

# Une formulation bayésienne du codage antiparcimonieux

Clément ELVIRA<sup>1</sup>, Pierre CHAINAIS<sup>1</sup> et Nicolas DOBIGEON<sup>2</sup>

<sup>1</sup>Université de Lille, CNRS, Centrale Lille, UMR 9189 - CRISTAL - Centre de Recherche en Informatique  
Signal et Automatique de Lille, F-59000 Lille, France

<sup>2</sup>Université of Toulouse, IRIT/INP-ENSEEIH, CNRS, 2 rue Charles Camichel,  
BP 7122, 31071 Toulouse cedex 7, France

{clement.elvira, pierre.chainais}@centralelille.fr, nicolas.dobigeon@enseeiht.fr

**Résumé** – Dans un but de robustesse, un codage antiparcimonieux répartit uniformément l’information d’un signal sur toutes les composantes de sa représentation. La recherche d’un tel codage s’exprime naturellement sous la forme d’un problème variationnel impliquant une régularisation de type  $\ell_\infty$ . Dans cet article une formulation bayésienne du problème est proposée, impliquant une nouvelle loi de probabilité, la *loi démocratique*, qui pénalise les fortes amplitudes. Cette distribution est choisie comme loi *a priori* sur les coefficients de représentation, couplée avec une vraisemblance gaussienne. Les estimateurs bayésiens des coefficients de représentation peuvent être approchés à l’aide d’un échantillonneur de Gibbs. Cette méthode passe cependant difficilement à l’échelle et un algorithme de Monte Carlo proximal a été proposé. On discute une nouvelle façon de choisir et régler la loi *a priori* sur les paramètres de nuisance. Deux simulations numériques permettent de valider le réglage des hyperparamètres et la recherche du paramètre de régularisation.

**Abstract** – For sake of robustness, anti-sparse coding aims at spreading the information uniformly over representation coefficients and can be naturally expressed by an  $\ell_\infty$ -norm regularization. This article discusses a Bayesian formulation of the anti-sparse coding problem, relying on a new probability distribution called *democratic distribution*. Once elected as a prior distribution in a linear Gaussian inverse problem, inference can be conducted using a Gibbs sampling scheme. This paper discusses an alternative choice of prior for the nuisance parameters and proposes a comparison between two scalable inference schemes based on recent developments in Monte Carlo methods. These findings are illustrated by simulations on synthetic data, and compared with the recent deterministic variational FITRA algorithm.

## 1 Introduction

La régularisation de problèmes inverses mal posés par des contraintes de parcimonie a donné lieu à de nombreux travaux dans la littérature, notamment motivés par le paradigme de l’échantillonnage compressé. À l’inverse, répartir uniformément l’information d’un signal sur toutes les composantes d’une représentation est également recherché dans certaines situations telles que la conception de convertisseurs analogique/numérique [1] ou la recherche approchée de plus proches voisins [2]. Ces représentations peuvent s’obtenir en minimisant l’amplitude maximale des coefficients sous contrainte d’une erreur de reconstruction quadratique. Ces représentations antiparcimonieuses, dites de Kashin [3] ou encore *démocratiques* [4], correspondent à la décomposition d’un signal sur une famille donnée ayant l’amplitude la plus faible. Ici, c’est l’énergie des coefficients que l’on souhaite répartir et non pas une distribution de probabilité comme pour les méthodes à maximum d’entropie. Une autre manière d’obtenir la représentation antiparcimonieuse d’un signal consiste à résoudre un problème variationnel [5] où l’amplitude des coefficients est pénalisée via la norme  $\ell_\infty$

$$\min_{\mathbf{x} \in \mathbb{R}^N} \frac{1}{2\sigma^2} \|\mathbf{y} - \mathbf{H}\mathbf{x}\|_2^2 + \lambda \|\mathbf{x}\|_\infty. \quad (1)$$

