

Comparaison de solutions à base d'ondelettes spatiales pour le problème inverse M/EEG

Samy MOKHTARI¹ Jean-Michel BADIER² Christian BÉNAR² Bruno TORRÉSANI¹

¹Aix Marseille Univ, CNRS, I2M, Marseille, France

²Aix Marseille Univ, INSERM, INS, Inst Neurosci Syst, Marseille, France

Résumé – Cet article décrit de nouvelles approches au problème inverse M/EEG intégrant une pénalisation favorisant la parcimonie dans un domaine d'ondelettes spatiales. Il compare des versions variationnelles (minimisation d'une attache aux données quadratique, avec régularisation favorisant la parcimonie) et Bayésiennes (*sparse Bayesian learning*) avec des approches plus classiques. Des résultats numériques (données simulées et réelles) montrent la capacité de ces approches à bien estimer des activités cérébrales localisées dans des régions étendues, tant en termes d'erreur de localisation que d'erreur sur l'amplitude des sources.

Abstract – This paper describes new approaches to the inverse M/EEG problem incorporating a penalty favoring sparsity in a spatial wavelet domain. It discusses and compares variational (minimization of a quadratic data fidelity, with sparsity promoting regularization) and Bayesian (*sparse Bayesian learning*) versions with more classical approaches. Numerical results (simulated and real data) show the ability of these approaches to estimate brain activities localized in extended regions, both in terms of spatial localization and sources amplitude.

1 Introduction, état de l'art

La localisation des sources cérébrales à partir de mesures EEG (électro-encéphalographie) ou MEG (magnéto-encéphalographie) joue un rôle central en neurosciences cognitives et pour le diagnostic et le traitement de troubles neurologiques. Disposer de méthodes précises de localisation de sources, *i.e.* de détermination de régions actives sur le cortex, devient essentiel. La majorité des approches privilégie la localisation des zones actives à la reconstruction fidèle de l'amplitude des densités de courant. Il y a un enjeu à améliorer la précision des algorithmes tant en termes de localisation que d'amplitude des sources reconstruites.

Nous nous focalisons ici sur les formulations variationnelles et Bayésiennes du problème inverse. On note $\mathbf{Z} \in \mathbb{R}^{J \times L}$ les données mesurées (J capteurs ou canaux spatiaux obtenus après blanchiment/réduction de dimension, et L échantillons temporels). On suppose disposer également d'une description géométrique de la surface corticale sous forme d'une triangulation, qui fournit un graphe à N sommets (de positions connues) et E arêtes. Les sources sont modélisées par une matrice $\mathbf{S} \in \mathbb{R}^{N \times L}$, l'équation d'observation est de la forme

$$\mathbf{Z} = \mathbf{G}\mathbf{S} + \mathbf{B} \quad (1)$$

où \mathbf{G} est la matrice de gain, qui résume la propagation du champ électromagnétique du cortex vers les capteurs, et \mathbf{B} la ligne de base, inconnue, modélisée comme un vecteur aléatoire Gaussien iid (résultat d'un blanchiment spatial préalable).

Il existe une importante littérature sur la localisation de sources M/EEG, avec des approches basées sur des formulations et hypothèses différentes. On peut notamment citer les méthodes de *dipole fitting* [12, 10], diverses techniques de formation de voies [18, 16], et les approches variationnelles et/ou Bayésiennes sur lesquelles nous nous focaliserons, avec des formulations basées sur la minimisation d'une fonction

objectif incluant une attache aux données quadratique, et une pénalisation $f_\gamma(\mathbf{S})$ dépendant d'hyper-paramètres notés γ .

Les régularisations quadratiques conduisent aux solutions explicites appelées MNE [9] et wMNE [5]. Ces solutions sont souvent trop étendues spatialement, et tendent à sous-estimer les sources profondes. Pour mieux contrôler l'extension spatiale des solutions, des choix de régularisation favorisant la parcimonie ont été proposés. Parmi eux, on peut mentionner MCE [11], basé sur une régularisation ℓ^1 , MxNE [13] basé sur des normes mixtes favorisant parcimonie en espace et persistance en temps, VB-SCCD [4] basé sur une norme de variation totale sur graphe, SVB-SCCD [1] variante ajoutant un terme de parcimonie en espace, ainsi que des variations autour de ces idées. Les pénalisations étant non lisses, les problèmes correspondants sont résolus par des algorithmes adaptés.

