hypothèses:

- **H** est une **convolution** circulante: $\mathbf{H} = \mathbf{F}^{-1} \cdot \text{diag}(\widehat{\mathbf{h}}) \cdot \mathbf{F}$,
- les variables aléatoires **x** et **e** sont centrées: $E\{x\} = 0$ et $E\{e\} = 0$,
- le bruit **e** est stationnaire et de densité spectrale de puissance $E\{\widehat{e}^2\}$:
 $\mathbf{C}_e = \mathbf{F}^{-1} \cdot \text{diag}(E\{\widehat{e}^2\}) \cdot \mathbf{F}$,
- on connaît *a priori* la densité spectrale de puissance de l'objet $E\{\widehat{x}^2\}$:
 $\mathbf{C}_x = \mathbf{F}^{-1} \cdot \text{diag}(E\{\widehat{x}^2\}) \cdot \mathbf{F}$.

Filtre de Wiener: Fourier

Le filtre de Wiener est $\widehat{\mathbf{G}}$ est une convolution et prend une forme très simple dans l'espace de Fourier:

$$\widehat{x}_k^{(\text{Wiener})} = \widehat{g}_k \widehat{y}_k = \frac{\widehat{h}_k^*}{\widehat{h}_k^2 + \frac{E\{\widehat{e}_k^2\}}{E\{\widehat{x}_k^2\}}} \widehat{y}_k$$

Filtre de Wiener: déconvolution

Hypothèses:

- **H** est une **convolution** circulante: $\mathbf{H} = \mathbf{F}^{-1} \cdot \text{diag}(\widehat{\mathbf{h}}) \cdot \mathbf{F}$,
- les variables aléatoires **x** et **e** sont centrées: $E\{x\} = 0$ et $E\{e\} = 0$,
- le bruit **e** est stationnaire et de densité spectrale de puissance $E\{\widehat{e}^2\}$:
 $\mathbf{C}_e = \mathbf{F}^{-1} \cdot \text{diag}(E\{\widehat{e}^2\}) \cdot \mathbf{F}$,
- on connaît *a priori* la densité spectrale de puissance de l'objet $E\{\widehat{x}^2\}$:
 $\mathbf{C}_x = \mathbf{F}^{-1} \cdot \text{diag}(E\{\widehat{x}^2\}) \cdot \mathbf{F}$.

Filtre de Wiener: Fourier

Le filtre de Wiener est $\widetilde{\mathbf{G}}$ est une convolution et prend une forme très simple dans l'espace de Fourier:

$$\widehat{x}_k^{(\text{Wiener})} = \widehat{g}_k \widehat{y}_k = \frac{\widehat{h}_k^*}{|\widehat{h}_k|^2 + \frac{E\{\widehat{e}_k^2\}}{E\{\widehat{x}_k^2\}}} \widehat{y}_k$$

Filtere de Wiener: déconvolution

Le filtre de Wiener est:

$$\widehat{g}_k = \frac{\widehat{h}_k^*}{|\widehat{h}_k|^2 + \widehat{q}_k} \quad \text{avec} \quad \widehat{q}_k = \frac{E\{\widehat{e}_k|^2\}}{E\{\widehat{x}_k|^2\}} > 0$$



Comportement:

$$\widehat{g}_u \simeq \begin{cases} 1/\widehat{h}_u & \text{si } \text{SNR}_u \gg 1 \\ 0 & \text{si } \text{SNR}_u \ll 1 \end{cases}$$

$$\text{avec } \text{SNR}_u \equiv \sqrt{\frac{|\widehat{h}_u|^2 E\{\widehat{x}_u|^2\}}{E\{\widehat{e}_u|^2\}}}$$

Mais:

- Les densités spectrales sont rarement connues et doivent être devinées d'après les données,
- Solution possiblement non physique (valeur négative, rebonds, ...).



Filtere de Wiener: déconvolution

Le filtre de Wiener est:

$$\widehat{g}_k = \frac{\widehat{h}_k^*}{|\widehat{h}_k|^2 + \widehat{q}_k} \quad \text{avec} \quad \widehat{q}_k = \frac{E\{\widehat{e}_k|^2\}}{E\{\widehat{x}_k|^2\}} > 0$$



Comportement:

$$\widehat{g}_u \simeq \begin{cases} 1/\widehat{h}_u & \text{si } \text{SNR}_u \gg 1 \\ 0 & \text{si } \text{SNR}_u \ll 1 \end{cases}$$

$$\text{avec } \text{SNR}_u \equiv \sqrt{\frac{|\widehat{h}_u|^2 E\{\widehat{x}_u|^2\}}{E\{\widehat{e}_u|^2\}}}.$$

Mais:

- Les densités spectrales sont rarement connues et doivent être devinées d'après les données,
- Solution possiblement non physique (valeur négative, rebonds, ...).



Filtere de Wiener: déconvolution

Le filtre de Wiener est:

$$\widehat{g}_k = \frac{\widehat{h}_k^*}{|\widehat{h}_k|^2 + \widehat{q}_k} \quad \text{avec} \quad \widehat{q}_k = \frac{E\{\widehat{e}_k|^2\}}{E\{\widehat{x}_k|^2\}} > 0$$



Comportement:

$$\widehat{g}_u \simeq \begin{cases} 1/\widehat{h}_u & \text{si } \text{SNR}_u \gg 1 \\ 0 & \text{si } \text{SNR}_u \ll 1 \end{cases}$$

$$\text{avec } \text{SNR}_u \equiv \sqrt{\frac{|\widehat{h}_u|^2 E\{\widehat{x}_u|^2\}}{E\{\widehat{e}_u|^2\}}}.$$

Mais:

- Les densités spectrales sont rarement connues et doivent être devinées d'après les données,
- Solution possiblement non physique (valeur négative, rebonds,...).



On suppose:

- Le bruit indépendant et stationnaire: $E\{\widehat{e}_k|^2\} = \text{cte}$
- La distribution d'intensité de l'objet suit une loi simple (loi de puissance):
 $E\{|\widehat{x}_k|^2\} \propto \|\omega_k\|^{-\beta}$; avec $\beta \geq 0$:

$$\widehat{g}_k = \frac{\widehat{h}_k^*}{|\widehat{h}_k|^2 + \alpha \|\mathbf{u}_k\|^\beta}.$$

Il reste plus qu'à déterminer les valeurs de α et β visuellement ou automatiquement (via GCV, GML, SURE,...).

Maximum de vraisemblance

- Quel est le meilleur modèle ?

⇒ **réponse** : c'est celui qui maximise la probabilité d'avoir observé les données :

$$x_{\text{ML}} = \arg \max_x \Pr(y|x)$$

où **ML** = *Maximum Likelihood*

▲ C'est la meilleure solution au sens de la statistiques des erreurs...

- Quel est le meilleur modèle ?

⇒ **réponse** : c'est celui qui maximise la probabilité d'avoir observé les données :

$$\mathbf{x}_{\text{ML}} = \arg \max_x \Pr(\mathbf{y}|\mathbf{x})$$

où **ML = *Maximum Likelihood***

▲ C'est la meilleure solution au sens de la statistiques des erreurs...

- Quel est le meilleur modèle ?

⇒ **réponse** : c'est celui qui maximise la probabilité d'avoir observé les données :


$$\mathbf{x}_{\text{ML}} = \arg \max_x \Pr(\mathbf{y}|\mathbf{x})$$

où **ML = *Maximum Likelihood***

- ▲ C'est la meilleure solution au sens de la statistiques des erreurs...