Ici  $\mathbf{H}$  est une matrice de codage de taille  $M \times N$  et  $\sigma^2$  est la

variance du résidu résultant de l’approximation. En outre, on note  $J(\mathbf{x}, \beta)$  la fonction de coût implicitement définie par (1), i.e.,

$$J(\mathbf{x}, \beta) \triangleq \|\mathbf{y} - \mathbf{H}\mathbf{x}\|_2^2 + \beta \|\mathbf{x}\|_\infty \text{ avec } \beta \triangleq 2\sigma^2\lambda.$$

Ce problème a récemment été considéré pour des applications en réduction de facteur de crête [6]. Nous proposons une formulation bayésienne du problème de reconstruction antiparcimonieuse sous jacent à (1), ce qui n’a à notre connaissance jamais été étudié dans la littérature. Les paramètres de nuisance  $\lambda$  et  $\sigma^2$  sont intégrés au modèle via leurs lois *a priori* dans l’espoir de régler le problème du choix des paramètres de régularisation. La formulation probabiliste permet également la conception et l’approximation de nouveaux estimateurs. Cette formulation repose sur l’utilisation de la *loi démocratique* introduite dans [7]. L’échantillonneur de Gibbs étant peu efficace en grande dimension pour l’inférence des paramètres du modèle, la méthode alternative P-MYULA [8] utilisant des opérateurs proximaux est mise en œuvre. Les échantillons générés sont utilisés pour approximer deux estimateurs Bayésiens.

Cet article est organisé comme suit. La *loi démocratique* est introduite dans la partie 2. Une formulation bayésienne du problème de codage antiparcimonieux est proposée dans la partie 3. Cette partie décrit également deux solutions algorithmiques permettant de générer des échantillons asymptotiquement

distribués suivant la loi *a posteriori* des paramètres. Les performances de ces méthodes sont comparées dans la partie 4. La partie 5 conclut l'article.

## 2 La loi démocratique

On s'appuie sur la pénalité en norme  $\ell_\infty$  du problème variationnel (1) pour définir une nouvelle loi de probabilité appelée *loi démocratique*. La densité de la loi démocratique  $\mathcal{D}_N(\lambda)$  est donnée pour tout vecteur  $\mathbf{x}$  de  $\mathbb{R}^N$  par

$$f(\mathbf{x}|\lambda) = \frac{\lambda^N}{2^N N!} \exp(-\lambda \|\mathbf{x}\|_\infty). \quad (2)$$

La Fig. 1 représente la fonction densité de probabilité associée à la loi  $\mathcal{D}_2(3)$ .




FIGURE 1 – Densité de la loi démocratique  $\mathcal{D}_2(3)$ .

### 2.1 Loïs conditionnelles

La densité (2) n'est pas pratique à manipuler, principalement en raison de la norme  $\ell_\infty$ . On introduit les cônes  $\mathcal{C}_n$  de  $\mathbb{R}^N$

$$\mathcal{C}_n \triangleq \{\mathbf{x} = [x_1, \dots, x_N]^T \in \mathbb{R}^N : \forall j \neq n, |x_j| < |x_n|\}. \quad (3)$$

induits par les symétries de la norme. Pour tout  $\mathbf{x} \in \mathcal{C}_n$ , on a  $\|\mathbf{x}\|_\infty = |x_n|$ . Les cônes  $(\mathcal{C}_n)$  forment une partition<sup>1</sup> de  $\mathbb{R}^N$ , et l'on a directement par symétrie

$$P[\mathbf{x} \in \mathcal{C}_n] = \frac{1}{N}, \quad \forall n \in \{1, \dots, N\}. \quad (4)$$

