

# Modélisation de l’habituation neurovasculaire de l’activité cérébrale en IRMf

Philippe CIUCIU<sup>1</sup>, Stéphane SOCKEEL<sup>2</sup>, Jérôme IDIER<sup>3</sup> et Thomas VINCENT<sup>1</sup>,

<sup>1</sup>NeuroSpin/CEA, 91191 Gif-sur-Yvette cedex, France

<sup>2</sup>unité INSERM U678, Pitié-Salpêtrière, 91 Bd de l’Hôpital, 75634 Paris cedex 13, France

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

philippe.ciuciu@cea.fr, stephane.sockeel@imed.jussieu.fr

Jerome.Idier@irccyn.ec-nantes.fr, thomas.vincent@cea.fr

**Résumé** – Un modèle non stationnaire du signal IRMf est proposé afin de prendre en compte des effets d’habituation apparaissant dans les paradigmes événementiels s’appuyant sur le phénomène de « suppression à la répétition ». Ce modèle autorise des amplitudes de la réponse BOLD variables à travers les occurrences du même stimulus et s’intègre dans le cadre de la détection estimation conjointe de l’activité cérébrale. Des cartes d’activation et d’habituation sont ainsi estimées conjointement au Filtre Hémodynamique (FH) dans le formalisme bayésien au sein d’une procédure non supervisée d’échantillonnage stochastique. Sur données simulées, nous illustrons que le modèle proposé surclasse le modèle stationnaire et que les paramètres d’habituation peuvent être précisément estimés au sein de voxels activés.

**Abstract** – A non-stationary model of fMRI time series is proposed in order to account for some habituation effect that may arise in event-related paradigms involving the so-called “repetition-suppression” phenomenon. This model enables trial-varying magnitudes of the BOLD response and takes place in the joint detection-estimation framework. Habituation and activation maps are thus estimated together with the hemodynamic filter within the Bayesian framework in an unsupervised sampling procedure. On artificial fMRI datasets, we show first that the proposed model outperforms the stationary one and second that habituation effects can be accurately recovered together with activation.

## 1 Introduction

L’analyse intra-sujet des données d’Imagerie par Résonance Magnétique fonctionnelle (IRMf) consiste à détecter les aires cérébrales impliquées dans une stimulation expérimentale (auditive, visuelle, ...) et à estimer la dynamique temporelle des activations. Une approche de détection-estimation a été proposée dans [1] pour aborder conjointement ces deux problèmes, par une analyse régionale où chaque région est fonctionnellement homogène. Une forme de filtre neurovasculaire est alors estimée par région, tout en introduisant une spécificité de l’activité en chaque voxel et pour chaque condition expérimentale à travers un facteur de modulation, appelé *amplitude neurale*. Afin de distinguer les voxels *activés* et *inactivés*, un modèle de mélange a été introduit par condition expérimentale. Dans [2], l’ajout d’un modèle de corrélation spatiale a permis d’optimiser le compromis sensibilité/spécificité de détection. Les derniers travaux menés dans [3] ont permis de rendre non supervisée et spatialement adaptative cette régularisation spatiale.

Alors que les travaux [1, 2] considèrent l’amplitude neurale constante au cours des différents *essais* de chaque type

de stimulus, nous proposons ici une extension non stationnaire pour prendre en compte, de façon simple, sa variabilité *inter-essais*. Cette approche répond aux besoins issus de l’analyse de nouveaux protocoles cognitifs en IRMf. La présentation répétée de stimuli identiques peut générer un phénomène de *suppression à la répétition* du stimulus dans certaines régions cérébrales [4]. L’amplitude neurale peut alors décroître au fur et à mesure des répétitions.

Dans la suite, nous présentons le modèle génératif reliant les signaux observés en IRMf et les inconnues du problème, puis l’extension *non linéaire* proposée afin de modéliser l’habituation. Nous détaillons ensuite l’algorithme d’échantillonnage stochastique pour inférer les paramètres du modèle. Enfin, nous validons l’approche proposée sur données synthétiques.

