
Sélection de capteurs pour interfaces cerveau-ordinateur de type P300

**Hubert Cecotti¹, Bertrand Rivet¹, Marco Congedo¹,
Christian Jutten¹, Olivier Bertrand², Emmanuel Maby²,
Jérémie Mattout²**

1. GIPSA-lab CNRS UMR 5216

Universités de Grenoble

F-38402 Saint Martin d'Hères, France

2. INSERM, U821, Lyon, F-69500, France

Institut Fédératif des Neurosciences, Lyon, F-69000, France

Université Lyon 1, Lyon, F-69000, France

RÉSUMÉ. Une interface cerveau-ordinateur (ICO) est un nouveau type d'interface homme-machine qui permet la communication directe entre l'utilisateur et la machine en décodant l'activité cérébrale. Les potentiels cognitifs évoqués comme le P300 peuvent être obtenus grâce au paradigme oddball – stimulus discordant – où les cibles sont sélectionnées par l'utilisateur. Une nouvelle méthode pour la réduction des capteurs des signaux électroencéphalographiques (EEG) est proposée. La réduction du nombre de capteurs permet d'accroître le confort de l'utilisateur en diminuant le temps nécessaire à la pose des capteurs. L'approche proposée est basée sur une élimination récursive des capteurs où la fonction de coût est basée sur une évaluation du rapport signal sur signal plus bruit (RSSB), après un filtrage spatial. Nous montrons que cette fonction de coût est plus robuste et moins coûteuse en temps de calcul que d'autres fonctions basées sur l'évaluation de la détection du P300 ou des cibles, permettant ainsi d'éviter une étape de classification. Nous proposons également une fonction de décision qui permet de mieux catégoriser l'importance d'un capteur en fonction du nombre de capteurs désirés. L'approche proposée est testée et validée sur 20 sujets au cours de plusieurs sessions.

ABSTRACT. A Brain-Computer Interface (BCI) is a new type of human-machine interface that allows direct communication between user and machine by decoding brain activity. The ERPs as the P300 can be obtained through the odd ball paradigm, where targets are selected by the user. A new method for reducing the number of sensors that record electroencephalography (EEG) signals is proposed. Reducing the number of sensors allows reducing the time required for the installation of sensors and therefore increases user's comfort. The proposed approach is based on a recursive elimination where the cost function is based on the signal to signal plus noise ratio (SSNR), after spatial filtering. We show that this cost function is more robust and less costly in computing time than other functions based on evaluation of the detection of P300 or targets, thus avoiding a step of classification. We also propose a decision function to better categorize the importance of a sensor based on the number of desired sensors. The proposed approach is tested and validated on 20 subjects over several sessions.

MOTS-CLÉS : interface cerveau-ordinateur, Potentiels cognitifs évoqués, P300, EEG, Clavier virtuel, sélection de capteurs.

KEYWORDS: Brain-Computer Interface (BCI), Evoked-Related Potentials, P300, EEG, Speller, Sensor Selection.

DOI:10.3166/TS.27.515-540 © 2010 Lavoisier, Paris

Extended Abstract

A Brain-Computer Interface (BCI) is a new type of human-computer interface that enables the direct communication between humans and computers through decoding of brain activity. BCI can be the only communication mean for people with motor disabilities so severe that they cannot communicate with their relatives. Patients with spinal cord injuries or amyotrophic lateral sclerosis (ALS), also called Lou Gehrig's disease, are the current best candidates for BCI. Event-related potentials (ERPs), like the P300, can be obtained with an oddball paradigm whose targets are selected by the user. In the P300 speller, the user can spell letters by paying attention to the letters the user wishes to spell. While such BCI can achieve relatively good performance, an important challenge is to bring this type of system outside of the laboratory to provide clinical/commercial applications. There exists a high need for some disabled people. The BCI field proposes many challenges in the signal processing and pattern recognition communities. Among these challenges, signal detection and feature selection are relevant topics for increasing the performance of BCI. Sensor selection is a particular case of feature selection, where different input features correspond to a sensor. Reducing the number of sensors is relevant and necessary step to bring BCI to a broader audience. A low number of sensors yields more comfort for the user, it may decrease installation time duration and it may also reduce the financial cost of the BCI product as the cost of an EEG cap and an amplifier depend on the number of channels. This study deals with methods that rank subsets of EEG sensors in the P300 speller application.