Les hyperparamètres γ sont choisis par des heuristiques, ou des méthodes plus élaborées. Les méthodes d'apprentissage Bayésien parcimonieux [19] considèrent plutôt γ comme inconnue du problème, les sources étant traitées comme variables latentes sur lesquelles est effectuée une marginalisation. Ceci conduit à un problème d'optimisation non-convexe, généralement résolu par des algorithmes MM (voir [7] pour une synthèse). Nous décrivons ici une approche implémentant la parcimonie non plus dans le domaine spatial (*i.e.* sur le cortex), mais dans un domaine transformé, en l'occurrence dans une représentation d'ondelettes spatiales. L'objectif est d'explorer des méthodes favorisant des solutions régulières par morceaux, comme dans le cas de traitement d'images classique. Nous montrons, en combinant les modèles variationnels et Bayésiens avec des représentations (redondantes) en ondelettes sur graphe [6] que cette combinaison permet effectivement de reconstruire des solutions localisées dans des régions sur la surface du cortex avec, sur un échantillon de métriques variées sensibles à différents types de distorsions, une précision supérieure aux méthodes existantes, dans le cas de données simulées et réelles de type potentiel évoqué auditif.

2 Utilisation d'ondelettes spatiales

2.1 Ondelettes sur surface ou graphe

Différentes approches existent pour construire des systèmes d'ondelettes sur des domaines non-standard, tels que variétés (surface dans le cas présent) ou graphes par exemple. On peut notamment citer les bases d'ondelettes construites par des techniques de relèvement (*lifting* [17]) à partir de discrétisations emboîtées, ou associées à des opérateurs de diffusion [3].

On se focalise ici sur la construction de [6] qui exploite la diagonalisation du Laplacien de graphe associé à la surface discrétisée (généralement disponible avec des données MEG). En quelques mots, le prolongement sur \mathbb{R}^+ du spectre $\{0, \dots, \lambda_{\max}\}$ du Laplacien est considéré comme domaine fréquentiel, sur lequel agit un opérateur de dilatation. Une trame de \mathbb{R}^N (famille génératrice, généralement surcomplète [2]) constituée d'ondelettes $\psi_{s,n}$ (centrée sur le vertex n du graphe, dilatée d'un facteur $s \in \{s_1, \dots, s_{N_s}\}$) et de fonctions d'échelle $\phi_n \in \mathbb{R}^N$ (centrée sur n , et captant les échelles inférieures à s_1) est ainsi obtenue par la procédure de [6]. Cette trame dépend du choix des échelles $\{s_1, \dots, s_{N_s}\}$, et de deux noyaux définis sur l'axe fréquentiel, qui donnent respectivement la fonction d'échelle et les ondelettes. On note $N_w = N(N_s + 1)$ le nombre total de vecteurs de cette trame, et \mathbf{W} la matrice associée. Les bornes A et B de la trame [2], qui contrôlent l'existence et la stabilité de l'inversion, sont les bornes inf et sup du spectre de $\mathbf{W}^T \mathbf{W}$.

2.2 Approches à la synthèse

Avec ces notations, on écrit $\mathbf{S} = \mathbf{W}^T \mathbf{A}$, avec $\mathbf{A} \in \mathbb{R}^{N_w \times L}$. Dans une approche à la synthèse l'équation (1) s'écrit

$$\mathbf{Z} = \tilde{\mathbf{G}} \mathbf{A} + \mathbf{B}, \quad (2)$$

avec $\tilde{\mathbf{G}} = \mathbf{G} \mathbf{W}^T$ une matrice de gain modifiée. Les formulations variationnelles prennent alors la forme générique

$$\mathbf{A}_* = \arg \min_{\mathbf{A} \in \mathbb{R}^{N_w \times L}} \left[\frac{1}{2} \|\mathbf{Z} - \tilde{\mathbf{G}} \mathbf{A}\|_F^2 + f_\gamma(\mathbf{A}) \right], \quad (3)$$

où $\|\cdot\|_F$ est la norme de Frobenius. Une fois \mathbf{A}_* obtenu, l'estimée correspondante des sources s'obtient par $\mathbf{S}_* = \mathbf{W}^T \mathbf{A}_*$. On se focalisera ici sur le cas

