

Super-résolution sans-grille en imagerie de fluctuation.

Bastien Laville, Laure Blanc-Féraud, Gilles Aubert

Projet Morpheme : Inria SAM, CNRS, UCA (France)

GRETSI 2022



Sommaire

- 1 Introduction
- 2 État de l'art sans-grille
- 3 Reconstruction par covariance
- 4 Conclusion

Introduction

Contexte biomédical

Objectif


Imager des structures biologiques à de petites échelles

Contexte biomédical



Objectif

Imager des structures biologiques à de petites échelles

Limitation physique à cause de la diffraction pour des corps < 200 nm :
convolution par la *point spread function* (PSF) du microscope



PSF h = disque d'Airy
ou gaussienne.




Contexte biomédical



Objectif

Imager des structures biologiques à de petites échelles

Limitation physique à cause de la diffraction pour des corps < 200 nm : convolution par la *point spread function* (PSF) du microscope




PSF h = disque d'Airy
ou gaussienne.




Reconstruction par exemple par microscopie de fluorescence SMLM : pile d'acquisition avec peu de fluorophores allumés par image. Défauts : beaucoup d'images ($\approx 1 \times 10^4$, ne permet pas l'imagerie de cellules vivantes).

Pile EPFL SMLM Challenge (10000 images, haute densité) :



Moyenne de la pile


Pile EPFL SMLM Challenge (10000 images, haute densité) :



Moyenne de la pile

Off-the-grid

Pile EPFL SMLM Challenge (10000 images, haute densité) :




Moyenne de la pile

Off-the-grid

Deep-STORM

Pile EPFL SMLM Challenge (10000 images, haute densité) :



Moyenne de la pile


Off-the-grid

Deep-STORM

Défauts SMLM : beaucoup d'images, pas d'imagerie de cellules vivantes.


État de l'art sans-grille

Problème inverse, à partir d'une acquisition on reconstruit positions et amplitudes de pics.




Acquisition

Inverse problem




Reconstruction

Problème inverse, à partir d'une acquisition on reconstruit positions et amplitudes de pics.



Acquisition

Inverse problem



Reconstruction

- déconvolution sans-grille peut s'interpréter comme la « limite » d'une grille de plus en plus fine ;
- plus limité par la grille fine.



Le cas discret

- les pics reconstruits sont nécessairement sur une grille ;
- optimisation combinatoire (non-)convexe ;
- littérature fournie.



Le cas discret

- les pics reconstruits sont nécessairement sur une grille ;
- optimisation combinatoire (non-)convexe ;
- littérature fournie.



Le cas sans-grille

- pas de limitation par la grille ;
- convexité mais dim infinie ;
- garanties (unicité, etc) ;
- information structurelle sur la solution ;
- domaine de recherche récent.

État de l'art sans-grille

Positionnement :

- \mathcal{X} est un compact de \mathbb{R}^d ;

État de l'art sans-grille

Positionnement :

- \mathcal{X} est un compact de \mathbb{R}^d ;
- comment modéliser les pics ? Par mesures de Dirac δ_x , élément de l'ensemble des mesures de Radon finies $\mathcal{M}(\mathcal{X})$;

État de l'art sans-grille

Positionnement :

- \mathcal{X} est un compact de \mathbb{R}^d ;
- comment modéliser les pics ? Par mesures de Dirac δ_x , élément de l'ensemble des mesures de Radon finies $\mathcal{M}(\mathcal{X})$;
- dual topologique de $\mathcal{C}_0(\mathcal{X})$ pour $\langle f, m \rangle = \int_{\mathcal{X}} f \, dm$. Généralisation de $L^1(\mathcal{X})$; $L^1(\mathcal{X}) \hookrightarrow \mathcal{M}(\mathcal{X})$;

État de l'art sans-grille

Positionnement :

