

Détection-estimation conjointe de l'activité cérébrale en imagerie fonctionnelle (IRMf)

Salima MAKNI¹, Philippe CIUCIU¹, Jérôme IDIER², Jean-Baptiste POLINE¹

¹Service Hospitalier Frédéric Joliot (CEA/DSV/DRM)
4 Place du Général Leclerc, 91401 Orsay cedex, France

²IRCCyN (CNRS)
1 rue de la Noë, BP 92101 44321 Nantes cedex 3, France
makni@shfj.cea.fr, ciuciu@shfj.cea.fr,
Jerome.Idier@irccyn.ec-nantes.fr, poline@shfj.cea.fr

Résumé – En imagerie par résonance magnétique fonctionnelle (IRMf), pour une meilleure compréhension des activations cérébrales, deux questions sont classiquement abordées : d'une part, la détection et la localisation de cette activité dans le cerveau humain, et d'autre part l'estimation de la dynamique de la réponse du système vasculaire cérébral. Généralement ces deux aspects sont traités séparément, en supposant une forme de réponse connue pour faire la détection, et en ayant préalablement localisé les zones d'activation pour faire l'estimation. Dans [1], détection et estimation sont abordées conjointement dans une région du cerveau où le bruit est modélisé comme étant la somme d'une dérive basse fréquence et d'un bruit blanc gaussien. Toutefois, il est désormais connu que le bruit présent dans les données IRMf est temporellement corrélé. Dans cette communication, nous étendons l'approche proposée dans [1] en modélisant le bruit comme un processus autoregressif d'ordre 1 variable spatialement. Nous illustrons l'apport de cette modélisation sur données synthétiques et réelles.

Abstract – Analysis of functional Magnetic Resonance Imaging (fMRI) data essentially focuses on two questions: first, a detection problem that studies which parts of the brain are activated by a given stimulus and second, an estimation problem that investigates the temporal dynamic of the brain response during activations. Up to now, these questions have been addressed independently. However, the activated areas need to be known prior to the analysis of the temporal dynamic of the response. On the other hand, a typical shape of the response has to be assumed a priori for detection purpose. This situation motivates the need for new methods in neuroimaging data analysis that are able to go beyond this unsatisfactory trade-off. In [1], a novel detection-estimation approach was proposed to perform these two tasks simultaneously in region-based analysis. In this paper, to deal with the noise modeling in fMRI data, we modelled the noise as the sum of a spatially varying low frequency drift and a random white component. However, it was shown that fMRI time series generally demonstrate serial correlation. To account for this important feature, we propose an extension of [1] that relies on AR(1) noise model and we demonstrate the gain brought by this generalization both on artificial and real data sets.

1 Introduction

Grâce à sa bonne résolution spatiale, l'Imagerie par Résonance Magnétique fonctionnelle (IRMf) permet de cartographier l'activité du cerveau lorsque le sujet sain ou pathologique perçoit un stimulus ou réalise une tâche [3]. Toutefois, sa faible résolution temporelle l'empêche de suivre la dynamique des activations au niveau neuronal. En effet, le couplage entre l'activation des neurones et le système vasculaire, en sortie duquel le signal IRMf est mesuré, introduit un délai hémodynamique et un filtrage passe-bas qu'il convient de caractériser pour tenter d'accéder à une réponse à haute résolution temporelle. Beaucoup d'approches voxeliques ont été proposées pour estimer ce filtre, encore appelé fonction de réponse hémodynamique (FRH) [4, 5]. Dans [4], il a été observé que pour des voxels voisins, la forme de la FRH estimée pour chacun d'entre eux présente une certaine régularité spatiale à un facteur d'échelle près. Ainsi l'introduction d'un facteur d'amplitude (modulation) qui reflèterait la

variabilité du niveau de réponse d'un voxel à un autre, semble une hypothèse justifiée. Dans [1], nous avons proposé d'estimer l'hémodynamique régionale au sein d'un ensemble de voxels d'activité homogène, *i.e.*, d'une région d'intérêt. Il s'agit d'estimer conjointement une *forme* de filtre sur cette région tout en introduisant une spécificité de l'activité en chaque voxel à travers un facteur de modulation, encore appelé *amplitude neurale*. En IRMf, le signal mesuré est composé de trois termes : un terme de signal utile qui est la convolution de la séquence binaire, codant les temps d'arrivée du stimulus, par la FRH, un terme de bruit physiologique (cœur, respiration, mouvement) et finalement une composante de bruit d'acquisition et d'incertitude sur le modèle. Dans [1], nous avons supposé que cette dernière composante est un bruit blanc gaussien variable spatialement. Toutefois, il a été démontré que le bruit IRMf est temporellement corrélé. Dans cette communication, nous présentons donc une variante de [1] qui tient compte de cette caractéristique.

