

# Estimateurs statistiques et décompositions directionnelles

Laurent Duval, IFP Energies nouvelles

avec A. Benazza-Benyahia, C. Chaux, J. Gauthier, J.-C. Pesquet

2013

# Introduction : plan

- ▶ Estimateurs statistiques standard
- ▶ Décompositions directionnelles multiéchelle
- ▶ Applications au débruitage
- ▶ Conclusions, pointeurs

## Applications : motivations initiales

- ▶ Traitement de données volumineuses
  - ▶ variété des types (image, sismique), échantillonnage hétérogènes, anisotropie
- ▶ Besoins
  - ▶ dév. de classes flexibles de transformations (1,2,3-D)
  - ▶ directionnalité, faible redondance, support spatial localisé
  - ▶ (idée de représentations complexes)
    1. bancs de filtres  $M$ -bandes complexes suréch. (OSFB)
    2. ondelettes  $M$ -bandes en arbre dual (DTT)
- ▶ Débruitage statistique
  - ▶ minimum d'hypothèses a priori (sur le bruit)
  - ▶ lemme de Stein et SURE (Stein Unbiased Risk Estimation)
    1. combinaison linéaire de seuillages (SURE-LET)
    2. estimateur paramétrique "générique"

# Applications : méthodologie

Deux approches :

- ▶ une low-cost, avec comparaison analyse/synthèse
  - ▶ trame non-ajustée (effort sur les filtres)
  - ▶ redondance très réduite ( $< 2$ )<sup>d</sup>
  - ▶ seuillage scalaire par groupes homologues
- ▶ une plus évoluée
  - ▶ trame potentiellement ajustée
  - ▶ redondance faible (2)
  - ▶ multicomposante (couleur), persistance multi-échelle, étalement du bruit

# Applications : approche 1





Figure : Banc de filtres redondant complexe (cf. STFT)


# Applications : problème de débruitage

Notation :



# Applications : problème de débruitage

Notation :



Objectifs :

- ▶ Trouver un estimateur  $\mathbf{G}(\mathbf{y})$  de  $\mathbf{x}$  minimisant l'erreur quadratique moyenne :  $E \left( \|\mathbf{G}(\mathbf{y}) - \mathbf{x}\|^2 \right)$ .
- ▶ Trouver un estimateur  $\mathbf{F}(\mathbf{Y})$  of  $\mathbf{X}$  minimisant l'erreur quadratique moyenne :  $E \left( \|\mathbf{F}(\mathbf{Y}) - \mathbf{X}\|^2 \right)$ .

## Applications : principe de Stein

### Lemme ([Stein 1981])

Soit  $\mathbf{G} : \mathbb{R}^L \rightarrow \mathbb{R}^L$  une fonction continue, différentiable presque partout, telle que :

1.  $E \left( \|\mathbf{G}(\mathbf{y})\|^2 \right) < \infty,$
2.  $E \left( \left\| \frac{\partial \mathbf{G}(\mathbf{y})}{\partial \mathbf{y}^\top} \right\|_F \right) < \infty,$
3.  $\forall \mathbf{z} \in \mathbb{R}^L, \quad \lim_{\|\mathbf{t}\| \rightarrow +\infty} \mathbf{G}(\mathbf{t}) \exp \left( -\frac{(\mathbf{t} - \mathbf{z})^\top (\boldsymbol{\Gamma}^{(b)})^{-1} (\mathbf{t} - \mathbf{z})}{2} \right) = \mathbf{0},$

alors :

$$E(\mathbf{G}(\mathbf{y}) \mathbf{x}^\top) = E(\mathbf{G}(\mathbf{y}) \mathbf{y}^\top) - E \left( \frac{\partial \mathbf{G}(\mathbf{y})}{\partial \mathbf{y}^\top} \right) \boldsymbol{\Gamma}^{(b)}.$$



# Applications : SURE-LET

Principe :

- ▶ Considérer plusieurs fonctions (de seuillage) :  $\mathbf{F}_k$  or  $\mathbf{G}_k$
- ▶ Combinaison linéaire de différentes fonctions :  $\mathbf{F} = \sum_k a_k \mathbf{F}_k$   
or  $\mathbf{G} = \sum_k a_k \mathbf{G}_k$
- ▶ Pour chaque estimateur de Stein de risque  
→ calculer les paramètres  $a_k$  (par minimisation)
- ▶ [Pesquet, Leporini 1997], [Raphan, Simoncelli 2006], [Luisier, Blu 2007]

## Applications : SURE-LET

Principe :

- ▶ Considérer plusieurs fonctions (de seuillage) :  $\mathbf{F}_k$  or  $\mathbf{G}_k$
- ▶ Combinaison linéaire de différentes fonctions :  $\mathbf{F} = \sum_k a_k \mathbf{F}_k$   
or  $\mathbf{G} = \sum_k a_k \mathbf{G}_k$
- ▶ Pour chaque estimateur de Stein de risque  
→ calculer les paramètres  $a_k$  (par minimisation)
- ▶ [Pesquet, Leporini 1997], [Raphan, Simoncelli 2006], [Luisier, Blu 2007]

Deux applications possibles du principe de Stein :

- ▶ Après reconstruction (sur les échantillons) → fb-sure-let-s.
- ▶ Après décomposition (sur les coefficients) → fb-sure-let-c.

## Applications : SURE-LET

### Principe :

- ▶ Considérer plusieurs fonctions (de seuillage) :  $\mathbf{F}_k$  or  $\mathbf{G}_k$
- ▶ Combinaison linéaire de différentes fonctions :  $\mathbf{F} = \sum_k a_k \mathbf{F}_k$   
or  $\mathbf{G} = \sum_k a_k \mathbf{G}_k$
- ▶ Pour chaque estimateur de Stein de risque  
→ calculer les paramètres  $a_k$  (par minimisation)
- ▶ [Pesquet, Leporini 1997], [Raphan, Simoncelli 2006], [Luisier, Blu 2007]

### Deux applications possibles du principe de Stein :

- ▶ Après reconstruction (sur les échantillons) → fb-sure-let-s.
- ▶ Après décomposition (sur les coefficients) → fb-sure-let-c.


**Dans le cas orthogonal → les 2 approches sont identiques.**

# Applications : SURE et échantillons




Image bruitée.

