

# Rapport Projet M1

Maxime Cauté\*

ENS Rennes

Janvier 2020

## 1 Introduction

### 1.1 Motivation

Après un accident cérébral, une rééducation médicale est parfois nécessaire pour restaurer des capacités cognitives réduites. Celle-ci requiert souvent une surveillance précise de l'activité cérébrale du patient. Afin d'observer le cerveau humain en fonctionnement, il est classique d'employer des appareils mesurant indirectement son activité. Parmi eux, les plus habituels sont ceux employant les méthodes de l'Électro-Encéphalographie (EEG), et de l'Imagerie par Résonance Magnétique (IRM). Ces deux méthodes ont des intérêts nets, et complémentaires. L'EEG, mesurant les courants électriques au travers d'électrodes, dispose ainsi d'une remarquable résolution temporelle, mais d'une résolution spatiale limitée. L'IRM analyse de son côté les variations d'un champ magnétique afin de localiser l'activité crânienne, ce qui conduit à une très bonne résolution spatiale, au détriment de celle temporelle.

Il est donc particulièrement intéressant de combiner les deux pour obtenir des informations plus complètes. Cependant, cela amène des interférences qui brouillent fortement les signaux. Parmi ces interférences, aussi appelées "artefacts", les plus importantes sont les artefacts de gradient (AG) et de pouls (AP). L'AG est causé par de légères variations du champ magnétique de la machine à IRM, périodiquement corrigées. De son côté, l'AP provient comme son nom l'indique du battement du cœur, qui amène des vibrations jusqu'à l'endroit où se situent les électrodes d'enregistrement.

Des méthodes de débruitage ont déjà été mises au point. Cependant, en dehors de procédures spécifiques à certains artefacts, celles-ci sont généralement effectuées manuellement, avec un certain temps. Or, dans le cadre d'une rééducation par exemple, il peut être souhaitable de réaliser ce débruitage en temps réel, ou du moins avec un décalage faible (de l'ordre de la seconde par exemple). Nous avons donc cherché à automatiser ce débruitage en s'inspirant de la procédure de Rémi Flamary, détaillée dans [1] pour la transcription musicale. Cette méthode emploie le Transport Optimal afin de ramener le problème de décomposition en un problème d'optimisation, ultimement résolu par programmation linéaire.

### 1.2 Bref état de l'art

La constatation et la résolution du problème de bruit dans les signaux EEG et IRM (éventuellement combinés) n'est pas nouvelle.

En 1998, Allen [2] souligne l'existence de l'artefact de pouls et propose une méthode pour sa soustraction. D'autres artefacts sont également ciblés, comme un artefact dit d'imagerie en 2000 [3]. Plusieurs autres techniques ont également fait leur apparition dans les années 2000, dans les domaines de décomposition (ICA) ou des ondelettes. Ces méthodes ont été passées en revue en 2013 dans [4], et plus largement dans la thèse de Hajipour Sardouie en 2014 [5].

---

\*supervisé par Pierre Maurel, Julie Coloigner, Giulia Lioi - INRIA/IRISA, équipe EMPENN

Le débruitage a également été récemment exploré sous l'angle des techniques de classification. En 2012 Liu et asso. [6] proposent une méthode statistique de soustraction des artefacts de gradient et de pouls, notamment par l'analyse de composantes indépendantes. Une méthode non-supervisée basée sur les ondelettes est également proposée en 2016 par Kaushal et asso. [7].

L'utilisation du transport optimal sur un tel problème est quant à elle plutôt récente, présentée en 2016 par Flamary [1] pour de la transcription musicale. La technique a par la suite été raffinée par Janati, Cuturi et Gramfort [8, 9], en introduisant un déséquilibre dans le transport optimal.

## 2 Formalisation du problème

### 2.1 Contexte

Comme expliqué plus haut, notre objectif est de développer une méthode automatique, en temps réel, de débruitage de signaux EEG et IRM combinés. Nous souhaitons en effet surveiller le rythme cérébral du patient afin d'observer sa réaction (cérébrale) aux tâches proposées. Ce rythme peut généralement se trouver dans plusieurs bandes de faibles fréquences. Dans notre cadre d'étude, nous nous sommes principalement intéressés à la bande de fréquences  $\alpha$ , située entre 8,5 et 12 Hz, ainsi qu'aux bandes de fréquences  $\beta$  (12Hz-45Hz) et  $\theta$  (4Hz-8.5Hz). Celles-ci caractérisent en effet les activités cérébrales habituelles, de la réalisation de tâches simples à l'état de conscience apaisée. À des fins d'application médicale, nous souhaiterions donc obtenir un spectrogramme du signal nettoyé afin de surveiller ces plages de fréquence.

