

# Mélanges spatiaux pour la détection-estimation conjointe de l'activité cérébrale en imagerie fonctionnelle (IRMF)

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

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

<sup>2</sup>Equipe ADTSI - IRCCyN/CNRS

1 rue de la Noë, BP 92101, 44321 Nantes cedex 3, France

thomas.vincent@cea.fr, philippe.ciuciu@cea.fr, Jerome.Idier@ircryn.ec-nantes.fr

**Résumé** – Cet article présente une étude de validation d'un travail récent [1] qui 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'activation spécifiques aux stimuli impliqués dans le paradigme expérimental. Dans [1], nous avons proposé d'intégrer un modèle de corrélation spatiale sur chacune des cartes d'activation à l'aide d'un champ de Markov caché binaire afin d'obtenir un meilleur compromis sensibilité-spécificité de détection par rapport à un modèle indépendant. Toutefois l'approche reste supervisée car le facteur de corrélation spatiale demeure fixé à la main. Dans l'attente d'une extension non-supervisée, nous étudions sur des simulations réalistes l'impact du réglage de ce paramètre sur la détection des activations.

**Abstract** – This paper presents a validation study of a recent work [1] dealing with the joint detection-estimation of brain activity in functional Magnetic Resonance Imaging. The ensued goal is to recover both the shape of the hemodynamic filter and activation maps for the stimuli involved in the experimental paradigm. In [1], we have proposed a spatially correlated model on these activation maps using a binary hidden Markov random field. A better sensitivity-specificity trade-off was achieved in comparison to a spatially independent model. However, our approach still remains supervised in the sense that the correlation factor is set by hand. Prior to the development of an adaptive estimation for this parameter, we study the impact of its tuning in terms of detection power on realistic artificial datasets.

## 1 Introduction

Depuis les premières études sur l'effet BOLD chez l'humain, l'IRM fonctionnelle (IRMf) est devenue un outil incontournable pour investiguer les relations entre tâche cognitive et réponse hémodynamique cérébrale. Une analyse intra-sujet en IRMF se résume donc à localiser les zones du cerveau activées par un type de stimulus ou une tâche d'intérêt, et à estimer la dynamique temporelle de ces activations tout en tenant compte de la variabilité spatiale de la réponse impulsionnelle du système neuro-vasculaire *i.e.*, la *Fonction de Réponse Hémodynamique* (FRH). Dans [2], une approche originale de détection-estimation recouvrant conjointement ces deux objets a été proposée avec une stratégie régionale, *i.e.* portant sur un ensemble prédéfini de régions d'intérêt (RDI).

Dans un cadre bayésien, des informations *a priori* physiologiques ont été introduites afin d'obtenir une estimée régulière de la FRH. Conjointement, un modèle de mélange indépendant (MMI) a été intégré pour rendre compte des modulations locales du signal d'un voxel à un autre au sein d'une RDI. Afin de prendre en compte la corrélation spatiale entre voxels voisins et de favoriser la détection de *clusters* d'activation plutôt que de voxels isolés, nous avons introduit un modèle de mélange *spatial* à l'aide d'un champ de Ising symétrique pour modéliser *a priori* l'état d'un voxel (activé ou non-activé). Le paramètre contrôlant le niveau de corrélation spatiale au sein du champ

est fixé empiriquement de façon analogue à la largeur du filtre spatial appliqué sur les données en guise de pré-traitement. Le recours à la règle de Bayes conduit à l'expression de la distribution *a posteriori* dont on tire des échantillons selon une procédure MCMC (*Markov Chain Monte Carlo*). Les paramètres recherchés tout comme les hyper-paramètres<sup>1</sup>, sont ensuite estimés au sens de l'espérance *a posteriori*, par moyennage des échantillons générés au cours du schéma MCMC, en tenant compte d'une période de chauffage. Dans [1], nous avons mis en évidence que cette approche par MMS induit un gain significatif en terme de sensibilité et de spécificité de détection.

En amont du développement d'une approche non-supervisée, la présente communication vise à étudier sur des simulations réalistes le comportement du modèle en détection en fonction de la valeur retenue pour le paramètre de corrélation spatiale.

