

Interpolation spatiale de signaux sur graphes avec une application pour la fusion d'ensembles de données EEG de diverses dimensions

Yassine EL OUAHIDI¹ Lucas DRUMETZ¹ Giulia LIOI¹ Nicolas FARRUGIA¹ Bastien PASDELOUP¹ Vincent GRIPON¹

¹IMT Atlantique, Lab-STICC, UMR CNRS 6285, F-29238 Brest, France

Résumé – Dans le domaine des Interfaces Cerveau Machine (ICM), les ensembles de données sont généralement petits et ont des configurations d'électrodes différentes. Lors de l'entraînement d'un réseau de neurones profond, il peut être souhaitable de capitaliser sur plusieurs de ces ensembles de données pour augmenter la quantité de données disponibles et améliorer la généralisation. À cette fin, nous proposons une technique d'interpolation spatiale de signaux sur graphe permettant d'interpoler efficacement plusieurs électrodes. Nous menons une série d'expériences avec 5 ensembles de données ICM d'Imagerie Motrice en comparant l'interpolation proposée avec l'interpolation par splines sphériques. Nous pensons que ce travail apporte des idées novatrices sur la façon de tirer parti des graphes pour interpoler des électrodes et sur la façon d'homogénéiser plusieurs ensembles de données.

Abstract – BCI Motor Imagery datasets usually are small and have different electrodes setups. When training a Deep Neural Network, one may want to capitalize on all these datasets to increase the amount of data available and hence obtain good generalization results. To this end, we introduce a spatial graph signal interpolation technique, that allows to interpolate efficiently multiple electrodes. We conduct a set of experiments with five BCI Motor Imagery datasets comparing the proposed interpolation with spherical splines interpolation. We believe that this work provides novel ideas on how to leverage graphs to interpolate electrodes and on how to homogenize multiple datasets.

1 Introduction

Un défi majeur dans la classification de signaux cérébraux est le manque de grands ensembles de données homogènes, tels que ceux de la vision par ordinateur. Ceci est également vrai pour les Interfaces Cerveau-Machine (ICM), où généralement le signal électro-encéphalographique (EEG) est collecté auprès de quelques sujets avec des configurations d'enregistrement spécifiques (disposition des électrodes, fréquence d'échantillonnage, paradigme de stimulation). Ce manque de données d'entraînement explique en partie le retard du domaine dans l'utilisation de méthodes basées sur l'apprentissage profond et l'apprentissage par transfert, avec des résultats contradictoires [9]. Une approche pour pallier cette limitation consiste à fusionner différents ensembles de données EEG. Nous proposons une nouvelle méthode pour fusionner des ensembles de données EEG basée sur l'interpolation de signal sur graphe, qui permet d'obtenir une configuration unifiée sans à priori et fournit des résultats interprétables en termes de motifs spatiaux EEG. Nous testons cette méthode pour la classification de données ICM d'Imagerie Motrice (IM).

2 Contexte scientifique

2.1 Classification de données d'ICM IM

Les systèmes ICM reposent sur la mesure en temps réel des signaux cérébraux, généralement EEG, et nécessitent d'être calibrés via un entraînement hors ligne. En phase opérationnelle, le système classe les signaux cérébraux et les traduit en commandes pour un dispositif en temps réel. Dans les applications actuelles, le système a besoin d'être calibré via des données préenregistrées de l'utilisateur pour être fiable, en raison du manque de classificateurs capables de généraliser à des sujets

et des setups de systèmes EEG [9]. Pour aller vers des systèmes ICM performants, une caractéristique clé est la capacité à extraire efficacement des connaissances à partir de la variété d'ensembles de données disponibles dans la littérature, et de les transférer à de nouveaux sujets. Cependant, la majorité des travaux dans la littérature considèrent des ensembles de données ICM séparés.