$$f_\lambda(\mathbf{A}) = \lambda \|\mathbf{A}\|_1, \quad f_{\lambda,\mu}(\mathbf{A}) = \lambda \|\mathbf{A}_\psi\|_1 + \mu \|\mathbf{A}_\phi\|_F^2, \quad (4)$$

où on écrit $\mathbf{A} = [\mathbf{A}_\psi : \mathbf{A}_\phi]$ en différenciant les coefficients d'ondelettes \mathbf{A}_ψ et d'échelle \mathbf{A}_ϕ . Ici $\lambda \in \mathbb{R}_+$ et $\mu \in \mathbb{R}_+$. Nous nommons ces approches sgw-MCE I et II.

La première formulation pénalise également coefficients d'échelle et d'ondelettes, la seconde les distingue. Dans les deux cas, nous utiliserons le même algorithme FISTA pour résoudre le problème d'optimisation. La norme ℓ^1 peut aussi être remplacée par une norme mixte $\ell^{2,1}$, sans modification de l'algorithme si ce n'est un changement d'opérateur proximal. Les hyperparamètres sont estimés par une heuristique

$$\mu = \frac{\|\tilde{\mathbf{G}}\|_F^2}{(\rho^2 - 1) \text{Tr}(\boldsymbol{\Sigma}_B)}, \quad \lambda = \frac{\sqrt{2}}{\sqrt{\rho^2 - 1}} \frac{\|\tilde{\mathbf{G}}\|_F}{\sqrt{\text{Tr}(\boldsymbol{\Sigma}_B)}}, \quad (5)$$

où ρ est une mesure de SNR dans le domaine des capteurs (obtenue en comparant signaux d'intérêt et ligne de base).

La formulation Bayésienne (*Sparse Bayesian Learning*, SBL) est elle aussi une transposition quasi directe de l'approche classique, et conduit à un problème non convexe

$$\underline{\gamma}_A^* = \arg \min_{\underline{\gamma}_A \in (\mathbb{R}_+)^{N_w}} \left[\text{Tr}(\mathbf{C}_Z \boldsymbol{\Sigma}_Z(\underline{\gamma}_A)^{-1}) + \ln \det(\boldsymbol{\Sigma}_Z(\underline{\gamma}_A)) \right] \quad (6)$$

où $\boldsymbol{\Gamma}_A = \text{diag}(\underline{\gamma}_A)$ est la matrice de covariance *a priori* des coefficients d'ondelettes (supposée diagonale), $\boldsymbol{\Sigma}_Z(\underline{\gamma}_A) = \mathbf{I}_J + \tilde{\mathbf{G}} \boldsymbol{\Gamma}_A \tilde{\mathbf{G}}^T$ est la matrice de covariance *a posteriori* des observations, et $\mathbf{C}_Z = \frac{1}{L} \mathbf{Z} \mathbf{Z}^T$ est la matrice de covariance empirique. Une fois $\underline{\gamma}_A^*$ obtenu, les sources sont évaluées via

$$\mathbf{A}_* = \boldsymbol{\Gamma}_A^* \tilde{\mathbf{G}}^T [\boldsymbol{\Sigma}_Z(\underline{\gamma}_A^*)]^{-1} \mathbf{Z}, \quad \mathbf{S}_* = \mathbf{W}^T \mathbf{A}_*. \quad (7)$$

Cette approche est nommée sgw-SBL.

On associe à $\mathbf{S} \in \mathbb{R}^{N \times L}$ une *carte d'amplitude* $\mathcal{A}_S \in \mathbb{R}^N$, calculée à partir d'un segment temporel $[l_0, l_1]$ où l'activité d'intérêt est présente, et une amplitude normalisée $\tilde{\mathcal{A}}_S$.

$$\mathcal{A}_S[k] \propto \left(\frac{1}{l_1 - l_0 + 1} \sum_{l=l_0}^{l_1} \mathbf{S}_{k,l}^2 \right)^{1/2}, \quad \tilde{\mathcal{A}}_S = \frac{\mathcal{A}_S}{\|\mathcal{A}_S\|_1}. \quad (8)$$

Remarque : Nous différencions ici les approches "à la synthèse" des approches à l'analyse, qui consisteraient par exemple à minimiser une fonctionnelle de la forme $\frac{1}{2} \|\mathbf{Z} - \mathbf{G} \mathbf{S}\|^2 + \lambda \|\mathbf{W} \mathbf{S}\|_1$. Ce problème n'est pas abordé ici.