- \mathcal{X} est un compact de \mathbb{R}^d ;
- comment modéliser les pics ? Par mesures de Dirac δ_x , élément de l'ensemble des mesures de Radon finies $\mathcal{M}(\mathcal{X})$;
- dual topologique de $\mathcal{C}_0(\mathcal{X})$ pour $\langle f, m \rangle = \int_{\mathcal{X}} f \, dm$. Généralisation de $L^1(\mathcal{X})$; $L^1(\mathcal{X}) \hookrightarrow \mathcal{M}(\mathcal{X})$;
- Banach pour la norme TV : $m \in \mathcal{M}(\mathcal{X})$,

$$|m|(\mathcal{X}) \stackrel{\text{def.}}{=} \sup \left(\int_{\mathcal{X}} f \, dm \mid f \in \mathcal{C}_0(\mathcal{X}), \|f\|_{\infty, \mathcal{X}} \leq 1 \right).$$

Si $m = \sum_{i=1}^N a_i \delta_{x_i}$ est une mesure discrète alors
 $|m|(\mathcal{X}) = \sum_{i=1}^N |a_i|$.

Soit $m_{a_0, x_0} \stackrel{\text{def.}}{=} \sum_{i=1}^N a_i \delta_{x_i}$ une mesure discrète, $\Phi : \mathcal{M}(\mathcal{X}) \rightarrow \mathbb{L}^2(\mathcal{X})$ opérateur d'acquisition (e.g. $\Phi m_{a_0, x_0} \stackrel{\text{def.}}{=} \sum_{i=1}^N a_i h(x - x_i)$ le noyau gaussien) et $w \in \mathbb{L}^2(\mathcal{X})$ bruit additif :

$$y \stackrel{\text{def.}}{=} \Phi m_{a_0, x_0} + w.$$

Soit $m_{a_0, x_0} \stackrel{\text{def.}}{=} \sum_{i=1}^N a_i \delta_{x_i}$ une mesure discrète, $\Phi : \mathcal{M}(\mathcal{X}) \rightarrow L^2(\mathcal{X})$ opérateur d'acquisition (e.g. $\Phi m_{a_0, x_0} \stackrel{\text{def.}}{=} \sum_{i=1}^N a_i h(x - x_i)$ le noyau gaussien) et $w \in L^2(\mathcal{X})$ bruit additif :

$$y \stackrel{\text{def.}}{=} \Phi m_{a_0, x_0} + w.$$

On appelle **BLASSO** le problème d'optimisation [Candes14, Duval15] pour $\lambda > 0$:

$$\operatorname{argmin}_{m \in \mathcal{M}(\mathcal{X})} \frac{1}{2} \|y - \Phi m\|_{L^2(\mathcal{X})}^2 + \lambda |m|(\mathcal{X}) \quad (\mathcal{P}_\lambda(y))$$

Soit $m_{a_0, x_0} \stackrel{\text{def.}}{=} \sum_{i=1}^N a_i \delta_{x_i}$ une mesure discrète, $\Phi : \mathcal{M}(\mathcal{X}) \rightarrow L^2(\mathcal{X})$ opérateur d'acquisition (e.g. $\Phi m_{a_0, x_0} \stackrel{\text{def.}}{=} \sum_{i=1}^N a_i h(x - x_i)$ le noyau gaussien) et $w \in L^2(\mathcal{X})$ bruit additif :

$$y \stackrel{\text{def.}}{=} \Phi m_{a_0, x_0} + w.$$

On appelle **BLASSO** le problème d'optimisation [Candes14, Duval15] pour $\lambda > 0$:

$$\operatorname{argmin}_{m \in \mathcal{M}(\mathcal{X})} \frac{1}{2} \|y - \Phi m\|_{L^2(\mathcal{X})}^2 + \lambda |m|(\mathcal{X}) \quad (\mathcal{P}_\lambda(y))$$

Problème difficile, résolu par exemple par algorithme glouton (*Frank-Wolfe*, ...)

Implémentation des méthodes sans-grille dans notre paquet python ¹.