## 2 Détection-estimation en IRMf

### 2.1 Modèle stationnaire du signal BOLD

Le modèle Blood Oxygen Level Dependent (BOLD) introduit dans [1] considère une décomposition du masque du cerveau en régions fonctionnellement homogènes  $(\Gamma_r)_{r=1:R}$

où typiquement  $R = 300$ . Dans chaque région  $\Gamma_r$  (composée de  $J_r$  voxels,  $80 \leq J_r \leq 400$ ), une seule forme de FH  $\mathbf{h}$  est modélisée afin de prendre en compte la variabilité spatiale du système neurovasculaire. Nous autorisons au sein de  $\Gamma_r$  des fluctuations en amplitude (voxel à voxel et d'un stimulus à l'autre) du signal BOLD évoqué par une stimulation, amplitude baptisée *Niveau de Réponse Neuronale* (NRN) et notée  $a_j^m$  pour le voxel  $j$  et le stimulus  $m$ .

$$\mathbf{y}_j = \sum_{m=1}^M a_j^m \mathbf{X}^m \mathbf{h} + \mathbf{P} \ell_j + \mathbf{b}_j, \forall j = 1 : J_r \quad (1)$$

où  $\mathbf{y}_j = (y_j(t_n))_{n=1:N}$  dénote le signal IRMF mesuré dans le voxel  $j$  aux instants  $t_n = n\text{TR}$  avec  $N$  le nombre de scans dans une session et TR le temps de répétition. Dans (1),  $M$  désigne le nombre total de types de stimuli et  $\mathbf{h} = (h_{d\Delta t})_{d=0:D}$  est un filtre RIF échantillonné sur une grille plus fine que celle des données ( $\Delta t < \text{TR}$ ). La matrice binaire  $\mathbf{X}^m = (x_{n-d\Delta t}^m)_{n=1:N, d=0:D}$  de dimensions  $N \times (D+1)$  définit les occurrences des stimuli de type  $m$ . Ainsi, la réponse BOLD au stimulus de type  $m$  dans le voxel  $j$  de la région  $\Gamma_r$  est donné par  $\mathbf{s}_j^m = a_j^m \mathbf{X}^m \mathbf{h}$ . La matrice  $\mathbf{P}$  définit une base de basses fréquences sur laquelle le vecteur  $\ell_j$  modélise la quantité de dérives. Le bruit  $\mathbf{b}_j \in \mathbb{R}^N$  suit un modèle AR(1) gaussien :  $\mathbf{b}_j \sim \mathcal{N}(\mathbf{0}, \sigma_j^2 \mathbf{\Lambda}_j^{-1})$  où  $\mathbf{\Lambda}_j$  dépend du paramètre AR  $\rho_j$  ( $|\rho_j| < 1$ ) [1].

## 2.2 Modèle paramétrique d'habituation

Le modèle (1) suppose que chaque *essai*  $k$  du stimulus de type  $m$  évoque le même signal BOLD. Des travaux récents ont mis en évidence les limites de cette modélisation [5, 6]. Ici, nous développons une extension de (1) qui tient compte d'une variabilité *inter-essais* de l'amplitude du signal BOLD évoqué, mais de forme constante. Par rapport à [6], notre modèle introduit une relation déterministe entre les amplitudes des différents essais. Il s'appuie sur un paramètre normalisé d'habituation moyenne à travers les essais  $r_{jm} \in [0, 1]$  en chaque voxel  $j$  et pour chaque condition  $m$ , qui introduit une relation *paramétrique* entre les NRNs  $a_{jk}^m$ . De plus, ce modèle hyperbolique est conçu pour imiter les effets de suppression à la répétition, autorisant ainsi les NRNs à décroître à travers les  $K_m$  essais. Toutefois, la Fig. 1 illustre aussi d'autres comportements. Une propriété clé de ce modèle réside dans sa capacité à oublier progressivement les événements du passé, comme l'illustre sa dépendance vis-à-vis du paradigme :

$$k \geq 2, \mathbf{a}_{jk}^m = \gamma_{jk}^m \mathbf{a}_{j1}^m \text{ où } \gamma_{jk}^m = \left( 1 + \sum_{\ell=1}^{k-1} \mathbf{a}_{j\ell}^m r_{jm}^{\delta_\ell^m} \right)^{-1} \quad (2)$$