Les méthodes employées ont été testées à petite échelle, principalement sur des signaux-jouets simplifiés qui comprenaient de tels signaux. Nous avons également pris en compte des composantes artefactuelles liées au gradient et au pouls. Dans les signaux jouets, celles-ci ont été, par simplicité, représentée par des fréquences arbitrairement sélectionnées sur base de comparaison avec les spectrogrammes d'artefacts classiques. Ainsi, l'artefact de pouls y était modélisé par une sinusoïde à 1 Hz, tandis que l'artefact de gradient était modélisé par les fréquences 1 Hz, 3 Hz et 4 Hz. Il est à noter l'écart d'amplitude de ces composantes : dans un signal typique observé, les facteurs de rapport aux signaux d'intérêt sont de 100 pour l'AG et 10 pour l'AP.

### 2.2 Un problème de décomposition

Nous avons donc quelques composantes classiques et connues dans le signal que nous souhaitons débruiter. Dans ce contexte, il est classique de simplement isoler les signaux d'intérêt afin de se débarrasser du bruit et des artefacts. Cela passe par l'utilisation d'un dictionnaire  $W$  qui contient  $M$  caractéristiques de chacune de nos  $N$  composantes. En appliquant ce dictionnaire à notre signal, nous pouvons donc chercher à obtenir les coefficients de ces composantes et, *in fine*, recomposer notre signal épuré des composantes indésirables. Plus formellement, notre élément à décomposer est un vecteur  $v$  contenant les caractéristiques retenues. De même, notre dictionnaire  $W$  est une matrice dont chacune des colonnes est un vecteur associé aux mêmes caractéristiques de chaque composante. Ainsi, isoler les composantes d'intérêt revient à obtenir la décomposition de  $v$  en les colonnes de  $W$ , soit, formellement, obtenir le vecteur  $h \geq 0$  tel que :

$$v \approx Wh$$

Cependant, cela ne peut généralement être qu'approximatif. Cela est dû à l'existence de composantes inconnues dans  $v$  qui ne sont pas recensées par  $W$ . Notre objectif est donc *d'optimiser* cette approximation.

### 2.3 Un problème d'optimisation

Nous avons décidé d'explorer la méthode de Rémi Flamary, développée en 2016 dans [1] pour la transcription de notes de musique. Celle-ci semblait à la fois assez simple à implémenter pour nos tests et surtout capable de fournir rapidement d'assez bons résultats.

Cette méthode s’inspire de la méthode d’analyse PLCA, qui s’intéresse à la factorisation matricielle non-négative, et qui est particulièrement utilisée en traitement du signal acoustique.

La PLCA vise à minimiser, sur  $h$ , la valeur de la KL-Divergence entre  $v$  et  $Wh$ , donc à trouver

$$H = \underset{H \geq 0}{\operatorname{argmin}} D_{KL}(Wh|v) \quad (1)$$

Cette méthode reste cependant fortement sensible à de légères variations dans les composantes, qui peuvent amener à une décomposition complètement fautive. Or, cette situation se produit fréquemment dans le cadre de signaux cérébraux : l’artefact de pouls, marqué par le rythme cardiaque, peut donc par exemple avoir une fréquence quelque peu différente de sa version du dictionnaire !

Nous employons donc contre cela une technique permettant de compenser ces variations : le Transport Optimal. Celui-ci calcule en effet une matrice positive de transport  $T$  de taille  $M \times M$ , capable de transposer les poids des  $M$  différentes caractéristiques. Plus formellement, il s’agit de calculer une matrice positive telle que

$$\forall i, j \in \llbracket 1; n \rrbracket, \sum_{j=1}^M t_{ij} = v_i, \sum_{i=1}^M t_{ij} = [Wh]_j \quad (2)$$

Afin de diriger les choix de transport qui sont réalisés, nous associons à chaque transport entre caractéristiques un coût, retenu dans une matrice  $C$  de taille  $M \times M$ . Notre objectif sera alors de minimiser la valeur de

$$J(T|v, Wh, C) = \sum_{ij} c_{ij} t_{ij} \quad (3)$$

pour  $T$  vérifiant (2). Cela se ramène alors à un classique problème d’optimisation, résoluble par programmation linéaire.