¹<https://gitlab.inria.fr/blaville/off-the-grid-python>

Implémentation des méthodes sans-grille dans notre paquet python ¹.

```
import offgrid

N_ECH = 500; X_GAUCHE = 0; X_DROIT = 1
domain = offgrid.Domain2D(X_GAUCHE, X_DROIT, N_ECH, dev="cuda")

psf = offgrid.Kernel2D('gaussian', {'sigma_psf': 5e-2})
```

¹<https://gitlab.inria.fr/blaville/off-the-grid-python>

Implémentation des méthodes sans-grille dans notre paquet python ¹.

```
import offgrid

N_ECH = 500; X_GAUCHE = 0; X_DROIT = 1
domain = offgrid.Domain2D(X_GAUCHE, X_DROIT, N_ECH, dev="cuda")

psf = offgrid.Kernel2D('gaussian', {'sigma_psf': 5e-2})

m_ax0 = offgrid.Spikes2D([1e1], [[0.2, 0.7]])
y = m_ax0.kernel(domain, psf)

(m_sfw, nrj_sfw, mes_sfw) = offgrid.SFW(y, domain, psf, regul=1e-2,
                                         nIter=1, dev="cuda")
```

¹<https://gitlab.inria.fr/blaville/off-the-grid-python>

Implémentation des méthodes sans-grille dans notre paquet python ¹.

```
import offgrid

N_ECH = 500; X_GAUCHE = 0; X_DROIT = 1
domain = offgrid.Domain2D(X_GAUCHE, X_DROIT, N_ECH, dev="cuda")

psf = offgrid.Kernel2D('gaussian', {'sigma_psf': 5e-2})

m_ax0 = offgrid.Spikes2D([1e1], [[0.2, 0.7]])
y = m_ax0.kernel(domain, psf)

(m_sfw, nrj_sfw, mes_sfw) = offgrid.SFW(y, domain, psf, regul=1e-2,
                                         nIter=1, dev="cuda")
```

Output:

```
Computing SFW on cuda device: 100%|--->| 1/1 [00:01<00:00, 1.03it/s]
```

¹<https://gitlab.inria.fr/blaville/off-the-grid-python>

Illustration de la reconstruction par Sliding Frank-Wolfe [Denoyelle19] :

Illustration de la reconstruction par Conic Particle Gradient Flow reconstruction [Chizat20] :

Reconstruction par covariance

Une autre imagerie : SOFI

Imagerie SOFI (*Super-resolution optical fluctuation imaging*)
[Dertinger10].

Une autre imagerie : SOFI

Imagerie SOFI (*Super-resolution optical fluctuation imaging*)
[Dertinger10].

- beaucoup de fluorophores
allumés en même temps ;

Une autre imagerie : SOFI

Imagerie SOFI (*Super-resolution optical fluctuation imaging*)
[Dertinger10].

- beaucoup de fluorophores allumés en même temps ;
- indépendance temporelle des fluorophores.

Une autre imagerie : SOFI


Imagerie SOFI (*Super-resolution optical fluctuation imaging*)
[Dertinger10].

- beaucoup de fluorophores allumés en même temps ;
- indépendance temporelle des fluorophores.
- moins nocif pour les structures biologiques étudiées ;

Une autre imagerie : SOFI

Imagerie SOFI (*Super-resolution optical fluctuation imaging*)
[Dertinger10].


- beaucoup de fluorophores allumés en même temps ;
- indépendance temporelle des fluorophores.
- moins nocif pour les structures biologiques étudiées ;



Une autre imagerie : SOFI

Imagerie SOFI (*Super-resolution optical fluctuation imaging*)
[Dertinger10].


- beaucoup de fluorophores allumés en même temps ;
- indépendance temporelle des fluorophores.
- moins nocif pour les structures biologiques étudiées ;



Une autre imagerie : SOFI

Imagerie SOFI (*Super-resolution optical fluctuation imaging*)
[Dertinger10].