où  $\delta_\ell^m = \tau_{\ell+1}^m - \tau_\ell^m$  et  $(\tau_\ell^m)_\ell$  définissent les intervalles inter-stimuli (IIS) successifs et les temps d'occurrence du  $m^e$  stimulus. Le signal BOLD dans l'Eq. (1) devient :

$$\mathbf{s}_j^m = \sum_{k=1}^{K_m} a_{jk}^m \mathbf{X}_k^m \mathbf{h} = a_{j1}^m \widetilde{\mathbf{X}}_j^m \mathbf{h} \text{ où } \widetilde{\mathbf{X}}_j^m = \sum_{k=1}^{K_m} \gamma_{jk}^m \mathbf{X}_k^m, \quad (3)$$




FIG. 1 – Effet d'habituation sur les amplitudes  $a_{jk}^m$  du signal BOLD dans trois voxels différents : habitude  $r_{jm}^m$  nulle (rouge), moyenne (bleue) et grande (verte).

où  $\gamma_{j1}^m = 1$  et  $\mathbf{X}_k^m$  est la  $k^e$  sous-matrice d'occurrence issue de  $\mathbf{X}^m$ . Le modèle consécutif régional du signal IRMF est décrit Fig. 2. Il indique clairement que la vitesse d'habituation peut varier dans l'espace et à travers les types de stimuli. Comme attendu, quand  $r_{jm} \rightarrow 0$ , l'extension proposée retrouve un régime stationnaire puisque  $a_{jk}^m \rightarrow a_{j1}^m$ ,  $\forall k \geq 2$  (en rouge Fig. 1(a)). Quand  $r_{jm} \in (0, 1)$ , la séquence  $(a_{jk}^m)_k$  est non-monotone et la variabilité inter-essais est fortement influencée par les IIS  $\delta_\ell^m$  (en bleu Fig. 1(a)). Enfin, quand  $r_{jm} \rightarrow 1$ , la séquence  $(a_{jk}^m)_k \rightarrow 0, \forall \delta_\ell^m$ , comme illustré en vert Fig. 1.




FIG. 2 – Modèle régional non-stationnaire prenant en compte les effets d'habituation neuro-vasculaire.

## 2.3 Vraisemblance

Contrairement à [7], nous négligeons la corrélation spatiale du bruit et considérons les signaux  $\mathbf{y} = (\mathbf{y}_j)_{j=1:J_r}$  au sein de  $\Gamma_r$  indépendants mais non iid :

$$p(\mathbf{y} | \mathbf{h}, \mathbf{a}_1, \mathbf{r}, \mathbf{l}, \boldsymbol{\theta}_0) \propto \prod_{j=1}^{J_r} \det \mathbf{\Lambda}_j^{1/2} \sigma_j^{-N} \exp\left(-\frac{\tilde{\mathbf{y}}_j^t \mathbf{\Lambda}_j \tilde{\mathbf{y}}_j}{2\sigma_j^2}\right),$$

où  $\mathbf{l} = (\ell_j)_{j=1:J_r}$ ,  $\boldsymbol{\theta}_0 = (\rho_j, \sigma_j^2)_{j=1:J_r}$  et  $\tilde{\mathbf{y}}_j = \mathbf{y}_j - \sum_m \mathbf{s}_j^m - \mathbf{P} \ell_j$ . Ici,  $\mathbf{a}_1$  et  $\mathbf{r}$  font respectivement référence aux NRNs des premiers essais et aux vitesses d'habituation.

## 2.4 Loix a priori

Ici, nous faisons les mêmes choix que dans [2] pour les lois *a priori* sur les paramètres inconnus  $(\mathbf{h}, \mathbf{a}_1)$  afin de re-

construire précisément la carte de l'activité cérébrale ( $\mathbf{a}_1$ ) et la dynamique sous-jacente ( $\mathbf{h}$ ). L'originalité réside dans la définition d'un *a priori* conjoint sur les NRNs  $\mathbf{a}_1$  et les vitesses d'habituation  $\mathbf{r}$ .

