



**HAL**  
open science

## Extraction de Caractéristiques du signal EEG

Fabien Lotte, Marco Congedo

► **To cite this version:**

Fabien Lotte, Marco Congedo. Extraction de Caractéristiques du signal EEG. Maureen Clerc; Laurent Bougrain; Fabien Lotte. Les Interfaces Cerveau-Ordinateur 1 : fondements et méthodes, ISTE-Wiley, 2016. hal-01417027

**HAL Id: hal-01417027**

**<https://hal.inria.fr/hal-01417027>**

Submitted on 15 Dec 2016

**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.

## Chapitre 8

# Extraction de Caractéristiques du signal EEG

### 8.1. Introduction

Une des étapes majeures de la conception d'une BCI exploitant les signaux EEG est le traitement et la classification de ces signaux pour identifier l'état mental de l'utilisateur. Comme vu précédemment, analyser ces signaux EEG se décompose en trois étapes successives qui sont le prétraitement (traité dans le chapitre précédent), l'extraction de caractéristiques et la classification. Ce chapitre s'intéresse à l'extraction de caractéristiques, qui, rappelons-le, consiste à décrire les signaux EEG par un ensemble essentiel (idéalement petit) de valeurs décrivant l'information pertinente qu'ils contiennent, en vue de les classer. En particulier, nous verrons quel type d'information extraire des signaux EEG, pour différents types de BCI, et comment extraire cette information pour quelle puisse discriminer au mieux différents états mentaux.

### 8.2. L'extraction de caractéristiques

Une caractéristique est une valeur décrivant une propriété des signaux EEG, par exemple, la puissance du signal EEG dans le rythme  $\mu$  pour l'électrode C3. Les caractéristiques sont généralement regroupées dans un vecteur qu'on appelle "vecteur de caractéristiques". En guise d'exemple, intéressons-nous à une BCI exploitant l'imagerie motrice (IM), c'est-à-dire pouvant reconnaître des mouvements imaginés, par exemple des mains. Dans ce cas les deux états mentaux à identifier sont un mouvement imaginé de la main gauche, et un mouvement imaginé de la main droite. Afin de les identifier dans les signaux EEG, les caractéristiques généralement extraites sont

des puissances de bande, i.e., la puissance du signal EEG dans une bande de fréquence spécifique. Pour l'IM, les puissances de bande sont généralement calculées dans les bandes de fréquences  $\mu$  (environ 8-12 Hz) et  $\beta$  (environ 16-24 Hz) pour les électrodes situées au-dessus du cortex sensori-moteur (par exemple pour les électrodes C3 et C4 pour des mouvements imaginés des mains) [PFU 01]. De telles caractéristiques peuvent typiquement être classifiées en utilisant un classifieur comme l'Analyse Linéaire Discriminante (cf le chapitre suivant).

Dans la conception des BCI, le traitement des signaux EEG s'appuie souvent sur des techniques d'apprentissage machine. Cela signifie que le classifieur et/ou les caractéristiques sont généralement ajustées et optimisées pour chaque utilisateur, à partir d'exemples de signaux EEG de cet utilisateur. Ces exemples de signaux EEG sont appelés un ensemble d'apprentissage, et sont étiquetés avec leur classe d'appartenance, c'est-à-dire l'état mental de l'utilisateur lorsque les signaux EEG ont été enregistrés. Grâce à cet ensemble d'apprentissage, on va pouvoir calibrer un classifieur pour qu'il puisse reconnaître la classe des différents signaux EEG, comme décrit dans le chapitre suivant. Les caractéristiques peuvent également être optimisées grâce à des exemples de signaux EEG, par exemple en sélectionnant les électrodes les plus pertinentes pour reconnaître les différents états mentaux. Ainsi, concevoir une BCI exploitant l'apprentissage machine (ce qui est le cas de la plupart des BCI) nécessite : 1) **Une phase de calibration** (aussi appelée phase d'apprentissage/d'entraînement), qui consiste à acquérir des signaux EEG d'apprentissage (i.e., des exemples) et optimiser la chaîne de traitement des signaux EEG en ajustant les paramètres des caractéristiques et/ou en entraînant un classifieur et 2) **Une phase d'utilisation** (aussi appelée phase de test), qui consiste à utiliser le modèle (caractéristiques et classifieur) obtenu lors de la phase de calibration pour reconnaître l'état mental de l'utilisateur à partir de nouveaux signaux EEG (i.e., des signaux EEG qui n'étaient pas dans l'ensemble d'apprentissage), afin de faire fonctionner la BCI.

Comme brièvement mentionné ici et comme nous le verrons en détail dans le chapitre suivant, un classifieur est capable d'apprendre à partir d'exemples quelle classe correspond à quelles caractéristiques d'entrée. Ainsi, pourquoi ne pas utiliser directement les valeurs des signaux EEG comme caractéristiques d'entrée du classifieur ? La réponse est que ça ne marcherait très probablement pas à cause d'un phénomène appelé la "malédiction de la dimension" ("curse-of-dimensionality" en anglais) : il a en effet été observé que la quantité d'exemples nécessaire pour décrire proprement différentes classes augmente exponentiellement avec la dimension du vecteur de caractéristiques (i.e., le nombre de caractéristiques utilisées) [RAU 91]. Certains chercheurs recommandent même d'utiliser de 5 à 10 fois plus d'exemples d'entraînement par classe que la dimension du vecteur de caractéristiques<sup>1</sup> [RAU 91]. Qu'est ce que