3 Application sur des données MEG

3.1 Données

Nous discutons ici des résultats sur données réelles et simulées. Nous disposons de jeux de données MEG obtenus par le centre MEG de l'INS Marseille. Outre les données \mathbf{Z} (moyennées sur plusieurs essais), sont disponibles la discrétisation de la surface corticale (sommets, arêtes), une matrice de gain \mathbf{G} (orientation contrainte, normale à la surface discrétisée) et la matrice de covariance $\boldsymbol{\Sigma}_B$ de la ligne de base \mathbf{B} , utilisée pour un blanchiment et une réduction de dimension préalables.

Nous présentons également des résultats sur données simulées, générées comme suit. Une activité \mathbf{S}_{sim} est propagée ($\mathbf{G} \mathbf{S}_{\text{sim}}$) jusqu'aux capteurs, avec ajout d'une ligne de base simulée $\mathbf{B} \sim \mathcal{N}(0, \boldsymbol{\Sigma}_B)$, dont l'amplitude est ajustée de façon à générer un PSNR fixé dans le domaine des capteurs. Nous considérons le cas où \mathbf{S}_{sim} est reconstruite (via un solveur fixé) à partir de données réelles de potentiels évoqués auditifs, avec 10 simulations avec lignes de bases différentes. Nous générons aussi des données purement simulées, avec des séries de 100 patches générés aléatoirement à la surface du cortex, avec 2 étendues spatiales distinctes, et une activité constante sur le patch.

3.2 Ondelettes

Partant du graphe associé à la triangulation de la surface du cortex (poids binaires) nous utilisons la construction d'ondelettes telle que décrite dans [6] (section 8.1), avec $N_s = 3$ échelles d'ondelettes suivant une progression logarithmique sur l'axe fréquentiel, la fréquence de coupure de la fonction d'échelle étant fixée à $\lambda_{\max}/16$. Ceci produit une trame de \mathbb{R}^N ; l'évaluation numérique des bornes de la trame [2] donne les valeurs $A \approx 0.71$ et $B \approx 1.41$, soit un très bon conditionnement.

3.3 Évaluation

Pour les données réelles, l'absence de vérité de terrain impose de s'appuyer sur les connaissances d'experts. Il n'existe pas non plus de consensus pour l'évaluation sur données simulées, la plupart des métriques introduites dans la littérature (cf par exemple [8, 15]) ayant tendance à favoriser des approches ou des situations spécifiques. Nous utilisons ici des métriques adaptées à des estimées quantitatives de sources (pas seulement leur support), plus précisément

- Une distance entre amplitudes normalisées simulée $\tilde{\mathcal{A}}_{S_{sim}}$ et estimée $\tilde{\mathcal{A}}_{S_*}$, pour laquelle nous choisissons la distance de Wasserstein (voir [14]) $WD = W_1(\tilde{\mathcal{A}}_{S_*}, \tilde{\mathcal{A}}_{S_{sim}})$. Pour conserver l'information d'amplitude nous calculons aussi le rapport d'amplitude $A_n = \|\mathcal{A}_{S_*}\|/\|\mathcal{A}_{S_{sim}}\|$

- Pour évaluer l'étendue spatiale des sources estimées et la comparer à celle de la simulation, nous évaluons deux mesures de dispersion. La dispersion spatiale au pic mesure un écart moyen au pic : en notant $(i_{max}, t_{max}) = \operatorname{argmax} \mathbf{S}(i, t)$, et $d_{i,k}$ la distance Euclidienne entre les vertex i et k , on définit

$$SD = \left(\frac{\sum_{k=1}^N d_{i_{max},k}^2 |\mathbf{S}_{k,t_{max}}|^2}{\sum_{k=1}^N |\mathbf{S}_{k,t_{max}}|^2} \right)^{\frac{1}{2}}. \quad (9)$$

L'entropie de l'amplitude normalisée $\tilde{\mathcal{A}}$ fournit une autre mesure de dispersion spatiale, prenant de petites valeurs pour des sources focales et plus grandes pour des sources étendues :

$$H(\mathcal{A}) = - \sum_{k=1}^N \tilde{\mathcal{A}}[k] \log_2(\tilde{\mathcal{A}}[k]). \quad (10)$$

Pour ces deux mesures, nous considérons le ratio de la mesure de la source estimée par la source simulée.

