



Déconvolution Dynamique par Descente de Gradient Préconditionnée

Joseph GABET Maxime FERREIRA DA COSTA Charles SOUSSEN

Laboratoire des Signaux et Systèmes, CentraleSupélec, Université Paris–Saclay, CNRS, Gif-sur-Yvette, France

Résumé – Nous considérons le problème de la déconvolution d’impulsions de Dirac à partir d’observations dans le domaine de Fourier lorsque leurs positions et amplitudes évoluent dynamiquement au cours du temps. Pour suivre efficacement cette évolution, l’originalité de notre approche réside dans l’introduction d’un algorithme de descente de gradient avec préconditionnement diagonal et momentum, une méthode de premier ordre exploitant la structure du problème pour accélérer la convergence. Notre contribution principale est de montrer que cette méthode peut être appliquée de manière efficace dans un cadre dynamique en réutilisant les estimations précédentes à chaque pas de temps.

Abstract – We consider the problem of deconvolving a series of spike trains in the Fourier domain when their positions and amplitudes evolve dynamically over time. To accurately track this evolution, the originality of our approach lies in the introduction of a gradient descent algorithm with diagonal preconditioning and momentum, a first-order method that leverages the structure of the problem to accelerate convergence. Our main contribution is to demonstrate that this method can be effectively applied in a dynamic setting by reusing previous estimates at each time step.

1 Introduction

1.1 Contributions, état de l’art et organisation

La reconstruction de signaux composés d’impulsions discrètes à partir d’observations dans le domaine de Fourier constitue un problème fondamental en traitement du signal et en imagerie. Les approches classiques incluent notamment des méthodes convexes reposant sur une discrétisation spatiale fine (par exemple, minimisation de norme en variation totale sur grille), et des méthodes spectrales paramétriques comme MUSIC ou ESPRIT, qui ne reposent pas explicitement sur une grille mais exploitent la structure particulière du problème. Une alternative moderne repose sur la formulation continue du problème, sans discrétisation préalable, via l’optimisation de fonctionnelles convexes définies sur des mesures — c’est notamment l’approche du Beurling LASSO [1]. Toutefois, la plupart de ces méthodes ont été développées pour des signaux statiques, c’est-à-dire temporellement invariants.

Dans de nombreux scénarios applicatifs pratiques tels que, les radars OFDM pour les communications sans fil [2], le suivi de cibles [3] ou encore l’imagerie astronomique [4], les Diracs évoluent temporellement : leurs localisations et amplitudes ne sont plus fixes. La déconvolution dynamique vise alors à suivre ces évolutions tout en garantissant robustesse face au bruit et efficacité computationnelle, de manière à permettre un traitement en temps réel ou quasi temps réel. Quelques approches existent dans un contexte dynamique, telles que des méthodes récursives basées sur des filtres de Kalman ou des extensions des méthodes spectrales classiques par fenêtre glissante, mais elles restent soit peu adaptées aux signaux parcimonieux, soit sensibles lorsque les Diracs sont proches ou se confondent ponctuellement.

Notre principale contribution est d’introduire une méthode paramétrique et sans grille, reposant sur une approche de premier ordre combinant préconditionnement diagonal adaptatif

et momentum. Malgré le caractère non-convexe du problème d’optimisation traité, notre approche suit efficacement l’évolution temporelle des Diracs, tout en gardant un coût par itération très faible. Cette stratégie simple, rapide et robuste convient particulièrement au cadre dynamique étudié ici.