Soit  $\mathbf{x}_{\setminus n}$  le vecteur  $\mathbf{x}$  privé de sa  $n$ -ième composante et  $\mathcal{I}_n \triangleq (-\|\mathbf{x}_{\setminus n}\|_\infty, \|\mathbf{x}_{\setminus n}\|_\infty)$ . Notons que  $\mathbf{x} \in \mathcal{C}_n \Rightarrow x_n \in \mathcal{I}_n$ . En conditionnant aux cônes, on obtient les lois conditionnelles explicites des composantes dominantes et dominées

$$x_n | \mathbf{x}_{\setminus n}, \mathbf{x} \in \mathcal{C}_n \sim \frac{\lambda}{2} e^{-\lambda(|x_n| - \|\mathbf{x}_{\setminus n}\|_\infty)} \mathbf{1}_{\mathbb{R} \setminus \mathcal{I}_n}(x_n) \quad (5)$$

$$\mathbf{x}_{\setminus n} | x_n, \mathbf{x} \in \mathcal{C}_n \sim \prod_{l \neq n} \mathcal{U}(\mathcal{I}_l), \quad (6)$$

En combinant les équations (4), (5) et (6), et en marginalisant sur les cônes, on obtient la loi conditionnelle

$$P(x_n | \mathbf{x}_{\setminus n}) = (1 - c_n) \frac{1}{2 \|\mathbf{x}_{\setminus n}\|_\infty} \mathbf{1}_{\mathcal{I}_n}(x_n) + c_n \frac{\lambda}{2} e^{-\lambda(|x_n| - \|\mathbf{x}_{\setminus n}\|_\infty)} \mathbf{1}_{\mathbb{R} \setminus \mathcal{I}_n}(x_n) \quad (7)$$

1. Les frontières, qui sont des droites de mesure nulle, doivent être exclues.

$$\text{où } c_n \triangleq P[\mathbf{x} \in \mathcal{C}_n | \mathbf{x}_{\setminus n}] = \frac{1}{1 + \lambda \|\mathbf{x}_{\setminus n}\|_\infty}. \quad (8)$$

La loi conditionnelle est donc un mélange à deux composantes définies sur des intervalles disjoints. L'échantillonnage de la loi *démocratique* exploitant ces propriétés est discutée dans [7].

### 2.2 Opérateur proximal de la neg-log densité

La densité de la loi démocratique peut se réécrire  $f(\mathbf{x}) \propto \exp(-g(\mathbf{x}))$  avec  $g(\mathbf{x}) = \lambda \|\mathbf{x}\|_\infty$ . L'opérateur proximal de  $g$  de paramètre  $\delta$ , est donné par

$$\text{prox}_\delta^g(\mathbf{x}) = \underset{\mathbf{u} \in \mathbb{R}^N}{\text{argmin}} \lambda \|\mathbf{u}\|_\infty + \frac{1}{2\delta} \|\mathbf{x} - \mathbf{u}\|_2^2. \quad (9)$$

Le problème de minimisation (9) n'a pas de solution explicite. On peut toutefois approcher des solutions pour un faible coût numérique en s'appuyant sur les propriétés de l'opérateur proximal et sur la dualité des normes  $\ell_1$  et  $\ell_\infty$  [7]

$$\text{prox}_{\lambda \|\cdot\|_\infty}(\mathbf{x}) = \mathbf{x} - \lambda \Pi_{\{\mathbf{u}, \|\mathbf{u}\|_1 / \lambda \leq 1\}}(\mathbf{x}), \quad (10)$$

où  $\Pi$  est le projecteur sur la boule  $\ell_1$ . Cet opérateur proximal servira dans la partie 3 à échantillonner la loi *a posteriori* résultant de la formulation bayésienne du codage antiparcimonieux.

## 3 Codage anti-parcimonieux bayésien

Cette partie décrit la formulation bayésienne du problème de codage antiparcimonieux associé à l'équation (1).

### 3.1 Modèle bayésien hiérarchique

Soit  $\mathbf{y}$  un vecteur d'observation de  $\mathbb{R}^M$ , et  $\mathbf{H}$  une matrice de codage de taille  $M \times N$  connue. On souhaite reconstruire ce vecteur d'observation à travers le modèle linéaire  $\mathbf{y} = \mathbf{H}\mathbf{x} + \mathbf{e}$  où  $\mathbf{e} = [e_1 \dots e_N]^T$  est le résidu, supposé gaussien centré et de matrice de covariance  $\sigma^2 \mathbf{I}_M$ . Ce choix de modèle de résidu conduit à la fonction de vraisemblance

$$f(\mathbf{y} | \mathbf{x}, \sigma^2) = \left( \frac{1}{2\pi\sigma^2} \right)^{\frac{M}{2}} \exp \left[ -\frac{1}{2\sigma^2} \|\mathbf{y} - \mathbf{H}\mathbf{x}\|_2^2 \right]. \quad (11)$$

On définit maintenant les lois *a priori* pour les paramètres inconnus liés au modèle d'observation.