Maximum de vraisemblance : Fonction de pénalisation

- Maximum de vraisemblance: on cherche la solution qui maximise $\Pr(\mathbf{y}|\mathbf{x})$:



- solution au sens du maximum de vraisemblance :

$$\begin{aligned}\mathbf{x}_{\text{ML}} &= \arg \max_x \Pr(\mathbf{y}|\mathbf{x}) \\ &= \arg \min_x f_{\mathbf{y}|\mathbf{x}}(\mathbf{x})\end{aligned}$$

- fonction de pénalisation :

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

Approximation gaussienne pour les erreurs

- modèle direct :

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

où e incorpore les erreurs de modélisation et le bruit ;

- la statistique des erreurs est **normale centrée** :

$$e | x \sim \mathcal{N}(\mathbf{0}, \mathbf{C}_{e|x})$$

c'est-à-dire que la fonction de distribution des erreurs sachant x est :

$$\text{PDF}(e | x) = \frac{\exp\left\{-\frac{1}{2} e^T \cdot \mathbf{C}_{e|x}^{-1} \cdot e\right\}}{(2\pi)^{M/2} |\mathbf{C}_{e|x}|^{\frac{1}{2}}}$$

où M est le nombre de mesures.

Maximum de vraisemblance : Approximation gaussienne, modèle non linéaire

- modèle :

$$\mathbf{y} = m(\mathbf{x}) + \mathbf{e}$$

- fonction de distribution des erreurs :

$$\text{PDF}(\mathbf{y}|\mathbf{x}) = \frac{\exp\left\{-\frac{1}{2} [\mathbf{y} - m(\mathbf{x})]^T \cdot \mathbf{C}_e^{-1} \cdot [\mathbf{y} - m(\mathbf{x})]\right\}}{(2\pi)^{M/2} |\mathbf{C}_e|^{\frac{1}{2}}}$$

- fonction de pénalisation :

$$f_{y|x}(\mathbf{x}) = \frac{1}{2} (\mathbf{y} - m(\mathbf{x}))^T \cdot \mathbf{C}_e^{-1} \cdot (\mathbf{y} - m(\mathbf{x}))$$

Maximum de vraisemblance: détection unique



Amas des Hyades

On recherche la position p et l'amplitude α d'un motif h dans l'image

$$m = m(\alpha, p) = \alpha h(x - p)$$

avec la PSF $h(x)$ et $g = h(x - p)$

$$\begin{aligned} f_{y|x}(\alpha, p) &= \frac{1}{2} (y - m)^T \cdot C_e^{-1} \cdot (y - m) \\ &= \frac{1}{2} m^T \cdot C_e^{-1} \cdot m - m^T \cdot C_e^{-1} \cdot y + \frac{1}{2} y^T \cdot C_e^{-1} \cdot y \\ &= \frac{1}{2} \alpha^2 g^T \cdot C_e^{-1} \cdot g + \frac{1}{2} y^T \cdot C_e^{-1} \cdot y \\ &\quad - \alpha g^T \cdot C_e^{-1} \cdot y \end{aligned}$$

Maximum de vraisemblance: détection unique



Amas des Hyades

On recherche la position p et l'amplitude α d'un motif h dans l'image

$$m = m(\alpha, p) = \alpha h(x - p)$$

avec la PSF $h(x)$ et $g = h(x - p)$

$$\begin{aligned} f_{y|x}(\alpha, p) &= \frac{1}{2} (y - m)^T \cdot C_e^{-1} \cdot (y - m) \\ &= \frac{1}{2} m^T \cdot C_e^{-1} \cdot m - m^T \cdot C_e^{-1} \cdot y + \frac{1}{2} y^T \cdot C_e^{-1} \cdot y \\ &= \frac{1}{2} \alpha^2 g^T \cdot C_e^{-1} \cdot g + \frac{1}{2} y^T \cdot C_e^{-1} \cdot y \\ &\quad - \alpha g^T \cdot C_e^{-1} \cdot y \end{aligned}$$

Détection unique: estimation de l'amplitude

$$f_{y|x}(\alpha) = \frac{1}{2} \alpha^2 \mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g} - \alpha \mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y} + \frac{1}{2} \mathbf{y}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y}.$$

Estimation de l'amplitude α

$$\begin{aligned} \left. \frac{\partial f_{y|x}(\alpha)}{\partial \alpha} \right|_{\alpha=\alpha^+} = 0 &\iff \alpha^+ \mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g} - \mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y} = 0, \\ &\iff \alpha^+ = \frac{\mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y}}{\mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g}}. \end{aligned}$$

$$\begin{aligned} f_{y|x}(\alpha, p) \Big|_{\alpha=\alpha^+} &= \frac{1}{2} \left(\frac{\mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y}}{\mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g}} \right)^2 \mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g} - \frac{\mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y}}{\mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g}} \mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y} \\ &= -\frac{1}{2} \frac{(\mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y})^2}{\mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g}} \end{aligned}$$

Détection unique: estimation de l'amplitude

$$f_{y|x}(\alpha) = \frac{1}{2}\alpha^2 \mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g} - \alpha \mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y} + \frac{1}{2}\mathbf{y}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y}.$$

Estimation de l'amplitude α

$$\begin{aligned} \left. \frac{\partial f_{y|x}(\alpha)}{\partial \alpha} \right|_{\alpha=\alpha^+} = 0 &\iff \alpha^+ \mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g} - \mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y} = 0, \\ &\iff \alpha^+ = \frac{\mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y}}{\mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g}}. \end{aligned}$$

$$\begin{aligned} f_{y|x}(\alpha, p) \Big|_{\alpha=\alpha^+} &= \frac{1}{2} \left(\frac{\mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y}}{\mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g}} \right)^2 \mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g} - \frac{\mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y}}{\mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g}} \mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y} \\ &= -\frac{1}{2} \frac{(\mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y})^2}{\mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g}} \end{aligned}$$

Détection unique: estimation de l'amplitude

$$f_{y|x}(\alpha) = \frac{1}{2}\alpha^2 \mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g} - \alpha \mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y} + \frac{1}{2}\mathbf{y}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y}.$$

Estimation de l'amplitude α

$$\begin{aligned} \left. \frac{\partial f_{y|x}(\alpha)}{\partial \alpha} \right|_{\alpha=\alpha^+} = 0 &\iff \alpha^+ \mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g} - \mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y} = 0, \\ &\iff \alpha^+ = \frac{\mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y}}{\mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g}}. \end{aligned}$$

$$\begin{aligned} f_{y|x}(\alpha, \mathbf{p}) \Big|_{\alpha=\alpha^+} &= \frac{1}{2} \left(\frac{\mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y}}{\mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g}} \right)^2 \mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g} - \frac{\mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y}}{\mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g}} \mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y} \\ &= -\frac{1}{2} \frac{(\mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y})^2}{\mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g}} \end{aligned}$$

Détection unique: estimation rapide de la position

Approximation: bruit blanc non stationnaire

$$\mathbf{C}_e^{-1} = \text{diag}(\mathbf{w}) \text{ avec } w_k = \frac{1}{\sigma_k^2} = \frac{1}{\text{Var}(y_k)}.$$

Estimation de la position au pixel près

En 1D : $g[k] = h[k - p]$

$$\begin{aligned} f_{y|x}(\alpha, p) \Big|_{\alpha=\alpha^+} &= -\frac{1}{2} \frac{(\mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y})^2}{\mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g}}, \\ &= -\frac{1}{2} \frac{(\sum_k h[k - p] w[k] y[k])^2}{\sum_k h^2[k - p] w[k]} \\ &= -\frac{1}{2} \frac{(\text{Inter-corrélation})^2}{\text{Normalisation}} \end{aligned}$$

Détection

Pour p qui maximise $\frac{(\text{Inter-corrélation})^2}{\text{Normalisation}}$ ou $\frac{\text{Inter-corrélation}}{\text{Normalisation}}$ si $\alpha > 0$. Calcul rapide par FFT.