---

1. Cette recommandation a été faite avant l'invention des SVM (décrités dans le chapitre suivant), ces dernières étant moins sensibles à la malédiction de la dimension

cette recommandation voudrait dire si on utilisait directement la valeur des signaux EEG comme caractéristiques ? Imaginons par exemple que nous utilisions un système EEG commun, avec 32 électrodes échantillonnées à 250 Hz, et qu'un exemple de signaux EEG pour une tâche mentale donnée dure 1 seconde. Nous aurions donc un vecteur de caractéristiques d'une dimension de  $32 * 250 * 1 = 8000$ , ce qui nécessiterait au moins  $8000 * 5 = 40000$  exemples d'apprentissage par classe. Bien évidemment, on ne peut pas demander à un utilisateur BCI d'effectuer chaque tâche mentale 40000 fois afin de calibrer la BCI avant qu'il/elle ne puisse l'utiliser. Il nous faut donc une représentation plus compacte, et donc extraire des caractéristiques des signaux EEG.

Pour concevoir une BCI, il y a trois sources principales d'information qui peuvent être utilisées pour extraire des caractéristiques des signaux EEG :

- **L'information spatiale** : qui décrit d'où (spatialement) vient le signal pertinent. En pratique, cela signifie sélectionner des électrodes EEG spécifiques ou se focaliser plus sur certains capteurs que sur d'autres. En d'autres termes, cela revient à utiliser le signal venant d'une ou plusieurs régions cérébrales spécifiques, mais pas (ou peu) d'ailleurs.

- **L'information spectrale (ou fréquentielle)** : qui décrit comment la puissance du signal EEG dans certaines bandes de fréquences spécifiques varie. En pratique cela revient à utiliser la puissance de bande du signal comme caractéristiques.

- **L'information temporelle** : qui décrit comment les signaux EEG varient au cours du temps. En pratique, cela signifie utiliser les valeurs des signaux EEG pour différents pas de temps spécifiques (pas tous) ou différentes fenêtres temporelles.


Pour l'instant, il est généralement nécessaire d'utiliser des sources d'information différentes pour différents types de BCI. En particulier, des BCI exploitant l'activité EEG oscillatoire (e.g., les BCI basés sur l'IM) utilisent principalement l'information spatiale et spectrale, tandis que les BCI exploitant les Potentiels Evoqués (PE) utilisent principalement l'information spatiale et temporelle. Les sections suivantes décrivent les techniques d'extraction de caractéristiques utilisées pour ces deux types de BCI.

### 8.3. Extraction de caractéristiques pour les BCI exploitant l'activité oscillatoire

Les BCI exploitant l'activité oscillatoire sont des BCI utilisant des états mentaux donnant lieu à des changements d'amplitude des oscillations EEG, c'est-à-dire des changements de puissance des signaux EEG dans certaines bandes de fréquences (donc des ERD/ERS, cf chapitre 3 et 4). De telles BCI incluent notamment les BCI exploitant l'IM [PFU 01], les SSVEP [VIA 10], diverses tâches d'imagerie mentales telles que du calcul mental ou de la génération mentale de mots [FRI 12], ou encore différents niveaux de charge mentale [MÚH 14]. Cette section présente tout d'abord une conception basique (et naïve) d'une telle BCI, puis des outils plus avancés et notamment l'algorithme majeur dit du "Common Spatial Patterns" (CSP).

### 8.3.1. Conception basique d'une BCI exploitant l'activité oscillatoire

Les BCI exploitant l'activité oscillatoire se servent de la puissance des signaux EEG dans certaines bandes de fréquence (information spectrale) et certaines régions cérébrales (information spatiale). Par exemple, une conception basique d'une BCI exploitant l'IM utiliserait l'information spatiale en extrayant des caractéristiques uniquement des capteurs EEG situés au-dessus des aires cérébrales motrices, typiquement les capteurs C3 pour un mouvement imaginé de la main droite, Cz pour un mouvement imaginé des pieds et C4 pour un mouvement imaginé de la main gauche. Elle utiliserait l'information spectrale en se focalisant sur les bandes de fréquences  $\mu$  (8-12 Hz) et  $\beta$  (16-24 Hz). Plus précisément, pour une BCI pouvant reconnaître des mouvements imaginés de la main gauche et droite, des caractéristiques basiques à extraire seraient la puissance de bande dans 8-12 Hz et 16-24 Hz pour chacune des électrodes C3 et C4, soient quatre caractéristiques. Il existe de nombreuses façons de calculer la puissance de bande des signaux EEG [BRO 11]. Cependant, une manière simple et néanmoins efficace est de tout d'abord filtrer le signal EEG d'un capteur donné dans la bande de fréquence d'intérêt, puis de calculer le carré du signal filtré pour obtenir la puissance de ce signal, et enfin de moyennner le signal au cours du temps (ex : au cours de la dernière seconde, si on utilise des fenêtres glissantes). Ce principe est illustré Figure 8.1.



**Figure 8.1.** Extraction de la puissance de bande comme une caractéristique d'un signal EEG brut. Le signal EEG illustré ici a été enregistré durant une imagination de mouvement de la main droite (début de l'imagination à  $t = 0s$ ). L'ERD contralatérale pendant l'imagination est clairement visible : la puissance du signal de l'électrode C3 (cortex moteur gauche) dans la bande 8-12 Hz diminue clairement durant l'imagination.