2 Modélisation

2.1 Modèle simplifié

Nous présentons ici une forme simplifiée du problème traité (un seul stimulus) par souci de clarté. Soit $\mathcal{R} = (V_j)_{j=1:J}$ une région d'intérêt supposée fonctionnellement homogène, 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 temps $(t_n = nTR)_{n=1:N}$, où TR désigne le délai entre deux acquisitions successives. Sous l'hypothèse d'un couplage vasculaire cérébral *linéaire* et *invariant* dans le temps, $\mathbf{h} = (h_{d\Delta t})_{d=0:D}$ désigne la réponse impulsionnelle inconnue du système ayant pour entrée la séquence binaire $\mathbf{x} = (x_n)_{n=1:N}$ codant les *temps d'arrivée* du stimulus et pour sortie les données \mathbf{y}_j . Dans [1], nous avons proposé un modèle régional d'activation cérébrale, intégrant une modulation spatiale de l'activité :

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

où $\mathbf{a} = (a_j)_{j=1:J}$ et a_j désigne l'amplitude au voxel j . $\mathbf{X} \in \mathbb{R}^N \times \mathbb{R}^{D+1}$ est la matrice binaire correspondante à la séquence \mathbf{x} . La matrice $\mathbf{P} \in \mathbb{R}^N \times \mathbb{R}^Q$ est une base orthonormée de fonctions (*e.g.*, base de cosinus avec $3 \leq Q \leq 10$), fixée *a priori*, modélisant la dérive basse fréquence présente dans les données, et due au repliement spectral de phénomènes physiologiques (battements cardiaques, respiration). Le vecteur \mathbf{l}_j définit les coefficients de régression sur cette base à estimer conjointement avec (\mathbf{h}, \mathbf{a}) . Enfin, \mathbf{b}_j modélise un terme d'erreurs de modèle et d'acquisition. Comme dans [6, 7], nous considérons un modèle autoregressif de premier ordre (*i.e.*, AR(1)) variable spatialement, $b_{j,t_n} = \rho_j b_{j,t_n-1} + \varepsilon_{j,t_n}$, $\forall j, t$, pour tenir compte de l'autocorrélation temporelle du bruit des données IRMF, et de sa non-stationnarité spatiale avec $\varepsilon_j \sim \mathcal{N}(\mathbf{0}, \sigma_{\varepsilon_j}^2 \mathbf{I}_N)$.

2.2 Détection-estimation conjointe de l'activité fonctionnelle

Nous nous plaçons dans un cadre bayésien où l'approche proposée correspond à une méthode de déconvolution *semi-aveugle* non supervisée qui consiste à estimer conjointement les paramètres d'intérêt (\mathbf{h}, \mathbf{a}) et d'autres paramètres statistiques (du bruit et de l'*a priori*).

2.3 Modèle *a priori*

Afin d'obtenir une estimée de \mathbf{h} suffisamment régulière, on introduit des connaissances *a priori* sur \mathbf{h} sous la forme de contraintes aux bords $h_0 = h_{P\Delta t} = 0$ et d'une distribution $p(\mathbf{h}; \sigma_h^2) \sim \mathcal{N}(\mathbf{0}, \sigma_h^2 \mathbf{R})$, où \mathbf{R} est une matrice de corrélation imposant une contrainte de régularité sur \mathbf{h} . De plus, dans une région d'intérêt donnée du cerveau, seule une partie des voxels peut être activée par le stimulus en question. Afin de prendre en compte cette propriété, on introduit le couple de variables aléatoires $z_j = (q_j, a_j)$, $j = 1:J$, où q_j est une variable binaire indiquant si le voxel V_j est activé ($q_j = 1$) ou non ($q_j = 0$) par le stimulus en question. Conditionnellement à q_j , a_j est une variable aléatoire gaussienne qui représente l'amplitude neurale pour le voxel V_j . Il s'agit donc d'un modèle *a priori* de

mélange gaussien à deux classes : $\lambda \mathcal{N}(\mu_1, \sigma_1^2) + \bar{\lambda} \mathcal{N}(0, \sigma_0^2)$, où $\lambda = Pr(q_j=1)$, $\bar{\lambda} = 1 - \lambda$.