Détection unique: estimation rapide de la position

Approximation: bruit blanc non stationnaire

$$\mathbf{C}_e^{-1} = \text{diag}(\mathbf{w}) \text{ avec } w_k = \frac{1}{\sigma_k^2} = \frac{1}{\text{Var}(y_k)}.$$

Estimation de la position au pixel près

En 1D : $g[k] = h[k - p]$

$$\begin{aligned} f_{y|x}(\alpha, p) \Big|_{\alpha=\alpha^+} &= -\frac{1}{2} \frac{(\mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y})^2}{\mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g}}, \\ &= -\frac{1}{2} \frac{(\sum_k h[k - p] w[k] y[k])^2}{\sum_k h^2[k - p] w[k]} \\ &= -\frac{1}{2} \frac{(\text{Inter-corrélation})^2}{\text{Normalisation}} \end{aligned}$$

Détection

Pour p qui maximise $\frac{(\text{Inter-corrélation})^2}{\text{Normalisation}}$ ou $\frac{\text{Inter-corrélation}}{\text{Normalisation}}$ si $\alpha > 0$. Calcul rapide par FFT.

Détection unique: estimation rapide de la position

Approximation: bruit blanc non stationnaire

$$\mathbf{C}_e^{-1} = \text{diag}(\mathbf{w}) \text{ avec } w_k = \frac{1}{\sigma_k^2} = \frac{1}{\text{Var}(y_k)}.$$

Estimation de la position au pixel près

En 1D : $g[k] = h[k - p]$

$$\begin{aligned} f_{y|x}(\alpha, p) \Big|_{\alpha=\alpha^+} &= -\frac{1}{2} \frac{(\mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y})^2}{\mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g}}, \\ &= -\frac{1}{2} \frac{(\sum_k h[k - p] w[k] y[k])^2}{\sum_k h^2[k - p] w[k]} \\ &= -\frac{1}{2} \frac{(\text{Inter-corrélation})^2}{\text{Normalisation}} \end{aligned}$$

Détection

Pour p qui maximise $\frac{(\text{Inter-corrélation})^2}{\text{Normalisation}}$ ou $\frac{\text{Inter-corrélation}}{\text{Normalisation}}$ si $\alpha > 0$. Calcul rapide par FFT.

Détection unique: estimation rapide de la position

Approximation: bruit blanc non stationnaire

$$\mathbf{C}_e^{-1} = \text{diag}(\mathbf{w}) \text{ avec } w_k = \frac{1}{\sigma_k^2} = \frac{1}{\text{Var}(y_k)}.$$

Estimation de la position au pixel près

En 1D : $g[k] = h[k - p]$

$$\begin{aligned} f_{y|x}(\alpha, \mathbf{p}) \Big|_{\alpha=\alpha^+} &= -\frac{1}{2} \frac{(\mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y})^2}{\mathbf{g}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g}}, \\ &= -\frac{1}{2} \frac{(\sum_k h[k - p] w[k] y[k])^2}{\sum_k h^2[k - p] w[k]} \\ &= -\frac{1}{2} \frac{(\text{Inter-corrélation})^2}{\text{Normalisation}} \end{aligned}$$

Détection

Pour p qui maximise $\frac{(\text{Inter-corrélation})^2}{\text{Normalisation}}$ ou $\frac{\text{Inter-corrélation}}{\text{Normalisation}}$ si $\alpha > 0$. Calcul rapide par FFT.

Maximum de vraisemblance: détection multiple



Amas des Hyades

On recherche la position p et l'amplitude α de N étoiles

$$m = m(\alpha, p) = \sum_n^N \alpha_n h(x - p_n)$$

avec la PSF $h(x)$ et $g_n = h(x - p_n)$

$$\begin{aligned} f_{y|x}(\alpha, p) &= \frac{1}{2} (y - m)^T \cdot C_e^{-1} \cdot (y - m) \\ &= \frac{1}{2} m^T \cdot C_e^{-1} \cdot m - m^T \cdot C_e^{-1} \cdot y + \frac{1}{2} y^T \cdot C_e^{-1} \cdot y \\ &= \frac{1}{2} \sum_n \alpha_n^2 g_n^T \cdot C_e^{-1} \cdot g_n + \frac{1}{2} y^T \cdot C_e^{-1} \cdot y \\ &\quad - \frac{1}{2} \sum_n \sum_{m \neq n} \alpha_n \alpha_m g_n^T \cdot C_e^{-1} \cdot g_m \\ &\quad - \sum_n \alpha_n g_n^T \cdot C_e^{-1} \cdot y \end{aligned}$$

Un problème combinatoire!!!

Maximum de vraisemblance: détection multiple



Amas des Hyades

On recherche la position p et l'amplitude α de N étoiles

$$m = m(\alpha, p) = \sum_n^N \alpha_n h(x - p_n)$$

avec la PSF $h(x)$ et $g_n = h(x - p_n)$

$$\begin{aligned} f_{y|x}(\alpha, p) &= \frac{1}{2} (y - m)^T \cdot C_e^{-1} \cdot (y - m) \\ &= \frac{1}{2} m^T \cdot C_e^{-1} \cdot m - m^T \cdot C_e^{-1} \cdot y + \frac{1}{2} y^T \cdot C_e^{-1} \cdot y \\ &= \frac{1}{2} \sum_n \alpha_n^2 g_n^T \cdot C_e^{-1} \cdot g_n + \frac{1}{2} y^T \cdot C_e^{-1} \cdot y \\ &\quad - \frac{1}{2} \sum_n \sum_{m \neq n} \alpha_n \alpha_m g_n^T \cdot C_e^{-1} \cdot g_m \\ &\quad - \sum_n \alpha_n g_n^T \cdot C_e^{-1} \cdot y \end{aligned}$$

Un problème combinatoire!!!

Maximum de vraisemblance: détection multiple



Amas des Hyades

On recherche la position p et l'amplitude α de N étoiles

$$m = m(\alpha, p) = \sum_n^N \alpha_n h(x - p_n)$$

avec la PSF $h(x)$ et $g_n = h(x - p_n)$

$$\begin{aligned} f_{y|x}(\alpha, p) &= \frac{1}{2} (y - m)^T \cdot C_e^{-1} \cdot (y - m) \\ &= \frac{1}{2} m^T \cdot C_e^{-1} \cdot m - m^T \cdot C_e^{-1} \cdot y + \frac{1}{2} y^T \cdot C_e^{-1} \cdot y \\ &= \frac{1}{2} \sum_n \alpha_n^2 g_n^T \cdot C_e^{-1} \cdot g_n + \frac{1}{2} y^T \cdot C_e^{-1} \cdot y \\ &\quad - \frac{1}{2} \sum_n \sum_{m \neq n} \alpha_n \alpha_m g_n^T \cdot C_e^{-1} \cdot g_m \\ &\quad - \sum_n \alpha_n g_n^T \cdot C_e^{-1} \cdot y \end{aligned}$$

Un problème combinatoire!!!