L'indépendance entre stimuli conduit à  $p(\mathbf{a}_1, \mathbf{r} | \boldsymbol{\theta}_a) = \prod_m p(\mathbf{a}_1^m, \mathbf{r}^m | \boldsymbol{\theta}^m)$  où  $(\mathbf{a}_1, \mathbf{r}) = (\mathbf{a}_1^m, \mathbf{r}^m)_{m=1}^M$ ,  $(\mathbf{a}_1^m, \mathbf{r}^m) = (a_{j1}^m, r_j^m)_{j=1:J_r}$  et  $\boldsymbol{\theta}_a = (\boldsymbol{\theta}^m)_{m=1}^M$ . Le vecteur  $\boldsymbol{\theta}^m$  rassemble les hyperparamètres inconnus reliés au  $m^e$  stimulus. Comme dans [2], nous utilisons des modèles de mélange spatial à variables latentes :  $q_j^m$  établit si le voxel  $j$  est activé sous l'action du stimulus  $m$  ( $q_j^m = 1$ ) ou pas ( $q_j^m = 0$ ). La probabilité d'activation  $\Pr(q_j^m = 1)$  dépend des variables voisines  $q_p^m$  à travers un champ de Ising  $\Pr(\mathbf{q}^m | \beta^m)$ .

Les variables  $(\mathbf{a}_1^m, \mathbf{r}^m)$  restent indépendantes conditionnellement à  $\mathbf{q}^m$  :  $p(\mathbf{a}_1^m, \mathbf{r}^m | \mathbf{q}^m, \boldsymbol{\theta}^m) = \prod_j p(a_{j1}^m, r_j^m | q_j^m, \boldsymbol{\theta}^m) \forall m$  où  $p(a_{j1}^m, r_j^m | q_j^m, \boldsymbol{\theta}^m) = p(a_{j1}^m | q_j^m, \boldsymbol{\theta}^m) p(r_j^m | q_j^m, \boldsymbol{\theta}^m)$ . D'après [2], les NRNs  $\mathbf{a}_1^m$  suivent un mélange gaussien à deux classes :  $a_{j1}^m | q_j^m = i \sim f_{i,m} \equiv \mathcal{N}(\mu_{i,m}, v_{i,m})$ , avec  $i = 0, 1$ . La moyenne des NRNs dans les voxels inactivés est centrée ( $\mu_{0,m} = 0$ ), alors que  $\boldsymbol{\theta}^m = [v_{0,m}, \mu_{1,m}, v_{1,m}]$  doit être estimé. Ici, les vitesses  $\mathbf{r}^m$  sont contraintes à zéro dans les voxels inactivés :  $r_j^m = 0 | q_j^m = 0$ . A l'inverse, pour les voxels activés, les vitesses  $\mathbf{r}^m$  sont supposées indépendantes et uniformément distribuées :  $(r_j^m | q_j^m = 1) \sim \mathcal{U}([0, 1])$ . Le mélange *a priori* s'écrit :

$$p(\mathbf{a}_1^m, \mathbf{r}^m | \boldsymbol{\theta}^m) = \sum_{\mathbf{q}^m} \left( \prod_{j=1}^{J_r} f_{i,m}(a_{j1}^m) p_i(r_j^m) \right) \Pr(\mathbf{q}^m | \beta^m).$$

Les paramètres reliés au bruit et aux dérives ( $\rho_j, \sigma_j^2, \ell_j$ ) <sub>$j$</sub>  sont supposés indépendants spatialement et distribués selon  $\ell_j \sim \mathcal{N}(\mathbf{0}, \sigma_\ell^2 \mathbf{I}_Q)$ ,  $p(\rho_j, \sigma_j^2) = \sigma_j^{-1} \mathbb{1}_{(-1,1)}(\rho_j)$ . Des lois conjuguées sont choisies pour  $\boldsymbol{\theta}^m$  et des *a priori* de Jeffreys sont introduits pour les variances ( $\sigma_h^2, \sigma_\ell^2$ ).