1.2 Notations et définitions

Les vecteurs sont notés en gras minuscules $\mathbf{a}$, et les matrices en gras majuscules $\mathbf{A}$. L’espace des matrices de taille $u \times v$ à coefficients dans un corps $\mathbb{K}$ est noté $\mathcal{M}_{u,v}(\mathbb{K})$. La transposée et la transposée hermitienne de $\mathbf{A}$ sont notées $\mathbf{A}^\top$ et $\mathbf{A}^H$. On note $\mathbb{1}_r$ et $\mathbf{0}_r$ les vecteurs de $\mathbb{C}^r$ tout en un ou tout en zéro. Le produit scalaire s’écrit $\langle \mathbf{a}, \mathbf{b} \rangle$, et $\mathbf{A} \otimes \mathbf{B}$ désigne le produit de Kronecker. Pour $a, b \in \mathbb{N}$, $\llbracket a; b \rrbracket$ est l’ensemble des entiers entre a et b , et $\llbracket a \rrbracket = \llbracket 1; a \rrbracket$.

2 Formulation du problème

2.1 Formulation du problème statique

On considère un signal composé de r impulsions de Dirac, chacune étant paramétrée par une amplitude complexe $a_\ell^* \in \mathbb{C}$ et un vecteur de localisation $\boldsymbol{\tau}_\ell^* \in \mathbb{R}^d$, pour $1 \leq \ell \leq r$. Soit $\mathbf{a}^* = [a_1^*, \dots, a_r^*]^\top \in \mathbb{C}^r$ le vecteur de toutes les amplitudes, et $\boldsymbol{\tau}^* = [\tau_{1;1}^*, \tau_{2;1}^*, \dots, \tau_{r;1}^*, \dots, \tau_{r;d}^*]^\top \in \mathbb{R}^{dr}$ le vecteur de localisation concaténé, où $\tau_{\ell;i}^*$ est la i -ème composante du vecteur de localisation de la ℓ -ème impulsion.

Pour tout couple $(\mathbf{a}, \boldsymbol{\tau})$, la mesure de Radon complexe parcimonieuse est définie par

$$\mu(\mathbf{a}, \boldsymbol{\tau}) = \sum_{j=1}^r a_j \delta_{\boldsymbol{\tau}_j}, \quad (1)$$

où $\delta_{\boldsymbol{\tau}_j}$ désigne la distribution de Dirac centrée en $\boldsymbol{\tau}_j \in \mathbb{R}^d$.

Après convolution avec une fonction d’étalement du point (PSF) connue $g \in L_1(\mathbb{R}^d)$, le signal continu $s(\mathbf{x})$, défini sur

Ce travail a été partiellement financé par l’ANR (ANR-24-CE48-3094), l’AID (AID-2023639) et la chaire Orange “6G durable” de CentraleSupélec.

$\mathbb{R}^d$, s'exprime par

$$s(\mathbf{x}) = \left(g \star \mu(\mathbf{a}^*, \boldsymbol{\tau}^*) \right)(\mathbf{x}), \quad (2)$$

où $\star$ désigne l'opérateur de convolution sur $\mathbb{R}^d$.

Nous considérons par ailleurs des mesures $\mathbf{y}$ acquises à partir du signal s observé dans le domaine de Fourier, un cadre très répandu en traitement du signal (astrophysique, IRM, télécommunications). La transformée de Fourier continue $\mathcal{F}(\cdot)$ d'une mesure de Radon est définie par

$$\mathcal{F}(\mu)(\mathbf{f}) = \int_{\mathbb{R}^d} e^{-2i\pi \langle \mathbf{f}, \mathbf{x} \rangle} d\mu(\mathbf{x}), \quad \forall \mathbf{f} \in \mathbb{R}^d. \quad (3)$$

On suppose disposer de N mesures dans le domaine de Fourier (avec N impair, $N = 2n + 1$), prises de manière uniforme sur la bande de fréquences $J_N = \left[-\frac{N}{2T}, \frac{N}{2T}\right]^d$, de sorte que l'ensemble d'échantillonnage $\Omega \subset \mathbb{R}^d$ est défini par $\Omega = \frac{1}{T} \llbracket -n, n \rrbracket^d$.

