

# Déconvolution impulsionnelle positive myope

Vincent MAZET<sup>1</sup>, Jérôme IDIER<sup>2</sup>, David BRIE<sup>1</sup>

<sup>1</sup>Université Henri Poincaré, Nancy 1, CRAN, CNRS UMR 7039,  
BP 239, F-54506 Vandœuvre-lès-Nancy Cedex

<sup>2</sup>École Centrale de Nantes, IRCCyN, CNRS UMR 6597,  
BP 92101, F-44321 Nantes Cedex 3

{vincent.mazet,david.brie}@cran.uhp-nancy.fr, jerome.idier@irccyn.ec-nantes.fr

**Résumé** – Dans cet article, nous considérons le problème de la déconvolution impulsionnelle positive myope, c’est-à-dire que nous souhaitons restaurer un signal impulsionnel dans le cas particulier où tous les pics sont positifs, en estimant également les paramètres de la réponse impulsionnelle et les hyperparamètres du problème. Du fait de la complexité du problème, nous utilisons une méthode MCMC basée sur l’algorithme de Gibbs. Enfin, deux indices originaux sont proposés pour estimer le signal impulsionnel et permettre une analyse plus pertinente de la chaîne de Markov résultante.

**Abstract** – We consider in this paper the problem of the blind deconvolution of positive peaks, *i.e.* we wish to restore a sparse spike train whose peaks are positive and to estimate the impulse response and the problem hyperparameters. Because of the complexity of the posterior global criterion, we use an MCMC method based on the Gibbs sampler. Finally, we propose two new indexes to give an estimate of the signal, yielding an efficient analysis of the Markov chain.

## 1 Introduction

Nous considérons dans cet article le problème de la déconvolution impulsionnelle positive myope non supervisée, c’est-à-dire que nous souhaitons estimer conjointement le signal impulsionnel  $\mathbf{z} \in \mathbb{R}^{+N}$ , la réponse impulsionnelle  $\mathbf{h} \in \mathbb{R}^M$  et les différents hyperparamètres du problème connaissant la sortie du système  $\mathbf{y} \in \mathbb{R}^N$ . Nous modélisons le problème sous la forme classique suivante :

$$\mathbf{y} = \mathbf{H}\mathbf{z} + \mathbf{b},$$

où  $\mathbf{H}$  est la matrice de Toeplitz de  $\mathbf{h}$ , et où le bruit  $\mathbf{b}$  permet la prise en compte des incertitudes de mesure et de modèle.

Le problème de la déconvolution impulsionnelle myope peut se rencontrer en spectroscopie [4], en sismique réflexion [1, 9], en électricité (décharges partielles) ou encore en génétique (séquençage d’ADN [5]).

La déconvolution myope, qui, comme la déconvolution classique, est un problème inverse mal posé, cherche de plus à estimer un grand nombre de variables par rapport aux données disponibles. La résolution de ce type de problème impose donc d’inclure des connaissances a priori fortes pour régulariser la solution, comme par exemple imposer de restaurer un signal impulsionnel. Dans ce contexte, l’approche bayésienne associée au développement des techniques de simulations stochastiques fournit un cadre particulièrement attractif pour résoudre ce type de problèmes.

Ainsi, certains auteurs imposent un a priori Bernoulli-gaussien sur  $\mathbf{z}$  et gaussien sur  $\mathbf{h}$  [1, 9] ; ils utilisent ensuite l’échantillonneur de Gibbs qui permet de générer une chaîne de Markov pour chaque quantité à estimer. Cheng *et al.* [1] et Rosec *et al.* [9] proposent deux estimateurs différents pour le signal impulsionnel (une discussion à propos du choix de ces estima-

teurs est proposée section 4). D’autres auteurs préfèrent estimer les paramètres de  $\mathbf{z}$  et  $\mathbf{h}$ , à savoir la position et l’amplitude des pics et la largeur de la réponse impulsionnelle [4, 5] : l’a priori Bernoulli-gaussien n’est pas utilisé puisque  $\mathbf{z}$  est modélisé par un ensemble de pics dont les positions et les amplitudes sont à estimer. Différentes lois a priori sur les paramètres  $\mathbf{y}$  sont proposées, mais tous appliquent l’algorithme RJMCMC. L’estimation des variables se fait ensuite en utilisant l’estimateur MAP (maximum a posteriori). Notons que le fait d’estimer seulement les paramètres de  $\mathbf{h}$  plutôt que  $\mathbf{h}$  entier permet de diminuer le nombre de variables à estimer, mais cela implique que la structure de la réponse impulsionnelle soit connue a priori, ce qui est le cas dans certaines applications, en particulier la spectroscopie.