Récemment, une tentative d'exploiter conjointement les informations provenant de ensembles distincts de données EEG a été entreprise avec le défi de transfert d'apprentissage NeurIPS EEG BEETL [19]. La tâche 2 du défi est une tâche de transfert d'apprentissage de classification d'IM vers de nouveaux sujets et ensembles de données. Trois ensembles de données d'IM sources sont fournis et les algorithmes sont ensuite testés sur deux nouveaux ensembles. Une première étape consiste à unifier les différents montages. Pour cela, des solutions simples telles que l'intersection des électrodes communes ont été proposées, négligeant les informations des électrodes restantes. Ici, nous proposons une méthode qui exploite les informations de toutes les électrodes disponibles grâce à l'interpolation de signaux sur graphes.

2.2 Traitement de signal sur graphe

Une manière intuitive de représenter les interactions entre électrodes dans le contexte des ICM est d'utiliser un graphe spatial. Les signaux EEG peuvent alors être vus comme des observations sur ce graphe, avec une dimension temporelle ajoutée. Le traitement de tels signaux peut être effectué à l'aide d'outils du Traitement du Signal sur Graphe (TSG) [16]

Dans ce cadre, un graphe pondéré $\mathcal{G} = \langle \mathcal{V}, \mathcal{E} \rangle$ avec des sommets \mathcal{V} et des arêtes $\mathcal{E} \subset \mathcal{V} \times \mathcal{V}$ est utilisé pour modéliser les électrodes et leurs interactions. Un tel graphe peut être représenté de manière équivalente par une matrice de poids

symétrique $\mathbf{W} \in \mathbb{R}^{|\mathcal{V}| \times |\mathcal{V}|}$ telle que $W_{ij} = 0$ si $\{i, j\} \notin \mathcal{E}$. Nous notons $\mathbf{D} \in \mathbb{R}^{|\mathcal{V}| \times |\mathcal{V}|}$ la matrice des degrés de \mathcal{G} , telle que $D_{ij} = \sum_{k=1}^{|\mathcal{V}|} W_{ik}$ si $i = j$ et 0 sinon. À partir de ces deux matrices, nous pouvons calculer le Laplacien $\mathbf{L} = \mathbf{D} - \mathbf{W}$ de \mathcal{G} . Étant donné que \mathbf{L} est réelle et symétrique, elle peut être diagonalisée sous la forme $\mathbf{L} = \mathbf{U}\mathbf{\Lambda}\mathbf{U}^\top$, où \mathbf{U} est une matrice de vecteurs orthonormaux associés aux valeurs propres formant la matrice diagonale $\mathbf{\Lambda}$, triées par ordre croissant. Un signal $\mathbf{s} \in \mathbb{R}^{|\mathcal{V}|}$ sur \mathcal{G} est une observation sur chacun de ses sommets. Sa transformée de Fourier de graphe $\hat{\mathbf{s}} = \mathbf{U}^\top \mathbf{s}$ peut être vue comme une observation pour chaque fréquence du graphe. En utilisant ces éléments, nous pouvons définir la variation totale du signal de graphe $\sigma(\mathbf{s})$ d'un signal \mathbf{s} comme :

$$\sigma(\mathbf{s}) = \mathbf{s}^\top \mathbf{L} \mathbf{s} = \sum_{i=1}^{|\mathcal{V}|} \Lambda_{ii} \hat{s}_i^2 = \sum_{i=1}^{|\mathcal{V}|} \sum_{j=1}^{|\mathcal{V}|} W_{ij} (s_i - s_j)^2 \quad (1)$$

2.3 Interpolation des signaux EEG

L'interpolation des électrodes est une étape commune à de nombreux pipelines de prétraitement EEG et est généralement nécessaire pour réparer artificiellement le signal provenant d'électrodes bruitées. Plusieurs méthodes permettent l'interpolation spatiale sans utiliser de graphes. La méthode de référence est l'interpolation Spherical Spline [13] avec des polynômes de Legendre. D'autres méthodes utilisent la corrélation du signal [14] ou des réseaux de neurones, comme [3] qui utilise un générateur profond. Cependant, ces méthodes souffrent soit d'une erreur de reconstruction élevée, soit d'un manque d'interprétabilité. Des méthodes d'interpolation à l'aide de graphes existent aussi, comme [11] qui se concentre sur les signaux à bande limitée. D'autres travaux cherchent à optimiser un critère de signal sur graphe tel que la parcimonie [8].