**Vecteur de représentation.** On choisit la loi démocratique introduite dans la partie 2 comme loi *a priori* sur le vecteur de représentation  $\mathbf{x}$  afin de favoriser l'antiparcimonie, *i.e.*, l'utilisation la plus uniforme possible de toutes les composantes

$$\mathbf{x} | \lambda \sim \mathcal{D}_N(\lambda). \quad (12)$$

Notons que c'est le produit  $\beta = 2\sigma^2\lambda$  qui contrôle effectivement l'estimateur du maximum *a posteriori* (MAP) de  $\mathbf{x}$ , ou, de manière équivalente, l'estimateur associé au problème (1). Le choix de la valeur du paramètre  $\lambda$  est discuté au paragraphe 3.2.3.

**Hyperparamètre.** Une loi conjuguée inverse Gamma est choisie comme loi *a priori* pour l'hyperparamètre  $\beta$

$$f(\beta) \propto \left( \frac{1}{\beta} \right)^{a_\beta+1} \exp \left( -\frac{b_\beta}{\beta} \right). \quad (13)$$

Le choix des hyperparamètres  $a_\beta$  et  $b_\beta$  est détaillé à la partie 4.

**Loi jointe *a posteriori*.** Le modèle hiérarchique défini précédemment conduit à la loi jointe *a posteriori* du couple  $(\mathbf{x}, \beta)$  plutôt que  $(\mathbf{x}, \sigma^2)$

$$f(\mathbf{x}, \beta | \mathbf{y}, \lambda) \propto \mu^N \exp\left(-\frac{\lambda}{\beta} \|\mathbf{y} - \mathbf{H}\mathbf{x}\|_2^2 - \lambda \|\mathbf{x}\|_\infty\right) \times \left(\frac{1}{\beta}\right)^{a_\beta + \frac{M}{2} + 1} \exp\left(-\frac{b_\beta}{\beta}\right). \quad (14)$$

On souligne le fait que, pour une valeur de  $\beta$  fixée, l'estimateur MAP du vecteur de représentation  $\mathbf{x}$  associé à (14) est exactement la solution du problème défini en (1). Dans un paradigme non supervisé, ce paramètre dit de nuisance est estimé conjointement au vecteur de reconstruction. La prochaine partie présente un échantillonneur de Gibbs permettant de générer des échantillons  $\{\mathbf{x}^{(t)}, \beta^{(t)}\}$  asymptotiquement distribués suivant (14). Ces échantillons sont utilisés pour approcher deux estimateurs bayésiens, à savoir l'estimateur qui minimise l'erreur quadratique moyenne (MMSE)  $\hat{\mathbf{x}}_{\text{MMSE}} = \mathbb{E}[\mathbf{x}|\mathbf{y}]$  et l'estimateur MAP marginal  $\hat{\mathbf{x}}_{\text{MAPm}} = \underset{\mathbf{x}}{\operatorname{argmax}} f(\mathbf{x}|\mathbf{y})$ .

## 3.2 Échantillonneur de Gibbs

### 3.2.1 Vecteur de reconstruction

La loi *a posteriori* de chaque composante  $x_n$  est disponible [7], mais un échantillonneur s'appuyant sur ce résultat aboutit à un mélange peu efficace de la chaîne et passe difficilement à l'échelle. On s'appuie sur P-MYULA [8], une version améliorée de P-MALA [9] pour simuler efficacement des échantillons suivant une distribution multidimensionnelle en s'appuyant sur les méthodes proximales pour l'optimisation convexe. P-MYULA exploite le fait que la fonction d'attache aux données liée à la vraisemblance est différentiable pour proposer des mouvements plus efficaces par rapport à P-MALA.

