

# Estimation régularisée d'attributs fractals par minimisation convexe pour la segmentation de textures.

Barbara Pascal

30 septembre 2020 Laboratoire de Physique à l'École Normale Supérieure de Lyon

Mme Laure Blanc-Féraud M. Bruno Torrésani M. Gabriel Peyré M. Rémi Bardenet M. Jean-François Giovannelli Mme Nelly Pustelnik M. Patrice Abry Examinatrice Rapporteur Rapporteur Examinateur Examinateur Co-directrice Directeur



# Estimation régularisée d'attributs fractals par minimisation convexe pour la segmentation de textures.

Barbara Pascal

30 septembre 2020 Laboratoire de Physique à l'École Normale Supérieure de Lyon

Mme Laure Blanc-Féraud M. Bruno Torrésani M. Gabriel Peyré M. Rémi Bardenet M. Jean-François Giovannelli Mme Nelly Pustelnik M. Patrice Abry Examinatrice Rapporteur Rapporteur Examinateur Examinateur Co-directrice Directeur

### Segmentation d'image



 Introduction
 Caractérisation de texture
 Constru

 ● 000
 0000
 000

églage des hyperparamètres Conclusi 0000000000000 000

### Segmentation d'image



**Objectif** : obtenir une partition de l'image en K régions homogènes  $\Omega = \Omega_1 \bigsqcup \ldots \bigsqcup \Omega_K$ 

 Introduction
 Caractérisation de texture
 Constru

 ● 000
 0000
 000

églage des hyperparamètres Conclusi 0000000000000 000

### Segmentation d'image



**Objectif** : obtenir une partition de l'image en K régions **homogènes**  $\Omega = \Omega_1 \bigsqcup \ldots \bigsqcup \Omega_K$ 

### Textures





### Textures





### Textures



 Introduction
 Caractérisation de texture
 Construction de fonction

 0000
 0000
 00

Algorithme de minimisation accélé

Réglage des hyperparamètres Concl

### Textures



Crucial pour décrire les images réelles

Introduction Caractérisation de texture 0000 0000

OO

Algorithme de minimisation accél 00000000000000 Réglage des hyperparamètres Conclus 0000000000000 000

### Écoulement multiphasiques en milieu poreux Laboratoire de Physique, ENS Lyon, V. Vidal, T. Busser, (M. Serres, IFPEN)



Mousse solide



## Écoulement multiphasiques en milieu poreux

Laboratoire de Physique, ENS Lyon, V. Vidal, T. Busser, (M. Serres, IFPEN)





## Écoulement multiphasiques en milieu poreux

Laboratoire de Physique, ENS Lyon, V. Vidal, T. Busser, (M. Serres, IFPEN)



Introduction Caractérisation de texture

oo

s Algorithme de minimisation acce 000000000000000 Réglage des hyperparamètres Conclusie 0000000000000 000

### Plan de l'exposé

#### 1. Caractérisation de textures

[Filtres de Gabor (Dunn, 1995)] [Amplitude et fréquence locales (Havlicek, 1996)] [Histogrammes spectraux (Yuan, 2015)] Introduction Caractérisation de texture 0000 0000

OO OO

Réglage des hyperparamètres Conclus 0000000000000 000

### Plan de l'exposé

#### 1. Caractérisation de textures

- $\rightarrow$  attributs fractals
  - > variance locale  $\sigma^2$
  - régularité locale h

[Filtres de Gabor (Dunn, 1995)] [Amplitude et fréquence locales (Havlicek, 1996)] [Histogrammes spectraux (Yuan, 2015)] Introduction Caractérisation de texture 0000 0000

OO OO

### Plan de l'exposé

#### 1. Caractérisation de textures

- ightarrow attributs fractals
  - ▶ variance locale  $\sigma^2$
  - régularité locale h

- [Filtres de Gabor (Dunn, 1995)] [Amplitude et fréquence locales (Havlicek, 1996)] [Histogrammes spectraux (Yuan, 2015)]
- 2. Construction de fonctionnelles

[Champ de Markov (Geman, 1984)] [Contours actifs (Chan, 2001)] [Variation Totale et Seuillage (Cai, 2013)] Introduction Caractérisation de texture 0 0000 0000 0

OO

Algorithme de minimisation accél 000000000000000

### Plan de l'exposé

#### 1. Caractérisation de textures

- ightarrow attributs fractals
  - ▶ variance locale  $\sigma^2$
  - régularité locale h

**2.** Construction de fonctionnelles

- ightarrow moindres carrés pénalisés
  - contours libres
  - contours co-localisés

[Filtres de Gabor (Dunn, 1995)] [Amplitude et fréquence locales (Havlicek, 1996)] [Histogrammes spectraux (Yuan, 2015)]

> [Champ de Markov (Geman, 1984)] [Contours actifs (Chan, 2001)] [Variation Totale et Seuillage (Cai, 2013)]

Introduction Caractérisation de texture (

Construction de fonctio 00 Algorithme de minimisation accél 000000000000000

### Plan de l'exposé

#### 1. Caractérisation de textures

- ightarrow attributs fractals
  - ▶ variance locale  $\sigma^2$ 
    - régularité locale h

2. Construction de fonctionnelles

- $\rightarrow$  moindres carrés pénalisés
  - contours libres
  - contours co-localisés

#### 3. Algorithme de minimisation accéléré

[Filtres de Gabor (Dunn, 1995)] [Amplitude et fréquence locales (Havlicek, 1996)] [Histogrammes spectraux (Yuan, 2015)]

> [Champ de Markov (Geman, 1984)] [Contours actifs (Chan, 2001)] [Variation Totale et Seuillage (Cai, 2013)]

[Forward-backward (Combettes, 2005)] [FISTA (Beck, 2009)] [Primal-dual (Chambolle, 2011)] Introduction Caractérisation de texture 0000 0000

OO

### Plan de l'exposé

#### 1. Caractérisation de textures

- ightarrow attributs fractals
  - ▶ variance locale  $\sigma^2$ 
    - régularité locale h

#### 2. Construction de fonctionnelles

- ightarrow moindres carrés pénalisés
  - contours libres
  - contours co-localisés

#### 3. Algorithme de minimisation accéléré

- ightarrow algorithmes proximaux scindés
  - calcul des opérateurs proximaux
  - accélération par forte-convexité

[Filtres de Gabor (Dunn, 1995)] [Amplitude et fréquence locales (Havlicek, 1996)] [Histogrammes spectraux (Yuan, 2015)]

> [Champ de Markov (Geman, 1984)] [Contours actifs (Chan, 2001)] [Variation Totale et Seuillage (Cai, 2013)]

[Forward-backward (Combettes, 2005)] [FISTA (Beck, 2009)] [Primal-dual (Chambolle, 2011)]

ré Réglage des hyperparamètres Conclus
 00000000000000 000

### Plan de l'exposé

#### 1. Caractérisation de textures

- ightarrow attributs fractals
  - > variance locale  $\sigma^2$ 
    - régularité locale h

#### 2. Construction de fonctionnelles

- ightarrow moindres carrés pénalisés
  - contours libres
  - contours co-localisés

#### 3. Algorithme de minimisation accéléré

- $\rightarrow$  algorithmes proximaux scindés
  - calcul des opérateurs proximaux
  - accélération par forte-convexité

#### 4. Réglage des hyperparamètres

[Filtres de Gabor (Dunn, 1995)] [Amplitude et fréquence locales (Havlicek, 1996)] [Histogrammes spectraux (Yuan, 2015)]

> [Champ de Markov (Geman, 1984)] [Contours actifs (Chan, 2001)] [Variation Totale et Seuillage (Cai, 2013)]

[Forward-backward (Combettes, 2005)] [FISTA (Beck, 2009)] [Primal-dual (Chambolle, 2011)]

> [SURE (Stein, 1981)] [SURE DFMC (Ramani, 2008)] [GSURE (Eldar, 2008)] [SUGAR (Deledalle, 2014)]

roduction	Caractérisation	de	texture	
00	0000			

Int

### Plan de l'exposé

#### 1. Caractérisation de textures

- ightarrow attributs fractals
  - ▶ variance locale  $\sigma^2$ 
    - régularité locale h

#### 2. Construction de fonctionnelles

- ightarrow moindres carrés pénalisés
  - contours libres
  - contours co-localisés

#### 3. Algorithme de minimisation accéléré

- ightarrow algorithmes proximaux scindés
  - calcul des opérateurs proximaux
  - accélération par forte-convexité

#### 4. Réglage des hyperparamètres

- $\rightarrow$  SURE avec bruit gaussien corrélé
  - erreur d'estimation projetée
  - ▶ minimisation par quasi-Newton → SUGAR généralisé

[Filtres de Gabor (Dunn, 1995)] [Amplitude et fréquence locales (Havlicek, 1996)] [Histogrammes spectraux (Yuan, 2015)]

> [Champ de Markov (Geman, 1984)] [Contours actifs (Chan, 2001)] [Variation Totale et Seuillage (Cai, 2013)]

[Forward-backward (Combettes, 2005)] [FISTA (Beck, 2009)] [Primal-dual (Chambolle, 2011)]

> [SURE (Stein, 1981)] [SURE DFMC (Ramani, 2008)] [GSURE (Eldar, 2008)] [SUGAR (Deledalle, 2014)]

### Modèle monofractal par morceaux





#### **Attributs fractals**

• variance  $\sigma^2$ 

amplitude des variations





### Attributs fractals

variance  $\sigma^2$ 

amplitude des variations

régularité locale h

invariance d'échelle





### Attributs fractals

variance  $\sigma^2$ 

amplitude des variations

régularité locale h

invariance d'échelle

$$|f(x) - f(y)| \le \sigma(x)|x - y|^{h(x)}$$



#### Attributs fractals

variance  $\sigma^2$ 

amplitude des variations

régularité locale h

invariance d'échelle

$$|f(x) - f(y)| \le \sigma(x)|x - y|^{h(x)}$$

 $h(x) \equiv h_1 = 0.9$   $h(x) \equiv h_2 = 0.3$ 



#### Attributs fractals

• variance  $\sigma^2$ 

amplitude des variations

régularité locale *h* invariance d'échelle

$$|f(x) - f(y)| \le \sigma(x)|x - y|^{h(x)}$$

 $h(x) \equiv h_1 = 0.9$   $h(x) \equiv h_2 = 0.3$ 

#### Segmentation

 $\blacktriangleright$  h et  $\sigma^2$  constants par morceaux



$$(\sigma_1^2,h_1)$$

### Attributs fractals

• variance  $\sigma^2$ 

amplitude des variations

régularité locale h

invariance d'échelle

$$|f(x) - f(y)| \le \sigma(x)|x - y|^{h(x)}$$

 $h(x) \equiv h_1 = 0.9$   $h(x) \equiv h_2 = 0.3$ 

#### Segmentation

- $\blacktriangleright$  h et  $\sigma^2$  constants par morceaux
- région  $\Omega_k$  caractérisée par  $(h_k, \sigma_k^2)$



$$(\sigma_1^2,h_1)$$

### Analyse multi-échelle

Image texturée



### Analyse multi-échelle

#### Image texturée







### Analyse multi-échelle

Image texturée













 $a = 2^5$ 

### Analyse multi-échelle

Image texturée

Maximum local des coefficients d'ondelettes :  $\mathcal{L}_{a,.}$ 





Proposition (Jaffard, 2004), (Wendt, 2008)

$$\log \left( \mathcal{L}_{a,\cdot} \right) \underset{a \to 0}{\simeq} \log(a)_{\substack{\textbf{r} \notin \text{gularit} \notin \\ (\text{variance})}} + \underset{(\text{variance})}{\textbf{v}}$$

Caractérisation de texture Construction de fonctionnelles Algorithme de minimisation accéléré Réglage des hyperparamètres Conclusion

### Analyse multi-échelle

Image texturée









### Analyse multi-échelle

Image texturée





Proposition (Jaffard, 2004), (Wendt, 2008)  

$$\log (\mathcal{L}_{a,.}) \underset{a \to 0}{\simeq} \log(a) \frac{\mathbf{h}}{r^{\text{égularité}}} + \underbrace{\mathbf{v}}_{\substack{\alpha \log(\sigma^{2}) \\ (\text{variance})}}$$



Caractérisation de texture Construction de fonctionnelles Algorithme de minimisation accéléré Réglage des hyperparamètres Conclusion

### Analyse multi-échelle

Image texturée









Caractérisation de texture Construction de fonctionnelles Algorithme de minimisation accéléré Réglage des hyperparamètres Conclusion

### Analyse multi-échelle

Image texturée









Caractérisation de texture Construction de fonctionnelles Algorithme de minimisation accéléré Réglage des hyperparamètres Conclusion

### Analyse multi-échelle

Image texturée








# Analyse multi-échelle

Image texturée

Maximum local des coefficients d'ondelettes :  $\mathcal{L}_{a,.}$ 





Proposition (Jaffard, 2004), (Wendt, 2008)  

$$\log (\mathcal{L}_{a,.}) \underset{a \to 0}{\simeq} \log(a) \underset{\text{régularité}}{h} + \underset{\substack{\alpha \log(\sigma^{2}) \\ (\text{variance})}}{v}$$



# Estimation directe ponctuelle

**Régression linéaire** 

$$\log (\mathcal{L}_{a,\cdot}) \simeq \log(a) \frac{h}{r + v} + \frac{v}{\cos(\sigma^2)}$$

#### Image texturée



#### Estimation directe ponctuelle

Régression linéaire $\log (\mathcal{L}_{a,\cdot}) \simeq \log(a) \frac{h}{régularité} + \frac{v}{\propto \log(\sigma^2)}$ 

$$\left(\widehat{\pmb{h}}^{ ext{RL}}, \widehat{\pmb{
u}}^{ ext{RL}}
ight) = \operatorname*{argmin}_{\pmb{h}, \pmb{
u}} \sum_{a=a_{ ext{min}}}^{a_{ ext{max}}} \left\|\log\left(\mathcal{L}_{a, \cdot}
ight) - \log(a)\pmb{h} - \pmb{
u}
ight\|^2$$

Image texturée



#### Estimation directe ponctuelle

**Régression linéaire** 

$$\log\left(\mathcal{L}_{a,\cdot}
ight)\simeq \log(a)rac{m{h}}{
m régularitm{e}}+rac{m{v}}{lpha\log(\sigma^2)}$$

$$\left(\widehat{\pmb{h}}^{ ext{RL}}, \widehat{\pmb{
u}}^{ ext{RL}}
ight) = \operatorname*{argmin}_{\pmb{h}, \pmb{
u}} \sum_{\pmb{a}=\pmb{a}_{ ext{min}}}^{a_{ ext{max}}} \|\log\left(\mathcal{L}_{\pmb{a}, \cdot}
ight) - \log(\pmb{a})\pmb{h} - \pmb{
u}\|^2$$

Image texturée



Régularité locale  $\widehat{\pmb{h}}^{ ext{RL}}$ 





Puissance locale  $\widehat{\pmb{v}}^{\mathrm{RL}}$ 

# Estimation directe ponctuelle



variance d'estimation élevée

#### Régularisation a posteriori

#### Régression linéaire $\widehat{\pmb{h}}^{\rm RL}$



# Régularisation a posteriori

Lissage par filtrage (linéaire)

$$\left(\mathbf{I} + \lambda \mathbf{D}^{\top} \mathbf{D}\right)^{-1} \hat{\mathbf{h}}^{\mathrm{RL}}$$

Régression linéaire  $\widehat{\pmb{h}}^{\mathrm{RL}}$ 



Lissage



#### Régularisation a posteriori

Lissage par filtrage (linéaire)

$$\left(\mathbf{I} + \lambda \mathbf{D}^{\top} \mathbf{D}\right)^{-1} \hat{\mathbf{h}}^{\mathrm{RL}}$$

Régression linéaire  $\widehat{\pmb{h}}^{\mathrm{RL}}$ 



Débruitage ROF (non linéaire)

$$\underset{\boldsymbol{h}}{\operatorname{argmin}} \|\boldsymbol{h} - \widehat{\boldsymbol{h}}^{\mathrm{RL}}\|^2 + \lambda \|\boldsymbol{\mathsf{D}}\boldsymbol{h}\|_{2,1}$$

Lissage





ROF

# Régularisation a posteriori

Lissage par filtrage (linéaire)

$$\left(\mathbf{I} + \lambda \mathbf{D}^{\top} \mathbf{D}\right)^{-1} \widehat{\boldsymbol{h}}^{\mathrm{RL}}$$

Débruitage ROF (non linéaire)

$$\underset{\pmb{h}}{\operatorname{argmin}} \ \| \pmb{h} - \widehat{\pmb{h}}^{\operatorname{RL}} \|^2 + \lambda \| \mathbf{D} \pmb{h} \|_{2,1}$$

ROF





 $\rightarrow$  cumul de la variance d'estimation et du biais de régularisation

$$\sum_{a} \frac{\|\log \mathcal{L}_{a,.} - \log(a)h - \mathbf{v}\|^2}{\underset{\rightarrow}{\text{Moindres Carrés}}}$$

Introduction Caractérisation de texture Construction de fonctionnelles Algorithme de minimisation accéléré Réglage des hyperparamètres Conclusion



 $\lambda \mathcal{Q}(\mathbf{D}\boldsymbol{h},\mathbf{D}\boldsymbol{v};\alpha)$ 

Variation Totale  $\rightarrow$  favorise la constance par morceaux





#### Fonctionnelles à contours libres et à contours co-localisés



**Différences finies**  $D_1 x$  (horizontales),  $D_2 x$  (verticales) en chaque pixel



**Différences finies**  $\mathbf{D}\mathbf{x} = [\mathbf{D}_1\mathbf{x}, \mathbf{D}_2\mathbf{x}]$ 

<u>libres</u>:  $\boldsymbol{h}$ ,  $\boldsymbol{v}$  sont indépendamment constantes par morceaux  $\mathcal{Q}_{L}(\mathbf{D}\boldsymbol{h},\mathbf{D}\boldsymbol{v};\alpha) = \alpha \|\mathbf{D}\boldsymbol{h}\|_{2,1} + \|\mathbf{D}\boldsymbol{v}\|_{2,1}$ 



**Différences finies**  $\mathbf{D}\mathbf{x} = [\mathbf{D}_1\mathbf{x}, \mathbf{D}_2\mathbf{x}]$ 

<u>libres</u>: *h*, *v* sont indépendamment constantes par morceaux  $Q_L(\mathbf{D}h, \mathbf{D}v; \alpha) = \alpha \|\mathbf{D}h\|_{2,1} + \|\mathbf{D}v\|_{2,1}$ 

<u>co-localisés</u> : h, v sont concomitamment constantes par morceaux  $Q_{C}(Dh, Dv; \alpha) = \|[\alpha Dh, Dv]\|_{2,1}$ 



Contours disjoints



Contours communs





Contours disjoints



Contours communs



 $\boldsymbol{h} \in \mathbb{R}^{2 \times 2}$   $\boldsymbol{v} \in \mathbb{R}^{2 \times 2}$ 

 $Q_L(\mathbf{D}h,\mathbf{D}v;1)=4$ 

00

Introduction Caractérisation de texture Construction de fonctionnelles Algorithme de minimisation accéléré Réglage des hyperparamètres Conclusion

# Fonctionnelles à contours libres et à contours co-localisés







 $\boldsymbol{h} \in \mathbb{R}^{2 \times 2}$   $\boldsymbol{v} \in \mathbb{R}^{2 \times 2}$ 

 $Q_L(\mathbf{D}h,\mathbf{D}v;1)=4$  $\mathcal{Q}_{\mathcal{C}}(\mathbf{D}h,\mathbf{D}v;1)=2\sqrt{2}\simeq 2.8$ 11

•0000000000000

# Minimisation de fonctionnelle

$$\underset{h,v}{\text{minimiser}} \sum_{a} \frac{\|\log \mathcal{L}_{a,.} - \log(a)h - v\|^2}{\text{Moindres Carrés}} + \frac{\lambda \mathcal{Q}(\mathsf{D}h, \mathsf{D}v; \alpha)}{\text{Variation Totale}}$$

•00000000000000

#### Minimisation de fonctionnelle



► descente de gradient  $\mathbf{x}^{n+1} = \mathbf{x}^n - \tau \nabla \varphi(\mathbf{x}^n)$ 

# Minimisation de fonctionnelle



• descente de gradient  $\mathbf{x}^{n+1} = \mathbf{x}^n - \tau \nabla \varphi(\mathbf{x}^n)$ 

descente de sous-gradient implicite : algorithme du point proximal  $\mathbf{x}^{n+1} = \mathbf{x}^n - \mathbf{u}^n, \ \mathbf{u}^n \in \partial \varphi(\mathbf{x}^{n+1}) \iff \mathbf{x}^{n+1} = \operatorname{prox}_{\tau \circ \sigma}(\mathbf{x}^n)$ 

# Minimisation de fonctionnelle



• descente de gradient 
$$\mathbf{x}^{n+1} = \mathbf{x}^n - \tau \nabla \varphi(\mathbf{x}^n)$$

descente de sous-gradient implicite : algorithme du point proximal

$$\mathbf{x}^{n+1} = \mathbf{x}^n - \mathbf{u}^n, \ \mathbf{u}^n \in \partial \varphi(\mathbf{x}^{n+1}) \ \Leftrightarrow \ \mathbf{x}^{n+1} = \operatorname{prox}_{\tau \varphi}(\mathbf{x}^n)$$

#### ▶ algorithme proximal scindé

$$\begin{aligned} \mathbf{y}^{n+1} &= \operatorname{prox}_{\sigma(\lambda \mathcal{Q})^*} \left( \mathbf{y}^n + \sigma \mathbf{D} \bar{\mathbf{x}}^n \right) \\ \mathbf{x}^{n+1} &= \operatorname{prox}_{\tau \parallel \mathcal{L} - \mathbf{\Phi} \cdot \parallel_2^2} \left( \mathbf{x}^n - \tau \mathbf{D}^\top \mathbf{y}^{n+1} \right), \quad \mathbf{\Phi} : (\mathbf{h}, \mathbf{v}) \mapsto \{ \log(\mathbf{a})\mathbf{h} + \mathbf{v} \}_{\mathbf{a}} \\ \bar{\mathbf{x}}^{n+1} &= 2\mathbf{x}^{n+1} - \mathbf{x}^n \end{aligned}$$

# Minimisation de fonctionnelle



• descente de gradient 
$$\mathbf{x}^{n+1} = \mathbf{x}^n - \tau \nabla \varphi(\mathbf{x}^n)$$

descente de sous-gradient implicite : algorithme du point proximal

$$\mathbf{x}^{n+1} = \mathbf{x}^n - \mathbf{u}^n, \ \mathbf{u}^n \in \partial \varphi(\mathbf{x}^{n+1}) \ \Leftrightarrow \ \mathbf{x}^{n+1} = \operatorname{prox}_{\tau \varphi}(\mathbf{x}^n)$$

► algorithme proximal scindé  

$$\mathbf{y}^{n+1} = \operatorname{prox}_{\sigma(\lambda Q)^*} (\mathbf{y}^n + \sigma \mathbf{D} \bar{\mathbf{x}}^n)$$
  
 $\mathbf{x}^{n+1} = \operatorname{prox}_{\tau \parallel \mathcal{L} - \Phi \cdot \parallel_2^2} (\mathbf{x}^n - \tau \mathbf{D}^\top \mathbf{y}^{n+1}), \quad \Phi : (\mathbf{h}, \mathbf{v}) \mapsto \{\log(a)\mathbf{h} + \mathbf{v}\}_a$   
 $\bar{\mathbf{x}}^{n+1} = 2\mathbf{x}^{n+1} - \mathbf{x}^n$ 

#### Calcul des opérateurs proximaux





**Ex. Norme mixte :** pour  $\mathbf{z} = [\mathbf{z}_1; \ldots,; \mathbf{z}_l]$ 

$$\mathcal{Q}(\boldsymbol{z}) = \|\boldsymbol{z}\|_{2,1} = \sum_{\underline{n}\in\Omega} \sqrt{\sum_{i=1}^{l} z_i^2(\underline{n})} = \sum_{\underline{n}\in\Omega} \|\boldsymbol{z}(\underline{n})\|_2$$



**Ex. Norme mixte :** pour  $\mathbf{z} = [\mathbf{z}_1; \ldots,; \mathbf{z}_l]$ 

$$\mathcal{Q}(oldsymbol{z}) = \|oldsymbol{z}\|_{2,1} = \sum_{\underline{n}\in\Omega} \sqrt{\sum_{i=1}^{l} z_i^2(\underline{n})} = \sum_{\underline{n}\in\Omega} \|oldsymbol{z}(\underline{n})\|_2$$

$$\boldsymbol{p} = \operatorname{prox}_{\lambda \parallel \cdot \parallel_{2,1}}(\boldsymbol{z}) \quad \Leftrightarrow \quad p_i(\underline{n}) = \max\left(0, 1 - \frac{\lambda}{\parallel \boldsymbol{z}(\underline{n}) \parallel_2}\right) \boldsymbol{z}_i(\underline{n})$$



Moindres carrés :  $\|\log \mathcal{L} - \Phi(h, \mathbf{v})\|^2$ ,  $\Phi : (h, \mathbf{v}) \mapsto \{\log(a)h + \mathbf{v}\}_a$ 



Moindres carrés :  $\|\log \mathcal{L} - \Phi(h, \mathbf{v})\|^2$ ,  $\Phi : (h, \mathbf{v}) \mapsto \{\log(a)h + \mathbf{v}\}_a$ 

Proposition (Pascal, 2019)

$$(\widetilde{\boldsymbol{h}},\widetilde{\boldsymbol{v}}) = \operatorname{prox}_{\tau \parallel \mathcal{L} - \boldsymbol{\Phi} \cdot \parallel^{2}}(\boldsymbol{h}, \boldsymbol{v}) \Longleftrightarrow (\widetilde{\boldsymbol{h}}, \widetilde{\boldsymbol{v}}) = \left(\mathbf{I} + \tau \boldsymbol{\Phi}^{\top} \boldsymbol{\Phi}\right)^{-1} \left((\boldsymbol{h}, \boldsymbol{v}) + \tau \boldsymbol{\Phi}^{\top} \log \mathcal{L}\right)$$



Moindres carrés : 
$$\|\log \mathcal{L} - \Phi(h, v)\|^2$$
,  $\Phi : (h, v) \mapsto \{\log(a)h + v\}_a$ 

