

# Approche multirésolution de la reconstruction de l'activité électrique cérébrale en EEG/MEG

Laurence GAVIT<sup>1</sup>, Sylvain BAILLET<sup>1</sup>, Line GARNERO<sup>1</sup>

<sup>1</sup>LENA, UPR CNRS 640

Hôpital de la Salpêtrière, 47 Bld de l'hôpital, 75651 Paris Cedex 13, France

lenalga@ext.jussieu.fr, lenasba@ext.jussieu.fr, lenalg@ext.jussieu.fr

**Résumé** – Dans le cadre de l'imagerie fonctionnelle électrique cérébrale MEG/EEG<sup>1</sup> le problème de reconstruction de l'activité des sources sous-jacentes appartient à la famille des problèmes mal posés et n'admet pas de solution unique. Nous présentons une méthode itérative multirésolution de recherche de l'activité électrique des neurones sur la surface corticale. Cette méthode consiste en une focalisation itérative sur les zones où l'activité est détectée à l'étape précédente. La recherche des sources se fait à densité de sources croissante à chaque itération, en re-distribuant un nombre constant de sources, avec une résolution croissante sur la surface du cortex. La méthode d'estimation est basée sur une approche bayésienne de régularisation introduite dans [1] qui permet la prise en compte d'informations de nature hétérogènes. Ces contraintes spatio-temporelles sont définies localement grâce à une modélisation par champ de Markov. Elles permettent de réaliser une reconstruction régularisée de l'activité électrique cérébrale sur la surface corticale tout en autorisant l'apparition de discontinuités. Ces contraintes sont basées sur une description réaliste et fine de l'anatomie du cerveau.

**Abstract** – We present a new method based on a multiresolution approach for solving the ill-posed problem of brain electrical activity reconstruction from EEG/MEG<sup>1</sup> signals, in a distributed source model. At each step of the algorithm, a regularized solution of the inverse problem is used to limit the brain surface that has to be scanned during the next step. The estimation procedure is worked out through a Bayesian approach. This method [1] consists in introducing spatial and temporal a priori informations as the cure to the ill-posed inverse problem that consists in recovering a source pattern. These priors are easily integrated into a constraint yielding a maximum a posteriori (MAP) estimator of brain electrical activity. A realistic description of the cortex is achieved through a Markovian Field description.

<sup>1</sup> MEG : Magnetoencephalography  
EEG : Electroencephalography

## 1. Introduction

### 1.1 Imagerie électrique fonctionnelle cérébrale

L'imagerie fonctionnelle cérébrale est un outil de cartographie des fonctions cognitives humaines. A long terme, les objectifs sont de deux ordres : identifier les colonnes ou assemblées de neurones responsables de certaines fonctions cognitives simples, ou surveiller l'évolution de dysfonctionnements d'ordre neurologiques ou psychiatriques pour éventuellement pouvoir les traiter plus efficacement.

Le principe de l'imagerie électrique est de retrouver les sources électriques à l'origine du champ électromagnétique recueilli à la surface de la tête. Ces sources correspondent à l'activité électrique de macrocolonnes d'environ  $10^6$  neurones, réparties orthogonalement à la surface du cortex. Une telle méthode, totalement non invasive, possède une excellente résolution temporelle. Cependant, plusieurs problèmes se posent. Il faut d'abord disposer d'un modèle réaliste du milieu de propagation pour le *Problème Direct*. Ensuite, la non-unicité des solutions pour un électro/magnéto encéphalogramme (EEG / MEG) donné et leur sensibilité au bruit handicapent grandement la reconstruction. En ce sens, on

peut parler de *Problème Inverse mal posé*.

### 1.2 Modélisation du Problème Inverse dans un modèle de sources distribuées

Lors d'un enregistrement EEG ou MEG, on acquiert les données sur un réseau de capteurs placés à la surface du crâne, au cours du temps. On obtient ainsi une succession d'échantillons. Il s'agit donc à chaque instant d'estimer l'orientation et l'amplitude des sources.