Méthode séparable

Négliger les termes croisés,

$$\mathbf{g}_n^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g}_m \approx 0$$

$$f_{y|x}(\boldsymbol{\alpha}, \mathbf{p}) \approx \frac{1}{2} \sum_n \alpha_n^2 \mathbf{g}_n^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g}_n - \sum_n \alpha_n \mathbf{g}_n^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y}$$

Méthode gloutone

$$\begin{aligned} f_{y|x}(\boldsymbol{\alpha}, \mathbf{p}) &\approx \frac{1}{2} \sum_n \alpha_n^2 \mathbf{g}_n^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g}_n - \sum_n \alpha_n \mathbf{g}_n^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y} + \frac{1}{2} \sum_n \sum_{m < n} \alpha_n \alpha_m \mathbf{g}_n^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g}_m \\ &\approx \frac{1}{2} \sum_n \alpha_n^2 \mathbf{g}_n^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g}_n - \sum_n \alpha_n \mathbf{g}_n^T \cdot \mathbf{C}_e^{-1} \cdot \underbrace{\left(\mathbf{y} - \sum_{m < n} \alpha_m \mathbf{r}_m \right)}_{\mathbf{r}_r}. \end{aligned}$$

détection dans les résidus \mathbf{r}_n (CLEAN):

$$\mathbf{r}_n = \mathbf{y} - \sum_{m < n} \alpha_m \mathbf{r}_m$$

Méthode séparable

Négliger les termes croisés,

$$\mathbf{g}_n^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g}_m \approx 0$$

$$f_{y|x}(\boldsymbol{\alpha}, \mathbf{p}) \approx \frac{1}{2} \sum_n \alpha_n^2 \mathbf{g}_n^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g}_n - \sum_n \alpha_n \mathbf{g}_n^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y}$$



Méthode gloutonne

$$\begin{aligned} f_{y|x}(\boldsymbol{\alpha}, \mathbf{p}) &\approx \frac{1}{2} \sum_n \alpha_n^2 \mathbf{g}_n^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g}_n - \sum_n \alpha_n \mathbf{g}_n^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y} + \frac{1}{2} \sum_n \sum_{m < n} \alpha_n \alpha_m \mathbf{g}_n^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g}_m \\ &\approx \frac{1}{2} \sum_n \alpha_n^2 \mathbf{g}_n^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{g}_n - \sum_n \alpha_n \mathbf{g}_n^T \cdot \mathbf{C}_e^{-1} \cdot \underbrace{\left(\mathbf{y} - \sum_{m < n} \alpha_m \mathbf{r}_m \right)}_{\mathbf{r}_r}. \end{aligned}$$



détection dans les résidus \mathbf{r}_n (CLEAN):

$$\mathbf{r}_n = \mathbf{y} - \sum_{m < n} \alpha_m \mathbf{r}_m$$



Détection hors-champ (0)





Détection hors-champ (1)





Détection hors-champ (2)





Détection hors-champ (3)





Détection hors-champ (4)





Détection hors-champ (5)





Détection hors-champ (6)





Détection hors-champ(7)



Détection hors-champ(10)



Détection hors-champ(18)



Maximum de vraisemblance: déconvolution

- modèle :

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

- fonction de distribution des erreurs :

$$\text{PDF}(\mathbf{y}|\mathbf{x}) = \frac{\exp\left\{-\frac{1}{2} [\mathbf{y} - \mathbf{H} \cdot \mathbf{x}]^T \cdot \mathbf{C}_e^{-1} \cdot [\mathbf{y} - \mathbf{H} \cdot \mathbf{x}]\right\}}{(2\pi)^{M/2} |\mathbf{C}_e|^{\frac{1}{2}}}$$

- fonction de pénalisation :

$$f_{\mathbf{y}|\mathbf{x}}(\mathbf{x}) = (\mathbf{y} - \mathbf{H} \cdot \mathbf{x})^T \cdot \mathbf{C}_e^{-1} \cdot (\mathbf{y} - \mathbf{H} \cdot \mathbf{x})$$

- condition d'optimalité du 1^{er} ordre (**équations normales**) :

$$\begin{aligned} \left. \frac{\partial f_{\mathbf{y}|\mathbf{x}}(\mathbf{x})}{\partial \mathbf{x}} \right|_{\mathbf{x}=\mathbf{x}_{\text{ML}}} &= \mathbf{0} \\ \iff \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H} \cdot \mathbf{x}_{\text{ML}} &= \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y} \\ \iff \mathbf{x}_{\text{ML}} &= \left(\mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H} \right)^{-1} \cdot \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y} \end{aligned}$$

- Approximation circulante: $\mathbf{H} = \mathbf{F}^{-1} \cdot \text{diag}(\hat{\mathbf{h}}) \cdot \mathbf{F}$.
- Bruit diagonal dans Fourier: $\mathbf{C}_e = \mathbf{F}^{-1} \cdot \text{diag}(\hat{\mathbf{e}}) \cdot \mathbf{F}$.

$$\hat{x}^{\text{ML}} = (\mathbf{H}^T \cdot \mathbf{C}_e \cdot \mathbf{H})^{-1} \cdot \mathbf{H}^T \cdot \mathbf{C}_e \cdot y,$$

$$\hat{x}_u^{(\text{ML})} = \frac{\hat{h}_u^* \hat{y}_u}{|\hat{h}_u|^2} = \frac{\hat{y}_u}{\hat{h}_u},$$

- C'est l'inversion directe

- Approximation circulante: $\mathbf{H} = \mathbf{F}^{-1} \cdot \text{diag}(\hat{\mathbf{h}}) \cdot \mathbf{F}$.
- Bruit diagonal dans Fourier: $\mathbf{C}_e = \mathbf{F}^{-1} \cdot \text{diag}(\hat{\mathbf{e}}) \cdot \mathbf{F}$.
-

$$\begin{aligned}x^{\text{ML}} &= (\mathbf{H}^T \cdot \mathbf{C}_e \cdot \mathbf{H})^{-1} \cdot \mathbf{H}^T \cdot \mathbf{C}_e \cdot \mathbf{y}, \\ \hat{x}_u^{(\text{ML})} &= \frac{\hat{h}_u^* \hat{y}_u}{|\hat{h}_u|^2} = \frac{\hat{y}_u}{\hat{h}_u},\end{aligned}$$

- C'est l'inversion directe

- Approximation circulante: $\mathbf{H} = \mathbf{F}^{-1} \cdot \text{diag}(\hat{\mathbf{h}}) \cdot \mathbf{F}$.
- Bruit diagonal dans Fourier: $\mathbf{C}_e = \mathbf{F}^{-1} \cdot \text{diag}(\hat{\mathbf{e}}) \cdot \mathbf{F}$.
-

$$\begin{aligned}x^{\text{ML}} &= (\mathbf{H}^T \cdot \mathbf{C}_e \cdot \mathbf{H})^{-1} \cdot \mathbf{H}^T \cdot \mathbf{C}_e \cdot \mathbf{y}, \\ \hat{x}_u^{(\text{ML})} &= \frac{\hat{h}_u^* \hat{y}_u}{|\hat{h}_u|^2} = \frac{\hat{y}_u}{\hat{h}_u},\end{aligned}$$

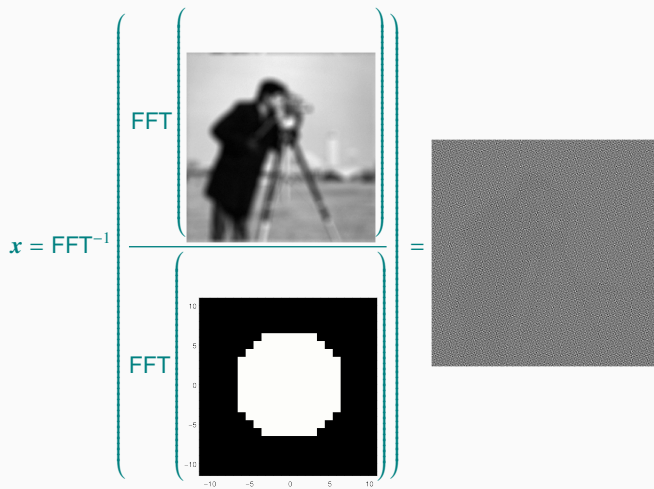
- C'est l'inversion directe

Inversion

$$x = \text{FFT}^{-1} \left(\frac{\text{FFT} \left(\text{Image of person on tripod} \right)}{\text{FFT} \left(\text{Circular mask} \right)} \right) =$$


$$\widehat{x}(\nu) = \frac{\widehat{y}(\nu)}{\widehat{h}(\nu)}$$

Inversion

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


$$\widehat{x}(\nu) = \frac{\widehat{y}(\nu)}{\widehat{h}(\nu)}$$

Quel est le problème?