2.4 Homogénéisation de données ICM

Peu d'approches ont été explorées pour exploiter conjointement des informations provenant de différents ensembles de données EEG. En général, les ensembles de données diffèrent sur plusieurs aspects (fréquence d'échantillonnage, prétraitement, paradigme d'enregistrement, configuration des électrodes). Certaines de ces inhomogénéités peuvent être résolues simplement en fenêtrant ou en rééchantillonnant les signaux EEG, tandis que l'unification de la configuration des électrodes reste un défi. Pour le résoudre, différentes méthodes ont été proposées. La dimension spatiale peut être réduite, en prenant l'intersection des électrodes disponibles ou via une décomposition en composantes principales [12], avec pour effet une perte d'information. Pour surmonter cette perte, certaines techniques [1] proposent d'apprendre une autre représentation avec de l'apprentissage antagoniste. D'autres proposent d'augmenter la dimension spatiale en passant dans l'espace Riemannien.

3 Méthodologie

Notre approche consiste à considérer chaque ensemble de données ICM comme un échantillonnage partiel d'un ensemble virtuel plus grand d'électrodes, puis à utiliser une technique d'interpolation de signaux sur graphe pour "récupérer" les électrodes manquantes. Le graphe est appris à partir d'un ensemble

de données EEG, à haute définition spatiale, contenant toutes les électrodes. Il est par la suite exploité pour homogénéiser plusieurs ensembles de données ICM et les entraîner simultanément dans une configuration similaire au défi BEETL.

3.1 Interpolation de signaux sur graphe

Nous proposons une technique d'interpolation de signaux sur graphe qui consiste à minimiser la variation du signal de graphe dans l'équation (1) en ne connaissant qu'une partie du signal. Nous montrons que ce problème admet une forme close, que nous pouvons directement utiliser pour obtenir la valeur optimale du signal à reconstruire qui minimisera cette variation.

Soit un graphe \mathcal{G} où les électrodes sont des sommets \mathcal{V} , avec un Laplacien $\mathbf{L} \in \mathbb{R}^{|\mathcal{V}| \times |\mathcal{V}|}$. Soit $\mathbf{s} \in \mathbb{R}^{|\mathcal{V}|}$ un signal sur \mathcal{G} . Nous considérons que \mathbf{s} a certaines entrées manquantes, en raison de l'absence de certaines électrodes. L'ensemble des électrodes manquantes est noté $\mathcal{M} \subset \mathcal{V}$, et son complément $\overline{\mathcal{M}} = \mathcal{V} \setminus \mathcal{M}$. Nous notons $\mathbf{s}_{\overline{\mathcal{M}}} = \{s_{i \in \overline{\mathcal{M}}}\}$ la partie observée de \mathbf{s} et $\mathbf{s}_{\mathcal{M}} = \{s_{i \in \mathcal{M}}\}$ sa partie manquante. Nous notons $\mathbf{L}_{\mathcal{M}} \in \mathbb{R}^{|\mathcal{M}| \times |\mathcal{M}|}$ la sous-matrice de \mathbf{L} où nous ne gardons que les lignes et colonnes avec des indices dans \mathcal{M} , et $\mathbf{L}_{\mathcal{M}\overline{\mathcal{M}}} \in \mathbb{R}^{|\mathcal{M}| \times |\overline{\mathcal{M}}|}$ la sous-matrice de \mathbf{L} où nous ne gardons que les lignes avec des indices dans \mathcal{M} et les colonnes avec des indices dans $\overline{\mathcal{M}}$.