Dans un modèle de sources distribuées à géométrie réaliste, le cortex est assimilé à une grille discrète, ou maillage, sur laquelle est distribué un grand nombre de sources dipolaires modélisant l'activité des colonnes de neurones. Si on fixe la position et l'orientation des dipôles (en chaque nœud du maillage, et d'orientation perpendiculaire à la surface du cortex), il devient possible d'écrire le système linéaire suivant :

$$\mathbf{M}_n = \mathbf{G}\mathbf{J}_n + \mathbf{b}_n \quad (1)$$

où  $\mathbf{M}_n$  est un vecteur (1,M) regroupant les mesures EEG ou MEG recueillies à la surface du crâne à l'instant  $n$ .

$\mathbf{J}_n$  est le vecteur (1,N) d'amplitudes des sources de courant à l'instant  $n$ . C'est le vecteur inconnu.

$\mathbf{G}$  est une matrice (M,N) modélisant les différents milieux

conducteurs traversés par les courants cérébraux, que nous appellerons matrice de gain.

$\mathbf{b}_n$  est un vecteur  $(1, M)$  de bruit additif du à la fois aux capteurs mais aussi à l'activité de fond du cerveau. Par la suite, nous omettrons l'indice temporel  $n$ .

## 2. Méthode multirésolution

### 2.1 Régularisation et limitations des méthodes distribuées

Si l'on dispose d'une description assez réaliste du cortex, la dimension du vecteur  $\mathbf{J}$  augmente de façon dramatique. Ainsi, on peut distribuer jusqu'à 20 000 sources sur l'ensemble de la grille, alors que les techniques actuelles offrent au maximum 200 mesures simultanées à la surface du crâne. Le problème inverse est alors largement sous-déterminé. De plus, une ambiguïté fondamentale interdit l'unicité de la solution.

La régularisation consiste alors à contraindre la solution en réduisant l'espace source. Son interprétation en termes bayésiens permet d'introduire des informations *a priori* de nature hétérogènes sur l'objet à reconstruire.

L'estimateur au sens du maximum *a posteriori*, ou MAP, s'écrit :

$$\hat{\mathbf{J}} = \max_{\mathbf{J}} (p(\mathbf{J}|\mathbf{M})) \quad (2)$$

Ce schéma classique de régularisation peut se ramener à la minimisation d'une fonction d'énergie  $U(\mathbf{J})$ :

$$\hat{\mathbf{J}} = \min_{\mathbf{J}} (U(\mathbf{J})) \quad (3)$$

où:

$$U(\mathbf{J}) = \|\mathbf{M} - \mathbf{G}\mathbf{J}\|_{\mathbf{R}}^2 + \lambda L(\mathbf{J}) \quad (4)$$

$\mathbf{R}$  est la matrice de covariance du bruit dans l'hypothèse d'un bruit gaussien centré.  $\lambda$  est un scalaire positif appelé hyperparamètre qui assure le compromis entre attache aux données et connaissances *a priori*. La norme  $\mathbf{R}$  est définie comme suit:

$$\|\mathbf{M} - \mathbf{G}\mathbf{J}\|_{\mathbf{R}}^2 = (\mathbf{M} - \mathbf{G}\mathbf{J})^t \mathbf{R}^{-1} (\mathbf{M} - \mathbf{G}\mathbf{J}) \quad (5)$$

L'opérateur  $L(\cdot)$  dépend de la nature des *a priori*.

Dans le schéma classique de régularisation de Tikhonov, l'opérateur  $L(\cdot)$  est une norme de l'objet à reconstruire. Il est clair qu'un tel choix correspond à un *a priori* d'homogénéité globale de  $\mathbf{J}$ .

Dans [1], Baillet et al introduisent des informations *a priori* de nature anatomo-fonctionnelles explicites. La distribution d'amplitudes des sources est supposée constituée de zones homogènes séparées par des discontinuités, comme cela peut-être le cas entre des aires corticales proches mais non corrélées fonctionnellement.

Après avoir défini un système de voisinage sur la surface corticale, le terme d'*a priori* s'écrit comme la somme de potentiels calculés localement:

$$L(\mathbf{J}) = \sum_{n=1}^{N_v} \Phi_v(\nabla \mathbf{J}|_v) \quad (6)$$

$\nabla$  désigne l'opérateur gradient sur les amplitudes des dipôles,  $N_v$  étant le nombre de voisins de chaque source. Ainsi  $u = \nabla \mathbf{J}|_v$  désigne-t-il le  $v^{\text{ième}}$  élément du vecteur gradient spatial. Les fonctions  $\Phi$  sont définies par:

$$\Phi_v(u) = \frac{u^2}{1 + \left(\frac{u}{K_v}\right)^2} \quad (7)$$

où  $K_v$  joue le rôle de seuil de détection local de saut d'intensité dans la distribution de sources. Ainsi, pour de faibles valeurs de gradients, le coût local est quadratique, alors que pour de plus fortes valeurs de gradients, le coût associé vaut  $\Phi_v(u) \approx K_v$  et préserve donc la création d'une discontinuité. Ces seuils  $K_v$  sont ajustés en fonction des orientations relatives d'une source et de son  $v^{\text{ème}}$  voisin d'une part, et en fonction de la distance euclidienne les séparant d'autre part.