### 3 Résolution du problème d’optimisation

#### 3.1 Définition des éléments caractéristiques

Il nous faut tout d’abord choisir les caractéristiques retenues pour nos signaux afin de procéder à la décomposition selon celles-ci. Dans notre contexte, la principale caractéristique des signaux cérébraux est leur fréquence. Nous avons donc choisi de représenter un signal par ses composantes fréquentielles. La plage généralement retenue pour nos tests se situe entre 0 et 14 Hz, avec une résolution fréquentielle de 0.25 Hz environ. Il est à noter qu’un tel choix, couplé à la méthode par dictionnaire, ne nous permet pas d’identifier les phases associées aux signaux. Aussi, il nous est impossible de reconstruire le signal avec ses phases selon cette méthode. Cependant, comme seul le spectrogramme nous intéresse réellement, cela n’est donc pas particulièrement problématique.

La matrice de coût retenue est alors une simple matrice de distance sur les fréquences. Celle-ci pénalise donc peu les légères variations de fréquence qui posaient problème à la PLCA. Cette matrice s’exprime de la forme  $c_{ij} = \lambda(f_i - f_j)^p$ . Le facteur  $p$  permet de moduler la variation de la pénalité. Nous avons pris la valeur arbitraire  $p = 2$ . Le facteur  $\lambda$ , quant à lui, n’a qu’un intérêt calculatoire : cela permet de contrôler l’ordre de grandeur des valeurs obtenues, afin d’éviter des problèmes liées à de trop grandes valeurs, par exemple. Dans nos tests finaux, nous avons cependant pu garder  $\lambda = 1$ . Ainsi, les coefficients de notre matrice  $C$  s’exprimaient comme  $c_{ij} = (f_i - f_j)^2$ .

#### 3.2 Implémentation

Il nous reste donc à résoudre le problème d’optimisation associé. Pour cela, nous avons implémenté un solveur par programmation linéaire. Le code est disponible à l’adresse *gitHub* suivante : <https://github.com/MaximeCaute/TraitementSignauxEEG>.

Pour résoudre le problème d'optimisation défini par (3), nous avons employé la méthode classique du simplexe. Pour cela, nous avons aplati nos matrices rectangulaires  $T$  et  $C$  en vecteurs  $\bar{t}$  et  $\bar{c}$  de taille  $M^2$ . La solution positive minimale cherchée est alors  $\bar{h}$ , concaténation de  $h$  et de  $\bar{t}$ . Notre problème s'écrit alors :

$$\bar{h} = \underset{\bar{h} \geq 0}{\operatorname{argmin}} \bar{t} \cdot \bar{c} \quad (4)$$

avec

$$\forall i, \sum_j 1 \cdot \bar{h}_{M+i*M+j} = v_i \quad (5)$$

$$\forall j, \sum_i 1 \cdot \bar{h}_{M+i*M+j} - \sum_k W_{jk} \cdot \bar{h}_k = 0 \quad (6)$$

Le simplexe nous donne alors  $\bar{h}$ , dont les  $M$  premières valeurs donnent la décomposition  $h$  souhaitée.

## 4 Débruitage manuel

Afin de pouvoir isoler les artefacts principaux, nous avons procédé à leur isolement manuel. L'artefact de gradient, tout d'abord, a été retiré à l'aide des marqueurs fournis par MNE, selon la méthode employée par le logiciel. La méthode d'acquisition permet en effet de connaître précisément l'instant où change le gradient du champ magnétique. Nous avons obtenu un signal moyen de l'artefact associé à l'aide d'une moyenne glissante s'étalant sur 21 intervalles de ces marqueurs. Une fois cet artefact isolé, il nous a été possible de le retrancher simplement par une soustraction point par point. La procédure employée par MNE, et suivie par nous-même, emploie par la suite un sous-échantillonnage et un filtrage passe-bas, afin de lisser les signaux obtenus.