#### Proposition (Pascal, 2019)

Soit 
$$S_m = \sum_{a} \log^m(a)$$
,  $\mathcal{D} = (1 + \tau S_2)(1 + \tau S_0) - \tau^2 S_1^2$ ,  
 $\mathcal{T} = \sum_{a} \log \mathcal{L}_a$  et  $\mathcal{G} = \sum_{a} \log(a) \log \mathcal{L}_a$ , alors  
 $(\tilde{h}, \tilde{v}) = \operatorname{prox}_{\tau \parallel \mathcal{L} - \Phi \cdot \parallel^2}(h, v) \iff (\tilde{h}, \tilde{v}) = (\mathbf{I} + \tau \Phi^\top \Phi)^{-1} ((h, v) + \tau \Phi^\top \log \mathcal{L})$   
 $\iff \begin{cases} \tilde{h} = \mathcal{D}^{-1} ((1 + \tau S_0)(\tau \mathcal{G} + h) - \tau S_1(\tau \mathcal{T} + v)) \\ \tilde{v} = \mathcal{D}^{-1} ((1 + \tau S_2)(\tau \mathcal{T} + v) - \tau S_1(\tau \mathcal{G} + h)) \end{cases}$ 

# Algorithme accéléré par forte-convexité



15

# Algorithme accéléré par forte-convexité



# Propriétés de convexité

$$\begin{array}{ll} \underset{h,\mathbf{v}}{\text{minimiser}} & \sum_{a} \frac{\|\log \mathcal{L}_{a,.} - \log(a)h - \mathbf{v}\|^2}{\text{Moindres Carrés}} & + & \lambda \frac{\mathcal{Q}(\mathbf{D}h, \mathbf{D}\mathbf{v}; \alpha)}{\text{Variation Totale}} \\ & & & & \\ & & & \\ & & & \\ & & & \\ & & & \\ & & & \\ & & & \\ & & & \\ & & & & \\ & & & \\ & & & & \\ & & & \\ & & & & \\ & & & \\ & & & \\ & & & \\ & & & \\ & & & \\ & & & & \\ & & & \\ & & & \\ & & & \\ & & & & \\ & & & \\ & & & \\ & & & \\ & & & \\ & & & \\ & & & \\ & & & \\$$

16

# Propriétés de convexité



#### Forte convexité

•  $\varphi \mu$ -fortement convexe ssi  $\varphi - \frac{\mu}{2} \| \cdot \|^2$  convexe





# Propriétés de convexité



#### Forte convexité

- $\varphi \mu$ -fortement convexe ssi  $\varphi \frac{\mu}{2} \|\cdot\|^2$  convexe
- $\varphi \ C^2$  de hessienne  $H\varphi \succeq 0 \implies \mu = \min \operatorname{Sp}(H\varphi)$

# Propriétés de convexité



#### Forte convexité

- $\varphi \mu$ -fortement convexe ssi  $\varphi \frac{\mu}{2} \|\cdot\|^2$  convexe
- $\varphi \ C^2$  de hessienne  $H\varphi \succeq 0 \implies \mu = \min \operatorname{Sp}(H\varphi)$

#### Proposition (Pascal, 2019)

$$\sum \|\log \mathcal{L} - \log(a)\boldsymbol{h} - \boldsymbol{v}\|^2 \text{ est } \boldsymbol{\mu} \text{-fortement convexe.}$$

$$a_{\min} = 2^1, \quad a_{\max} \quad 2^2 \quad 2^3 \quad 2^4 \quad 2^5 \quad 2^6$$
  
 $\mu = \min \operatorname{Sp} \left( 2 \Phi^\top \Phi \right) \quad 0.29 \quad \mathbf{0.72} \quad 1.20 \quad 1.69 \quad 2.20$ 

# Algorithme accéléré par forte-convexité



Algorithme primal-dual accéléré (Chambolle, 2011)

for 
$$n = 0, 1, ...$$
  
 $\mathbf{y}^{n+1} = \operatorname{prox}_{\sigma_n(\lambda Q)^*} (\mathbf{y}^n + \sigma_n \mathbf{D} \bar{\mathbf{x}}^n)$   
 $\mathbf{x}^{n+1} = \operatorname{prox}_{\tau_n \parallel \mathcal{L} - \mathbf{\Phi} \cdot \parallel_2^2} \left( \mathbf{x}^n - \tau_n \mathbf{D}^\top \mathbf{y}^{n+1} \right)$   
 $\theta_n = \sqrt{1 + 2\mu\tau_n}, \quad \tau_{n+1} = \tau_n/\theta_n, \quad \sigma_{n+1} = \theta_n \sigma_n$   
 $\bar{\mathbf{x}}^{n+1} = \mathbf{x}^{n+1} + \theta_n^{-1} (\mathbf{x}^{n+1} - \mathbf{x}^n)$
### Algorithme accéléré par forte-convexité

$$\begin{array}{ll} \underset{h,v}{\operatorname{minimiser}} & \sum_{a} \frac{\|\log \mathcal{L}_{a,.} - \log(a)h - v\|^2}{\operatorname{Moindres Carrés}} & + & \lambda \frac{\mathcal{Q}(\mathsf{D}h, \mathsf{D}v; \alpha)}{\operatorname{Variation Totale}} \\ & & & & \\ & & & \\ & & & & \\ & & & \\ & & & & \\ & & & \\ & & & & \\ & & & \\ & & & & \\ & & & \\ & & & \\ & & & \\ & & & & \\ & & & \\ & & & \\ & & & & \\ & & & & \\ & & & \\ & & & \\ & & & \\ & & & \\ & & & \\ & & & \\ & & &$$

$$\delta$$
 : gap de dualité,  $\delta({m x}^n,{m y}^n) \underset{n o \infty}{\longrightarrow} 0$ 



### Segmentation par seuillage itéré

$$\underset{h,\mathbf{v}}{\text{minimiser}} \sum_{a} \frac{\|\log \mathcal{L}_{a,.} - \log(a)h - \mathbf{v}\|^2}{\text{Moindres Carrés}} +$$

 $\lambda \mathcal{Q}(\mathbf{D}\boldsymbol{h},\mathbf{D}\boldsymbol{v};\alpha)$ 

Variation Totale

#### Image texturée



### Segmentation par seuillage itéré

$$\begin{array}{c} \min_{h,v} \sum_{a} \frac{\|\log \mathcal{L}_{a,.} - \log(a)h - v\|^2}{|\text{Moindres Carrés}} + \lambda \frac{\mathcal{Q}(\mathsf{D}h,\mathsf{D}v;\alpha)}{|\text{Variation Totale}} \\ \\ \text{Image texturée} \quad \text{Rég. lin. } \hat{h}^{\mathrm{RL}} \\ \\ \hline \end{array} \end{array}$$

### Segmentation par seuillage itéré



### Segmentation par seuillage itéré



### Méthodes de l'état-de-l'art en segmentation de texture

**ROF-Seuillé sur**  $\hat{h}^{RL}$ (Nafornita, 2014), (Pustelnik, 2016)

 $\underset{\boldsymbol{h}}{\operatorname{argmin}} \|\boldsymbol{h} - \hat{\boldsymbol{h}}^{\mathrm{RL}}\|^2 + \lambda \|\boldsymbol{\mathsf{D}}\boldsymbol{h}\|_{2,1}$ 

Rég. lin.







S'appuie uniquement sur la régularité **h**.

<sup>†</sup>https://sites.google.com/site/factorizationsegmentation/

Introduction Caractérisation de texture Construction de fonctionnelles Algorithme de minimisation accéléré

### Méthodes de l'état-de-l'art en segmentation de texture

**ROF-Seuillé sur**  $\hat{h}^{\text{RL}}$ (Nafornita, 2014), (Pustelnik, 2016)

 $\operatorname{argmin} \|\boldsymbol{h} - \widehat{\boldsymbol{h}}^{\mathrm{RL}}\|^2 + \lambda \|\boldsymbol{\mathsf{D}}\boldsymbol{h}\|_{2,1}$ h

Rég. lin.







S'appuie uniquement sur la régularité **h**.

Segmentation par factorisation matricielle<sup>†</sup> (Yuan, 2015)

histogrammes locaux (i)



(ii) factorisation matricielle



Fig. 2. Scatterplot of features in subspace. (a) Scatterplot of features projected onto the 3-d subspace. (b) Scatterplot after removing features with high edgeness.

<sup>†</sup>https://sites.google.com/site/factorizationsegmentation/

### Performances comparées sur des textures synthétiques

Synthèse de texture monofractale par morceaux (Pascal, 2019)

• masque :  $\Omega = \Omega_1 \sqcup \Omega_2$ ,

• attributs : 
$$(\bar{h}_k, \bar{\sigma}_k^2)_{k=1,2}$$



### Performances comparées sur des textures synthétiques

Synthèse de texture monofractale par morceaux (Pascal, 2019)

- masque :  $\Omega = \Omega_1 \sqcup \Omega_2$ ,
- attributs :  $(\bar{h}_k, \bar{\sigma}_k^2)_{k=1,2}$
- Ex.  $\bar{h}_1 = 0.5, \ \bar{\sigma}_1^2 = 0.6$  $\bar{h}_2 = 0.6, \ \bar{\sigma}_2^2 = 0.7$



### Performances comparées sur des textures synthétiques

Synthèse de texture monofractale par morceaux (Pascal, 2019)

- masque :  $\Omega = \Omega_1 \sqcup \Omega_2$ ,
- attributs :  $(ar{h}_k,ar{\sigma}_k^2)_{k=1,2}$
- Ex.  $\bar{h}_1 = 0.5, \ \bar{\sigma}_1^2 = 0.6$  $\bar{h}_2 = 0.6, \ \bar{\sigma}_2^2 = 0.7$



Performances de segmentation moyennées sur 5 réalisations





# Faible activité : $Q_{\rm G} = 300 \,\mathrm{mL}/\mathrm{min}$ - $Q_{\rm L} = 300 \,\mathrm{mL}/\mathrm{min}$



Liquide :  $h_{\rm L} = 0.4$ 

Gaz :  $h_{\rm G} = 0.9$ 

# Faible activité : $Q_{\rm G} = 300 \,\mathrm{mL}/\mathrm{min}$ - $Q_{\rm L} = 300 \,\mathrm{mL}/\mathrm{min}$



Liquide : 
$$h_{
m L}=0.4$$
  $\sigma_{
m sombre}^2=10^{-2}$ 

Gaz :  $h_{\rm G} = 0.9$ 



Liquide : 
$$h_{\rm L}=0.4$$
  $\sigma_{\rm sombre}^2=10^{-2}$   
Gaz :  $h_{\rm G}=0.9$ 



Liquide : 
$$h_{\rm L} = 0.4$$
 $\sigma_{\rm sombre}^2 = 10^{-2}$ Gaz :  $h_{\rm G} = 0.9$  $\sigma_{\rm sombre}^2 = 10^{-2}$  (bulles sombres)



0000000000000000

# Transition : $Q_{\rm G} = 400 \,\mathrm{mL}/\mathrm{min}$ - $Q_{\rm L} = 700 \,\mathrm{mL}/\mathrm{min}$



000000000000000

# Forte activité : $Q_{ m G} = 1200 { m mL}/{ m min}$ - $Q_{ m L} = 300 { m mL}/{ m min}$



000000000000000



#### Écoulement multiphasiques en milieu poreux Laboratoire de Physique, ENS Lyon, V. Vidal, T. Busser, (M. Serres, IFPEN)

Fraction de gaz dans la cellule







$$\left(\widehat{h},\widehat{v}\right)(\mathcal{L};\lambda,\alpha) = \operatorname*{argmin}_{h,v} \sum_{a} \|\log \mathcal{L}_{a,.} - \log(a)h - v\|^2 + \lambda \mathcal{Q}(\mathsf{D}h,\mathsf{D}v;\alpha)$$

$$\left(\widehat{\boldsymbol{h}},\widehat{\boldsymbol{v}}\right)(\mathcal{L};\lambda,\alpha) = \operatorname*{argmin}_{\boldsymbol{h},\boldsymbol{v}} \sum_{\boldsymbol{a}} \|\log \mathcal{L}_{\boldsymbol{a},\cdot} - \log(\boldsymbol{a})\boldsymbol{h} - \boldsymbol{v}\|^2 + \lambda \mathcal{Q}(\mathsf{D}\boldsymbol{h},\mathsf{D}\boldsymbol{v};\alpha)$$

Rég. lin.  $\widehat{\mathbf{h}}^{\mathrm{RL}}$  $(\lambda; \alpha) = (0; 0)$ 



$$\left(\widehat{h},\widehat{v}
ight)(\mathcal{L};\lambda,lpha) = \operatorname*{argmin}_{h,v} \sum_{a} \|\log \mathcal{L}_{a,.} - \log(a)h - v\|^2 + \lambda \mathcal{Q}(\mathsf{D}h,\mathsf{D}v;\alpha)$$

Estimée  $\hat{h}^{C}$  à contours co-localisés Rég. lin.  $\hat{h}^{RL}$  $(\lambda; \alpha) = (0; 0)$   $(\lambda, \alpha) = (0,5; 0,5)$ 



trop faible

$$\left(\widehat{h},\widehat{v}
ight)(\mathcal{L};\lambda,lpha) = \operatorname*{argmin}_{h,v} \sum_{a} \|\log \mathcal{L}_{a,.} - \log(a)h - v\|^2 + \lambda \mathcal{Q}(\mathsf{D}h,\mathsf{D}v;lpha)$$

Rég. lin.  $\hat{h}^{RL}$ Estimée  $\hat{\mathbf{h}}^{\mathrm{C}}$  à contours co-localisés  $(\lambda; \alpha) = (0; 0)$   $(\lambda, \alpha) = (0,5; 0,5)$  $(\lambda; \alpha) = (500; 500)$ 



trop faible



trop grand

$$\left(\widehat{h},\widehat{v}
ight)(\mathcal{L};\lambda,lpha) = \operatorname*{argmin}_{h,v} \sum_{a} \|\log \mathcal{L}_{a,.} - \log(a)h - v\|^2 + \lambda \mathcal{Q}(\mathsf{D}h,\mathsf{D}v;lpha)$$

Rég. lin.  $\hat{h}^{RL}$ Estimée  $\hat{\mathbf{h}}^{\mathrm{C}}$  à contours co-localisés

 $(\lambda; \alpha) = (0; 0)$   $(\lambda, \alpha) = (0,5; 0,5)$   $(\lambda^{\dagger}, \alpha^{\dagger}) = (11,5; 0,8)$   $(\lambda; \alpha) = (500; 500)$ 



$$\left(\widehat{h},\widehat{v}\right)(\mathcal{L};\lambda,\alpha) = \operatorname*{argmin}_{h,v} \sum_{a} \|\log \mathcal{L}_{a,.} - \log(a)h - v\|^2 + \lambda \mathcal{Q}(\mathsf{D}h,\mathsf{D}v;\alpha)$$

Rég. lin.  $\hat{h}^{RL}$ Estimée  $\hat{\mathbf{h}}^{C}$  à contours co-localisés

 $(\lambda; \alpha) = (0; 0)$   $(\lambda, \alpha) = (0,5; 0,5)$   $(\lambda^{\dagger}, \alpha^{\dagger}) = (11,5; 0,8)$   $(\lambda; \alpha) = (500; 500)$ 



Que signifie optimal?

$$\left(\widehat{h},\widehat{v}
ight)(\mathcal{L};\lambda,lpha) = \operatorname*{argmin}_{h,v} \sum_{a} \|\log \mathcal{L}_{a,.} - \log(a)h - v\|^2 + \lambda \mathcal{Q}(\mathsf{D}h,\mathsf{D}v;lpha)$$

Rég. lin.  $\hat{h}^{RL}$ Estimée  $\hat{\mathbf{h}}^{C}$  à contours co-localisés

 $(\lambda; \alpha) = (0; 0)$   $(\lambda, \alpha) = (0,5; 0,5)$   $(\lambda^{\dagger}, \alpha^{\dagger}) = (11,5; 0,8)$   $(\lambda; \alpha) = (500; 500)$ 



Réglage des paramètres (Recherche systématique)

$$\left(\widehat{\mathbf{h}}, \widehat{\mathbf{v}}\right) (\mathcal{L}; \lambda, \alpha) = \underset{h, \mathbf{v}}{\operatorname{argmin}} \sum_{a} \|\log \mathcal{L}_{a, \cdot} - \log(a)\mathbf{h} - \mathbf{v}\|^{2} + \lambda \mathcal{Q}(\mathbf{D}\mathbf{h}, \mathbf{D}\mathbf{v}; \alpha)$$

👖 . UISCIIIIIIIIIIIIII, V . AUXIIIAIIE

# Réglage des paramètres (Recherche systématique)

$$\left( \widehat{\boldsymbol{h}}, \widehat{\boldsymbol{v}} \right) (\boldsymbol{\mathcal{L}}; \lambda, \alpha) = \underset{\boldsymbol{h}, \boldsymbol{v}}{\operatorname{argmin}} \sum_{\boldsymbol{a}} \| \log \boldsymbol{\mathcal{L}}_{\boldsymbol{a}, \cdot} - \log(\boldsymbol{a})\boldsymbol{h} - \boldsymbol{v} \|^2 + \lambda \mathcal{Q}(\boldsymbol{\mathsf{D}}\boldsymbol{h}, \boldsymbol{\mathsf{D}}\boldsymbol{v}; \alpha)$$
  
$$\boldsymbol{h} : discriminant, \ \boldsymbol{v} : auxiliaire$$

 $ar{m{h}}$ : vraie régularité $\mathcal{R}(\lambda, lpha) = \left\| \widehat{m{h}}(\mathcal{L}; \lambda, lpha) - ar{m{h}} \right\|^2$ 

### Réglage des paramètres (Recherche systématique)

$$\widehat{(\boldsymbol{h}, \hat{\boldsymbol{v}})}(\boldsymbol{\mathcal{L}}; \lambda, \alpha) = \underset{\boldsymbol{h}, \boldsymbol{v}}{\operatorname{argmin}} \sum_{\boldsymbol{a}} \|\log \boldsymbol{\mathcal{L}}_{\boldsymbol{a}, \cdot} - \log(\boldsymbol{a})\boldsymbol{h} - \boldsymbol{v}\|^2 + \lambda \mathcal{Q}(\boldsymbol{D}\boldsymbol{h}, \boldsymbol{D}\boldsymbol{v}; \alpha)$$
  
$$\boldsymbol{h} : discriminant, \ \boldsymbol{v} : auxiliaire$$



Réglage des paramètres (Recherche systématique)

$$\left( \widehat{\boldsymbol{h}}, \widehat{\boldsymbol{v}} \right) (\boldsymbol{\mathcal{L}}; \lambda, \alpha) = \underset{\boldsymbol{h}, \boldsymbol{v}}{\operatorname{argmin}} \sum_{\boldsymbol{a}} \| \log \boldsymbol{\mathcal{L}}_{\boldsymbol{a}, \cdot} - \log(\boldsymbol{a})\boldsymbol{h} - \boldsymbol{v} \|^2 + \lambda \mathcal{Q}(\boldsymbol{\mathsf{D}}\boldsymbol{h}, \boldsymbol{\mathsf{D}}\boldsymbol{v}; \alpha)$$
$$\boldsymbol{h} : discriminant, \ \boldsymbol{v} : auxiliaire$$



Introduction Caractérisation de texture Construction de fonctionne 0000 0000 00 Algorithme de minimisation accélé

Réglage des paramètres (Recherche systématique)



Introduction Caractérisation de texture Construction de fonctionne 0000 0000 00 Algorithme de minimisation accélé

Réglage des paramètres (Recherche systématique)

$$\left( \widehat{\boldsymbol{h}}, \widehat{\boldsymbol{v}} \right) (\boldsymbol{\mathcal{L}}; \lambda, \alpha) = \underset{\boldsymbol{h}, \boldsymbol{v}}{\operatorname{argmin}} \sum_{\boldsymbol{a}} \| \log \boldsymbol{\mathcal{L}}_{\boldsymbol{a}, \cdot} - \log(\boldsymbol{a})\boldsymbol{h} - \boldsymbol{v} \|^2 + \lambda \mathcal{Q}(\boldsymbol{\mathsf{D}}\boldsymbol{h}, \boldsymbol{\mathsf{D}}\boldsymbol{v}; \alpha)$$
$$\boldsymbol{h} : discriminant, \ \boldsymbol{v} : auxiliaire$$

**h** : vraie régularité  $\mathcal{R}(\lambda, \alpha) = \left\| \widehat{\boldsymbol{h}}(\mathcal{L}; \lambda, \alpha) - \overline{\boldsymbol{h}} \right\|^2$ 15000  $\log_{10}(\lambda)$ 10000 0 5000-1 -2 -2 2  $\log_{10}(\alpha)$ 



# Stein Unbiased Risk Estimate (Principe) **Observations** $y = \bar{x} + \zeta \in \mathbb{R}^{P}$ , $\bar{x}$ : vérité et $\zeta \sim \mathcal{N}(0, \rho^{2} \mathbf{I})$

Stein Unbiased Risk Estimate (Principe) **Observations**  $y = \bar{x} + \zeta \in \mathbb{R}^{P}$ ,  $\bar{x}$ : vérité et  $\zeta \sim \mathcal{N}(0, \rho^{2} \mathbf{I})$ 

**Estimateur paramétrique**  $(\mathbf{y}; \lambda) \mapsto \hat{\mathbf{x}}(\mathbf{y}; \lambda)$ 

Ex. 
$$\widehat{\mathbf{x}}(\mathbf{y}; \lambda) = \begin{cases} \left(\mathbf{I} + \lambda \mathbf{D}^{\top} \mathbf{D}\right)^{-1} \mathbf{y} & (\text{linéaire}) \\ \operatorname*{argmin}_{\mathbf{x}} \|\mathbf{y} - \mathbf{x}\|^2 + \lambda \mathcal{Q}(\mathbf{D}\mathbf{x}) & (\text{non linéaire}) \end{cases}$$

Stein Unbiased Risk Estimate (Principe) **Observations**  $\mathbf{y} = \bar{\mathbf{x}} + \boldsymbol{\zeta} \in \mathbb{R}^{P}$ ,  $\bar{\mathbf{x}}$ : vérité et  $\boldsymbol{\zeta} \sim \mathcal{N}(\mathbf{0}, \rho^{2}\mathbf{I})$ 

**Estimateur paramétrique**  $(\mathbf{y}; \lambda) \mapsto \widehat{\mathbf{x}}(\mathbf{y}; \lambda)$ 

Ex. 
$$\widehat{\mathbf{x}}(\mathbf{y}; \lambda) = \begin{cases} \left(\mathbf{I} + \lambda \mathbf{D}^{\top} \mathbf{D}\right)^{-1} \mathbf{y} & \text{(linéaire)} \\ \operatorname*{argmin}_{\mathbf{x}} \|\mathbf{y} - \mathbf{x}\|^2 + \lambda \mathcal{Q}(\mathbf{D}\mathbf{x}) & \text{(non linéaire)} \end{cases}$$

Erreur quadratique  $R(\lambda) \triangleq \mathbb{E}_{\mathcal{L}} \| \widehat{\mathbf{x}}(\mathbf{y}; \lambda) - \overline{\mathbf{x}} \|^2 \stackrel{?}{=} \mathbb{E}_{\mathcal{L}} \widehat{R}(\mathbf{y}; \lambda) \overline{\mathbf{x}}$  inconnue
Construction OO

Stein Unbiased Risk Estimate (Principe) Observations  $y = \bar{x} + \zeta \in \mathbb{R}^{P}$ ,  $\bar{x}$ : vérité et  $\zeta \sim \mathcal{N}(\mathbf{0}, \rho^{2}\mathbf{I})$ 

Estimateur paramétrique  $(\mathbf{y}; \lambda) \mapsto \widehat{\mathbf{x}}(\mathbf{y}; \lambda)$ 

Ex. 
$$\widehat{\mathbf{x}}(\mathbf{y}; \lambda) = \begin{cases} \left(\mathbf{I} + \lambda \mathbf{D}^{\top} \mathbf{D}\right)^{-1} \mathbf{y} & (\text{linéaire}) \\ \operatorname*{argmin}_{\mathbf{x}} \|\mathbf{y} - \mathbf{x}\|^2 + \lambda \mathcal{Q}(\mathbf{D}\mathbf{x}) & (\text{non linéaire}) \end{cases}$$

Erreur quadratique  $R(\lambda) \triangleq \mathbb{E}_{\zeta} \| \widehat{\boldsymbol{x}}(\boldsymbol{y}; \lambda) - \overline{\boldsymbol{x}} \|^2 \stackrel{?}{=} \mathbb{E}_{\zeta} \widehat{R}(\boldsymbol{y}; \lambda) \quad \overline{\boldsymbol{x}} \text{ inconnue}$ 

#### Théorème (Stein, 1981)

Soit  $(\boldsymbol{y}; \lambda) \mapsto \widehat{\boldsymbol{x}}(\boldsymbol{y}; \lambda)$  un estimateur de  $\overline{\boldsymbol{x}}$ 

- différentiable au sens faible par rapport à y,
- tel que  $\boldsymbol{\zeta} \mapsto \langle \widehat{\boldsymbol{x}}(\overline{\boldsymbol{x}} + \boldsymbol{\zeta}; \lambda), \boldsymbol{\zeta} \rangle$  est intégrable par rapport à  $\mathcal{N}(\mathbf{0}, \rho^2 \mathbf{I})$ .  $\widehat{R}(\boldsymbol{y}; \lambda) \triangleq \|\widehat{\boldsymbol{x}}(\boldsymbol{y}; \lambda) - \boldsymbol{y}\|^2 + 2\rho^2 \operatorname{tr}(\partial_{\boldsymbol{y}} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \lambda)) - \rho^2 P$  $\Longrightarrow R(\lambda) = \mathbb{E}_{\boldsymbol{\zeta}}[\widehat{R}(\boldsymbol{y}; \lambda)].$

# Stein Unbiased Risk Estimate généralisé

**Observations**  $\mathbf{y} = \mathbf{\Phi} \bar{\mathbf{x}} + \boldsymbol{\zeta} \in \mathbb{R}^{P}, \quad \bar{\mathbf{x}} \in \mathbb{R}^{N}, \ \mathbf{\Phi} : \mathbb{R}^{P \times N} \text{ et } \boldsymbol{\zeta} \sim \mathcal{N}(\mathbf{0}, \boldsymbol{\mathcal{S}})$ 

## Stein Unbiased Risk Estimate généralisé Observations $\mathbf{y} = \mathbf{\Phi} \bar{\mathbf{x}} + \boldsymbol{\zeta} \in \mathbb{R}^{P}, \quad \bar{\mathbf{x}} \in \mathbb{R}^{N}, \ \mathbf{\Phi} : \mathbb{R}^{P \times N} \text{ et } \boldsymbol{\zeta} \sim \mathcal{N}(\mathbf{0}, \boldsymbol{\mathcal{S}})$

Ex. des estimateurs  $\hat{h}(\mathcal{L}; \lambda, \alpha)$  à contours libres ou co-localisés

$$\log \mathcal{L} = \Phi(\bar{\boldsymbol{h}}, \bar{\boldsymbol{v}}) + \zeta$$

$$\mathbf{P}: (\mathbf{h}, \mathbf{v}) \mapsto \{\log(a)\mathbf{h} + \mathbf{v}\}_a$$