Malheureusement, cette conception basique est loin d'être optimale. En effet, elle n'utilise que deux électrodes : de l'information pertinente mesurée par d'autres capteurs peut manquer. De plus, C3 et C4 ne sont peut-être pas les meilleurs capteurs pour le sujet courant. De même, les bandes de fréquences fixes 8-12 Hz et 16-24 Hz ne sont peut-être pas non plus les meilleurs bandes pour le sujet courant. De manière générale, de meilleures performances peuvent être obtenues en utilisant une conception spécifique à chaque sujet, avec les meilleures électrodes et bandes de fréquences optimisées pour ce sujet. Utiliser plus de deux capteurs permet aussi d'obtenir des performances généralement meilleures.

### 8.3.2. *Vers des BCI plus avancées utilisant de multiples électrodes*

Le besoin d'utiliser des capteurs spécifiques à chaque sujet et d'utiliser plus de deux capteurs nous amène à concevoir des BCI utilisant de multiples électrodes. Ce besoin a été confirmé par diverses études qui suggèrent que, pour l'IM, les performances maximales sont obtenues avec un grand nombre d'électrodes, par exemple avec 48 capteurs dans [SAN 10]. Cependant, simplement rajouter des capteurs ne va pas résoudre les problèmes de performances. En effet, utiliser plus de capteurs signifie extraire plus de caractéristiques ce qui expose d'autant plus à la malédiction de la dimension. Ainsi, simplement ajouter des capteurs peut même réduire les performances si le nombre d'exemples d'apprentissage disponible est trop faible. Afin d'exploiter efficacement de multiples capteurs, il existe trois approches principales, chacune contribuant à réduire la dimension du vecteur de caractéristiques :

- Des algorithmes de **sélection de caractéristiques**, qui sont des méthodes pour sélectionner automatiquement un sous-ensemble pertinent de caractéristiques, parmi toutes les caractéristiques initialement extraites [GUY 03].
- Des algorithmes de **sélection de capteurs**, qui sont des méthodes, similaires à celles de sélection de caractéristiques, pour sélectionner automatiquement un sous-ensemble pertinent de capteurs, parmi tous les capteurs disponibles.
- Des algorithmes de **filtrage spatial**, qui sont des méthodes combinant plusieurs capteurs, généralement par combinaison linéaire, pour en former un nouveau (virtuel) à partir duquel les caractéristiques vont être extraites.

Dans la suite, nous nous focaliserons sur le filtrage spatial, pour lequel des algorithmes spécifiques à l'EEG et aux BCI ont vu le jour. La sélection de caractéristique est en effet un ensemble d'outils généraux en apprentissage machine, non spécifiques à l'EEG ou aux BCI (voir [GUY 03] pour plus de détails). Quant à la sélection de capteurs, les algorithmes utilisés sont généralement dérivés d'algorithme de sélection de caractéristiques. Le lecteur intéressé pourra se référer par exemple à [SCH 05] ou [ARV 11] et à leur références pour en apprendre plus sur le sujet.

### 8.3.2.1. Filtrage spatial

Le filtrage spatial consiste à utiliser un petit nombre de nouveaux canaux (des canaux virtuels) qui sont définis comme une combinaison linéaire des capteurs originaux. Formellement le filtrage spatial se décrit par  $\tilde{x} = \sum_i w_i x_i = wX$  avec  $\tilde{x}$  étant le signal spatialement filtré,  $x_i$  le signal EEG par le capteur  $i$ ,  $w_i$  le poids donné à ce capteur dans le filtre spatial et  $X$  une matrice dont la  $i^{me}$  ligne est  $x_i$ , i.e.,  $X$  est la matrice des signaux EEG de chaque capteur. Le filtrage spatial est utile non seulement car il réduit la dimension du problème (passage de nombreux capteurs EEG initiaux à un petit nombre de signaux spatialement filtrés - on utilise typiquement beaucoup moins de filtres spatiaux que le nombre de capteurs originaux) mais aussi car il a un sens neurophysiologique. En effet, comme vu précédemment (chapitres 2 et 3), les signaux EEG mesurés en surface du cuir chevelu sont le résultat de mélanges bruités de signaux EEG venant de différentes régions cérébrales. En d'autres termes, étant donné que le signal EEG provenant du cortex se diffuse lorsqu'il traverse le crâne ou le cuir chevelu, lorsqu'il arrive au niveau des capteurs EEG, ce signal se retrouve diffusé et dispersé sur plusieurs capteurs EEG. Ainsi, le filtrage spatial permet d'aider à récupérer le signal original (venant du cortex) en rassemblant l'information pertinente qui a été éparpillée sur différents capteurs.

Il y a différentes façon de définir les filtres spatiaux. En particulier, les poids du filtre  $w_i$  peuvent être fixé a priori, selon des connaissances neurophysiologiques, ou peuvent être optimisés à partir de données, sur des exemples d'apprentissage. Parmi les filtres spatiaux fixes, on peut notamment mentionner les filtres bipolaires et Laplaciens, déjà décrits dans le chapitre précédent. Il a été montré qu'extraire des caractéristiques de canaux bipolaires ou laplaciens plutôt que des capteurs EEG originaux permet d'augmenter significativement les performances de classification [MCF 97]. Les méthodes de reconstruction de sources distribuées (également présentées dans le chapitre précédent) peuvent également être utilisées pour définir des filtres spatiaux fixes, afin d'analyser le signal EEG provenant de régions cérébrales bien particulières. Extraire des caractéristiques de filtres spatiaux obtenus par reconstruction de sources permet également d'obtenir de meilleurs performances de classification qu'en extrayant les caractéristiques depuis les capteurs EEG originaux [CON 06].