Soit $\mathbf{G} = \text{diag}([\mathcal{F}(g)(\mathbf{f})]_{\mathbf{f} \in \Omega})$ la matrice diagonale formée des valeurs de $\mathcal{F}(g)$ sur Ω . Le vecteur d'observation discret $\mathbf{y}$ s'écrit alors

$$\mathbf{y} = \mathbf{G} \mathbf{V}_{\boldsymbol{\tau}^*} \mathbf{a}^* + \mathbf{z}, \quad (4)$$

où $\mathbf{V}_{\boldsymbol{\tau}} \in \mathbb{C}^{N^d \times r}$ est la matrice de Vandermonde dont les éléments sont $e^{-2i\pi \langle \mathbf{f}, \boldsymbol{\tau}_j \rangle}$ pour $\mathbf{f} \in \Omega$, et $\mathbf{z}$ est un bruit additif, supposé *arbitraire*.

2.2 Problème dynamique

Dans le problème dynamique, nous supposons que les paramètres $\boldsymbol{\theta}(t) = (\mathbf{a}(t), \boldsymbol{\tau}(t))$ évoluent en fonction d'une variable de temps t (distincte de la variable spatiale $\mathbf{x}$) et que la fonction $\boldsymbol{\theta} : t \mapsto (\mathbf{a}(t), \boldsymbol{\tau}(t)) \in \mathbb{C}^r \times \mathbb{R}^{r \times d}$ est continue.

Nous considérons alors le signal continu dynamique $s(\mathbf{x}, t)$, défini sur $\mathbb{R}^d \times \mathbb{R}^+$, s'exprime par

$$s(\mathbf{x}, t) = \left(g \star \mu(\mathbf{a}^*(t), \boldsymbol{\tau}^*(t)) \right)(\mathbf{x}), \quad (5)$$

et nous observons à chaque pas de temps $t_i \in \mathbb{R}^+$, $i \in [T_{\max}]$ le vecteur discret dans le domaine de Fourier

$$\mathbf{y}(t_i) = \mathbf{G} \mathbf{V}_{\boldsymbol{\tau}^*(t_i)} \mathbf{a}^*(t_i) + \mathbf{z}(t_i). \quad (6)$$

3 Descente de gradient préconditionnée avec momentum

3.1 Algorithme dans le cadre statique

Étant donné le modèle de mesure statique (4), nous introduisons la fonction de coût quadratique

$$\mathcal{L}_{\mathbf{y}}(\mathbf{a}, \boldsymbol{\tau}) = \frac{1}{2} \|\mathbf{G} \mathbf{V}_{\boldsymbol{\tau}} \mathbf{a} - \mathbf{y}\|_2^2. \quad (7)$$

Dans le cas d'un bruit i.i.d. gaussien, l'expression (7) correspond à un facteur près à l'anti log-vraisemblance du modèle. Nous estimons les paramètres du signal $(\hat{\mathbf{a}}, \hat{\boldsymbol{\tau}})$ comme le minimiseur non contraint de (7). Puisque la fonction de coût (7) est non convexe, plusieurs minimiseurs locaux peuvent exister, et l'optimisation par une méthode locale ne garantit pas

Algorithm 1 Descente Préconditionnée avec Momentum

```

1: Entrées :  $\boldsymbol{\theta}_0, \mathbf{y}, K_{\max}, \eta, \nu$ .
2: Initialiser  $v \leftarrow 0$ .
3: Pour  $k \leftarrow 0$  jusqu'à  $K_{\max}$ 
4:   Calculer  $\mathbf{P}_k$  comme en (9).
5:   Calculer  $\nabla \mathcal{L}_{\mathbf{y}}(\boldsymbol{\theta}_k)$ .
6:    $v \leftarrow \nu \cdot v - \eta \mathbf{P}_k \nabla \mathcal{L}_{\mathbf{y}}(\boldsymbol{\theta}_k)$ .
7:    $\boldsymbol{\theta}_{k+1} \leftarrow \boldsymbol{\theta}_k + v$ .
8: Fin Pour
9: Sortie :  $\boldsymbol{\theta}_{K_{\max}}$ .