- beaucoup de fluorophores allumés en même temps ;
- indépendance temporelle des fluorophores.
- moins nocif pour les structures biologiques étudiées ;



Quantités en jeu

- on effectue des acquisitions (images dans $L^2(\mathcal{X})$) sur $[0, T]$;

Quantités en jeu

- on effectue des acquisitions (images dans $L^2(\mathcal{X})$) sur $[0, T]$;
- on définit $y : [0, T] \rightarrow L^2(\mathcal{X})$ la pile d'acquisition SOFI ;

Quantités en jeu

- on effectue des acquisitions (images dans $L^2(\mathcal{X})$) sur $[0, T]$;
- on définit $y : [0, T] \rightarrow L^2(\mathcal{X})$ la pile d'acquisition SOFI ;
- on cherche à reconstruire une mesure *dynamique* :

$$t \mapsto \mu(t) \stackrel{\text{def.}}{=} \sum_{i=1}^N a_i(t) \delta_{x_i} \in L^2(0, T; \mathcal{M}(\mathcal{X}))$$

qui génère pour presque tout $t \in [0, T]$: $y(t) = \Phi\mu(t)$.

Quantités en jeu

- on effectue des acquisitions (images dans $L^2(\mathcal{X})$) sur $[0, T]$;
- on définit $y : [0, T] \rightarrow L^2(\mathcal{X})$ la pile d'acquisition SOFI ;
- on cherche à reconstruire une mesure *dynamique* :

$$t \mapsto \mu(t) \stackrel{\text{def.}}{=} \sum_{i=1}^N a_i(t) \delta_{x_i} \in L^2(0, T; \mathcal{M}(\mathcal{X}))$$

qui génère pour presque tout $t \in [0, T]$: $y(t) = \Phi\mu(t)$.

Les cumulants peuvent nous aider à retrouver les positions x_i . Exemple : moyenne temporelle $\bar{y} \stackrel{\text{def.}}{=} \frac{1}{T} \int_0^T y(\cdot, t) dt$. On a $\Phi m_{a,x} = \bar{y}$ où $m_{a,x} \stackrel{\text{def.}}{=} \sum_{i=1}^N \bar{a}_i \delta_{x_i}$.

Construire les problèmes

Si R_y est la covariance temporelle, on a $\forall u, v \in \mathcal{X}$:

Construire les problèmes

Si R_y est la covariance temporelle, on a $\forall u, v \in \mathcal{X}$:

$$\begin{aligned} R_y(u, v) &\stackrel{\text{def.}}{=} \frac{1}{T} \int_0^T (y(u, t) - \bar{y}(u)) (y(v, t) - \bar{y}(v)) dt \\ &= \dots \quad (\text{indépendance des fluctuations [Dertinger10]}) \\ &= \sum_{i=1}^N \underbrace{M_i}_{\text{Variance de } a_i} h(u - x_i) h(v - x_i) \\ &= \int_{\mathcal{X}} h(u - x) h(v - x) dm_{M,x}(x) \\ &= \Lambda m_{M,x}(u, v). \end{aligned}$$


Construire les problèmes

Si R_y est la covariance temporelle, on a $\forall u, v \in \mathcal{X}$:

$$\begin{aligned}
 R_y(u, v) &\stackrel{\text{def.}}{=} \frac{1}{T} \int_0^T (y(u, t) - \bar{y}(u)) (y(v, t) - \bar{y}(v)) dt \\
 &= \dots \quad (\text{indépendance des fluctuations [Dertinger10]}) \\
 &= \sum_{i=1}^N \underbrace{M_i}_{\text{Variance de } a_i} h(u - x_i) h(v - x_i) \\
 &= \int_{\mathcal{X}} h(u - x) h(v - x) dm_{M,x}(x) \\
 &= \Lambda m_{M,x}(u, v).
 \end{aligned}$$

$m_{M,x} \stackrel{\text{def.}}{=} \sum_{i=1}^N M_i \delta_{x_i}$ partage les mêmes positions que $\mu = \sum_{i=1}^N a_i(t) \delta_{x_i}$, on appelle $\Lambda : \mathcal{M}(\mathcal{X}) \rightarrow L^2(\mathcal{X}^2)$ cet « opérateur de covariance ».