La deuxième catégorie de filtres spatiaux, basés sur les données, contient des filtres qui sont optimisés pour chaque sujet, sur des données d'apprentissage. Cette catégorie contient notamment les filtres spatiaux construits par Analyse en Composantes Indépendantes (ACI) [KAC 08], décrites dans le chapitre précédent. Ces techniques permettant d'obtenir les poids  $w_i$  des filtres spatiaux de manière non-supervisée, c'est-à-dire sans avoir connaissance des étiquettes (classes) des données d'apprentissage. Alternativement, les poids des filtres spatiaux peuvent être définis de manière supervisée (i.e., en connaissant l'étiquette de chaque exemple d'apprentissage), afin d'optimiser une mesure de séparation entre les classes. Un algorithme de ce type a été

développé pour les BCI basés sur l'activité EEG oscillatoire : l'algorithme "Common Spatial Patterns" (CSP) [RAM 00], décrit ci-dessous.

### 8.3.3. L'algorithme "Common Spatial Patterns"

Informellement, l'algorithme du CSP optimise les filtres spatiaux  $w$  tel que la variance du signal EEG filtré soit maximale pour une classe et minimale pour l'autre classe. Etant donné que la variance d'un signal filtré dans la bande  $b$  est égale à la puissance du signal dans la bande  $b$ , cela signifie que le CSP optimise des filtres spatiaux de façon à obtenir des caractéristiques de puissance de bande qui sont optimalement discriminante puisque leur valeur est maximale différente entre les deux classes. Ainsi, le CSP est particulièrement utile pour les BCI exploitant l'activité oscillatoire puisque le type de caractéristiques le plus utile pour leur conception est justement la puissance de bande. Par exemple, pour les BCI exploitant l'IM, les signaux EEG sont typiquement filtrés dans la bande 8-30 Hz (rythmes  $\mu$  et  $\beta$ ) avant d'être spatialement filtrés grâce au CSP [RAM 00]. Formellement, le CSP optimise les filtres spatiaux  $w$  en extrémisant (i.e., en minimisant et en maximisant) la fonction suivante :

$$J_{CSP1}(w) = \frac{wX_1X_1^T w^T}{wX_2X_2^T w^T} \quad [8.1]$$

ce qui est équivalent à extrémiser

$$J_{CSP2}(w) = \frac{wC_1w^T}{wC_2w^T} \quad [8.2]$$


où  $T$  représente la transposée matricielle,  $X_i$  sont les signaux EEG d'apprentissage pour la classe  $i$ , préalablement filtrés passe-bande (avec les échantillons EEG en colonne et les capteurs en ligne) et  $C_i$  la matrice de covariance spatiale pour la classe  $i$ . En pratique, la matrice de covariance  $C_i$  est définie comme la moyenne des matrices de covariance de chaque exemple de la classe  $i$  [RAM 00]. Dans cette équation,  $wX_i$  est le signal EEG de la classe  $i$  spatialement filtré, et  $wX_iX_i^T w^T$  est donc la variance du signal spatialement filtré, c'est-à-dire sa puissance de bande. Ainsi, extrémiser  $J_{CSP}(w)$ , i.e., maximiser et minimiser cette fonction, permet en effet d'obtenir des signaux spatialement filtrés dont la puissance de bande est maximallement différente entre les classes.  $J_{CSP}(w)$  est sous la forme de ce que l'on appelle mathématiquement un quotient de Rayleigh généralisé. Par conséquent, extrémiser cette fonction peut être résolu par Décomposition en Valeur Propre Généralisée (DVPG). Les filtres spatiaux  $w$  qui maximise ou minimise  $J_{CSP}(w)$  sont donc les vecteurs propres correspondant respectivement aux valeurs propres les plus grandes et les plus petites de la DVPG des



matrices  $C_1$  et  $C_2$ . Typiquement, on utilise six filtres CSP (i.e., trois paires de filtres), correspondant aux trois plus grandes et aux trois plus petites valeurs propres. Une fois que les filtres ont été obtenus, une caractéristique CSP  $f$  est calculée comme suit :

$$f = \log(wCw^T) = \log(\text{var}(wX)) \quad [8.3]$$

i.e., une caractéristique CSP est simplement la puissance de bande du signal spatialement filtré avec l'un des filtres CSP  $w$ . L'utilisation du CSP est illustrée sur la Figure 8.2. Sur cette Figure, on peut observer une nette différence de variance (et donc de puissance de bande) entre les signaux spatialement filtrés avec le CSP pour chacune des deux classes, ce qui assure de bonnes performances de classification.



**Figure 8.2.** Des signaux EEG spatialement filtrés avec l'algorithme CSP (Common Spatial Patterns). Les deux premiers filtres spatiaux (les deux signaux du haut) sont ceux qui maximisent la variance des signaux de la classe "Mouvement imaginé de la main gauche" (en rouge) tout en minimisant ceux de la classe "Mouvement imaginé de la main droite" (en vert). Les deux derniers filtres (les deux signaux du bas) font le contraire, i.e., ils maximisent la variance de la classe "Mouvement imaginé de la main droite" tout en minimisant la variance de la classe "Mouvement imaginé de la main gauche".


L'algorithme CSP a de nombreux avantages : tout d'abord il permet d'obtenir des performances de classification relativement élevées pour des BCI. C'est un algorithme assez flexible puisqu'il peut être utilisé pour n'importe quelle BCI utilisant les ERD/ERS. Enfin, c'est un algorithme numériquement efficace et simple à implémenter. Tout ceci fait que le CSP est devenu l'un des algorithmes les plus populaires et les plus efficaces pour la conception de BCI basées sur l'activité oscillatoire [LOT 11]. Ces performances sont illustrées dans la section suivante.

