

# Application du rééchantillonnage stochastique de l'échelle en détection-estimation de l'activité cérébrale par IRMf

Philippe CIUCIU<sup>1</sup>, Jérôme IDIER<sup>2</sup>, Thomas VEIT<sup>2\*</sup>, Thomas VINCENT<sup>1</sup>

<sup>1</sup>NeuroSpin/I2BM/CEA, Bâtiment 145 – Point Courrier 156 91191 Gif-sur-Yvette cedex, France

<sup>2</sup>IRCCyN (CNRS) BP 92101, 1 rue de la Noë, 44321 Nantes cedex 3

philippe.ciuciu@cea.fr, thomas.vincent@cea.fr,  
Jerome.Idier@ircyn.ec-nantes.fr, thomas.veit@inrets.fr

**Résumé** – Cet article présente une application en neuroimagerie fonctionnelle de la communication compagne [1], visant à simuler au sein d'un algorithme MCMC des échantillons moins corrélés par l'inclusion d'une étape de rééchantillonnage d'un paramètre d'échelle lorsque le modèle d'observation est bilinéaire vis-à-vis des paramètres inconnus. L'application visée concerne la détection-estimation conjointe de l'activité cérébrale en Imagerie par Résonance Magnétique fonctionnelle (IRMf). Il s'agit de recouvrer à la fois un filtre hémodynamique régional et des cartes d'activations spécifiques à chaque type de stimulus impliqué dans le paradigme expérimental. L'apport de la méthode du rééchantillonnage de l'échelle est illustré sur des simulations réalistes.

**Abstract** – This paper presents an application of the submission [1] to functional neuroimaging. This joint work aims at simulating less correlated samples in a MCMC algorithm by including a sampling step of a scale parameter when the forward model is bilinear with respect to the unknown parameters. Our application concerns the joint detection-estimation of brain activity in functional Magnetic Resonance Imaging, where one tries to recover both the shape of the regional Hemodynamic Response Function and stimulus-dependent activation maps. The gain that we obtained is illustrated on realistic simulations.

## 1 Introduction

L'analyse intra-sujet des données d'IRMf consiste d'une part à *détecter* les aires cérébrales activées en réponse à une stimulation expérimentale, et d'autre part, à *estimer* la dynamique temporelle de ces activations. Dans [2, 3], une approche de détection-estimation a été proposée pour aborder ces deux problèmes conjointement au sein d'une région fonctionnellement homogène  $\mathcal{R}$ . Il s'agit alors d'estimer le filtre hémodynamique régional  $\mathbf{h}$  tout en introduisant une spécificité de l'activité en chaque voxel  $V_j$  et pour chaque condition expérimentale  $m$  à travers un facteur de modulation  $\mathbf{a} = (a_j^m)_j^m$ , appelé *niveau de réponse neurale* par la suite. Cette modélisation nous conduit à résoudre un problème inverse bilinéaire en  $(\mathbf{a}, \mathbf{h})$  de type *déconvolution aveugle* où le signal d'entrée est assimilé à un peigne de Dirac dont les instants des pics sont fixés par le paradigme expérimental et dont les intensités correspondent à  $\mathbf{a}$ . Compte tenu de l'ambiguïté d'échelle inhérente à ce type de problèmes, tout couple solution  $(\hat{\mathbf{h}}, \hat{\mathbf{a}})$  au sens du maximum de vraisemblance n'est pas distinguable de  $(\hat{\mathbf{h}}/s, s \times \hat{\mathbf{a}})$  où  $s$  est un paramètre scalaire non nul. L'ajout d'informations *a priori* sur le couple  $(\mathbf{h}, \mathbf{a})$  dans un cadre bayésien doit permettre de lever cette ambiguïté d'échelle intrinsèque. Toutefois, en pratique, lorsqu'on simule des échantillons de la loi *a posteriori* à l'aide d'un algorithme MCMC, on constate que l'échelle des échantillons générés pour  $\mathbf{h}$  et  $\mathbf{a}$  varie très lentement. Il est d'usage alors d'introduire une contrainte, par exemple sur  $\mathbf{h}$ , pour lever

cette indétermination. Toutefois, un tel procédé déforme la loi cible et modifie ainsi le point de convergence de la chaîne de Markov générée par le schéma MCMC.