## 2 Modèle génératif régional

### 2.1 Motivations

Les approches classiques s'appuient sur la définition d'un *unique* modèle linéaire généralisé (MLG), popularisé par le logiciel *Statistical Parametric Mapping*<sup>2</sup>, du signal BOLD mesuré en IRMF. Dans cette formulation, le modèle ainsi

<sup>1</sup>en dehors du facteur de corrélation spatiale

<sup>2</sup>SPM, <http://www.fil.ion.ucl.ac.uk/spm>.

défini s'appuie sur une seule forme de FRH pour l'ensemble du cerveau. Des travaux récents [3] ont pourtant mis en évidence une variabilité spatiale de cette réponse impulsionnelle neuro-vasculaire, notamment entre les cortex moteur et occipital. Nous prônons par conséquent la définition d'un MLG régional au sein duquel la FRH est estimée plutôt que fixée à l'avance, à une échelle spatiale plus grossière que celle du voxel. Afin de définir cette échelle, nous utilisons une partition de la matière grise du volume cérébral en une centaines de RDIs connectées, issue d'un algorithme de parcellisation multi-sujets anatomofonctionnelle [4]. Un exemple de ce processus est illustré à la Fig. 1(a). Au sein d'une RDI, un seul régresseur caractérise donc chaque condition expérimentale autorisant ainsi une comparaison statistique directe entre les amplitudes des réponses aux différentes conditions.

## 2.2 Formulation du problème

La présente contribution s'appuie sur le modèle régional génératif des données d'IRMF développé dans [2, 5]. Soit  $\mathcal{P}=(V_j)_{j=1:J}$  une parcelle comme illustré en Fig. 1(a), et soit  $\mathbf{y}_j=(y_{j,t_n})_{n=1:N}$ , le signal IRMF acquis au voxel  $V_j$  dans  $\mathcal{P}$ , et mesuré aux instants  $(t_n=n TR)_{n=1:N}$ , 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* 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)  $(a_j^m)_{j=1:J}^{m=1:M}$ , rendant le modèle génératif bilinéaire :

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

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  $\Delta t < TR$ . 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 [5] et ainsi réduire le taux de faux positifs en détection [5].




FIG. 1 – (a) : Exemple de parcellisation. (b) : Modèle génératif régional du signal BOLD

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  $\mathbf{b}_j$ . La matrice  $\boldsymbol{\Lambda}_j$  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  $(\boldsymbol{\Lambda}_j)_{\ell+1,\ell}=-\rho_j$ .

## 3 Détection-estimation conjointe bayésienne

Nous rappelons la loi *a priori* associée aux NRNs  $\mathbf{a}$  en suivant la présentation initiale de [1]. Pour les autres quantités *i.e.*, la FRH  $\mathbf{h}$ , les dérivées  $\mathbf{l}$ , les hyper-paramètres, ... le lecteur intéressé pourra consulter [2, 1].

### 3.1 Modèle de Mélange Spatial

Nous supposons que différents types de stimuli induisent des NRNs statistiquement indépendants *i.e.*,  $p(\mathbf{a} | \boldsymbol{\theta}_\mathbf{a})=\prod_m p(\mathbf{a}^m | \boldsymbol{\theta}^m)$  avec  $\mathbf{a}=(\mathbf{a}^m)_{m=1:M}$ ,  $\mathbf{a}^m=(a_j^m)_{j=1:J}$  et  $\boldsymbol{\theta}_\mathbf{a}=(\boldsymbol{\theta}^m)_{m=1:M}$ .  $\boldsymbol{\theta}^m$  contient l'ensemble des hyper-paramètres inconnus reliés au  $m^{\text{ème}}$  stimulus. Nous définissons un modèle de mélange spatial en introduisant des variables binaires indicatrices  $q_j^m$  ou *labels*, qui établissent si un voxel  $V_j \in \mathcal{P}$  s'active ( $q_j^m=1$ ) ou non ( $q_j^m=0$ ) en réponse au stimulus de type  $m$ . Conditionnellement à ces labels, les NRNs  $\mathbf{a}^m$  sont distribués spatialement selon une loi normale :  $(a_j^m | q_j^m=i) \sim \mathcal{N}(\mu_{i,m}, v_{i,m})$ , avec  $i=0,1$ . Nous imposons  $\mu_{0,m}=0$  pour la classe des voxels non-activés, de ce fait :  $\boldsymbol{\theta}^m=[v_{0,m}, \mu_{1,m}, v_{1,m}]$ . Contrairement à [2], nous introduisons des variables  $q_j^m$  corrélées spatialement entre elles impliquant  $\Pr(q_j^m=1)=\lambda_{1,j}^m$  au lieu de  $\Pr(q_j^m=1)=\lambda_1^m, \forall m$ . Le modèle de corrélation retenu est un champ de Markov binaire sur les variables  $q_j^m$ , alors que les NRNs restent indépendants entre eux conditionnellement à  $\mathbf{q}^m$ . Plus précisément, un champ de Ising *symétrique* est introduit :