### Stein Unbiased Risk Estimate généralisé Observations $\mathbf{y} = \mathbf{\Phi} \bar{\mathbf{x}} + \boldsymbol{\zeta} \in \mathbb{R}^{P}$ , $\bar{\mathbf{x}} \in \mathbb{R}^{N}$ , $\mathbf{\Phi} : \mathbb{R}^{P \times N}$ et $\boldsymbol{\zeta} \sim \mathcal{N}(\mathbf{0}, \boldsymbol{\mathcal{S}})$

Ex. des estimateurs  $\hat{h}(\mathcal{L}; \lambda, \alpha)$  à contours libres ou co-localisés

$$\log \mathcal{L} = \Phi(\bar{h}, \bar{v}) + \zeta \qquad \zeta \sim \mathcal{N}(0, \mathcal{S})$$
  
$$\Phi : (h, v) \mapsto \{\log(a)h + v\}_a \qquad \overleftarrow{\zeta} \sim \mathcal{N}(0, \mathcal{S})$$

Stein Unbiased Risk Estimate généralisé **Observations**  $\mathbf{y} = \mathbf{\Phi} \bar{\mathbf{x}} + \boldsymbol{\zeta} \in \mathbb{R}^{P}, \quad \bar{\mathbf{x}} \in \mathbb{R}^{N}, \ \mathbf{\Phi} : \mathbb{R}^{P \times N} \text{ et } \boldsymbol{\zeta} \sim \mathcal{N}(\mathbf{0}, \boldsymbol{\mathcal{S}})$ 

**Ex.** des estimateurs  $\hat{h}(\mathcal{L}; \lambda, \alpha)$  à contours libres ou co-localisés

$$\log \mathcal{L} = \Phi(\bar{h}, \bar{v}) + \zeta \qquad \zeta \sim \mathcal{N}(\mathbf{0}, \mathcal{S}) \qquad \mathcal{R} = \|\bar{h} - \bar{h}\|^2$$
  
$$\Phi : (h, v) \mapsto \{\log(a)h + v\}_a \qquad \overbrace{\cdot \cdot \cdot \cdot \cdot \cdot \cdot}^{\bullet \bullet \bullet \bullet \bullet \bullet \bullet \bullet \bullet \bullet \bullet} \qquad \Pi : (h, v) \mapsto (h, \mathbf{0})$$

Stein Unbiased Risk Estimate généralisé Observations  $\mathbf{y} = \mathbf{\Phi}\bar{\mathbf{x}} + \boldsymbol{\zeta} \in \mathbb{R}^{P}, \quad \bar{\mathbf{x}} \in \mathbb{R}^{N}, \ \mathbf{\Phi} : \mathbb{R}^{P \times N} \text{ et } \boldsymbol{\zeta} \sim \mathcal{N}(\mathbf{0}, \boldsymbol{\mathcal{S}})$ 

Ex. des estimateurs  $\hat{h}(\mathcal{L}; \lambda, \alpha)$  à contours libres ou co-localisés

$$\log \mathcal{L} = \Phi(\bar{h}, \bar{v}) + \zeta \qquad \zeta \sim \mathcal{N}(\mathbf{0}, \mathcal{S}) \qquad \mathcal{R} = \|\bar{h} - \bar{h}\|^2$$
  
$$\Phi : (h, v) \mapsto \{\log(a)h + v\}_a \qquad \overbrace{\cdot \cdot \cdot \cdot \cdot \cdot \cdot}^{\bullet \bullet \bullet \bullet \bullet \bullet \bullet \bullet \bullet \bullet} \qquad \Pi : (h, v) \mapsto (h, \mathbf{0})$$

**Erreur d'estimation projetée**  $R_{\Pi}(\Lambda) \triangleq \mathbb{E}_{\zeta} \|\Pi \widehat{x}(\mathbf{y}; \Lambda) - \Pi \overline{x}\|^2$ 

# Stein Unbiased Risk Estimate généralisé (Calcul) Observations $\mathbf{y} = \mathbf{\Phi} \bar{\mathbf{x}} + \boldsymbol{\zeta} \in \mathbb{R}^{P}$ , $\bar{\mathbf{x}} \in \mathbb{R}^{N}$ , $\mathbf{\Phi} : \mathbb{R}^{P \times N}$ et $\boldsymbol{\zeta} \sim \mathcal{N}(\mathbf{0}, \boldsymbol{\mathcal{S}})$ $R_{\Pi}(\mathbf{\Lambda}) \triangleq \mathbb{E}_{\boldsymbol{\zeta}} || \Pi \widehat{\mathbf{x}}(\mathbf{y}; \mathbf{\Lambda}) - \Pi \bar{\mathbf{x}} ||^{2}$

 $\begin{array}{l} \hline \begin{array}{l} Stein \ Unbiased \ Risk \ Estimate \ généralisé \ \left( \mathsf{Calcul} \right) \\ \hline \begin{array}{l} \mathbf{Observations} \quad \mathbf{y} = \mathbf{\Phi} \bar{\mathbf{x}} + \boldsymbol{\zeta} \in \mathbb{R}^{P}, \quad \bar{\mathbf{x}} \in \mathbb{R}^{N}, \ \mathbf{\Phi} : \mathbb{R}^{P \times N} \ \text{et} \ \boldsymbol{\zeta} \sim \mathcal{N}(\mathbf{0}, \boldsymbol{\mathcal{S}}) \\ \hline \begin{array}{l} R_{\Pi}(\Lambda) \triangleq \mathbb{E}_{\boldsymbol{\zeta}} \| \Pi \widehat{\mathbf{x}}(\mathbf{y}; \Lambda) - \Pi \bar{\mathbf{x}} \|^{2} \\ = \mathbb{E}_{\boldsymbol{\zeta}} \left\| \Pi (\Phi^{\top} \Phi)^{-1} \Phi^{\top} \Phi (\widehat{\mathbf{x}}(\mathbf{y}; \Lambda) - \bar{\mathbf{x}}) \right\|^{2} \qquad \mathbf{A} \triangleq \Pi (\Phi^{\top} \Phi)^{-1} \Phi^{\top} \end{array}$ 

Stein Unbiased Risk Estimate généralisé (Calcul) Observations  $\mathbf{y} = \mathbf{\Phi} \bar{\mathbf{x}} + \boldsymbol{\zeta} \in \mathbb{R}^{P}$ ,  $\bar{\mathbf{x}} \in \mathbb{R}^{N}$ ,  $\mathbf{\Phi} : \mathbb{R}^{P \times N}$  et  $\boldsymbol{\zeta} \sim \mathcal{N}(\mathbf{0}, \boldsymbol{\mathcal{S}})$  $R_{\Pi}(\Lambda) \triangleq \mathbb{E}_{\boldsymbol{\zeta}} \|\Pi \widehat{\mathbf{x}}(\mathbf{y}; \Lambda) - \Pi \bar{\mathbf{x}}\|^{2}$ 

$$= \mathbb{E}_{\boldsymbol{\zeta}} \left\| \Pi(\Phi^{\top} \Phi)^{-1} \Phi^{\top} \Phi(\widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}) - \bar{\boldsymbol{x}}) \right\|^{2} \qquad \mathbf{A} \triangleq \Pi(\Phi^{\top} \Phi)^{-1} \Phi^{\top} \\ = \mathbb{E}_{\boldsymbol{\zeta}} \left\| \mathbf{A}(\Phi \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}) - \boldsymbol{y} + \boldsymbol{y} - \Phi \bar{\boldsymbol{x}}) \right\|^{2}$$

Stein Unbiased Risk Estimate généralisé (Calcul) Observations  $\mathbf{y} = \mathbf{\Phi} \bar{\mathbf{x}} + \boldsymbol{\zeta} \in \mathbb{R}^{P}$ ,  $\bar{\mathbf{x}} \in \mathbb{R}^{N}$ ,  $\mathbf{\Phi} : \mathbb{R}^{P \times N}$  et  $\boldsymbol{\zeta} \sim \mathcal{N}(\mathbf{0}, \boldsymbol{S})$  $R_{\Pi}(\mathbf{\Lambda}) \triangleq \mathbb{E}_{\boldsymbol{\zeta}} || \Pi \widehat{\mathbf{x}}(\mathbf{y}; \mathbf{\Lambda}) - \Pi \bar{\mathbf{x}} ||^{2}$ 

$$\begin{split} &= \mathbb{E}_{\boldsymbol{\zeta}} \left\| \boldsymbol{\Pi}(\boldsymbol{\Phi}^{\top}\boldsymbol{\Phi})^{-1}\boldsymbol{\Phi}^{\top}\boldsymbol{\Phi}(\widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda}) - \bar{\boldsymbol{x}}) \right\|^{2} \qquad \boldsymbol{\mathsf{A}} \triangleq \boldsymbol{\Pi}(\boldsymbol{\Phi}^{\top}\boldsymbol{\Phi})^{-1}\boldsymbol{\Phi}^{\top} \\ &= \mathbb{E}_{\boldsymbol{\zeta}} \left\| \boldsymbol{\mathsf{A}}(\boldsymbol{\Phi}\widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda}) - \boldsymbol{y} + \boldsymbol{y} - \boldsymbol{\Phi}\overline{\boldsymbol{x}}) \right\|^{2} \\ &= \mathbb{E}_{\boldsymbol{\zeta}} \left\| \boldsymbol{\mathsf{A}}(\boldsymbol{\Phi}\widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda}) - \boldsymbol{y} + \boldsymbol{\zeta}) \right\|^{2} \end{split}$$

Stein Unbiased Risk Estimate généralisé (Calcul) Observations  $\mathbf{y} = \mathbf{\Phi}\bar{\mathbf{x}} + \boldsymbol{\zeta} \in \mathbb{R}^{P}$ ,  $\bar{\mathbf{x}} \in \mathbb{R}^{N}$ ,  $\mathbf{\Phi} : \mathbb{R}^{P \times N}$  et  $\boldsymbol{\zeta} \sim \mathcal{N}(\mathbf{0}, \boldsymbol{\mathcal{S}})$   $R_{\Pi}(\Lambda) \triangleq \mathbb{E}_{\boldsymbol{\zeta}} \| \mathbf{\Pi} \widehat{\mathbf{x}}(\mathbf{y}; \Lambda) - \mathbf{\Pi} \bar{\mathbf{x}} \|^{2}$   $= \mathbb{E}_{\boldsymbol{\zeta}} \| \mathbf{\Pi} (\mathbf{\Phi}^{\top} \mathbf{\Phi})^{-1} \mathbf{\Phi}^{\top} \mathbf{\Phi} (\widehat{\mathbf{x}}(\mathbf{y}; \Lambda) - \bar{\mathbf{x}}) \|^{2}$   $= \mathbb{E}_{\boldsymbol{\zeta}} \| \mathbf{A} (\mathbf{\Phi} \widehat{\mathbf{x}}(\mathbf{y}; \Lambda) - \mathbf{y} + \mathbf{y} - \mathbf{\Phi} \bar{\mathbf{x}}) \|^{2}$  $= \mathbb{E}_{\boldsymbol{\zeta}} \| \mathbf{A} (\mathbf{\Phi} \widehat{\mathbf{x}}(\mathbf{y}; \Lambda) - \mathbf{y} + \boldsymbol{\zeta}) \|^{2}$ 

 $= \mathbb{E}_{\zeta} \left[ \left\| \mathsf{A}(\Phi \widehat{x}(\mathbf{y}; \Lambda) - \mathbf{y}) \right\|^2 + 2 \left\langle \mathsf{A}(\Phi \widehat{x}(\mathbf{y}; \Lambda) - \mathbf{y}), \mathsf{A}\zeta \right\rangle + \left\| \mathsf{A}\zeta \right\|^2 \right]$ 

 $\begin{aligned} & \textit{Stein Unbiased Risk Estimate généralisé (Calcul)} \\ & \textit{Observations} \quad \mathbf{y} = \mathbf{\Phi}\bar{\mathbf{x}} + \boldsymbol{\zeta} \in \mathbb{R}^{P}, \quad \bar{\mathbf{x}} \in \mathbb{R}^{N}, \; \mathbf{\Phi} : \mathbb{R}^{P \times N} \; \text{et} \; \boldsymbol{\zeta} \sim \mathcal{N}(\mathbf{0}, \boldsymbol{\mathcal{S}}) \\ & R_{\Pi}(\Lambda) \triangleq \mathbb{E}_{\boldsymbol{\zeta}} \| \Pi \widehat{\mathbf{x}}(\mathbf{y}; \Lambda) - \Pi \bar{\mathbf{x}} \|^{2} \\ & = \mathbb{E}_{\boldsymbol{\zeta}} \left\| \Pi (\Phi^{\top} \Phi)^{-1} \Phi^{\top} \Phi (\widehat{\mathbf{x}}(\mathbf{y}; \Lambda) - \bar{\mathbf{x}}) \right\|^{2} \qquad \mathbf{A} \triangleq \Pi (\Phi^{\top} \Phi)^{-1} \Phi^{\top} \\ & = \mathbb{E}_{\boldsymbol{\zeta}} \left\| \mathbf{A} (\Phi \widehat{\mathbf{x}}(\mathbf{y}; \Lambda) - \mathbf{y} + \mathbf{y} - \Phi \bar{\mathbf{x}}) \right\|^{2} \\ & = \mathbb{E}_{\boldsymbol{\zeta}} \left\| \mathbf{A} (\Phi \widehat{\mathbf{x}}(\mathbf{y}; \Lambda) - \mathbf{y} + \boldsymbol{\zeta}) \right\|^{2} \\ & = \mathbb{E}_{\boldsymbol{\zeta}} \left\| \mathbf{A} (\Phi \widehat{\mathbf{x}}(\mathbf{y}; \Lambda) - \mathbf{y} + \boldsymbol{\zeta}) \right\|^{2} \\ & = \mathbb{E}_{\boldsymbol{\zeta}} \left[ \left\| \mathbf{A} (\Phi \widehat{\mathbf{x}}(\mathbf{y}; \Lambda) - \mathbf{y}) \right\|^{2} + 2 \left\langle \mathbf{A} (\Phi \widehat{\mathbf{x}}(\mathbf{y}; \Lambda) - \mathbf{y}), \mathbf{A} \boldsymbol{\zeta} \right\rangle + \left\| \mathbf{A} \boldsymbol{\zeta} \right\|^{2} \right] \\ & = \mathbb{E}_{\boldsymbol{\zeta}} \left[ \left\| \mathbf{A} (\Phi \widehat{\mathbf{x}}(\mathbf{y}; \Lambda) - \mathbf{y}) \right\|^{2} + 2 \left\langle \mathbf{A} \Phi \widehat{\mathbf{x}}(\mathbf{y}; \Lambda), \mathbf{A} \boldsymbol{\zeta} \right\rangle - 2 \left\langle \mathbf{A} \mathbf{y}, \mathbf{A} \boldsymbol{\zeta} \right\rangle + \left\| \mathbf{A} \boldsymbol{\zeta} \right\|^{2} \right] \end{aligned}$ 

Stein Unbiased Risk Estimate généralisé (Calcul) **Observations**  $\mathbf{y} = \mathbf{\Phi} \bar{\mathbf{x}} + \boldsymbol{\zeta} \in \mathbb{R}^{P}, \quad \bar{\mathbf{x}} \in \mathbb{R}^{N}, \ \mathbf{\Phi} : \mathbb{R}^{P \times N} \text{ et } \boldsymbol{\zeta} \sim \mathcal{N}(\mathbf{0}, \boldsymbol{\mathcal{S}})$  $R_{\Pi}(\Lambda) \triangleq \mathbb{E}_{\mathcal{L}} \|\Pi \widehat{\mathbf{x}}(\mathbf{y}; \Lambda) - \Pi \overline{\mathbf{x}}\|^2$  $= \mathbb{E}_{\boldsymbol{\zeta}} \left\| \boldsymbol{\Pi} (\boldsymbol{\Phi}^{\top} \boldsymbol{\Phi})^{-1} \boldsymbol{\Phi}^{\top} \boldsymbol{\Phi} (\widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}) - \bar{\boldsymbol{x}}) \right\|^{2}$  $\mathbf{A} \triangleq \mathbf{\Pi} (\mathbf{\Phi}^{\top} \mathbf{\Phi})^{-1} \mathbf{\Phi}^{\top}$  $=\mathbb{E}_{\mathcal{L}}\left\|\mathsf{A}(\mathbf{\Phi}\widehat{\mathbf{x}}(\mathbf{y};\mathbf{\Lambda})-\mathbf{y}+\mathbf{y}-\mathbf{\Phi}\overline{\mathbf{x}})\right\|^{2}$  $= \mathbb{E}_{\zeta} \|\mathbf{A}(\mathbf{\Phi}\widehat{\mathbf{x}}(\mathbf{y}; \mathbf{\Lambda}) - \mathbf{y} + \boldsymbol{\zeta})\|^2$  $=\mathbb{E}_{\boldsymbol{\zeta}}\left[\left\|\boldsymbol{\mathsf{A}}(\boldsymbol{\Phi}\widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda})-\boldsymbol{y})\right\|^{2}+2\left\langle\boldsymbol{\mathsf{A}}(\boldsymbol{\Phi}\widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda})-\boldsymbol{y}),\boldsymbol{\mathsf{A}}\boldsymbol{\zeta}\right\rangle+\left\|\boldsymbol{\mathsf{A}}\boldsymbol{\zeta}\right\|^{2}\right]$  $= \mathbb{E}_{\boldsymbol{\zeta}} \left[ \left\| \mathsf{A}(\boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}) - \boldsymbol{y}) \right\|^{2} + 2 \left\langle \mathsf{A} \boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}), \mathsf{A} \boldsymbol{\zeta} \right\rangle - 2 \left\langle \mathsf{A} \boldsymbol{y}, \mathsf{A} \boldsymbol{\zeta} \right\rangle + \left\| \mathsf{A} \boldsymbol{\zeta} \right\|^{2} \right]$  $=\mathbb{E}_{\boldsymbol{\zeta}}\left[\left\|\boldsymbol{\mathsf{A}}(\boldsymbol{\Phi}\widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda})-\boldsymbol{y})\right\|^{2}+2\left\langle\boldsymbol{\mathsf{A}}\boldsymbol{\Phi}\widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda}),\boldsymbol{\mathsf{A}}\boldsymbol{\zeta}\right\rangle-2\left\langle\boldsymbol{\mathsf{A}}(\boldsymbol{\Phi}\overline{\boldsymbol{x}}+\boldsymbol{\zeta}),\boldsymbol{\mathsf{A}}\boldsymbol{\zeta}\right\rangle+\left\|\boldsymbol{\mathsf{A}}\boldsymbol{\zeta}\right\|^{2}\right]$ 

Stein Unbiased Risk Estimate généralisé (Calcul) **Observations**  $\mathbf{y} = \mathbf{\Phi} \bar{\mathbf{x}} + \boldsymbol{\zeta} \in \mathbb{R}^{P}, \quad \bar{\mathbf{x}} \in \mathbb{R}^{N}, \ \mathbf{\Phi} : \mathbb{R}^{P \times N} \text{ et } \boldsymbol{\zeta} \sim \mathcal{N}(\mathbf{0}, \boldsymbol{\mathcal{S}})$  $R_{\Pi}(\Lambda) \triangleq \mathbb{E}_{\mathcal{L}} \|\Pi \widehat{\mathbf{x}}(\mathbf{y}; \Lambda) - \Pi \overline{\mathbf{x}}\|^2$  $= \mathbb{E}_{\boldsymbol{\zeta}} \left\| \boldsymbol{\Pi} (\boldsymbol{\Phi}^{\top} \boldsymbol{\Phi})^{-1} \boldsymbol{\Phi}^{\top} \boldsymbol{\Phi} (\widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}) - \bar{\boldsymbol{x}}) \right\|^{2}$  $\mathbf{A} \triangleq \mathbf{\Pi} (\mathbf{\Phi}^{\top} \mathbf{\Phi})^{-1} \mathbf{\Phi}^{\top}$  $=\mathbb{E}_{\mathcal{L}}\left\|\mathsf{A}(\mathbf{\Phi}\widehat{\mathbf{x}}(\mathbf{y};\mathbf{\Lambda})-\mathbf{y}+\mathbf{y}-\mathbf{\Phi}\overline{\mathbf{x}})\right\|^{2}$  $= \mathbb{E}_{\zeta} \|\mathbf{A}(\mathbf{\Phi}\widehat{\mathbf{x}}(\mathbf{y}; \mathbf{\Lambda}) - \mathbf{y} + \boldsymbol{\zeta})\|^2$  $=\mathbb{E}_{\boldsymbol{\zeta}}\left[\left\|\boldsymbol{\mathsf{A}}(\boldsymbol{\Phi}\widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda})-\boldsymbol{y})\right\|^{2}+2\left\langle\boldsymbol{\mathsf{A}}(\boldsymbol{\Phi}\widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda})-\boldsymbol{y}),\boldsymbol{\mathsf{A}}\boldsymbol{\zeta}\right\rangle+\left\|\boldsymbol{\mathsf{A}}\boldsymbol{\zeta}\right\|^{2}\right]$  $=\mathbb{E}_{\boldsymbol{\zeta}}\left[\left\|\boldsymbol{\mathsf{A}}(\boldsymbol{\Phi}\widehat{\boldsymbol{\mathsf{x}}}(\boldsymbol{\mathsf{y}};\boldsymbol{\Lambda})-\boldsymbol{\mathsf{y}})\right\|^{2}+2\left\langle\boldsymbol{\mathsf{A}}\boldsymbol{\Phi}\widehat{\boldsymbol{\mathsf{x}}}(\boldsymbol{\mathsf{y}};\boldsymbol{\Lambda}),\boldsymbol{\mathsf{A}}\boldsymbol{\zeta}\right\rangle-2\left\langle\boldsymbol{\mathsf{A}}\boldsymbol{\mathsf{y}},\boldsymbol{\mathsf{A}}\boldsymbol{\zeta}\right\rangle+\left\|\boldsymbol{\mathsf{A}}\boldsymbol{\zeta}\right\|^{2}\right]$  $= \mathbb{E}_{\boldsymbol{\zeta}} \left[ \left\| \mathsf{A}(\boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}) - \boldsymbol{y}) \right\|^{2} + 2 \left\langle \mathsf{A} \boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}), \mathsf{A} \boldsymbol{\zeta} \right\rangle - 2 \left\langle \mathsf{A} \right\rangle + \left\| \mathsf{A} \boldsymbol{\zeta} \right\|^{2} \right]$ 

Stein Unbiased Risk Estimate généralisé (Calcul) **Observations**  $\mathbf{y} = \mathbf{\Phi} \bar{\mathbf{x}} + \boldsymbol{\zeta} \in \mathbb{R}^{P}, \quad \bar{\mathbf{x}} \in \mathbb{R}^{N}, \ \mathbf{\Phi} : \mathbb{R}^{P \times N} \text{ et } \boldsymbol{\zeta} \sim \mathcal{N}(\mathbf{0}, \boldsymbol{\mathcal{S}})$  $R_{\Pi}(\Lambda) \triangleq \mathbb{E}_{\mathcal{L}} \|\Pi \widehat{\mathbf{x}}(\mathbf{y}; \Lambda) - \Pi \overline{\mathbf{x}}\|^2$  $= \mathbb{E}_{\boldsymbol{\zeta}} \left\| \boldsymbol{\Pi} (\boldsymbol{\Phi}^{\top} \boldsymbol{\Phi})^{-1} \boldsymbol{\Phi}^{\top} \boldsymbol{\Phi} (\widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}) - \bar{\boldsymbol{x}}) \right\|^{2}$  $\mathbf{A} \triangleq \mathbf{\Pi} (\mathbf{\Phi}^{\top} \mathbf{\Phi})^{-1} \mathbf{\Phi}^{\top}$  $=\mathbb{E}_{\mathcal{L}}\left\|\mathsf{A}(\mathbf{\Phi}\widehat{\mathbf{x}}(\mathbf{y};\mathbf{\Lambda})-\mathbf{y}+\mathbf{y}-\mathbf{\Phi}\overline{\mathbf{x}})\right\|^{2}$  $= \mathbb{E}_{\zeta} \|\mathbf{A}(\mathbf{\Phi}\widehat{\mathbf{x}}(\mathbf{y}; \mathbf{\Lambda}) - \mathbf{y} + \boldsymbol{\zeta})\|^2$  $=\mathbb{E}_{\boldsymbol{\zeta}}\left[\left\|\boldsymbol{\mathsf{A}}(\boldsymbol{\Phi}\widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda})-\boldsymbol{y})\right\|^{2}+2\left\langle\boldsymbol{\mathsf{A}}(\boldsymbol{\Phi}\widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda})-\boldsymbol{y}),\boldsymbol{\mathsf{A}}\boldsymbol{\zeta}\right\rangle+\left\|\boldsymbol{\mathsf{A}}\boldsymbol{\zeta}\right\|^{2}\right]$  $=\mathbb{E}_{\boldsymbol{\zeta}}\left[\left\|\boldsymbol{\mathsf{A}}(\boldsymbol{\Phi}\widehat{\boldsymbol{\mathsf{x}}}(\boldsymbol{\mathsf{y}};\boldsymbol{\Lambda})-\boldsymbol{\mathsf{y}})\right\|^{2}+2\left\langle\boldsymbol{\mathsf{A}}\boldsymbol{\Phi}\widehat{\boldsymbol{\mathsf{x}}}(\boldsymbol{\mathsf{y}};\boldsymbol{\Lambda}),\boldsymbol{\mathsf{A}}\boldsymbol{\zeta}\right\rangle-2\left\langle\boldsymbol{\mathsf{A}}\boldsymbol{\mathsf{y}},\boldsymbol{\mathsf{A}}\boldsymbol{\zeta}\right\rangle+\left\|\boldsymbol{\mathsf{A}}\boldsymbol{\zeta}\right\|^{2}\right]$  $= \mathbb{E}_{\boldsymbol{\zeta}} \left[ \left\| \mathsf{A}(\boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}) - \boldsymbol{y}) \right\|^{2} + 2 \left\langle \mathsf{A} \boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}), \mathsf{A} \boldsymbol{\zeta} \right\rangle - 2 \left\langle \mathsf{A} \qquad \boldsymbol{\zeta} \right. , \left. \mathsf{A} \boldsymbol{\zeta} \right\rangle + \left\| \mathsf{A} \boldsymbol{\zeta} \right\|^{2} \right] \right]$  $= \mathbb{E}_{\mathcal{L}} \left\| \mathsf{A}(\Phi \widehat{\mathsf{x}}(\mathsf{y}; \Lambda) - \mathsf{y}) \right\|^{2} + 2\mathbb{E}_{\mathcal{L}} \left\langle \mathsf{A} \Phi \widehat{\mathsf{x}}(\mathsf{y}; \Lambda), \mathsf{A} \mathcal{L} \right\rangle - \mathbb{E}_{\mathcal{L}} \left\| \mathsf{A} \mathcal{L} \right\|^{2}$ 