L'objet de cette communication est d'adapter l'approche décrite dans [1] pour l'analyse de données d'IRMf. Il s'agit d'insérer, au sein de l'algorithme MCMC, une étape supplémentaire de rééchantillonnage d'un paramètre correspondant à l'*échelle intrinsèque* du problème. Le but est de **garantir** et d'**accélérer** la convergence des estimateurs de type espérance *a posteriori* construits à partir des réalisations de la chaîne de Markov ainsi générée. Nous mettons en évidence l'apport de cette technique, rigoureuse mathématiquement et peu coûteuse numériquement, sur des simulations réalistes.

## 2 Modèle génératif régional

### 2.1 Formulation du problème

La présente contribution s'appuie sur le modèle régional génératif des données d'IRMf développé dans [2, 3]. Soit  $\mathcal{R}=(V_j)_{j=1:J}$  une région d'intérêt supposée fonctionnellement homogène, typiquement segmentée à l'aide d'un algorithme de parcellisation fonctionnelle [4], et soit  $\mathbf{y}_j=(y_{j,t_n})_{n=1:N}$ , le signal IRMf acquis au voxel  $V_j$  dans  $\mathcal{R}$ , et mesuré aux instants  $(t_n=n \text{ TR})_{n=1:N}$ , où TR désigne le délai entre deux acquisitions successives. Sous l'hypothèse d'un couplage *linéaire* et *invariant* dans le temps,  $\mathbf{h}=(h_{d\Delta t})_{d=0:P}$  désigne la réponse impulsionnelle inconnue du système neuro-vasculaire ayant pour entrée la séquence binaire  $\mathbf{x}=(x_n)_{n=1:N}$  codant les *temps d'arrivée*

\*adresse actuelle: Equipe Perception, LIVIC, bâtiment 824 - 14, route de la Minière, 78000 Versailles

du stimulus et pour sortie les données  $\mathbf{y}_j$ . Dans [2], pour tenir compte de la variabilité spatiale et inter-stimulus de l'amplitude de la réponse hémodynamique observée, nous avons introduit des niveaux de réponse neuronale (NRN)  $(a_j^m)_{j=1:M}^{m=1:M}$ , rendant le modèle génératif bilinéaire :

$$\mathbf{y}_j = \sum_{m=1}^M a_j^m \mathbf{X}^m \mathbf{h} + \mathbf{P} \ell_j + \mathbf{b}_j, \quad \forall V_j \in \mathcal{R} \quad (1)$$

où  $\mathbf{X}^m = (x_{t_n - d\Delta t}^m)_{n=1:N, d=0:P}$  est la matrice binaire correspondant à la séquence  $\mathbf{x}^m$  et  $\Delta t$  est la période d'échantillonnage de  $\mathbf{h}$  telle que  $\Delta t < \text{TR}$ . La matrice  $\mathbf{P}$  est une base orthonormée de fonctions (*e.g.*, base de cosinus), fixée *a priori*, modélisant la dérive basse fréquence présente dans les données. Le vecteur  $\ell_j$  définit les coefficients de régression à estimer conjointement avec  $(\mathbf{h}, \mathbf{a})$ . Enfin,  $\mathbf{b}_j$  modélise les incertitudes et les bruits physiologique et d'acquisition, sous la forme d'un processus AR(1), variable spatialement (*i.e.*, de paramètre  $\rho_j$  en  $V_j$ ) pour tenir compte de l'autocorrélation temporelle des données [3].