## Applications : SURE et échantillons



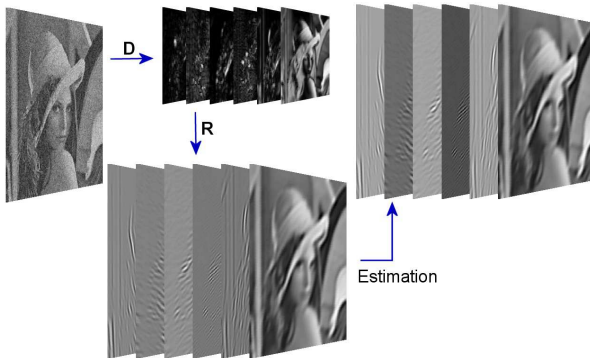
Décomposition.

## Applications : SURE et échantillons



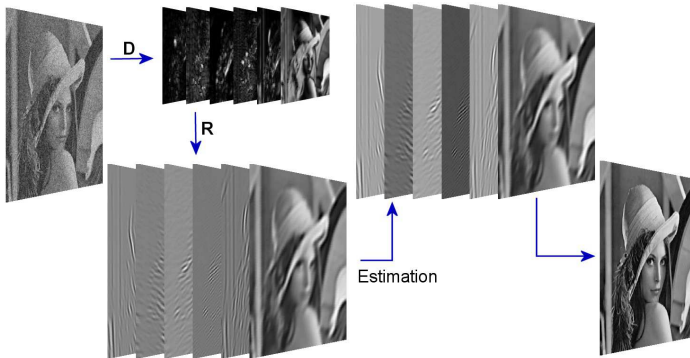
Reconstruction avec les fonctions de seuillage (fonctions  $G_k$ ).

## Applications : SURE et échantillons



Minimisation de l'estimateur de risque de Stein calculé sur les images reconstruites  $\rightarrow$  estimation des paramètres  $a_k$ .

## Applications : SURE et échantillons



Combinaison linéaire  $\rightarrow$  image débruitée.



## Applications : SURE et échantillons

Estimateur :

$$\varepsilon_S = \|\mathbf{G}(\mathbf{y}) - \mathbf{y}\|^2 + 2\sigma^2 \text{div}(\mathbf{G}(\mathbf{y})) - L\sigma^2$$

estimateur non-biaisé de  $E\left(\|\mathbf{G}(\mathbf{y}) - \mathbf{x}\|^2\right)$ .

Divergence (cas complexe) :

$$\text{div}(\mathbf{G}(\mathbf{y})) = \text{diag}(\mathbf{D}^R \mathbf{R})^\top \underline{\Theta}^{(1)}(\mathbf{Y}^R, \mathbf{Y}^I) + \text{diag}(\mathbf{D}^I \mathbf{R})^\top \underline{\Theta}^{(2)}(\mathbf{Y}^R, \mathbf{Y}^I),$$


avec  $\cdot^R$ : partie réelle et  $\cdot^I$ : partie imaginaire.

# Applications : SURE et coefficients




Image bruitée.

## Applications : SURE et coefficients




Décomposition et seuillage (fonctions  $F_k$ ).

## Applications : SURE et coefficients



Minimisation de l'estimateur de risque de Stein  $\rightarrow$  calcul des paramètres  $a_k$ .

## Applications : SURE et coefficients



Combinaison linéaire et reconstruction → image débruitée.

## Applications : SURE et coefficients

Estimateur :

$$\varepsilon_C = \sum_{j=1}^{L'} \left( \left\| \vec{\Theta}_j(\mathbf{Y}_j) - \mathbf{Y}_j \right\|^2 + 2\text{Tr} \left( \frac{\partial \vec{\Theta}_j(\mathbf{Y}_j)}{\partial \mathbf{Y}_j^\top} \mathbf{\Gamma}_j \right) - \text{Tr}(\mathbf{\Gamma}_j) \right)$$

estimateur non-biaisé  $E \left( \left\| \mathbf{F}(\mathbf{Y}) - \mathbf{X} \right\|^2 \right)$ .


# Applications : fonctions “de seuillage”

En chaque coefficient :

$$\theta_1(x, y) = x + iy, \quad \forall (x, y) \in \mathbb{R}^2$$

$$\theta_2(x, y) = (x + iy) \left( 1 - e^{-\frac{(x^2+y^2)^{\frac{m_0}{2}}}{(\beta\sigma)^{m_0}}} \right), \quad \forall (x, y) \in \mathbb{R}^2,$$

avec  $m_0 \in \mathbb{R}_+^*$  et  $\beta \in \mathbb{R}_+^*$ .




# Applications : fonctions “de seuillage”







# Applications : fonctions “de seuillage”




# Applications : fonctions “de seuillage”




# Applications : fonctions “de seuillage”



# Applications : fonctions “de seuillage”



# Applications : fonctions “de seuillage”



## Applications : FB-SURE vs oracle

	<i>Lena</i> $256 \times 256$	<i>Lena</i> $512 \times 512$
Image bruitée	22.1	22.1
fb-sure-let-s	30.0	31.3
Oracle-S	30.2	31.3
fb-sure-let-c	29.2	30.5
Oracle-C	29.6	30.7

**Table :** Débruitage (PSNR) avec fb-sure-let-s et fb-sure-let-c ainsi que leurs oracles respectifs pour *Lena* avec un bruit de  $\sigma = 20$ .

# Applications : FB-SURE vs redondance

Redondance $k'$	5/4	3/2	7/4	2
fb-sure-let-c	16.7	24.3	25.5	25.9
fb-sure-let-s	26.0	26.7	26.9	27.0
Différence	9.3	2.4	1.4	1.1

Redondance $k'$	9/4	5/2	11/4	3
fb-sure-let-c	26.0	25.7	25.8	27.1
fb-sure-let-s	27.2	26.8	26.9	27.4
Différence	1.2	1.1	1.1	0.3

**Table :** PSNR (en dB) après reconstruction pour les deux méthodes, pour Lena ( $\sigma = 30$ ), avec  $N = 8$ ,  $k = 3$  et différents  $k'$ .

# Applications : FB-SURE vs redondance

Redondance $k'$	5/4	3/2	7/4	2
fb-sure-let-c	16.7	24.3	25.5	25.9
fb-sure-let-s	26.0	26.7	26.9	27.0
Différence	9.3	2.4	1.4	1.1

Redondance $k'$	9/4	5/2	11/4	3
fb-sure-let-c	26.0	25.7	25.8	27.1
fb-sure-let-s	27.2	26.8	26.9	27.4
Différence	1.2	1.1	1.1	0.3

**Table :** PSNR (en dB) après reconstruction pour les deux méthodes, pour Lena ( $\sigma = 30$ ), avec  $N = 8$ ,  $k = 3$  et différents  $k'$ .