Stein Unbiased Risk Estimate généralisé (Calcul) **Observations**  $\mathbf{y} = \mathbf{\Phi} \bar{\mathbf{x}} + \boldsymbol{\zeta} \in \mathbb{R}^{P}, \quad \bar{\mathbf{x}} \in \mathbb{R}^{N}, \ \mathbf{\Phi} : \mathbb{R}^{P \times N} \text{ et } \boldsymbol{\zeta} \sim \mathcal{N}(\mathbf{0}, \boldsymbol{\mathcal{S}})$  $R_{\Pi}(\Lambda) \triangleq \mathbb{E}_{\mathcal{L}} \|\Pi \widehat{\mathbf{x}}(\mathbf{y}; \Lambda) - \Pi \overline{\mathbf{x}}\|^2$  $= \mathbb{E}_{\boldsymbol{\zeta}} \left\| \boldsymbol{\Pi} (\boldsymbol{\Phi}^{\top} \boldsymbol{\Phi})^{-1} \boldsymbol{\Phi}^{\top} \boldsymbol{\Phi} (\widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}) - \bar{\boldsymbol{x}}) \right\|^{2}$  $\mathbf{A} \triangleq \mathbf{\Pi} (\mathbf{\Phi}^{\top} \mathbf{\Phi})^{-1} \mathbf{\Phi}^{\top}$  $=\mathbb{E}_{\mathcal{L}}\left\|\mathsf{A}(\mathbf{\Phi}\widehat{\mathbf{x}}(\mathbf{y};\mathbf{\Lambda})-\mathbf{y}+\mathbf{y}-\mathbf{\Phi}\overline{\mathbf{x}})\right\|^{2}$  $= \mathbb{E}_{\zeta} \|\mathbf{A}(\mathbf{\Phi}\widehat{\mathbf{x}}(\mathbf{y}; \mathbf{\Lambda}) - \mathbf{y} + \boldsymbol{\zeta})\|^2$  $=\mathbb{E}_{\boldsymbol{\zeta}}\left[\left\|\boldsymbol{\mathsf{A}}(\boldsymbol{\Phi}\widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda})-\boldsymbol{y})\right\|^{2}+2\left\langle\boldsymbol{\mathsf{A}}(\boldsymbol{\Phi}\widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda})-\boldsymbol{y}),\boldsymbol{\mathsf{A}}\boldsymbol{\zeta}\right\rangle+\left\|\boldsymbol{\mathsf{A}}\boldsymbol{\zeta}\right\|^{2}\right]$  $=\mathbb{E}_{\boldsymbol{\zeta}}\left[\left\|\boldsymbol{\mathsf{A}}(\boldsymbol{\Phi}\widehat{\boldsymbol{\mathsf{x}}}(\boldsymbol{\mathsf{y}};\boldsymbol{\Lambda})-\boldsymbol{\mathsf{y}})\right\|^{2}+2\left\langle\boldsymbol{\mathsf{A}}\boldsymbol{\Phi}\widehat{\boldsymbol{\mathsf{x}}}(\boldsymbol{\mathsf{y}};\boldsymbol{\Lambda}),\boldsymbol{\mathsf{A}}\boldsymbol{\zeta}\right\rangle-2\left\langle\boldsymbol{\mathsf{A}}\boldsymbol{\mathsf{y}},\boldsymbol{\mathsf{A}}\boldsymbol{\zeta}\right\rangle+\left\|\boldsymbol{\mathsf{A}}\boldsymbol{\zeta}\right\|^{2}\right]$  $= \mathbb{E}_{\boldsymbol{\zeta}} \left[ \left\| \mathbf{A}(\boldsymbol{\Phi} \widehat{\mathbf{x}}(\mathbf{y}; \boldsymbol{\Lambda}) - \mathbf{y}) \right\|^{2} + 2 \left\langle \mathbf{A} \boldsymbol{\Phi} \widehat{\mathbf{x}}(\mathbf{y}; \boldsymbol{\Lambda}), \mathbf{A} \boldsymbol{\zeta} \right\rangle - 2 \left\langle \mathbf{A} \qquad \boldsymbol{\zeta} \right. , \mathbf{A} \boldsymbol{\zeta} \right\rangle + \left\| \mathbf{A} \boldsymbol{\zeta} \right\|^{2} \right]$  $= \mathbb{E}_{\mathcal{L}} \left\| \mathsf{A}(\mathbf{\Phi} \widehat{\mathbf{x}}(\mathbf{y}; \mathbf{\Lambda}) - \mathbf{y}) \right\|^{2} + 2\mathbb{E}_{\mathcal{L}} \left\langle \mathsf{A} \mathbf{\Phi} \widehat{\mathbf{x}}(\mathbf{y}; \mathbf{\Lambda}), \mathsf{A} \mathbf{\zeta} \right\rangle - \operatorname{tr} \left( \mathsf{A} \mathcal{S} \mathsf{A}^{\top} \right)$ 

Stein Unbiased Risk Estimate généralisé (Calcul) **Observations**  $\mathbf{y} = \mathbf{\Phi} \bar{\mathbf{x}} + \boldsymbol{\zeta} \in \mathbb{R}^{P}, \quad \bar{\mathbf{x}} \in \mathbb{R}^{N}, \ \mathbf{\Phi} : \mathbb{R}^{P \times N} \text{ et } \boldsymbol{\zeta} \sim \mathcal{N}(\mathbf{0}, \boldsymbol{\mathcal{S}})$  $R_{\Pi}(\Lambda) \triangleq \mathbb{E}_{\mathcal{L}} \|\Pi \widehat{\mathbf{x}}(\mathbf{y}; \Lambda) - \Pi \overline{\mathbf{x}}\|^2$  $= \mathbb{E}_{\boldsymbol{\zeta}} \left\| \boldsymbol{\Pi} (\boldsymbol{\Phi}^{\top} \boldsymbol{\Phi})^{-1} \boldsymbol{\Phi}^{\top} \boldsymbol{\Phi} (\widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}) - \bar{\boldsymbol{x}}) \right\|^{2}$  $\mathbf{A} \triangleq \mathbf{\Pi} (\mathbf{\Phi}^{\top} \mathbf{\Phi})^{-1} \mathbf{\Phi}^{\top}$  $=\mathbb{E}_{\mathcal{L}}\left\|\mathsf{A}(\mathbf{\Phi}\widehat{\mathbf{x}}(\mathbf{y};\mathbf{\Lambda})-\mathbf{y}+\mathbf{y}-\mathbf{\Phi}\overline{\mathbf{x}})\right\|^{2}$  $= \mathbb{E}_{\zeta} \|\mathbf{A}(\mathbf{\Phi}\widehat{\mathbf{x}}(\mathbf{y}; \mathbf{\Lambda}) - \mathbf{y} + \boldsymbol{\zeta})\|^2$  $=\mathbb{E}_{\boldsymbol{\zeta}}\left[\left\|\boldsymbol{\mathsf{A}}(\boldsymbol{\Phi}\widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda})-\boldsymbol{y})\right\|^{2}+2\left\langle\boldsymbol{\mathsf{A}}(\boldsymbol{\Phi}\widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda})-\boldsymbol{y}),\boldsymbol{\mathsf{A}}\boldsymbol{\zeta}\right\rangle+\left\|\boldsymbol{\mathsf{A}}\boldsymbol{\zeta}\right\|^{2}\right]$  $= \mathbb{E}_{\boldsymbol{\zeta}} \left[ \left\| \mathsf{A}(\boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}) - \boldsymbol{y}) \right\|^{2} + 2 \left\langle \mathsf{A} \boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}), \mathsf{A} \boldsymbol{\zeta} \right\rangle - 2 \left\langle \mathsf{A} \boldsymbol{y}, \mathsf{A} \boldsymbol{\zeta} \right\rangle + \left\| \mathsf{A} \boldsymbol{\zeta} \right\|^{2} \right]$  $= \mathbb{E}_{\boldsymbol{\zeta}} \left[ \left\| \mathsf{A}(\boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}) - \boldsymbol{y}) \right\|^{2} + 2 \left\langle \mathsf{A} \boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}), \mathsf{A} \boldsymbol{\zeta} \right\rangle - 2 \left\langle \mathsf{A} \qquad \boldsymbol{\zeta} \right. , \mathsf{A} \boldsymbol{\zeta} \right\rangle + \left\| \mathsf{A} \boldsymbol{\zeta} \right\|^{2} \right]$  $= \mathbb{E}_{\boldsymbol{\zeta}} \left\| \mathsf{A}(\boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}) - \boldsymbol{y}) \right\|^{2} + 2\mathbb{E}_{\boldsymbol{\zeta}} \left\langle \mathsf{A} \boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}), \mathsf{A} \boldsymbol{\zeta} \right\rangle - \operatorname{tr} \left( \mathsf{A} \boldsymbol{\mathcal{S}} \mathsf{A}^{\top} \right)$ accessible

Stein Unbiased Risk Estimate généralisé (Calcul) **Observations**  $\mathbf{y} = \mathbf{\Phi} \bar{\mathbf{x}} + \boldsymbol{\zeta} \in \mathbb{R}^{P}, \quad \bar{\mathbf{x}} \in \mathbb{R}^{N}, \ \mathbf{\Phi} : \mathbb{R}^{P \times N} \text{ et } \boldsymbol{\zeta} \sim \mathcal{N}(\mathbf{0}, \boldsymbol{\mathcal{S}})$  $R_{\Pi}(\Lambda) \triangleq \mathbb{E}_{\mathcal{L}} \|\Pi \widehat{\mathbf{x}}(\mathbf{y}; \Lambda) - \Pi \overline{\mathbf{x}}\|^2$  $= \mathbb{E}_{\boldsymbol{\zeta}} \left\| \boldsymbol{\Pi} (\boldsymbol{\Phi}^{\top} \boldsymbol{\Phi})^{-1} \boldsymbol{\Phi}^{\top} \boldsymbol{\Phi} (\widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}) - \bar{\boldsymbol{x}}) \right\|^{2}$  $\mathbf{A} \triangleq \mathbf{\Pi} (\mathbf{\Phi}^{\top} \mathbf{\Phi})^{-1} \mathbf{\Phi}^{\top}$  $=\mathbb{E}_{\mathcal{L}}\left\|\mathsf{A}(\mathbf{\Phi}\widehat{\mathbf{x}}(\mathbf{y};\mathbf{\Lambda})-\mathbf{y}+\mathbf{y}-\mathbf{\Phi}\overline{\mathbf{x}})\right\|^{2}$  $= \mathbb{E}_{\zeta} \|\mathbf{A}(\mathbf{\Phi}\widehat{\mathbf{x}}(\mathbf{y}; \mathbf{\Lambda}) - \mathbf{y} + \boldsymbol{\zeta})\|^2$  $=\mathbb{E}_{\boldsymbol{\zeta}}\left[\left\|\boldsymbol{\mathsf{A}}(\boldsymbol{\Phi}\widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda})-\boldsymbol{y})\right\|^{2}+2\left\langle\boldsymbol{\mathsf{A}}(\boldsymbol{\Phi}\widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda})-\boldsymbol{y}),\boldsymbol{\mathsf{A}}\boldsymbol{\zeta}\right\rangle+\left\|\boldsymbol{\mathsf{A}}\boldsymbol{\zeta}\right\|^{2}\right]$  $= \mathbb{E}_{\boldsymbol{\zeta}} \left[ \left\| \mathsf{A}(\boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}) - \boldsymbol{y}) \right\|^{2} + 2 \left\langle \mathsf{A} \boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}), \mathsf{A} \boldsymbol{\zeta} \right\rangle - 2 \left\langle \mathsf{A} \boldsymbol{y}, \mathsf{A} \boldsymbol{\zeta} \right\rangle + \left\| \mathsf{A} \boldsymbol{\zeta} \right\|^{2} \right]$  $= \mathbb{E}_{\boldsymbol{\zeta}} \left[ \left\| \mathsf{A}(\boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}) - \boldsymbol{y}) \right\|^{2} + 2 \left\langle \mathsf{A} \boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}), \mathsf{A} \boldsymbol{\zeta} \right\rangle - 2 \left\langle \mathsf{A} \qquad \boldsymbol{\zeta} \right. , \mathsf{A} \boldsymbol{\zeta} \right\rangle + \left\| \mathsf{A} \boldsymbol{\zeta} \right\|^{2} \right]$  $= \mathbb{E}_{\boldsymbol{\zeta}} \left\| \mathsf{A}(\boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}) - \boldsymbol{y}) \right\|^{2} + 2\mathbb{E}_{\boldsymbol{\zeta}} \left\langle \mathsf{A} \boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}), \mathsf{A} \boldsymbol{\zeta} \right\rangle - \mathrm{tr} \left( \mathsf{A} \boldsymbol{\mathcal{S}} \mathsf{A}^{\top} \right)$ accessible accessible

Stein Unbiased Risk Estimate généralisé (Calcul) **Observations**  $\mathbf{y} = \mathbf{\Phi} \bar{\mathbf{x}} + \boldsymbol{\zeta} \in \mathbb{R}^{P}, \quad \bar{\mathbf{x}} \in \mathbb{R}^{N}, \ \mathbf{\Phi} : \mathbb{R}^{P \times N} \text{ et } \boldsymbol{\zeta} \sim \mathcal{N}(\mathbf{0}, \boldsymbol{\mathcal{S}})$  $R_{\Pi}(\Lambda) \triangleq \mathbb{E}_{\mathcal{L}} \|\Pi \widehat{\mathbf{x}}(\mathbf{y}; \Lambda) - \Pi \overline{\mathbf{x}}\|^2$  $= \mathbb{E}_{\boldsymbol{\zeta}} \left\| \boldsymbol{\Pi} (\boldsymbol{\Phi}^{\top} \boldsymbol{\Phi})^{-1} \boldsymbol{\Phi}^{\top} \boldsymbol{\Phi} (\widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}) - \bar{\boldsymbol{x}}) \right\|^{2}$  $\mathbf{A} \triangleq \mathbf{\Pi} (\mathbf{\Phi}^{\top} \mathbf{\Phi})^{-1} \mathbf{\Phi}^{\top}$  $=\mathbb{E}_{\mathcal{L}}\left\|\mathsf{A}(\mathbf{\Phi}\widehat{\mathbf{x}}(\mathbf{y};\mathbf{\Lambda})-\mathbf{y}+\mathbf{y}-\mathbf{\Phi}\overline{\mathbf{x}})\right\|^{2}$  $= \mathbb{E}_{\zeta} \|\mathbf{A}(\mathbf{\Phi}\widehat{\mathbf{x}}(\mathbf{y}; \mathbf{\Lambda}) - \mathbf{y} + \boldsymbol{\zeta})\|^2$  $=\mathbb{E}_{\boldsymbol{\zeta}}\left[\left\|\boldsymbol{\mathsf{A}}(\boldsymbol{\Phi}\widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda})-\boldsymbol{y})\right\|^{2}+2\left\langle\boldsymbol{\mathsf{A}}(\boldsymbol{\Phi}\widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda})-\boldsymbol{y}),\boldsymbol{\mathsf{A}}\boldsymbol{\zeta}\right\rangle+\left\|\boldsymbol{\mathsf{A}}\boldsymbol{\zeta}\right\|^{2}\right]$  $= \mathbb{E}_{\boldsymbol{\zeta}} \left[ \left\| \mathsf{A}(\boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}) - \boldsymbol{y}) \right\|^{2} + 2 \left\langle \mathsf{A} \boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}), \mathsf{A} \boldsymbol{\zeta} \right\rangle - 2 \left\langle \mathsf{A} \boldsymbol{y}, \mathsf{A} \boldsymbol{\zeta} \right\rangle + \left\| \mathsf{A} \boldsymbol{\zeta} \right\|^{2} \right]$  $= \mathbb{E}_{\boldsymbol{\zeta}} \left[ \left\| \mathsf{A}(\boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}) - \boldsymbol{y}) \right\|^{2} + 2 \left\langle \mathsf{A} \boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}), \mathsf{A} \boldsymbol{\zeta} \right\rangle - 2 \left\langle \mathsf{A} \qquad \boldsymbol{\zeta} \right. , \mathsf{A} \boldsymbol{\zeta} \right\rangle + \left\| \mathsf{A} \boldsymbol{\zeta} \right\|^{2} \right]$  $= \mathbb{E}_{\mathcal{L}} \left\| \mathsf{A}(\Phi \widehat{\mathsf{x}}(\mathsf{y}; \Lambda) - \mathsf{y}) \right\|^{2} + 2\mathbb{E}_{\mathcal{L}} \left\langle \mathsf{A} \Phi \widehat{\mathsf{x}}(\mathsf{y}; \Lambda), \mathsf{A} \mathcal{L} \right\rangle - \operatorname{tr} \left( \mathsf{A} \mathcal{S} \mathsf{A}^{\top} \right)$ accessible accessible

Stein Unbiased Risk Estimate généralisé (Calcul) **Observations**  $\mathbf{y} = \mathbf{\Phi} \bar{\mathbf{x}} + \boldsymbol{\zeta} \in \mathbb{R}^{P}, \quad \bar{\mathbf{x}} \in \mathbb{R}^{N}, \ \mathbf{\Phi} : \mathbb{R}^{P \times N} \text{ et } \boldsymbol{\zeta} \sim \mathcal{N}(\mathbf{0}, \boldsymbol{\mathcal{S}})$  $R_{\Pi}(\Lambda) \triangleq \mathbb{E}_{\mathcal{L}} \|\Pi \widehat{\mathbf{x}}(\mathbf{y}; \Lambda) - \Pi \overline{\mathbf{x}}\|^2$  $= \mathbb{E}_{\boldsymbol{\zeta}} \left\| \boldsymbol{\Pi} (\boldsymbol{\Phi}^{\top} \boldsymbol{\Phi})^{-1} \boldsymbol{\Phi}^{\top} \boldsymbol{\Phi} (\widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}) - \bar{\boldsymbol{x}}) \right\|^{2}$  $\mathbf{A} \triangleq \mathbf{\Pi} (\mathbf{\Phi}^{\top} \mathbf{\Phi})^{-1} \mathbf{\Phi}^{\top}$  $= \mathbb{E}_{\mathcal{L}} \left\| \mathsf{A}(\Phi \widehat{\mathsf{x}}(\mathsf{y}; \Lambda) - \mathsf{y} + \mathsf{y} - \Phi \overline{\mathsf{x}}) \right\|^2$  $= \mathbb{E}_{\zeta} \|\mathbf{A}(\mathbf{\Phi}\widehat{\mathbf{x}}(\mathbf{y}; \mathbf{\Lambda}) - \mathbf{y} + \boldsymbol{\zeta})\|^2$  $=\mathbb{E}_{\boldsymbol{\zeta}}\left[\left\|\boldsymbol{\mathsf{A}}(\boldsymbol{\Phi}\widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda})-\boldsymbol{y})\right\|^{2}+2\left\langle\boldsymbol{\mathsf{A}}(\boldsymbol{\Phi}\widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda})-\boldsymbol{y}),\boldsymbol{\mathsf{A}}\boldsymbol{\zeta}\right\rangle+\left\|\boldsymbol{\mathsf{A}}\boldsymbol{\zeta}\right\|^{2}\right]$  $= \mathbb{E}_{\boldsymbol{\zeta}} \left[ \left\| \mathsf{A}(\boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}) - \boldsymbol{y}) \right\|^{2} + 2 \left\langle \mathsf{A} \boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}), \mathsf{A} \boldsymbol{\zeta} \right\rangle - 2 \left\langle \mathsf{A} \boldsymbol{y}, \mathsf{A} \boldsymbol{\zeta} \right\rangle + \left\| \mathsf{A} \boldsymbol{\zeta} \right\|^{2} \right]$  $= \mathbb{E}_{\boldsymbol{\zeta}} \left[ \left\| \mathsf{A}(\boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}) - \boldsymbol{y}) \right\|^{2} + 2 \left\langle \mathsf{A} \boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}), \mathsf{A} \boldsymbol{\zeta} \right\rangle - 2 \left\langle \mathsf{A} \qquad \boldsymbol{\zeta} \right. , \mathsf{A} \boldsymbol{\zeta} \right\rangle + \left\| \mathsf{A} \boldsymbol{\zeta} \right\|^{2} \right]$  $= \mathbb{E}_{\boldsymbol{\zeta}} \left\| \mathsf{A}(\Phi \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}) - \boldsymbol{y}) \right\|^{2} + 2\mathbb{E}_{\boldsymbol{\zeta}} \left\langle \mathsf{A} \Phi \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}), \mathsf{A} \boldsymbol{\zeta} \right\rangle - \operatorname{tr} \left( \mathsf{A} \boldsymbol{\mathcal{S}} \mathsf{A}^{\top} \right)$ accessible accessible  $\mathbb{E}_{\mathcal{L}} \langle \mathsf{A} \Phi \widehat{\mathbf{x}}(\mathbf{y}; \mathbf{\Lambda}), \mathsf{A} \zeta \rangle = \mathbb{E}_{\mathcal{L}} \langle \Pi \widehat{\mathbf{x}}(\mathbf{y}; \mathbf{\Lambda}), \mathsf{A} \zeta \rangle$ 

Stein Unbiased Risk Estimate généralisé (Calcul) **Observations**  $\mathbf{y} = \mathbf{\Phi} \bar{\mathbf{x}} + \boldsymbol{\zeta} \in \mathbb{R}^{P}, \quad \bar{\mathbf{x}} \in \mathbb{R}^{N}, \ \mathbf{\Phi} : \mathbb{R}^{P \times N} \text{ et } \boldsymbol{\zeta} \sim \mathcal{N}(\mathbf{0}, \boldsymbol{\mathcal{S}})$  $R_{\Pi}(\Lambda) \triangleq \mathbb{E}_{\mathcal{L}} \|\Pi \widehat{\mathbf{x}}(\mathbf{y}; \Lambda) - \Pi \overline{\mathbf{x}}\|^2$  $=\mathbb{E}_{\mathcal{L}}\left\|\Pi(\Phi^{\top}\Phi)^{-1}\Phi^{\top}\Phi(\widehat{\mathbf{x}}(\mathbf{y};\Lambda)-\bar{\mathbf{x}})\right\|^{2}$  $\mathbf{A} \triangleq \mathbf{\Pi} (\mathbf{\Phi}^{\top} \mathbf{\Phi})^{-1} \mathbf{\Phi}^{\top}$  $=\mathbb{E}_{\mathcal{L}}\left\|\mathsf{A}(\mathbf{\Phi}\widehat{\mathbf{x}}(\mathbf{y};\mathbf{\Lambda})-\mathbf{y}+\mathbf{y}-\mathbf{\Phi}\overline{\mathbf{x}})\right\|^{2}$  $= \mathbb{E}_{\zeta} \|\mathbf{A}(\mathbf{\Phi}\widehat{\mathbf{x}}(\mathbf{y}; \mathbf{\Lambda}) - \mathbf{y} + \boldsymbol{\zeta})\|^2$  $=\mathbb{E}_{\boldsymbol{\zeta}}\left[\left\|\boldsymbol{\mathsf{A}}(\boldsymbol{\Phi}\widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda})-\boldsymbol{y})\right\|^{2}+2\left\langle\boldsymbol{\mathsf{A}}(\boldsymbol{\Phi}\widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda})-\boldsymbol{y}),\boldsymbol{\mathsf{A}}\boldsymbol{\zeta}\right\rangle+\left\|\boldsymbol{\mathsf{A}}\boldsymbol{\zeta}\right\|^{2}\right]$  $= \mathbb{E}_{\boldsymbol{\zeta}} \left[ \left\| \mathsf{A}(\boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}) - \boldsymbol{y}) \right\|^{2} + 2 \left\langle \mathsf{A} \boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}), \mathsf{A} \boldsymbol{\zeta} \right\rangle - 2 \left\langle \mathsf{A} \boldsymbol{y}, \mathsf{A} \boldsymbol{\zeta} \right\rangle + \left\| \mathsf{A} \boldsymbol{\zeta} \right\|^{2} \right]$  $= \mathbb{E}_{\boldsymbol{\zeta}} \left[ \left\| \mathsf{A}(\boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}) - \boldsymbol{y}) \right\|^{2} + 2 \left\langle \mathsf{A} \boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}), \mathsf{A} \boldsymbol{\zeta} \right\rangle - 2 \left\langle \mathsf{A} \qquad \boldsymbol{\zeta} \right. , \mathsf{A} \boldsymbol{\zeta} \right\rangle + \left\| \mathsf{A} \boldsymbol{\zeta} \right\|^{2} \right]$  $= \mathbb{E}_{\boldsymbol{\zeta}} \left\| \mathsf{A}(\boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}) - \boldsymbol{y}) \right\|^{2} + 2\mathbb{E}_{\boldsymbol{\zeta}} \left\langle \mathsf{A} \boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}), \mathsf{A} \boldsymbol{\zeta} \right\rangle - \mathrm{tr} \left( \mathsf{A} \boldsymbol{\mathcal{S}} \mathsf{A}^{\top} \right)$ accessible accessible  $\mathbb{E}_{\mathcal{L}} \langle \mathsf{A} \Phi \widehat{x}(\mathbf{y}; \Lambda), \mathsf{A} \zeta \rangle = \mathbb{E}_{\mathcal{L}} \langle \Pi \widehat{x}(\mathbf{y}; \Lambda), \mathsf{A} \zeta \rangle$  $= \int \langle \Pi \widehat{x} (\Phi \overline{x} + \zeta; \lambda), \mathbf{A} \zeta \rangle \exp(-\frac{\zeta^{\top} \mathcal{S}^{-1} \zeta}{2}) \, \mathrm{d} \zeta$ 