## 2.2 Vraisemblance

Nous négligeons la corrélation spatiale du bruit considérant qu'il est plus important de modéliser celle du signal d'intérêt induit par la stimulation. Les signaux  $\mathbf{y} = (\mathbf{y}_j)_{j=1}^J$  sont donc supposés indépendants dans l'espace :

$$p(\mathbf{y} | \mathbf{h}, \mathbf{a}, \mathbf{l}, \boldsymbol{\theta}_0) = \prod_{j=1}^J p(\mathbf{y}_j | \mathbf{h}, \mathbf{a}_j, \ell_j, \rho_j, \sigma_{\varepsilon_j}^2) \quad (2)$$

$$\propto \prod_{j=1}^J |\boldsymbol{\Lambda}_j|^{1/2} \sigma_{\varepsilon_j}^{-N} \exp\left(-\sum_{j=1}^J \frac{\tilde{\mathbf{y}}_j^t \boldsymbol{\Lambda}_j \tilde{\mathbf{y}}_j}{2\sigma_{\varepsilon_j}^2}\right)$$

où  $\boldsymbol{\theta}_0 = (\rho_j, \sigma_{\varepsilon_j}^2)_{j=1:J}$  et  $\tilde{\mathbf{y}}_j = \mathbf{y}_j - \sum_m a_j^m \mathbf{X}^m \mathbf{h} - \mathbf{P} \ell_j$ . Notons que  $\sigma_{\varepsilon_j}^{-2} \boldsymbol{\Lambda}_j$  définit l'inverse de la matrice d'autocorrélation de  $\mathbf{b}_j$ . Selon [5, p. 177],  $\boldsymbol{\Lambda}_j$  est tridiagonale symétrique, avec  $|\boldsymbol{\Lambda}_j| = 1 - \rho_j^2$ ,  $(\boldsymbol{\Lambda}_j)_{1,1} = (\boldsymbol{\Lambda}_j)_{N,N} = 1$ ,  $(\boldsymbol{\Lambda}_j)_{\ell,\ell} = 1 + \rho_j^2$ ,  $\ell = 2 : N - 1$  et  $(\boldsymbol{\Lambda}_j)_{\ell+1,\ell} = -\rho_j$ .

Sur la seule base de (2), il est impossible de lever l'ambiguïté d'échelle permettant d'identifier le couple solution  $(\hat{\mathbf{h}}, \hat{\mathbf{a}})$ . Pour ce faire, dans des travaux antérieurs, nous avons introduit des informations *a priori* sur la régularité temporelle du filtre  $\mathbf{h}$  [2] et sur la répartition spatiale des NRNs  $\mathbf{a}$  [3, 6].

## 3 Inférence bayésienne

### 3.1 Lois *a priori*

Nous donnons une présentation extrêmement synthétique des lois introduites sans justification, les détails étant par ailleurs disponibles dans [2, 6].

Afin d'obtenir une estimée  $\hat{\mathbf{h}}$  suffisamment régulière, on introduit une distribution  $p(\mathbf{h}; \sigma_h^2) \sim \mathcal{N}(\mathbf{0}, \sigma_h^2 \mathbf{R})$ , où  $\mathbf{R}$  est la matrice de corrélation imposant une contrainte de type  $C^2$  sur  $\mathbf{h}$  et on fixe  $h_0 = h_{P\Delta t} = 0$ . Concernant  $\mathbf{a}$ , il est d'usage de supposer que chaque type de stimulus induit des amplitudes indépendantes *i.e.*,  $p(\mathbf{a} | \boldsymbol{\theta}_a) = \prod_m p(\mathbf{a}^m | \boldsymbol{\theta}^m)$  avec  $\mathbf{a} = (\mathbf{a}^m)_{m=1:M}$ ,  $\mathbf{a}^m = (a_j^m)_{j=1:J}$