Notons  $h$  l'opposé du logarithme de la loi *a posteriori* de  $\mathbf{x}$ ,  $h(\mathbf{x}) \triangleq J(\mathbf{x}, 2\lambda\sigma^2)/(2\sigma^2)$ . La fonction  $h$  est la somme d'une fonction différentiable  $h_d$  et d'une fonction convexe  $h_c$ . P-MYULA consiste à échantillonner suivant la distribution régularisée  $\exp(-h^\nu)$ , où  $h^\nu$  s'obtient en remplaçant la partie non différentiable  $h_c$  par son enveloppe de Moreau-Yoshida [10]. On effectue d'abord un pas de type descente de gradient

$$\bar{\mathbf{x}}^{(t-1/2)} = \left(1 - \frac{\gamma}{\nu}\right) \mathbf{x}^{(t-1)} - \gamma \nabla f(\mathbf{x}^{(t-1)}) + \frac{\gamma}{\nu} \operatorname{prox}_{h_c}^\nu \mathbf{x}^{(t-1)}$$

puis un pas de marche aléatoire de loi

$$\mathbf{x}^* | \mathbf{x}^{(t-1)} \sim \mathcal{N}\left(\bar{\mathbf{x}}^{(t-1/2)}, 2\gamma\right) \quad (15)$$

En choisissant  $\nu = L_{h_d}^{-1}$ , où  $L_{h_d}$  est la constante de Lipschitz de la partie différentiable  $h_d$  de  $h$ , et  $\gamma = \nu/4$ , l'erreur relative entre la distribution cible et la posterior est estimée à 1% dans [8]. Cette erreur peut être corrigée par une étape de Metropolis-Hastings, mais nous choisissons de ne pas le faire.

### 3.2.2 Paramètres de nuisance

Par conjugaison, la loi *a posteriori* du paramètre de nuisance est donnée par

$$\beta | \mathbf{y}, \mathbf{x} \sim \mathcal{IG}\left(a_\beta + \frac{M}{2}, b_\beta + \lambda \|\mathbf{y} - \mathbf{H}\mathbf{x}\|_2^2\right). \quad (16)$$

### 3.2.3 Réglage des hyper-paramètres

Les paramètres à régler sont  $\lambda$ ,  $a_\beta$  et  $b_\beta$ . On rappelle que les paramètres  $\nu$  et  $\gamma$  de MYULA sont réglés par la géométrie du problème. Des lois *a priori* vagues ont précédemment été proposées pour les paramètres de nuisance dans [7]. Cependant, dans le cas de la recherche d'une représentation antiparcomnieuse qui répartit uniformément l'énergie sur toutes les composantes, il est légitime de chercher  $|x_n| \simeq \|\mathbf{y}\|_2 / \sqrt{N}$ . Or, on peut calculer

$$\mathbb{E}[|x_n| | \mathbf{x} \sim \mathcal{D}_N(\lambda)] = \frac{N+1}{2\lambda}. \quad (17)$$

Une équipartition de l'énergie étant visée pour une représentation démocratique, on espère  $|x_n| \simeq \|\mathbf{y}\|_2 / \sqrt{N}$ . Un choix pertinent serait donc de choisir *a priori*  $\lambda \propto (N+1)\sqrt{N}/(2\|\mathbf{y}\|_2)$ . Notons que cette compréhension du paramètre a été rendue possible grâce à l'interprétation bayésienne du problème.