Stein Unbiased Risk Estimate généralisé (Calcul) **Observations**  $\mathbf{y} = \mathbf{\Phi} \bar{\mathbf{x}} + \boldsymbol{\zeta} \in \mathbb{R}^{P}, \quad \bar{\mathbf{x}} \in \mathbb{R}^{N}, \ \mathbf{\Phi} : \mathbb{R}^{P \times N} \text{ et } \boldsymbol{\zeta} \sim \mathcal{N}(\mathbf{0}, \boldsymbol{\mathcal{S}})$  $R_{\Pi}(\Lambda) \triangleq \mathbb{E}_{\mathcal{L}} \|\Pi \widehat{\mathbf{x}}(\mathbf{y}; \Lambda) - \Pi \overline{\mathbf{x}}\|^2$  $= \mathbb{E}_{\mathcal{L}} \left\| \Pi(\Phi^{\top} \Phi)^{-1} \Phi^{\top} \Phi(\widehat{\mathbf{x}}(\mathbf{y}; \Lambda) - \bar{\mathbf{x}}) \right\|^{2}$  $\mathbf{A} \triangleq \mathbf{\Pi} (\mathbf{\Phi}^{\top} \mathbf{\Phi})^{-1} \mathbf{\Phi}^{\top}$  $=\mathbb{E}_{\mathcal{L}}\left\|\mathsf{A}(\mathbf{\Phi}\widehat{\mathbf{x}}(\mathbf{y};\mathbf{\Lambda})-\mathbf{y}+\mathbf{y}-\mathbf{\Phi}\overline{\mathbf{x}})\right\|^{2}$  $= \mathbb{E}_{\zeta} \|\mathbf{A}(\mathbf{\Phi}\widehat{\mathbf{x}}(\mathbf{y}; \mathbf{\Lambda}) - \mathbf{y} + \boldsymbol{\zeta})\|^2$  $=\mathbb{E}_{\boldsymbol{\zeta}}\left[\left\|\boldsymbol{\mathsf{A}}(\boldsymbol{\Phi}\widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda})-\boldsymbol{y})\right\|^{2}+2\left\langle\boldsymbol{\mathsf{A}}(\boldsymbol{\Phi}\widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda})-\boldsymbol{y}),\boldsymbol{\mathsf{A}}\boldsymbol{\zeta}\right\rangle+\left\|\boldsymbol{\mathsf{A}}\boldsymbol{\zeta}\right\|^{2}\right]$  $= \mathbb{E}_{\boldsymbol{\zeta}} \left[ \left\| \mathsf{A}(\boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}) - \boldsymbol{y}) \right\|^{2} + 2 \left\langle \mathsf{A} \boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}), \mathsf{A} \boldsymbol{\zeta} \right\rangle - 2 \left\langle \mathsf{A} \boldsymbol{y}, \mathsf{A} \boldsymbol{\zeta} \right\rangle + \left\| \mathsf{A} \boldsymbol{\zeta} \right\|^{2} \right]$  $= \mathbb{E}_{\boldsymbol{\zeta}} \left[ \left\| \mathsf{A}(\boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}) - \boldsymbol{y}) \right\|^{2} + 2 \left\langle \mathsf{A} \boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}), \mathsf{A} \boldsymbol{\zeta} \right\rangle - 2 \left\langle \mathsf{A} \qquad \boldsymbol{\zeta} \right. , \mathsf{A} \boldsymbol{\zeta} \right\rangle + \left\| \mathsf{A} \boldsymbol{\zeta} \right\|^{2} \right]$  $= \mathbb{E}_{\boldsymbol{\zeta}} \left\| \mathsf{A}(\boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}) - \boldsymbol{y}) \right\|^{2} + 2\mathbb{E}_{\boldsymbol{\zeta}} \left\langle \mathsf{A} \boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}), \mathsf{A} \boldsymbol{\zeta} \right\rangle - \mathrm{tr} \left( \mathsf{A} \boldsymbol{\mathcal{S}} \mathsf{A}^{\top} \right)$ accessible accessible  $\mathbb{E}_{\mathcal{L}} \langle \mathsf{A} \Phi \widehat{x}(\mathbf{y}; \Lambda), \mathsf{A} \zeta \rangle = \mathbb{E}_{\mathcal{L}} \langle \Pi \widehat{x}(\mathbf{y}; \Lambda), \mathsf{A} \zeta \rangle$  $= \int \langle \Pi \widehat{\boldsymbol{x}} (\boldsymbol{\Phi} \overline{\boldsymbol{x}} + \boldsymbol{\zeta}; \boldsymbol{\lambda}), \boldsymbol{A} \boldsymbol{\zeta} \rangle \exp(-\frac{\boldsymbol{\zeta}^{\top} \boldsymbol{\mathcal{S}}^{-1} \boldsymbol{\zeta}}{2}) \, \mathrm{d} \boldsymbol{\zeta}$ (I.P.P. gén.) =  $\mathbb{E}_{\boldsymbol{\zeta}} \operatorname{tr} \left( \boldsymbol{\mathcal{S}} \boldsymbol{\mathsf{A}}^{\top} \boldsymbol{\Pi} \partial_{\boldsymbol{y}} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}) \right)$ 30 Stein Unbiased Risk Estimate généralisé Observations  $\mathbf{y} = \mathbf{\Phi} \bar{\mathbf{x}} + \boldsymbol{\zeta} \in \mathbb{R}^{P}, \quad \bar{\mathbf{x}} \in \mathbb{R}^{N}, \ \mathbf{\Phi} : \mathbb{R}^{P \times N} \text{ et } \boldsymbol{\zeta} \sim \mathcal{N}(\mathbf{0}, \boldsymbol{\mathcal{S}})$ 

Ex. des estimateurs  $\widehat{h}(\mathcal{L}; \lambda, \alpha)$  à contours libres ou co-localisés

 $\log \mathcal{L} = \Phi(\bar{h}, \bar{v}) + \zeta \qquad \zeta \sim \mathcal{N}(\mathbf{0}, \mathcal{S}) \qquad \mathcal{R} = \|\widehat{h} - \bar{h}\|^2$  $\Phi : (h, v) \mapsto \{\log(a)h + v\}_a \qquad \overbrace{\cdot \cdot \cdot \cdot \cdot \cdot \cdot}^{\bullet \bullet \bullet \bullet \bullet \bullet \bullet \bullet \bullet} \qquad \Pi : (h, v) \mapsto (h, \mathbf{0})$ 

Erreur d'estimation projetée  $R_{\Pi}(\Lambda) \triangleq \mathbb{E}_{\zeta} \|\Pi \widehat{x}(\mathbf{y}; \Lambda) - \Pi \overline{x}\|^2$ 

#### Théorème (Pascal, 2020)

Soit  $({m y};{m \Lambda})\mapsto \widehat{{m x}}({m y};{m \Lambda})$  un estimateur de  $ar{{m x}}$ 

- différentiable au sens faible par rapport à y,
- tel que  $\boldsymbol{\zeta} \mapsto \langle \Pi \widehat{\boldsymbol{x}}(\overline{\boldsymbol{x}} + \boldsymbol{\zeta}; \lambda), \boldsymbol{A} \boldsymbol{\zeta} \rangle$  est intégrable par rapport à  $\mathcal{N}(\boldsymbol{0}, \boldsymbol{\mathcal{S}})$ .

$$\begin{split} \widehat{R}(\boldsymbol{\Lambda}) &\triangleq \|\boldsymbol{\mathsf{A}}(\boldsymbol{\Phi}\widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda}) - \boldsymbol{y})\|^2 + 2\mathrm{tr}\left(\boldsymbol{\mathcal{S}}\boldsymbol{\mathsf{A}}^\top\boldsymbol{\Pi}\partial_{\boldsymbol{y}}\widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda})\right) - \mathrm{tr}\left(\boldsymbol{\mathsf{A}}\boldsymbol{\mathcal{S}}\boldsymbol{\mathsf{A}}^\top\right) \\ &\Longrightarrow R_{\boldsymbol{\Pi}}(\boldsymbol{\Lambda}) = \mathbb{E}_{\boldsymbol{\zeta}}[\widehat{R}(\boldsymbol{\Lambda})]. \end{split}$$

Stein Unbiased Risk Estimate généralisé Observations  $\mathbf{y} = \mathbf{\Phi} \bar{\mathbf{x}} + \boldsymbol{\zeta} \in \mathbb{R}^{P}, \quad \bar{\mathbf{x}} \in \mathbb{R}^{N}, \ \mathbf{\Phi} : \mathbb{R}^{P \times N} \text{ et } \boldsymbol{\zeta} \sim \mathcal{N}(\mathbf{0}, \boldsymbol{\mathcal{S}})$ 

Ex. des estimateurs  $\widehat{h}(\mathcal{L}; \lambda, \alpha)$  à contours libres ou co-localisés

 $\log \mathcal{L} = \Phi(\bar{h}, \bar{v}) + \zeta \qquad \zeta \sim \mathcal{N}(\mathbf{0}, \mathcal{S}) \qquad \mathcal{R} = \|\widehat{h} - \bar{h}\|^2$  $\Phi : (h, v) \mapsto \{\log(a)h + v\}_a \qquad \overbrace{\cdot \cdot \cdot \cdot \cdot \cdot \cdot}^{\bullet \bullet \bullet \bullet \bullet \bullet \bullet \bullet \bullet} \qquad \Pi : (h, v) \mapsto (h, \mathbf{0})$ 

Erreur d'estimation projetée  $R_{\Pi}(\Lambda) \triangleq \mathbb{E}_{\zeta} \|\Pi \widehat{x}(\mathbf{y}; \Lambda) - \Pi \overline{x}\|^2$ 

#### Théorème (Pascal, 2020)

Soit  $({m y};{m \Lambda})\mapsto \widehat{{m x}}({m y};{m \Lambda})$  un estimateur de  $ar{{m x}}$ 

- différentiable au sens faible par rapport à y,
- tel que  $\boldsymbol{\zeta} \mapsto \langle \Pi \widehat{\boldsymbol{x}}(\overline{\boldsymbol{x}} + \boldsymbol{\zeta}; \lambda), \boldsymbol{A} \boldsymbol{\zeta} \rangle$  est intégrable par rapport à  $\mathcal{N}(\boldsymbol{0}, \boldsymbol{\mathcal{S}})$ .

$$egin{aligned} \widehat{R}(oldsymbol{\Lambda}) &\triangleq \|oldsymbol{A}(oldsymbol{\Phi}\widehat{x}(oldsymbol{y};oldsymbol{\Lambda}) - oldsymbol{y})\|^2 + 2\mathrm{tr}\left(oldsymbol{\mathcal{S}}oldsymbol{A}^ op \Pi\partial_{oldsymbol{y}}\widehat{x}(oldsymbol{y};oldsymbol{\Lambda})
ight) - \mathrm{tr}\left(oldsymbol{A}oldsymbol{\mathcal{S}}oldsymbol{A}^ op 
ight) \ &\Longrightarrow R_{\Pi}(oldsymbol{\Lambda}) = \mathbb{E}_{\zeta}[\widehat{R}(oldsymbol{\Lambda})]. \end{aligned}$$

Introduction Caractérisation de texture Construction de fonctionnelles Algorithme de minimisation accéléré Réglage des hyperparamètres Conclusion

## Calcul des degrés de liberté

Degrés de liberté

$$\acute{\mathbf{b}} \qquad \mathrm{dof} \triangleq \mathrm{tr}\left(\boldsymbol{\mathcal{S}} \mathbf{A}^{\top} \boldsymbol{\Pi} \partial_{\boldsymbol{y}} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda})\right)$$

Introduction Caractérisation de texture Construction de fonctionnelles Algorithme de minimisation accéléré Réglage des hyperparamètres Conclusion

### Calcul des degrés de liberté

**Degrés de liberté** 
$$\operatorname{dof} \triangleq \operatorname{tr} \left( \boldsymbol{\mathcal{S}} \boldsymbol{\mathsf{A}}^\top \boldsymbol{\Pi} \partial_{\boldsymbol{y}} \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda}) \right)$$

• Stratégie de Monte Carlo (MC)  $M \in \mathbb{R}^{P \times P}$  de grande taille  $\operatorname{tr}(\mathsf{M}) = \mathbb{E}_{\varepsilon} \langle \mathsf{M} \varepsilon, \varepsilon \rangle, \quad \varepsilon \sim \mathcal{N}(\mathbf{0}, I_P)$ 

Introduction Caractérisation de texture Construction de fonctionnelles Algorithme de minimisation accéléré Réglage des hyperparamètres Conclusion

## Calcul des degrés de liberté

**Degrés de liberté** 
$$dof \triangleq tr \left( SA^{\top} \Pi \partial_{y} \hat{x}(y; \Lambda) \right)$$

- Stratégie de Monte Carlo (MC)  $M \in \mathbb{R}^{P \times P}$  de grande taille  $\operatorname{tr}(\mathsf{M}) = \mathbb{E}_{\varepsilon} \langle \mathsf{M} \varepsilon, \varepsilon \rangle, \quad \varepsilon \sim \mathcal{N}(\mathbf{0}, I_P)$
- Différences Finies (DF) Jacobienne inaccessible  $\partial_{\mathbf{y}} \widehat{\mathbf{x}} \left[ \mathbf{\varepsilon} \right] \underset{\nu \to 0}{\simeq} \frac{1}{\nu} \left( \widehat{\mathbf{x}} (\mathbf{y} + \nu \mathbf{\varepsilon}; \mathbf{\Lambda}) - \widehat{\mathbf{x}} (\mathbf{y}; \mathbf{\Lambda}) \right)$

Introduction Caractérisation de texture Con 0000 0000 000

Construction de fonct
 OO

Algorithme de minimisation accél

Réglage des hyperparamètres Conclusie

## Calcul des degrés de liberté

Degrés de liberté 
$$\mathrm{dof} \triangleq \mathrm{tr}\left(\mathcal{S}\mathbf{A}^{\top}\mathbf{\Pi}\partial_{\mathbf{y}}\widehat{\mathbf{x}}(\mathbf{y};\mathbf{\Lambda})\right)$$

- Stratégie de Monte Carlo (MC)  $M \in \mathbb{R}^{P \times P}$  de grande taille  $\operatorname{tr}(M) = \mathbb{E}_{\varepsilon} \langle M \varepsilon, \varepsilon \rangle, \quad \varepsilon \sim \mathcal{N}(\mathbf{0}, I_P)$
- Différences Finies (DF) Jacobienne inaccessible  $\partial_{y} \hat{x} [\varepsilon] \underset{\nu \to 0}{\simeq} \frac{1}{\nu} (\hat{x}(y + \nu \varepsilon; \Lambda) - \hat{x}(y; \Lambda))$

#### Proposition (Pascal, 2020)

Soit  $(m{y};m{\Lambda})\mapsto \widehat{m{x}}(m{y};m{\Lambda})$  un estimateur de  $ar{m{x}}$ 

- uniformément lipschitzien par rapport à y,
- tel que  $orall \Lambda \in \mathbb{R}^L$ ,  $\widehat{\pmb{x}}(\pmb{0}_P; \pmb{\Lambda}) = \pmb{0}_N$ . Alors

$$\mathbb{E}_{\boldsymbol{\zeta}}\left[\operatorname{dof}\right] = \lim_{\nu \to 0} \mathbb{E}_{\boldsymbol{\zeta}, \boldsymbol{\varepsilon}}\left[\frac{1}{\nu} \left\langle \boldsymbol{\mathcal{S}} \boldsymbol{\mathsf{A}}^\top \boldsymbol{\Pi}\left(\widehat{\boldsymbol{x}}(\boldsymbol{y} + \nu \boldsymbol{\varepsilon}; \boldsymbol{\Lambda}) - \widehat{\boldsymbol{x}}(\boldsymbol{y}; \boldsymbol{\Lambda})\right), \boldsymbol{\varepsilon} \right\rangle\right]$$

## Stein Unbiased Risk Estimate (Calcul)

**Observations**  $\mathbf{y} = \mathbf{\Phi} \bar{\mathbf{x}} + \boldsymbol{\zeta} \in \mathbb{R}^{P}, \quad \bar{\mathbf{x}} \in \mathbb{R}^{N}, \ \mathbf{\Phi} : \mathbb{R}^{P \times N} \text{ et } \boldsymbol{\zeta} \sim \mathcal{N}(\mathbf{0}, \boldsymbol{\mathcal{S}})$ 

**Erreur d'estimation projetée**  $R_{\Pi}(\Lambda) \triangleq \mathbb{E}_{\mathcal{L}} \| \Pi \hat{\mathbf{x}}(\mathbf{y}; \Lambda) - \Pi \bar{\mathbf{x}} \|^2$ 

SURE généralisé Différences Finies Monte Carlo

$$\widehat{R}_{\nu,\boldsymbol{\varepsilon}}(\boldsymbol{y};\boldsymbol{\Lambda} \,|\, \boldsymbol{\mathcal{S}}) \triangleq \|\boldsymbol{\mathsf{A}} \left(\boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda}) - \boldsymbol{y}\right)\|^{2} + \frac{2}{\nu} \left\langle \boldsymbol{\mathcal{S}} \boldsymbol{\mathsf{A}}^{\top} \boldsymbol{\Pi} \left(\widehat{\boldsymbol{x}}(\boldsymbol{y} + \nu \boldsymbol{\varepsilon};\boldsymbol{\Lambda}) - \widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda})\right), \boldsymbol{\varepsilon} \right\rangle - \operatorname{tr} \left(\boldsymbol{\mathsf{A}} \boldsymbol{\mathcal{S}} \boldsymbol{\mathsf{A}}^{\top}\right)$$

## Stein Unbiased Risk Estimate (Calcul)

**Observations**  $\mathbf{y} = \mathbf{\Phi} \bar{\mathbf{x}} + \boldsymbol{\zeta} \in \mathbb{R}^{P}, \quad \bar{\mathbf{x}} \in \mathbb{R}^{N}, \ \mathbf{\Phi} : \mathbb{R}^{P \times N} \text{ et } \boldsymbol{\zeta} \sim \mathcal{N}(\mathbf{0}, \boldsymbol{\mathcal{S}})$ 

**Erreur d'estimation projetée**  $R_{\Pi}(\Lambda) \triangleq \mathbb{E}_{\mathcal{L}} \| \Pi \widehat{\mathbf{x}}(\mathbf{y}; \Lambda) - \Pi \overline{\mathbf{x}} \|^2$ 

SURE généralisé Différences Finies Monte Carlo

$$\widehat{R}_{\nu,\varepsilon}(\boldsymbol{y};\boldsymbol{\Lambda} \,|\, \boldsymbol{S}) \triangleq \|\boldsymbol{\mathsf{A}} \left( \Phi \widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda}) - \boldsymbol{y} \right)\|^2 + \frac{2}{\nu} \left\langle \boldsymbol{\mathcal{S}} \boldsymbol{\mathsf{A}}^\top \boldsymbol{\Pi} \left( \widehat{\boldsymbol{x}}(\boldsymbol{y} + \nu \boldsymbol{\varepsilon};\boldsymbol{\Lambda}) - \widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda}) \right), \boldsymbol{\varepsilon} \right\rangle - \operatorname{tr} \left( \boldsymbol{\mathsf{A}} \boldsymbol{\mathcal{S}} \boldsymbol{\mathsf{A}}^\top \right)$$

#### Théorème (Pascal, 2020)

Soit  $(\mathbf{y}; \mathbf{\Lambda}) \mapsto \widehat{\mathbf{x}}(\mathbf{y}; \mathbf{\Lambda})$  un estimateur de  $\overline{\mathbf{x}}$ 

- uniformément lipschitzien par rapport à y,
- tel que  $\forall \Lambda \in \mathbb{R}^L$ ,  $\widehat{\mathbf{x}}(\mathbf{0}_P; \Lambda) = \mathbf{0}_N$ . Alors

$${\it R}_{oldsymbol{\Pi}}(oldsymbol{\Lambda}) = \lim_{
u
ightarrow 0} \mathbb{E}_{oldsymbol{\zeta},oldsymbol{arepsilon}} \left[\widehat{\it R}_{
u,oldsymbol{arepsilon}}(oldsymbol{y};oldsymbol{\Lambda}\,|\,oldsymbol{\mathcal{S}})
ight]$$

$$\left(\widehat{\boldsymbol{h}}, \widehat{\boldsymbol{v}}\right)(\boldsymbol{\mathcal{L}}; \lambda, \alpha) = \underset{\boldsymbol{h}, \boldsymbol{v}}{\operatorname{argmin}} \sum_{\boldsymbol{a}} \|\log \boldsymbol{\mathcal{L}}_{\boldsymbol{a}, \cdot} - \log(\boldsymbol{a})\boldsymbol{h} - \boldsymbol{v}\|^2 + \lambda \mathcal{Q}(\mathsf{D}\boldsymbol{h}, \mathsf{D}\boldsymbol{v}; \alpha)$$

**h** : vraie régularité  $\mathcal{R}(\lambda,\alpha) = \left\| \widehat{\boldsymbol{h}}(\mathcal{L};\lambda,\alpha) - \overline{\boldsymbol{h}} \right\|^2$  $\mathbf{2}$ 15000 1 10000  $\log_{10}(\lambda)$ 5000 -1 -2 -2 0 2 $\log_{10}(\alpha)$ 

**h** : inconnue !

$$\widehat{R}_{\nu,\varepsilon}(\mathcal{L};\lambda,\alpha|\mathcal{S})$$

$$\left(\widehat{\boldsymbol{h}}, \widehat{\boldsymbol{v}}\right)(\boldsymbol{\mathcal{L}}; \lambda, \alpha) = \underset{\boldsymbol{h}, \boldsymbol{v}}{\operatorname{argmin}} \sum_{\boldsymbol{a}} \|\log \boldsymbol{\mathcal{L}}_{\boldsymbol{a}, \ldots} - \log(\boldsymbol{a})\boldsymbol{h} - \boldsymbol{v}\|^2 + \lambda \mathcal{Q}(\boldsymbol{\mathsf{D}}\boldsymbol{h}, \boldsymbol{\mathsf{D}}\boldsymbol{v}; \alpha)$$

**h** : *vraie* régularité  $\mathcal{R}(\lambda,\alpha) = \left\| \widehat{\boldsymbol{h}}(\mathcal{L};\lambda,\alpha) - \overline{\boldsymbol{h}} \right\|^2$ 15000 1 10000  $\log_{10}(\lambda)$ 5000 -1 -2 -2 0 2 $\log_{10}(\alpha)$ 

 $\bar{h}$  : inconnue!

 $\widehat{R}_{\nu,\varepsilon}(\mathcal{L};\lambda,\alpha|\mathcal{S})$ 



$$\left(\widehat{\boldsymbol{h}}, \widehat{\boldsymbol{v}}\right)(\boldsymbol{\mathcal{L}}; \lambda, \alpha) = \underset{\boldsymbol{h}, \boldsymbol{v}}{\operatorname{argmin}} \sum_{\boldsymbol{a}} \|\log \boldsymbol{\mathcal{L}}_{\boldsymbol{a}, \ldots} - \log(\boldsymbol{a})\boldsymbol{h} - \boldsymbol{v}\|^2 + \lambda \mathcal{Q}(\boldsymbol{\mathsf{D}}\boldsymbol{h}, \boldsymbol{\mathsf{D}}\boldsymbol{v}; \alpha)$$

**h** : *vraie* régularité  $\mathcal{R}(\lambda,\alpha) = \left\| \widehat{\boldsymbol{h}}(\mathcal{L};\lambda,\alpha) - \overline{\boldsymbol{h}} \right\|^2$ 15000 1 10000  $\log_{10}(\lambda)$ 5000 -1 -2 -2 0 2 $\log_{10}(\alpha)$ 

**h** : inconnue !

 $\widehat{R}_{\nu,\varepsilon}(\mathcal{L};\lambda,\alpha|\mathcal{S})$ 



$$\left(\widehat{\boldsymbol{h}}, \widehat{\boldsymbol{v}}\right)(\boldsymbol{\mathcal{L}}; \lambda, \alpha) = \underset{\boldsymbol{h}, \boldsymbol{v}}{\operatorname{argmin}} \sum_{\boldsymbol{a}} \|\log \boldsymbol{\mathcal{L}}_{\boldsymbol{a}, \cdot} - \log(\boldsymbol{a})\boldsymbol{h} - \boldsymbol{v}\|^2 + \lambda \mathcal{Q}(\boldsymbol{\mathsf{D}}\boldsymbol{h}, \boldsymbol{\mathsf{D}}\boldsymbol{v}; \alpha)$$

**h** : *vraie* régularité  $\mathcal{R}(\lambda,\alpha) = \left\| \widehat{\boldsymbol{h}}(\mathcal{L};\lambda,\alpha) - \overline{\boldsymbol{h}} \right\|^2$ 15000 1 10000  $\log_{10}(\lambda)$ 5000 -1 -2 -2 0 2 $\log_{10}(\alpha)$ 

**h** : inconnue!

 $\widehat{R}_{\nu,\varepsilon}(\mathcal{L};\lambda,\alpha|\mathcal{S})$ 



### Recherche systématique des paramètres de régularisation

$$\left(\widehat{\boldsymbol{h}}^{\mathsf{L}}, \widehat{\boldsymbol{v}}^{\mathsf{L}}\right)(\boldsymbol{\mathcal{L}}; \boldsymbol{\Lambda}) = \underset{\boldsymbol{h}, \boldsymbol{v}}{\operatorname{argmin}} \sum_{\boldsymbol{a}} \|\log \boldsymbol{\mathcal{L}}_{\boldsymbol{a}, \cdot} - \log(\boldsymbol{a})\boldsymbol{h} - \boldsymbol{v}\|^2 + \lambda \mathcal{Q}_{\mathsf{L}}(\mathsf{D}\boldsymbol{h}, \mathsf{D}\boldsymbol{v}; \alpha)$$

#### Exemple



### Recherche systématique des paramètres de régularisation

$$\left(\widehat{\mathbf{h}}^{\mathsf{L}}, \widehat{\mathbf{v}}^{\mathsf{L}}\right)(\mathcal{L}; \mathbf{\Lambda}) = \underset{\mathbf{h}, \mathbf{v}}{\operatorname{argmin}} \sum_{\mathbf{a}} \|\log \mathcal{L}_{\mathbf{a}, \cdot} - \log(\mathbf{a})\mathbf{h} - \mathbf{v}\|^2 + \lambda \mathcal{Q}_{\mathsf{L}}(\mathsf{D}\mathbf{h}, \mathsf{D}\mathbf{v}; \alpha)$$












#### Recherche systématique des paramètres de régularisation

$$\begin{aligned} \left( \hat{h}^{L}, \hat{v}^{L} \right) (\mathcal{L}; \Lambda) &= \underset{h, v}{\operatorname{argmin}} \sum_{a} \| \log \mathcal{L}_{a, \cdot} - \log(a)h - v \|^{2} + \lambda \mathcal{Q}_{L}(\mathbf{D}h, \mathbf{D}v; \alpha) \end{aligned} \\ \begin{aligned} \mathbf{Exemple} & \hat{h}^{L}(\mathcal{L}; \lambda^{\dagger}, \alpha^{\dagger}) \\ \left( \operatorname{grille} \right) & \hat{h}^{L}(\mathcal{L}; \hat{\lambda}^{\dagger}, \hat{\alpha}^{\dagger}) \\ \left( \operatorname{grille} \right) & \hat{h}^{L}(\mathcal{L}; \hat{\lambda}^{\dagger}) \\ \left( \operatorname{grille} \right) & \hat{h}^{L}(\mathcal{L}; \hat{\lambda}^{\dagger}) \\ \left( \operatorname{grille} \right) \\ \left( \operatorname{grille} \right) & \hat{h}^{L}(\mathcal{L}; \hat{\lambda}^{\dagger}) \\ \left( \operatorname{$$

#### Recherche systématique des paramètres de régularisation



 $15 \times 15 = 225$  paramètres  $\longrightarrow$  recherche sur grille très coûteuse

**Observations**  $\mathbf{y} = \mathbf{\Phi} \bar{\mathbf{x}} + \boldsymbol{\zeta} \in \mathbb{R}^{P}$ ,  $\bar{\mathbf{x}} \in \mathbb{R}^{N}$ ,  $\mathbf{\Phi} : \mathbb{R}^{P \times N}$  et  $\boldsymbol{\zeta} \sim \mathcal{N}(\mathbf{0}, \boldsymbol{\mathcal{S}})$ 