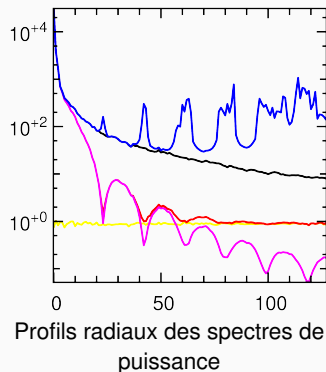
- object,
- blurred object,
- noise,
- blurred object + noise,
- direct inversion.

- inversion directe :

$$\widehat{x}_{\text{ML}}(\nu) = \frac{\widehat{y}(\nu)}{\widehat{h}(\nu)} = \widehat{x}(\nu) + \frac{\widehat{e}(\nu)}{\widehat{h}(\nu)}$$

- Amplification du bruit C'est bien un problème mal conditionné.

Quel est le problème?



- object,
- blurred object,
- noise,
- blurred object + noise,
- direct inversion.

- inversion directe :

$$\widehat{x}_{\text{ML}}(\nu) = \frac{\widehat{y}(\nu)}{\widehat{h}(\nu)} = \widehat{x}(\nu) + \frac{\widehat{e}(\nu)}{\widehat{h}(\nu)}$$

- **Amplification du bruit** C'est bien un problème mal conditionné.

$$f_{y|x}(\mathbf{x}) = \frac{1}{2}(\mathbf{y} - \mathbf{H} \cdot \mathbf{x})^T \cdot \mathbf{C}_e^{-1} \cdot (\mathbf{y} - \mathbf{H} \cdot \mathbf{x}),$$
$$\nabla f_{y|x}(\mathbf{x}) = \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H} \cdot \mathbf{x} - \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y}$$

- **descente de gradient:**

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} - \gamma \nabla f_{y|x}(\mathbf{x})$$

taille du pas: $\gamma < 1/L$ avec L la constante de Lipschitz de $f_{y|x}(\mathbf{x})$.

- **méthodes du second ordre** (Newton):

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} - \mathbf{B} \cdot \nabla f_{y|x}(\mathbf{x})$$

où $\mathbf{B} = (\mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H})^{-1}$ est l'inverse de la matrice Hessienne. Approximation de \mathbf{B} possible (BFGS, ...).

- **gradients conjugués** Le plus efficace pour les fonctions quadratiques.
- méthode de points fixes

$$f_{y|x}(\mathbf{x}) = \frac{1}{2}(\mathbf{y} - \mathbf{H} \cdot \mathbf{x})^T \cdot \mathbf{C}_e^{-1} \cdot (\mathbf{y} - \mathbf{H} \cdot \mathbf{x}),$$
$$\nabla f_{y|x}(\mathbf{x}) = \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H} \cdot \mathbf{x} - \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y}$$

- **descente de gradient:**

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} - \gamma \nabla f_{y|x}(\mathbf{x})$$

taille du pas: $\gamma < 1/L$ avec L la constante de Lipschitz de $f_{y|x}(\mathbf{x})$.

- **méthodes du second ordre** (Newton):

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} - \mathbf{B} \cdot \nabla f_{y|x}(\mathbf{x})$$

où $\mathbf{B} = (\mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H})^{-1}$ est l'inverse de la matrice Hessienne. Approximation de \mathbf{B} possible (BFGS, ...).

- **gradients conjugués** Le plus efficace pour les fonctions quadratiques.
- méthode de points fixes

$$f_{y|x}(\mathbf{x}) = \frac{1}{2}(\mathbf{y} - \mathbf{H} \cdot \mathbf{x})^T \cdot \mathbf{C}_e^{-1} \cdot (\mathbf{y} - \mathbf{H} \cdot \mathbf{x}),$$
$$\nabla f_{y|x}(\mathbf{x}) = \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H} \cdot \mathbf{x} - \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y}$$

- **descente de gradient:**

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} - \gamma \nabla f_{y|x}(\mathbf{x})$$

taille du pas: $\gamma < 1/L$ avec L la constante de Lipschitz de $f_{y|x}(\mathbf{x})$.

- **méthodes du second ordre** (Newton):

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} - \mathbf{B} \cdot \nabla f_{y|x}(\mathbf{x})$$

où $\mathbf{B} = (\mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H})^{-1}$ est l'inverse de la matrice Hessienne. Approximation de \mathbf{B} possible (BFGS,...).

- **gradients conjugués** Le plus efficace pour les fonctions quadratiques.
- méthode de points fixes

$$f_{y|x}(\mathbf{x}) = \frac{1}{2}(\mathbf{y} - \mathbf{H} \cdot \mathbf{x})^T \cdot \mathbf{C}_e^{-1} \cdot (\mathbf{y} - \mathbf{H} \cdot \mathbf{x}),$$
$$\nabla f_{y|x}(\mathbf{x}) = \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H} \cdot \mathbf{x} - \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y}$$

- **descente de gradient:**

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} - \gamma \nabla f_{y|x}(\mathbf{x})$$

taille du pas: $\gamma < 1/L$ avec L la constante de Lipschitz de $f_{y|x}(\mathbf{x})$.

- **méthodes du second ordre** (Newton):

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} - \mathbf{B} \cdot \nabla f_{y|x}(\mathbf{x})$$

où $\mathbf{B} = (\mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H})^{-1}$ est l'inverse de la matrice Hessienne. Approximation de \mathbf{B} possible (BFGS,...).

- **gradients conjugués** Le plus efficace pour les fonctions quadratiques.
- méthode de points fixes

$$f_{y|x}(\mathbf{x}) = \frac{1}{2}(\mathbf{y} - \mathbf{H} \cdot \mathbf{x})^T \cdot \mathbf{C}_e^{-1} \cdot (\mathbf{y} - \mathbf{H} \cdot \mathbf{x}),$$
$$\nabla f_{y|x}(\mathbf{x}) = \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H} \cdot \mathbf{x} - \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y}$$

- **descente de gradient:**

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} - \gamma \nabla f_{y|x}(\mathbf{x})$$

taille du pas: $\gamma < 1/L$ avec L la constante de Lipschitz de $f_{y|x}(\mathbf{x})$.

- **méthodes du second ordre** (Newton):

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} - \mathbf{B} \cdot \nabla f_{y|x}(\mathbf{x})$$

où $\mathbf{B} = (\mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H})^{-1}$ est l'inverse de la matrice Hessienne. Approximation de \mathbf{B} possible (BFGS,...).

- **gradients conjugués** Le plus efficace pour les fonctions quadratiques.
- méthode de points fixes

Arrêt prématuré (Early stopping)


Si on laisse converger les algorithmes itératifs, la solution sera très bruitées (solution MV).

Erreur en fonction des itérations

Solution à l'itération 24.

Arrêt prématuré (Early stopping)


Si on laisse converger les algorithmes itératifs, la solution sera très bruitées (solution MV).



Solution à l'itération 24.

Arrêt prématuré (Early stopping)

Si on laisse converger les algorithmes itératifs, la solution sera très bruitée (solution MV).



Solution à l'itération 24.

Maximum de vraisemblance avec contraintes

Restriction de l'espace des paramètres

Solution naive:

$$\mathbf{x}_{\text{ML}} = \mathbf{H}^{-1} \cdot \mathbf{y} = \mathbf{x} + \mathbf{H}^{-1} \cdot \mathbf{e}$$

Recherche de la solution dans un sous-espace où $\mathbf{H}^{-1} \cdot \mathbf{e}$ est petit:

- Espace décrit par les vecteurs propres correspondant aux grandes valeurs propres de \mathbf{H} :

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

Restriction de l'espace des paramètres

Solution naive:

$$x_{ML} = \mathbf{H}^{-1} \cdot \mathbf{y} = \mathbf{x} + \mathbf{H}^{-1} \cdot \mathbf{e}$$

Recherche de la solution dans un sous-espace où $\mathbf{H}^{-1} \cdot \mathbf{e}$ est petit:

- Espace décrit par les vecteurs propres correspondant aux grandes valeurs propres de \mathbf{H} :



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

Débruitage de la solution naïve

Solution naïve:

$$x_{ML} = \mathbf{H}^{-1} \cdot y = x + \mathbf{H}^{-1} \cdot e$$

Recherche de la solution dans un sous-espace où $\mathbf{H}^{-1} \cdot e$ est bien séparée de x :

- Espace décrit par une base d'ondelettes \mathbf{M} (ForWarD [Neelamani,2004])



$$x = \mathbf{M}^{-1} S(\mathbf{M}x_{ML})$$

avec $S()$ un seuillage.