Ratio temps de calcul fb-sure-let-cvs fb-sure-let-s: 1/12



# Applications : FB-SURE vs. autres méthodes

$\sigma$	10	20	30	40	50
Image bruitée	28.1	22.1	18.6	16.1	14.2
Lena					
<i>Curvelets</i>	33.0	29.3	27.3	25.9	24.8
<i>SureShrink CS</i>	32.6	28.9	26.4	25.5	24.0
<i>BiShrink</i>	32.8	29.0	26.9	25.5	24.6
<i>UWT sure-let</i>	33.0	29.4	27.4	26.1	25.2
<i>fb-sure-let-c</i>	33.0	29.3	27.1	25.5	24.3
<i>fb-sure-let-s</i>	<b>33.8</b>	<b>30.0</b>	<b>28.0</b>	<b>26.4</b>	<b>25.3</b>
Barbara					
<i>Curvelets</i>	31.2	27.2	25.1	23.6	22.6
<i>SureShrink CS</i>	30.7	26.5	24.1	21.9	21.4
<i>BiShrink</i>	30.1	26.6	24.4	23.1	22.2
<i>UWT sure-let</i>	30.8	26.4	24.3	23.2	22.4
<i>fb-sure-let-c</i>	31.6	27.6	25.4	23.7	22.3
<i>fb-sure-let-s</i>	<b>32.2</b>	<b>28.3</b>	<b>26.2</b>	<b>24.7</b>	<b>23.6</b>


## Applications : résultats visuels



Original



Bruitée

*BiShrink**Curvelets**UWT* sure-let

fb-sure-let-c


## Applications : résultats visuels



Original

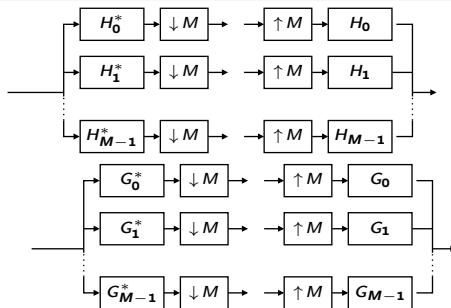


Bruitée

*BiShrink**Curvelets**UWT* sure-let

fb-sure-let-s

## Applications : approche 2



### Objectif

$\forall M \geq 2$  et  $M \in \mathbb{N}$ , construire une décomposition en ondelettes  $M$ -bandes orthogonale "duale" associée à la fonction d'échelle  $\psi_0^H$  et aux ondelettes mères  $\psi_m^H$ , où

$$\forall m \in \{1, \dots, M-1\}, \quad \hat{\psi}_m^H(\omega) = -i \operatorname{sign}(\omega) \hat{\psi}_m(\omega)$$

$G_m, m \in \{0, \dots, M-1\}$ : filtres associés à la décomposition duale.

## Applications : $M$ -bandes en arbre dual

- ▶ Décomposition en ondelettes  $M$ -bandes orthogonales of  $L^2(\mathbb{R})$ 
  - ▶ deux ensembles de filtres :  $(H_m)_{0 \leq m < M}$  and  $(G_m)_{0 \leq m < M}$
  - ▶ deux bases :  $(\psi_m)_{0 \leq m < M}$  and  $(\psi_m^H)_{0 \leq m < M}$
- ▶ Conditions d'orthogonalité

$$\sum_{p=0}^{M-1} \{\tilde{H}_m || \tilde{G}_m\}(\omega + p \frac{2\pi}{M}) \{H_{m'}^* || G_{m'}^*\}(\omega + p \frac{2\pi}{M}) = M \delta_{m-m'}.$$



- ▶ Équations d'échelle

$$\begin{aligned} \forall m \in \mathbb{N}_M, \quad \sqrt{M} \hat{\psi}_m(M\omega) &= H_m(\omega) \hat{\psi}_0(\omega), \\ \sqrt{M} \hat{\psi}_m^H(M\omega) &= G_m(\omega) \hat{\psi}_0^H(\omega), . \end{aligned}$$

- ▶ Conditions de paires de Hilbert

$$\forall m \in \mathbb{N}_M^*, \quad \hat{\psi}_m^H(\omega) = -i \operatorname{sign}(\omega) \hat{\psi}_m(\omega)$$

# Applications : $M$ -bandes en arbre dual



Ondelettes dual-tree  $M$ -bandes

Quadrant fréquentiel, 4-bandes

# Applications : $M$ -bandes en arbre dual

- ▶ **Avantages** en  $M$ -bandes ( $M > 2$ ) :
  - ▶ décomposition plus précise dans le domaine fréquentiel
  - ▶ plus grande liberté dans le choix des filtres  $M$ -bandes  $\iff$  ondelettes symétriques et orthogonales, à support compact

# Applications : $M$ -bandes en arbre dual

- ▶ **Avantages** en  $M$ -bandes ( $M > 2$ ) :
  - ▶ décomposition plus précise dans le domaine fréquentiel
  - ▶ plus grande liberté dans le choix des filtres  $M$ -bandes  $\iff$  ondelettes symétriques et orthogonales, à support compact
- ▶ **Avantages** de la construction **duale** :
  - ▶ quasi invariance par translation
  - ▶ directionnalité en 2D
- $M = 2$ : [Kingsbury, 1998] [Selesnick, 2001]



## Applications : $M$ -bandes en arbre dual

- ▶ **Avantages** en  $M$ -bandes ( $M > 2$ ) :
  - ▶ décomposition plus précise dans le domaine fréquentiel
  - ▶ plus grande liberté dans le choix des filtres  $M$ -bandes  $\iff$  ondelettes symétriques et orthogonales, à support compact
- ▶ **Avantages** de la construction **duale** :
  - ▶ quasi invariance par translation
  - ▶ directionnalité en 2D
- $M = 2$ : [Kingsbury, 1998] [Selesnick, 2001]

**Transformée géométrique** basée sur des bancs de filtres  $M$ -bandes ayant une faible redondance (facteur 2) [Chaux *et al.*, 2006]