Nous considérons ici le cas particulier (courant en spectroscopie ou en génétique) où les impulsions sont positives :

$$\forall n \in \{1, \dots, N\}, \mathbf{z}_n \geq 0.$$

De plus, pour éviter d’avoir à optimiser un critère a posteriori trop compliqué, nous suivons la majorité des travaux en se plaçant dans un cadre bayésien et en utilisant une méthode MCMC basée sur l’échantillonneur de Gibbs [1, 8]. Cet algorithme itératif génère une chaîne de Markov du vecteur de variables  $\boldsymbol{\theta} = \{\boldsymbol{\theta}_1, \dots, \boldsymbol{\theta}_N\}$ . Partant de valeurs initiales  $\boldsymbol{\theta}^{(0)} = \{\boldsymbol{\theta}_1^{(0)}, \dots, \boldsymbol{\theta}_N^{(0)}\}$ , on simule à tour de rôle les variables de  $\boldsymbol{\theta}$  à partir leur distributions a posteriori conditionnelles. Ainsi, à l’itération  $i$  et  $\forall n \in \{1, \dots, N\}$ ,

$$\boldsymbol{\theta}_n^{(i)} \sim p(\boldsymbol{\theta}_n | \mathbf{y}, \boldsymbol{\theta}_1^{(i)}, \dots, \boldsymbol{\theta}_{n-1}^{(i)}, \boldsymbol{\theta}_{n+1}^{(i-1)}, \dots, \boldsymbol{\theta}_N^{(i-1)}).$$

La section 2 présente les lois a priori choisies pour chaque quantité dont on déduit les lois a posteriori (en section 3), à partir desquelles l’échantillonneur de Gibbs permet de simuler chaque variable. Le choix des estimateurs est discuté dans la

section 4 : nous y proposons deux indices originaux permettant d'obtenir une estimation pertinente du signal impulsionnel. Enfin, la section 5 conclut ce travail.

## 2 Lois a priori

### 2.1 Loi a priori de $\mathbf{z}$

Le signal impulsionnel est modélisé par un processus Bernoulli-gaussien à support positif. Aussi, le signal est représenté par le couple  $\mathbf{z} = (\mathbf{q}, \mathbf{x})$  où

- $\mathbf{q}$  fixe l'occurrence des pics et suit une loi de Bernoulli de paramètre  $\lambda$  [8] :

$$\mathbf{q}_n \sim \mathcal{Ber}(\lambda) ;$$

- $\mathbf{x}$  correspond à l'amplitude des pics et suit une loi gaussienne à support positif de variance  $r_1 > 0$  s'il y a un pic au point  $n$  ( $\mathbf{q}_n = 1$ ) ou  $r_0 = 0$  sinon ( $\mathbf{q}_n = 0$ ) :

$$\mathbf{x}_n \sim \mathcal{N}^+(0, r_1 \mathbf{q}_n + r_0(1 - \mathbf{q}_n)).$$

$\mathcal{N}^+(\mu, \sigma^2)$  représente la loi gaussienne de moyenne  $\mu$  et de variance  $\sigma^2$  tronquée en zéro.

La loi a priori de  $\mathbf{z}_n$  s'écrit alors :

$$\begin{aligned} p(\mathbf{z}_n | \mathbf{z}_{-n}, \lambda, r_1, s, r_b) &= p(\mathbf{x}_n, \mathbf{q}_n | \mathbf{z}_{-n}, \lambda, r_1, s, r_b) \\ &= p(\mathbf{x}_n | \mathbf{q}_n, r_1) p(\mathbf{q}_n | \lambda), \end{aligned}$$

où  $\mathbf{z}_{-n} = \{\mathbf{z}_1, \dots, \mathbf{z}_{n-1}, \mathbf{z}_{n+1}, \dots, \mathbf{z}_N\}$ .