Proposition 1. *La solution $\mathbf{s}_{\mathcal{M}}$ qui optimise le problème de variation de l'équation (1) dans notre configuration est directement donnée par la forme close suivante :*

$$\mathbf{s}_{\mathcal{M}} = -\mathbf{L}_{\mathcal{M}}^{-1} \mathbf{L}_{\mathcal{M}\overline{\mathcal{M}}} \mathbf{s}_{\overline{\mathcal{M}}} \quad (2)$$

Démonstration. Nous partons de :

$$\sigma(\mathbf{s}) = \mathbf{s}^\top \mathbf{L} \mathbf{s} = \sum_{i=1}^{|\mathcal{V}|} \sum_{j=1}^{|\mathcal{V}|} s_i \mathbf{L}_{ij} s_j \quad (3)$$

Nous pouvons décomposer l'équation (3) en 4 termes : 1. $i \in \mathcal{M}$ et $j \in \mathcal{M}$; 2. $i \in \mathcal{M}$ et $j \notin \mathcal{M}$; 3. $i \notin \mathcal{M}$ et $j \in \mathcal{M}$; 4. $i \notin \mathcal{M}$ et $j \notin \mathcal{M}$. Ici, les termes 2 et 3 sont symétriques et le terme 4 est une constante. Ainsi, nous avons :

$$\sigma(\mathbf{s}) = \mathbf{s}_{\mathcal{M}}^\top \mathbf{L}_{\mathcal{M}} \mathbf{s}_{\mathcal{M}} + 2 \sum_{i \in \mathcal{M}} \sum_{j \notin \mathcal{M}} s_i \mathbf{L}_{ij} s_j + \text{constante}, \quad (4)$$

où $\sigma_{\mathcal{M}\overline{\mathcal{M}}}(\mathbf{s}) = 2 \sum_{i \in \mathcal{M}} \sum_{j \notin \mathcal{M}} s_i \mathbf{L}_{ij} s_j$ correspond aux deux parties symétriques 2 et 3 dans l'équation (4). Nous avons :

$$\forall i \in \mathcal{M}, \frac{\partial \sigma_{\mathcal{M}\overline{\mathcal{M}}}}{\partial s_i} = 2 \sum_{j \notin \mathcal{M}} \mathbf{L}_{ij} s_j = 2 (\mathbf{L}_{\mathcal{M}\overline{\mathcal{M}}} \mathbf{s}_{\overline{\mathcal{M}}})_i, \quad (5)$$

où nous notons $(\cdot)_i$ la $i^{\text{ème}}$ entrée du vecteur entre parenthèses. Nous obtenons alors :

$$\nabla \sigma(\mathbf{s}_{\mathcal{M}}) = 2(\mathbf{L}_{\mathcal{M}} \mathbf{s}_{\mathcal{M}} + \mathbf{L}_{\mathcal{M}\overline{\mathcal{M}}} \mathbf{s}_{\overline{\mathcal{M}}}) = 0 \Rightarrow \mathbf{s}_{\mathcal{M}} = -\mathbf{L}_{\mathcal{M}}^{-1} \mathbf{L}_{\mathcal{M}\overline{\mathcal{M}}} \mathbf{s}_{\overline{\mathcal{M}}} \quad (6)$$

Une preuve similaire a été fournie par [6]. Il convient de noter que pour que la Proposition 1 soit vraie, il est nécessaire que la sous-matrice Laplacienne du graphe $\mathbf{L}_{\mathcal{M}}$ soit inversible. En pratique, il est possible d'envisager d'ajouter $\varepsilon \mathbf{I}$ dans le cas où cela n'est pas le cas. La reconstruction des entrées dans \mathcal{M} nécessite donc l'utilisation d'un graphe. Pour cela, nous l'apprenons à partir des signaux EEG. \square