## Bases — 1-D

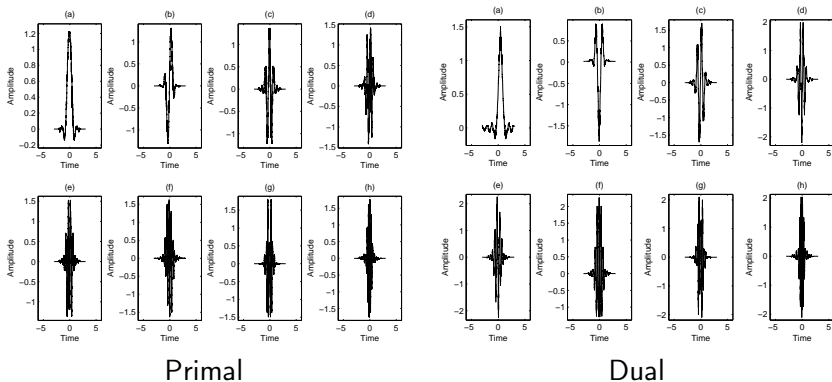




Figure : En 8 bandes

# Bases — 2-D



Dir. positive



Dir. négative

Figure : En 8 bandes

## Propriétés du bruit

En présence d'un bruit blanc : pour tout  $\ell = (\ell_1, \ell_2) \in \mathbb{Z}^2$ ,

- Dans le cas  $1D$  : pour tout  $(m, m') \in \{0, \dots, M-1\}^2$  et  $\ell \in \mathbb{Z}$ ,

$$\Gamma_{n_{j,m}, n_{j,m'}}(\ell) = \Gamma_{n_{j,m}^H, n_{j,m'}^H}(\ell) = \sigma^2 \delta_{m-m'} \delta_\ell$$

$$\Gamma_{n_{j,m}, n_{j,m'}^H}(\ell) = \sigma^2 \gamma_{\psi_m, \psi_{m'}^H}(-\ell),$$

## Propriétés du bruit

En présence d'un bruit blanc : pour tout  $\ell = (\ell_1, \ell_2) \in \mathbb{Z}^2$ ,

- Dans le cas  $1D$  : pour tout  $(m, m') \in \{0, \dots, M-1\}^2$  et  $\ell \in \mathbb{Z}$ ,

$$\Gamma_{n_{j,m}, n_{j,m'}}(\ell) = \Gamma_{n_{j,m}^H, n_{j,m'}^H}(\ell) = \sigma^2 \delta_{m-m'} \delta_\ell$$

$$\Gamma_{n_{j,m}, n_{j,m'}^H}(\ell) = \sigma^2 \gamma_{\psi_m, \psi_{m'}^H}(-\ell),$$


- Dans le cas  $2D$  : pour tout  $(\mathbf{m}, \mathbf{m}') \in \{0, \dots, M-1\}^2 \times \{0, \dots, M-1\}^2$  et  $\ell \in \mathbb{Z}^2$ ,

$$\Gamma_{n_{j,\mathbf{m}}, n_{j,\mathbf{m}'}}(\ell) = \Gamma_{n_{j,\mathbf{m}}^H, n_{j,\mathbf{m}'}^H}(\ell) = \sigma^2 \delta_{m_1-m'_1} \delta_{m_2-m'_2} \delta_{\ell_1} \delta_{\ell_2}$$

$$\Gamma_{n_{j,\mathbf{m}}, n_{j,\mathbf{m}'}^H}(\ell) = \sigma^2 \gamma_{\psi_{\mathbf{m}_1}, \psi_{\mathbf{m}'_1}^H}(-\ell_1) \gamma_{\psi_{\mathbf{m}_2}, \psi_{\mathbf{m}'_2}^H}(-\ell_2)$$

**Rque :** La comb. lin. des sous-bandes annule les corrélations inter-arbres à une position spatiale  $\mathbf{k}$  donnée mais crée des corrélations spatiales.

## Résumé



Coefficients d'approximation






Coefficients de détails ( $m \neq 0$ )Coefficients de détails avec  $m_1 m_2 \neq 0$ 

Schéma des corrélations inter-arbres pour une sous-bande  $(j, m)$  donnée, avant (haut) et après (bas) isométrie [Chaux, 2007].

# Imagerie multi-canaux



# Imagerie multi-canaux





## Objectif :

Construire un estimateur  $\hat{s}_{j,m}^{(b)}$  des coef. d'ondelettes  $s_{j,m}^{(b)}$  de  $s^{(b)}$  à partir des coefficients d'ondelettes observés  $r_{j,m}^{(b')}$  de tous les canaux  $b'$ .



## Imagerie multi-canaux

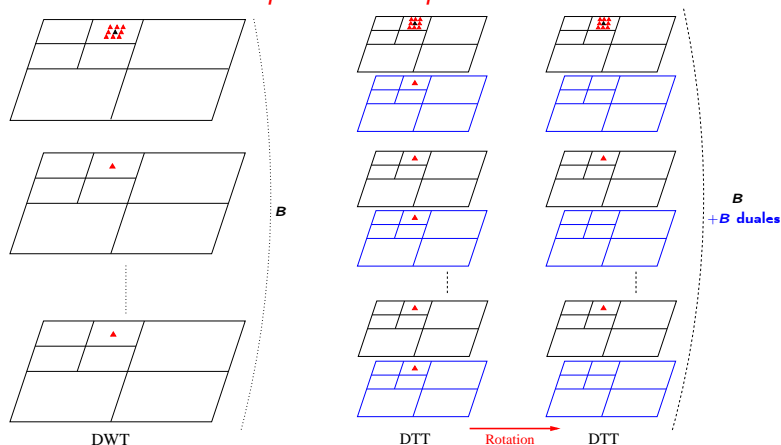


### Objectif :

Construire un estimateur  $\hat{s}_{j,m}^{(b)}$  (resp.  $\hat{s}_{j,m}^{H(b)}$ ) des coef. issus de la DTT  $s_{j,m}^{(b)}$  (resp.  $s_{j,m}^{H(b)}$ ) de  $s^{(b)}$  (resp.  $s^{H(b)}$ ) à partir des coef. observés  $r_{j,m}^{(b')}$  et  $r_{j,m}^{H(b')}$ .