En pratique, lorsque le nombre de pics  $N_{\mathbf{q}} = \sum_n \mathbf{q}_n$  devient très faible, il apparaît que la solution qui consiste à avoir un grand nombre de pics de petite amplitude devient très probable : c'est typiquement un problème de dégénérescence. Il est donc nécessaire de fixer un a priori sur  $\lambda$  qui permette de limiter le nombre de pics. Nous choisissons la loi a priori conjuguée<sup>1</sup> :

$$\lambda \sim \mathcal{Be}(1, N + 1).$$

où  $\mathcal{Be}(\alpha, \beta)$  représente la famille des lois beta [8].

En outre, si aucun a priori n'est fixé sur  $r_1$ , sa loi a posteriori s'écrit :

$$r_1 \sim \mathcal{IG}(N_{\mathbf{q}}/2 - 1, \mathbf{x}_n^T \mathbf{x}_n/2),$$

où  $\mathcal{IG}(\alpha, \beta)$  représente la famille des lois inverse gamma [8]. Un problème numérique se pose alors dans le cas où  $N_{\mathbf{q}} \leq 2$  : le premier paramètre de la loi inverse gamma n'est plus strictement positif. Pour éviter cela, nous posons un a priori sur  $r_1$  en choisissant également une loi conjuguée :

$$r_1 \sim \mathcal{IG}(\alpha_1, \beta_1)$$

dont l'espérance et la variance sont [8] :

$$\begin{aligned} \mathbb{E}[r_1] &= \beta_1 / (\alpha_1 - 1), & (\text{si } \alpha_1 > 1), \\ \text{Var}[r_1] &= \beta_1^2 / ((\alpha_1 - 1)^2 (\alpha_1 - 2)) & (\text{si } \alpha_1 > 2). \end{aligned}$$

L'a priori a été choisi pour éviter les erreurs numériques. Cependant, afin de minimiser son influence sur l'estimation, il doit être le moins informatif possible. À ce titre, la variance doit être choisie la plus grande possible et l'espérance de manière à

<sup>1</sup>Une loi a priori conjuguée permet d'obtenir une loi a posteriori de même forme mais dont les paramètres sont fonction de la vraisemblance et de l'a priori.

ne pas affecter l'estimation. On choisit donc de prendre l'espérance égale à une estimation grossière de la variance de l'amplitude des pics. Dès lors, puisque  $\text{Var}[r_1] = \mathbb{E}[r_1]^2 / (\alpha_1 - 2)$ , il faut que  $\alpha_1$  soit le plus petit possible, donc  $\alpha_1 = 2 + \varepsilon$ , où  $\varepsilon \ll 1$ . D'après l'expression de l'espérance on en déduit :  $\beta_1 = \mathbb{E}[r_1](\alpha_1 - 1) = \mathbb{E}[r_1](1 + \varepsilon)$ .

### 2.2 Loi a priori de $s$

Le cas le plus général consiste à supposer la réponse impulsionnelle inconnue. Cependant, dans certaines applications (en particulier la spectroscopie), on peut supposer que la structure de  $\mathbf{h}$  est connue. Seuls les paramètres de la structure sont à estimer, limitant ainsi le nombre d'inconnues du problème. C'est ce cas que nous traitons : dans la suite de l'article, nous prenons l'exemple d'une réponse impulsionnelle lorentzienne de paramètre  $s$  :

$$\mathbf{h}_n = \frac{s^2}{s^2 + n^2}.$$

Alors, seul le scalaire  $s$  est à estimer. Le seul a priori imposé à  $s$  est qu'il soit positif.

### 2.3 Loi a priori de $\mathbf{b}$

$\mathbf{b}$  est modélisé par un processus gaussien i.i.d. de moyenne nulle et de variance  $r_b \mathbf{I}$ . De même que pour  $s$ , le seul a priori imposé est la positivité de  $r_b$ .

### 2.4 Indéterminations en déconvolution myope

Dans le problème de la déconvolution myope de signaux réels, plusieurs types d'indéterminations peuvent intervenir [1] :

- l'indétermination sur le contenu spectral tient au fait qu'il n'est pas possible a priori de différencier les cas  $h(n) \star z(n)$  et  $h_1(n) \star (h_2(n) \star z(n))$  où  $h_1(n) \star h_2(n) = h(n)$ . Dans notre cas, l'a priori Bernoulli-gaussien à support positif sur  $z$  permet de lever cette indétermination ;
- l'indétermination temporelle correspond au fait que  $\forall \eta$ ,  $h(n) \star z(n) = h(n + \eta) \star z(n - \eta)$  : le signal impulsionnel et la réponse impulsionnelle peuvent être décalés d'une valeur inverse l'un par rapport à l'autre. Ici, l'indétermination est levée en fixant le maximum de la réponse impulsionnelle en  $n = 0$  ;
- enfin, l'indétermination sur l'amplitude correspond au fait que  $\forall \alpha$ ,  $h(n) \star z(n) = \alpha h(n) \star z(n) / \alpha$ . On lève l'indétermination en fixant le maximum de la réponse impulsionnelle à 1.