## 2.5 Inférence bayésienne

La règle de Bayes donne la loi *a posteriori* suivante :

$$p(\mathbf{h}, \mathbf{a}_1, \mathbf{r}, \mathbb{1}, \boldsymbol{\Theta} | \mathbf{y}) \propto \sigma_h^{-D} \sigma_\ell^{-JQ} \prod_{j=1}^{J_r} \frac{\sqrt{1 - \rho_j^2}}{\sigma_j^{N+1}} \mathbb{1}_{(-1,1)}(\rho_j) \exp\left(-\sum_{j=1}^{J_r} \left( \frac{1}{2\sigma_j^2} \tilde{\mathbf{y}}_j^t \boldsymbol{\Lambda}_j \tilde{\mathbf{y}}_j + \frac{1}{2\sigma_\ell^2} \|\ell_j\|^2 \right)\right) \exp\left(-\frac{\mathbf{h}^t \mathbf{R}^{-1} \mathbf{h}}{2\sigma_h^2}\right) \prod_{m=1}^M p(\mathbf{a}_1^m, \mathbf{r}^m | \boldsymbol{\theta}^m) p(\boldsymbol{\theta}^m).$$

La simulation de  $p(\mathbf{h}, \mathbf{a}_1, \mathbf{r}, \mathbb{1}, \boldsymbol{\Theta} | \mathbf{y})$  est réalisée à l'aide d'un échantillonneur de Gibbs. Ici, la loi conditionnelle *a posteriori* de  $r_j^m$  s'écrit  $\pi_1^*(r_j^m) = p(r_j^m | \mathbf{y}_j, q_j^m = 1, \dots)$  :

$$\pi_1^*(r_j^m) \propto \exp(-\|\mathbf{y}_j - C_{j \setminus m} - \mathbf{s}_j^m\|_{\boldsymbol{\Lambda}_j}^2 / 2\sigma_j^2) \mathcal{U}_{(0,1)}(r_j^m),$$

où  $\mathbf{s}_j^m$  dépend de  $r_j^m$  et  $C_{j \setminus m} = \mathbf{P}\ell_j - \sum_{n \neq m} \mathbf{s}_n^j$  est indépendant de  $r_j^m$ . Cette loi n'étant pas simulable directement, nous insérons une étape de Metropolis avec pour loi

instrumentale la densité  $f(r|r_0) = Z_{\beta, r_0}^{-1} e^{-\beta|r-r_0|} \mathbb{1}_{[0,1]}(r)$ , où  $r_0 = r_j^{m,(t-1)}$ . A l'itération  $t$ , le rapport d'acceptation vaut  $\alpha(r_0; r) = \min[1, \frac{\pi_1^*(r)}{\pi_1^*(r_0)} \frac{Z_{\beta, r_0}}{Z_{\beta, r}}]$  nécessitant la génération des NRNs à l'aide de (2) aux habituations  $r$  et  $r_0$ . Finalement, des estimées au sens de la moyenne *a posteriori* (MP) sont calculées pour chacune des inconnues à partir des échantillons générés au delà d'une période de chauffe de  $I$  itérations. La détection est réalisée au sens du MAP marginal :  $(\hat{q}_j^m)^{\text{MAP}} = \arg \max_i \Pr(q_j^m = i | \mathbf{y}_j)$ . L'estimée des vitesses d'habituation s'obtient comme suit :  $\forall j, m | (\hat{q}_j^m)^{\text{MAP}} = 0 \Rightarrow \hat{r}_j^m = 0$  ou si  $(\hat{q}_j^m)^{\text{MAP}} = 1$ ,  $(\hat{r}_j^m)^{\text{MP}} = \sum_k^K q_j^{(k),m} r_j^{m,(k)}$ .

## 3 Résultats de simulation

Des signaux IRMF synthétiques ont été générés selon le modèle (1). Une séquence aléatoire codant deux types de stimuli ( $M = 2$ ) répétés chacun au cours des  $K_m = 30$  essais définit les instants des stimuli. Les signaux  $\mathbf{s}_j^m$  ont été simulés selon (2)-(3) à l'aide des mêmes paramètres  $\boldsymbol{\theta}^m$  pour générer  $\mathbf{a}$  :  $(\mu_{1,m}, v_{1,m}, v_{0,m}) = (5; 0, 3, 0, 1)$ ,  $\forall m$ , conduisant au même rapport signal à bruit (RSB) pour les deux stimuli. Du bruit AR(1) gaussien  $\mathbf{b}_j$  ( $|\rho_j| < 0, 4$ ) et des dérives basse fréquence  $\mathbf{P}\ell_j$  où  $\ell_j \sim \mathcal{N}(\mathbf{0}, 2\mathbf{I}_Q)$  ont été ajoutés au signal BOLD pour chaque voxel. Une première simulation compare les performances du modèle stationnaire à celles de l'extension proposée. Elle est réalisée sur un modèle plus simple *i.e.*, sans corrélation spatiale comme dans [1]. La seconde simulation répond exactement au modèle présenté.