# Voisinage

$\bar{r}_{j,m}^{(b)}(k)$  : coefficients observés utilisés au débruitage de  $s_{j,m}^{(b)}(k)$  (ROV). On a choisi un voisinage de  $d$  coefficients combinant des informations *inter-composantes et spatiales* :



# Estimateurs: point de départ

- Neighblock [Cai et Silverman, 2001]:

*Étude asymptotique minimax*

$$\hat{s}_{j,m}^{(b)}(\mathbf{k}) = \left( \frac{\|\mathbf{r}_{j,m}^{(b)}(\mathbf{k})\|^2 - \lambda}{\|\mathbf{r}_{j,m}^{(b)}(\mathbf{k})\|^2} \right)_+ \mathbf{r}_{j,m}^{(b)}(\mathbf{k})$$

## Estimateurs: point de départ

- Neighblock [Cai et Silverman, 2001]:

*Étude asymptotique minimax*

$$\hat{s}_{j,\mathbf{m}}^{(b)}(\mathbf{k}) = \left( \frac{\|r_{j,\mathbf{m}}^{(b)}(\mathbf{k})\|^2 - \lambda}{\|r_{j,\mathbf{m}}^{(b)}(\mathbf{k})\|^2} \right) + r_{j,\mathbf{m}}^{(b)}(\mathbf{k})$$

- Seuillage bivarié [Şendur et Selesnick, 2002]:

*Approche bayésienne*

$$\hat{s}_{j,\mathbf{m}}^{(b)}(\mathbf{k}) = \left( \frac{\sqrt{(r_{j,\mathbf{m}}^{(b)}(\mathbf{k}))^2 + (r_{j+1,\mathbf{m}}^{(b)}(\lceil \frac{\mathbf{k}}{2} \rceil))^2} - \lambda}{\sqrt{(r_{j,\mathbf{m}}^{(b)}(\mathbf{k}))^2 + (r_{j+1,\mathbf{m}}^{(b)}(\lceil \frac{\mathbf{k}}{2} \rceil))^2}} \right) + r_{j,\mathbf{m}}^{(b)}(\mathbf{k})$$

où

$$(f)_+ = \begin{cases} f & \text{si } f > 0 \\ 0 & \text{sinon} \end{cases}$$

→ On omettra les indices  $j, \mathbf{m}$  dans la suite.

## Estimateur proposé

- Fonction de seuillage généralisée  $\eta_\lambda(\|\mathbf{r}^{(b)}(\mathbf{k})\|^\beta)$ , où:

$$\forall \tau \in \mathbb{R}_+,$$

$$\eta_\lambda(\tau) = \left( \frac{\tau - \lambda}{\tau} \right)_+$$

et  $\beta > 0$  et  $\lambda \geq 0$ .

## Estimateur proposé

- Fonction de seuillage généralisée  $\eta_{\lambda}(\|\bar{\mathbf{r}}^{(b)}(\mathbf{k})\|^{\beta})$ , où:

$$\forall \tau \in \mathbb{R}_+,$$

$$\eta_{\lambda}(\tau) = \left( \frac{\tau - \lambda}{\tau} \right)_+$$

et  $\beta > 0$  et  $\lambda \geq 0$ .



$$\hat{s}^{\lambda^{(b)}}(\mathbf{k}) = f(\bar{\mathbf{r}}(\mathbf{k})) = \eta_{\lambda^{(b)}}(\|\bar{\mathbf{r}}^{(b)}(\mathbf{k})\|^{\beta^{(b)}}) (\mathbf{q}^{(b)})^{\top} \bar{\mathbf{r}}^{(b)}(\mathbf{k})$$

où  $\mathbf{q}^{(b)}$  : vecteur de même taille que le ROV,  $\beta^{(b)} > 0$ ,  
 $\lambda^{(b)} \geq 0$ .

## Calcul des paramètres

- $\lambda^{(b)} \iff$  valeur de seuil ( seuillage doux de  $\|\mathbf{r}^{(b)}(\mathbf{k})\|^{\beta^{(b)}}$  )

# Calcul des paramètres

- ▶  $\lambda^{(b)} \iff$  valeur de seuil ( seuillage doux de  $\|\mathbf{r}^{(b)}(\mathbf{k})\|^{\beta^{(b)}}$  )
- ▶ Objectif :
  - ▶ Trouver la valeur du seuil  $\lambda^{(b)}$
  - ▶ Trouver le paramètre exposant  $\beta^{(b)}$
  - ▶ Trouver le vecteur  $\mathbf{q}^{(b)}$  servant à la combinaison linéaire



# Calcul des paramètres

- ▶  $\lambda^{(b)} \iff$  valeur de seuil ( seuillage doux de  $\|\bar{\mathbf{r}}^{(b)}(\mathbf{k})\|^{\beta^{(b)}}$  )
- ▶ Objectif :
  - ▶ Trouver la valeur du seuil  $\lambda^{(b)}$
  - ▶ Trouver le paramètre exposant  $\beta^{(b)}$
  - ▶ Trouver le vecteur  $\mathbf{q}^{(b)}$  servant à la combinaison linéaire

*minimisant l'erreur quadratique moyenne:*

$$\begin{aligned}
 R(\lambda, \beta, \mathbf{q}) &= \mathbb{E}[|s^{(b)}(\mathbf{k}) - \hat{s}^{(b)}(\mathbf{k})|^2] \\
 &= \mathbb{E}[|s^{(b)}(\mathbf{k})|^2] + \mathbb{E}[|f(\bar{\mathbf{r}}^{(b)}(\mathbf{k}))|^2] - 2\mathbb{E}[f(\bar{\mathbf{r}}^{(b)}(\mathbf{k}))s^{(b)}(\mathbf{k})].
 \end{aligned}$$

## Calcul des paramètres

- ▶  $\lambda^{(b)} \iff$  valeur de seuil ( seuillage doux de  $\|\bar{\mathbf{r}}^{(b)}(\mathbf{k})\|^{\beta^{(b)}}$  )
- ▶ Objectif :
  - ▶ Trouver la valeur du seuil  $\lambda^{(b)}$
  - ▶ Trouver le paramètre exposant  $\beta^{(b)}$
  - ▶ Trouver le vecteur  $\mathbf{q}^{(b)}$  servant à la combinaison linéaire

*minimisant l'erreur quadratique moyenne:*

$$\begin{aligned}
 R(\lambda, \beta, \mathbf{q}) &= \mathbb{E}[|s^{(b)}(\mathbf{k}) - \hat{s}^{(b)}(\mathbf{k})|^2] \\
 &= \mathbb{E}[|s^{(b)}(\mathbf{k})|^2] + \mathbb{E}[|f(\bar{\mathbf{r}}^{(b)}(\mathbf{k}))|^2] - 2\mathbb{E}[f(\bar{\mathbf{r}}^{(b)}(\mathbf{k}))s^{(b)}(\mathbf{k})].
 \end{aligned}$$

❗  $s^{(b)}$  est inconnu : utilisation du Principe de Stein.