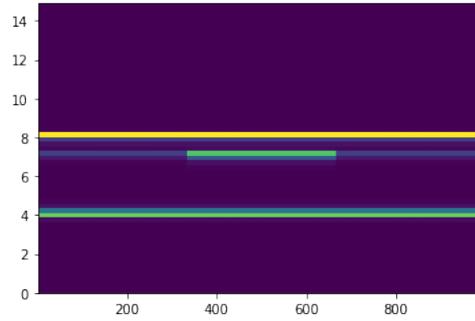
Cela est important par la suite car nous réutilisons ces signaux nettoyés pour isoler l'artefact de pouls. La méthode suivie ici est celle présentée dans [2]. Elle repose sur un principe similaire à celle de soustraction de l'artefact de gradient, malgré l'absence de marqueurs initialement. En effet, ceux-ci doivent tout d'abord être déterminés à partir du signal d'électrocardiogramme (ECG) enregistré par une électrode spécifique. Située au niveau du cœur, celle-ci peut donc enregistrer un signal sans interférence cérébrale, et ses seules perturbations sont donc le pouls et les variations de gradient. Nous pouvons donc repérer sur le signal ECG les instants de pulsation cardiaque. Ceux-ci se situent sur les pics de complexes appelés QRS visibles périodiquement sur le signal. Ces pics doivent donc être préalablement repérés. Par simplicité, nous avons procédé à cette reconnaissance en remarquant les maxima locaux au-delà d'un seuil, puis procédé à un regroupement des pics proches, aux points d'amplitude maximale.

Une fois les marqueurs obtenus pour ces pics, nous les avons transférés sur le signal EEG initial, avec un léger décalage temporel (de  $0,2s$ ) lié à la distance entre le cœur et le cerveau. Nous avons alors observé le signal sur des intervalles centré sur ces marqueurs. Nous leur avons choisi une taille commune, égale à la durée moyenne entre deux marqueurs. Nous avons ensuite moyenné de même ces intervalles avec ceux des 10 secondes précédentes. Les résultats obtenus par cette méthode n'ont cependant pas été très concluants pour l'artefact de pouls.

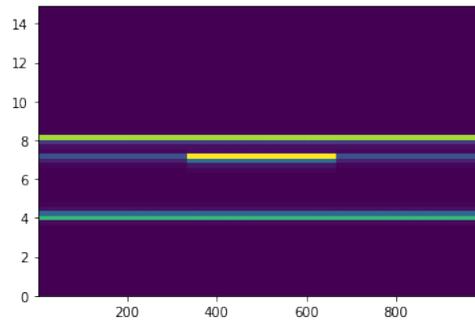
## 5 Discussion

### 5.1 Résultats

Nous avons donc testé notre solveur sur différents signaux, notamment des signaux jouets simplifiés comme décrit plus haut. Ceux-ci, dont un exemple de spectrogrammes est observable en figure 1, semblent indiquer une relative efficacité du solveur dans le cadre des signaux-jouets. Les fréquences sont convenablement



(a) Spectrogramme du signal-jouet d'origine



(b) Spectrogramme du signal-jouet recomposé

Figure 1: Exemple de spectrogrammes pour des signaux-jouets

repérées, mais il est à noter que les valeurs numériques semblent très imprécises. Les taux d'erreur dépassent ainsi fréquemment les 10%.

Le passage à l'échelle montre de son côté d'encore plus fortes imprécisions, avec notamment l'absence de détection de l'artefact de gradient, pourtant le plus important dans le signal.

## 5.2 Discussion

Les résultats sont donc assez mitigés : malgré une capacité théorique à résoudre ce type de problème, attestée dans l'article de Flamary [1], les résultats offerts semblent insuffisants, même au niveau de la simple reconstruction de spectrogramme.

Il nous semble y avoir trois raisons à ces problèmes. Premièrement, il y a une imprécision inhérente à cette méthode de résolution : malgré une décomposition dont les coefficients sont corrects, le signal recomposé sera imprécis, car le spectrogramme n'est pas la somme des spectrogrammes des coefficients. Cela semble dû à la non-linéarité des spectrogrammes, liée à l'apparition d'un module dans les calculs.

Il est également possible de considérer la résolution fréquentielle de nos spectrogrammes. Il a en effet été observé une forme d'étalement des fréquences, amplifiée en cas de pics de fréquence proche. Cela amène toutefois un problème de compromis, car l'augmentation de la résolution fréquentielle se fait au détriment de la résolution temporelle.