Comme on définit un voisinage spatial pour chaque source, on peut définir un voisinage temporel composé des échantillons précédents et suivants. Ceci nous permet d'introduire un nouveau terme de régularisation temporelle dans la fonctionnelle d'énergie. Celui-ci traduit le fait que l'échantillonnage est rapide à l'échelle des phénomènes neuraux. On exige ainsi une douceur dans la variation d'amplitude d'un instant à l'autre.

### 2.2 Méthode multirésolution de reconstruction

Malgré des résultats encourageants, de telles méthodes pêchent par des limitations pratiques étant donné la dimension du vecteur source  $\mathbf{J}$  dans le cas d'une description réaliste du cortex. Nous proposons donc une nouvelle méthode permettant de réduire la dimension de l'espace des sources en réalisant un zoom itératif sur les régions où a été estimée une activité significative à l'échelle précédente.

Dans cette optique, diverses tentatives ont déjà été menées pour développer une estimation itérative par focalisation successive.

FOCUSS [3] réalise ainsi un calcul de norme minimale pondérée de façon itérative pour favoriser les zones les plus actives. Cette méthode est donc assez sensible à l'initialisation de l'algorithme. Cependant FOCUSS donne des résultats satisfaisants dans le cas de sources isolées, très focales.

R. Srebro quant à lui propose un algorithme réalisant une re-focalisation de l'estimation dans un ellipsoïde centré sur le barycentre des sources estimées à l'étape précédente, [5]. Les longueurs des axes de l'ellipsoïde sont calculées comme un écart type autour de l'origine, dans les trois directions. La méthode que nous proposons ici s'inspire de la démarche adoptée par R. Srebro.

La méthode exposée ici consiste en une distribution itérative d'un petit nombre de sources, sur des maillages de plus en plus fins. En pratique, 500 sources sont uniformément distribuées sur l'ensemble de la grille corticale et une première estimation de l'activité de ces sources est réalisée. A partir de cette distribution d'amplitudes, on réalise un zoom autour des zones les plus actives afin de réduire la surface à explorer. Le sous-espace ainsi défini est à nouveau décimé pour placer 500 nouveaux points. Ce procédé est réitéré

jusqu'à atteindre la finesse de résolution la plus grande, déterminée par le plus fin maillage obtenu de la surface corticale (taille des mailles : environ 3 mm). On peut alors poursuivre le processus en réduisant le nombre de sources à chaque itération.

### 2.3 Processus de focalisation

Les distributions d'amplitudes des sources sont assimilées à des densités de probabilités, notées  $p_i$  pour  $i=1,2,\dots,ndip$ , où  $ndip$  désigne le nombre de dipôles distribués.

On réalise une approximation des zones actives à l'aide d'ellipsoïdes dont les axes ont pour demi-longueur l'écart type des amplitudes suivant chaque direction.

Pour cela, le processus itératif de focalisation débute par l'identification du dipôle le plus actif, désigné par l'indice  $i_c$ , c'est à dire le dipôle de plus grande amplitude, dans la configuration de sources obtenue par la résolution du problème inverse.

$$p_{i_c} \geq p_i, \forall i \neq i_c \quad (8)$$

On centre alors le nuage de points sur ce dipôle, et on détermine ses axes principaux à partir d'une décomposition en éléments propres. Ces axes principaux fournissent alors un repère  $(Ox', Oy', Oz')$ .

