

Régularisation temporelle du problème inverse en imagerie électrique cérébral

Laurence GAVIT¹, Maria PETROU², Line GARNERO¹

¹Lena - CNRS UPR 640

Laboratoire de Neurosciences Cognitives et Imagerie Cérébrale
47, Bd de l'hôpital, 75651 Paris cedex 13, France

²School of Electronics and Mathematics, University of Surrey, United Kingdom

laurence.gavit@chups.jussieu.fr

Résumé –

Nous présentons une nouvelle méthode de régularisation du problème inverse en Magnétoencéphalographie et Électroencéphalographie (MEG et EEG), plus particulièrement adaptée à la reconstruction de signaux épileptiques. Cette méthode est originale car elle se propose de tirer parti de l'excellente résolution temporelle de ces techniques. Elle s'appuie sur une modélisation du déroulement temporel des sources à partir de pointes intercritiques chez des patients épileptiques afin de contraindre les sources reconstruites. Le modèle utilisé est linéaire par morceaux et permet donc de reconstruire des pics abruptes dans le déroulement temporel des sources. L'estimation de l'amplitude des sources est menée à l'aide d'une approche à résolution spatiale variable décrite dans [1]. Nous présentons ici une première simulation qui montre que le déroulement temporel d'une source peut être mieux identifié grâce à l'ajout de la régularisation temporelle.

Abstract –

Magnetoencephalography (MEG) and Electroencephalography (EEG) possess excellent temporal resolution for the observation of underlying electrophysiological process. However, the inverse problem of cortical source estimation is ill-posed. We propose a new regularization scheme, within the framework of epileptic interictal generators localization from MEG data, based on a source temporal model. This model is piece-wise linear and allow the reconstruction of sharp peaks in the source signal. The source magnitude estimation is driven through a multiresolution procedure described in [1]. We present some preliminary results on simulations, which show an improvement in a source signal reconstruction when using the temporal regularization.

1 Introduction

Les travaux présentés se placent dans le cadre classique de la restauration d'image observée au travers d'une équation linéaire. En effet, le modèle de source utilisé est le modèle distribué qui consiste à tapisser la surface corticale de milliers de dipôles de courant dont il faut estimer l'amplitude en chaque instant d'échantillonnage n . Cette estimation passe par la construction puis par la minimisation d'un critère pénalisé portant sur le vecteur d'amplitude des sources J_n . L'équation de formation des données s'écrit à tout instant n :

$$M_n = GJ_n + b_n \quad (1)$$

où G est la matrice de gain $N_M \times N$ qui modélise la formation des champs et b_n est un vecteur de bruit.

Le critère à minimiser pour obtenir l'estimée de J_n s'écrit sous la forme :

$$U(J_n) = \|M_n - GJ_n\|^2 + U_s(J_n) + U_t(J_n) \quad (2)$$

où $U_s(J_n)$ désigne le terme de régularisation spatiale décrit dans [2], et sur lequel nous ne reviendrons pas, et $U_t(J_n)$ désigne le terme de régularisation temporelle.

2 Régularisation temporelle

2.1 Contrainte de douceur temporelle

Une première approche, introduite dans [3], consiste à imposer une contrainte d'évolution douce en deux échantillons successifs J_n et J_{n+1} . Étant données d'une part les fréquences mises en jeu dans l'activité électrophysiologique, typiquement inférieures au kHz, et bien souvent filtrées en dessous de 100 Hz, et sachant d'autre part que les acquisitions sont réalisées à une fréquence d'échantillonnage d'au moins 500 Hz, on peut supposer de façon juste que le signal est sur-échantillonné, et ainsi imposer une contrainte de douceur entre chaque échantillon successif. Une solution consiste à minimiser la projection orthogonale de J_n sur l'hyperplan perpendiculaire à J_{n-1} , soit :

$$U_t(J_n) = \lambda_t \|P_{n-1} J_n\|^2 \quad (3)$$

où λ_t est l'hyperparamètre réglant le poids du terme de régularisation temporelle.