Les coefficients $\boldsymbol{\ell} = [\ell_1^t, \dots, \ell_J^t]^t$ doivent aussi être estimés. Pour cela, on suppose que $\boldsymbol{\ell}$ est un processus aléatoire indépendant de \mathbf{h} tel que $p(\boldsymbol{\ell}; \eta^2) = \prod_j p(\ell_j; \eta^2)$ et $\ell_j \sim \mathcal{N}(\mathbf{0}, \eta^{-2} \mathbf{I}_Q)$. Pour les hyperparamètres $\boldsymbol{\theta} = \{\lambda, \sigma_1^2, \sigma_0^2, \mu_1, \boldsymbol{\rho}, \boldsymbol{\sigma}_{\varepsilon}^2, \eta^2\}$, le recours à des *a priori* non informatifs conduit à :

$$p(\sigma_{\varepsilon}^2) = \prod_j p(\sigma_{\varepsilon_j}^2) = \prod_j \sigma_{\varepsilon_j}^{-2} \quad (2)$$

$$p(\lambda, \mu_1, \sigma_1^2, \sigma_0^2) = \lambda^{1/2} \bar{\lambda}^{1/2} \sigma_1^{-1} \sigma_0^{-1}. \quad (3)$$

2.4 Distribution *a posteriori*

Compte tenu de (1)–(3), la règle de Bayes nous donne :

$$p(\mathbf{h}, \mathbf{a}, \boldsymbol{\ell}, \boldsymbol{\theta} | \mathbf{y}) \propto \eta^{-JQ} \left(\prod_j \epsilon_j^{-N-1} (1 - \rho_j^2)^{1/2} \mathbb{1}_{[-1,1]}(\rho_j) \right) \exp \left(-\frac{\mathbf{h}^t \mathbf{R}^{-1} \mathbf{h}}{2\sigma_h^2} - \sum_j \left(\frac{\tilde{\mathbf{y}}_j^t \boldsymbol{\Lambda}_j \tilde{\mathbf{y}}_j}{2\sigma_{\varepsilon_j}^2} + \frac{\|\boldsymbol{\ell}_j\|^2}{2\eta^2} \right) \right) \prod_j \sum_{i=0}^1 \frac{\lambda_i^2 \lambda_{1-i}}{\sigma_i^2 \sigma_{1-i}} \exp \left(-\frac{(a_j - \mu_i)^2}{2\sigma_i^2} \right) \quad (4)$$

avec $\tilde{\mathbf{y}}_j = \mathbf{y}_j - a_j \mathbf{X} \mathbf{h} - \mathbf{P} \boldsymbol{\ell}_j$, et $\boldsymbol{\Lambda}_j$ est l'inverse de la covariance d'un AR(1) de paramètre ρ_j et de variance 1.

2.5 Estimateurs

À partir de (4), il s'agit de construire des estimateurs pour les différents paramètres inconnus et de classifier les voxels de la région d'intérêt en voxels activés et inactivés. Comme dans [1], nous recourons à un échantillonneur de Gibbs. Il s'agit de simuler successivement des réalisations des paramètres inconnus selon leurs distributions conditionnelles *a posteriori*, d'itérer ce procédé jusqu'à convergence, puis de calculer des estimateurs marginaux du type espérance *a posteriori*.

Par rapport à [1], l'échantillonnage des paramètres autorégressifs $\boldsymbol{\rho}$ pose une difficulté supplémentaire. En effet, la distribution conditionnelle $p(\rho_j | rest)$ s'écrit :

$$p(\rho_j | rest) \propto (1 - \rho_j^2)^{1/2} \exp \left(-\frac{A_j}{2\sigma_{\varepsilon_j}^2} \left(\rho_j - \frac{B_j}{A_j} \right)^2 \right) \mathbb{1}_{[-1,1]} \quad (5)$$

où $A_j = \sum_{n=2}^{N-1} \tilde{y}_{j,n}^2$ et $B_j = \sum_{n=1}^{N-1} \tilde{y}_{j,n} \tilde{y}_{j,n+1}$. La distribution (5) ne s'identifiant pas à une loi connue, nous proposons de l'approcher par une loi beta $g(\rho_j) \sim \mathcal{B}(\alpha_j, \beta_j)$ définie sur l'intervalle $[-1, 1]$, qui servira de loi instrumentale au sein d'un algorithme de Metropolis-Hastings [8]. La procédure d'identification des paramètres de cette loi se fait de la façon suivante :