## 4 Résultats expérimentaux

Cette partie présente les résultats de deux expériences où la paramétrisation est différente en dimensions  $M = 30$  et  $N = 50$ . Les matrices d'encodage sont générées en sous échantillonnant les lignes d'une matrice de transformée en cosinus discrets (DCT), et les observations  $\mathbf{y}$  de  $\mathbb{R}^M$  sont des tirages d'une loi normale [3]. On cherche un vecteur de représentation  $\hat{\mathbf{x}}$  telle que  $\mathbf{y} \approx \mathbf{H}\hat{\mathbf{x}}$  tout en minimisant  $\|\mathbf{x}\|_\infty$ . Les estimateurs bayésiens obtenus sont comparés à l'algorithme FITRA [6] qui résout le problème (1) par une méthode itérative de *forward-backward*. Les métriques utilisées pour évaluer la qualité des résultats sont une mesure de reconstruction  $\text{SNR}_{\mathbf{y}} = 20 \ln(\|\mathbf{y}\|_2 / \|\mathbf{y} - \mathbf{H}\hat{\mathbf{x}}\|_2)$  et une mesure d'antiparcomnie définie par  $\text{PAPR} = N \|\hat{\mathbf{x}}\|_\infty^2 / \|\hat{\mathbf{x}}\|_2^2$ . L'objectif est de trouver des solutions avec un  $\text{SNR}_{\mathbf{y}}$  élevé et un faible PAPR traduisant une représentation démocratique. On affichera souvent les solutions dans le plan  $(\text{PAPR}, \text{SNR}_{\mathbf{y}})$ .

### 4.1 Comportement des estimateurs

Dans cette partie, le paramètre  $\beta$  n'est pas estimé, il est arbitrairement fixé à  $\beta = 0.01$ . Notons que le comportement des estimateurs est qualitativement indépendant de ce choix. On a montré dans la partie 3 que pour des valeurs fixées des paramètres  $\lambda$  et  $\beta$ , l'estimateur MAP  $\arg \max f(\mathbf{x}|\mathbf{y}, \beta, \lambda)$  correspond à la solution du problème (1). On étudie dans cette partie la robustesse de la méthode en faisant varier la valeur de  $\lambda$ . La valeur de  $\sigma^2$  s'obtient via  $\sigma^2 = \beta/2\lambda$ . Les estimateurs sont calculés sur  $10^5$  itérations de l'algorithme MCMC. La Figure 2-a affiche la valeur de  $J(\hat{\mathbf{x}}, 0.01)$  pour les estimateurs MAP et MMSE. La droite horizontale est la valeur de  $J(\hat{\mathbf{x}}, 0.01)$  obtenue avec FITRA, utilisée comme référence. Comme l'estimateur MAP ne dépend que de  $\beta$ , les performances devraient être les mêmes. On constate que les estimateurs sont proches de




FIGURE 2 – (a) Valeurs de  $J(\hat{x}, 0.01)$  pour les estimateurs MAP et MMSE en fonction de  $\lambda$ . (b) Position des estimateurs MAP et MMSE dans le plan (PAPR,  $SNR_y$ ) en fonction de  $\lambda$ .

FITRA dès lors que le paramètre  $\lambda$  dépasse une valeur seuil environ égale à  $(N + 1)\sqrt{N}/\|y\|_2$ . Ce seuil correspond à l'ordre de grandeur prédit dans la partie 3.2.3.

La Figure 2-b représente les estimateurs MAP (points bleu clair) et MMSE (points bleu foncé) dans le plan (PAPR,  $SNR_y$ ) lorsque  $\lambda$  croît. La courbe noire correspond aux solutions proposées par FITRA pour toutes les valeurs du paramètre de régularisation  $\beta$ . On constate que les chemins des deux estimateurs obtenus en faisant croître  $\lambda$  convergent vers le point correspondant à la solution proposée par FITRA pour  $\beta = 0.01$ .

## 4.2 Inférence du paramètre de régularisation

Dans cette partie, le paramètre  $\beta$  n'est plus fixé, mais est estimé suivant le modèle hiérarchique présenté dans la partie 3. L'objectif est d'inférer la valeur de  $\beta$  qui correspond au meilleur compromis entre  $SNR_y$  et PAPR. On s'intéresse en particulier à la zone critique mise en évidence par FITRA. Cette zone critique correspond à la transition de phase des solutions dans le plan (PAPR,  $SNR_y$ ) obtenue avec les solutions de FITRA en faisant varier le paramètre de régularisation. Sur la Figure 3, cela correspond à un PAPR entre 1.5 et 1.8. On souhaite *a priori* que  $\beta$  explore cette région des solutions. On choisit pour cela  $a_\delta = 2000$  et  $b_\delta = 200$ .

