

Comparaison de Problèmes Inverses pour la classification d'activité cérébrale en temps réel

Joan Fruitet, Maureen Clerc

► **To cite this version:**

Joan Fruitet, Maureen Clerc. Comparaison de Problèmes Inverses pour la classification d'activité cérébrale en temps réel. GRETSI 2009, 2009, DIJON, France. 2009. <hal-00727083>

HAL Id: hal-00727083

<https://hal.inria.fr/hal-00727083>

Submitted on 1 Sep 2012

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Comparaison de Problèmes Inverses pour la classification d'activités cérébrales en temps réel.

JOAN FRUITET¹, MAUREEN CLERC¹

¹ Equipe projet Odyssee, INRIA
2004, route des lucioles, BP 93, 06902 Sophia Antipolis Cedex, France

¹Joan.Fruitet@inria.fr, Maureen.Clerc@inria.fr

Résumé - Cet article compare l'apport de différentes méthodes de résolution du problème inverse pour la classification de l'activité cérébrale en temps réel. Un jeu de données provenant d'une expérience de somatotopie en MEG a été utilisé et une expérience d'imagination motrice en EEG a été réalisée. L'objectif est de classer les données afin de retrouver, à partir des enregistrements MEG, quel doigt a été l'objet d'une stimulation, et à partir des données EEG, quelle a été la tâche motrice réalisée. Pour cela, diverses méthodes de résolution du problème inverse sont utilisées pour reconstruire l'activité corticale et ainsi augmenter la résolution spatiale. Un algorithme récursif se servant du t-test de Student est proposé pour sélectionner les sources corticales pertinentes pour la classification. Les résultats sont obtenus à l'aide d'une Machine à Vecteur Support (SVM). Sur l'ensemble des données traitées, l'utilisation du Minimum-Norm n'entraîne pas d'amélioration significative des taux de classification. En revanche, l'application du Beamforming a permis de faire progresser le pourcentage de réussite de 80.2% à 83.4% en moyenne pour la MEG et 60% à 62% pour l'EEG.

Abstract - This article compares the contribution of different methods of resolution of the inverse problem for the classification of brain activity in real time. A set of data from an somatotopic experiment in MEG has been used and an experiment of motor imaginary in EEG was performed. The aim is to classify the data in order to retrieve, from the MEG recordings, which finger has been stimulated, and for the EEG data, which motor task was mentally performed. For this, various methods for solving the inverse problem are used to reconstruct the cortical activity and enhance the spatial resolution. A recursive algorithm using Student's t-test is proposed to select the cortical sources relevant for classification. The results are obtained using a Support Vector Machine (SVM). Overall, the use of the Minimum-Norm does not improve significantly the rate of classification. However, the use of the Beamforming increases the results from 80.2% to 83.4% for the MEG experiment and from 60% to 62% for the EEG experiment.

1 Introduction

1.1 Interface Cerveau Ordinateur ou BCI

De nombreuses études [1-3], durant les deux dernières décennies, ont montré qu'il est possible d'utiliser les signaux électromagnétiques enregistrés à la surface du scalp (par électroencéphalographie, EEG ou magnétoencéphalographie, MEG) comme moyen de communication ou de contrôle ne faisant pas intervenir le système moteur. Les dispositifs utilisant ces signaux, provenant directement du cortex, sont appelés Interface Cerveau Ordinateur (ou BCI pour *Brain Computer Interface*). Ils ont, comme première vocation, de permettre à des personnes souffrant de graves dysfonctionnements moteurs de retrouver un moyen de communication avec le monde extérieur [2-3]. A moyen terme, les BCI peuvent être vus comme complémentaires des interfaces traditionnelles (clavier, souris...).

1.2 Intérêt de la reconstruction des sources corticales pour les BCI

La MEG et l'EEG ont comme avantage d'être totalement non-invasifs et d'avoir une très bonne résolution temporelle, ce qui en fait des méthodes de prédilection pour les BCI chez l'être humain.

Cependant, les capteurs étant situés à la surface du scalp, l'analyse directe des signaux ne permet pas toujours de distinguer des phénomènes ayant des origines voisines dans le cortex. Il est alors possible d'essayer de déconvoluer les signaux mesurés pour reconstruire les sources corticales qui ont généré ces mesures. Une telle approche peut améliorer l'efficacité d'une BCI [4].