### 8.3.4. Illustration sur de vraies données

Pour illustrer l'impact des filtres spatiaux sur les performances de classification de la BCI, nous avons comparé les performances obtenues par différents filtres sur le jeu de données IIa de la "BCI competition IV" [TAN 12]. Lors de cette compétition, un ensemble d'apprentissage et un ensemble de test étaient mis à disposition des compétiteurs. Chaque ensemble contenait 72 exemples de signaux EEG pour chaque classe (imagination d'un mouvement de la main gauche, droite, de la langue et des pieds) pour 9 sujets différents. Les exemples de l'ensemble d'apprentissage étaient étiquetés avec leur classe, tandis que les exemples de l'ensemble de test n'étaient pas étiquetés : les compétiteurs devaient calibrer leurs algorithmes (ex : le classifieur) sur l'ensemble d'apprentissage, et l'utiliser pour deviner la classe des exemples de test. Le but de la compétition était d'identifier les meilleurs algorithmes pour reconnaître ces différentes tâches mentales. Les données de cette compétition sont maintenant disponibles pour tester, évaluer et comparer différentes méthodes.

Nous avons comparé hors-ligne quatre conceptions différentes de BCI, basées sur quatre filtres spatiaux différents, pour distinguer mouvements imaginés de la main droite et gauche. Les quatre filtres utilisés sont 1) pas de filtre mais juste les signaux EEG des électrodes C3 et C4, 2) filtrage bipolaire autour de C3 et C4, 3) filtrage Laplacien autour de C3 et C4 et 4) filtrage CSP (trois paires de filtres). Pour classifier les signaux, nous les avons tout d'abord filtrés spectralement dans la bande 8-30 Hz, puis filtrés spatialement avec l'un des quatre filtres. Ensuite nous avons calculé la puissance de bande moyenne du signal sur une fenêtre temporelle de 2 secondes commençant 0.5s après le début de la tâche d'imagination. Ces puissances de bande pour chaque filtre sont ensuite donné à un classifieur (Analysis Linéaire Discriminante - ALD) pour identifier la tâche effectuée. Le CSP et l'ALD sont calibrés sur l'ensemble d'apprentissage, et chaque méthode est ensuite testé sur l'ensemble de test. La Figure 8.3 montrent les performances de classification obtenues sur l'ensemble de test par chaque méthode.

Comme on peut le constater sur cette figure, utiliser un filtre spatial fixe, tel que les filtres bipolaires ou Laplaciens, permet déjà d'augmenter les performances (performances moyennes filtres bipolaires : 70.5%, filtres Laplacien 68%) par rapport à utiliser C3 et C4 seuls (performance moyenne 60.7%). Utiliser un filtre basé sur les données comme le CSP permet d'augmenter encore plus les performances de classification (performance moyenne 78.1%). Il convient toutefois de noter que le CSP n'est pas un algorithme parfait, loin de là. Il est notamment sensible à la présence de bruit et d'artefacts, et fonctionne mal avec peu de données d'apprentissage. Ainsi de nombreuses variantes du CSP ont été proposées pour remédier à ça, et la recherche sur le sujet est encore très active [LOT 11][SAM 14].




**Figure 8.3.** Performances de classification (taux de bonnes classifications) obtenues sur le jeu de données Ia de la “BCI competition IV” [TAN 12], pour classifier mouvements imaginés de la main gauche et droite, pour différents filtres spatiaux.

#### 8.4. Extraction de caractéristiques pour les BCI exploitant les Potentiels Evoqués

Un exemple typique d’PE évoqué utilisé dans les BCI est le P300 [FAZ 12], comme décrit dans le chapitre 4. Les PE sont caractérisés par des variations temporelles spécifiques par rapport à l’apparition du stimulus qui les déclenche. Ainsi, contrairement aux BCI exploitant l’activité cérébrales, les BCI utilisant les PE se servent principalement d’une information temporelle, mais assez rarement d’une information spectrale. Néanmoins, tout comme les BCI exploitant l’activité oscillatoire, ceux exploitant les PE peuvent aussi exploiter l’information spatiale.

Par exemple, dans le cas d’une BCI utilisant le P300, l’information spatiale est principalement utilisée en se focalisant sur les électrodes pariétales et occipitales (i.e., en extrayant des caractéristiques uniquement de ces électrodes), d’où le P300 provient. Krusienski et al recommandent par exemple d’utiliser un ensemble de 8 capteurs, situés en Fz, Cz, P3, Pz, P4, PO7, Oz, PO8 [KRU 06]. Une fois l’information spatiale pertinente identifiée, i.e., les électrodes (comme dans l’exemple ci-dessus), des caractéristiques peuvent-être extraites du signal de chacune d’entre-elles. Pour les PE en général, et donc également pour le P300, les caractéristiques utilisées reflètent généralement l’information temporelle des signaux, c’est-à-dire comment l’amplitude des signaux varie avec le temps. Ceci est effectué en utilisant la valeur des différents points des signaux EEG prétraités comme caractéristiques. Plus précisément, on extrait généralement des caractéristiques d’un PE en 1) filtrant passe-bas ou passe-bande les signaux (par ex : dans 1-12 Hz pour le P300, les PE étant généralement des ondes lentes), 2) en sous-échantillonnant le signal filtré, afin de réduire le nombre de point du signal EEG et donc la dimension du problème et 3) en rassemblant les valeurs des

points EEG restant de tous les capteurs sélectionnés en un seul vecteur de caractéristiques qui sera utilisé en entrée du classifieur. Ce procédé est illustré sur la Figure 8.4, afin d'extraire des caractéristiques de l'électrode Pz pour une BCI utilisant le P300.