1. Trouver une loi beta qui se rapproche de $p(\rho_j | rest)$. Pour cela, on écrit la loi beta sous la forme $g(\rho_j) \propto (1 + \rho_j)^{\alpha_j - 1} (1 - \rho_j)^{\beta_j - 1}$, $\forall |\rho_j| < 1$.
2. On écrit le développement de Taylor au second ordre

de $\ln(1+\rho_j)$ et $\ln(1-\rho_j)$ au voisinage de $m_j=B_j/A_j$:

$$\ln(1 \pm \rho_j) = \ln(1 \pm m_j) \pm \frac{\rho_j - m_j}{1 \pm m_j} - \frac{1}{2} \frac{(\rho_j - m_j)^2}{(1 \pm m_j)^2} + O((\rho_j - m_j)^3).$$

3. On définit les scalaires (a_j, b_j, c_j) tels que :

$$a_j \ln(1 + \rho_j) + b_j \ln(1 - \rho_j) + c_j = -\frac{A_j}{2\sigma_{\varepsilon_j}^2} (\rho_j - m_j)^2 + O((\rho_j - m_j)^3).$$

4. Par identification, on détermine donc a_j et b_j :

$$a_j = A_j (1 - m_j^2) (1 + m_j) / 2\sigma_{\varepsilon_j}^2, \\ b_j = A_j (1 - m_j^2) (1 - m_j) / 2\sigma_{\varepsilon_j}^2,$$

5. On obtient ainsi $g(\rho_j) \propto (1 - \rho_j^2)^{1/2} (1 + \rho_j)^{a_j} (1 - \rho_j)^{b_j} \mathbb{1}_{[-1,1]}$, avec $\alpha_j = a_j + 3/2$ et $\beta_j = b_j + 3/2$.

L'algorithme est décrit dans la table 1.

3 Simulation

3.1 Génération des données

Nous avons simulé une séquence *aléatoire* pour un stimulus. Les intervalles inter-stimuli sont aléatoires et suivent une distribution uniforme sur [2.5, 3.5] sec. Les temps d'arrivée du stimulus sont placés sur une grille échantillonnée au pas $\delta t = 0.5$ sec. La région d'intérêt \mathcal{R} contient $J_1 = 22$ voxels activés et $J_0 = 38$ voxels non activés. La distribution des amplitudes choisie est : $\mathbf{a}_{j \in C_1} \sim \mathcal{N}(\mu_1 = 10, \sigma_1^2 = 3)$ et $\mathbf{a}_{j \in C_0} \sim \mathcal{N}(0, \sigma_0^2 = 1)$.

Pour tous les voxels, la séquence binaire \mathbf{x}_t est ensuite convoluée par une FRH, \mathbf{h}_c , reportée en Fig. 2(a). Un bruit AR(1) \mathbf{b}_j est ensuite additionné au signal induit par le stimulus $a_j \mathbf{X} \mathbf{h}$ pour chaque voxel V_j . Tous les coefficients AR ont été fixés à la même valeur : $\rho_j = \rho = 0.4, \forall j = 1 : J$. Des dérivées basse fréquence $\mathbf{P} \boldsymbol{\ell}_j$ sont aussi ajoutées à la série temporelle. Ces dérivées ont été générées à partir d'une base de cosinus avec des coefficients $\boldsymbol{\ell}_j$ générés à partir d'une distribution normale.

3.2 Résultats

Les résultats d'estimation des FRH et des amplitudes neuronales obtenues avec les deux modèles de bruit gaussien (blanc (BBG) et AR(1) (BAR(1))) sont représentés à la Figure 1. Les résultats montrent tout d'abord que le modèle de bruit temporellement corrélé induit une forme de FRH estimée plus proche de \mathbf{h}_c . Les coefficients AR estimés ont des valeurs en moyenne égale à 0.35. Finalement, on obtient une meilleure estimation des amplitudes neuronales avec une covariance plus faible en utilisant le modèle de bruit corrélé (Figure 1(c)-(d)).