2 Matériels et méthodes

2.1 Les données d'enregistrement

Les données utilisées dans cet article proviennent de deux expériences : une expérience MEG de somatotopie [5] et une expérience EEG d'imagination motrice.

2.1.1 Les données MEG

L'expérience de somatotopie est réalisée sur un sujet présentant une dystonie de la main gauche. Les enregistrements sont effectués par une MEG à 151 gradiomètres. Durant chaque essai un doigt est stimulé par une impulsion électrique sur la dernière phalange. Environ 350 stimulations sont réalisées pour chaque doigt. Chaque stimulation provoque plusieurs bouffées d'activité neuronale dans une zone particulière du cortex somatosensoriel correspondant au doigt stimulé (Figure 1). L'objectif est ici de retrouver, pour chaque

essai, quel doigt a été stimulé à partir de l'analyse des signaux MEG.




Figure 1 : Zone corticale associée à la stimulation de quatre doigts de la main droite. (Figure provenant de [5])

2.1.2 L'expérience EEG

Le sujet, un homme de 25 ans n'ayant aucune expérience avec les BCI, est assis à 1,5m d'un écran LCD de 23". L'EEG est enregistré sur 64 électrodes avec une fréquence d'échantillonnage de 2048Hz. L'expérience est composée de cinq blocs de 12 essais. Chaque essai commence par l'apparition d'une croix de fixation au centre de l'écran. 0,5 secondes plus tard une image représentant l'une des six tâches motrices apparaît (Figure 2). Le sujet doit alors, durant 8 secondes, imaginer réaliser la tâche sans quitter la croix de fixation des yeux. Une pause de 1,5 secondes est observée avant l'essai suivant. Les six tâches mentales sont: imaginer jouer de la basse (le sujet est un bassiste amateur), imaginer bouger l'index droit, la main droite, la main gauche, le pied droit et le pied gauche.




Figure 2 : Les six tâches d'imagination motrice.

2.2 Prétraitement des signaux et extraction des variables de classification

2.2.1 Pour les données MEG

On définit quatre variables de classification pour chaque électrode, ou source, comme étant les valeurs du signal 42, 57, 80 et 134 ms après la stimulation. Ces instants correspondent aux maxima des bouffées d'activités observées en moyenne sur l'ensemble des stimulations.

2.2.2 Pour les données EEG

Les données EEG étant beaucoup plus bruitées et polluées par des sources extérieures que les données MEG, il est nécessaire d'effectuer des prétraitements.

Un filtrage entre 4 et 40Hz est réalisé, puis les électrodes sont re-référencées par rapport à la moyenne des électrodes.

Afin d'être compatible avec une expérience temps réel, chaque essai est découpé en 28 fenêtres glissantes de 1 seconde. L'objectif est ici de retrouver pour chaque fenêtre quelle tâche mentale devait être accomplie. On utilise comme variables de classification la puissance du signal à 21 bandes de fréquences, comprises entre 6 et 36 Hz, pour chaque électrode ou source si un modèle inverse est utilisé.

2.3 Les différentes méthodes pour la localisation de source corticales en temps réel

Plusieurs méthodes existent pour reconstruire les sources corticales à l'origine des signaux MEG ou EEG. Ces méthodes étant sensibles au bruit, elles sont généralement conçues pour être appliquées, offline, sur des signaux moyennés sur un grand nombre d'essais afin d'obtenir une localisation fiable.

Les deux méthodes suivantes, résultant d'approches différentes, sont cependant applicables en temps réel. Elles utilisent, dans le cas de l'expérience MEG, un modèle réaliste de la tête du sujet, réalisé à partir d'images IRM. Pour l'expérience EEG, le sujet n'ayant pas passé d'IRM, un modèle de tête a été utilisé.

Pour les données EEG, les résultats sont comparés à l'utilisation du Laplacien de surface qui est souvent utilisé en BCI [6].

2.3.1 Minimum-Norm surfacique

On représente l'activité corticale par une distribution d'un grand nombre de dipôles sur une surface modélisant la matière grise du cortex. Chaque dipôle représente une macro-colonne corticale et son intensité traduit l'activité de cette dernière.