3.4 Résultats

La Figure 1 présente des résultats obtenus sur des données réelles de potentiels évoqués auditifs (cartes d'amplitudes (8), sans seuillage). La localisation attendue se trouve principalement dans le cortex auditif¹ de l'hémisphère droit, ce que reproduisent bien les deux images du bas, obtenue avec sgw-SBL (algorithme EM) à gauche et SVB-SCCD à droite. Ces deux solveurs concentrent toute l'activité dans la région auditive. SVB-SCCD fournit une solution constante par morceaux sur un patch, tandis que sgw-SBL EM autorise davantage de variation d'amplitude sur l'étendue du patch, et parvient aussi à reconstruire de l'activité plus profonde dans le sillon auditif. La convergence de l'algorithme EM est atteinte en moins de 50 itérations. MNE (haut gauche) fournit comme attendu une activité diffuse, qui déborde largement du cortex auditif droit. MNE ne parvient pas non plus à reconstruire l'activité en profondeur dans le sillon auditif. Quant à MCE (haut droite), il fournit comme attendu une solution très parcimonieuse. Son utilisation directe dans le domaine des sources est plus adaptée aux sources focales qu'au cas considéré.

Nous considérons dans la suite, comme *patch* simulé de référence, la solution reconstruite par sgw-SBL EM à partir des données capteurs. Cela nous permet d'évaluer numériquement les métriques introduites précédemment. La Table 1 ci-après synthétise les résultats (valeurs moyennes sur 10 réalisations de ligne de base) obtenus à partir de ce *patch*, avec différents solveurs. On note $SD_n = SD/SD_{ref}$ et $H_n = H/H_{ref}$.

¹Voir par exemple https://en.wikipedia.org/wiki/Auditory_cortex

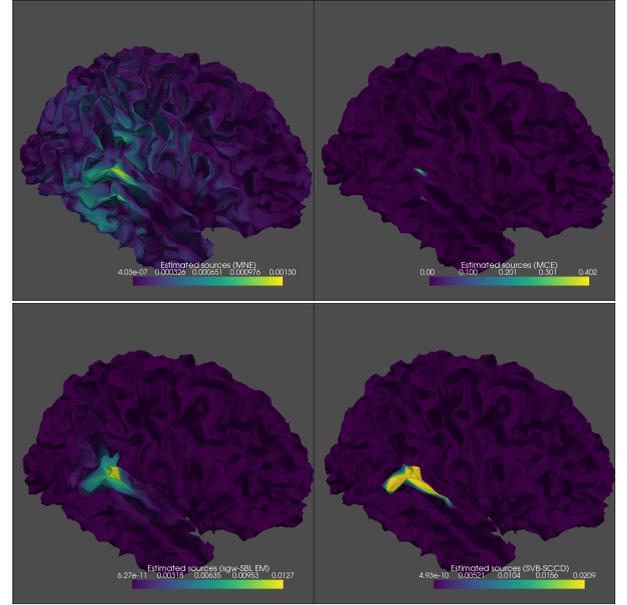


FIGURE 1 : Potentiels évoqués auditifs : cartes d'amplitude (8) pour les solutions MNE (haut gauche), MCE (haut droite), sgw-SBL EM (bas gauche) et SVB-SCCD (bas droite).