Si elle permet de stabiliser la solution du problème inverse, cette méthode reste assez simpliste. Nous avons donc proposé dans le cas de signaux épileptiques, un modèle d'évolution temporelle des sources sous-jacentes, qui soit à la fois assez souple pour décrire n'importe quelle pointe intercritique, tout en imposant assez de restriction pour régulariser le problème inverse.

2.2 Une régularisation temporelle adaptée aux signaux épileptiques

2.2.1 Principe

Les pointes intercritiques épileptiques sont facilement observables sur les tracés EEG/MEG. Elles se caractérisent par une alternance très rapide de pics largement positifs et négatifs autour du niveau de fond d'activité cérébrale. Néanmoins, ces données de surface ne sont pas suffisantes pour construire un modèle de sources profondes, puisque les ondes observées résultent de la somme d'activités sous-jacentes, voir figure 1. Il est donc nécessaire




FIG. 1 – *Illustration de la diffusion. Ici, 2 sources sont actives successivement. Les capteurs situés à mi-chemin entre elles voient la somme des activités. Le déroulement temporel résultant est montré en bas à droite en traits pleins. Il est plus lent que les déroulements temporels respectifs des sources.*

d'utiliser des enregistrements de profondeur effectués au niveau cortical pour construire notre modèle. En profondeur, les signaux SEEG présentent eux aussi des pointes très rapides localisées sur quelques plots d'enregistrement voisins, et de forte amplitude.

D'après ces observations, nous avons construit un modèle d'évolution temporelle des sources adapté aux pics d'activité visibles sur les tracés. On suppose que le signal à reconstruire est linéaire par morceaux, c'est-à-dire que L_s échantillons consécutifs d'une source s sont colinéaires, voir figure 3. En effet, les pics d'amplitude au cours de la pointe sont assimilables à des portions de droite. On va donc chercher à favoriser les sources ayant un tel comportement. Pour cela, pour estimer chaque échantillon \hat{J}_n , on construit un modèle temporel $J_{mod,n}$ issu d'une prédiction linéaire menée sur les échantillons précédents \hat{J}_{n-i} . Cette régression est menée source par source pour permettre d'adapter la longueur de la mémoire de prédiction à chaque source. En effet, l'idée est d'augmenter la taille de la mémoire pour accroître la précision de la prédiction, tant que l'amplitude de la source s continue d'évoluer linéairement, c'est-à-dire tant que l'estimée \hat{J}_n^s colle à son modèle $J_{mod,n}^s$. Quand ce n'est plus le cas, cela signifie que l'amplitude de la source s a changé de pente et qu'il faut donc réinitialiser la mémoire pour "oublier" la pente précédente. Le processus d'estimation-modélisation est illustré à la figure 2.

2.2.2 Méthode

Pour chaque source s , l'idée est de contraindre son amplitude J_n^s à être proche du modèle $J_{mod,n}^s$ au travers d'une

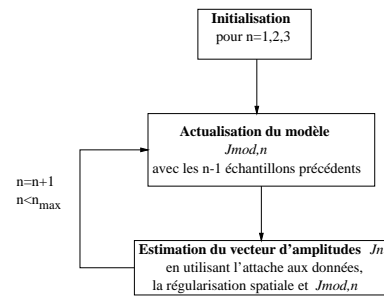


FIG. 2 – *Processus d'estimation-modélisation*




FIG. 3 – *La courbe représente le déroulement temporel d'une source à estimer. Les points sont les échantillons estimés en chaque instant. I: Initialisation, l'échantillon 1 est calculé sans modèle temporel. CD: Contrainte de Douceur, les échantillons 2 et 3 sont estimés avec pour contrainte la ressemblance respective aux échantillons 1 et 2. Les échantillons 4, 5, et 6 sont estimés avec un modèle temporel issu de la régression linéaire sur l'ensemble des échantillons précédents. M: Modèle, l'échantillon 7 est loin de son modèle M. Cela signifie un changement de pente dans la course temporelle de la source. La taille de la mémoire de régression est donc ramenée à 3 échantillons. L'échantillon 8 aura donc pour modèle la régression linéaire sur les échantillons 5, 6 et 7. Et ainsi de suite.*