et  $\boldsymbol{\theta}_a = (\boldsymbol{\theta}^m)_{m=1:M}$ .  $\boldsymbol{\theta}^m$  contient l'ensemble des hyperparamètres inconnus reliés au stimulus de type  $m$ . Par ailleurs, seule une partie des voxels de la région  $\mathcal{R}$  peut s'activer en réponse à une stimulation donnée. Il est donc pertinent d'introduire un modèle de mélange reposant sur des variables d'allocations cachées  $q_j^m$ , telles que  $q_j^m = 1$  si  $V_j$  est activé pour la condition  $m$  et  $q_j^m = 0$  sinon. Conditionnellement à  $q_j^m$ , le NRN  $a_j^m$  suit une loi gaussienne :  $(a_j^m | q_j^m = i) \sim \mathcal{N}(\mu_i^m, v_i^m)$  avec  $i = 0, 1$ . Nous imposons  $\mu_0^m = 0$  pour la moyenne des NRNs des voxels inactifs. Il s'agit donc d'un modèle *a priori* de mélange gaussien *indépendant* à deux classes  $\forall m : \lambda_1^m \mathcal{N}(\mu_1^m, v_1^m) + \lambda_0^m \mathcal{N}(0, v_0^m)$ , où  $\lambda_1^m = \text{Pr}(q_j^m = 1)$  et  $\lambda_0^m = 1 - \lambda_1^m$ , donnant ainsi  $\boldsymbol{\theta}^m = [\lambda_1^m, v_0^m, \mu_1^m, v_1^m]$ . Les développements suivants restent valables pour le cas de modèles de mélanges *spatiaux* présentés dans [6].

Il est modélisé comme un processus aléatoire indépendant de  $\mathbf{h}$  et régi par une distribution de probabilité  $p(\mathbb{1} | \boldsymbol{\theta}_{\mathbb{L}})$ , satisfaisant  $p(\mathbb{1} | \boldsymbol{\theta}_{\mathbb{L}}) = \prod_{i=1}^I p(\mathbf{l}_i | \sigma_i^2)$ , où  $\mathbf{l}_i \sim \mathcal{N}(\mathbf{0}, \sigma_i^2 \mathbf{I}_{Q_i})$ . Pour les hyperparamètres  $\{\boldsymbol{\rho}, \boldsymbol{\sigma}_{\varepsilon}^2\}$ , le recours à des *a priori* non informatifs conduit à :

$$p(\boldsymbol{\rho}, \boldsymbol{\sigma}_{\varepsilon}^2) = \prod_j \sigma_{\varepsilon_j}^{-2} \mathbb{1}_{(-1,1)}(\rho_j)$$

alors que l'usage de densités *a priori* propres (normale, inverse gamma, beta) est préférable pour les paramètres de moyenne variance et de proportions contenus dans  $(\boldsymbol{\theta}^m)_m$ .

### 3.2 Loi *a posteriori*

A l'aide de la règle de Bayes et des autres *a priori* définis dans [3], la loi *a posteriori*  $p(\mathbf{h}, \mathbf{a}, \mathbf{l}, \boldsymbol{\theta} | \mathbf{y})$  s'écrit :

$$p(\mathbf{h}, \mathbf{a}, \mathbf{l}, \boldsymbol{\theta} | \mathbf{y}) \propto \sigma_h^{-D} \sigma_{\varepsilon}^{-JQ} \prod_{j=1}^J \left( \frac{(1 - \rho_j^2)^{1/2}}{\sigma_{\varepsilon_j}^{N+1}} \mathbb{1}_{(-1,1)}(\rho_j) \right)$$

$$\times \exp\left(-\frac{\mathbf{h}^t \mathbf{R}^{-1} \mathbf{h}}{2\sigma_h^2} - \sum_{j=1}^J \left( \frac{1}{2\sigma_{\varepsilon_j}^2} \tilde{\mathbf{y}}_j^t \boldsymbol{\Lambda}_j \tilde{\mathbf{y}}_j + \frac{1}{2\sigma_{\varepsilon_j}^2} \|\ell_j\|^2 \right)\right)$$

$$\times \prod_{m=1}^M \left( p(\boldsymbol{\theta}^m) \prod_{j=1}^J \sum_{i=0}^1 \lambda_i^m \mathcal{N}(\mu_i^m, v_i^m) \right) \quad (3)$$