3.2 Apprendre le graphe

Afin de reconstruire les entrées manquantes \mathcal{M} d'un signal, nous proposons d'apprendre un graphe \mathcal{G} de \mathcal{V} électrodes. Nous considérons ici trois graphes différents :

1. Un graphe spatial, avec une matrice d'adjacence basée sur les positions des capteurs, que nous binarisons en fonction d'un rayon ;
2. Nous enrichissons le graphe spatial en le pondérant avec des scores *Weighted Phase Lag Index* (WPLI) [18] calculés à partir d'un ensemble contenant tous les électrodes, similairement au graphe proposé dans [10] ;
3. Nous apprenons la matrice d'adjacence d'un graphe optimal par descente de gradient, afin de construire un graphe qui optimise notre problème de variation du signal, en maximisant R^2 , le coefficient de détermination. À chaque étape de l'apprentissage, nous masquons aléatoirement la moitié des électrodes et essayons de les reconstruire. Premièrement, nous proposons d'apprendre le graphe en utilisant un grand ensemble de données A contenant toutes les électrodes. Dans une deuxième étape, nous utilisons le graphe appris pour reconstruire les électrodes manquantes dans un autre ensemble de données B. Pour cela, nous expérimentons deux façons : (a) Transfert direct, i.e utiliser le graphe appris sur A pour reconstruire B ; (b) Fine-tuning du graphe appris sur A vers l'ensemble de données B, où nous entraînons conjointement sur A et B.

Les capacités de reconstruction des graphes sont évaluées sur des problèmes contrôlés, où nous masquons artificiellement des électrodes et évaluons la qualité des reconstructions.

4 Expériences

4.1 Interpolation des électrodes

Nous utilisons plusieurs ensembles de données EEG d'IM en accès libre, qui sont tous disponibles sur MOABB¹. Le code de nos expériences est également disponible².

Les ensembles de données sont unifiés en fréquence avec un filtre passe-bande à [2,40] Hz. L'ensemble Schirrneister sert à apprendre le graphe d'union, car il contient presque toutes les électrodes des ensembles de données que nous considérons dans notre cas d'application. Cet ensemble est également utilisé pour apprendre le graphe optimal et pour calculer WPLI. Les cinq autres ensembles sont utilisés pour : 1. Évaluer les performances des techniques d'interpolation en Section 4.1 ; 2. Créer une configuration similaire à celle du défi BEETL afin d'évaluer les performances de notre méthode d'interpolation pour homogénéiser des ensembles de données en Section 4.2. Afin d'homogénéiser les cinq ensembles de données restants, nous avons effectué, en plus du filtre passe-bande, une réduction de la fréquence d'échantillonnage à la plus basse (160 Hz) et un fenêtrage sur les trois premières secondes du signal.

Nous observons en Figure 1 que le graphe pondéré WPLI permet une reconstruction légèrement meilleure du signal que

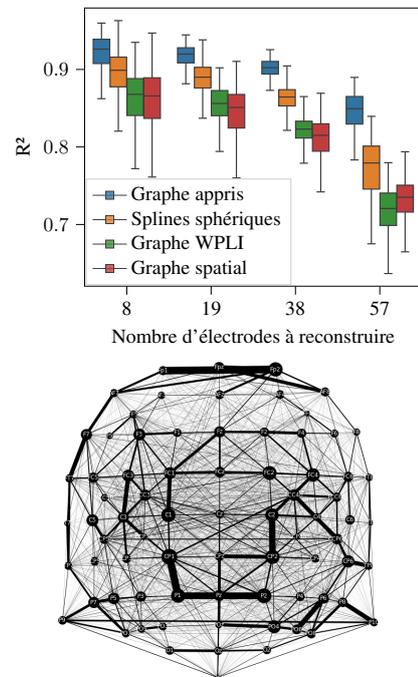


FIGURE 1 : Haut — Performances de reconstruction en fonction du nombre d'électrodes manquantes sur Schirrneister (76 électrodes) ; Bas — Graphe appris. La taille des nœuds est pondérée par leur force, et l'épaisseur correspond à leur poids. Les deux sont à l'échelle carrée pour accentuer les écarts.