fonction coût ϕ_t - fonction de Lorentz dans notre cas¹ - pénalisant leur différence :

$$U_t(J_n) = \sum_{s=1}^N \phi_t(J_n^s - J_{mod,n}^s) \quad (4)$$

où N est le nombre total de sources, avec

$$\phi_t(u) = \frac{u^2}{1 + \left(\frac{u}{K_t^s}\right)^2} \quad (5)$$

K_t^s est adapté à chaque source séparément, comme décrit ci-dessous, et joue le rôle de seuil de détection d'une discontinuité.

Une fois que le vecteur \hat{J}_n est calculé, on vérifie qu'il est suffisamment "proche" de son modèle $J_{mod,n}$. Si ce n'est pas le cas, c'est-à-dire si la différence entre chaque composante $|J_{mod,n}^s - \hat{J}_n^s|$ est supérieure à un certain seuil μ_s , cela signifie que le modèle $J_{mod,n}^s$ n'était pas adapté à la source s . La taille de la mémoire de la source s doit donc

1. ce choix entraîne la perte de la convexité du critère. Cependant, il nous semble important pour obtenir deux types de pénalisation bien distincts, une pénalisation quadratique autour de l'origine, et une pénalisation bornée au delà. Une discussion intéressante concernant le choix des fonctions potentielles est disponible dans [4]

être réinitialisée. Au contraire, si $|J_{mod,n}^s - \hat{J}_n^s| < \mu_s$, la taille de la mémoire est incrémentée de 1, comme nous allons le voir dans le prochain paragraphe.

On considère par définition que \hat{J}_n^s est “proche” de son modèle $J_{mod,n}^s$, si leur différence reste du même ordre que les différences entre les points d'échantillonnage et la droite de régression. On choisit donc empiriquement l'expression suivante pour μ_s :

$$\mu_s = m_{p=1,\dots,L_s}(|J_p^s - J_{mod,p}^s|) + 2\sigma_{p=1,\dots,L_s}(|J_p^s - J_{mod,p}^s|) \quad (6)$$

où m désigne la valeur moyenne, et σ l'écart-type, et les $J_{mod,p}^s$ sont les points sur la droite de régression aux instants p . Ce seuil peut être aussi utilisé dans la fonction potentielle, K_i^s est donc calculé de la façon suivante avant d'être normalisé entre zéro et un :

$$K_i^s = \frac{1}{\mu_s} \quad (7)$$

De cette façon, si le seuil μ_s est faible, c'est-à-dire si la droite de régression est proche de l'ensemble des points utilisés de la mémoire, on aura tendance à contraindre de façon plus stricte \hat{J}_n^s à être proche du modèle $J_{mod,n}^s$.

2.2.3 Une mémoire à taille variable

Lorsque le modèle $J_{mod,n}^s$ n'était pas adapté à la source s , la mémoire de cette source doit être réinitialisée. L'échantillon J_{n+1}^s est alors estimé avec un modèle à “mémoire courte”, c'est-à-dire en ne considérant que les trois échantillons précédents J_n^s , J_{n-1}^s et J_{n-2}^s pour la prédiction linéaire. À l'instant $n+2$, la taille de la mémoire est allongée, en construisant $J_{mod,n+2}^s$ avec les quatre échantillons précédents, et ainsi de suite. Cette procédure est répétée jusqu'à atteindre une taille maximale de longueur de mémoire L_{max} , largement corrélée à la fréquence d'échantillonnage. Intuitivement L_{max} correspond à la longueur du signal entre deux passages par zéro, voir figure. On peut donc en estimer un majorant sur les signaux de surface. Cette procédure de variation de la taille de la mémoire est menée séparément pour chaque source afin d'obtenir un modèle temporel adaptatif, et autoriser l'apparition déphasée de sources actives.