# Principe de Stein

$$\forall \mathbf{k} \in \mathbb{Z}^2, \quad \bar{\mathbf{r}}^{(b)}(\mathbf{k}) = \bar{\mathbf{s}}^{(b)}(\mathbf{k}) + \bar{\mathbf{n}}^{(b)}(\mathbf{k}),$$

$$\bar{\mathbf{r}}^{(b)}(\mathbf{k}) = \begin{bmatrix} r^{(b)}(\mathbf{k}) \\ \tilde{r}^{(b)}(\mathbf{k}) \end{bmatrix}, \quad \bar{\mathbf{s}}^{(b)}(\mathbf{k}) = \begin{bmatrix} s^{(b)}(\mathbf{k}) \\ \tilde{s}^{(b)}(\mathbf{k}) \end{bmatrix}, \quad \bar{\mathbf{n}}^{(b)}(\mathbf{k}) = \begin{bmatrix} n^{(b)}(\mathbf{k}) \\ \tilde{n}^{(b)}(\mathbf{k}) \end{bmatrix}$$

## Principe de Stein

$$\forall \mathbf{k} \in \mathbb{Z}^2, \quad \bar{\mathbf{r}}^{(b)}(\mathbf{k}) = \bar{\mathbf{s}}^{(b)}(\mathbf{k}) + \bar{\mathbf{n}}^{(b)}(\mathbf{k}),$$

$$\bar{\mathbf{r}}^{(b)}(\mathbf{k}) = \begin{bmatrix} r^{(b)}(\mathbf{k}) \\ \tilde{r}^{(b)}(\mathbf{k}) \end{bmatrix}, \quad \bar{\mathbf{s}}^{(b)}(\mathbf{k}) = \begin{bmatrix} s^{(b)}(\mathbf{k}) \\ \tilde{s}^{(b)}(\mathbf{k}) \end{bmatrix}, \quad \bar{\mathbf{n}}^{(b)}(\mathbf{k}) = \begin{bmatrix} n^{(b)}(\mathbf{k}) \\ \tilde{n}^{(b)}(\mathbf{k}) \end{bmatrix}$$

### Principe de Stein

Soit  $f : \mathbb{R}^d \rightarrow \mathbb{R}$  une fonction continue, différentiable presque partout telle que :

$$\forall \boldsymbol{\theta} \in \mathbb{R}^d, \quad \lim_{\|\mathbf{t}\| \rightarrow +\infty} f(\mathbf{t}) \exp\left(-\frac{(\mathbf{t} - \boldsymbol{\theta})^\top (\boldsymbol{\Gamma}^{(\bar{\mathbf{n}}^{(b)})})^{-1} (\mathbf{t} - \boldsymbol{\theta})}{2}\right) = 0$$

$$\mathbb{E}[|f(\bar{\mathbf{r}}^{(b)}(\mathbf{k}))|^2] < +\infty \quad \text{et} \quad \mathbb{E}\left[\left\|\frac{\partial f(\bar{\mathbf{r}}^{(b)}(\mathbf{k}))}{\partial \bar{\mathbf{r}}^{(b)}(\mathbf{k})}\right\|\right] < +\infty.$$

$$\text{On a, } \mathbb{E}[f(\bar{\mathbf{r}}^{(b)}(\mathbf{k})) \mathbf{s}^{(b)}(\mathbf{k})] = \mathbb{E}[f(\bar{\mathbf{r}}^{(b)}(\mathbf{k})) r^{(b)}(\mathbf{k})] - \mathbb{E}\left[\frac{\partial f(\bar{\mathbf{r}}^{(b)}(\mathbf{k}))}{\partial \bar{\mathbf{r}}^{(b)}(\mathbf{k})}\right]^\top \mathbb{E}[\bar{\mathbf{n}}^{(b)} n^{(b)}].$$

## Calcul des paramètres

- Dans notre cas  $f : \mathbf{u} \mapsto \eta_{\lambda^{(b)}}(\|\mathbf{u}\|^{\beta^{(b)}}) (\mathbf{q}^{(b)})^\top \mathbf{u}$

## Calcul des paramètres

- Dans notre cas  $f : \mathbf{u} \mapsto \eta_{\lambda^{(b)}}(\|\mathbf{u}\|^{\beta^{(b)}}) (\mathbf{q}^{(b)})^\top \mathbf{u}$
- Afin de limiter la complexité de calcul,  $\mathbf{q}^{(b)}$  peut être contraint à un sous-espace de dimension  $d' \leq d$ . Soit  $\mathbf{P}^{(b)} \in \mathbb{R}^{d \times d'}$  une matrice dont les colonnes forment une base de ce sous-espace ;  $\mathbf{q}^{(b)} = \mathbf{P}^{(b)} \mathbf{a}^{(b)}$  où  $\mathbf{a}^{(b)} \in \mathbb{R}^{d'}$ . Exemple :

$$\mathbf{P}^{(b)} = \begin{bmatrix} \mathbf{I}_{d'} \\ \mathbf{O} \end{bmatrix}$$

$\mathbf{I}_{d'}$  : matrice identité de taille  $d' \times d'$

## Calcul des paramètres

- ▶ Dans notre cas  $f : \mathbf{u} \mapsto \eta_{\lambda^{(b)}}(\|\mathbf{u}\|^{\beta^{(b)}}) (\mathbf{q}^{(b)})^\top \mathbf{u}$
- ▶ Afin de limiter la complexité de calcul,  $\mathbf{q}^{(b)}$  peut être contraint à un sous-espace de dimension  $d' \leq d$ . Soit  $\mathbf{P}^{(b)} \in \mathbb{R}^{d \times d'}$  une matrice dont les colonnes forment une base de ce sous-espace ;  $\mathbf{q}^{(b)} = \mathbf{P}^{(b)} \mathbf{a}^{(b)}$  où  $\mathbf{a}^{(b)} \in \mathbb{R}^{d'}$ . Exemple :

$$\mathbf{P}^{(b)} = \begin{bmatrix} \mathbf{I}_{d'} \\ \mathbf{O} \end{bmatrix}$$

$\mathbf{I}_{d'}$  : matrice identité de taille  $d' \times d'$

- ▶ Dans ce cas  $f : \mathbf{u} \mapsto \eta_{\lambda^{(b)}}(\|\mathbf{u}\|^{\beta^{(b)}}) (\mathbf{a}^{(b)})^\top (\mathbf{P}^{(b)})^\top \mathbf{u}$

## Calcul des paramètres

- ▶ Dans notre cas  $f : \mathbf{u} \mapsto \eta_{\lambda^{(b)}}(\|\mathbf{u}\|^{\beta^{(b)}}) (\mathbf{q}^{(b)})^\top \mathbf{u}$
- ▶ Afin de limiter la complexité de calcul,  $\mathbf{q}^{(b)}$  peut être contraint à un sous-espace de dimension  $d' \leq d$ . Soit  $\mathbf{P}^{(b)} \in \mathbb{R}^{d \times d'}$  une matrice dont les colonnes forment une base de ce sous-espace ;  $\mathbf{q}^{(b)} = \mathbf{P}^{(b)} \mathbf{a}^{(b)}$  où  $\mathbf{a}^{(b)} \in \mathbb{R}^{d'}$ . Exemple :

$$\mathbf{P}^{(b)} = \begin{bmatrix} \mathbf{I}_{d'} \\ \mathbf{O} \end{bmatrix}$$