$$\Pr(\mathbf{q}_j^m | \beta^m) \propto \exp\left(-\beta^m \sum_{j \sim k} \omega_{jk} I(q_j^m = q_k^m)\right),$$

où  $I(A)=1$  si  $A$  est vraie et  $I(A)=0$  sinon. La notation  $j \sim k$  signifie que la somme s'étend sur tous les voxels voisins de  $V_j$ , tandis que  $\omega_{jk}$  sont des constantes pré-définies qui pondèrent les interactions entre voxels  $(V_j, V_k)$  :  $\omega_{jk} \propto 1/d(V_j, V_k)$  où  $d(V_j, V_k)$  est la distance entre  $V_j$  et  $V_k$ . Notons que ce champ est caché car  $\mathbf{q}=(\mathbf{q}^m)_{m=1:M}$  n'apparaît pas dans (1). Le paramètre  $\beta^m > 0$  dans  $\Pr(\mathbf{q}_j^m | \beta^m)$  contrôle le niveau de corrélation spatiale. Ici, il est fixé

empiriquement. En combinant ces informations, nous obtenons un MMS pour chaque type de stimulus :

$$p(\mathbf{a}^m | \boldsymbol{\theta}^m) = \sum_{\mathbf{q}^m} \left( \prod_{j=1}^J p(a_j^m | q_j^m, \boldsymbol{\theta}^m) \right) \Pr(\mathbf{q}^m | \beta^m). \quad (3)$$

### 3.2 Loi *a posteriori* conjointe

À l'aide de la règle de Bayes et des autres *a priori* définis dans [5], la loi *a posteriori*  $p(\mathbf{h}, \mathbf{q}, \mathbf{a}, (\ell_j), \boldsymbol{\Theta} | \mathbf{y})$  s'écrit :

$$p(\mathbf{h}, \mathbf{a}, \mathbf{l}, \boldsymbol{\Theta} | \mathbf{y}) \propto \sigma_{\mathbf{h}}^{-D} \sigma_{\ell}^{-JQ} \prod_{j=1}^J \left( \frac{(1 - \rho_j^2)^{1/2}}{\sigma_{\varepsilon_j}^{N+1}} \mathbb{1}_{(-1,1)}(\rho_j) \right) \times \exp \left( -\frac{\mathbf{h}^t \mathbf{R}^{-1} \mathbf{h}}{2\sigma_{\mathbf{h}}^2} - \sum_{j=1}^J \left( \frac{1}{2\sigma_{\varepsilon_j}^2} \tilde{\mathbf{y}}_j^t \boldsymbol{\Lambda}_j \tilde{\mathbf{y}}_j + \frac{1}{2\sigma_{\ell}^2} \|\ell_j\|^2 \right) \right) \times \prod_{m=1}^M \left( p(\boldsymbol{\theta}^m) p(\mathbf{a}^m | \boldsymbol{\theta}^m) \right) \quad (4)$$

avec  $\tilde{\mathbf{y}}_j = \mathbf{y}_j - \mathbf{S}_j \mathbf{h}$  et  $\mathbf{S}_j = \sum_j a_j^m \mathbf{X}^m$ .