## 3 Lois a posteriori

### 3.1 Fonction de vraisemblance

Il y a donc  $2N + 4$  variables à estimer :  $\theta = \{\mathbf{x}, \mathbf{q}, r_1, \lambda, s, r_b\}$ . L'a priori gaussien sur le bruit permet de déterminer l'expression de la vraisemblance selon :

$$p(\mathbf{y} | \mathbf{x}, s, r_b) = \frac{1}{(2\pi r_b)^{N/2}} \exp\left(-\frac{1}{2r_b} \|\mathbf{y} - \mathbf{H}\mathbf{x}\|^2\right).$$

### 3.2 Détermination des lois a posteriori

La règle de Bayes permet de déterminer les lois a posteriori à simuler :

$$\begin{aligned} \mathbf{x}_n &\sim \mathcal{N}^+(\mu_{\mathbf{q}_n, n}, \rho_{\mathbf{q}_n, n}), \\ \mathbf{q}_n &\sim \mathcal{B}er(\lambda_{1, n}), \\ r_1 &\sim \mathcal{IG}(N_{\mathbf{q}}/2 + \alpha_1, \mathbf{x}_n^T \mathbf{x}_n/2 + \beta_1), \\ \lambda &\sim \mathcal{B}e(N_{\mathbf{q}} + 1, 2N - N_{\mathbf{q}} + 1), \\ s &\sim \exp(-\|\mathbf{y} - \mathbf{H}(s)\mathbf{x}\|^2/2r_{\mathbf{b}}), \\ r_{\mathbf{b}} &\sim \mathcal{IG}(N/2 - 1, \|\mathbf{y} - \mathbf{H}\mathbf{x}\|^2/2), \end{aligned}$$

où :

$$\begin{aligned} \rho_{1, n} &= \frac{r_1 r_{\mathbf{b}}}{r_{\mathbf{b}} + r_1 \mathbf{H}_n^T \mathbf{H}_n}, & \mu_{1, n} &= \frac{r_{1, n}}{r_{\mathbf{b}}} \mathbf{e}_n^T \mathbf{H}_n, \\ \rho_{0, n} &= 0, & \mu_{0, n} &= 0, & \mathbf{e}_n &= \mathbf{y} - (\mathbf{H}\mathbf{x} - \mathbf{H}_n \mathbf{x}_n), \\ \lambda_{1, n} &= \left[ 1 + \frac{1 - \lambda}{\lambda} \sqrt{\frac{r_1}{\rho_{1, n}}} \exp\left(-\frac{\mu_{1, n}^2}{2\rho_{1, n}}\right) \right]^{-1}, \end{aligned}$$

et où  $\mathbf{H}_n$  est la  $n^{\text{ème}}$  colonne de  $\mathbf{H}$ . Notons que dans la loi a posteriori de  $s$ , la dépendance de  $\mathbf{H}$  par rapport à  $s$  a été rendue explicite.

### 3.3 Simulation des lois à posteriori

L'échantillonnage des variables  $\mathbf{q}_n$ ,  $\lambda$ ,  $r_1$  et  $r_{\mathbf{b}}$  est facile puisqu'il s'agit de lois classiques.

Pour  $\mathbf{x}_n$ , des techniques efficaces de génération de variables gaussiennes positives existent [2, 6, 7] ; en particulier, dans [6], nous proposons un algorithme d'acceptation-rejet mixte utilisant plusieurs lois candidates et dont le taux d'acceptation moyen est très élevé, donnant ainsi une méthode d'échantillonnage rapide.

Enfin, la loi de  $s$  n'étant pas standard, son échantillonnage est réalisé par un algorithme de Metropolis-Hastings à marche aléatoire avec, comme loi candidate, une gaussienne à support positif de moyenne  $s^{(i-1)}$  et de variance  $r_s$  fixée. L'efficacité de l'algorithme dépend en grande partie de  $r_s$  : si la variance est trop faible, la chaîne de Markov risque de converger trop lentement puisque ses pas seront petits ; au contraire, si la variance est trop grande, l'algorithme va rejeter un grand nombre de propositions [3, 8]. En général, ce réglage est heuristique. Dans [3], Gelman *et al.* recommandent par exemple de chercher à atteindre un taux d'acceptation de 0,5 pour les modèles de dimension 1.