Un ellipsoïde de demi-axes  $a$ ,  $b$ , et  $c$  égaux à l'écart type des amplitudes dans les trois directions  $(Ox', Oy', Oz')$  est alors déterminé.

$$a = \sqrt{\frac{\sum_{i \neq i_c} x_i^2 p_i^2}{\sum_{i \neq i_c} p_i^2}}, b = \sqrt{\frac{\sum_{i \neq i_c} y_i^2 p_i^2}{\sum_{i \neq i_c} p_i^2}}, c = \sqrt{\frac{\sum_{i \neq i_c} z_i^2 p_i^2}{\sum_{i \neq i_c} p_i^2}} \quad (9)$$

où  $x_i$ ,  $y_i$ , et  $z_i$  sont les coordonnées cartésiennes des points.

Seuls les sources appartenant à cet ellipsoïde et dont l'orientation n'est pas largement décorrélée de l'orientation de  $i_c$ , sont sélectionnés. Puis on itère l'opération sur les points restants dont l'amplitude est supérieure à un seuil  $\mu$  proportionnel à la déviation de la distribution d'amplitudes de toutes les sources.

$$\mu = k \cdot \sigma(P), k \in \mathbb{R} \quad (10)$$

où  $P$  désigne la distribution d'amplitude des sources.

À la résolution supérieure, on itère le processus en focalisant dans la zone précédemment déterminée. La figure 1 illustre ce processus itératif.

### 2.4 Contraintes spatiales et multirésolution

La méthode de régularisation développée par Baillet et Garnero [1] a été adaptée à une approche multirésolution en adaptant les seuils de détection locaux de sauts d'intensité  $K_v$  (éq.7) à la finesse de la grille. Pour cela, on définit l'échelle  $s$  à laquelle on travaille à la résolution  $k$  par:

$$s = \frac{d_k}{d_{\min}} \quad (11)$$

où  $d_k$  désigne la distance moyenne entre sources à la résolution  $k$ , et  $d_{\min}$  la distance moyenne entre sources à la résolution la plus grande. Les seuils deviennent alors:

$$K_v(s) = K_v^{\max} \left( 100 \frac{1 - \exp(s-1)}{1 - \exp(s_1-1)} + 1 \right) \quad (12)$$

où  $s_1$  est l'échelle la plus grande, à l'itération 1 et  $K_v^{\max}$  désigne le seuil  $K_v$  à la résolution la plus fine.

Lorsque l'on atteint la résolution maximale, c'est à dire que  $s = 1$ ,  $K_v = K_v^{\max}$ .

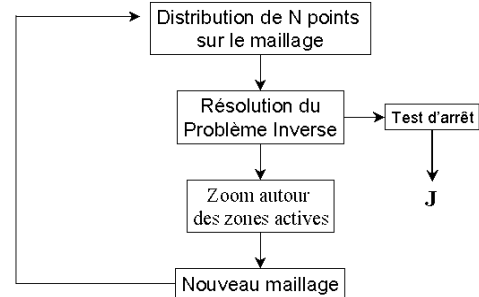


FIG. 1 : Algorithme multirésolution de reconstruction de l'activité sur le cortex

## 3. Évaluations de la méthode

### 3.1 Données

Une première évaluation a été menée sur des données simulées. Nous avons construit un nuage de points décrivant une suite de sillons corticaux, que nous avons virtuellement placée dans un maillage de crâne, cf. figure 2. Nous avons considéré deux modèles de tête pour former les données. Le premier est sphérique, à trois couches. Le second modèle que nous avons utilisé est un modèle réaliste de tête, utilisant la méthode des intégrales de frontières (BEM) pour le calcul de la matrice de gain.




FIG. 2 : Maillage virtuel de surface corticale

Par ailleurs, nous avons également mené des expérimentations sur une maquette réaliste appelée fantôme, et réalisée au LENA par S. Baillet. Ce fantôme se compose d'un crâne humain dans lequel 6 sources de courant ont été placées. Le tout est baigné d'une gélatine conductrice, cf. figure 3. La connaissance des conductivités auxquelles on n'a pas accès *in vivo* permet un modèle de formation des données plus réaliste. La matrice de gain a été calculée par la méthode BEM sur 60 capteurs. Un cortex de synthèse constitué de 506 nœuds (dont les 6 dipôles connus) constituait notre espace source. Nous avons pu ainsi activer une source et tenter de retrouver cette activité.