4 Données réelles

4.1 Génération des données

Cette nouvelle approche a été également testée sur des données IRMf issues d'un protocole de repérage des zones

TABLE 1 – Etape de l'algorithme

<ul style="list-style-type: none"> • Initialisation : choisir $\mathbf{h}^0, \mathbf{a}^0, \mathbf{l}^0, \theta^0$. • Itération k : générer $\mathbf{h}^k, \mathbf{a}^k, \mathbf{l}^k, \theta^k$ selon les lois conditionnelles a posteriori : <ul style="list-style-type: none"> – HRF : $\mathbf{h}^k \sim \mathcal{N}(m_h, \mathbf{R}_h)$. $m_h = \mathbf{R}_h \sum_j \mathbf{S}_j^t \mathbf{Q}_j \mathbf{y}_j, \quad \mathbf{R}_h^{-1} = \mathbf{R}^{-1} + \sum_j \mathbf{S}_j^t \mathbf{Q}_j \mathbf{S}_j,$ $\mathbf{S}_j = a_j \mathbf{X}, \quad \mathbf{Q}_j = \sigma_{\varepsilon_j}^{-2} \boldsymbol{\Lambda}_j$ – variance de la HRF : $(\sigma_h^2)^k \sim \mathcal{IG}(D/2, \mathbf{h}^t \mathbf{R}^{-1} \mathbf{h}/2)$. – variables de nuisance : $\boldsymbol{\ell}_j^k \sim \mathcal{N}(\boldsymbol{\mu}_{l_j}, \boldsymbol{\Sigma}_{l_j})$, $\boldsymbol{\Sigma}_{l_j}^{-1} = \eta^{-2} \mathbf{I}_Q + \sigma_{\varepsilon_j}^{-2} \mathbf{P}^t \boldsymbol{\Lambda}_j \mathbf{P},$ $\boldsymbol{\mu}_{l_j} = \sigma_{\varepsilon_j}^{-2} \boldsymbol{\Sigma}_{l_j} \mathbf{P}^t \boldsymbol{\Lambda}_j (\mathbf{y}_j - \mathbf{S}_j \mathbf{h}).$ – amplitudes : Pour chaque voxel j, <ul style="list-style-type: none"> * $u_j^k \sim \mathcal{U}[0, 1]$; si $u_j^k \leq \lambda_{1,j}^k$, alors $q_j^k = 1$ sinon $q_j^k = 0$. $\lambda_{i,j} = (1 + \tilde{\lambda}_{1-i,j} / \tilde{\lambda}_{i,j})^{-1},$ $\tilde{\lambda}_{i,j} = \frac{\lambda_i^2 \lambda_{1-i}}{\sigma_i} \sigma_{i,j} \exp(\mu_{i,j}^2 / 2\sigma_{i,j}^2), \quad i = 0, 1.$ * $a_j^k q_j^k = i \sim \mathcal{N}(\mu_{i,j}^k, (\sigma_{i,j}^2)^k), \quad i = 0, 1.$ $\sigma_{i,j}^{-2} = \sigma_i^{-2} + \mathbf{g}^t \mathbf{Q}_j \mathbf{g}, \quad \mathbf{g} = \mathbf{X} \mathbf{h}$ $\mu_{i,j} = \sigma_{i,j}^2 (\mathbf{g}^t \mathbf{Q}_j \mathbf{e}_j + i \mu_i \sigma_i^{-2}),$ – variances du bruit blanc ε_j^2 : $\forall j, \quad \sigma_{\varepsilon_j}^2 \sim \mathcal{IG}\left(\frac{N+1}{2}, \frac{1}{2} \ \tilde{\mathbf{y}}_j\ _{\boldsymbol{\Lambda}_j}^2\right).$ – paramètres du mélange : <ul style="list-style-type: none"> * poids : $\lambda^k \sim \mathcal{B}(J_1 + 3/2, J_0 + 3/2)$. * Variance de la classe 0 : $(\sigma_0^2)^k \sim \mathcal{IG}\left(\frac{J_0 - 1}{2}, \frac{\nu_0}{2}\right)$. $\nu_i = \sum_{j \in C_i} (a_j - \eta_i)^2 \quad \text{et} \quad \eta_i = \frac{1}{J_i} \sum_{j \in C_i} a_j, \quad (i = 0, 1).$ * variance et moyenne de la classe 1 : $(\sigma_1^2)^k \sim \mathcal{IG}\left(\frac{J_1 - 1}{2}, \frac{\nu_1}{2}\right), \quad \mu_1^k \sim \mathcal{N}\left(\eta_1, \frac{\sigma_1^2}{J_1}\right).$ – $\eta^2 \sim \mathcal{IG}\left(\frac{QJ+1}{2}, \sum_j \frac{\ \boldsymbol{\ell}_j\ ^2}{2}\right)$. • Itérer jusqu'à K_0 (nombre d'itérations maximum). Finalement, Calculer la moyenne a posteriori selon : $\hat{\kappa}^{\text{MP}} = \frac{1}{K_0 - I + 1} \sum_{k=I}^{K_0} \kappa^k, \quad \forall \kappa \in \{\mathbf{h}, \mathbf{a}, \mathbf{l}, \theta\}$ <p>(les échantillons $\kappa^1, \dots, \kappa^I$ sont rejetés pour tenir compte de la période de chauffage de l'échantillonneur)</p>