```

la convergence globale. De plus, la fonction de coût souffre d'ambiguïtés de permutation sur les composantes de $\boldsymbol{\tau}$, ce qui implique l'existence de plusieurs minimiseurs globaux.

Pour les besoins de l'optimisation, nous vectorisons les paramètres d'entrée $(\mathbf{a}, \boldsymbol{\tau})$ dans la variable $\boldsymbol{\theta} = [\mathbf{a}^\top; \boldsymbol{\tau}^\top]^\top \in \mathbb{C}^r \times \mathbb{R}^{rd}$. Nous présentons ci-après l'expression du gradient de la fonction de coût (7) par rapport aux amplitudes et aux positions. Pour ce faire, on introduit $\mathbf{M}_{\mathbf{a}} = \text{diag}([\mathbb{1}_r; (\mathbb{1}_d \otimes \mathbf{a})^\top]^\top) \in \text{Diag}_{(d+1)r}(\mathbb{C})$, et on définit la matrice de dérivation suivant la j -ème dimension $\boldsymbol{\Lambda}_j = -2i\pi \text{diag}(\{[f_u]_j\}_{f_u \in \Omega}) \in \text{Diag}_{N^d}(\mathbb{C})$. De plus, on pose $\mathbf{W}_{\boldsymbol{\tau}} = [\mathbf{V}_{\boldsymbol{\tau}} \mid \boldsymbol{\Lambda}_1 \mathbf{V}_{\boldsymbol{\tau}} \mid \dots \mid \boldsymbol{\Lambda}_d \mathbf{V}_{\boldsymbol{\tau}}] \in \mathcal{M}_{N^d, (d+1)r}(\mathbb{C})$. Ainsi, le gradient de $\mathcal{L}_{\mathbf{y}}$, défini en (7), s'écrit :

$$\nabla \mathcal{L}_{\mathbf{y}}(\boldsymbol{\theta}) = \mathbf{M}_{\mathbf{a}}^\text{H} \mathbf{W}_{\boldsymbol{\tau}}^\text{H} \left(\mathbf{W}_{\boldsymbol{\tau}} \mathbf{M}_{\mathbf{a}} \begin{bmatrix} \mathbf{a} \\ \mathbf{0}_{rd} \end{bmatrix} - \mathbf{W}_{\boldsymbol{\tau}^*} \mathbf{M}_{\mathbf{a}^*} \begin{bmatrix} \mathbf{a}^* \\ \mathbf{0}_{rd} \end{bmatrix} + \mathbf{z} \right). \quad (8)$$

Compte tenu de la nature hétérogène du vecteur $\boldsymbol{\theta}$, qui contient à la fois des positions et des amplitudes, la matrice hessienne associée à la fonction de coût (7) est généralement mal conditionnée. Ce mauvais conditionnement se répercute sur la régularité de la fonction de coût elle-même et sur la stabilité numérique du gradient (8), en particulier lorsque la plage dynamique des amplitudes est importante. Nous nous appuyons donc sur la *préconditionnement* — une méthode quasi-Newton — afin d'adapter la direction de descente au paysage local de la fonction de coût. Ceci est réalisé en multipliant, à l'étape k , le gradient par une matrice $\mathbf{P}_k$ [5], qui dépend de l'estimation courante $\boldsymbol{\theta}_k$. On définit la fonction d'autocorrélation $K(\boldsymbol{\tau}) = \langle \mathbf{G} \mathbf{V}_0; \mathbf{G} \mathbf{V}_{\boldsymbol{\tau}} \rangle$ et on choisit le préconditionneur

$$\mathbf{P}_k = \text{diag} \left(\begin{bmatrix} \mathbb{1}_r \\ [-\nabla^2 K(\mathbf{0})]_{1,1}^{-1} |\mathbf{a}_k|^{-2} \\ \vdots \\ [-\nabla^2 K(\mathbf{0})]_{d,d}^{-1} |\mathbf{a}_k|^{-2} \end{bmatrix} \right). \quad (9)$$