TABLE 1 : Potentiels évoqués auditifs simulés (à partir de la solution sgw-SBL EM) : performances de MNE (#1), MCE (#2), SVB-SCCD (#3), sgw-SBL EM (#4), sgw-MCE II (#5), et sgw-MCE I (#6). Gras : meilleur résultat ; souligné : 2nd meilleur résultat

	#1	#2	#3	#4	#5	#6
SD_n	3.18	1.52	<u>1.37</u>	0.95	2.05	1.47
H_n	1.390	0.492	0.739	0.945	1.210	0.952
WD	0.14	0.51	0.11	9.6e-3	0.11	<u>1.9e-2</u>
A_n	0.21	3.69	1.73	<u>1.07</u>	0.72	1.05

Ces résultats confirment, pour ce type d'activation, la dispersion spatiale trop importante et la sous-estimation de l'amplitude des solutions MNE. A l'inverse, MCE produit un support trop restreint (entropie la plus faible) et sur-estime l'amplitude. L'implémentation de la parcimonie dans le domaine des ondelettes spatiales fournit ici les meilleurs résultats, avec le solveur sgw-SBL EM (résultat attendu) mais aussi sgw-MCE I, alors que SVB-SCCD s'éloigne de la source simulée en obtenant une solution constante par morceaux. La pénalisation de coefficients d'échelles (sgw-MCE II) ne semble pas pertinente ici, mais ceci est à relativiser car un meilleur choix de μ pourrait améliorer les résultats. L'absence d'hyperparamètre pour les solutions SBL est à cet égard un avantage certain.

La Table 2 donne les résultats obtenus pour des métriques similaires (sauf entropie) sur 100 simulations de sources constantes sur un *patch* connexe généré aléatoirement à la surface du cortex (2 tailles de support sont considérées). Ces résultats confirment les tendances de la Table 1, notamment les biais systématiques de MNE, ainsi que les performances de la parcimonie en ondelettes pour des activités étendues. MCE s'avère performant dans le cas de petits *patches*, à noter toutefois que la dispersion spatiale n'est pas pertinente dans ce cas. On peut aussi noter que sgw-SBL soutient la comparaison avec SVB-SCCD, qui est a priori adapté à ce type de simulation (activité constante par morceaux), en particulier pour la distance de Wasserstein.

TABLE 2 : Sources simulées constantes sur un *patch* : valeurs moyennes et écart-types des métriques SD_n , WD et A_n (de haut en bas) : petit v./ grand *patch*

	MNE	sgw-SBL	MCE	SVB-SCCD
<i>mean</i>	6.27 / 2.40	2.67 / 0.72	<u>2.79</u> / 1.12	2.82 / <u>1.20</u>
<i>std</i>	2.22 / 0.43	1.23 / 0.29	2.22 / 0.73	1.98 / 0.82
<i>mean</i>	6.96 / 1.34	<u>6.47</u> / <u>0.88</u>	5.54 / 1.87	6.65 / 1.11
<i>std</i>	5.19 / 0.96	5.08 / 0.74	4.92 / 1.65	5.25 / 0.95
<i>mean</i>	0.04 / 0.13	0.14 / <u>0.54</u>	1.12 / 3.25	<u>0.40</u> / 1.09
<i>std</i>	0.01 / 0.02	0.02 / 0.08	0.45 / 0.97	0.19 / 0.43

4 Discussion et conclusion

Nous avons introduit une nouvelle famille d’approches du problème inverse MEG implémentant un a priori de parcimonie dans un domaine d’ondelettes spatiales (trames redondantes d’ondelettes sur graphe), suivant des points de vue variationnel et Bayésien. Nos résultats sur données simulées montrent que ces approches permettent de reconstruire avec une bonne précision des sources corticales étendues, l’approche Bayésienne étant particulièrement intéressante, car dénuée d’hyperparamètres difficiles à régler. Toutefois, les performances constatées varient en fonction du type de données simulées. Le choix de la métrique d’évaluation est également une question importante. Des tests numériques plus complets feront l’objet d’une publication à venir. Nous projetons aussi de comparer avec des approches similaires utilisant des bases orthonormées d’ondelettes sur graphe ou surface, et d’explorer des méthodes d’estimation d’hyperparamètres plus élaborées que les heuristiques utilisées ici pour les approches variationnelles.

Les résultats obtenus sur données réelles sont encourageants, mais difficiles à évaluer quantitativement en l’absence de vérité terrain. L’utilisation de données intracrânielles en parallèle de données MEG devrait permettre de faciliter cette évaluation.

Remerciements. Ce travail a bénéficié du soutien de l’état Français au travers du projet BMWs (ANR-20-CE45-0018), et de l’Institut Convergence ILCB (ANR-16-CONV-0002). Nous remercions également M. Kowalski, G. Mebarki et C. Mélot pour de nombreuses discussions.