FIG. 3 : Fantôme de tête contenant 6 sources de courant

### 3.2 Méthodologie employée

Nous avons effectué des reconstructions avec et sans étape de focalisation afin de quantifier l'apport de cette dernière. Pour comparer les performances relatives des méthodes de reconstruction, nous avons défini quatre critères d'évaluation des résultats. Le premier, *EQM*, calcule une erreur quadratique moyenne normalisée entre les données simulées et les données reconstruites. Dans les zones n'ayant pas été activées, nous calculons le second critère qui mesure l'énergie résiduelle, *EnRes*, introduite par erreur lors de la reconstruction.

$$EQM = \frac{\|\mathbf{J}_{simu} - \mathbf{J}_{reconst}\|^2}{\|\mathbf{J}_{simu}\|^2} \quad (13)$$

$$EnRes = \frac{\|\mathbf{J}_{reconst\_erreur}\|^2}{\|\mathbf{J}_{simu}\|^2} \quad (14)$$

Enfin, nous avons défini deux critères plus quantitatifs que qualitatifs permettant d'affirmer si une zone est impliquée ou non dans l'activité. Il s'agit du pourcentage de sources fantômes, *%\_fant*, c'est à dire déclarées actives, alors qu'elles ne l'ont pas été, et du pourcentage de sources manquées, *%\_manq*, c'est à dire déclarées inactives alors qu'elles l'étaient. Le seuil au delà duquel une source est considérée comme active a été fixé à deux fois l'écart type de la distribution d'amplitudes des sources reconstruites.

Nous présentons dans cet article des simulations préliminaires utilisant uniquement la régularisation de Tikhonov.

### 3.3 Résultats

Lors des simulations sur les sillons corticaux, cf. Table 1 et 2, nous avons constaté que quelque soit la sophistication du modèle direct, l'étape de focalisation améliorerait nettement les résultats. Cependant il est intéressant de noter que bien que les deux modèles donnent des résultats comparables sans focalisation, c'est le modèle réaliste qui voit ses résultats fortement améliorés par la focalisation.

TAB.1 : Modèle sphérique avec 27 capteurs

Focalisation	EQM	EnRes	<i>%_manq</i>	<i>%_fant</i>
Sans	0.176	.18	2.62	4.43

Avec	.032	0	2.56	0
------	------	---	------	---

TAB.2 : Modèle BEM avec 27 capteurs

Focalisation	EQM	EnRes	<i>%_manq</i>	<i>%_fant</i>
Sans	0.21	0.22	0	5
Avec	1.32e-5	0	0	0

Les résultats sur fantôme, cf. Table 3, sont eux aussi très encourageants et montrent que bien que la source active ait été retrouvée sans focalisation, une activité diffuse persiste. Avec focalisation cette activité de fond est éliminée.

TAB.3 : Modèle BEM avec 60 capteurs

Focalisation	EQM	EnRes	<i>%_manq</i>	<i>%_fant</i>
Sans	0.05	0.20	0	4.74
Avec	1.46e-4	0	0	0

## 4. Conclusion

Nous avons présenté une méthode de résolution du problème inverse dans le cadre de l'imagerie électrique cérébrale. Cette méthode appartient à la famille des modèles de sources distribuées. En travaillant sur des sous-ensembles de sources du cortex, elle diminue la dimension du vecteur d'inconnues et permet ainsi de mieux déterminer le problème inverse. Cette approche itérative permet d'accroître la résolution spatiale au cours de l'estimation.

Les premiers résultats obtenus dans le cadre d'une régularisation de Tikhonov sont encourageants. Dans un deuxième temps, il faudra les compléter, et passer à l'évaluation de la focalisation dans le cadre d'une régularisation tenant compte des *a priori* anatomo-fonctionnels.

## Références

- [1] S. Baillet, L. Garnero, « A bayesian approach to introducing anatomo-functional priors in the EEG/MEG inverse problem », *IEEE Trans. Biomed. Eng.*, vol.44, pp.374-385, May 1997
- [2] S. Geman, D. Geman, « Stochastic relaxation, Gibbs distributions and the bayesian restoration of images », *IEEE Trans. on Pattern Anal.*, Vol.PAMI-6, pp.721-741, 1984.
- [3] I. F. Gorodnitsky *et al.*, « Neuromagnetic source imaging with FOCUSS: a recursive weighted minimum norm algorithm », *Electroenceph. clin. Neurophysiol.*, pp. 231-251, 1995.
- [4] R. Srebro, « An iterative approach to the solution of the inverse problem », *Electroenceph. clin. Neurophysiol.*, pp. 349-362, 1996.