La complexité de calcul de l'Algorithme 1 est déterminée par celle de la multiplication matrice-vecteur dans la quatrième ligne. Nous limitons notre analyse aux matrices de préconditionnement diagonales de sorte que le calcul de la direction de descente préconditionnée entraîne un coût de calcul supplémentaire marginal par rapport à la descente de gradient non préconditionnée. Il a été montré [5] que lorsque l'on initialise la descente de gradient suffisamment proche du minimiseur global alors, sous des conditions raisonnables de séparation entre les impulsions de Dirac [6] et sur l'échelle dynamique du problème, la descente de gradient préconditionnée converge linéairement vers $\boldsymbol{\theta}^*$. Par ailleurs, il a été montré [7] qu'il était

possible d'initialiser dans le bassin d'attraction de la fonction de perte (7) au temps t_0 rendant l'Algorithme 1 effectif en pratique.

Nous proposons d'incorporer une dynamique de momentum [8] — une méthode classique ayant récemment retrouvé un intérêt marqué dans le contexte de l'apprentissage automatique — dans l'Algorithme 1 (MPGD) afin d'accélérer plus encore la convergence. L'idée est d'ajouter un terme qui exploite la direction des mises à jour précédentes. Cela se traduit par la mise en œuvre de deux hyperparamètres : un taux d'apprentissage $\eta > 0$ et un coefficient de momentum $\nu \in [0; 1[$ ce qui permet d'obtenir en pratique le meilleur compromis entre stabilité et vitesse de convergence. Concrètement, la mise à jour complète des paramètres s'exprime par

$$\theta_{k+1} = \theta_k - \eta P_k \nabla \mathcal{L}_y(\theta_k) + \nu(\theta_k - \theta_{k-1}). \quad (10)$$

3.2 Algorithme dans le cadre dynamique

Étant donné que le modèle d'observation dynamique (6) correspond à une succession de problèmes statiques (4), nous proposons de résoudre un problème statique à chaque pas de temps en ne considérant connue que l'estimation du pas de temps précédent. Cette procédure est décrite dans l'Algorithme 2.

Algorithme 2 Déconvolution Dynamique

- 1: **Entrées** : (A_0, τ_0) , $K_{\max}$, $T_{\max}$, η , ν .
 - 2: Initialiser $\theta[0] \leftarrow (A_0, \tau_0)$.
 - 3: **Pour** $i \leftarrow 0$ **jusqu'à** $T_{\max}$
 - 4: On observe $y[i]$
 - 5: $\theta[i+1] \leftarrow \text{MPGD}(\theta[i], y[i], K_{\max}, \eta, \nu)$.
 - 6: **Fin Pour**
 - 7: **Sortie** : $\{\hat{\theta}[i], i \in [T_{\max}]\}$.
-

4 Résultats numériques

Le code est intégralement disponible sur Gitlab ¹.

Sans perte de généralité, on se place dans le cas de signaux monodimensionnels ($d = 1$), quelque soit le scénario (statique ou dynamique). La difficulté du problème de déconvolution est liée au fait que la position des impulsions de Dirac se rapproche dans le temps, dégradant ainsi le conditionnement du problème.

4.1 Comparaison des descentes de gradients

Dans un premier temps, nous allons chercher à démontrer expérimentalement l'avantage du préconditionnement et du momentum par rapport à une simple descente de gradient. Pour ce faire, nous nous plaçons dans un cadre statique afin d'illustrer la supériorité de l'Algorithme 1.