La Figure 3 montre les 200 dernières itérations de l'algorithme MCMC. On observe que les itérations sont proches de la courbe obtenue par l'algorithme FITRA et de la transition de phase. On constate que l'estimateur MAPm défini par  $\hat{x}_{MAPm} = \arg\max_x f(x|y)$  correspond à un point de la courbe FITRA. Cependant, l'estimateur MMSE reste à une certaine distance de la courbe FITRA, ce qui n'était pas le cas dans la partie 4.1.

On en déduit que dans le cas où  $\beta$  est conjointement estimé, il est possible que le modèle incluant une loi *a priori* conjuguée sur  $\beta$  induise un biais faible mais notable dans l'estimation des coefficients  $x$  considérés. Nous ne sommes toutefois pas encore en mesure de quantifier ce biais.

## 5 Conclusion

Cet article a introduit une nouvelle loi de probabilité, la loi *démocratique*, utilisée ensuite comme loi *a priori* sur des coefficients de représentation dans un problème de codage an-




FIGURE 3 – 200 dernières itérations de l'algorithme MCMC lorsque  $\beta$  est également échantillonné.

tiparcimonieux. Un algorithme MCMC basé sur P-MYULA a été utilisé pour générer des échantillons asymptotiquement distribués suivant la loi *a posteriori*. Cet échantillonneur s'est avéré plus efficace qu'un échantillonneur de Gibbs classique. Si l'on fixe les paramètres du modèle, les résultats expérimentaux ont montré que les estimateurs MAP et MMSE convergent vers les solutions proposées par l'algorithme d'optimisation FITRA. L'estimation du paramètre de régularisation est une question difficile. Néanmoins, le choix d'une loi *a priori* conjuguée pour le paramètre de régularisation permet d'obtenir des estimateurs MMSE et surtout MAPm proches de l'optimum.

## Références

- [1] A. R. Calderbank and I. Daubechies, "The pros and cons of democracy," *IEEE Trans. Inf. Theory*, 2002.
- [2] H. Jégou, T. Furon, and J. J. Fuchs, "Anti-sparse coding for approximate nearest neighbor search," in *Proc. Int. Conf. Acoustics Speech Signal Process. (ICASSP)*, 2012.
- [3] Y. Lyubarskii and R. Vershynin, "Uncertainty principles and vector quantization," *IEEE Trans. Inf. Theory*, 2010.
- [4] C. Studer, Y. Wotao, and R. G. Baraniuk, "Signal representations with minimum  $\ell_\infty$ -norm," in *Proc. Ann. Allerton Conf. Comm. Control Comput.*, 2012.
- [5] J.-J. Fuchs, "Spread representations," in *Proc. IEEE Asilomar Conf. Signals, Systems, Computers*, 2011.
- [6] C. Studer and E. G. Larsson, "PAR-aware large-scale multi-user MIMO-OFDM downlink," *IEEE J. Sel. Areas Comm.*, 2013.
- [7] C. Elvira, P. Chainais, and N. Dobigeon, "Bayesian antisparse coding," *IEEE Trans. Signal Process.*, April 2017.
- [8] A. Durmus, E. Moulines, and M. Pereyra, "Efficient Bayesian computation by proximal Markov chain Monte Carlo : when Langevin meets Moreau," *ArXiv e-prints*.
- [9] M. Pereyra, "Proximal Markov chain Monte Carlo algorithms," *Stat. Comput.*, 2015.
- [10] J.-J. Moreau, "Fonctions convexes duales et points proximaux dans un espace hilbertien," *CR Acad. Sci. Paris Sér. A Math*, 1962.