La première étape consiste à modéliser et résoudre le problème direct, soit de calculer la matrice de gain G reliant le vecteur des mesures $M(t)$ réalisées sur les capteurs à l'instant t à l'intensité des sources $S(t)$:

$$M(t) = GS(t) + N(t) \quad (1)$$

$N(t)$ modélisant le bruit que l'on suppose additif et Gaussien centré.

La résolution du problème inverse par Minimum-Norm consiste à calculer une distribution de sources minimisant la norme de la différence entre les mesures $M(t)$ et les mesures idéales $G.S(t)$:

$$\min_S \|M - G.S\|^2 \quad (2)$$

Le nombre de sources (de l'ordre de 10^4) étant très supérieur au nombre de capteurs (environ 64 pour l'EEG et 250 pour la MEG), la matrice G est à rang déficient et le minimum n'est pas unique. Une méthode pour obtenir un minimum unique est d'utiliser une régularisation, comme la régularisation de Tikhonov (3) dont l'unique solution est donnée par l'équation (4).

$$\min_S \|M - G.S\|^2 + \lambda \|S\|^2 \quad (3)$$

$$S_\lambda = AM \text{ avec } A = G^T(GG^T + \lambda I)^{-1} \quad (4)$$

L'avantage de cette méthode est que la matrice A peut être calculée avant l'expérience. La résolution du problème inverse est alors réduite à une multiplication matricielle et peut être effectuée en temps réel.

La localisation de sources par Minimum-Norm revient à chercher la distribution de sources de norme minimale qui explique au mieux le signal mesuré. Le paramètre de régularisation doit être ajusté pour que la distribution de source reste compatible avec les mesures tout en évitant d'expliquer le bruit. Un des inconvénients de cette méthode est donc que le bruit contenu dans les mesures peut être partiellement projeté sur les sources. L'autre inconvénient provient de l'utilisation de la norme L2 pour la pénalisation, ce qui

produit une solution très lisse. La norme L1 permet d'obtenir une meilleure résolution spatiale mais, la solution n'étant plus linéaire, il n'est pas possible de l'appliquer en temps réel.

Deux variantes du Minimum-Norm ont été utilisées. Le Minimum-Norm pondéré, qui consiste à appliquer à la matrice G une pondération pour éviter que les sources profondes du cortex soient sous-estimées [7]. Cette variante est très proche de la méthode sLORETA qui a été appliquée avec succès dans le cadre des BCI [6]. La deuxième variante ajoute une régularisation pénalisant les fortes variations temporelles (équation 5), mais cela rend les temps de calcul beaucoup plus importants et est donc plus difficilement applicable en temps réel.

$$\min_S \|M - G \cdot S\|^2 + \lambda \|S\|^2 + \mu \left\| \frac{dS}{dt} \right\|^2 \quad (5)$$

2.3.2 Beamforming

Le Beamforming, ou formation de voies, consiste à construire un filtre spatial ne laissant passer que le signal provenant d'une petite zone de l'espace. Le principe du Beamforming repose sur l'hypothèse que les sources spatialement disjointes sont décorréélées et que le bruit n'est pas corrélé avec les sources.

Comme pour le Minimum-Norm, le Beamforming implique d'abord de résoudre le problème direct pour calculer le vecteur de gain $g(x_0)$ associé à la position x_0 de la source cherchée. Les poids du filtre $w(x_0)$ peuvent être pré-calculés grâce à l'équation (6), où C_M représente la covariance des mesures.

$$w(x_0) = \frac{C_M^{-1} g(x_0)}{g(x_0)^T C_M^{-1} g(x_0)} \quad (6)$$

L'intensité de la source en x_0 peut alors être estimée en chaque instant par l'équation (7).

$$s(x_0, t) = w(x_0)^T M(t) \quad (7)$$

La principale différence avec le Minimum-Norm est que le Beamforming ne cherche pas à expliquer l'ensemble du signal mesuré, mais à le filtrer pour en extraire l'information provenant d'une position de l'espace. Les bruits extérieurs (bruits ambiants ou dus à l'activité musculaire) sont donc mieux éliminés et risquent moins d'être projetés sur les sources que dans le Minimum-Norm. Cependant, le Beamforming est très sensible à la qualité de la matrice de Gain et de la matrice de covariances des mesures et plusieurs dizaines de minutes de signal peuvent être nécessaires pour l'estimer correctement. Le signal utilisé pour estimer la matrice de covariance étant antérieur au signal que l'on veut filtrer, le Beamforming peut être appliqué en temps réel, la seule contrainte étant de se contenter d'une matrice de covariance imprécise durant les premières minutes d'enregistrement.