Nous simulons des réalisations de (3) par échantillonnage de Gibbs pour approcher des estimateurs de type espérance *a posteriori*  $\hat{\mathbf{q}}^{\text{PM}}$ ,  $\hat{\mathbf{a}}^{\text{PM}}$  et  $\hat{\mathbf{h}}^{\text{PM}}$ . Nous déduisons ainsi à travers  $\hat{\mathbf{q}}^{\text{PM}}$  quels sont les voxels activés, et  $(\hat{\mathbf{a}}_j^m)^{\text{PM}} \hat{\mathbf{h}}^{\text{PM}}$  estime la réponse hémodynamique du voxel  $j$  pour le stimulus  $m$ . Dans [3], pour lever l'indétermination de l'échelle, chaque tirage  $\tilde{\mathbf{h}}^{(k)}$  de la loi conditionnelle *a posteriori*  $p(\mathbf{h} | \mathbf{y}, \text{reste})$  est normalisée pour former l'échantillon courant, *i.e.*,  $\mathbf{h}^{(k)} = \tilde{\mathbf{h}}^{(k)} / \|\tilde{\mathbf{h}}^{(k)}\|$ . Comme souligné dans [1], cette solution n'est pas satisfaisante théoriquement, car la convergence vers la loi cible n'est plus garantie. Pour assurer à la fois la convergence et la rapidité de l'algorithme, les auteurs de [1] proposent d'insérer une étape de rééchantillonnage de l'échelle intrinsèque au problème au sein de l'algorithme de Gibbs.

### 3.3 Rééchantillonnage de l'échelle $s$

Cette nouvelle étape s'écrit sur les quantités aléatoires :  $[\mathbf{a}^{\text{new}}, \boldsymbol{\mu}_1^{\text{new}}] = [\mathbf{a}^{\text{old}}, \boldsymbol{\mu}_1^{\text{old}}]/s$  et  $\mathbf{h}^{\text{new}} = \mathbf{h}^{\text{old}} \times s$ , où  $s$  est le paramètre d'échelle qui est lui-même échantillonné à chaque itération du schéma MCMC. Contrairement aux cas détaillés dans [1], nous introduisons dans le changement de variables les moyennes non nulles  $\boldsymbol{\mu}_1$  des classes des voxels activés. L'application directe des principes exposés en [1, § 3] permet d'obtenir à partir de (3) l'expression de la loi conditionnelle *a posteriori* de  $s$  :

$$\begin{aligned} f_S(s | \text{reste}) &= |s|^{P-2-M(J+1)} f\left(\frac{\mathbf{a}^{\text{old}}}{s}, \frac{\boldsymbol{\mu}_1^{\text{old}}}{s}, s\mathbf{h}^{\text{old}} | \mathbf{q}, \boldsymbol{\Theta}\right) \\ &\propto |s|^{P-2-M(J+1)} \exp\left(-\frac{s^2(\mathbf{h}^{\text{old}})^t \mathbf{R}^{-1} \mathbf{h}^{\text{old}}}{2\sigma_h^2}\right) \\ &\quad p\left(\frac{\boldsymbol{\mu}_1^{\text{old}}}{s}\right) \prod_{j=1}^J \mathcal{N}\left(\frac{\mathbf{a}_j^{\text{old}}}{s} \mid \frac{\boldsymbol{\mu}_{q_j}^{\text{old}}}{s}, \mathbf{v}_{q_j}\right) \end{aligned} \quad (4)$$