Résumé des quantités



Légende : partie dynamique, partie moyenne temporelle \bar{y} et partie covariance temporelle R_y .

BLASSO on cumulants

Soit $\lambda > 0$,

La reconstruction par covariance s'écrit :

$$\operatorname{argmin}_{m \in \mathcal{M}(\mathcal{X})} T_\lambda(m) \stackrel{\text{def.}}{=} \frac{1}{2} \|R_y - \Lambda(m)\|_{L^2(\mathcal{X}^2)}^2 + \lambda |m|(\mathcal{X}) \quad (\mathcal{Q}_\lambda(y))$$

BLASSO on cumulants

Soit $\lambda > 0$,


La reconstruction par covariance s'écrit :

$$\operatorname{argmin}_{m \in \mathcal{M}(\mathcal{X})} T_\lambda(m) \stackrel{\text{def.}}{=} \frac{1}{2} \|R_y - \Lambda(m)\|_{L^2(\mathcal{X}^2)}^2 + \lambda |m|(\mathcal{X}) \quad (\mathcal{Q}_\lambda(y))$$

Résultats numériques 2D SOFItool

Test sur des filaments 2D issus du ISBI challenge 2016 :


- pile de 1000 acquisitions en 64×64 simulées par SOFItool ;
- 8700 émetteurs répartis sur les filaments ; bruit de fond **fort** + bruit de Poisson à 4 + bruit gaussien à 1×10^{-2} . SNR ≈ 10 db.



Résultats numériques 2D SOFItool

Test sur des filaments 2D issus du ISBI challenge 2016 :

- pile de 1000 acquisitions en 64×64 simulées par SOFItool ;
- 8700 émetteurs répartis sur les filaments ; bruit de fond **fort** + bruit de Poisson à 4 + bruit gaussien à 1×10^{-2} . SNR ≈ 10 db.






Figure 1: Vérité-terrain




Figure 1: Vérité-terrain




Figure 2: $(Q_\lambda(y))$




Figure 1: Vérité-terrain




Figure 2: $(Q_\lambda(y))$





Figure 3: SRRF [Culley18]



Application : paléomagnétisme, imagerie biomédicale, etc.

Corollaire (AMG)


Soit $\mathcal{V} \stackrel{\text{def.}}{=} \left\{ \mathbf{m} \in \mathcal{M}(\mathcal{X})^2, \text{div}(\mathbf{m}) \in \mathcal{M}(\mathcal{X}) \right\}$, le problème CROC admet comme minimiseur une combinaison linéaire finie de courbes :

$$\operatorname{argmin}_{\mathbf{m} \in \mathcal{V}} \frac{1}{2} \|y - \Phi \mathbf{m}\|_{\mathcal{H}}^2 + \alpha (\|\mathbf{m}\|_{\text{TV}^2} + \|\text{div} \mathbf{m}\|_{\text{TV}}). \quad (\text{CROC})$$

Corollaire (AMG)

Soit $\mathcal{V} \stackrel{\text{def.}}{=} \left\{ \mathbf{m} \in \mathcal{M}(\mathcal{X})^2, \operatorname{div}(\mathbf{m}) \in \mathcal{M}(\mathcal{X}) \right\}$, le problème CROC admet comme minimiseur une combinaison linéaire finie de courbes :

$$\operatorname{argmin}_{\mathbf{m} \in \mathcal{V}} \frac{1}{2} \|y - \Phi \mathbf{m}\|_{\mathcal{H}}^2 + \alpha (\|\mathbf{m}\|_{\text{TV}^2} + \|\operatorname{div} \mathbf{m}\|_{\text{TV}}). \quad (\text{CROC})$$