Restriction aux solution positive

- **Gradient projeté**

$$\mathbf{x}^{(k+1)} = \mathcal{P}_{>0} \left(\mathbf{x}^{(k)} - \gamma \nabla f_{y|x}(\mathbf{x}) \right)$$

avec la projection

$$\mathcal{P}_{>0}(x) = \begin{cases} x & \text{si } x > 0 \\ 0 & \text{sinon} \end{cases}$$

- **Methodes multiplicatives**

ISRA (points fixe)

$$\mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H} \cdot \mathbf{x} = \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y}$$

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} \frac{\mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y}}{\mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H} \cdot \mathbf{x}^{(k)}}$$



Solution positive

Maximum a posteriori

Approche Bayesienne : Maximum a posteriori

- maximiser la probabilité du model étant donnée les mesures (MAP = *maximum a posteriori*) :

$$\begin{aligned} \mathbf{x}_{\text{MAP}} &= \arg \max_{\mathbf{x}} \Pr(\mathbf{x} | \mathbf{y}) \\ &= \arg \max_{\mathbf{x}} \frac{\Pr(\mathbf{y}|\mathbf{x}) \Pr(\mathbf{x})}{\Pr(\mathbf{y})} && \text{(Bayes)} \\ &= \arg \min_{\mathbf{x}} \left\{ \underbrace{-\log \Pr(\mathbf{y}|\mathbf{x})}_{f_{\mathbf{y}|\mathbf{x}}(\mathbf{x})} - \underbrace{\log \Pr(\mathbf{x})}_{f_{\mathbf{x}}(\mathbf{x})} \right\} \\ &= \arg \min_{\mathbf{x}} f_{\text{post}}(\mathbf{x}) \end{aligned}$$

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

$$f_{\text{post}}(\mathbf{x}) = f_{\mathbf{y}|\mathbf{x}}(\mathbf{x}) + f_{\mathbf{x}}(\mathbf{x})$$

- $f_{\mathbf{y}|\mathbf{x}}(\mathbf{x})$ = fonction de **vraisemblance**
- $f_{\mathbf{x}}(\mathbf{x})$ = fonction de **régularisation** (a priori)

- PDF des mesures :

$$\text{PDF}(\mathbf{y}|\mathbf{x}) = \frac{\exp\{-\frac{1}{2} [\mathbf{y} - \mathbf{m}(\mathbf{x})]^T \cdot \mathbf{C}_e^{-1} \cdot [\mathbf{y} - \mathbf{m}(\mathbf{x})]\}}{(2\pi)^{N_y/2} |\mathbf{C}_e|^{\frac{1}{2}}}$$

- ▶ terme de vraisemblance :

$$f_{y|x}(\mathbf{x}) = (\mathbf{y} - \mathbf{H} \cdot \mathbf{x})^T \cdot \mathbf{C}_e^{-1} \cdot (\mathbf{y} - \mathbf{H} \cdot \mathbf{x})$$

- PDF a priori:

$$\text{PDF}(\mathbf{x}) = \frac{\exp\{-\frac{1}{2} (\mathbf{x} - \bar{\mathbf{x}})^T \cdot \mathbf{C}_x^{-1} \cdot (\mathbf{x} - \bar{\mathbf{x}})\}}{(2\pi)^{N_x/2} |\mathbf{C}_x|^{\frac{1}{2}}}$$

- ▶ terme de regularisation :

$$f_x(\mathbf{x}) = (\mathbf{x} - \bar{\mathbf{x}})^T \cdot \mathbf{C}_x^{-1} \cdot (\mathbf{x} - \bar{\mathbf{x}})$$

- fonction de coût a posteriori :

$$\begin{aligned}f_{\text{post}}(\mathbf{x}) &= f_{y|x}(\mathbf{x}) + f_x(\mathbf{x}) \\ &= (\mathbf{y} - \mathbf{H} \cdot \mathbf{x})^T \cdot \mathbf{C}_e^{-1} \cdot (\mathbf{y} - \mathbf{H} \cdot \mathbf{x}) + (\mathbf{x} - \bar{\mathbf{x}})^T \cdot \mathbf{C}_x^{-1} \cdot (\mathbf{x} - \bar{\mathbf{x}})\end{aligned}$$

- ▶ gradient :

$$\frac{\partial f_{\text{post}}(\mathbf{x})}{\partial \mathbf{x}} = 2 \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot (\mathbf{H} \cdot \mathbf{x} - \mathbf{y}) + 2 \mathbf{C}_x^{-1} \cdot (\mathbf{x} - \bar{\mathbf{x}})$$

- ▶ solution MAP :

$$\begin{aligned}\mathbf{x}_{\text{MAP}} &= \arg \min_{\mathbf{x}} f_{\text{post}}(\mathbf{x}) \\ &= (\mathbf{C}_x^{-1} + \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H})^{-1} \cdot (\mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y} + \mathbf{C}_x^{-1} \cdot \bar{\mathbf{x}})\end{aligned}$$

solution MAP

$$\begin{aligned} \mathbf{x}_{\text{MAP}} &= \arg \max_{\mathbf{x}} \Pr(\mathbf{x} | \mathbf{y}) \\ &= (\mathbf{C}_x^{-1} + \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H})^{-1} \cdot (\mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y} + \mathbf{C}_x^{-1} \cdot \bar{\mathbf{x}}) \\ &= \bar{\mathbf{x}} + (\mathbf{C}_x^{-1} + \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H})^{-1} \cdot \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot (\mathbf{y} - \mathbf{H} \cdot \bar{\mathbf{x}}) \\ &= \bar{\mathbf{x}} + \mathbf{C}_x \cdot \mathbf{H}^T (\mathbf{H} \cdot \mathbf{C}_x \cdot \mathbf{H}^T + \mathbf{C}_e)^{-1} \cdot (\mathbf{y} - \mathbf{H} \cdot \bar{\mathbf{x}}) \\ &= \mathbf{x}_{\text{MMSE}} \\ &= \arg \min_{\bar{\mathbf{x}}} \langle \|\mathbf{x} - \bar{\mathbf{x}}\|^2 \rangle \end{aligned}$$

- ▶ Dans le cas Gaussien le MAP a les mêmes propriétés que le MMSE (PDF, expectations, ...)

Calcul direct (filtre de Wiener)

Toutes les matrices (\mathbf{H} , \mathbf{C}_x and \mathbf{C}_e) doivent être diagonales dans le même espace.

Attention: \mathbf{C}_e est en général diagonale que dans l'espace des mesures.

Optimisation de $f_{\text{post}}(\mathbf{x})$

$(\mathbf{C}_x^{-1} + \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H}) \cdot \mathbf{x} = \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y}$ résolu via les gradients conjugués ou des méthode de Newton ou quasi-Newton (Hessian: $\mathbf{B} = \mathbf{C}_x^{-1} + \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H}$)

Méthodes du point fixe (ISRA / RLA)

$$\frac{(\mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y})}{(\mathbf{C}_x^{-1} + \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H}) \cdot \mathbf{x}} = 1 \quad \Rightarrow \quad \mathbf{x}^{t+1} = \mathbf{x}^t \times \frac{\mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y}}{(\mathbf{C}_x^{-1} + \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H}) \cdot \mathbf{x}^t}$$

Calcul direct (filtre de Wiener)

Toutes les matrices (\mathbf{H} , \mathbf{C}_x and \mathbf{C}_e) doivent être diagonales dans le même espace.