 $\mathsf{SURE} \,\, \mathsf{g\acute{e}n\acute{e}ralis\acute{e}} \,\, \mathsf{DFMC} \quad \lim_{\nu \to 0} \mathbb{E}_{\zeta,\varepsilon} \widehat{R}_{\nu,\varepsilon}(\textbf{\textit{y}}; \Lambda \,|\, \boldsymbol{\mathcal{S}}) = R_{\Pi}(\Lambda)$ 

 $\textbf{Observations} \quad \textbf{\textit{y}} = \boldsymbol{\Phi} \bar{\textbf{\textit{x}}} + \boldsymbol{\zeta} \in \mathbb{R}^{P}, \quad \bar{\textbf{\textit{x}}} \in \mathbb{R}^{N}, \ \boldsymbol{\Phi} : \mathbb{R}^{P \times N} \text{ et } \boldsymbol{\zeta} \sim \mathcal{N}(\textbf{0}, \boldsymbol{\mathcal{S}})$ 

 $\mathsf{SURE} \,\, \mathsf{généralisé} \,\, \mathsf{DFMC} \quad \lim_{\nu \to 0} \mathbb{E}_{\boldsymbol{\zeta},\varepsilon} \widehat{R}_{\nu,\varepsilon}(\boldsymbol{y}; \boldsymbol{\Lambda} \,|\, \boldsymbol{\mathcal{S}}) = R_{\boldsymbol{\Pi}}(\boldsymbol{\Lambda})$ 

 $\mathsf{But}: \min_{\boldsymbol{\Lambda}} \operatorname{iser} \, \widehat{R}_{\nu, \boldsymbol{\varepsilon}}(\boldsymbol{y}; \boldsymbol{\Lambda} \,|\, \boldsymbol{\mathcal{S}}) \qquad \qquad \mathsf{pour} \,\, \boldsymbol{y}, \,\, \boldsymbol{\mathcal{S}} \,\, \mathsf{donn\acute{e}s}$ 

 $\textbf{Observations} \quad \textbf{\textit{y}} = \boldsymbol{\Phi} \bar{\textbf{\textit{x}}} + \boldsymbol{\zeta} \in \mathbb{R}^{P}, \quad \bar{\textbf{\textit{x}}} \in \mathbb{R}^{N}, \ \boldsymbol{\Phi} : \mathbb{R}^{P \times N} \text{ et } \boldsymbol{\zeta} \sim \mathcal{N}(\textbf{0}, \boldsymbol{\mathcal{S}})$ 

 $\mathsf{SURE} \,\, \mathsf{g}\acute{\mathsf{e}}\mathsf{n}\acute{\mathsf{e}}\mathsf{ralis\acute{e}} \,\, \mathsf{DFMC} \quad \lim_{\nu \to 0} \mathbb{E}_{\boldsymbol{\zeta},\varepsilon} \widehat{R}_{\nu,\varepsilon}(\boldsymbol{y}; \boldsymbol{\Lambda} \,|\, \boldsymbol{\mathcal{S}}) = R_{\Pi}(\boldsymbol{\Lambda})$ 

 $\mathsf{But}: \operatornamewithlimits{minimiser}_{\boldsymbol{\Lambda}} \widehat{R}_{\nu, \boldsymbol{\varepsilon}}(\boldsymbol{y}; \boldsymbol{\Lambda} \,|\, \boldsymbol{\mathcal{S}}) \equiv \widehat{R}(\boldsymbol{\Lambda}) \quad \text{ pour } \boldsymbol{y}, \, \boldsymbol{\mathcal{S}} \text{ donnés}$ 

 $\textbf{Observations} \quad \textbf{\textit{y}} = \boldsymbol{\Phi} \bar{\textbf{\textit{x}}} + \boldsymbol{\zeta} \in \mathbb{R}^{P}, \quad \bar{\textbf{\textit{x}}} \in \mathbb{R}^{N}, \ \boldsymbol{\Phi} : \mathbb{R}^{P \times N} \text{ et } \boldsymbol{\zeta} \sim \mathcal{N}(\textbf{0}, \boldsymbol{\mathcal{S}})$ 

$$\mathsf{SURE} \,\, \mathsf{g\acute{e}n\acute{e}ralis\acute{e}} \,\, \mathsf{DFMC} \quad \lim_{\nu \to 0} \mathbb{E}_{\boldsymbol{\zeta},\varepsilon} \widehat{R}_{\nu,\varepsilon}(\boldsymbol{y}; \boldsymbol{\Lambda} \,|\, \boldsymbol{\mathcal{S}}) = R_{\boldsymbol{\Pi}}(\boldsymbol{\Lambda})$$

$$\mathsf{But}: \min_{\boldsymbol{\Lambda}} \inf \widehat{R}_{\nu, \boldsymbol{\varepsilon}}(\boldsymbol{y}; \boldsymbol{\Lambda} \,|\, \boldsymbol{\mathcal{S}}) \equiv \widehat{R}(\boldsymbol{\Lambda}) \quad \text{ pour } \boldsymbol{y}, \, \boldsymbol{\mathcal{S}} \text{ donnés}$$

Quasi-Newton de Broyden-Fletcher-Goldfarb-Shanno (Nocedal, 2006) for t = 0, 1, ...  $d^{[t]} = -H^{[t]}\partial_{\Lambda}\widehat{R}(\Lambda^{[t]})$  direction de descente  $\alpha^{[t]} \in \operatorname{Argmin}_{\alpha \in \mathbb{R}} \widehat{R}(\Lambda^{[t]} + \alpha d^{[t]})$  recherche sur une ligne  $\Lambda^{[t+1]} = \Lambda^{[t]} + \alpha^{[t]} d^{[t]}$   $u^{[t]} = \partial_{\Lambda}\widehat{R}(\Lambda^{[t+1]}) - \partial_{\Lambda}\widehat{R}(\Lambda^{[t]})$  variation du gradient  $H^{[t+1]} = \operatorname{BFGS}(H^{[t]}, d^{[t]}, u^{[t]})$  mise à jour "hessienne inverse"

 $\textbf{Observations} \quad \textbf{\textit{y}} = \boldsymbol{\Phi} \bar{\textbf{\textit{x}}} + \boldsymbol{\zeta} \in \mathbb{R}^{P}, \quad \bar{\textbf{\textit{x}}} \in \mathbb{R}^{N}, \ \boldsymbol{\Phi} : \mathbb{R}^{P \times N} \text{ et } \boldsymbol{\zeta} \sim \mathcal{N}(\textbf{0}, \boldsymbol{\mathcal{S}})$ 

$$\mathsf{SURE} \,\, \mathsf{g\acute{e}n\acute{e}ralis\acute{e}} \,\, \mathsf{DFMC} \quad \lim_{\nu \to 0} \mathbb{E}_{\boldsymbol{\zeta},\varepsilon} \widehat{R}_{\nu,\varepsilon}(\boldsymbol{y}; \boldsymbol{\Lambda} \,|\, \boldsymbol{\mathcal{S}}) = R_{\boldsymbol{\Pi}}(\boldsymbol{\Lambda})$$

 $\mathsf{But}: \min_{\boldsymbol{\Lambda}} \inf \widehat{R}_{\nu, \boldsymbol{\varepsilon}}(\boldsymbol{y}; \boldsymbol{\Lambda} \,|\, \boldsymbol{\mathcal{S}}) \equiv \widehat{R}(\boldsymbol{\Lambda}) \quad \text{ pour } \boldsymbol{y}, \, \boldsymbol{\mathcal{S}} \text{ donnés}$ 

Quasi-Newton de Broyden-Fletcher-Goldfarb-Shanno (Nocedal, 2006) for t = 0, 1, ...  $d^{[t]} = -H^{[t]}\partial_{\Lambda}\widehat{R}(\Lambda^{[t]})$  direction de descente  $\alpha^{[t]} \in \operatorname{Argmin}_{\alpha \in \mathbb{R}} \widehat{R}(\Lambda^{[t]} + \alpha d^{[t]})$  recherche sur une ligne  $\Lambda^{[t+1]} = \Lambda^{[t]} + \alpha^{[t]} d^{[t]}$   $u^{[t]} = \partial_{\Lambda}\widehat{R}(\Lambda^{[t+1]}) - \partial_{\Lambda}\widehat{R}(\Lambda^{[t]})$  variation du gradient  $H^{[t+1]} = \operatorname{BFGS}(H^{[t]}, u^{[t]})$  mise à jour "hessienne inverse"

### Stein Unbiased GrAdient Risk estimate

#### SURE généralisé DFMC

$$\widehat{R}_{\nu,\varepsilon}(\boldsymbol{y};\boldsymbol{\Lambda} \,|\, \boldsymbol{\mathcal{S}}) = \|\boldsymbol{\mathsf{A}} \left( \Phi \widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda}) - \boldsymbol{y} \right)\|^2 + \frac{2}{\nu} \left\langle \boldsymbol{\mathcal{S}} \boldsymbol{\mathsf{A}}^\top \boldsymbol{\Pi} \left( \widehat{\boldsymbol{x}}(\boldsymbol{y} + \nu \varepsilon;\boldsymbol{\Lambda}) - \widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda}) \right), \varepsilon \right\rangle - \operatorname{tr} \left( \boldsymbol{\mathsf{A}} \boldsymbol{\mathcal{S}} \boldsymbol{\mathsf{A}}^\top \right)$$

## Stein Unbiased GrAdient Risk estimate

#### SURE généralisé DFMC

$$\widehat{R}_{\nu,\varepsilon}(\boldsymbol{y};\boldsymbol{\Lambda} \,|\, \boldsymbol{\mathcal{S}}) = \|\boldsymbol{\mathsf{A}} \left( \boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda}) - \boldsymbol{y} \right)\|^2 + \frac{2}{\nu} \left\langle \boldsymbol{\mathcal{S}} \boldsymbol{\mathsf{A}}^\top \boldsymbol{\Pi} \left( \widehat{\boldsymbol{x}}(\boldsymbol{y} + \nu \boldsymbol{\varepsilon};\boldsymbol{\Lambda}) - \widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda}) \right), \boldsymbol{\varepsilon} \right\rangle - \operatorname{tr} \left( \boldsymbol{\mathsf{A}} \boldsymbol{\mathcal{S}} \boldsymbol{\mathsf{A}}^\top \right)$$

SUGAR généralisé Différences Finies Monte Carlo

$$egin{aligned} \partial_{\mathbf{\Lambda}}\widehat{R}_{
u,oldsymbol{arepsilon}}(oldsymbol{y};oldsymbol{\Lambda}\,|\,oldsymbol{\mathcal{S}}) &= 2\left(oldsymbol{A}\Phi\partial_{\mathbf{\Lambda}}\widehat{oldsymbol{x}}(oldsymbol{y};oldsymbol{\Lambda})
ight)^{ op}oldsymbol{A}\left(\Phi\widehat{oldsymbol{x}}(oldsymbol{y};oldsymbol{\Lambda})-oldsymbol{y}
ight) &+ rac{2}{
u}\left\langleoldsymbol{\mathcal{S}}oldsymbol{A}^{ op}\Pi\left(\partial_{\mathbf{\Lambda}}\widehat{oldsymbol{x}}(oldsymbol{y}+
uarepsilon;oldsymbol{\Lambda})-\partial_{\mathbf{\Lambda}}\widehat{oldsymbol{x}}(oldsymbol{y};oldsymbol{\Lambda})
ight),oldsymbol{arepsilon}
ight
angle \end{aligned}$$

## Stein Unbiased GrAdient Risk estimate

#### SURE généralisé DFMC

$$\widehat{R}_{\nu,\varepsilon}(\boldsymbol{y};\boldsymbol{\Lambda} \,|\, \boldsymbol{\mathcal{S}}) = \|\boldsymbol{\mathsf{A}} \left( \boldsymbol{\Phi} \widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda}) - \boldsymbol{y} \right)\|^2 + \frac{2}{\nu} \left\langle \boldsymbol{\mathcal{S}} \boldsymbol{\mathsf{A}}^\top \boldsymbol{\Pi} \left( \widehat{\boldsymbol{x}}(\boldsymbol{y} + \nu \boldsymbol{\varepsilon};\boldsymbol{\Lambda}) - \widehat{\boldsymbol{x}}(\boldsymbol{y};\boldsymbol{\Lambda}) \right), \boldsymbol{\varepsilon} \right\rangle - \operatorname{tr} \left( \boldsymbol{\mathsf{A}} \boldsymbol{\mathcal{S}} \boldsymbol{\mathsf{A}}^\top \right)$$

SUGAR généralisé Différences Finies Monte Carlo  $\partial_{\Lambda} \widehat{R}_{\nu,\varepsilon}(\mathbf{y}; \Lambda | \mathbf{S}) = 2 \left( \mathbf{A} \Phi \partial_{\Lambda} \widehat{\mathbf{x}}(\mathbf{y}; \Lambda) \right)^{\top} \mathbf{A} \left( \Phi \widehat{\mathbf{x}}(\mathbf{y}; \Lambda) - \mathbf{y} \right)$  $+ \frac{2}{\nu} \left\langle \mathbf{S} \mathbf{A}^{\top} \mathbf{\Pi} \left( \partial_{\Lambda} \widehat{\mathbf{x}}(\mathbf{y} + \nu \varepsilon; \Lambda) - \partial_{\Lambda} \widehat{\mathbf{x}}(\mathbf{y}; \Lambda) \right), \varepsilon \right\rangle$ 

#### Théorème (Pascal, 2020)

Soit  $(oldsymbol{y};oldsymbol{\Lambda})\mapsto \widehat{oldsymbol{x}}(oldsymbol{y};oldsymbol{\Lambda})$  un estimateur de  $oldsymbol{ar{x}}$ 

- uniformément lipschitzien par rapport à y
- tel que  $orall \Lambda \in \mathbb{R}^L$ ,  $\widehat{\pmb{x}}(\pmb{0}_P; \pmb{\Lambda}) = \pmb{0}_N$ ,
- uniformément *L*-lipschitzien par rapport à  $\Lambda$ , *L* indép. de  $\mathbf{y}$ . Alors  $\partial_{\Lambda} R_{\Pi}(\Lambda) = \lim_{\nu \to 0} \mathbb{E}_{\boldsymbol{\zeta}, \boldsymbol{\varepsilon}} \left[ \partial_{\Lambda} \widehat{R}_{\nu, \boldsymbol{\varepsilon}}(\mathbf{y}; \Lambda \,|\, \boldsymbol{\mathcal{S}}) \right]$

 Introduction
 Caractérisation de texture
 Construction de fonction

 0000
 0000
 00

Algorithme de minimisation accélé

Réglage des hyperparamètres Control Co

# Réglage des paramètres (Recherche automatique)

$$\left(\widehat{\boldsymbol{h}}, \widehat{\boldsymbol{v}}\right)(\boldsymbol{\mathcal{L}}; \lambda, \alpha) = \underset{\boldsymbol{h}, \boldsymbol{v}}{\operatorname{argmin}} \sum_{\boldsymbol{a}} \|\log \boldsymbol{\mathcal{L}}_{\boldsymbol{a}, \ldots} - \log(\boldsymbol{a})\boldsymbol{h} - \boldsymbol{v}\|^2 + \lambda \mathcal{Q}(\boldsymbol{\mathsf{D}}\boldsymbol{h}, \boldsymbol{\mathsf{D}}\boldsymbol{v}; \alpha)$$

**h** : *vraie* régularité  $\mathcal{R}(\lambda,\alpha) = \left\| \widehat{\boldsymbol{h}}(\mathcal{L};\lambda,\alpha) - \overline{\boldsymbol{h}} \right\|^2$ 15000 1 10000  $\log_{10}(\lambda)$ 5000 -1 -2 -2 0 2  $\log_{10}(\alpha)$ 

**h** : inconnue !

 $\widehat{R}_{\nu,\varepsilon}(\mathcal{L};\lambda,\alpha|\mathcal{S})$ 



#### Recherche automatique des paramètres de régularisation

$$\begin{aligned} \left( \hat{\boldsymbol{h}}^{\mathsf{L}}, \hat{\boldsymbol{v}}^{\mathsf{L}} \right) (\boldsymbol{\mathcal{L}}; \boldsymbol{\Lambda}) &= \operatorname{argmin}_{\boldsymbol{h}, \boldsymbol{v}} \sum_{\boldsymbol{a}} \|\log \boldsymbol{\mathcal{L}}_{\boldsymbol{a}, \cdot} - \log(\boldsymbol{a})\boldsymbol{h} - \boldsymbol{v}\|^{2} + \lambda \mathcal{Q}_{\mathsf{L}}(\mathsf{D}\boldsymbol{h}, \mathsf{D}\boldsymbol{v}; \boldsymbol{\alpha}) \\ \\ \hline \mathsf{Exemple} & \hat{\boldsymbol{h}}^{\mathsf{L}}(\boldsymbol{\mathcal{L}}; \lambda^{\dagger}, \boldsymbol{\alpha}^{\dagger}) \\ \left( \operatorname{grille} \right) & \hat{\boldsymbol{h}}^{\mathsf{L}}(\boldsymbol{\mathcal{L}}; \hat{\lambda}^{\dagger}, \hat{\boldsymbol{\alpha}}^{\dagger}) \\ \left( \operatorname{grille} \right) & \hat{\boldsymbol{\mu}}^{\mathsf{L}}(\boldsymbol{\mathcal{L}}; \hat{\lambda}^{\dagger}, \hat{\boldsymbol{\alpha}}^{\dagger}) \\ \hline \mathsf{O} & \mathsf{O} & \mathsf{O} \\ \hline \mathsf{O} \\ \hline \mathsf{O} \\ \hline \mathsf{O} & \mathsf{O}$$

#### Recherche automatique des paramètres de régularisation

#### Recherche automatique des paramètres de régularisation

$$\begin{aligned} \left( \hat{\boldsymbol{h}}^{L}, \hat{\boldsymbol{v}}^{L} \right) (\boldsymbol{\mathcal{L}}; \boldsymbol{\Lambda}) &= \underset{\boldsymbol{h}, \boldsymbol{v}}{\operatorname{argmin}} \sum_{\boldsymbol{a}} \| \log \boldsymbol{\mathcal{L}}_{\boldsymbol{a}, \cdot} - \log(\boldsymbol{a}) \boldsymbol{h} - \boldsymbol{v} \|^{2} + \lambda \mathcal{Q}_{L}(\mathbf{D}\boldsymbol{h}, \mathbf{D}\boldsymbol{v}; \boldsymbol{\alpha}) \\ \\ \mathbf{Exemple} & \hat{\boldsymbol{h}}^{L}(\boldsymbol{\mathcal{L}}; \lambda^{\dagger}, \boldsymbol{\alpha}^{\dagger}) \\ \left( \operatorname{grille} \right) & \hat{\boldsymbol{h}}^{L}(\boldsymbol{\mathcal{L}}; \hat{\lambda}^{\dagger}, \hat{\boldsymbol{\alpha}}^{\dagger}) \\ \left( \operatorname{grille} \right) & \hat{\boldsymbol{h}}^{L}(\boldsymbol{\mathcal{L}}; \hat{\lambda}^{q}, \hat{\boldsymbol{\alpha}}^{qN}) \\ \left( \operatorname{grille} \right) & \hat{\boldsymbol{h}}^{L}(\boldsymbol{\mathcal{L}}; \hat{\boldsymbol{\lambda}}^{q}, \hat{\boldsymbol{\alpha}}^{qN}) \\ \\ \left( \operatorname{grille} \right) & \hat{\boldsymbol{\mu}}^{L}(\boldsymbol{\mathcal{L}}; \hat{\boldsymbol{\lambda}}^{q}, \hat{\boldsymbol{\alpha}}^{qN}) \\ \\ \left( \operatorname{grille} \right) & \hat{\boldsymbol{\mu}}^{L}(\boldsymbol{\mathcal{L}}; \hat{\boldsymbol{\lambda}}^{q}, \hat{\boldsymbol{\alpha}}^{qN}) \\ \\ \left( \operatorname{grille} \right) & \hat{\boldsymbol{\mu}}^{L}(\boldsymbol{\mathcal{L}}; \hat{\boldsymbol{\lambda}}^{q}, \hat{\boldsymbol{\alpha}}^{qN}) \\ \\ \left( \operatorname{grille} \right) & \hat{\boldsymbol{\mu}}^{L}(\boldsymbol{\mathcal{L}}; \hat{\boldsymbol{\lambda}}^{q}, \hat{\boldsymbol{\alpha}}^{qN}) \\ \\ \left( \operatorname{grille} \right) & \hat{\boldsymbol{\mu}}^{L}(\boldsymbol{\mathcal{L}}; \hat{\boldsymbol{\lambda}}^{q}, \hat{\boldsymbol{\alpha}}^{qN}) \\ \\ \left( \operatorname{grille} \right) & \hat{\boldsymbol{\mu}}^{L}(\boldsymbol{\mathcal{L}}; \hat{\boldsymbol{\lambda}}^{q}, \hat{\boldsymbol{\alpha}}^{qN}) \\ \\ \left( \operatorname{grille} \right) & \hat{\boldsymbol{\mu}}^{L}(\boldsymbol{\mathcal{L}}; \hat{\boldsymbol{\lambda}}^{q}, \hat{\boldsymbol{\mu}}^{qN}) \\ \\ \left( \operatorname{grille} \right) & \hat{\boldsymbol{\mu}}^{L}(\boldsymbol{\mathcal{L}}; \hat{\boldsymbol{\lambda}}^{qN}, \hat{\boldsymbol{\mu}}^{qN}) \\ \\ \left( \operatorname{grille} \right) & \hat{\boldsymbol{\mu}}^{L}(\boldsymbol{\mathcal{L}}; \hat{\boldsymbol{\lambda}}^{qN}, \hat{\boldsymbol{\mu}}^{qN}) \\ \\ \left( \operatorname{grille} \right) & \hat{\boldsymbol{\mu}}^{L}(\boldsymbol{\mathcal{L}}; \hat{\boldsymbol{\mu}}^{N}, \hat{\boldsymbol{\mu}}^{qN}) \\ \\ \left( \operatorname{grille} \right) & \hat{\boldsymbol{\mu}}^{L}(\boldsymbol{\mathcal{L}}; \hat{\boldsymbol{\mu}}^{N}, \hat{\boldsymbol{\mu}}^{N}) \\ \\ \left( \operatorname{grille} \right) & \hat{\boldsymbol{\mu}}^{L}(\boldsymbol{\mathcal{L}}; \hat{\boldsymbol{\mu}}^{N}, \hat{\boldsymbol{\mu}}^{N}) \\ \\ \left( \operatorname{grille} \right) & \hat{\boldsymbol{\mu}}^{L}(\boldsymbol{\mathcal{L}}; \hat{\boldsymbol{\mu}}^{N}, \hat{\boldsymbol{\mu}}^{N}) \\ \\ \left( \operatorname{grille} \right) & \hat{\boldsymbol{\mu}}^{L}(\boldsymbol{\mu}, \hat{\boldsymbol{\mu}}^{N}) \\ \\ \left( \operatorname{grille} \right$$

40 appels de l'estimateurs v.s. 225 sur une grille

Réglage des hyperparamètres Conclusion

## Bilan de la présentation

• Régularité et variance locale [ICIP, 2018]

- Régularité et variance locale [ICIP, 2018]
  - > aptes à caractériser des textures réelles

- Régularité et variance locale [ICIP, 2018]
  - aptes à caractériser des textures réelles
  - attributs complémentaires  $\rightarrow$  capacité à discriminer finement

- Régularité et variance locale [ICIP, 2018]
  - > aptes à caractériser des textures réelles
  - $\blacktriangleright\,$  attributs complémentaires  $\rightarrow\,$  capacité à discriminer finement
- Estimation et régularisation simultanées [ACHA, 2019]

 Réglage des hyperparamètres
 Conclusion

 000000000000
 000

- Régularité et variance locale [ICIP, 2018]
  - > aptes à caractériser des textures réelles
  - $\blacktriangleright$  attributs complémentaires  $\rightarrow$  capacité à discriminer finement
- Estimation et régularisation simultanées [ACHA, 2019]
  - forte diminution de l'erreur d'estimation

- Régularité et variance locale [ICIP, 2018]
  - aptes à caractériser des textures réelles
  - attributs complémentaires  $\rightarrow$  capacité à discriminer finement
- Estimation et régularisation simultanées [ACHA, 2019]
  - forte diminution de l'erreur d'estimation
  - contours précis et réguliers grâce à la pénalisation co-localisée

- Régularité et variance locale [ICIP, 2018]
  - > aptes à caractériser des textures réelles
  - $\blacktriangleright\,$  attributs complémentaires  $\rightarrow\,$  capacité à discriminer finement
- Estimation et régularisation simultanées [ACHA, 2019]
  - forte diminution de l'erreur d'estimation
  - contours précis et réguliers grâce à la pénalisation co-localisée
- Algorithmes rapides et réglage automatique des paramètres [JMIV, 2020]

- Régularité et variance locale [ICIP, 2018]
  - > aptes à caractériser des textures réelles
  - $\blacktriangleright\,$  attributs complémentaires  $\rightarrow\,$  capacité à discriminer finement
- Estimation et régularisation simultanées [ACHA, 2019]
  - forte diminution de l'erreur d'estimation
  - contours précis et réguliers grâce à la pénalisation co-localisée
- Algorithmes rapides et réglage automatique des paramètres [JMIV, 2020]
  - possibilité de traiter de gros volumes de données

- Régularité et variance locale [ICIP, 2018]
  - aptes à caractériser des textures réelles
  - attributs complémentaires  $\rightarrow$  capacité à discriminer finement
- Estimation et régularisation simultanées [ACHA, 2019]
  - forte diminution de l'erreur d'estimation
  - contours précis et réguliers grâce à la pénalisation co-localisée
- Algorithmes rapides et réglage automatique des paramètres [JMIV, 2020]
  - possibilité de traiter de gros volumes de données
  - objectivité et reproductibilité

----> En cours : traitement automatisé de séries temporelles issues de l'étude des écoulements multiphasiques [Ann. Telecom, 2020]







• Synthèse de textures monofractales par morceaux [ACHA, 2019]

OO CONSTRUCTION DE

Algorithme de minimisation accéléré Régla

églage des hyperparamètres Conclusion

#### Autres contributions

• Synthèse de textures monofractales par morceaux [ACHA, 2019]

 $\blacktriangleright$  segmentation et attributs prescrits  $\rightarrow$  performances

• Synthèse de textures monofractales par morceaux [ACHA, 2019]

- $\blacktriangleright$  segmentation et attributs prescrits  $\rightarrow$  performances
- possibilité de générer de grosses bases de données

- Synthèse de textures monofractales par morceaux [ACHA, 2019]
  - $\blacktriangleright$  segmentation et attributs prescrits  $\rightarrow$  performances
  - possibilité de générer de grosses bases de données
- Comparaison d'algorithmes proximaux [ACHA, 2019]