Nous simulons des réalisations de (4) par échantillonnage de Gibbs pour approcher des estimateurs de type espérance *a posteriori*  $\hat{\mathbf{q}}^{\text{MP}}$ ,  $\hat{\mathbf{a}}^{\text{MP}}$  et  $\hat{\mathbf{h}}^{\text{MP}}$ . Nous déduisons ainsi à travers  $\hat{\mathbf{q}}^{\text{MP}}$  quels sont les voxels activés, et  $(\hat{\mathbf{a}}_j^m)^{\text{MP}} \hat{\mathbf{h}}^{\text{MP}}$  estime la réponse hémodynamique du voxel  $j$  pour le stimulus  $m$ . Ces différents estimateurs sont donnés par  $\hat{\mathbf{x}}^{\text{MP}} = (K - I)^{-1} \sum_{k=I+1}^K x^{(k)}$ ,  $\forall x \in \{\mathbf{h}, \mathbf{a}, \mathbf{q}, \boldsymbol{\Theta}\}$  où  $I$  est la longueur de la "période de chauffe" de la chaîne. Nous ne présenterons dans la suite que la formulation de la loi conditionnelle *a posteriori* de  $(\mathbf{a}, \mathbf{q})$ . Le lecteur pourra se référer à [5] pour les autres quantités d'intérêt.

### 3.3 Mélange spatial *a posteriori*

La distribution *a priori* sur les NRN étant un mélange gaussien, et l'expression de la vraisemblance à  $\mathbf{h}$  fixée demeurant gaussienne, la densité conditionnelle *a posteriori* des NRNs est aussi un mélange gaussien par un argument de conjugaison. De (4), on peut montrer que chaque  $a_j^m$  est une réalisation de :

$$p(a_j^m | \mathbf{y}_j, \mathbf{h}, \boldsymbol{\theta}^m, \varepsilon_j^2, a_j^{m' \neq m}, q_{k \in N_j}^m) = \sum_{i=0,1} \lambda_{i,j}^m \mathcal{N}(\mu_{i,j}^m, v_{i,j}^m),$$

en posant  $N_j = \{V_k | k \sim j\}$ . Cette simulation se décompose en trois étapes : (i) identifier les paramètres  $(\lambda_{i,j}^m, \mu_{i,j}^m, v_{i,j}^m)$ ; (ii) échantillonner le label binaire  $q_j^m$  en accord avec  $\lambda_{i,j}^m$  et finalement (iii) simuler  $a_j^m$  conditionnellement à  $q_j^m$  selon  $\mathcal{N}(\mu_{i,j}^m, v_{i,j}^m)$  pour  $i = 0, 1$ ; cf. [5] :

$$v_{i,j}^m = (v_{i,m}^{-1} + \frac{\mathbf{g}_m^t \boldsymbol{\Lambda}_j \mathbf{g}_m}{\sigma_{\varepsilon_j}^2})^{-1}, \quad \mu_{i,j}^m = v_{i,j}^m \left( \frac{\mathbf{g}_m^t \boldsymbol{\Lambda}_j \mathbf{e}_{m,j}}{\sigma_{\varepsilon_j}^2} + i \frac{\mu_{i,m}}{v_{i,m}} \right)$$

où  $\mathbf{g}_m = \mathbf{X}^m \mathbf{h}$  et  $\mathbf{e}_{m,j} = \mathbf{y}_j - \mathbf{P} \ell_j - \sum_{m' \neq m} a_j^{m'} \mathbf{g}_{m'}$ . La probabilité  $\lambda_{i,j}^m$  de l'événement  $(q_j^m = i)$  s'écrit :

$$\lambda_{i,j}^m = \left( 1 + \frac{r_{1-i,j}^m \pi_{1-i,j}^m}{r_{i,j}^m \pi_{i,j}^m} \right)^{-1} \quad (5)$$

avec  $r_{i,j}^m = (v_{i,j}^m / v_{i,m})^{1/2} \exp((\mu_{i,j}^m)^2 / v_{i,j}^m - i(\mu_{i,m}^m)^2 / v_{i,m}^m)$  et  $\pi_{i,j}^m = \Pr(q_j^m = i | q_{k \in N_j}^m, \beta^m)$ . Pour calculer (5), nous

devons évaluer :

$$\pi_{1-i,j}^m / \pi_{i,j}^m = \exp \left( \beta^m \sum_{k \in N_j} w_{jk} (1 - 2q_k^m) \right),$$

qui ne dépend que des labels dans le voisinage  $N_j$  de  $V_j$ .