Attention: \mathbf{C}_e est en général diagonale que dans l'espace des mesures.

Optimisation de $f_{\text{post}}(\mathbf{x})$

$(\mathbf{C}_x^{-1} + \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H}) \cdot \mathbf{x} = \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y}$ résolu via les gradients conjugués ou des méthode de Newton ou quasi-Newton (Hessian: $\mathbf{B} = \mathbf{C}_x^{-1} + \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H}$)

Méthodes du point fixe (ISRA / RLA)

$$\frac{(\mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y})}{(\mathbf{C}_x^{-1} + \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H}) \cdot \mathbf{x}} = 1 \quad \Rightarrow \quad \mathbf{x}^{t+1} = \mathbf{x}^t \times \frac{\mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y}}{(\mathbf{C}_x^{-1} + \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H}) \cdot \mathbf{x}^t}$$

Calcul direct (filtre de Wiener)

Toutes les matrices (\mathbf{H} , \mathbf{C}_x and \mathbf{C}_e) doivent être diagonales dans le même espace.

Attention: \mathbf{C}_e est en général diagonale que dans l'espace des mesures.

Optimisation de $f_{\text{post}}(\mathbf{x})$

$(\mathbf{C}_x^{-1} + \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H}) \cdot \mathbf{x} = \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y}$ résolu via les gradients conjugués ou des méthode de Newton ou quasi-Newton (Hessian: $\mathbf{B} = \mathbf{C}_x^{-1} + \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H}$)

Méthodes du point fixe (ISRA / RLA)

$$\frac{(\mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y})}{(\mathbf{C}_x^{-1} + \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H}) \cdot \mathbf{x}} = 1 \quad \Rightarrow \quad \mathbf{x}^{t+1} = \mathbf{x}^t \times \frac{\mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y}}{(\mathbf{C}_x^{-1} + \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H}) \cdot \mathbf{x}^t}$$

Calcul direct (filtre de Wiener)

Toutes les matrices (\mathbf{H} , \mathbf{C}_x and \mathbf{C}_e) doivent être diagonales dans le même espace.

Attention: \mathbf{C}_e est en général diagonale que dans l'espace des mesures.

Optimisation de $f_{\text{post}}(\mathbf{x})$

$(\mathbf{C}_x^{-1} + \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H}) \cdot \mathbf{x} = \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y}$ résolu via les gradients conjugués ou des méthode de Newton ou quasi-Newton (Hessian: $\mathbf{B} = \mathbf{C}_x^{-1} + \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H}$)

Méthodes du point fixe (ISRA / RLA)

$$\frac{(\mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y})}{(\mathbf{C}_x^{-1} + \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H}) \cdot \mathbf{x}} = 1 \quad \Rightarrow \quad \mathbf{x}^{t+1} = \mathbf{x}^t \times \frac{\mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{y}}{(\mathbf{C}_x^{-1} + \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H}) \cdot \mathbf{x}^t}$$

$$\begin{aligned}\text{PDF}(\mathbf{x}|\mathbf{y}) &= \frac{\text{PDF}(\mathbf{y}|\mathbf{x}) \text{PDF}(\mathbf{x})}{\int \text{PDF}(\mathbf{y}|\mathbf{x}') \text{PDF}(\mathbf{x}') d\mathbf{x}'} \\ &= \frac{\exp\{-\frac{1}{2} (\mathbf{x} - \mathbf{x}_{\text{MAP}}(\mathbf{y}))^T \cdot \mathbf{C}_{x,y}^{-1} \cdot (\mathbf{x} - \mathbf{x}_{\text{MAP}}(\mathbf{y}))\}}{(2\pi)^{N_x/2} |\mathbf{C}_{x,y}|^{\frac{1}{2}}}\end{aligned}$$

avec la covariance a posteriori:

$$\begin{aligned}\mathbf{C}_{x,y} &= (\mathbf{C}_x^{-1} + \mathbf{H}^T \cdot \mathbf{C}_e^{-1} \cdot \mathbf{H})^{-1} \\ &\leq \mathbf{C}_x\end{aligned}$$

MAP non linéaire

$$\mathbf{x}_{\text{MAP}} = \arg \min_{\mathbf{x}} f_{\text{ML}}(\mathbf{x}) + f_{\text{prior}}(\mathbf{x})$$

Cas Gaussien centré

$$f_{\text{prior}}(\mathbf{x}) = \mathbf{x}^T \mathbf{C}_x^{-1} \mathbf{x}$$

Cas Général

$$f_{\text{prior}}(\mathbf{x}) = \mu \varphi(\mathbf{D} \mathbf{x})$$

- μ : hyper-paramètre
- φ : fonction de coût,
- \mathbf{D} : opérateur linéaire.

MAP: régularisation non linéaire:

Une littérature importante sur les régularisation non linéaires:

- maximum d'entropie $f_{\text{prior}}(\mathbf{x}) = \mu \sum_k \left[p_k - x_k + x_k \log \left(\frac{x_k}{p_k} \right) \right]$
- variation totale $f_{\text{prior}}(\mathbf{x}) = \mu \|\mathbf{D}\mathbf{x}\|_1$
- $\ell_2 - \ell_1$: $\varphi(\mathbf{x}) = \sqrt{\|\mathbf{x}\|_2^2 + \epsilon^2} - \epsilon$
- ...

Bonne propriétés:

- convexité,
- dérivabilité,
- rapide à calculer.



Restoration with TV MSE = 21 dB

approche analyse

$$\mathbf{x}_{\text{MAP}} = \arg \min_x \|\mathbf{H} \mathbf{x} - \mathbf{y}\|_{\mathbf{W}}^2 + \mu \varphi(\mathbf{D} \mathbf{x})$$

approche synthèse

Si \mathbf{D} est inversible (base d'ondelettes)

$$\mathbf{x}_{\text{MAP}} = \arg \min_x \|\mathbf{H} \mathbf{D}^{-1} \mathbf{x} - \mathbf{y}\|_{\mathbf{W}}^2 + \mu \varphi(\mathbf{x})$$

Solutions identiques si $\varphi(\mathbf{x}) = \|\mathbf{x}\|_2^2$ (Parseval).

approche analyse

$$\mathbf{x}_{\text{MAP}} = \arg \min_x \|\mathbf{H} \mathbf{x} - \mathbf{y}\|_{\mathbf{W}}^2 + \mu \varphi(\mathbf{D} \mathbf{x})$$

approche synthèse

Si \mathbf{D} est inversible (base d'ondelettes)


$$\mathbf{x}_{\text{MAP}} = \arg \min_x \|\mathbf{H} \mathbf{D}^{-1} \mathbf{x} - \mathbf{y}\|_{\mathbf{W}}^2 + \mu \varphi(\mathbf{x})$$

Solutions identiques si $\varphi(\mathbf{x}) = \|\mathbf{x}\|_2^2$ (Parseval).

Parcimonie


$$f_{\text{prior}}(\mathbf{x}) = \mu \varphi(\mathbf{D} \mathbf{x})$$

- \mathbf{D} “blanchit” le signal: $\text{Cov}(\mathbf{D} \mathbf{x}) = \mathbf{I}$
- $\varphi(z) = -\log(-\log \text{Pr}(z))$



$$f_{\text{prior}}(\mathbf{x}) = \mu \varphi(\mathbf{D} \mathbf{x})$$

- \mathbf{D} "blanchit" le signal: $\text{Cov}(\mathbf{D} \mathbf{x}) = \mathbf{I}$
- $\varphi(z) = -\log(-\log \text{Pr}(z))$




Beaucoup de signaux semblent mieux modélisés par des processus parcimonieux.