où  $(\boldsymbol{\mu}_{q_j}^{\text{old}}, \mathbf{v}_{q_j})$  sont des vecteurs rassemblant les moyennes  $(\boldsymbol{\mu}_{q_j^m}^{\text{old}})_{m=1:M}$  et les variances  $(v_{q_j^m})_{m=1:M}$  pour tous les types de stimuli. Il est intéressant de constater que la loi de  $s$  explicitée en (4) ne dépend pas des données  $\mathbf{y}$ . On retrouve l'ambiguïté d'échelle inhérente au modèle d'observation bilinéaire. Dès lors, on déduit de (4) que  $s^2$  suit une loi *Inverse Gaussienne Généralisée* [7, 1], notée  $GIG(\lambda, \alpha, \beta)$  où

$$\lambda = (P - M(J + 1))/2, \quad \alpha = (\mathbf{h}^{\text{old}})^t \mathbf{R}^{-1} \mathbf{h}^{\text{old}} / \sigma_h^2,$$

$$\beta = \frac{\|\boldsymbol{\mu}^{\text{old}}\|^2}{2\sigma_\mu^2} + \sum_{j=1}^J (\mathbf{a}_j^{\text{old}})^t \Sigma_j^{-1} \mathbf{a}_j^{\text{old}} \text{ avec } \Sigma_j = \text{diag}_M[v_{q_j^m}]$$

Des méthodes efficaces de simulation de la loi  $GIG$  s'appuient sur le principe d'acceptation-rejet.

### 3.4 Nouveau schéma d'échantillonnage

L'algorithme global de simulation des réalisations de la loi *a posteriori* (3) devient donc :

1. Simuler  $\mathbf{q}^{(k)}$  puis  $(\mathbf{a}^{\text{old}} | \mathbf{q}^{(k)})$  sachant que  $a_j^m \sim \sum_{i=0}^1 \lambda_{i,j}^m \mathcal{N}(\mu_{i,j}^m; v_{i,j}^m), \forall j, m$  : cf. [3] pour les expressions de  $(\lambda_{i,j}^m, \mu_{i,j}^m, v_{i,j}^m)$ ;
2. Simuler  $\mathbf{h}^{\text{old}}$  selon  $\mathcal{N}(\boldsymbol{\mu}_h, \boldsymbol{\Sigma}_h)$  : cf. [3];
3. Échantillonner les dérivées  $(\ell_j)_j$  et les hyperparamètres  $\boldsymbol{\Theta}$  notamment  $\boldsymbol{\mu}_1^{\text{old}}$  : cf. [3];
4. Simuler  $(s^2)^{(k)}$  selon la loi  $GIG(\lambda, \alpha, \beta)$ , puis en prendre la racine carrée  $s^{(k)}$ ;
5. En déduire  $[\mathbf{a}^{(k)}, \boldsymbol{\mu}_1^{(k)}] = [\mathbf{a}^{\text{old}}, \boldsymbol{\mu}_1^{\text{old}}]/s^{(k)}$  et  $\mathbf{h}^{(k)} = \mathbf{h}^{\text{old}} \times s^{(k)}$ .

## 4 Évaluation des performances

### 4.1 Données simulées

L'ordre des stimuli est généré par permutation aléatoire en mélangeant trente essais de  $M = 2$  types de stimuli. Les intervalles inter-stimuli suivent une distribution

uniforme sur [2.5, 3.5] sec. Les temps d'arrivée des stimuli sont placés sur une grille échantillonnée au pas  $\delta t = 0.5$  sec. Les séquences binaires  $(\mathbf{x}_t^m)_{m=1}^2$  couplées aux conditions  $m = 1, 2$  sont ensuite multipliées par des NRNs variables dans l'espace et à travers les deux conditions expérimentales, simulés selon un modèle de mélange spatial, illustré à la Fig.1 et défini dans [6]. Cette génération passe par la simulation de labels  $\mathbf{q}^m$  issus d'un champ de Ising spécifique à chaque condition  $m$  (voir Fig.1(a)-(b)) pour différencier les voxels activés de ceux inactivés, puis par la génération des NRNs distribuées selon des densités gaussiennes :

$$\begin{aligned} (a_j^1 | q_j^1 = 0) &\sim \mathcal{N}(0, .3), & (a_j^1 | q_j^1 = 1) &\sim \mathcal{N}(1.5, .5), \\ (a_j^2 | q_j^2 = 0) &\sim \mathcal{N}(0, .6), & (a_j^2 | q_j^2 = 1) &\sim \mathcal{N}(1, .5). \end{aligned}$$