Conclusion

Les nouvelles approches

- ① approche sans-grille en imagerie SOFI de microscopie fluorescente, reconstruction par covariance ;
- ② reconstruction sans-grille de courbes AMG

Les nouvelles approches

- 1 approche sans-grille en imagerie SOFI de microscopie fluorescente, reconstruction par covariance ;
- 2 reconstruction sans-grille de courbes AM \mathcal{G}

Dans le futur :

- étoffer le paquet *python* sans-grille à destination des biologistes (accélération *PyKeOps* ?) ;

Les nouvelles approches

- 1 approche sans-grille en imagerie SOFI de microscopie fluorescente, reconstruction par covariance ;
- 2 reconstruction sans-grille de courbes AMG

Dans le futur :

- étoffer le paquet *python* sans-grille à destination des biologistes (accélération *PyKeOps* ?) ;
- implémentation numérique de CROC/AMG avec une version de (*Sliding*) *Frank-Wolfe* ;

Les nouvelles approches

- 1 approche sans-grille en imagerie SOFI de microscopie fluorescente, reconstruction par covariance ;
- 2 reconstruction sans-grille de courbes AMG

Dans le futur :

- étoffer le paquet *python* sans-grille à destination des biologistes (accélération *PyKeOps* ?) ;
- implémentation numérique de CROC/AMG avec une version de (*Sliding*) *Frank-Wolfe* ;
- reconstruction de Diracs dynamiques à partir d'acquisitions vidéos réelles (*tracking*).

Publications pour approfondir :

- *'Off-the-grid curve reconstruction through divergence regularisation: an extreme point result'*. Bastien Laville, Laure Blanc-Féraud, Gilles Aubert. Prépublication avril 2022.
- *'Off-the-grid covariance-based super-resolution microscopy'*. Bastien Laville, Laure Blanc-Féraud, Gilles Aubert. IEEE ICASSP 2022. DOI : 10.1109/ICASSP43922.2022.9746845

Disponibles également sur : <https://www-sop.inria.fr/members/Bastien.Laville/> ou <https://cv.archives-ouvertes.fr/bastien-laville>.



Bibliographie I

-  Yohann de Castro and Fabrice Gamboa. *Exact reconstruction using Beurling minimal extrapolation*. Journal of Mathematical Analysis and Applications, Elsevier BV, 2012, 395, 336-354
-  Quentin Denoyelle, Vincent Duval, Gabriel Peyré, Emmanuel Soubies. *The Sliding Frank-Wolfe Algorithm and its Application to Super-Resolution Microscopy*. Inverse Problems, IOP Publishing, In press.
-  Lenaïc Chizat, Francis Bach. *On the Global Convergence of Gradient Descent for Over-parameterized Models using Optimal Transport*. Advances in Neural Information Processing Systems (NIPS), Dec 2018, Montréal, Canada.
-  Tamir Bendory, Shai Dekel, Arie Feuer, Robust recovery of stream of pulses using convex optimization, Journal of Mathematical Analysis and Applications, Volume 442, Issue 2, 2016.

Bibliographie II

-  A Fast Iterative Shrinkage-Thresholding Algorithm for Linear Inverse Problems, Amir Beck and Marc Teboulle, SIAM J. IMAGING SCIENCES, 2009.
-  Marguerite Frank et Philip Wolfe, « An algorithm for quadratic programming », Naval Research Logistics Quarterly, vol. 3, 1956.
-  J J. B. Lasserre, « Moments, positive polynomials and their applications », Imperial College Press Optimization Series, vol. 1, pp. xxii+361, 2010
-  K. Bredies and H. K. Pikkarainen, « Inverse problems in spaces of measures », ESAIM Control Optim. Calc. Var., vol. 19, no. 1, pp. 190-218, 2013.
-  Lenaïc Chizat, Francis Bach. On the Global Convergence of Gradient Descent for Over-parameterized Models using Optimal Transport. Advances in Neural Information Processing Systems (NIPS), Dec 2018, Montréal, Canada.