$\mathbf{I}_{d'}$  : matrice identité de taille  $d' \times d'$

- ▶ Dans ce cas  $f : \mathbf{u} \mapsto \eta_{\lambda^{(b)}}(\|\mathbf{u}\|^{\beta^{(b)}}) (\mathbf{a}^{(b)})^\top (\mathbf{P}^{(b)})^\top \mathbf{u}$
- ▶ Les paramètres à déterminer sont alors  $\lambda^{(b)}$ ,  $\beta^{(b)}$  et  $\mathbf{a}^{(b)}$  pour  $\mathbf{P}^{(b)}$  donnée.



# Algorithme

- **Etape 1** Risque quadratique en  $a$  : calcul de  $a$  pour  $\lambda$  et  $\beta$  fixés

# Algorithme

- **Etape 1 Risque quadratique** en  $\mathbf{a}$  : calcul de  $\mathbf{a}$  pour  $\lambda$  et  $\beta$  fixés

- **Etape 2 Risque quadratique par morceaux** en  $\lambda^{(b)}$

$$R(\lambda, \beta, \mathbf{a}) = E[\alpha_2(\mathbf{k})(\lambda^{(b)})^2 + \alpha_1(\mathbf{k})\lambda^{(b)} + \alpha_0(\mathbf{k})]$$

Généralisation de SUREShrink [Donoho *et al.*, 1995].

Réordonnancement :  $\|\bar{\mathbf{r}}(\mathbf{k}_1)\| \geq \|\bar{\mathbf{r}}(\mathbf{k}_2)\| \geq \dots \geq \|\bar{\mathbf{r}}(\mathbf{k}_K)\|$

$\lambda \in I_{i_0}$  avec  $i_0 \in \{1, \dots, K+1\}$  et

$$I_{i_0} = \begin{cases} [\|\bar{\mathbf{r}}(\mathbf{k}_1)\|^\beta, \infty) & \text{si } i_0 = 1 \\ [\|\bar{\mathbf{r}}(\mathbf{k}_{i_0})\|^\beta, \|\bar{\mathbf{r}}(\mathbf{k}_{i_0-1})\|^\beta) & \text{si } i_0 \in \{2, \dots, K\} \\ [0, \|\bar{\mathbf{r}}(\mathbf{k}_K)\|^\beta) & \text{si } i_0 = K+1. \end{cases}$$

Pour un  $\beta^{(b)}$  fixé on détermine le  $\lambda^{(b)}$  optimal

# Algorithmes

- **Etape 1 Risque quadratique** en  $\mathbf{a}$  : calcul de  $\mathbf{a}$  pour  $\lambda$  et  $\beta$  fixés

- **Etape 2 Risque quadratique par morceaux** en  $\lambda^{(b)}$

$$R(\lambda, \beta, \mathbf{a}) = E[\alpha_2(\mathbf{k})(\lambda^{(b)})^2 + \alpha_1(\mathbf{k})\lambda^{(b)} + \alpha_0(\mathbf{k})]$$

Généralisation de SUREShrink [Donoho *et al.*, 1995].

Réordonnancement :  $\|\bar{\mathbf{r}}(\mathbf{k}_1)\| \geq \|\bar{\mathbf{r}}(\mathbf{k}_2)\| \geq \dots \geq \|\bar{\mathbf{r}}(\mathbf{k}_K)\|$

$\lambda \in I_{i_0}$  avec  $i_0 \in \{1, \dots, K+1\}$  et

$$I_{i_0} = \begin{cases} [\|\bar{\mathbf{r}}(\mathbf{k}_1)\|^\beta, \infty) & \text{si } i_0 = 1 \\ [\|\bar{\mathbf{r}}(\mathbf{k}_{i_0})\|^\beta, \|\bar{\mathbf{r}}(\mathbf{k}_{i_0-1})\|^\beta) & \text{si } i_0 \in \{2, \dots, K\} \\ [0, \|\bar{\mathbf{r}}(\mathbf{k}_K)\|^\beta) & \text{si } i_0 = K+1. \end{cases}$$

Pour un  $\beta^{(b)}$  fixé on détermine le  $\lambda^{(b)}$  optimal

- **Etape 3 Recherche exhaustive** sur un ensemble réduit de valeurs pour trouver le meilleur  $\beta^{(b)}$

# Comparaisons

Acronym	Description	Acronym	Description
Biv.	Seuillage bivarié [Şendur, Selesnick, 2002]	Méthodes multivariées	
BLS-GSM	Bayesian Least Squares Gaussian Scale Mixture DWT décimée [Portilla, 2003]	ProbShrink (. × .)	Multiv. (images 3-bandes) DWT décimée voisinage (. × .) [Pizurica, 2006]
BLS-GSM + parent	BLS-GSM DWT décimée + coefficient parent [Portilla, 2003]	ProbShrink red. (. × .)	Multiv. (images 3-bandes) DWT non décimée + voisinage (. × .) [Pizurica, 2006]
BLS-GSM red.	BLS-GSM + pyramide orientée (transformée redondante) [Portilla, 2003]	Surevect	Appr. SURE étendue DWT décimée  [Benazza, 2005]
Curvelets	Curvelets + Estim. par bloc redondance de 7.5 [Candès, 2006]		

# Résultats comparatifs


## Non redondant

Canal	SNR <sub>init</sub>	Biv	ProbShrink (3 × 3)	BLS-GSM	BLS-GSM + parent	Surevect	Méthode proposée
$b = 1$	4.664	11.12	11.18	11.32	11.42	12.95	13.24
$b = 2$	5.653	11.60	11.63	11.81	11.90	12.99	13.34
$b = 3$	4.926	12.82	12.77	13.01	13.11	13.30	13.65
Moy.	5.081	11.85	11.86	12.05	12.14	13.08	13.41
$b = 1$	14.66	17.32	17.05	17.67	17.81	19.16	19.71
$b = 2$	15.65	18.01	17.65	18.36	18.50	19.35	19.94
$b = 3$	14.93	18.32	17.93	18.64	18.74	18.61	19.27
Moy.	15.08	17.88	17.54	18.22	18.35	19.04	19.64