Enfin, afin d'accélérer la convergence de l'algorithme, les  $\mathbf{z}_n$  sont échantillonnés dans un ordre aléatoire à chaque itération.

## 4 Choix de l'estimateur

Dans cette section, nous nous concentrons sur le choix de l'estimateur du signal impulsionnel, les autres quantités étant estimées au sens de l'EAP (espérance a posteriori) car facile à implémenter à partir d'une chaîne de Markov [1]. On suppose donc que l'échantillonneur de Gibbs a généré les chaînes de Markov de  $\mathbf{x}$  et  $\mathbf{q}$ . Pour simplifier, nous supposons que la période de transition de la chaîne de Markov est négligeable ou a été supprimée : on considère donc que la chaîne est en régime stationnaire de  $i = 1$  à  $i = I$ . Dans un premier temps, nous

présentons les deux estimateurs proposés dans [1] et [9] et les appliquons à la chaîne de Markov générée, et nous montrons qu'ils peuvent, dans certains cas, conduire à une interprétation erronée. Nous proposons alors deux indices permettant d'obtenir une interprétation correcte des résultats.

Pour cela, considérons l'exemple d'une chaîne de Markov telle que  $I = 4$  et  $N = 4$  (figure 1). En  $k = 1$ , la chaîne de Markov ne génère jamais de pic ; en  $k = 2$ , elle en génère toujours un ; enfin, elle génère alternativement un pic en  $k = 3$  et en  $k = 4$ , signifiant qu'il y a sans doute un pic situé entre les points 3 et 4, mais qu'il est difficile de le positionner avec précision. Les résultats des différents estimateurs sont également représentés, avec éventuellement l'estimation de  $\mathbf{q}_n$ .

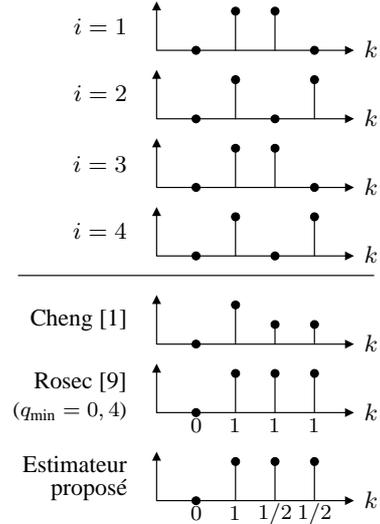


FIG. 1 – Comparaison des différents estimateurs

Dans [1], les auteurs ne considèrent pas le vecteur  $\mathbf{q}$  des occurrences des pics et proposent d'estimer  $\mathbf{x}_n$  au sens de l'EAP :

$$\hat{\mathbf{x}}_n^{\text{EAP}} = \mathbb{E}[\mathbf{x}_n | \mathbf{y}] = \int \mathbf{x}_n p(\mathbf{x}_n | \mathbf{y}) d\mathbf{x}_n.$$

Cette quantité n'étant pas calculable explicitement, l'estimateur est approché par :

$$\hat{\mathbf{x}}_n \triangleq \frac{1}{I} \sum_{i=1}^I \mathbf{x}_n^{(i)}.$$

Le résultat fourni par cet estimateur sur l'exemple de la figure 1 donne un résultat cohérent en  $k = 1$  et  $k = 2$ . En revanche, l'analyse de l'estimation indique qu'il y a deux pics de faible amplitude en  $k = 3$  et  $k = 4$ , alors qu'il n'y en a qu'un seul grand : cet estimateur est donc inadéquat.