Nous ne présentons des résultats que pour  $m = 1$  obtenus en  $10^3$  itérations ( $I = 500$ ). La Fig. 3(a) décrit les vrais NRNs  $\mathbf{a}_1^1$  et leurs estimées par les modèles stationnaire (en  $\circ$ ) ou non (en  $\odot$ ). En présence d'habituation, le modèle proposé surpasse la version stationnaire pour l'estimation de  $\hat{\mathbf{a}}_1^1$ . Le modèle stationnaire sous-estime en effet les NRNs en raison du moyennage implicite des amplitudes à travers les essais. Ceci est particulièrement apparent dans les voxels où  $r_j^m \geq 0, 4$ . Les deux méthodes identifient sans erreur les voxels activés en raison d'un RSB favorable et les paramètres d'habituation sont bien restaurés par le modèle proposé comme illustré Fig. 3(b).

Les vrais paramètres ( $\mathbf{a}_1, \mathbf{r}, \mathbf{q}, \mathbf{h}$ ) définissant les mélanges *a priori* composites et la FH sont décrits en Fig. 4 (haut). Les voxels activés et inactivés apparaissent respectivement en **rouge** et **noir**. La quantité de bruit varie dans l'espace selon un RSB  $\in [-10; 12]$  dB, obtenant ainsi une situation réaliste par rapport aux données réelles. La Fig. 4 ne montre que les résultats pour  $m = 1$ .

Après 2000 itérations ( $I = 10^3$ ), l'algorithme fournit des estimées ( $\hat{\mathbf{a}}_1^1, \hat{\mathbf{r}}^1, \hat{\mathbf{h}}$ ) très proches des vrais valeurs, notamment dans les voxels activés. Un seul voxel apparaît mal étiqueté en position (4, 0) : il s'agit d'un faux né-

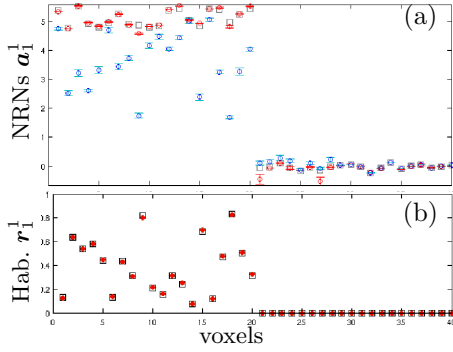


FIG. 3 – (a) : NRNs  $a_1^1$  : vraies valeurs en  $\square$ , estimées  $\hat{a}_1^1$  en  $\circ$  et  $\circ$  fournies par les modèles stationnaire ou non. (b) : labels  $q^1$ . (c) : vitesses d’habituations estimées  $\hat{r}_1^1$ .

gatif dont la conséquence est une estimation erronée de  $r_{(4,0)}^1$  car les voxels inactivés sont « stationnaires ». Dans ce cas,  $a_{(4,0)}^1$  est aussi mal estimé car tiré selon la mauvaise composante du mélange *a posteriori*. Cette erreur tient à la présence d’une forte vitesse d’habituations ( $r_{(4,0)}^1 \approx 1$ ). La Fig. 4 montre aussi que les vitesses d’habituations sont également bien restaurées par  $\hat{r}^{\text{MP}}$ . La Fig. 5 illustre le profil des NRNs essai à essai  $\hat{a}_{jk}^1$  pour deux voxels d’habituations différentes. La Fig. 5(a) montre qu’une faible habitude n’affecte pas l’hypothèse de stationnarité tandis que la Fig. 5(b) souligne qu’une habitude autour de 0,5 induit une décroissance rapide du NRN particulièrement importante pour des essais proches.