Par ailleurs, nous nous plaçons dans le schéma à résolution variable décrit dans [1]. À chaque niveau de résolution des contraintes spatiales anatomo-fonctionnelles sont introduites et automatiquement adaptées au niveau de résolution, tout comme les paramètres de régularisation.

2.2.4 Récapitulatif des différentes étapes

La procédure d'estimation de sources, dans notre schéma multirésolution et utilisant un modèle temporel adapté à chaque source est la suivante :

1. Initialisation : Le vecteur d'amplitudes des sources au premier échantillon de la fenêtre temporelle, J_1 est estimé sans terme de régularisation temporelle. J_2 et J_3 sont estimés avec un terme de régularisation temporelle de type contrainte de douceur temporelle. La longueur de la mémoire L_s est fixée égale à 3 pour toutes les sources s .

2. Pour chaque latence $3 < n < n_{max}$:

- (a) Calcul du modèle temporel de chaque source : $J_{mod,n}^s$ est la prédiction linéaire estimée à partir des L_s échantillons précédemment estimés;
- (b) J_n est estimé en minimisant le critère : $U(J_n) = \|M_n - GJ_n\|^2 + U_s(J_n) + U_t(J_n)$, où $U_t(J_n) = \sum_{s=1}^S \phi_t(J_n^s - J_{mod,n}^s)$;
- (c) Mise à jour de la taille de la mémoire pour chaque source s : si $|J_n^s - J_{mod,n}^s| > \mu_s$, aller en (d) sinon aller en (e)
- (d) $L_s = 3$,
 $n = n + 1$, aller en 2;
- (e) si $L_s < L_{max}$, $L_s = L_s + 1$,
sinon $L_s = L_s$,
 $n = n + 1$, aller en 2;

Nous allons à présent décrire la procédure de calcul du modèle temporel $J_{mod,n}^s$ par régression linéaire.

2.2.5 Régression linéaire robuste

Considérons le problème de choix de la meilleure approximation linéaire passant par L points (t_i, J_i^s) . Une première intuition consiste à minimiser l'écart entre cette droite et tous les points d'échantillonnage :

$$(\hat{a}_s, \hat{b}_s) = \underset{(a,b)}{\operatorname{argmin}} \left(\sum_{i=1}^L (\hat{J}_i^s - (a_s t_i + b_s))^2 \right) \quad (8)$$

Cependant, dans notre cas, certaines sources ont pu être estimées de façon erronée aux latences précédentes, il est important de mener une régression linéaire “robuste” à partir des (t_i, J_i^s) . Plus précisément, la droite sélectionnée devra être proche des points d'échantillonnage (t_i, J_i^s) , à l'exception de ceux *trop loin* des autres, voir figure 4 pour l'illustration de cette idée. Pour cela, on optimise un critère non quadratique :

$$(\hat{a}_s, \hat{b}_s) = \underset{(a,b)}{\operatorname{argmin}} \left(\sum_{i=1}^L f(at_{n-i} + b - J_{n-i}^s) \right), \quad (9)$$

où f est une fonction potentielle qui pénalise fortement les valeurs autour de l'origine, mais laisse les fortes valeurs apparaître, en supposant que ces points correspondent à des points aberrants. Encore une fois, c'est la fonction de Lorentz qui nous a semblée la plus à même de réaliser ce compromis :

$$f(u) = \frac{u^2}{1 + \frac{u^2}{K^2}} \quad (10)$$

Et ainsi, J_{mod} à l'instant n est calculé pour chaque source s :

$$J_{mod,n}^s = a_s^n t_n + b_s^n \quad (11)$$

3 Simulations

Nous présentons des résultats préliminaires obtenus lors d'une simulation numérique. Pour cela une source corticale




FIG. 4 – Exemple de nuage de points nécessitant une méthode de régression linéaire robuste : les techniques non-robustes telles que les moindres carrés montrent une trop grande sensibilité face aux points aberrants.