**Figure 8.4.** Processus classique pour extraire des caractéristiques d'un capteur EEG pour un BCI exploitant les PE (ici un P300). Le stimulus pouvant évoquer le PE apparaît à  $t=0s$ .

Extraire plusieurs points temporels de plusieurs capteurs comme caractéristiques fait que les BCI exploitant les PE ont généralement une dimension plus élevée que ceux exploitant l'activité oscillatoire. Ainsi, il est important d'utiliser des classifieurs pouvant gérer une dimension élevée (cf. Chapitre suivant), ou bien d'utiliser, comme mentionné précédemment, des algorithmes de sélection de caractéristiques ou de sélection de capteurs, ceux-ci étant les mêmes pour les 2 types de BCI. Des filtres spatiaux dédiés aux PE ont également été proposés.

#### 8.4.1. Filtrage Spatial pour les BCI exploitant les Potentiels Evoqués

Tout comme pour les BCI exploitant l'activité oscillatoire, les BCI utilisant les PE peuvent aussi bénéficier de filtrage spatial, pour extraire des sources cérébrales dont les caractéristiques sont discriminantes. Ainsi pourquoi ne pas utiliser également le CSP pour les PE ? Ceci est due au fait que l'information cruciale pour classifier des PE est l'information sur le déroulement temporel des signaux EEG. Malheureusement le CSP ignore complètement cette information étant donné qu'il considère uniquement la puissance moyenne du signal (et donc pas son déroulement temporel) pour optimiser les filtres. Ainsi, le CSP n'est pas approprié pour la classification de PE. Bien heureusement il existe d'autres algorithmes de filtrages spatiaux spécifiquement pour les PE. On peut notamment citer le filtre spatial de Fisher dédié aux PE, proposé par Hoffmann *et al* [HOF 06], ou encore xDAWN, proposé par Rivet *et al* [RIV 09]. L'objectif

de ces deux filtres spatiaux est d'obtenir des signaux spatialement filtrés tels que les PE soient plus visibles et plus discriminables que dans les signaux EEG originaux. Ces deux méthodes utilisent des fonctions objectives différentes pour atteindre ce but. Nous décrivons dans la suite le filtre xDAWN pour illustrer le filtrage spatial des PE pour les BCI. L'algorithme de filtrage spatial xDAWN, qui s'est avéré très efficace pour la classification de PE, cherche à maximiser la rapport signal sur signal plus bruit. De manière informelle, cela signifie qu'xDAWN cherche à mettre en valeur le PE, à le rendre plus visible au milieu du bruit. Formellement, xDAWN optimise les filtres spatiaux en maximisant la fonction suivante :

$$J_{xDAWN} = \frac{wSS^T w^T}{wXX^T w^T} \quad [8.4]$$

où  $S$  est une estimation du décours temporel moyen du PE (moyenné sur les répétitions). Ce PE moyen peut-être estimé plus finement par moindres carrés dans le cas où les PE se chevauchent temporellement (ce qui est le cas avec le "P300-speller") [RIV 09]. Dans cette équation, le numérateur représente le signal, c'est-à-dire l'information pertinente que l'on veut mettre en valeur. En effet,  $wSS^T w^T$  est la puissance du décours temporel du PE après filtrage spatial. Par opposition, dans le dénominateur,  $wXX^T w^T$  est la puissance de tous les signaux EEG, après filtrage spatial. Le dénominateur contient donc à la fois le signal (le PE d'intérêt) et le bruit. Ainsi, maximiser  $J_{xDAWN}$  revient à simultanément maximiser le signal, c'est-à-dire à mettre en valeur le PE, et à minimiser le signal plus le bruit, c'est-à-dire à rendre le bruit aussi petit que possible [RIV 09]. Cette approche permet en effet d'améliorer significativement les performances de classification des PE, en particulier quand peu d'exemples d'apprentissage sont disponibles.

### 8.5. Méthodes alternatives et l'approche par géométrie Riemmanienne

Ce chapitre a présenté les outils principaux pour reconnaître l'état mental de l'utilisateur en fonction des oscillations EEG (information spectrale) et PE (information temporelle). Ces outils sont relativement simples, très largement utilisés et efficaces. Ce ne sont cependant pas les seuls outils disponibles. On peut par exemple citer d'autres méthodes pour extraire de l'information temporelle telles que les paramètres de Hjorth [OBE 01] ou les "Time Domain Parameters (TDP)" [VID 09], des méthodes pour mesurer la complexité des signaux [BRO 12] ou encore des méthodes mesurant des informations de connectivité, c'est-à-dire mesurant à quel point les signaux de différents capteurs sont liés (par exemple synchronisés ou corrélés) [CAR 14].


Des travaux récents ont exploré une nouvelle approche pour l'extraction de caractéristiques pour les BCI [BAR 12, CON 13]. L'idée est de résumer l'information

pertinente, qu'elle soit spatiale, fréquentielle et/ou temporelle, par un point dans un espace multidimensionnel particulier. Cet espace est la variété Riemannienne des matrices définies positives (en anglais : symmetric positive definite matrix, ou SPD). Une matrice SPD est une matrice carrée et symétrique dont toutes les valeurs propres sont positives. Par exemple, les matrices de covariance spatiale en EEG sont SPD (Figure 8.5, gauche). Or, la variété Riemannienne des matrices SPD est leur espace natif et courbe (cf Figure 8.5). Sur cette variété une métrique appropriée nous fournit une façon de calculer la distance entre n'importe quelle paire de points (Figure 8.5, droite).