Rosec *et al.* [9], pour leur part, prennent en compte le vecteur  $\mathbf{q}$  et l'estime au sens du MAP (maximum a posteriori) :  $\hat{\mathbf{q}}_n$  ne peut donc prendre que la valeur 0 ou 1.

$$\hat{\mathbf{q}}_n \triangleq \begin{cases} 1 & \text{si } \frac{1}{I} \sum_{i=1}^I \mathbf{q}_n^{(i)} > q_{\min}, \\ 0 & \text{sinon,} \end{cases}$$

où  $q_{\min}$  est un seuil fixé a priori. L'estimateur de l'amplitude est défini ainsi :

$$\hat{\mathbf{x}}_n \triangleq \begin{cases} \frac{1}{\sum_{i=1}^I \mathbf{q}_n^{(i)}} \sum_{\substack{i=1 \\ \mathbf{q}_n^{(i)}=1}}^I \mathbf{x}_n^{(i)} & \text{si } \hat{\mathbf{q}}_n = 1, \\ \frac{1}{\sum_{i=1}^I (1 - \mathbf{q}_n^{(i)})} \sum_{\substack{i=1 \\ \mathbf{q}_n^{(i)}=0}}^I \mathbf{x}_n^{(i)} & \text{si } \hat{\mathbf{q}}_n = 0, \end{cases}$$

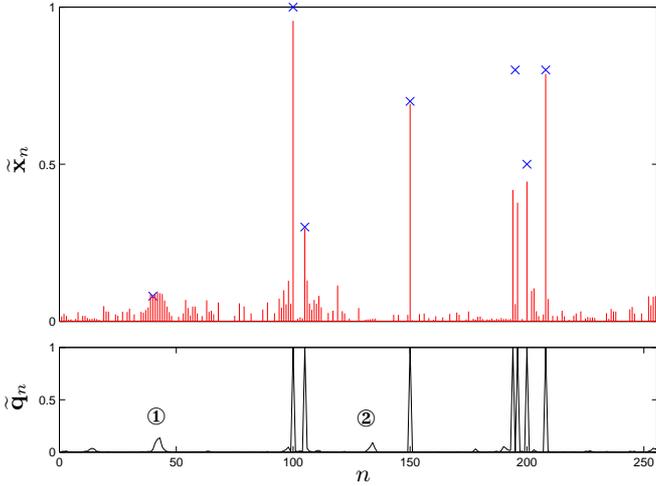


FIG. 2 – Estimation sur un signal simulé. Les croix représentent les pics réels et les lignes leur estimation.

L'estimation à partir de la chaîne de Markov de la figure 1 estime correctement les deux premiers pics, mais, avec  $q_{\min} < 0,5$ , estime deux pics de grande amplitude en  $k = 3$  et  $k = 4$  alors qu'il n'y en a qu'un seul.

La principale limitation des estimateurs précédents provient de la prise de décision sous-jacente à l'estimateur. Dans le premier cas, tous les pics sont considérés comme étant significatifs, alors que dans le deuxième, seuls les plus probables sont pris en compte. Afin d'améliorer l'analyse de la chaîne de Markov, nous proposons d'utiliser conjointement deux indices estimant respectivement la probabilité d'occurrence d'un pic et son amplitude :

$$\tilde{\mathbf{q}}_n \triangleq \frac{1}{I} \sum_{i=1}^I \mathbf{q}_n^{(i)}, \quad \tilde{\mathbf{x}}_n \triangleq \frac{1}{\sum_{i=1}^I \mathbf{q}_n^{(i)}} \sum_{\substack{i=1 \\ \mathbf{q}_n^{(i)}=1}}^I \mathbf{x}_n^{(i)}.$$

Notons que pour  $I \rightarrow \infty$ , ces quantités s'écrivent également :

$$\tilde{\mathbf{q}}_n \approx \mathbb{E}[\mathbf{q}_n | \mathbf{y}], \quad \tilde{\mathbf{x}}_n \approx \mathbb{E}[\mathbf{x}_n | \mathbf{y}] / \mathbb{E}[\mathbf{q}_n | \mathbf{y}].$$

L'indice  $\tilde{\mathbf{q}}_n$  n'est pas à proprement parler un estimateur de  $\mathbf{q}_n$  car il peut prendre des valeurs non entières. Cependant, il permet d'obtenir une estimation de la *probabilité d'occurrence des pics*, donc de leur probabilité d'existence. Ainsi, dans le cas de la figure 1, les deux premiers pics sont toujours correctement estimés, et en  $k = 3$  et  $k = 4$  on estime deux pics de grande amplitude, mais de probabilité d'existence 1/2, ce qui reflète mieux le comportement de la chaîne de Markov. L'analyse conjointe des deux indices permet de déduire qu'il n'y a qu'un seul pic situé au barycentre des deux estimés (c'est-à-dire en  $k = 3,5$ ), et dont l'amplitude est la somme des amplitudes  $\tilde{\mathbf{x}}_n$  pondérées par leur probabilité d'occurrence  $\tilde{\mathbf{q}}_n$ . Ces deux indices permettent ainsi une analyse plus fine de la chaîne de Markov les estimateurs proposés par [1] et [9].