Nous mesurons le taux de contraction en termes de *pire distance relative* de tout paramètre par rapport à la vérité terrain. Cela permet un contrôle homogène de l'estimation des paramètres sur l'ensemble des impulsions et transcende certaines propriétés du problème considéré, telles que le nombre

¹<https://gitlab-student.centralesupelec.fr/joseph.gabet/gretsi-2025/-/tree/main>




FIGURE 1 : Comparaison de la vitesse de convergence des descentes de gradient (moyenne sur 100 réalisations d'une expérience avec des initialisations aléatoires de θ_0 ; sans bruit). Les courbes affichent la moyenne $\pm$ un écart-type.




FIGURE 2 : Comparaison de la largeur du bassin d'attraction des descentes de gradient (sans bruit).

de sources ou la plage dynamique. Mathématiquement nous étudions la contraction de la suite d'itérés

$$\|S(\theta_k - \theta^*)\|_\infty = \max_j \left\{ \frac{|a_{k,j} - a_j^*|}{|a_j^*|}; \sqrt{-K''(0)} |\tau_{k,j} - \tau_j^*| \right\}.$$

La Figure 1 montre que la vitesse de convergence de la descente préconditionnée est linéaire comme exprimé par la théorie [5]. On observe également que le préconditionnement accélère considérablement la convergence. De plus, bien que l'ajout du momentum seul ne semble pas améliorer drastiquement la vitesse de convergence moyenne, apparaissant ainsi comme moins intéressant que le préconditionnement seul, l'ajout d'un faible momentum en complément du préconditionnement semble apporter un avantage substantiel. Pour chaque expérience, les paramètres η et ν ont été fixés indépendamment, à 10^{-1} près de sorte à obtenir la meilleure vitesse de convergence moyenne sans diverger.

Outre la rapidité constatée en Figure 1, la Figure 2 montre que le bassin d'attraction induit par le préconditionnement est significativement plus large que celui obtenu sans préconditionnement. L'ajout d'un momentum semble légèrement réduire la taille du bassin d'attraction, sans que cela paraisse significatif au regard de l'accélération apportée.

4.2 Déconvolution dynamique

Considérons maintenant $r = 3$ impulsions évoluant dynamiquement en amplitudes $a_i^*(t) \in \mathbb{R}^+$ et positions




FIGURE 3 : Erreur moyenne (100 expériences) comparée à la borne de Cramér-Rao — SNR = 40 dB.




FIGURE 4 : Comparaison de l'erreur de la descente préconditionnée avec et sans momentum (200 expériences, SNR = 40 dB). Les courbes représentent la médiane et l'intervalle interquartile.

$\tau_i^*(t) \in [-10; 10]$, tel que les amplitudes sont normalisées et $\frac{\max_i a_i^*(t)}{\min_i a_i^*(t)} \geq \frac{3}{2}$. Les données ont été simulées de telle sorte que positions des impulsions sont initialement éloignées, puis se croisent à partir du pas de temps 75 avant de se séparer de nouveau à partir du pas de temps 120.

Les amplitudes optimales pour la fonction de perte (7) associées à une estimation $\hat{\tau}$ étant obtenues par moindres carrés, nous ne considérons que la distance entre $\hat{\tau}$ et la vérité-terrain τ^* . Pour lever l'ambiguïté due à la permutation des positions, nous utilisons la distance quadratique de pairage $md_2(\hat{\tau}, \tau^*)$, définie comme la distance euclidienne minimale entre $\hat{\tau}$ et toute permutation de τ^* .

La Figure 4 compare les performances de l'algorithme 1 avec un grand nombre d'itérations (200) à la borne théorique de Cramér-Rao. On observe que l'algorithme suit précisément cette borne lorsque les sources sont suffisamment éloignées. Quand les sources se rapprochent, la qualité de la solution diminue tout en restant relativement proche de la borne. Dès que les sources s'éloignent à nouveau, l'algorithme retrouve des performances proche de la limite théorique. Cette expérience valide ainsi empiriquement la précision de l'algorithme dans un régime de convergence complète.