2.4 Sélection de variables et classification

L'espace des sources étant de très haute dimension, il n'est pas possible d'utiliser les variables de classification issues de l'ensemble des sources. Un algorithme récursif de sélection de variables utilisant le t-test de Student est proposé pour réduire l'espace de classification: la première variable sélectionnée est celle

ayant le plus haut t-test de Student calculé par l'équation suivante :

$$F(v) = \frac{|\bar{v}_1 - \bar{v}_2|}{\sqrt{\frac{S_{v_1}^2 + S_{v_2}^2}{n}}} \quad (8)$$

où \bar{v}_i et S_{v_i} sont la moyenne et la variance de la variable v sur l'ensemble des n essais portant sur le doigt i .

En définissant un produit scalaire sur l'espace des variables par l'équation (9), l'information contenue dans la variable sélectionnée peut être retirée des autres variables en les projetant orthogonalement à celle-ci (10).

$$\langle u|v \rangle = \sum_{i \in E} u(i) * v(i) \quad (9)$$

$$\tilde{v} = v - \frac{\langle v|v^* \rangle}{\|v^*\|^2} v^* \quad (10)$$

avec $u(i)$ la valeur de la variable u pour l'essai i , E l'ensemble des essais et \tilde{v} la projection de la variable v orthogonalement à la variable sélectionnée v^* . La sélection se poursuit de façon récursive en sélectionnant une nouvelle variable ayant le plus haut t-test de Student (pour éviter de sélectionner des variables ne contenant pas originellement de l'information, on moyenne les résultats de ce nouveau t-test avec ceux des variables originelles).

Ce mode de sélection de variables récursif permet d'obtenir de meilleurs résultats de classification et avec un nombre de variables bien plus faible que la sélection directe des N variables ayant le plus grand t-test. (Figure 3).

Afin de permettre une meilleure comparaison, ce mode de sélection de variables a été utilisé avec et sans problème inverse.

Une fois les variables sélectionnées, la classification est effectuée par un SVM avec un noyau linéaire. La fiabilité des résultats est estimée par validation croisée. Afin d'éviter tout biais pour l'expérience EEG, les fenêtres issues d'un même essai ne sont jamais partagées entre données d'apprentissage et données test.




Figure 3 : Evolution du pourcentage de bien classés en fonction du nombre de variables sélectionnées, sur les données d'apprentissage (traits pleins) et les données test (pointillés). Expérience EEG avec utilisation du Beamforming.

3 Résultats et discussion

3.1 Résultats quantitatif sur les données MEG

L'utilisation du Beamforming permet d'améliorer la classification de 3.2% en moyenne (intervalle de confiance à 95% : [2.6%, 3.7%]). En revanche, le

Minimum-Norm pondéré entraîne une très légère baisse des résultats avec -0.6% en moyenne (intervalle de confiance à 95% : [-1.2%, -0.0%]).

Tab 1: Classification binaire entre deux doigts appartenant aux deux mains, à la main droite ou à la main gauche et en moyenne sur toutes les paires de doigts. Résultats en pourcentage de doigts bien classés. Entre parenthèses : l'apport des méthodes par rapport à l'utilisation directe des capteurs, seules les variations en gras sont significatives à 95%.

Méthode	Inter mains	Intra main D.	Intra main G.	Moyenne
Sans Pb. inverse	89.5%	72.4%	63.3%	80.2%
MN	88.4% (-1.1%)	73.0% (+0.6%)	58.7% (-4.6%)	78.8% (-1.5%)
MN pondéré	88.8% (-0.7%)	73.8% (+1.4%)	60.9% (-2.4%)	79.6% (-0.6%)
MN pondéré temporel	89.7% (+0.2%)	71.7% (-0.7%)	61.7% (-1.6%)	79.8% (-0.4%)
Beamforming	92.7% (+3.1%)	75.9% (+3.5%)	66.2% (+2.9%)	83.4% (+3.2%)

3.2 Résultats quantitatifs sur les données EEG

Les résultats varient fortement suivant les tâches. Il est possible de différencier « imaginer jouer de la basse » et imaginer bouger l'index droit avec plus de 80% de réussite, par contre il est impossible de différencier un mouvement imaginaire du pied droit d'un du pied gauche.