- Synthèse de textures monofractales par morceaux [ACHA, 2019]
  - $\blacktriangleright$  segmentation et attributs prescrits  $\rightarrow$  performances
  - possibilité de générer de grosses bases de données
- Comparaison d'algorithmes proximaux [ACHA, 2019]
  - stratégie FISTA pour accélérer l'algorithme forward-backward

- Synthèse de textures monofractales par morceaux [ACHA, 2019]
  - $\blacktriangleright$  segmentation et attributs prescrits  $\rightarrow$  performances
  - possibilité de générer de grosses bases de données
- Comparaison d'algorithmes proximaux [ACHA, 2019]
  - > stratégie FISTA pour accélérer l'algorithme forward-backward
  - calcul du gap de dualité et choix d'un critère d'arrêt

- Synthèse de textures monofractales par morceaux [ACHA, 2019]
  - $\blacktriangleright$  segmentation et attributs prescrits  $\rightarrow$  performances
  - possibilité de générer de grosses bases de données
- Comparaison d'algorithmes proximaux [ACHA, 2019]
  - > stratégie FISTA pour accélérer l'algorithme forward-backward
  - calcul du gap de dualité et choix d'un critère d'arrêt
- Réseaux convolutionnels pour la segmentation de textures [EUSIPCO, 2020]

- Synthèse de textures monofractales par morceaux [ACHA, 2019]
  - $\blacktriangleright$  segmentation et attributs prescrits  $\rightarrow$  performances
  - possibilité de générer de grosses bases de données
- Comparaison d'algorithmes proximaux [ACHA, 2019]
  - > stratégie FISTA pour accélérer l'algorithme forward-backward
  - calcul du gap de dualité et choix d'un critère d'arrêt
- Réseaux convolutionnels pour la segmentation de textures [EUSIPCO, 2020]
  - performance et robustesse

- Synthèse de textures monofractales par morceaux [ACHA, 2019]
  - $\blacktriangleright$  segmentation et attributs prescrits  $\rightarrow$  performances
  - possibilité de générer de grosses bases de données
- Comparaison d'algorithmes proximaux [ACHA, 2019]
  - > stratégie FISTA pour accélérer l'algorithme forward-backward
  - calcul du gap de dualité et choix d'un critère d'arrêt
- Réseaux convolutionnels pour la segmentation de textures [EUSIPCO, 2020]
  - performance et robustesse
  - comparaison coûts de calcul et mémoire

- Synthèse de textures monofractales par morceaux [ACHA, 2019]
  - segmentation et attributs prescrits  $\rightarrow$  performances
  - possibilité de générer de grosses bases de données
- Comparaison d'algorithmes proximaux [ACHA, 2019]
  - stratégie FISTA pour accélérer l'algorithme forward-backward
  - calcul du gap de dualité et choix d'un critère d'arrêt
- Réseaux convolutionnels pour la segmentation de textures [EUSIPCO, 2020]
  - performance et robustesse
  - comparaison coûts de calcul et mémoire
- Application à la physique du formalisme de Stein généralisé [Ann. Telecom, 2020]
  - $\blacktriangleright$  segmentation de texture  $\rightarrow$  écoulements multiphasiques

- Synthèse de textures monofractales par morceaux [ACHA, 2019]
  - $\blacktriangleright$  segmentation et attributs prescrits  $\rightarrow$  performances
  - possibilité de générer de grosses bases de données
- Comparaison d'algorithmes proximaux [ACHA, 2019]
  - stratégie FISTA pour accélérer l'algorithme forward-backward
  - calcul du gap de dualité et choix d'un critère d'arrêt
- Réseaux convolutionnels pour la segmentation de textures [EUSIPCO, 2020]
  - performance et robustesse
  - comparaison coûts de calcul et mémoire
- Application à la physique du formalisme de Stein généralisé [Ann. Telecom, 2020]
  - $\blacktriangleright$  segmentation de texture  $\rightarrow$  écoulements multiphasiques
  - ▶ débruitage linéaire par morceaux → frottement solide



IntroductionCaractérisation de textureConstruction de fonction0000000000

églage des hyperparamètres C 000000000000000 C

#### Conclusion

# Merci

# Thank you



Grazie

# Gracias

## Définition du gap de dualité

$$\begin{array}{l} \underset{h,v}{\operatorname{minimiser}} \sum_{a} \frac{\|\log \mathcal{L}_{a,.} - \log(a)h - v\|^2}{\operatorname{Moindres Carrés}} + \lambda \frac{\mathcal{Q}(\mathsf{D}h, \mathsf{D}v; \alpha)}{\operatorname{Variation Totale}} \\ \\ \operatorname{non \ lisse} \\ \end{array}$$
# Définition du gap de dualité

$$\begin{array}{ll} \underset{h,v}{\operatorname{minimiser}} & \sum_{a} \frac{\|\log \mathcal{L}_{a,.} - \log(a)h - v\|^{2}}{\operatorname{Moindres \ Carrés}} + & \lambda \frac{\mathcal{Q}(\mathsf{D}h,\mathsf{D}v;\alpha)}{\operatorname{Variation \ Totale}} \\ & \text{non lisse} \end{array}$$

# Définition du gap de dualité

$$\begin{array}{l} \underset{h,v}{\operatorname{minimiser}} \sum_{a} \frac{\|\log \mathcal{L}_{a,.} - \log(a)h - v\|^{2}}{\operatorname{Moindres Carrés}} + \lambda \frac{\mathcal{Q}(\mathsf{D}h,\mathsf{D}v;\alpha)}{\operatorname{Variation Totale}} \\ & \text{non lisse} \end{array}$$

$$\begin{array}{l} \underset{x}{\operatorname{Primal}} & \underset{x}{\operatorname{min}} \operatorname{MC}(x) + \lambda \mathcal{Q}(\mathsf{D}x) \\ \underset{y}{\operatorname{Dual}} & \underset{y}{\operatorname{max}} - \operatorname{MC}^{*}(-\mathsf{D}^{\top}y) - (\lambda \mathcal{Q})^{*}(y) \end{array}$$

$$\begin{array}{l} \underset{y}{\operatorname{Proposition}} (Bauschke, 2011) \\ \text{Soit } \delta(x;y) \triangleq \mathcal{P}(x) - \mathcal{D}(y) \text{ le gap de dualité,} \end{array}$$

# Définition du gap de dualité

$$\begin{array}{l} \underset{h,v}{\operatorname{minimiser}} & \sum_{a} \frac{\|\log \mathcal{L}_{a,.} - \log(a)h - v\|^{2}}{\operatorname{Moindres Carrés}} + & \lambda \frac{\mathcal{Q}(\mathsf{D}h,\mathsf{D}v;\alpha)}{\operatorname{Variation Totale}} \\ & \text{non lisse} \\ \end{array}$$

$$\begin{array}{l} \begin{array}{l} \underset{x}{\operatorname{primal}} & \underset{x}{\operatorname{min}} & \operatorname{MC}(x) + \lambda \mathcal{Q}(\mathsf{D}x) \\ \\ \end{array} \\ \begin{array}{l} \underset{y}{\operatorname{Dual}} & \underset{y}{\operatorname{max}} - \operatorname{MC}^{*}(-\mathsf{D}^{\top}y) - (\lambda \mathcal{Q})^{*}(y) \\ \end{array} \end{array}$$

$$\begin{array}{l} \begin{array}{l} \begin{array}{l} \underset{y}{\operatorname{proposition}} & (Bauschke, \ 2011) \\ \end{array} \\ \begin{array}{l} \underset{\delta(\widehat{x}; \ \widehat{y})}{\operatorname{sign}} = \mathcal{P}(\widehat{x}) - \mathcal{D}(\widehat{y}) = 0 \end{array}$$

$$\mathrm{MC}^*(\boldsymbol{h}, \boldsymbol{v}) = \sup_{\widetilde{\boldsymbol{h}}, \widetilde{\boldsymbol{v}}} \langle \widetilde{\boldsymbol{h}}, \boldsymbol{h} \rangle + \langle \widetilde{\boldsymbol{v}}, \boldsymbol{v} \rangle - \mathrm{MC}(\widetilde{\boldsymbol{h}}, \widetilde{\boldsymbol{v}}) = \langle \overline{\boldsymbol{h}}, \boldsymbol{h} \rangle + \langle \overline{\boldsymbol{v}}, \boldsymbol{v} \rangle - \mathrm{MC}(\overline{\boldsymbol{h}}, \overline{\boldsymbol{v}}).$$
(si le sup est atteint)

$$\mathrm{MC}^*(\boldsymbol{h},\boldsymbol{v}) = \sup_{\widetilde{\boldsymbol{h}},\widetilde{\boldsymbol{v}}} \langle \widetilde{\boldsymbol{h}},\boldsymbol{h} \rangle + \langle \widetilde{\boldsymbol{v}},\boldsymbol{v} \rangle - \mathrm{MC}(\widetilde{\boldsymbol{h}},\widetilde{\boldsymbol{v}}) = \langle \overline{\boldsymbol{h}},\boldsymbol{h} \rangle + \langle \overline{\boldsymbol{v}},\boldsymbol{v} \rangle - \mathrm{MC}(\overline{\boldsymbol{h}},\overline{\boldsymbol{v}}).$$
(si le sup est atteint)

#### Condition d'optimalité

$$\begin{cases} \mathbf{h} - 2\sum_{a} \log(a) \left( \bar{\mathbf{v}} + \log(a) \bar{\mathbf{h}} - \log \mathcal{L}_{a,.} \right) = 0 \\ \mathbf{v} - 2\sum_{a} \left( \bar{\mathbf{v}} + \log(a) \bar{\mathbf{h}} - \log \mathcal{L}_{a,.} \right) = 0 \end{cases}$$

$$MC^*(\boldsymbol{h}, \boldsymbol{v}) = \sup_{\boldsymbol{\widetilde{h}}, \boldsymbol{\widetilde{v}}} \langle \boldsymbol{\widetilde{h}}, \boldsymbol{h} \rangle + \langle \boldsymbol{\widetilde{v}}, \boldsymbol{v} \rangle - MC(\boldsymbol{\widetilde{h}}, \boldsymbol{\widetilde{v}}) = \langle \boldsymbol{\overline{h}}, \boldsymbol{h} \rangle + \langle \boldsymbol{\overline{v}}, \boldsymbol{v} \rangle - MC(\boldsymbol{\overline{h}}, \boldsymbol{\overline{v}}).$$
(si le sup est atteint)

#### Condition d'optimalité

$$\begin{cases} \mathbf{h} - 2\sum_{a} \log(a) \left( \bar{\mathbf{v}} + \log(a) \bar{\mathbf{h}} - \log \mathcal{L}_{a,.} \right) = 0 \iff \Phi^* \Phi \begin{pmatrix} \bar{\mathbf{h}} \\ \bar{\mathbf{v}} \end{pmatrix} = \begin{pmatrix} \mathbf{h}/2 + \mathcal{G} \\ \mathbf{v}/2 + \mathcal{T} \end{pmatrix} \\ \mathcal{T} = \sum_{a} \log \mathcal{L}_{a,.} \quad \text{and} \quad \mathcal{G} = \sum_{a} \log(a) \log \mathcal{L}_{a,.}, \end{cases}$$

$$\mathrm{MC}^*(\boldsymbol{h}, \boldsymbol{v}) = \sup_{\widetilde{\boldsymbol{h}}, \widetilde{\boldsymbol{v}}} \langle \widetilde{\boldsymbol{h}}, \boldsymbol{h} \rangle + \langle \widetilde{\boldsymbol{v}}, \boldsymbol{v} \rangle - \mathrm{MC}(\widetilde{\boldsymbol{h}}, \widetilde{\boldsymbol{v}}) = \langle \overline{\boldsymbol{h}}, \boldsymbol{h} \rangle + \langle \overline{\boldsymbol{v}}, \boldsymbol{v} \rangle - \mathrm{MC}(\overline{\boldsymbol{h}}, \overline{\boldsymbol{v}}).$$
(si le sup est atteint)

#### Condition d'optimalité

$$\begin{cases} \mathbf{h} - 2\sum_{a} \log(a) \left( \bar{\mathbf{v}} + \log(a) \bar{\mathbf{h}} - \log \mathcal{L}_{a,.} \right) = 0 \iff \Phi^* \Phi \begin{pmatrix} \bar{\mathbf{h}} \\ \bar{\mathbf{v}} \end{pmatrix} = \begin{pmatrix} \mathbf{h}/2 + \mathcal{G} \\ \mathbf{v}/2 + \mathcal{T} \end{pmatrix} \\ \mathcal{T} = \sum_{a} \log \mathcal{L}_{a,.} \quad \text{and} \quad \mathcal{G} = \sum_{a} \log(a) \log \mathcal{L}_{a,.} \\ \forall m = \{0,1,2\}, S_m = \sum_{a} (\log a)^m, \quad \Phi^* \Phi = \begin{pmatrix} S_2 \mathbf{I} & S_1 \mathbf{I} \\ S_1 \mathbf{I} & S_0 \mathbf{I} \end{pmatrix} \end{cases}$$

$$\mathrm{MC}^*(\boldsymbol{h}, \boldsymbol{v}) = \sup_{\widetilde{\boldsymbol{h}}, \widetilde{\boldsymbol{v}}} \langle \widetilde{\boldsymbol{h}}, \boldsymbol{h} \rangle + \langle \widetilde{\boldsymbol{v}}, \boldsymbol{v} \rangle - \mathrm{MC}(\widetilde{\boldsymbol{h}}, \widetilde{\boldsymbol{v}}) = \langle \overline{\boldsymbol{h}}, \boldsymbol{h} \rangle + \langle \overline{\boldsymbol{v}}, \boldsymbol{v} \rangle - \mathrm{MC}(\overline{\boldsymbol{h}}, \overline{\boldsymbol{v}}).$$
(si le sup est atteint)

#### Condition d'optimalité

 $\mathrm{MC}^*(\boldsymbol{h},\boldsymbol{v}) = \frac{1}{4} \langle (\boldsymbol{h},\boldsymbol{v}), (\Phi^*\Phi)^{-1}(\boldsymbol{h},\boldsymbol{v}) \rangle + \langle (\mathcal{G},\mathcal{T}), (\Phi^*\Phi)^{-1}(\boldsymbol{h},\boldsymbol{v}) \rangle + \mathcal{C}$ 

où  $\mathcal{C}$  est une constante dépendant uniquement de  $\mathcal{L}$ .

#### Architecture pour la segmentation de texture Avec connexions résiduelles



#### Critère d'arrêt



#### Performances de segmentation Configuration I

	2 classes	3 classes	4 classes	
Entraîné sur la Config. I, testé sur la Config. I				
Segmentation à contours $\ll$ libres $\gg$	$93{,}2\pm0{,}8\%$	$69{,}3\pm2{,}8\%$	$58{,}6\pm1{,}5\%$	
Entraîné sur 2000 images Réseau à $8 \cdot 10^7$ poids / $P = 2000$ Réseau à $2 \cdot 10^6$ poids / $P = 2000$ Réseau à $4 \cdot 10^5$ poids / $P = 2000$	$\begin{array}{c} 97.3 \pm 0.6\% \\ 97.4 \pm 0.6\% \\ 96.9 \pm 0.7\% \end{array}$	$\begin{array}{c} 97,8\pm0,3\%\\ 98.1\pm0,3\%\\ 98,0\pm0,3\%\end{array}$	$\begin{array}{c} 97,1\pm 0,4\%\\ 96,8\pm 0,5\%\\ 96.5\pm 0,5\%\end{array}$	
Entraîné sur 20 images Réseau à $8 \cdot 10^7$ poids / $P = 20$ Réseau à $2 \cdot 10^6$ poids / $P = 20$ Réseau à $4 \cdot 10^5$ poids / $P = 20$	$\begin{array}{c} 95,5\pm0,9\%\\ 95,4\pm1,1\%\\ 96,6\pm0,7\%\end{array}$	$\begin{array}{c} 97,5\pm0,4\%\\ 97,4\pm0,5\%\\ 98,0\pm0,4\%\end{array}$	$\begin{array}{c} 95,4\pm0,8\%\\ 95,9\pm0,7\%\\ 96,5\pm0,5\%\end{array}$	

#### Performances de segmentation Configuration II

	2 classes	3 classes	4 classes	
Entraîné sur la Config. II, testé sur la Config. II				
Segmentation à contours $\ll$ libres $\gg$	$97,8\pm0,2\%$	$95{,}2\pm3{,}1\%$	$64{,}9\pm1{,}4\%$	
Entraîné sur 2000 images Réseau à $8 \cdot 10^7$ poids / $P = 2000$ Réseau à $2 \cdot 10^6$ poids / $P = 2000$ Réseau à $4 \cdot 10^5$ poids / $P = 2000$	$\begin{array}{c} 99,1\pm0,2\%\\ 99,0\pm0,2\%\\ 99,1\pm0,2\%\end{array}$	$\begin{array}{c} 98,3\pm0,3\%\\ 98,5\pm0,3\%\\ 98,4\pm0,3\%\end{array}$	$\begin{array}{c} 95,7\pm0,5\%\\ 95,6\pm0,5\%\\ 95,2\pm0,6\%\end{array}$	
Entraîné sur 20 images Réseau à $8 \cdot 10^7$ poids / $P = 20$ Réseau à $2 \cdot 10^6$ poids / $P = 20$ Réseau à $4 \cdot 10^5$ poids / $P = 20$	$\begin{array}{c} 98,8\pm0,2\%\\ 98,6\pm0,3\%\\ 98,8\pm0,3\%\end{array}$	$\begin{array}{c} 97,9\pm0,3\%\\ 97,4\pm0,4\%\\ 98,3\pm0,3\%\end{array}$	$\begin{array}{c} 94,5\pm 0,7\%\\ 93,0\pm 0,9\%\\ 94,8\pm 0,6\%\end{array}$	

#### Robustesse Entraîné sur la Config. I, testé sur la Config. II

	2 classes	3 classes	4 classes
Entraîné sur la Config. I, testé sur la Config. II			
Segmentation à contours $\ll$ libres $\gg$	$79,2\pm2,9\%$	$95{,}2\pm1{,}2\%$	$66{,}3\pm1{,}1\%$
Entraîné sur 2000 images Réseau à $8 \cdot 10^7$ poids / $P = 2000$ Réseau à $2 \cdot 10^6$ poids / $P = 2000$ Réseau à $4 \cdot 10^5$ poids / $P = 2000$	$\begin{array}{c} 91,2\pm2,1\%\\ 87,9\pm2,5\%\\ 81,8\pm3,8\%\end{array}$	$\begin{array}{c} 65,7\pm7,2\%\\ 69,0\pm7,6\%\\ 65,2\pm7,2\%\end{array}$	$\begin{array}{c} 55.6\pm3.4\%\\ 50.8\pm4.0\%\\ 46.4\pm3.7\%\end{array}$
Entraîné sur 20 images Réseau à $8 \cdot 10^7$ poids / $P = 20$ Réseau à $2 \cdot 10^6$ poids / $P = 20$ Réseau à $4 \cdot 10^5$ poids / $P = 20$	$\begin{array}{c} 91,\!4\pm1,\!6\%\\ 92,\!4\pm1,\!6\%\\ 86,\!3\pm2,\!6\%\end{array}$	$\begin{array}{c} 63,3\pm7,1\%\\ 65,6\pm7,4\%\\ 64,9\pm7,2\%\end{array}$	$54,7\pm 3,3\%\\44,4\pm 3,4\%\\48,4\pm 3,8\%$

#### Robustesse Entraîné sur la Config. II, testé sur la Config. I

	2 classes	3 classes	4 classes	
Entraîné sur la Config. II, testé sur la Config. I				
Segmentation à contours $\ll$ libres $\gg$	$90{,}9\pm2{,}8\%$	$66,7\pm2,5\%$	$52,0\pm1,5\%$	
Entraîné sur 2000 images Réseau à $8 \cdot 10^7$ poids / $P = 2000$ Réseau à $2 \cdot 10^6$ poids / $P = 2000$ Réseau à $5 \cdot 10^5$ poids / $P = 2000$	$56,2\pm 13,5\%\ 55,1\pm 14.0\%\ 55,5\pm 13,8\%$	$73,5 \pm 8,2\% \\74,9 \pm 8,2\% \\72,6 \pm 8,1\%$	$50,9 \pm 3,9\% \\ 51,3 \pm 4,3\% \\ 50,2 \pm 3.8\%$	
Entraîné sur 20 images Réseau à $8 \cdot 10^7$ poids / $P = 20$ Réseau à $2 \cdot 10^6$ poids / $P = 20$ Réseau à $5 \cdot 10^5$ poids / $P = 20$	$57,1 \pm 13,3\% \\ 55,3 \pm 14,0\% \\ 62,3 \pm 11,5\%$	$71,1\pm 8,2\% \\71,7\pm 8,4\% \\71,0\pm 8,2\%$	$52,6 \pm 3,8\% \\ 49,6 \pm 4,2\% \\ 54,1 \pm 3,7\%$	

#### Convergence de la phase d'entraînement

Évolution du score de segmentation des trois réseaux au cours de l'entraînement sur la Config. I, avec deux classes k = 2



# Comparaison effort de calcul $\mathcal{C}$

	$\mathcal{W}$	Р	$\mathcal{I}$	$\mathcal{C}$
Segmentation à contours $\ll$ libres $\gg$	2	1	10 <sup>7</sup>	2 10 <sup>7</sup>
$\begin{array}{l} \mbox{Réseau à } 8 \cdot 10^7 \mbox{ poids } / \ P = \{20,2000\} \\ \mbox{Réseau à } 2 \cdot 10^6 \mbox{ poids } / \ P = \{20,2000\} \\ \mbox{Réseau à } 4 \cdot 10^5 \mbox{ poids } / \ P = \{20,2000\} \end{array}$	$\begin{array}{c} 8 \cdot 10^{7} \\ 2 \cdot 10^{6} \\ 4 \cdot 10^{5} \end{array}$	{20,2000} {20,2000} {20,2000}	{3000,30} {3000,30} {3000,30}	$\begin{array}{c} 4,8\cdot 10^{12} \\ 1,2\cdot 10^{11} \\ 2,4\cdot 10^{10} \end{array}$

- $\mathcal{W}$  : nombre de poids
- P : taille base d'entraînement
- *I* : nombre d'*epochs*

#### Réseaux de neurones convolutionnels<sup>†</sup>



<sup>†</sup> V. Andrearczyk, https://arxiv.org/abs/1703.05230

#### Réseaux de neurones convolutionnels<sup>†</sup>



<sup>†</sup> V. Andrearczyk, https://arxiv.org/abs/1703.05230

Estimateur paramétrique  $(\mathbf{y}; \lambda) \mapsto \widehat{\mathbf{x}}(\mathbf{y}; \lambda)$ 

Estimateur paramétrique  $(\mathbf{y}; \lambda) \mapsto \widehat{\mathbf{x}}(\mathbf{y}; \lambda)$ 

Ex. 
$$\widehat{\mathbf{x}}(\mathbf{y}; \lambda) = \begin{cases} \left(\mathbf{I} + \lambda \mathbf{D}^{\top} \mathbf{D}\right)^{-1} \mathbf{y} & (\text{linéaire}) \\ \operatorname*{argmin}_{\mathbf{x}} \|\mathbf{y} - \mathbf{x}\|^2 + \lambda \mathcal{Q}(\mathbf{D}\mathbf{x}) & (\text{non linéaire}) \end{cases}$$

Estimateur paramétrique  $(\mathbf{y}; \lambda) \mapsto \widehat{\mathbf{x}}(\mathbf{y}; \lambda)$ 

Ex. 
$$\widehat{\mathbf{x}}(\mathbf{y}; \lambda) = \begin{cases} \left(\mathbf{I} + \lambda \mathbf{D}^{\top} \mathbf{D}\right)^{-1} \mathbf{y} & (\text{linéaire}) \\ \operatorname*{argmin}_{\mathbf{x}} \|\mathbf{y} - \mathbf{x}\|^2 + \lambda \mathcal{Q}(\mathbf{D}\mathbf{x}) & (\text{non linéaire}) \end{cases}$$

Erreur quadratique  $R(\lambda) \triangleq \mathbb{E}_{\zeta} \| \widehat{x}(\mathbf{y}; \lambda) - \overline{\mathbf{x}} \|^2 = \mathbb{E}_{\zeta} \widehat{R}(\mathbf{y}; \lambda) \quad \overline{\mathbf{x}} \text{ inconnue}$ 

Estimateur paramétrique  $(\mathbf{y}; \lambda) \mapsto \widehat{\mathbf{x}}(\mathbf{y}; \lambda)$ 

Ex. 
$$\widehat{\mathbf{x}}(\mathbf{y}; \lambda) = \begin{cases} \left(\mathbf{I} + \lambda \mathbf{D}^{\top} \mathbf{D}\right)^{-1} \mathbf{y} & (\text{linéaire}) \\ \operatorname*{argmin}_{\mathbf{x}} \|\mathbf{y} - \mathbf{x}\|^2 + \lambda \mathcal{Q}(\mathbf{D}\mathbf{x}) & (\text{non linéaire}) \end{cases}$$

Erreur quadratique  $R(\lambda) \triangleq \mathbb{E}_{\zeta} \| \widehat{x}(\mathbf{y}; \lambda) - \overline{x} \|^2 = \mathbb{E}_{\zeta} \widehat{R}(\mathbf{y}; \lambda)$   $\overline{x}$  inconnue  $R(\lambda) = \mathbb{E}_{\zeta} \| \widehat{x}(\mathbf{y}; \lambda) - \mathbf{y} + \mathbf{y} - \overline{x} \|^2$ 

Estimateur paramétrique  $(\mathbf{y}; \lambda) \mapsto \widehat{\mathbf{x}}(\mathbf{y}; \lambda)$ 

Ex. 
$$\widehat{\mathbf{x}}(\mathbf{y}; \lambda) = \begin{cases} \left(\mathbf{I} + \lambda \mathbf{D}^{\top} \mathbf{D}\right)^{-1} \mathbf{y} & (\text{linéaire}) \\ \operatorname*{argmin}_{\mathbf{x}} \|\mathbf{y} - \mathbf{x}\|^2 + \lambda \mathcal{Q}(\mathbf{D}\mathbf{x}) & (\text{non linéaire}) \end{cases}$$

Erreur quadratique  $R(\lambda) \triangleq \mathbb{E}_{\zeta} \| \widehat{x}(\mathbf{y}; \lambda) - \overline{\mathbf{x}} \|^2 = \mathbb{E}_{\zeta} \widehat{R}(\mathbf{y}; \lambda) \quad \overline{\mathbf{x}} \text{ inconnue}$ 

$$R(\lambda) = \mathbb{E}_{\boldsymbol{\zeta}} \| \widehat{\boldsymbol{x}}(\boldsymbol{y}; \lambda) - \boldsymbol{y} + \boldsymbol{y} - \bar{\boldsymbol{x}} \|^{2}$$
  