Laplace

$$\Pr(z) = \frac{\lambda}{2} e^{-\lambda|z|}$$

$$\varphi(z) = -\log(\Pr(z)) \propto \lambda|z|$$



Il existe une base ψ où le signal peut être décrit par peu de coefficients (compressibilité)

MAP a priori de parcimonie

$$\mathbf{x}_{\text{MAP}} = \arg \min_x \|\mathbf{H} \mathbf{x} - \mathbf{y}\|_{\mathbf{W}}^2 + \mu |\psi \mathbf{x}|$$

φ est la norme ℓ_1 (norme ℓ_p : $\|\mathbf{x}\|_p = (\sum_k x_k^p)^{1/p}$)

Compressive sensing

Extrêmement efficace lorsque l'espace des mesures est incohérent avec la base ψ .
Cohérence:

$$\mu(\psi, \mathbf{H}) = \sqrt{n} \max_{1 \leq k, j \leq n} |\langle \psi_{\cdot, k}, H_{j \cdot} \rangle| \in [1, \sqrt{n}]$$

$\mu(\psi, \mathbf{H}) = 1 \Rightarrow$ bases totalement incohérentes.

Nombre de mesures nécessaires $m \propto \mu^2(\psi, \mathbf{H}) S \log(n)$ pour un signal S -parcimonieux.

Il existe une base ψ où le signal peut être décrit par peu de coefficients (compressibilité)

MAP a priori de parcimonie

$$\mathbf{x}_{\text{MAP}} = \arg \min_x \|\mathbf{H} \mathbf{x} - \mathbf{y}\|_{\mathbf{W}}^2 + \mu \|\psi \mathbf{x}\|$$

φ est la norme ℓ_1 (norme ℓ_p : $\|\mathbf{x}\|_p = (\sum_k x_k^p)^{1/p}$)

Compressive sensing

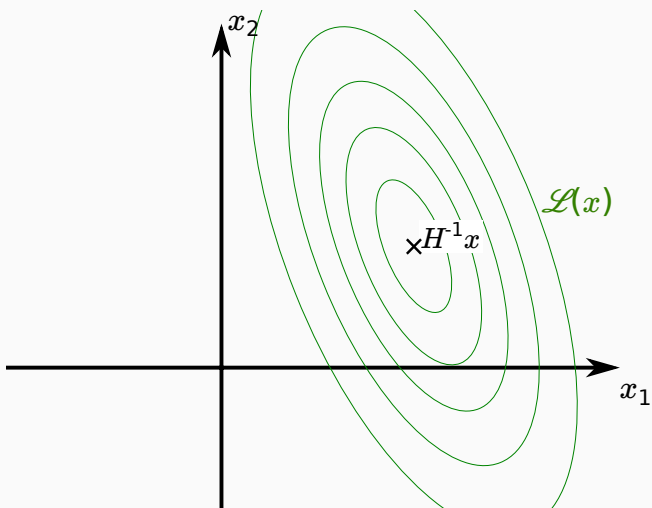
Extrêmement efficace lorsque l'espace des mesures est incohérent avec la base ψ .
Cohérence:

$$\mu(\psi, \mathbf{H}) = \sqrt{n} \max_{1 \leq k, j \leq n} |\langle \psi_{\cdot, k}, H_{j, \cdot} \rangle| \in [1, \sqrt{n}]$$

$\mu(\psi, \mathbf{H}) = 1 \Rightarrow$ bases totalement incohérentes.

Nombre de mesures nécessaires $m \propto \mu^2(\psi, \mathbf{H}) S \log(n)$ pour un signal S-parcimonieux.

Effect of the ℓ_1 norm



Level set of the **likelihood**
and the **regularization**


At convergence level sets
are tangent:

$$\nabla \mathcal{L}(x) = -\mu \nabla \mathcal{R}(x)$$

Solution path $x^+(\mu)$

$$x^+ = \arg \min_x \mathcal{L}(x) + \mu \mathcal{R}(x)$$

Effect of the ℓ_1 norm



Level set of the **likelihood** and the **regularization**


At convergence level sets are tangent:

$$\nabla \mathcal{L}(x) = -\mu \nabla \mathcal{R}(x)$$

Solution path $x^+(\mu)$

$$x^+ = \arg \min_x \mathcal{L}(x) + \mu \mathcal{R}(x)$$

Effect of the ℓ_1 norm




Level set of the **likelihood**
and the **regularization**
At convergence level sets
are tangent:

$$\nabla \mathcal{L}(x) = -\mu \nabla \mathcal{R}(x)$$

Solution path $x^+(\mu)$

$$x^+ = \arg \min_x \mathcal{L}(x) + \mu \mathcal{R}(x)$$

Effect of the ℓ_1 norm




Level set of the **likelihood**
and the **regularization**
At convergence level sets
are tangent:

$$\nabla \mathcal{L}(x) = -\mu \nabla \mathcal{R}(x)$$

Solution path $x^+(\mu)$

$$x^+ = \arg \min_x \mathcal{L}(x) + \mu \mathcal{R}(x)$$

Effect of the ℓ_1 norm



Level set of the **likelihood**
and the **regularization**
At convergence level sets
are tangent:

$$\nabla \mathcal{L}(x) = -\mu \nabla \mathcal{R}(x)$$

Solution path $x^+(\mu)$

$$x^+ = \arg \min_x \mathcal{L}(x) + \mu \mathcal{R}(x)$$

Optimisation non différentiable

$|x|$ n'est pas dérivable en $x = 0$

Rappel: contraintes convexes (e.g. positivité)

Estimer le maximum de vraisemblance sous contraintes de positivité revient à:

$$\mathbf{x}_{\text{ML}} = \arg \min_{\mathbf{x}} f_{y|\mathbf{x}}(\mathbf{x}) + c_{>0}(\mathbf{x})$$

$$\text{avec l'indicatrice } c_{\geq 0}(\mathbf{x}) = \begin{cases} 0 & \text{si } x \geq 0 \\ +\infty & \text{sinon} \end{cases}$$

L'indicatrice $c_{\geq 0}(\mathbf{x})$ n'est pas dérivable en 0.

Solution par descente de gradient projeté:

$$\mathbf{x}^{(k+1)} = \mathcal{P}_{\geq 0}(\mathbf{x}^{(k)} - \gamma \nabla f_{y|\mathbf{x}}(\mathbf{x}))$$

avec la projection (séparable):

$$\begin{aligned} \mathcal{P}_{\geq 0}(y) &= \arg \min_x \frac{1}{2} \|x - y\|_2^2 + c_{\geq 0}(x) \\ &= \begin{cases} x & \text{si } x > 0 \\ 0 & \text{sinon} \end{cases} \end{aligned}$$

Optimisation non différentiable

$|x|$ n'est pas dérivable en $x = 0$

Problème

$$\mathbf{x}_{\text{ML}} = \arg \min_{\mathbf{x}} f_{y|\mathbf{x}}(\mathbf{x}) + \lambda g(\mathbf{x})$$

$f_{y|\mathbf{x}}(\mathbf{x})$ est dérivable et $g(\mathbf{x})$ est semi-continue par dessous.

Algorithme de gradient proximaux

Similaire à la descente de gradient projeté:


$$\mathbf{x}^{(k+1)} = \text{prox}_{\lambda g} \left(\mathbf{x}^{(k)} - \gamma \nabla f_{y|\mathbf{x}}(\mathbf{x}) \right)$$

avec l'opérateur proximal:

$$\text{prox}_{\lambda g}(\mathbf{y}) = \arg \min_{\mathbf{x}} \frac{1}{2} \|\mathbf{x} - \mathbf{y}\|_2^2 + \lambda g(\mathbf{x})$$

Opérateur proximal de ℓ_1

$$\begin{aligned}\text{prox}_{\lambda\ell_1}(y) &= \arg \min_x \frac{1}{2} \|x - y\|_2^2 + \lambda |x|. \\ &= \text{sign}(y) \max(|y| - \lambda, 0).\end{aligned}$$



Seuillage doux