	Physionet [5]	BNCI [17]	Cho [2]	Shin [15]	Zhou [20]
Transfert	52.5±3.6	56.3±30.4	18.8±11.8	33.8±17.3	8.3±18.1
Transfert + FT	86.1±1.2	93.2±2.8	77.1±2.3	90.4±1.7	70.0±9.2
Spatial	59.3±2.6	79.3±4.8	35.0±6.8	73.4±4.2	32.9±18.4
Spherical	80.6±4.5	94.9±1.5	75.6±4.4	85.9±4.2	54.1±21.8

TABLE 1 : R^2 de reconstruction de la moitié des électrodes par différentes méthodes sur différents ensembles de données.

le graphe spatial. D'autre part, la méthode par splines sphériques est plus efficace que le graphe spatial et WPLI. Enfin, nous montrons que le graphe appris surpasse tous les autres graphes, même en absence de 57 électrodes. Dans la suite de cet article, nous considérerons donc le graphe appris.

Nous évaluons ensuite la capacité du graphe appris à reconstruire des signaux sur d'autres ensembles de données. Pour ce faire, nous récupérons les 4 graphes construits sur Schirrneister, avec la technique Transfert+FT, pour résoudre des problèmes de reconstruction de la moitié d'électrodes masquées aléatoirement. Nous répétons l'opération 20 fois, ce qui nous fournit un R^2 pour chaque graphe et ensemble de données. Dans le Tableau 1, nous observons que l'utilisation directe du graphe (la ligne Transfert) n'est pas très efficace, indiquant une sur-adaptation aux données Schirrneister sur lequel il est entraîné. Pour compenser cela, nous le ré-entraînons individuellement pour chaque ensemble de données, comme décrit en Section 3.2. La méthode surpasse ainsi systématiquement (ligne Transfert + FT) la méthode par splines sphériques, sauf sur BNCI où les résultats sont très proches. En Figure 1, nous affichons le graphe appris après son entraînement sur l'ensemble de données Schirrneister. Nous observons un cluster dans la région centro-fronto-pariétale autour de C4 et C3, des régions et des connexions sollicitées lors de tâches d'imagerie motrice [4].

¹<http://moabb.neurotechx.com>

²https://github.com/elouayas/eeg_interpolation

	Shin [15]		Zhou [20]	
	Accuracy	N	Accuracy	N
Intersection	53.2±2.8	2	61.2±2.0	9
Dataset	63.2±2.3	22	56.2±4.8	14
Union	62.3±2.1	76	46.4±2.8	76

TABLE 2 : Performance de généralisation. N désigne nombre d'électrodes. "Intersection" désigne les électrodes communes aux 4 ensembles de données. "Dataset" correspond aux électrodes du jeu de données cible. "Union" est l'union des électrodes dans les 5 ensembles de données.

4.2 Application à l'entraînement de plusieurs ensembles de données ICM

Afin d'évaluer notre méthode d'interpolation pour homogénéiser différents ensembles de données BCI, nous utilisons une configuration similaire au défi BEETL : 3 ensembles de données sources (BNCI, Cho et PhysionetMI) et deux ensembles cibles (Shin et Zhou). Nous n'utilisons que les 40 premiers enregistrements pour chaque sujet des deux ensembles cibles et essayons de généraliser au reste de leurs enregistrements. Les données sont normalisées avec un alignement euclidien [7].

Nous utilisons un réseau de neurones convolutif 1D, pour classifier nos données, entraîné conjointement sur les 4 ensembles de données. L'entrée du modèle a pour dimension le nombre d'électrodes, avec un canal de convolution 1D par électrode. Le réseau est composé de deux parties : 1. une couche commune à tous les ensembles de données (une entrée unique et plusieurs couches de convolution); 2. une tête de classification propre à chaque ensemble de données (3 sources, 1 cible).