Grâce à cette notion de distance nous pouvons estimer la moyenne géométrique d'un nuage de points (chaque point étant une matrice SPD représentant le signal EEG) correspondant aux différentes classes d'une BCI, obtenus dans la phase de calibration. On peut ainsi classifier de nouveaux signaux simplement en évaluant leur distance par rapport aux moyennes géométriques de chaque classe (Figure 8.6). Cette approche s'est avérée aussi simple qu'efficace, en donnant des résultats de classification aussi bons que l'état-de-l'art pour l'IM et le P300, tout en permettant une meilleure généralisation entre sessions et entre sujets [BAR 12, CON 13]. D'ailleurs, cette robustesse a aussi permis de concevoir des BCI sans calibration. Pour cela une base de données est utilisée pour initialiser la BCI, et cette BCI s'adapte ensuite au sujet pendant l'utilisation. De plus, avec cette approche, la chaîne de traitement est identique pour tous les types de BCI : seule la définition du point qui résume les signaux EEG sur la variété change en fonction du type de BCI. E.g., pour les BCI basées sur l'IM on utilise l'information spatiale et ceux basées sur les PE l'information temporelle [CON 13].

## 8.6. Conclusion


Dans ce chapitre, nous avons essayé de montrer au lecteur quel type d'information pertinente peut-être extraite des signaux EEG, afin de les classifier plus tard, et comment extraire cette information. Nous avons notamment vu que les 3 sources d'information principales sont 1) l'information spectrale, qui est utilisée avec des caractéristique de puissance de bande, 2) l'information temporelle, typiquement représentée comme l'amplitude de signaux EEG pré-traités au court du temps et 3) l'information spatiale, qui peut être exploitée en se focalisant sur certains capteurs ou en utilisant des filtres spatiaux (CSP pour les BCI exploitant l'activité oscillatoire ou xDAWN pour celles exploitant les potentiels évoqués). Il est important de noter qu'il y a encore de nombreux travaux sur l'extraction de caractéristiques pour les BCI, et que la méthode idéale, qui serait à la fois robuste, invariante (au cours du temps) et universelle (qui marche bien pour tous les utilisateurs) reste encore à trouver !



**Figure 8.5.** Gauche : Les matrices de covariance de dimension  $N \times N$  sont notamment contraintes par leur symétrie et la positivité de leurs éléments diagonaux (variance), entre autre. On peut visualiser aisément cette topologie dans le cas des matrices  $2 \times 2$  ; on représente alors chacune de ces matrices comme un point dans l'espace Euclidien à trois dimension, où deux coordonnées correspondent aux deux variances (les deux éléments diagonaux) et la troisième à la covariance (les éléments hors-diagonal, qui sont égaux la matrice étant symétrique). Par construction, le point doit demeurer à l'intérieur du cône. Dès que le point touche le bord du cône, la matrice n'est plus SPD. Droite : La géodésique traversant deux points  $C_1$  et  $C_2$  sur la variété Riemannienne des matrices SPD est le chemin de longueur minimale qui les relie. La moyenne géométrique de ces deux points est le point à mi-chemin sur la géodésique, qui est en général très loin de la moyenne arithmétique  $\frac{1}{2}(C_1 + C_2)$ .

## 8.7. Bibliographie

- [ARV 11] ARVANEH M., GUAN C., ANG K., QUEK H., « Optimizing the Channel Selection and Classification Accuracy in EEG-based BCI », *IEEE Transactions on Biomedical Engineering*, vol. 58, p. 1865-1873, 2011.
- [BAR 12] BARACHANT A., BONNET S., CONGEDO M., JUTTEN C., « Multiclass brain-computer interface classification by Riemannian geometry », *Biomedical Engineering, IEEE Transactions on*, vol. 59, n° 4, p. 920-928, IEEE, 2012.
- [BRO 11] BRODU N., LOTTE F., LÉCUYER A., « Comparative study of band-power extraction techniques for motor imagery classification », *Proc. IEEE CCMB*, IEEE, p. 1-6, 2011.
- [BRO 12] BRODU N., LOTTE F., LÉCUYER A., « Exploring Two Novel Features for EEG-based Brain-Computer Interfaces : Multifractal Cumulants and Predictive Complexity », *Neurocomputing*, vol. 79, n° 1, p. 87-94, 2012.
- [CAR 14] CARAMIA N., LOTTE F., RAMAT S., « Optimizing spatial filter pairs for EEG classification based on phase synchronization », *Proc. ICASSP*, 2014.



**Figure 8.6.** Considérons une BCI à deux classes avec des matrices  $2 \times 2$ . Avec les données de calibration nous estimons la moyenne géométrique pour la classe 1 ( $\mu_1$ ) et pour la classe 2 ( $\mu_2$ ). En phase de test, un essai (C), représenté par une matrice SPD, est classifié en évaluant sa distance par rapport à chaque moyenne géométrique et étiqueté comme appartenant à la classe la plus proche. Le même processus est utilisé pour des matrices de n'importe quelle dimension et pour n'importe quel nombre de classes.