## Redondant

Canal	SNR <sub>init</sub>	Curvelets	BLS-GSM red + parent	ProbShrink red (3 × 3)	ProbShrink red (1 × 1)	Méthode proposée
$b = 1$	4.664	11.16	12.21	12.36	12.84	13.57
$b = 2$	5.653	11.64	12.69	12.77	13.14	13.65
$b = 3$	4.925	12.92	13.88	13.88	14.00	13.91
Moy.	5.081	11.91	12.92	13.00	13.33	13.71
$b = 1$	14.66	16.87	18.47	18.22	18.95	19.94
$b = 2$	15.65	17.50	19.12	18.80	19.38	20.16
$b = 3$	14.93	18.31	19.53	19.24	19.28	19.53
Moy.	15.08	17.56	19.04	18.76	19.20	19.88


## Résultats comparatifs




Originale



Bruitée



Probshrink



Dual-tree

# Conclusions

- Applications de débruitage

# Conclusions

- ▶ Applications de débruitage
  - ▶ combinaison d'estimateurs statistiques et décompositions directionnelles



# Conclusions

- ▶ Applications de débruitage
  - ▶ combinaison d'estimateurs statistiques et décompositions directionnelles
  - ▶ extensions à des bruits de Poisson, des mélanges, au défloutage
- ▶ Codes, démos
  - ▶ <https://www.projet-plume.org/relier/surelet-deconv>
  - ▶ <http://www.greyc.ensicaen.fr/~jfadili/software.html>
  - ▶ <http://www.laurent-duval.eu/misc-research-codes.html>
- ▶ Perspectives

# Conclusions

- ▶ Applications de débruitage
  - ▶ combinaison d'estimateurs statistiques et décompositions directionnelles
  - ▶ extensions à des bruits de Poisson, des mélanges, au défloutage
- ▶ Codes, démos
  - ▶ <https://www.projet-plume.org/relrier/surelet-deconv>
  - ▶ <http://www.greyc.ensicaen.fr/~jfadili/software.html>
  - ▶ <http://www.laurent-duval.eu/misc-research-codes.html>
- ▶ Perspectives
  - ▶ erreurs : de vraies mesures pratiques

# Conclusions

- ▶ Applications de débruitage
  - ▶ combinaison d'estimateurs statistiques et décompositions directionnelles
  - ▶ extensions à des bruits de Poisson, des mélanges, au défloutage
- ▶ Codes, démos
  - ▶ <https://www.projet-plume.org/relier/surelet-deconv>
  - ▶ <http://www.greyc.ensicaen.fr/~jfadili/software.html>
  - ▶ <http://www.laurent-duval.eu/misc-research-codes.html>
- ▶ Perspectives
  - ▶ erreurs : de vraies mesures pratiques
  - ▶ hybridation étendue : représentations, statistiques et optimisation

# Conclusions

- ▶ Applications de débruitage
  - ▶ combinaison d'estimateurs statistiques et décompositions directionnelles
  - ▶ extensions à des bruits de Poisson, des mélanges, au défloutage
- ▶ Codes, démos
  - ▶ <https://www.projet-plume.org/relier/surelet-deconv>
  - ▶ <http://www.greyc.ensicaen.fr/~jfadili/software.html>
  - ▶ <http://www.laurent-duval.eu/misc-research-codes.html>
- ▶ Perspectives
  - ▶ erreurs : de vraies mesures pratiques
  - ▶ hybridation étendue : représentations, statistiques et optimisation
  - ▶ meilleure percolation des ondelettes dans les problèmes concrets

## Références

- ▶ J.-C. Pesquet and D. Leporini. *A new wavelet estimator for image denoising*, in *IEE Sixth Int. Conf. Im. Proc. Appl.*, volume 1, pages 249–253, Dublin, Ireland, Jul. 14-17 1997.
- ▶ C. Chaux, L. Duval et J.-C. Pesquet, *Image Analysis Using a Dual-Tree M-Band Wavelet Transform*, IEEE Trans. on Image Proc., Aug. 2006 (pdf).
- ▶ C. Chaux, J.-C. Pesquet et L. Duval, *Noise Covariance Properties in Dual-Tree Wavelet Decompositions*, IEEE Trans. on Inf. Theory, Dec. 2007 (pdf).
- ▶ C. Chaux, L. Duval, A. Benazza-Benyahia et J.-C. Pesquet, *A Nonlinear Stein Based Estimator for Multichannel Image Denoising*, IEEE Trans. on Signal Proc., Aug. 2008 (pdf).
- ▶ J. Gauthier, L. Duval, and J.-C. Pesquet *Optimization of synthesis oversampled complex filter banks*, IEEE Trans. Signal Process., Oct. 2009 (pdf).
- ▶ J.-C. Pesquet, A. Benazza-Benyahia et C. Chaux, *A SURE Approach for Digital Signal/Image Deconvolution Problems*, IEEE Trans. on Signal Proc., Dec. 2009 (pdf),
- ▶ L. Jacques, L. Duval, C. Chaux, G. Peyré, *A Panorama on Multiscale Geometric Representations, Intertwining Spatial, Directional and Frequency Selectivity*, Signal Processing, Dec. 2011 (pdf).

## Références

- ▶ D. L. Donoho and I. M. Johnstone *Adapting to unknown smoothness via wavelet shrinkage*, J. Am. Stat. Assoc., Dec. 1995.
- ▶ M. Raphan and E. P. Simoncelli *Empirical Bayes least squares estimation without an explicit prior*, Technical Report TR2007-900, Courant Institute of Mathematical Sciences, NYU, 2007.
- ▶ F. Luisier, T. Blu, and M. Unser *A new SURE approach to image denoising: Inter-scale orthonormal wavelet thresholding*, IEEE Trans. Image Process., Mar. 2007.
- ▶ T. Blu and F. Luisier, *The SURE-LET approach to image denoising*, IEEE Trans. Image Process., Nov. 2007.
- ▶ M. Raphan and E.P. Simoncelli *Optimal denoising in redundant representations*, IEEE Trans. Image Process., Aug. 2008.
- ▶ M. Raphan and E. P. Simoncelli *Learning least squares estimators without assumed priors or supervision*, Technical Report TR2009-923, Howard Hughes Medical Institute, Center for Neural Science, New York University, Aug. 2009.
- ▶ C. Chesneau, M. J. Fadili, and J.-L. Starck, *Stein Block Thresholding For Image Denoising*, Appl. Comp. Harm. Analysis, Jan. 2010
- ▶ G. Peyré, *A Review of Adaptive Image Representations*, J. Sel. Topics Signal Proc., 2011