Nous comparons les performances d'une configuration qui considère uniquement l'intersection des électrodes des 4 ensembles de données à deux configurations considérant en plus l'interpolation des électrodes manquantes. Nous comparons deux façons d'interpoler : 1. interpoler toutes les électrodes présentes dans les ensembles de données ; 2. ou uniquement les électrodes manquantes de l'ensemble de données cible évalué.

Dans le Tableau 2, nous constatons qu'interpoler uniquement les électrodes de l'ensemble de données cible est plus efficace que d'interpoler l'ensemble de toutes les électrodes. Il est donc plus utile d'interpoler les 3 ensembles sources, pour exploiter l'information contenue dans les électrodes cibles, que d'interpoler l'ensemble cible en allant chercher artificiellement l'information des électrodes sources. Une autre conclusion est qu'il n'est pas toujours utile d'interpoler en utilisant notre méthode et cette procédure. Si nous regardons les résultats sur Zhou, nous constatons que l'intersection donne de meilleurs résultats. Cette différence de résultats vient du fait que la différence entre l'intersection et l'union des électrodes est très importante pour Shin, contrairement à Zhou.

5 Conclusion

En conclusion, une nouvelle technique d'interpolation d'électrodes efficace exploitant des outils du TSG a été proposée. Nous illustrons son intérêt pour homogénéiser des jeux de données EEG. Notre méthode permet d'interpoler les électrodes de manière efficace, et certains résultats ouvrent de nouvelles questions, notamment sur la manière dont il convient d'homogénéiser des ensembles de données dans le cas où l'intersection des électrodes n'est pas réduite au strict minimum.