- [CON 06] CONGEDO M., LOTTE F., LÉCUYER A., « Classification of Movement Intention by Spatially Filtered Electromagnetic Inverse Solutions », *Physics in Medicine and Biology*, vol. 51, n° 8, p. 1971-1989, 2006.
- [CON 13] CONGEDO M., EEG Source Analysis, PhD thesis, HDR presented at Doctoral School EDISCE, University of Grenoble, 2013.
- [FAZ 12] FAZEL-REZAI R., ALLISON B., GUGER C., SELLERS E., KLEIH S., KÜBLER A., « P300 brain computer interface : current challenges and emerging trends », *Frontiers in Neuroengineering*, vol. 5, n° 14, 2012.
- [FRI 12] FRIEDRICH E., SCHERER R., NEUPER C., « The effect of distinct mental strategies on classification performance for brain-computer interfaces », *Int J Psychophys*, 2012.
- [GUY 03] GUYON I., ELISSEEFF A., « An introduction to variable and feature selection. », *Journal of Machine Learning Research*, vol. 3, p. 1157-1182, 2003.
- [HOF 06] HOFFMANN U., VESIN J., EBRAHIMI T., « Spatial filters for the classification of event-related potentials », *Proc. ESANN*, 2006.
- [KAC 08] KACHENOURA A., ALBERA L., SENHADJI L., COMON P., « ICA : A Potential Tool for BCI Systems », *IEEE Signal Processing Magazine*, vol. 25, n° 1, p. 57-68, 2008.
- [KRU 06] KRUSIENSKI D., SELLERS E., CABESTAING F., BAYOUDH S., MCFARLAND D., VAUGHAN T., WOLPAW J., « A comparison of classification techniques for the P300 Speller », *Journal of Neural Engineering*, vol. 3, p. 299-305, 2006.



- [LOT 11] LOTTE F., GUAN C., « Regularizing Common Spatial Patterns to Improve BCI Designs : Unified Theory and New Algorithms », *IEEE Transactions on Biomedical Engineering*, vol. 58, n° 2, p. 355-362, 2011.
- [MCF 97] MCFARLAND D. J., MCCANE L. M., DAVID S. V., WOLPAW J. R., « Spatial filter selection for EEG-based communication », *Electroencephalographic Clinical Neurophysiology*, vol. 103, n° 3, p. 386-394, 1997.
- [MÜH 14] MÜHL C., JEUNET C., LOTTE F., « EEG-based Workload Estimation Across Affective Contexts », *Frontiers in Neuroscience*, vol. 8, page 114, Frontiers, 2014.
- [OBE 01] OBERMEIER B., GUGER C., NEUPER C., PFURTSCHELLER G., « Hidden Markov models for online classification of single trial EEG », *Patt Rec Let*, p. 1299-1309, 2001.
- [PFU 01] PFURTSCHELLER G., NEUPER C., « Motor Imagery and Direct Brain-Computer Communication », *proceedings of the IEEE*, vol. 89, n° 7, p. 1123-1134, 2001.
- [RAM 00] RAMOSER H., MULLER-GERKING J., PFURTSCHELLER G., « Optimal spatial filtering of single trial EEG during imagined hand movement », *IEEE Transactions on Rehabilitation Engineering*, vol. 8, n° 4, p. 441-446, 2000.
- [RAU 91] RAUDYS S. J., JAIN A. K., « Small Sample Size Effects in Statistical Pattern Recognition : Recommendations for Practitioners », *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 13, n° 3, p. 252-264, 1991.
- [RIV 09] RIVET B., SOULOUMIAC A., ATTINA V., GIBERT G., « xDAWN Algorithm to Enhance Evoked Potentials : Application to Brain Computer Interface », *IEEE Transactions on Biomedical Engineering*, vol. 56, n° 8, p. 2035-2043, 2009.
- [SAM 14] SAMEK W., KAWANABE M., MULLER K., « Divergence-based framework for common spatial patterns algorithms », *IEEE Rev Biomed Eng*, IEEE, 2014.
- [SAN 10] SANNELLI C., DICKHAUS T., HALDER S., HAMMER E., MÜLLER K.-R., BLANKERTZ B., « On optimal channel configurations for SMR-based brain-computer interfaces », *Brain Topography*, 2010.
- [SCH 05] SCHRÖDER M., LAL T., HINTERBERGER T., BOGDAN M., HILL N., BIRBAUMER N., ROSENSTIEL W., SCHÖLKOPF B., « Robust EEG channel selection across subjects for brain-computer interfaces », *EURASIP J. Appl. Signal Process*, p. 3103-3112, 2005.
- [TAN 12] TANGERMANN M., MÜLLER K., AERTSEN A., BIRBAUMER N., BRAUN C., BRUNNER C., LEEB R., MEHRING C., MILLER K. J., MÜLLER-PUTZ G., NOLTE G., PFURTSCHELLER G., PREISSL H., SCHALK G., SCHLÖGL A., VIDAURRE C., WALDERT S., BLANKERTZ B., « Review of the BCI competition IV », *Front Neurosc*, 2012.
- [VIA 10] VIALATTE F., MAURICE M., DAUWELS J., CICHOCKI A., « Steady-State Visually Evoked Potentials : Focus on Essential Paradigms and Future Perspectives. », *Progress in Neurobiology*, vol. 90, p. 418-438, 2010.
- [VID 09] VIDAURRE C., KRÄMER N., BLANKERTZ B., SCHLÖGL A., « Time domain parameters as a feature for EEG-based brain computer interfaces », *Neural Networks*, vol. 22, p. 1313-1319, 2009.