TAB. 1 – Comparaison des performances des méthodes de régularisation temporelle.

Méthode	RV	cc	d_{max}
Douceur temp.	1,85%	0,9755	0,89 cm
Modèle lin.	2,23%	0,9962	0,65 cm

dont la course temporelle est une “vraie” pointe intercritique épileptique mesurée lors d’enregistrements intracrâniens est virtuellement activée à une position connue. On cherche alors à reconstruire son activité. Pour évaluer la qualité de la reconstruction, nous avons défini trois paramètres :

- la variance résiduelle RV ,
- le coefficient de corrélation cc entre la course temporelle de la source de plus forte amplitude et la course temporelle de la source simulée,
- la distance d_{max} entre la source simulée et la source de plus forte amplitude estimée.

Les résultats sont présentés dans la table 1, et les courses temporelles simulées et reconstruites sont montrées dans la figure 5. Ils montrent que la régularisation temporelle a permis de reconstruire de façon presque parfaite la course temporelle de la source maximale retrouvée, avec un coefficient de corrélation supérieur à 0,99, alors qu’il n’était inférieur à 0,98 avec une simple contrainte de douceur temporelle. La localisation de la source d’amplitude maximale est par ailleurs améliorée puisqu’on obtient une erreur de localisation de 0,65 cm, contre 0,89 cm avec la contrainte de douceur. D’un point de vue qualitatif, les résultats demandent encore à être améliorés. En effet, plusieurs sources “fantômes” sont identifiées, avec des décours temporels très chahutés, cf. figure 5.

4 Conclusion

La méthode de régularisation spatio-temporelle à résolution variable a permis une meilleure reconstruction de la source, aussi bien en terme de localisation, qu’en terme de dynamique d’activation qu’une méthode utilisant une régularisation spatiale alliée à une contrainte d’évolution douce des courses temporelles, voir figure 5. Ces résul-

tats sont encourageants, même si plusieurs problèmes subsistent. En particulier, on voit sur les tracés des oscillations parasites qu’idéalement un modèle devrait pouvoir éviter, en allongeant par exemple la taille de la mémoire. Par ailleurs, des simulations plus complètes doivent être menées, pour reconstruire plusieurs sources déphasées, modélisant un réseau épileptogène.




FIG. 5 – Reconstruction d’une pointe intercritique simulée (c). Les courses reconstruites avec une contrainte de douceur temporelle sont montrées en (a) ; celles utilisant le modèle temporel linéaire par morceaux en (b). Le résultat (b) est plus satisfaisant car les courses temporelles des 2 sources maximales sont très proches de la course réelle. Les oscillations parasites peuvent être facilement repérées et identifiées comme du bruit. Le résultat (a) montre lui des courses temporelles plus éloignées de la course réelle, et une activité plus répartie.

Références

- [1] L. Gavit, M. Petrou, and L. Garnero, “Approche multirésolution de la reconstruction de l’activité électrique cérébrale en EEG/MEG”, in *GRETSI’99*, 1999.
- [2] L. Gavit, S. Baillet, J. Mangin, J. Pescatore, and L. Garnero, “A multiresolution framework to MEG/EEG source imaging”, *IEEE Trans. Biomedical Engineering* in press, 2001.
- [3] S. Baillet and L. Garnero, “A Bayesian approach to introducing anatomo-functional priors in the EEG/MEG inverse problem”, *IEEE Trans. Biomedical Engineering*, vol. 44, no. 5, pp. 374–385, may 1997.
- [4] J. Idier, “Regularization tools and models for image and signal reconstruction”, in *3rd Intern. Conf. Inverse Problems in Engineering*, Port Ludlow, U.S.A., June 1999, pp. 1–6.