Enfin, les résultats aberrants obtenus lors du passage à l'échelle avec le signal réel peuvent trouver une autre explication. Ceux-ci seraient partiellement dus à un problème "mal posé" : dans notre dictionnaire, les signaux élémentaires semblent assez proches, notamment au regard d'une composante forte à 1 Hz (visible sur la figure 2), qui peut ainsi fortement masquer les autres et bouleverser les résultats. Deux solutions sont ici envisageables. Tout d'abord, éliminer les composantes autour de 1 Hz, ce qui risque toutefois d'amener de graves imprécisions par la suite, notamment pour l'artefact de pouls qui n'a quasiment que cette composante.

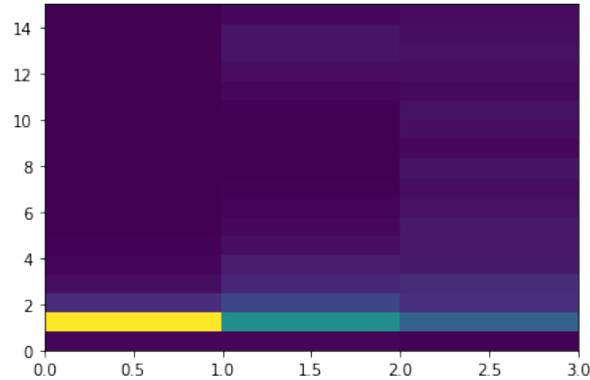


Figure 2: Dictionnaire des spectrogrammes des signaux élémentaires pour un signal réel  
De gauche à droite sont représentés : l'AP, l'AG, le signal d'intérêt (signal nettoyé)

Autrement, il peut être envisageable de modifier la matrice de coût pour fortement pénaliser les déplacements autour de 1 Hz. Plus généralement, une autre matrice de coût, prenant par exemple d'autres critères que les fréquences, pourrait être envisagée comme amélioration.

## Conclusion

Nous avons donc exploré au cours de ce projet la possibilité d'employer un solveur basé sur le transport optimal afin de décomposer et nettoyer les signaux IRM-EEG combinés. Malgré de bons résultats théoriques, ainsi qu'en pratique sur d'autres problèmes, nos résultats semblent plutôt mitigés, avec d'importantes imprécisions lors du passage aux signaux réels. En dehors de difficultés inhérentes à la méthode, une bonne piste d'amélioration semble être le traitement de composantes trop importantes, communes aux signaux à distinguer, particulièrement les pics autour de 1 Hz. Une manière de procéder pourrait consister en une adaptation au problème de la matrice de coût, plutôt que le choix d'une simple matrice de distances fréquentielles.

## References

- [1] Nicolas Courty Valentin Emiya Rémi Flamary, Cédric Févotte. Optimal spectral transportation with application to music transcription. *29th Conference on Neural Information Processing Systems (NIPS 2016)*, Barcelona, Spain., 2016.
- [2] Karsten Krakow David R. Fish et Louis Lemieux Philip J. Allen, Giovanni Polizzi. Identification of eeg events in the mr scanner: The problem of pulse artifact and a method for its subtraction. *NeuroImage*, 1998.
- [3] et Robert Turner Philip J. Allen, Oliver Josephs. A method for removing imaging artifact from continuous eeg recorded during functional mri. *NeuroImage*, 2000.
- [4] Archana Tiwari Priyanka Khatwani1. A survey on different noise removal techniques of eeg signals. *International Journal of Advanced Research in Computer and Communication Engineering*, 2013.
- [5] Hajipour Sardouie. *Suppression du bruit de signaux EEG épileptiques*. PhD thesis, Université de Rennes 1, Rennes, France, 2014.
- [6] Peter van Gelderen Li-Wei Kuo Zhongming Liu, Jacco A. de Zwart and Jeff H. Duyn. Statistical feature extraction for artifact removal from concurrent fmri-eeg recordings. *NeuroImage*, 2012.

- [7] V.K. Jain Gautam Kaushal, Amanpreet Singh. Better approach for denoising eeg signals. *IEEE*, 2016.
- [8] Alexandre Gramfort Hicham Janati, Marco Cuturi. Wasserstein regularization for sparse multi-taskregression. 2018.
- [9] Bertrand Thirion Marco Cuturi Alexandre Gramfort Hicham Janati, Thomas Bazeille. Group level meg/eeg source imaging via optimaltransport: minimum wasserstein estimates. *IPMI*, 2019.