Références

- [1] David BETHGE, Philipp HALLGARTEN, Ozan ÖZDENIZCI, Ralf MIKUT, Albrecht SCHMIDT et Tobias GROSSE-PUPPENHAHL : Exploiting multiple eeg data domains with adversarial learning. *arXiv preprint arXiv : 2204.07777*, 2022.
- [2] Hohyun CHO, Minkyu AHN, Sangtae AHN, Moonyoung KWON et Sung Chan JUN : Eeg datasets for motor imagery brain-computer interface. *GigaScience*, 6(7):gix034, 2017.
- [3] Isaac A CORLEY et Yufei HUANG : Deep eeg super-resolution : Upsampling eeg spatial resolution with generative adversarial networks. In *2018 IEEE EMBS International Conference on Biomedical & Health Informatics (BHI)*, pages 100–103. IEEE, 2018.
- [4] Claire CURY, Giulia LIOI, Lorraine PERRONNET, Anatole LÉCUYER, Pierre MAUREL et Christian BARILLOT : Impact of 1d and 2d visualisation on eeg-fmri neurofeedback training during a motor imagery task. In *2020 IEEE 17th International Symposium on Biomedical Imaging (ISBI)*, pages 1018–1021. IEEE, 2020.
- [5] Ary L GOLDBERGER, Luis AN AMARAL, Leon GLASS, Jeffrey M HAUSDORFF, Plamen Ch IVANOV, Roger G MARK, Joseph E MIETUS, George B MOODY, Chung-Kang PENG et H Eugene STANLEY : Physiobank, physiotoolkit, and physionet : components of a new research resource for complex physiological signals. *circulation*, 101(23):e215–e220, 2000.
- [6] Leo John GRADY et Eric L SCHWARTZ : *Anisotropic interpolation on graphs : The combinatorial Dirichlet problem*. Boston University, Center for Adaptive Systems and Department of Cognitive ..., 2003.
- [7] He HE et Dongrui WU : Transfer learning for brain-computer interfaces : A euclidean space data alignment approach. *IEEE Transactions on Biomedical Engineering*, 67(2):399–410, 2019.
- [8] Pierre HUMBERT, Laurent OUDRE et Nicolas VAYATIS : Subsampling of multivariate time-vertex graph signals. In *2019 27th European Signal Processing Conference (EUSIPCO)*, pages 1–5. IEEE, 2019.
- [9] Fabien LOTTE, Laurent BOUGRAIN, Andrzej CICHOCKI, Maureen CLERC, Marco CONGEDO, Alain RAKOTOMAMONJY et Florian YGER : A review of classification algorithms for eeg-based brain-computer interfaces : a 10 year update. *Journal of neural engineering*, 15(3):031005, 2018.
- [10] Mathilde MÉNORET, Nicolas FARRUGIA, Bastien PASDELOUP et Vincent GRIPON : Evaluating graph signal processing for neuroimaging through classification and dimensionality reduction. In *2017 IEEE Global Conference on Signal and Information Processing (GlobalSIP)*, pages 618–622. IEEE, 2017.
- [11] Sunil K NARANG, Akshay GADDE et Antonio ORTEGA : Signal processing techniques for interpolation in graph structured data. In *2013 IEEE International Conference on Acoustics, Speech and Signal Processing*, pages 5445–5449. IEEE, 2013.
- [12] Thu NGUYEN, Rabindra KHADKA, Nhan PHAN, Anis YAZIDI, Pål HALVORSEN et Michael A RIEGLER : Combining datasets to increase the number of samples and improve model fitting. *arXiv preprint arXiv : 2210.05165*, 2022.
- [13] François PERRIN, Jacques PERNIER, O BERTRAND et Jean Francois ECHALLIER : Spherical splines for scalp potential and current density mapping. *Electroencephalography and clinical neurophysiology*, 72(2):184–187, 1989.
- [14] AG RAMAKRISHNAN et JV SATYANARAYANA : Reconstruction of eeg from limited channel acquisition using estimated signal correlation. *Biomedical Signal Processing and Control*, 27:164–173, 2016.
- [15] Jaeyoung SHIN, Alexander von LÜHMANN, Benjamin BLANKERTZ, Do-Won KIM, Jichai JEONG, Han-Jeong HWANG et Klaus-Robert MÜLLER : Open access dataset for eeg+ nirs single-trial classification. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 25(10):1735–1745, 2016.
- [16] David I SHUMAN, Sunil K NARANG, Pascal FROSSARD, Antonio ORTEGA et Pierre VANDERGHEYNST : The emerging field of signal processing on graphs : Extending high-dimensional data analysis to networks and other irregular domains. *IEEE signal processing magazine*, 30(3):83–98, 2013.
- [17] Michael TANGERMANN, Klaus-Robert MÜLLER, Ad AERTSEN, Niels BIRBAUMER, Christoph BRAUN, Clemens BRUNNER, Robert LEEB, Carsten MEHRING, Kai J MILLER, Gernot MUELLER-PUTZ *et al.* : Review of the bci competition iv. *Frontiers in neuroscience*, page 55, 2012.
- [18] Martin VINCK, Robert OOSTENVELD, Marijn VAN WINGERDEN, Francesco BATTAGLIA et Cyriel MA PENNARTZ : An improved index of phase-synchronization for electrophysiological data in the presence of volume-conduction, noise and sample-size bias. *Neuroimage*, 55(4):1548–1565, 2011.
- [19] Xiaoxi WEI, Aldo FAISAL, Moritz GROSSE-WENTRUP, Alexandre GRAMFORT, Sylvain CHEVALLIER, Vinay JAYARAM, Camille JEUNET, Stylianos BAKAS, Siegfried LUDWIG, Konstantinos BARMAS *et al.* : 2021 beetl competition : Advancing transfer learning for subject independence & heterogenous eeg data sets. *arXiv preprint arXiv : 2202.12950*, 2022.
- [20] Bangyan ZHOU, Xiaopei WU, Zhao LV, Lei ZHANG et Xiaojin GUO : A fully automated trial selection method for optimization of motor imagery based brain-computer interface. *PLoS one*, 11(9):e0162657, 2016.