Le paramètre  $\beta^m$  est fixé par l'utilisateur. Son estimation nécessiterait l'approximation de la fonction de partition du champ de Ising  $Z(\beta^m)$  en amont de la boucle d'échantillonnage. Pour ce faire, il est possible d'adopter la démarche retenue dans [6] qui consiste à simuler de champs d'Ising sur une grille discrète de valeurs de  $\beta^m$ , en particulier à basse température (*i.e.*, à  $\beta^m$  élevé). L'échantillonnage efficace des champs de Potts à « basse température » donc très corrélés est une question qui n'a connu des avancées théoriques et pratiques que très récemment [7, 8]. Avant d'envisager cette solution au coût d'implantation numérique élevé, il convient tout d'abord de vérifier dans quelle mesure ce paramètre est "critique" dans notre approche et conditionne la sensibilité et la spécificité de détection.

## 4 Résultats

### 4.1 Données simulées

L'ordre des stimuli est généré *par permutation aléatoire* en mélangeant trente essais de  $M = 2$  types de stimulus. Les intervalles inter-stimuli suivent une distribution uniforme de moyenne 2 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.2 et défini dans [1]. Cette génération passe par la simulation de labels  $\mathbf{q}^m$  qui s'écartent du modèle *a priori* défini par un champ de Ising spécifique à chaque condition  $m$  (voir Fig.2(a)-(b)) pour différencier les voxels activés de ceux inactivés, puis par la génération des NRNs distribuées selon des densités gaussiennes :

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

Puisque  $\mu_{1,2} < \mu_{1,1}$ , la condition expérimentale  $m = 2$  correspond donc à un plus faible rapport contraste-à-bruit (RCB). Le signal de chaque voxel  $\sum_m a_j^m \mathbf{X}^m$  est ensuite convo-




FIG. 2 – Cartes simulées de labels :  $\mathbf{q}^m$  pour  $m = 1$  (a) et  $m = 2$  (b).

lué avec une FRH de forme spécifiée. Une dérive basse fréquence et un bruit blanc ici sont ensuite ajoutés dans chaque voxel  $V_j$  selon le modèle (1) pour former  $\mathbf{y}_j$  et cibler un RCB réaliste de 3dB environ.

## 4.2 Comportement de la détection en fonction de $\beta^m$

Par souci de simplicité, on choisit  $\beta^1 = \beta^2 = \beta$  pour la phase d'estimation. L'algorithme de détection-estimation a été lancé pour chaque valeur de  $\beta \in [0, 1; 1]$  par pas de 0,1. La Fig. 3 rend compte de l'évolution de la qualité de




FIG. 3 – (a) Évolution des courbes COR en fonction des valeurs croissantes de  $\beta$  pour  $m = 2$  (gradient jaune-rouge). (b) Courbes de sensibilité et spécificité en fonction de  $\beta$ , seuillage des  $\widehat{q}^{2MP}$  à 0,5.

la détection pour les différentes valeurs de  $\beta$  testées. On note que  $\beta > 0,5$  induit une mauvaise détection. En effet, le champ devient très corrélé comme le montre la Fig. 4 (d). L'évolution des courbes de sensibilité et spécificité en Fig. 3(b) indique des convergences vers des états totalement activés ou non-activés pour  $\beta > 0,6$  et traduit ainsi un "décrochage" autour de cette valeur alors que les courbes sont plutôt stables lorsque  $\beta < 0,4$ . Nous retrouvons ici le phénomène de transition de phase caractéristique des champs de Ising. La valeur de  $\beta$  correspondante est connue :  $\beta_{\text{transition}} \simeq 0,441$  qui correspond effectivement à l'ordre de grandeur observé. Il convient donc de fixer  $\beta$  en deçà de cette valeur afin de ne pas basculer vers des configurations trop corrélées. Par ailleurs, l'observation des cartes d'activation pour des valeurs inférieures à 0,3 donne des résultats peu contrastés, comme illustré en Fig. 4(a) et (e). D'après ces résultats, il semble nécessaire de choisir  $\beta \in [0, 3; 0, 4]$ . Ces résultats font l'objet actuellement d'un étalonnage sur données réelles.