Bibliographie III

-  Lenaïc Chizat. Sparse Optimization on Measures with Over-parameterized Gradient Descent. 2020
-  Candès, Emmanuel & Fernandez-Granda, Carlos. (2014). Towards a Mathematical Theory of Super-Resolution. Communications on Pure and Applied Mathematics. 67. 10.1002/cpa.21455.
-  Vincent Duval, Gabriel Peyré. Exact Support Recovery for Sparse Spikes Deconvolution. Foundations of Computational Mathematics, Springer Verlag, 2015, 15 (5), pp.1315-1355.
-  Thomas Dertinger, Ryan Colyer, Robert Vogel, Jörg Enderlein, and Shimon Weiss, "Achieving increased resolution and more pixels with Superresolution Optical Fluctuation Imaging (SOFI)," Opt. Express 18, 18875-18885 (2010)
-  Culley S, Tosheva KL, Matos Pereira P, Henriques R. SRRF: Universal live-cell super-resolution microscopy. Int J Biochem Cell Biol. 2018;101:74-79. doi:10.1016/j.biocel.2018.05.014

Bibliographie IV



Oren Solomon, Maor Mutzafi, Mordechai Segev, and Yonina C. Eldar, "Sparsity-based super-resolution microscopy from correlation information," Opt. Express 26, 18238-18269 (2018)

Sliding Frank-Wolfe

Algorithm 1: *Sliding Frank-Wolfe.*

Entrées: Acquisition $y \in \mathcal{H}$, nombre d'itérations K , $\lambda > 0$

1 Initialisation : $m^{[0]} = 0$ $N^{[k]} = 0$

2 **for** *Récurrence pour l'étape* k , $0 \leq k \leq K$ **do**

3 Pour $m^{[k]} = \sum_{i=1}^{N^{[k]}} a_i^{[k]} \delta_{x_i^{[k]}}$ telle que $a_i^{[k]} \in \mathbb{R}$, $x_i^{[k]} \in \mathcal{X}$, trouver $x_*^{[k]} \in \mathcal{X}$ tel que :

$$x_*^{[k]} \in \operatorname{argmax}_{x \in \mathcal{X}} \left| \eta^{[k]}(x) \right| \quad \text{où} \quad \eta^{[k]}(x) \stackrel{\text{def.}}{=} \frac{1}{\lambda} \Phi^*(\Phi m^{[k]} - y),$$

if $\left| \eta^{[k]}(x_*^{[k]}) \right| < 1$ **then**

4 $m^{[k]}$ est la solution du BLASSO. Stop.

else

6 Calculer $m^{[k+1/2]} = \sum_{i=1}^{N^{[k]}} a_i^{[k+1/2]} \delta_{x_i^{[k+1/2]}} + a_{N^{[k]}+1}^{[k+1/2]} \delta_{x_*^{[k+1/2]}}$ telle que :

$$a_i^{[k+1/2]} \in \operatorname{argmin}_{a \in \mathbb{R}^{N^{[k]}+1}} \frac{1}{2} \|y - \Phi_{x^{[k+1/2]}}(a)\|_{\mathcal{H}}^2 + \lambda \|a\|_1$$

pour $x^{[k+1/2]} \stackrel{\text{def.}}{=} (x_1^{[k]}, \dots, x_{N^{[k]}}^{[k]}, x_*^{[k]})$.

7 Calculer $m^{[k+1]} = \sum_{i=1}^{N^{[k+1]}} a_i^{[k+1]} \delta_{x_i^{[k+1]}}$ telle que :

$$(a_i^{[k+1]}, x_i^{[k+1]}) \in \operatorname{argmax}_{(a,x) \in R} \frac{1}{2} \|y - \Phi_{x^{[k+1/2]}}(a)\|_{\mathcal{H}}^2 + \lambda \|a\|_1$$

8 **end**

9 **end**

Sortie: Mesure discrète $m^{[k]}$ pour k l'itération d'arrêt.