Afin de valider notre méthode et d'illustrer la pertinence de l'estimateur, nous avons simulé un signal de  $N = 256$  points qui est la convolution d'un signal impulsionnel et d'une lorentzienne de largeur  $s = 2$ . Le RSB a été fixé à 30 dB environ. Le résultat d'une simulation de 1000 itérations est donné figure 2. La largeur de la réponse impulsionnelle a été estimée à  $\hat{s} = 1,954$  et l'estimation obtenue est relativement bonne :

les pics aux alentours de 100, 150 et 200 sont bien retrouvés. En ① et ②, on trouve un ensemble de pics d'occurrence 10 % environ. Il y a donc probablement un pic aux alentours de ces endroits, dont l'amplitude est bien estimée par la somme pondérée des  $\tilde{\mathbf{x}}$  et la position par le barycentre des  $\tilde{\mathbf{q}}$ , sous réserve que la zone considérée soit correctement sélectionnée. En raisonnant de la sorte, on retrouve bien le pic de faible amplitude en ①. En revanche, l'amplitude des pics estimés en ② est très faible : on peut en déduire qu'il n'y a pas de pic à cet endroit. Une analyse telle que celle présentée dans [1] et [9] n'aboutirait pas à ces conclusions. Le pic situé à 195 a été estimé par deux pics *très proches* d'occurrence 1, et d'amplitude moitié. Encore une fois, en supposant que la zone relative à ce pic soit correctement sélectionnée, sa position et son amplitude sont bien estimés par le barycentre et la somme pondérée. Il est clair que la qualité de l'analyse est très fortement liée à la sélection de la zone relative à un pic, étape qui à l'heure actuelle est laissée à l'appréciation de l'utilisateur.

## 5 Conclusion

Nous avons présenté dans cet article une méthode de déconvolution impulsionnelle positive myope, dans le cas où la réponse impulsionnelle est de structure connue. De plus, nous nous sommes restreint au cas courant où les pics sont positifs. Un a priori Bernoulli-gaussien à support positif a permis de modéliser le signal impulsionnel, et, en se plaçant dans un cadre bayésien, nous avons utilisé l'échantillonneur de Gibbs pour simuler les lois a posteriori de chaque variable. Enfin, nous avons proposé deux nouveaux indices qui, utilisés conjointement, permettent d'obtenir une analyse plus fine des résultats fournis par l'algorithme de déconvolution.

## Références

- [1] Q. Cheng, R. Chen et T.-H. Li, Simultaneous wavelet estimation and deconvolution of reflection seismic signals, *IEEE Transactions on Geoscience and Remote Sensing* **34** (1996) 377–384.
- [2] L. Devroye, *Non-uniform random variate generation*, Springer-Verlag, New York (1986). Disponible sur <http://jeff.cs.mcgill.ca/~luc/rnbookindex.html>.
- [3] A. Gelman, G.O. Roberts et W.R. Gilks, Efficient Metropolis jumping rules, *Bayesian Statistics* **5** Oxford University Press (1996) 599–607.
- [4] S. Gulam Razul, W.J. Fitzgerald et C. Andrieu, Bayesian model selection and parameter estimation of nuclear emission spectra using RJMCMC, *Nucl. Inst. Meth. Phys. Res. A* **497** (2003) 492–510.
- [5] N.M. Haan et S.J. Godsill, Bayesian model for DNA sequencing, *ICASSP'02*, Orlando, Floride, USA, (2002) **4** 4020–4023.
- [6] V. Mazet, D. Brie et J. Idier, Simuler une distribution normale positive à partir de plusieurs lois candidates, *20<sup>e</sup> GRETSI*, Louvain-la-Neuve, Belgique, 6-9 septembre 2005.
- [7] C.P. Robert, Simulation of truncated normal variables, *Statistics and Computing* **5** (1995) 121–125.
- [8] C.P. Robert, *Méthodes de Monte Carlo par chaînes de Markov*, Economica (1996).
- [9] O. Rosec, J.-M. Boucher, B. Nsiri et T. Chonavel, Blind marine seismic deconvolution using statistical MCMC methods, *IEEE Journal of Oceanic Engineering* **28** (2003) 502–512.