## 5 Conclusion

Nous avons précisé le comportement d'un MMS intégré à une approche de détection-estimation conjointe en IRMF. Sur des simulations portant sur des cartes d'activation réalistes, nous avons fait ressortir un intervalle de valeurs optimales du paramètre  $\beta$  assez restreint, indiquant la nécessité d'envisager rapidement l'implantation d'une démarche non-supervisée. En outre, nous avons exhibé un comportement de type « transition de phase », caractéristique des champs de Ising 2D, et précisé son impact sur notre procédure de détection.

### Remerciements

Projet soutenu par l'attribution d'une Allocation Doctorale Région Ile-de-France.

## Références

[1] T. Vincent, P. Ciuciu et J. Idier, « Spatial mixture modeling for the joint detection-estimation of brain activity in

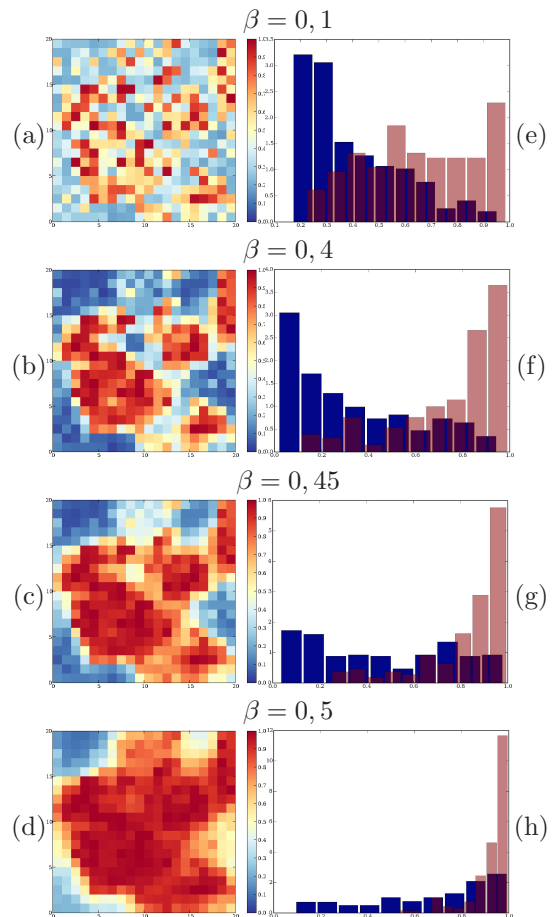


FIG. 4 – (a)-(d) Évolution des cartes de  $\widehat{q}^{2MP}$  en fonction de  $\beta$ . (e)-(h) Histogrammes des  $\widehat{q}^{2MP}$  correspondants : en rouge  $\widehat{q}_j^{2MP}$  avec  $j/q_j^2 = 1$ , en bleu  $\widehat{q}_{j'}^{2MP}$  avec  $j'/q_{j'}^2 = 0$ .

fMRI », in *32th Proc. IEEE ICASSP*, Honolulu, Hawaii, USA, avr. 2007, vol. I, pp. 325–328.

[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. 3488–3502, sep. 2005.

[3] D. A. Handwerker, J. M. Ollinger, et M. D'Esposito, « Variation of BOLD hemodynamic responses across subjects and brain regions and their effects on statistical analyses », *Neuroimage*, vol. 21, pp. 1639–1651, 2004.

[4] B. Thirion, G. Flandin, P. Pinel, 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(8), pp. 678–693, 2006.

[5] S. Makni, P. Ciuciu, J. Idier et J.-B. Poline, « Joint detection-estimation of brain activity in fMRI using an autoregressive noise model », in *3th Proc. IEEE ISBI*, Arlington, VA, USA, avr. 2006, pp. 1048–1051.

[6] D. M. Higdon, J. E. Bowsher, V. E. Johnson et R. J. Jaszczak, « Fully Bayesian estimation of Gibbs hyperparameters for emission computed tomography data », *IEEE Trans. Med. Imag.*, vol. 16(5), pp. 516–526, oct. 1997.

[7] S.-C. Chang, J. L. Jacobsen, J. Salas et R. Shrock, « Exact potts model partition functions for strips of the triangular lattice », *J.STAT.PHYS.*, vol. 114, pp. 763, 2004.

[8] T. Luczak et E. Vigoda, « Torpid mixing of the wangswendsen-kotecký algorithm for sampling colorings. », *J. Discrete Algorithms*, vol. 3(1), pp. 92–100, 2005.