activées par différents stimuli (moteur, visuel, auditif,...). L'expérience comportait $N = 125$ scans ($TR = 2.4$ sec.). Ici, on s'intéresse au stimulus suivant : clic avec la main droite (clicD). La région d'intérêt choisie \mathcal{R}_1 est un clus-

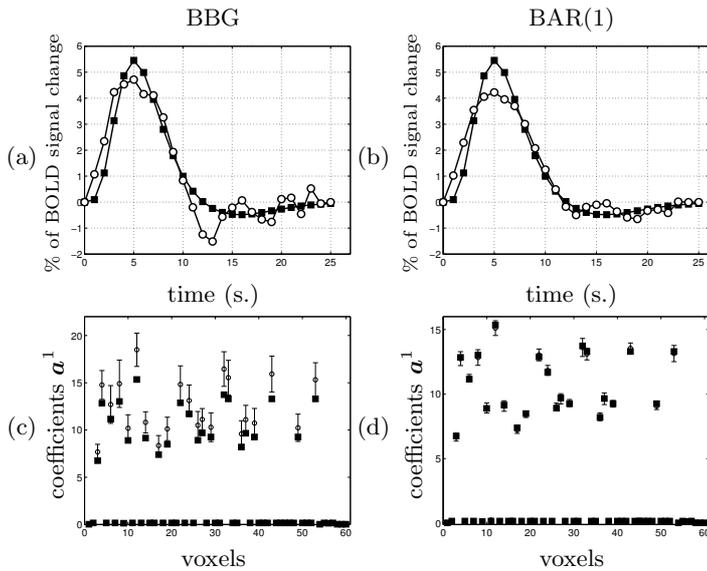


FIG. 1 – (a) et (b) représentent l’estimation de la FRH en utilisant un modèle de bruit BBG et BAR(1). Les symboles ■ et ○ représentent la vraie FRH h_c utilisée et son estimée. (c) et (d) représentent l’estimation des amplitudes en utilisant les modèles BBG et BAR(1). Les symboles ■ and ○ représentent les vraies amplitudes et leurs estimées. Les barres d’erreurs sont calculées à partir des variances a posteriori estimées à partir des amplitudes échantillonnées.

ter SPM (Statistical Parametric Mapping) obtenu à partir d’une carte t seuillée avec $P=0.001$. Cette région contient 178 voxels localisés autour du voxel de coordonnées en millimètres : ($X=-36, Y=-21, Z=48$).

4.2 Résultats

Les résultats d’estimation des FRH et des cartes d’amplitudes neuronales obtenues avec les deux modèles de bruit BBG et BAR(1) sont représentés en Figure 2. Ces résultats montrent tout d’abord que le modèle BAR(1) induit une forme de FRH à peu près similaire à celle obtenue avec le modèle BBG (avec le modèle BAR(1), on a une HRF moins passe-bas car la corrélation des données se répartit entre celle du signal utile et celle du bruit). Les coefficients AR estimés ont des valeurs en moyenne égale à 0.2. On observe aussi que les amplitudes estimées ont des valeurs plus élevées en utilisant le modèle de bruit BAR(1) que le modèle BBG. Un autre résultat intéressant concerne la détection des voxels activés : on observe un taux de faux positifs moins élevé avec le modèle BAR(1).