Dans un scénario embarqué temps-réel, le temps de calcul entre chaque pas est souvent limité, imposant un faible nombre d'itérations de gradient. Afin d'illustrer l'importance de la vitesse de convergence, la Figure 4 compare les performances médianes de la descente préconditionnée avec et sans momentum, en fixant un budget de 40 pas de gradient. Ce nombre limité ne permet pas d'atteindre la borne de Cramér-Rao. Plu-

sieurs expériences avec une même trajectoire mais avec un bruit aléatoire correspondant à un SNR de 40 dB montrent que l'ajout du momentum accélère la convergence, diminuant ainsi l'erreur médiane comparativement au préconditionnement seul.

De plus, une convergence trop lente augmente le risque de quitter le bassin d'attraction du minimiseur global entre deux pas de temps, pouvant mener à une divergence de l'algorithme. Pour quantifier ce risque, nous calculons le taux de décrochage en réalisant, au temps $T_{\max}$, une descente de gradient sur 200 pas et en vérifiant l'obtention d'une erreur autour de 10^{-1} (le bruit empêchant une convergence exacte vers θ^*). Le Tableau 1 montre que, dans la configuration de la Figure 4, le taux de décrochage sans momentum est significativement supérieur à celui avec momentum.

Méthode	% décrochage
PGD sans momentum	8.0%
PGD avec momentum	1.5%

TABLE 1 : Impact du momentum sur le taux de décrochage

5 Conclusion

Dans cette étude, nous avons présenté une méthode du premier ordre pour résoudre un problème de déconvolution dynamique d'impulsions de Dirac dans le domaine de Fourier, en dimension finie quelconque. Nous avons montré expérimentalement la robustesse de cette approche en présence de bruit, tout en maintenant un budget de calcul réduit par pas de temps. De plus, l'algorithme proposé reste consistant lors des situations difficiles où les impulsions se confondent à certains instants.

Une possible extension de ce travail serait d'étendre les garanties théoriques de convergence de la descente de gradient préconditionnée à l'application d'un terme de momentum. Une analyse théorique de l'algorithme dans le cadre dynamique dans de sources se croisent est également d'intérêt pour comprendre les performances de la méthode numérique proposée.

Références

- [1] Q. Denoyelle, V. Duval, and G. Peyré. Support recovery for sparse spikes deconvolution from short-time Fourier transform measurements. *Inverse Problems*, 33(5):055012, 2017.
- [2] C. Berger, Z. Zhou, J. Huang, S. Zhou, and P. Willett. Sparse channel estimation for OFDM: Overcomplete dictionaries and superresolution methods. *IEEE Transactions on Signal Processing*, 61(23):5956–5968, 2013.
- [3] R. Heckel and H. Bolcskei. Compressive sensing radar imaging of moving targets. *2010 IEEE Radar Conference*, pages 852–857, 2010.
- [4] F. Mertens, A. Repetti, J. Birdi, A. Dabbech, and Y. Wiaux. Radio interferometric imaging with joint sparsity constraints. *Monthly Notices of the Royal Astronomical Society*, 500(1):1037–1055, 2020.
- [5] J. Gabet and M. Ferreira Da Costa. Preconditioned gradient descent for sketched mixture learning. In *Proceedings of the IEEE International Symposium on Information Theory (ISIT)*, 2024.
- [6] M. Hockmann. Analysis of the sparse super resolution limit using the Cramér-Rao lower bound. *IEEE Transactions on Information Theory*, 71(1):390–395, 2025.
- [7] J. Gabet, M. Kalra, M. Ferreira Da Costa, and K. Lee. Global Convergence of ESPRIT with Preconditioned First-Order Methods for Spike Deconvolution. preprint, February 2025.
- [8] B. T. Polyak. Some methods of speeding up the convergence of iteration methods. *USSR Computational Mathematics and Mathematical Physics*, 4(5):1–17, 1964.