Puisque  $\mu_{1,2} < \mu_{1,1}$ , la condition expérimentale  $m = 2$  correspond à un plus faible rapport signal à bruit (RSB). La Fig. 1(c)-(d) illustre l'impact de la corrélation spatiale des probabilités d'activation  $\mathbf{q}^m$  sur les cartes de NRNs.




FIG. 1 – Cartes simulées de labels (a)-(b) et de NRNs (c)-(d) pour  $m = 1$  (a)-(b) et  $m = 2$  (c)-(d).

Le signal de chaque voxel  $\sum_m a_j^m \mathbf{X}^m$  est ensuite convolué avec une FRH de forme spécifiée en Fig.2(a) en couleur mauve. Deux termes de dérive basse fréquence et de bruit AR(1) sont ensuite ajoutés dans chaque voxel  $V_j$  selon le modèle génératif (1) pour former  $\mathbf{y}_j$ . La variance du bruit et la tendance basse fréquence ont été choisies pour cibler un RSB réaliste de 3dB environ.

### 4.2 Résultats

La Fig.2 met en évidence sur la forme de la FRH estimée l'impact des trois stratégies d'échantillonnage visitées, à savoir (a) : le schéma standard sans contrainte ni échelle, (b) : l'ajout d'une contrainte de norme unitaire sur  $\mathbf{h}$ , et (c) : l'échantillonnage de l'échelle intrinsèque  $s$ . L'apport de l'approche (c) est illustré en Fig.2(c). L'estimée  $\hat{\mathbf{h}}^{\text{PM}}$  ainsi construite converge plus vite et plus précisément vers la vraie FRH, que celles issues des stratégies (a)-(b) décrites en Fig.2(a)-(b). Le fait d'obtenir une solution  $\hat{\mathbf{h}}^{\text{PM}}$  pour le schéma (b) moins bonne que pour la version standard s'explique par le fait que la vraie FRH n'est pas de

norme unitaire. Néanmoins, l'approche contrainte (b) rétablit un niveau de signal utile  $\sum_m a_j^m \mathbf{X}^m$  comparable à celui de la solution standard car les moyennes *a priori* estimées  $\hat{\boldsymbol{\mu}}_1^{\text{PM}}$  dans (b) pour les voxels activés sont bien supérieures aux vraies moyennes  $\boldsymbol{\mu}_1$ . La Fig.3(b)-(e) montre cet effet de contre-balancier pour les deux types de stimulus.

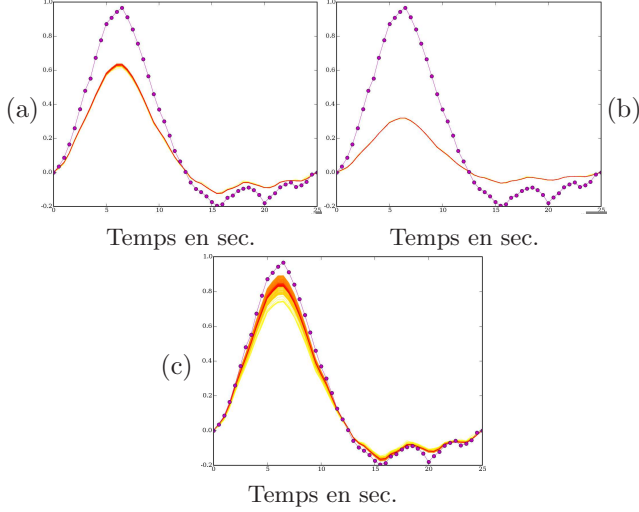


FIG. 2 – FRH estimées  $\hat{\mathbf{h}}^{\text{PM}}$  en rouge selon les schémas MCMC : standard (a), normalisation (b)-(e) et échelle (c).