## 4 Conclusion

Cette contribution permet d’appréhender la variabilité de l’amplitude de la réponse BOLD à travers les essais d’un stimulus en adoptant un modèle d’habituations hy-




FIG. 4 – En haut : vrais paramètres sur une grille  $5 \times 5$ . En bas, estimées au sens de la MP.

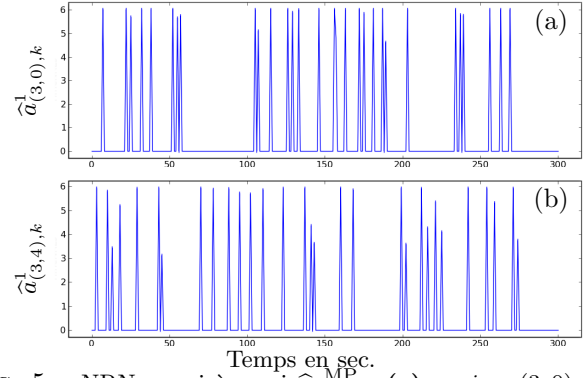


FIG. 5 – NRNs essai à essai  $\hat{a}_1^{\text{MP}}$  : (a) en  $j = (3,0)$  pour  $\hat{r}_{(3,0)}^1 = 0.29$  et (b) :  $m = 2, V_j = (3,4)$  avec  $\hat{r}_{(3,4)}^2 = 0.42$ .

perbolique simple. D’autres choix paramétriques peuvent être envisagés. La dépendance vis-à-vis des IIS peut également être remise en cause notamment s’ils sont tous identiques. L’algorithme a été validé sur des données simulées en conditions réalistes de RSB. Le modèle proposé s’avère plus puissant que l’alternative stationnaire en cas d’habituations évidente. Nos perspectives concernent la validation sur données réelles notamment dans le sillon temporal supérieur gauche, siège du langage.

## Références

- [1] S. Makni, J. Idier, T. Vincent, B. Thirion, G. Dehaene-Lambertz et P. Ciuciu, « A fully Bayesian approach to the parcel-based detection-estimation of brain activity in fMRI », *Neuroimage*, vol. 41, 3, pp. 941–969, juil. 2008.
- [2] T. Vincent, P. Ciuciu et J. Idier, « Spatial mixture modelling for the joint detection-estimation of brain activity in fMRI », in *32th Proc. IEEE ICASSP*, Honolulu, Hawaii, USA, avr. 2007, vol. I, pp. 325–328.
- [3] L. Risser, T. Vincent, P. Ciuciu et J. Idier, « Robust extrapolation scheme for fast estimation of 3D Ising field partition functions. application to within-subject fMRI data analysis », à paraître dans MICCAI’09, juin 2009.
- [4] G. Dehaene-Lambertz, S. Dehaene, J.-L. Anton, A. Campagne, P. Ciuciu, G. P. Dehaene, I. Denghien, A. Jobert, D. Le Bihan, M. Sigman, C. Pallier et J.-B. Poline, « Functional segregation of cortical language areas by sentence repetition », *Hum. Brain Mapp.*, vol. 27, pp. 360–371, 2006.
- [5] J. Duann, T. Jung, W. Kuo, T. Yeh, S. Makeig, H. JC et S. T.J, « Single-trial variability in event-related BOLD signals », *Neuroimage*, vol. 15, 4, pp. 823–35, avr. 2002.
- [6] S. Donnet, M. Lavielle et J.-B. Poline, « Are fMRI event-related response constant in time? A model selection answer », *Neuroimage*, pp. 1169–1176, avr. 2006.
- [7] W. Penny, G. Flandin et N. Trujillo-Bareto, « Bayesian Comparison of Spatially Regularized General Linear Models », *Hum. Brain Mapp.*, vol. 28, 4, pp. 275–293, 2007.
- [8] A. Gelman et X.-L. Meng, « Simulating normalizing constants : from importance sampling to bridge sampling to path sampling », *Stat. Sci.*, vol. 13, pp. 163–185, 1998.