5 Conclusion

Les résultats de nos différents tests ont montré que le modèle BAR(1) apporte des améliorations mais ceci au prix d’un temps de calcul plus élevé. Nos simulations ont illustré que ce modèle de bruit a une influence sur l’estimation des amplitudes neuronales a posteriori et sur les barres d’erreur. Ces conclusions ont été confirmées sur des données IRMf. Nous avons aussi noté des améliorations de détection en terme de réduction du taux de faux positifs.

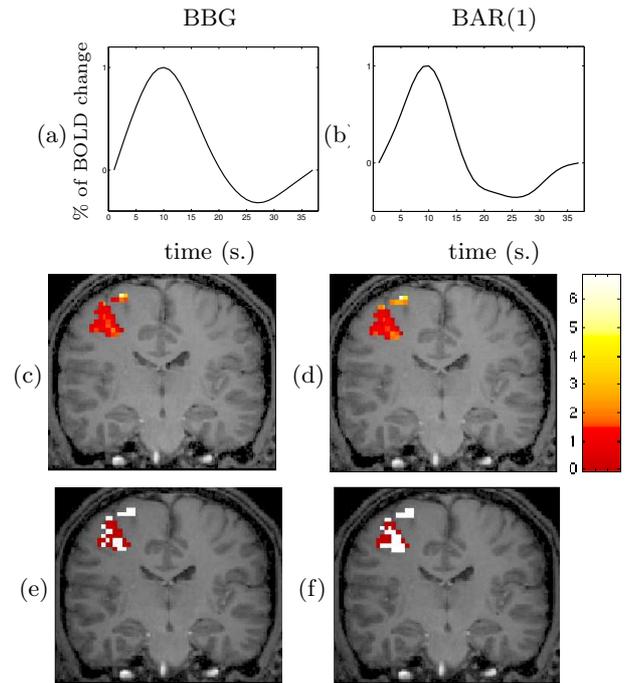


FIG. 2 – (a) et (b) représentent l’estimation de la FRH dans la région \mathcal{R}_1 . (c) et (d) représentent la carte spatiale des amplitudes estimées pour la condition clicD. (e) et (f) représentent la carte spatiale des résultats de détection (Les voxels blanc sont activés, ceux en rouge inactivés).

Références

- [1] S. Makni, P. Ciuciu, J. Idier et J.-B. Poline, « Joint detection-estimation of brain activity in functional MRI : a multichannel deconvolution solution », *to appear in IEEE Trans. SP*, vol. 53, n°9, Sep. 2005.
- [2] E. T. Bullmore, M. Brammer, S. C. Williams, S. Rabe-Hesketh, N. Janot, A. David, J. Mellers, R. Howard et P. Sham, « Statistical methods of estimation and inference for functional MR image analysis », *Magn. Reson. Med.*, vol. 35, pp. 261–277, 1996.
- [3] P. A. Bandettini, A. Jesmanowicz, E. C. Wong et J. S. Hyde, « Processing strategies for time-course data sets in functional MRI of the human brain », *Magn. Reson. Med.*, vol. 30, pp. 161–173, 1993.
- [4] P. Ciuciu, J.-B. Poline, G. Marrelec, J. Idier, C. Pallier et H. Benali, « Unsupervised robust non-parametric estimation of the hemodynamic response function for any fMRI experiment », *IEEE Trans. Med. Imag.*, vol. 22, n°10, pp. 1235–1251, 2003.
- [5] M. Woolrich, M. Jenkinson, J. M. Brady et S. Smith, « Constrained linear basis set for HRF modelling using variational Bayes », *Neuroimage*, vol.21, pp.1748–1761, 2004.
- [6] M. Woolrich, B. Ripley, M. Brady et S. Smith, « Temporal autocorrelation in univariate linear modelling of fMRI data », *Neuroimage*, vol. 14, n°6, pp. 1370–1386, 2001.
- [7] M. Woolrich, M. Jenkinson, J. Brady, and S. Smith, “Fully Bayesian spatio-temporal modelling of fMRI data,” *IEEE Trans. Med. Imag.*, vol. 23(2), pp. 213–231, 2004.
- [8] W. K. Hastings, « Monte Carlo sampling methods using Markov chains and their applications », *Biometrika*, vol. 57, pp. 97, 1970.