Outre l'apport de l'échantillonnage de l'échelle sur la convergence de  $\hat{\mathbf{h}}^{\text{PM}}$ , l'approche (c) induit une convergence plus rapide des moyennes *a priori* estimées  $\hat{\boldsymbol{\mu}}_1^{\text{PM}}$  vers les vraies valeurs utilisées pour générer les NRNs des voxels activés comme l'illustre la Fig. 3(c)-(f). Ces courbes mettent en évidence de façon synthétique les différences observables sur les cartes de NRNs produites.




FIG. 3 – Estimées des moyennes *a priori* pour  $m = 1$  (a)-(c) et  $m = 2$  (d)-(f) selon les schémas MCMC : standard (a)-(d), normalisation (b)-(e) et échelle (c)-(f).

Enfin, l'impact du schéma MCMC sur les cartes de détection, dans leur forme probabiliste  $\hat{\mathbf{q}}^{\text{PM}}$  ou segmentée  $\hat{\mathbf{q}}^{\text{MAP}}$ , semble négligeable. Quel que soit l'approche, les estimateurs convergent vers les résultats illustrés en Fig. 4(a)-(b) et Fig. 4(c)-(d) pour les condition  $m = 1$  et  $m = 2$ , respectivement.




FIG. 4 – (a)-(c) : (a)-(c) : Cartes de probabilité de détection  $\hat{\mathbf{q}}^{\text{PM}}$  pour les deux conditions expérimentales. (b)-(d) : versions seuillées au sens du maximum *a posteriori*  $\hat{\mathbf{q}}^{\text{MAP}}$ .

## 5 Conclusion

Dans cet article, nous avons démontré sur des simulations réalistes l'apport de l'approche [1] visant à introduire une étape de rééchantillonnage d'un paramètre d'échelle intrinsèque dans le schéma MCMC pour résoudre le problème de détection-estimation conjointe de l'activité cérébrale en IRMF.

## Références

- [1] T. Veit et J. Idier, « Rééchantillonnage de l'échelle dans les algorithmes MCMC pour les problèmes inverses bilinéaires », in 21<sup>e</sup> GRETSI, sep. 2007, Id 375.
- [2] S. Makni, P. Ciuciu, J. Idier et J.-B. Poline, « Joint detection-estimation of brain activity in functional MRI : a multichannel deconvolution solution », *IEEE Trans. Sig. Proc.*, vol. 53(9), pp. 3488-, sep. 2005.
- [3] S. Makni, P. Ciuciu, J. Idier et J.-B. Poline, « Joint detection-estimation of brain activity in fMRI using an autoregressive noise model », in 3<sup>th</sup> Proc. IEEE ISBI, Arlington, VA, USA, 2006, pp. 1048–1051.
- [4] B. Thirion, G. Flandin, A. Roche, P. Ciuciu et J.-B. Poline, « Dealing with the shortcomings of spatial normalization : Multi-subject parcellation of fMRI datasets », *Hum. Brain Mapp.*, vol. 27, pp. 678-, 2006.
- [5] S. M. Kay, *Modern Spectral Estimation*, Prentice-Hall, Englewood Cliffs, NJ, USA, 1988.
- [6] T. Vincent, P. Ciuciu et J. Idier, « Spatial mixture modelling for the joint detection-estimation of brain activity in fMRI », in 32<sup>th</sup> Proc. IEEE ICASSP, Honolulu, Hawaii, USA, avr. 2007, vol. I, pp. 325–328.
- [7] H. Snoussi et J. Idier, « Bayesian blind separation of generalized hyperbolic processes in noisy and underdetermined mixtures », *IEEE Trans. Sig. Proc.*, vol. 54(9), pp. 3257-, sep. 2006.