Comme pour l'expérience MEG, seule l'utilisation du Beamforming est capable d'améliorer significativement les résultats avec un gain de 2.1% en moyenne (Tab 1).

Tab 2: Classification binaire entre deux tâches. Résultats moyens en pourcentage de tâches bien classées et apport des méthodes par rapport à l'utilisation directe des électrodes (seules les variations en gras sont significative à 95%).

Méthode	Moyenne	Gain
Sans pb. inverse	59.9%	
Laplacien	60.9%	+1.0% [-0.3, +2.2]
MN pondéré	60.7%	+0.8% [-1.2, +2.8]
Beamforming	62.0%	+2.1% [+0.3, +3.8]

3.3 Localisation des sources en MEG et EEG

Les figures 3 et 4 montrent que même si le Beamforming ne permet pas une localisation plus précise que le Minimum-Norm il permet d'obtenir des variables plus discriminantes.




Figure 4 : Localisation des variables discriminantes en MEG par t-test de Student pour différencier index et auriculaire de la main droite. De gauche à droite : Sans problème inverse, avec Minimum-Norm pondéré et Beamforming.




Figure 5 : Localisation des variables discriminantes en EEG par t-test de Student pour différencier « jouer de la basse » et « bouger l'index droit ». De gauche à droite : Sans problème inverse, avec Minimum-Norm pondéré et Beamforming.

3.4 Discussion et perspectives

Il est probable que l'amélioration liée à l'utilisation du Beamforming provienne de l'emploi de la matrice de covariance des mesures. En effet, cette matrice, qui sert à calculer le filtre spatial, permettrait simultanément d'atténuer l'influence du bruit provenant des autres zones du cerveau et de l'extérieur. Grosse-Wentrup *et al.* mettent en évidence un apport du Beamforming dans le cas où les données EEG sont particulièrement bruitées [9].

Le Minimum-Norm, lui, n'est capable dans aucune des deux expériences d'augmenter significativement la résolution spatiale de la MEG et de l'EEG. Ceci peut être expliqué, pour les données MEG, par un trop grand lissage dû à l'utilisation de la norme L2. Pour les données EEG, il est probable qu'utiliser un modèle réaliste de la tête du sujet réalisé à partir d'image IRM permette de meilleurs gains dans l'utilisation des méthodes inverses.

Références

- [1] L. A. Farwell & E. Donchin, "Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials" *Electroencephalogr. Clin. Neurophysiol.* 70 510-523, **1988**
- [2] G. Pfurtscheller, D. Flotzinger & J. Kalcher, "Brain-computer interface - a new communication device for handicapped persons" *J. Microcomp. Applic.* 16 293-299, **1993**
- [3] N. Birbaumer *et al.*, "A spelling device for the paralyzed" *Nature* 398 297-298, **1999**
- [4] M. Besserve "Analyse de la dynamique neuronale pour les Interfaces Cerveau-Machines : un retour aux sources" Thèse, **2007**
- [5] S. Meunier *et al.*, "Human brain mapping in dystonia reveals both endophenotypic traits and adaptative reorganization" *Annals of Neurology* 50, **2001**
- [6] D. J. McFarland *et al.*, "Spatial filter selection for EEG-based communication" *Electroenceph. Clin. Neurophysiol.* 103 386-394, **1997**
- [7] F.-H. Lin *et al.* "Assessing and improving the spatial accuracy in MEG source localization by depth-weighted minimum-norm estimates" *NeuroImage* 31 **2006**
- [8] F. Lotte, A. Lecuyer & B. Arnaldi "FuRIA : un nouvel algorithme d'extraction de caractéristiques pour les interfaces cerveau-ordinateur utilisant modèles inverses et modèles flous" *Colloque GRETSI* **2007**
- [9] M. Grosse-Wentrup *et al.*, "Beamforming in Noninvasive Brain-Computer Interfaces" *IEEE Trans. Bio. Eng.* 56, **2009**

Remerciements à Alexandre Gramfort pour son aide et pour la mise à disposition de ses scripts Matlab pour la résolution du problème inverse.