Références

- [1] H. BECKER, L. ALBERA, P. COMON, R. GRIBONVAL et I. MERLET : Fast, variation-based methods for the analysis of extended brain sources. *In 22nd European Signal Processing Conference*, pages 41–45, 2014.
- [2] O. CHRISTENSEN : *An Introduction to Frames and Riesz Bases*. ANHA series. Birkhäuser, 2003.
- [3] R. R. COIFMAN et M. MAGGIONI : Diffusion wavelets. *Appl. Comput. Harmon. Anal.*, 21(1):53–94, 2006.
- [4] L. DING : Reconstructing cortical current density by exploring sparseness in the transform domain. *Phys. Med. Biol.*, 54(9):2683–2697, apr 2009.
- [5] M. FUCHS, M. WAGNER, T. KÖHLER et H.-A. WISCHMANN : Linear and nonlinear current density reconstructions. *J Clin Neurophysiol*, 16(3):267–295, 1999.
- [6] D.K. HAMMOND, P. VANDERGHEYNST et R. GRIBONVAL : Wavelets on graphs via spectral graph theory. *Appl. Comput. Harmon. Anal.*, 30(2):129 – 150, 2011.
- [7] A. HASHEMI, C. CAI, G. KUTYNIOK, K.-R. MÜLLER, S.S. NAGARAJAN et S. HAUFE : Unification of sparse bayesian learning algorithms for electromagnetic brain imaging with the majorization minimization framework. *NeuroImage*, 239:118309, 2021.
- [8] O. HAUKE, M. STENROOS et M.S. TREDER : Towards an objective evaluation of EEG/MEG source estimation methods – the linear approach. *NeuroImage*, 255:119177, 2022.
- [9] M. S. HÄMÄLÄINEN et R. J. ILMONIEMI : Interpreting magnetic fields of the brain : minimum norm estimates. *Med Biol Eng Comput*, 32(1):35–42, 1994.
- [10] K. JERBI, S. BAILLET, J.C. MOSHER, G. NOLTE, L. GARNERO et R.M. LEAHY : Localization of realistic cortical activity in MEG using current multipoles. *NeuroImage*, 22(2):779 – 793, 2004.
- [11] K. MATSUURA et Y. OKABE : Selective minimum-norm solution of the biomagnetic inverse problem. *IEEE Trans. Biomed. Eng.*, 42(6):608–615, June 1995.
- [12] J.C. MOSHER, P.S. LEWIS et R.M. LEAHY : Multiple dipole modeling and localization from spatio-temporal MEG data. *IEEE Trans. Biomed. Eng.*, 39(6):541–557, June 1992.
- [13] W. OU, M.S. HÄMÄLÄINEN et P. GOLLAND : A distributed spatio-temporal EEG/MEG inverse solver. *NeuroImage*, 44(3):932 – 946, 2009.
- [14] G. PEYRÉ et M. CUTURI : Computational optimal transport : With applications to data science. *Foundations and Trends® in Machine Learning*, 11(5-6):355–607, 2019.
- [15] J. G. SAMUELSSON, N. PELED, F. MAMASHLI, J. AHVENINEN et M. S. HÄMÄLÄINEN : Spatial fidelity of MEG/EEG source estimates : A general evaluation approach. *NeuroImage*, 224:117430, 2021.
- [16] K. SEKIYAMA et S.S. NAGARAJAN : *Adaptive Spatial Filters for Electromagnetic Brain Imaging*. Series in Biomedical Engineering. Springer-Verlag Berlin, 2008.
- [17] W. SWELDENS : The lifting scheme : A construction of second generation wavelets. *SIAM J. Math. Anal.*, 29(2):511–546, 1998.
- [18] B.D. VAN VEEN, W. VAN DRONGELEN, M. YUCHTMAN et A. SUZUKI : Localization of brain electrical activity via linearly constrained minimum variance spatial filtering. *IEEE Trans. Biomed. Eng.*, 44(9):867–880, 1997.
- [19] D.P. WIPF, J.P. OWEN, H.T. ATTIAS, K. SEKIYAMA et S.S. NAGARAJAN : Robust Bayesian estimation of the location, orientation, and time course of multiple correlated neural sources using MEG. *NeuroImage*, 49(1):641–655, 2010.