=  $\mathbb{E}_{\boldsymbol{\zeta}} \| \widehat{\boldsymbol{x}}(\boldsymbol{y}; \lambda) - \boldsymbol{y} \|^{2} + 2\mathbb{E}_{\boldsymbol{\zeta}} \langle \widehat{\boldsymbol{x}}(\boldsymbol{y}; \lambda) - \boldsymbol{y}, \boldsymbol{y} - \bar{\boldsymbol{x}} \rangle + \mathbb{E}_{\boldsymbol{\zeta}} \| \boldsymbol{y} - \bar{\boldsymbol{x}} \|^{2}$ 

Estimateur paramétrique  $(\mathbf{y}; \lambda) \mapsto \widehat{\mathbf{x}}(\mathbf{y}; \lambda)$ 

Ex. 
$$\widehat{\mathbf{x}}(\mathbf{y}; \lambda) = \begin{cases} \left(\mathbf{I} + \lambda \mathbf{D}^{\top} \mathbf{D}\right)^{-1} \mathbf{y} & (\text{linéaire}) \\ \operatorname*{argmin}_{\mathbf{x}} \|\mathbf{y} - \mathbf{x}\|^2 + \lambda \mathcal{Q}(\mathbf{D}\mathbf{x}) & (\text{non linéaire}) \end{cases}$$

Erreur quadratique  $R(\lambda) \triangleq \mathbb{E}_{\zeta} \| \widehat{x}(\mathbf{y}; \lambda) - \overline{\mathbf{x}} \|^2 = \mathbb{E}_{\zeta} \widehat{R}(\mathbf{y}; \lambda) \quad \overline{\mathbf{x}} \text{ inconnue}$ 

$$R(\lambda) = \mathbb{E}_{\boldsymbol{\zeta}} \| \widehat{\boldsymbol{x}}(\boldsymbol{y}; \lambda) - \boldsymbol{y} + \boldsymbol{y} - \bar{\boldsymbol{x}} \|^{2}$$
  
=  $\mathbb{E}_{\boldsymbol{\zeta}} \| \widehat{\boldsymbol{x}}(\boldsymbol{y}; \lambda) - \boldsymbol{y} \|^{2} + 2\mathbb{E}_{\boldsymbol{\zeta}} \langle \widehat{\boldsymbol{x}}(\boldsymbol{y}; \lambda) - \boldsymbol{y}, \boldsymbol{y} - \bar{\boldsymbol{x}} \rangle + \mathbb{E}_{\boldsymbol{\zeta}} \| \boldsymbol{y} - \bar{\boldsymbol{x}} \|^{2}$   
=  $\mathbb{E}_{\boldsymbol{\zeta}} \| \widehat{\boldsymbol{x}}(\boldsymbol{y}; \lambda) - \boldsymbol{y} \|^{2} + 2\mathbb{E}_{\boldsymbol{\zeta}} \langle \widehat{\boldsymbol{x}}(\boldsymbol{y}; \lambda), \boldsymbol{\zeta} \rangle - 2\mathbb{E}_{\boldsymbol{\zeta}} \langle \bar{\boldsymbol{x}} + \boldsymbol{\zeta}, \boldsymbol{\zeta} \rangle + \mathbb{E}_{\boldsymbol{\zeta}} \| \boldsymbol{\zeta} \|^{2}$ 

Estimateur paramétrique  $(\mathbf{y}; \lambda) \mapsto \widehat{\mathbf{x}}(\mathbf{y}; \lambda)$ 

Ex. 
$$\widehat{\mathbf{x}}(\mathbf{y}; \lambda) = \begin{cases} \left(\mathbf{I} + \lambda \mathbf{D}^{\top} \mathbf{D}\right)^{-1} \mathbf{y} & (\text{linéaire}) \\ \operatorname*{argmin}_{\mathbf{x}} \|\mathbf{y} - \mathbf{x}\|^2 + \lambda \mathcal{Q}(\mathbf{D}\mathbf{x}) & (\text{non linéaire}) \end{cases}$$

$$\begin{aligned} R(\lambda) &= \mathbb{E}_{\boldsymbol{\zeta}} \left\| \widehat{\boldsymbol{x}}(\boldsymbol{y}; \lambda) - \boldsymbol{y} + \boldsymbol{y} - \overline{\boldsymbol{x}} \right\|^2 \\ &= \mathbb{E}_{\boldsymbol{\zeta}} \left\| \widehat{\boldsymbol{x}}(\boldsymbol{y}; \lambda) - \boldsymbol{y} \right\|^2 + 2\mathbb{E}_{\boldsymbol{\zeta}} \left\langle \widehat{\boldsymbol{x}}(\boldsymbol{y}; \lambda) - \boldsymbol{y}, \boldsymbol{y} - \overline{\boldsymbol{x}} \right\rangle + \mathbb{E}_{\boldsymbol{\zeta}} \left\| \boldsymbol{y} - \overline{\boldsymbol{x}} \right\|^2 \\ &= \mathbb{E}_{\boldsymbol{\zeta}} \left\| \widehat{\boldsymbol{x}}(\boldsymbol{y}; \lambda) - \boldsymbol{y} \right\|^2 + 2\mathbb{E}_{\boldsymbol{\zeta}} \left\langle \widehat{\boldsymbol{x}}(\boldsymbol{y}; \lambda), \boldsymbol{\zeta} \right\rangle - 2\mathbb{E}_{\boldsymbol{\zeta}} \left\langle -\boldsymbol{\zeta}, \boldsymbol{\zeta} \right\rangle + \mathbb{E}_{\boldsymbol{\zeta}} \left\| \boldsymbol{\zeta} \right\|^2 \end{aligned}$$

Estimateur paramétrique  $(\mathbf{y}; \lambda) \mapsto \widehat{\mathbf{x}}(\mathbf{y}; \lambda)$ 

Ex. 
$$\widehat{\mathbf{x}}(\mathbf{y}; \lambda) = \begin{cases} \left(\mathbf{I} + \lambda \mathbf{D}^{\top} \mathbf{D}\right)^{-1} \mathbf{y} & (\text{linéaire}) \\ \operatorname*{argmin}_{\mathbf{x}} \|\mathbf{y} - \mathbf{x}\|^2 + \lambda \mathcal{Q}(\mathbf{D}\mathbf{x}) & (\text{non linéaire}) \end{cases}$$

$$R(\lambda) = \mathbb{E}_{\boldsymbol{\zeta}} \| \widehat{\boldsymbol{x}}(\boldsymbol{y}; \lambda) - \boldsymbol{y} + \boldsymbol{y} - \overline{\boldsymbol{x}} \|^{2}$$
  
=  $\mathbb{E}_{\boldsymbol{\zeta}} \| \widehat{\boldsymbol{x}}(\boldsymbol{y}; \lambda) - \boldsymbol{y} \|^{2} + 2\mathbb{E}_{\boldsymbol{\zeta}} \langle \widehat{\boldsymbol{x}}(\boldsymbol{y}; \lambda) - \boldsymbol{y}, \boldsymbol{y} - \overline{\boldsymbol{x}} \rangle + \mathbb{E}_{\boldsymbol{\zeta}} \| \boldsymbol{y} - \overline{\boldsymbol{x}} \|^{2}$   
=  $\mathbb{E}_{\boldsymbol{\zeta}} \| \widehat{\boldsymbol{x}}(\boldsymbol{y}; \lambda) - \boldsymbol{y} \|^{2} + 2\mathbb{E}_{\boldsymbol{\zeta}} \langle \widehat{\boldsymbol{x}}(\boldsymbol{y}; \lambda), \boldsymbol{\zeta} \rangle - 2\mathbb{E}_{\boldsymbol{\zeta}} \langle \boldsymbol{\zeta}, \boldsymbol{\zeta} \rangle + \mathbb{E}_{\boldsymbol{\zeta}} \| \boldsymbol{\zeta} \|^{2}$   
=  $\mathbb{E}_{\boldsymbol{\zeta}} \| \widehat{\boldsymbol{x}}(\boldsymbol{y}; \lambda) - \boldsymbol{y} \|^{2} + 2\mathbb{E}_{\boldsymbol{\zeta}} \langle \widehat{\boldsymbol{x}}(\boldsymbol{y}; \lambda), \boldsymbol{\zeta} \rangle - 2\mathbb{E}_{\boldsymbol{\zeta}} \langle \boldsymbol{\zeta}, \boldsymbol{\zeta} \rangle + \mathbb{E}_{\boldsymbol{\zeta}} \| \boldsymbol{\zeta} \|^{2}$ 

Estimateur paramétrique  $(\mathbf{y}; \lambda) \mapsto \widehat{\mathbf{x}}(\mathbf{y}; \lambda)$ 

Ex. 
$$\widehat{\mathbf{x}}(\mathbf{y}; \lambda) = \begin{cases} \left(\mathbf{I} + \lambda \mathbf{D}^{\top} \mathbf{D}\right)^{-1} \mathbf{y} & (\text{linéaire}) \\ \operatorname*{argmin}_{\mathbf{x}} \|\mathbf{y} - \mathbf{x}\|^2 + \lambda \mathcal{Q}(\mathbf{D}\mathbf{x}) & (\text{non linéaire}) \end{cases}$$

$$R(\lambda) = \mathbb{E}_{\zeta} \|\widehat{\mathbf{x}}(\mathbf{y}; \lambda) - \mathbf{y} + \mathbf{y} - \overline{\mathbf{x}}\|^{2}$$
  
=  $\mathbb{E}_{\zeta} \|\widehat{\mathbf{x}}(\mathbf{y}; \lambda) - \mathbf{y}\|^{2} + 2\mathbb{E}_{\zeta} \langle \widehat{\mathbf{x}}(\mathbf{y}; \lambda) - \mathbf{y}, \mathbf{y} - \overline{\mathbf{x}} \rangle + \mathbb{E}_{\zeta} \|\mathbf{y} - \overline{\mathbf{x}}\|^{2}$   
=  $\mathbb{E}_{\zeta} \|\widehat{\mathbf{x}}(\mathbf{y}; \lambda) - \mathbf{y}\|^{2} + 2\mathbb{E}_{\zeta} \langle \widehat{\mathbf{x}}(\mathbf{y}; \lambda), \zeta \rangle - 2\mathbb{E}_{\zeta} \langle -\zeta, \zeta \rangle + \mathbb{E}_{\zeta} \|\zeta\|^{2}$   
=  $\mathbb{E}_{\zeta} \frac{\|\widehat{\mathbf{x}}(\mathbf{y}; \lambda) - \mathbf{y}\|^{2}}{\operatorname{accessible}} + 2\mathbb{E}_{\zeta} \langle \widehat{\mathbf{x}}(\mathbf{y}; \lambda), \zeta \rangle - \underline{\mathbb{E}_{\zeta} \|\zeta\|^{2}}$ 

Estimateur paramétrique  $(\mathbf{y}; \lambda) \mapsto \widehat{\mathbf{x}}(\mathbf{y}; \lambda)$ 

Ex. 
$$\widehat{\mathbf{x}}(\mathbf{y}; \lambda) = \begin{cases} \left(\mathbf{I} + \lambda \mathbf{D}^{\top} \mathbf{D}\right)^{-1} \mathbf{y} & (\text{linéaire}) \\ \operatorname*{argmin}_{\mathbf{x}} \|\mathbf{y} - \mathbf{x}\|^2 + \lambda \mathcal{Q}(\mathbf{D}\mathbf{x}) & (\text{non linéaire}) \end{cases}$$

$$\begin{aligned} R(\lambda) &= \mathbb{E}_{\boldsymbol{\zeta}} \left\| \hat{\boldsymbol{x}}(\boldsymbol{y};\lambda) - \boldsymbol{y} + \boldsymbol{y} - \bar{\boldsymbol{x}} \right\|^{2} \\ &= \mathbb{E}_{\boldsymbol{\zeta}} \left\| \hat{\boldsymbol{x}}(\boldsymbol{y};\lambda) - \boldsymbol{y} \right\|^{2} + 2\mathbb{E}_{\boldsymbol{\zeta}} \left\langle \hat{\boldsymbol{x}}(\boldsymbol{y};\lambda) - \boldsymbol{y}, \boldsymbol{y} - \bar{\boldsymbol{x}} \right\rangle + \mathbb{E}_{\boldsymbol{\zeta}} \left\| \boldsymbol{y} - \bar{\boldsymbol{x}} \right\|^{2} \\ &= \mathbb{E}_{\boldsymbol{\zeta}} \left\| \hat{\boldsymbol{x}}(\boldsymbol{y};\lambda) - \boldsymbol{y} \right\|^{2} + 2\mathbb{E}_{\boldsymbol{\zeta}} \left\langle \hat{\boldsymbol{x}}(\boldsymbol{y};\lambda), \boldsymbol{\zeta} \right\rangle - 2\mathbb{E}_{\boldsymbol{\zeta}} \left\langle \boldsymbol{\zeta}, \boldsymbol{\zeta} \right\rangle + \mathbb{E}_{\boldsymbol{\zeta}} \left\| \boldsymbol{\zeta} \right\|^{2} \\ &= \mathbb{E}_{\boldsymbol{\zeta}} \frac{\left\| \hat{\boldsymbol{x}}(\boldsymbol{y};\lambda) - \boldsymbol{y} \right\|^{2}}{_{\text{accessible}}} + 2\mathbb{E}_{\boldsymbol{\zeta}} \left\langle \hat{\boldsymbol{x}}(\boldsymbol{y};\lambda), \boldsymbol{\zeta} \right\rangle - \frac{\mathbb{E}_{\boldsymbol{\zeta}} \left\| \boldsymbol{\zeta} \right\|^{2}}{_{\rho^{2}P}} \end{aligned}$$

Estimateur paramétrique  $(\mathbf{y}; \lambda) \mapsto \widehat{\mathbf{x}}(\mathbf{y}; \lambda)$ 

Ex. 
$$\widehat{\mathbf{x}}(\mathbf{y}; \lambda) = \begin{cases} \left(\mathbf{I} + \lambda \mathbf{D}^{\top} \mathbf{D}\right)^{-1} \mathbf{y} & (\text{linéaire}) \\ \operatorname*{argmin}_{\mathbf{x}} \|\mathbf{y} - \mathbf{x}\|^2 + \lambda \mathcal{Q}(\mathbf{D}\mathbf{x}) & (\text{non linéaire}) \end{cases}$$

Erreur quadratique  $R(\lambda) \triangleq \mathbb{E}_{\zeta} \| \widehat{\boldsymbol{x}}(\boldsymbol{y}; \lambda) - \bar{\boldsymbol{x}} \|^2 = \mathbb{E}_{\zeta} \widehat{R}(\boldsymbol{y}; \lambda) \quad \bar{\boldsymbol{x}} \text{ inconnue}$ 

$$R(\lambda) = \mathbb{E}_{\boldsymbol{\zeta}} \| \widehat{\boldsymbol{x}}(\boldsymbol{y}; \lambda) - \boldsymbol{y} + \boldsymbol{y} - \bar{\boldsymbol{x}} \|^{2}$$

$$= \mathbb{E}_{\boldsymbol{\zeta}} \| \widehat{\boldsymbol{x}}(\boldsymbol{y}; \lambda) - \boldsymbol{y} \|^{2} + 2\mathbb{E}_{\boldsymbol{\zeta}} \langle \widehat{\boldsymbol{x}}(\boldsymbol{y}; \lambda) - \boldsymbol{y}, \boldsymbol{y} - \bar{\boldsymbol{x}} \rangle + \mathbb{E}_{\boldsymbol{\zeta}} \| \boldsymbol{y} - \bar{\boldsymbol{x}} \|^{2}$$

$$= \mathbb{E}_{\boldsymbol{\zeta}} \| \widehat{\boldsymbol{x}}(\boldsymbol{y}; \lambda) - \boldsymbol{y} \|^{2} + 2\mathbb{E}_{\boldsymbol{\zeta}} \langle \widehat{\boldsymbol{x}}(\boldsymbol{y}; \lambda), \boldsymbol{\zeta} \rangle - 2\mathbb{E}_{\boldsymbol{\zeta}} \langle \boldsymbol{\zeta}, \boldsymbol{\zeta} \rangle + \mathbb{E}_{\boldsymbol{\zeta}} \| \boldsymbol{\zeta} \|^{2}$$

$$= \mathbb{E}_{\boldsymbol{\zeta}} \frac{\| \widehat{\boldsymbol{x}}(\boldsymbol{y}; \lambda) - \boldsymbol{y} \|^{2}}{\operatorname{accessible}} + 2\mathbb{E}_{\boldsymbol{\zeta}} \langle \widehat{\boldsymbol{x}}(\boldsymbol{y}; \lambda), \boldsymbol{\zeta} \rangle - \frac{\mathbb{E}_{\boldsymbol{\zeta}} \| \boldsymbol{\zeta} \|^{2}}{\rho^{2}P}$$

 $\mathbb{E}_{\boldsymbol{\zeta}} \langle \widehat{\boldsymbol{x}}(\boldsymbol{y}; \lambda), \boldsymbol{\zeta} \rangle = \int \langle \widehat{\boldsymbol{x}}(\overline{\boldsymbol{x}} + \boldsymbol{\zeta}; \lambda), \boldsymbol{\zeta} \rangle \exp(-\frac{\|\boldsymbol{\zeta}\|^2}{2\rho^2}) \, \mathrm{d}\boldsymbol{\zeta}$ 

Estimateur paramétrique  $(\mathbf{y}; \lambda) \mapsto \widehat{\mathbf{x}}(\mathbf{y}; \lambda)$ 

Ex. 
$$\widehat{\mathbf{x}}(\mathbf{y}; \lambda) = \begin{cases} \left(\mathbf{I} + \lambda \mathbf{D}^{\top} \mathbf{D}\right)^{-1} \mathbf{y} & (\text{linéaire}) \\ \operatorname*{argmin}_{\mathbf{x}} \|\mathbf{y} - \mathbf{x}\|^2 + \lambda \mathcal{Q}(\mathbf{D}\mathbf{x}) & (\text{non linéaire}) \end{cases}$$

Erreur quadratique  $R(\lambda) \triangleq \mathbb{E}_{\zeta} \| \widehat{x}(\mathbf{y}; \lambda) - \overline{\mathbf{x}} \|^2 = \mathbb{E}_{\zeta} \widehat{R}(\mathbf{y}; \lambda) \quad \overline{\mathbf{x}} \text{ inconnue}$ 

$$\begin{aligned} R(\lambda) &= \mathbb{E}_{\boldsymbol{\zeta}} \left\| \widehat{\boldsymbol{x}}(\boldsymbol{y};\lambda) - \boldsymbol{y} + \boldsymbol{y} - \bar{\boldsymbol{x}} \right\|^{2} \\ &= \mathbb{E}_{\boldsymbol{\zeta}} \left\| \widehat{\boldsymbol{x}}(\boldsymbol{y};\lambda) - \boldsymbol{y} \right\|^{2} + 2\mathbb{E}_{\boldsymbol{\zeta}} \left\langle \widehat{\boldsymbol{x}}(\boldsymbol{y};\lambda) - \boldsymbol{y}, \boldsymbol{y} - \bar{\boldsymbol{x}} \right\rangle + \mathbb{E}_{\boldsymbol{\zeta}} \left\| \boldsymbol{y} - \bar{\boldsymbol{x}} \right\|^{2} \\ &= \mathbb{E}_{\boldsymbol{\zeta}} \left\| \widehat{\boldsymbol{x}}(\boldsymbol{y};\lambda) - \boldsymbol{y} \right\|^{2} + 2\mathbb{E}_{\boldsymbol{\zeta}} \left\langle \widehat{\boldsymbol{x}}(\boldsymbol{y};\lambda), \boldsymbol{\zeta} \right\rangle - 2\mathbb{E}_{\boldsymbol{\zeta}} \left\langle -\boldsymbol{\zeta}, \boldsymbol{\zeta} \right\rangle + \mathbb{E}_{\boldsymbol{\zeta}} \left\| \boldsymbol{\zeta} \right\|^{2} \\ &= \mathbb{E}_{\boldsymbol{\zeta}} \frac{\left\| \widehat{\boldsymbol{x}}(\boldsymbol{y};\lambda) - \boldsymbol{y} \right\|^{2}}{\text{accessible}} + 2\mathbb{E}_{\boldsymbol{\zeta}} \left\langle \widehat{\boldsymbol{x}}(\boldsymbol{y};\lambda), \boldsymbol{\zeta} \right\rangle - \frac{\mathbb{E}_{\boldsymbol{\zeta}} \left\| \boldsymbol{\zeta} \right\|^{2}}{\rho^{2}P} \\ \mathbb{E}_{\boldsymbol{\zeta}} \left\langle \widehat{\boldsymbol{x}}(\boldsymbol{y};\lambda), \boldsymbol{\zeta} \right\rangle = \int \left\langle \widehat{\boldsymbol{x}}(\bar{\boldsymbol{x}} + \boldsymbol{\zeta};\lambda), \boldsymbol{\zeta} \right\rangle \exp\left(-\frac{\|\boldsymbol{\zeta}\|^{2}}{2r^{2}}\right) \mathrm{d}\boldsymbol{\zeta} \stackrel{\mathrm{I.P.P.}}{=} \rho^{2} \mathbb{E}_{\boldsymbol{\zeta}} \mathrm{tr} \left(\partial_{\boldsymbol{y}} \widehat{\boldsymbol{x}}(\boldsymbol{y};\lambda)\right) \end{aligned}$$

# Estimateur séquentiel et différentiation récursive

$$\mathbf{\Lambda} \triangleq (\lambda, \alpha), \quad \mathbf{U}_{\mathbf{\Lambda}} : (\mathbf{h}, \mathbf{v}) \mapsto \lambda[\alpha \mathbf{D}\mathbf{h}, \mathbf{D}\mathbf{v}]$$

#### Primal-dual accéléré

$$\widetilde{\boldsymbol{z}}^{n} = \boldsymbol{z}^{n} + \tau_{n} \mathbf{U}_{\Lambda} \boldsymbol{w}^{n}$$

$$\boldsymbol{z}^{n+1} = \operatorname{prox}_{\tau_{n} (\|\cdot\|_{2,1})^{*}} (\widetilde{\boldsymbol{z}}^{n})$$

$$\widetilde{\boldsymbol{x}}^{n} = \boldsymbol{x}^{n} - \sigma_{n} \mathbf{U}_{\Lambda}^{*} \boldsymbol{z}^{n+1}$$

$$\boldsymbol{x}^{n+1} = \operatorname{prox}_{\sigma_{n} \| \mathbf{D} \mathcal{L} - \mathbf{\Phi} \cdot \|_{2}^{2}} (\widetilde{\boldsymbol{x}}^{n})$$

$$\theta_{n} = (1 + 2\mu\sigma_{n})^{-\frac{1}{2}},$$

$$\tau_{n+1} = \tau_{n}/\theta_{n}, \sigma_{n+1} = \theta_{n}\sigma_{n}$$

$$\boldsymbol{w}^{n+1} = \boldsymbol{x}^{n} + \theta^{n} (\boldsymbol{x}^{n+1} - \boldsymbol{x}^{n})$$

#### Primal-dual accéléré différentié

$$\begin{split} \partial_{\Lambda} \widetilde{\boldsymbol{z}}^{n} &= \partial_{\Lambda} \boldsymbol{z}^{n} + \tau_{n} \boldsymbol{U}_{\Lambda} \partial_{\Lambda} \boldsymbol{w}^{n} + \tau_{n} \partial_{\Lambda} \boldsymbol{U}_{\Lambda} \boldsymbol{w}^{n} \\ \partial_{\Lambda} \boldsymbol{z}^{n+1} &= \partial_{\widetilde{\boldsymbol{z}}} \mathrm{prox}_{\tau_{n} \left( \| \cdot \|_{2,1} \right)^{*}} \left( \widetilde{\boldsymbol{z}}^{n} \right) \left[ \partial_{\Lambda} \widetilde{\boldsymbol{z}}^{n} \right] \\ \partial_{\Lambda} \widetilde{\boldsymbol{x}}^{n} &= \partial_{\Lambda} \boldsymbol{x}^{n} - \sigma_{n} \boldsymbol{U}_{\Lambda}^{*} \partial_{\Lambda} \boldsymbol{z}^{n+1} - \sigma_{n} \partial_{\Lambda} \boldsymbol{U}_{\Lambda} \boldsymbol{z}^{n+1} \\ \partial_{\Lambda} \boldsymbol{x}^{n+1} &= \partial_{\widetilde{\boldsymbol{x}}} \mathrm{prox}_{\sigma_{n} \| \boldsymbol{D} \mathcal{L} - \boldsymbol{\Phi} \cdot \|_{2}^{2}} \left( \widetilde{\boldsymbol{x}}^{n} \right) \left[ \partial_{\Lambda} \widetilde{\boldsymbol{x}}^{n} \right] \end{split}$$

$$\partial_{\mathbf{\Lambda}} \mathbf{w}^{n+1} = \partial_{\mathbf{\Lambda}} \mathbf{x}^n + \theta^n \left( \partial_{\mathbf{\Lambda}} \mathbf{x}^{n+1} - \partial_{\mathbf{\Lambda}} \mathbf{x}^n \right)$$

Matrice de covariance estimée  ${\cal S}$ 



Matrice de covariance estimée  ${\cal S}$ 



Matrice de covariance estimée  $\widehat{oldsymbol{\mathcal{S}}}$ 



Matrice de covariance estimée  $\widehat{oldsymbol{\mathcal{S}}}$ 


## Initialisation quasi-Newton

• Hyperparamètres  $\mathbf{\Lambda}^{[0]} = \left(\lambda^{[0]}, lpha^{[0]}
ight)$ , avec

$$\lambda^{[0]} = \frac{\operatorname{tr}(\boldsymbol{\mathcal{S}})}{2\operatorname{TV}(\hat{\boldsymbol{\nu}}^{\operatorname{RL}}(\boldsymbol{\mathcal{L}}))}, \quad \text{et} \quad \alpha^{[0]} = \frac{\operatorname{TV}(\hat{\boldsymbol{\nu}}^{\operatorname{RL}}(\boldsymbol{\mathcal{L}}))}{\operatorname{TV}(\hat{\boldsymbol{h}}^{\operatorname{RL}}(\boldsymbol{\mathcal{L}}))}$$

Approximation de l'inverse de la hessienne

$$\boldsymbol{H}^{[0]} = \operatorname{diag}\left(\left|\frac{\kappa\lambda^{[0]}}{\partial_{\lambda}\widehat{R}_{\nu,\varepsilon}(\boldsymbol{\mathcal{L}};\boldsymbol{\Lambda}^{[0]}|\boldsymbol{\mathcal{S}})}\right|, \left|\frac{\kappa\alpha^{[0]}}{\partial_{\alpha}\widehat{R}_{\nu,\varepsilon}(\boldsymbol{\mathcal{L}};\boldsymbol{\Lambda}^{[0]}|\boldsymbol{\mathcal{S}})}\right|\right)$$