Several cost functions during sensor selection are proposed and evaluated: the signal to signal-plus-noise ration (signal processing level), the P300 detection (classification level), and the P300 speller accuracy (application level). The goal is to find a reliable cost function that translates the efficiency of the BCI system. These cost functions represent different stages for the detection of a character in the P300 speller. For the P300 detection, it corresponds to a binary classification where the input is a matrix containing the EEG signal corresponding to the recorded signal of different electrodes over a short time after the presentation of a visual stimulus. If the user pays attention to the target where the visual stimulus occurs, we expect to detect a P300 (class 1), otherwise we do not have a P300 (class 2). For the P300 speller, the classifier outputs corresponding to several visual stimuli are combined to determine accurately the target selected by the user. These cost functions are evaluated with and without spatial filtering. Our new approach to select relevant sensors is based on backward elimination using a cost function based on the signal to signal-plus-noise ratio (SSNR), after some spatial filtering. An algebraic model of the recorded signals is considered. It is composed of three terms: the P300 responses, a response common to all stimuli (on targets and non target) and the residual noise. Applied on the signal,

signal filters shall enhance the P300 responses. Spatial filters are obtained through the xDAWN algorithm. This method considers the Rayleigh quotient by maximizing the SSNR after two QR decompositions and a singular value decomposition. For both the classification of ERP and the cost function based on the P300 detection, we consider a Bayesian Linear Discriminant Analysis (BLDA) classifier, which considers an objective function for ridge regression as the exponent of a probability distribution from the exponential family. We validate our selection strategy on data from 20 healthy subjects. A session of 50 characters is dedicated to the sensor selection and classifier training. Three other sessions of 60 characters are considered for the evaluation of the different methods. The results indicate that the best strategies always consider spatial filters as pre-processing. We show that the cost function selects sensors subsets that provide a better accuracy in the speller recognition rate during the test sessions than selected subsets based on classification accuracy. The accuracy is equivalent or better than cost functions based on mining evaluations related to the P300 or the character recognition rate. The two best methods are based on the evaluation of the SSNR and the P300 recognition, showing that it is useless to take into account the speller stage. While the SSNR and the P300 recognition provide both equivalent results, both consider spatial filters based on the xDAWN algorithm. With only eight sensors, the speller accuracy is superior to 94 %. When we consider adaptive subsets, the average performance with eight sensors is equivalent to the whole set of 32 sensors. Considering the signal processing stage is therefore more efficient than the P300 detection and P300 speller stages. In addition, we present the best sensor locations, which are located at the parietal and occipital area. Across subjects, the five best sensors for the P300 speller are PZ, P8, OZ, P3 and P7. These sensor subsets are consistent with other studies that have evaluated predefined subsets of sensors.

Although the brain responses that we want to detect remains the same across subjects, we highlight the differences that can occur if the sensors are not directly set in relation to a particular individual. A sensor selection procedure for each individual is justified. Some persons would get a poor performance with a predefined set of sensors. Finally, a decision function is proposed to better analyze the rank of every sensor, given a desired number of sensors. This cost function is based on a sigmoid function and considers as input the rank of the sensors during backward elimination.

1. Introduction

Une interface cerveau-ordinateur (ICO) est un moyen de communication direct entre le cerveau d'un utilisateur et un ordinateur. Ce type d'interface permet la communication grâce à l'analyse directe et en ligne de mesures de l'activité cérébrale, sans aucune activité musculaire (Allison *et al.*, 2007). L'utilisation principale des ICO est pour les personnes handicapées qui ne sont pas capables de communiquer par des moyens plus conventionnels (clavier, souris...). Dans certains cas de paralysie, pour les patients atteints du syndrome d'enfermement, une ICO peut représenter le seul moyen de communication possible (Birbaumer *et al.*, 2007). Par conséquent, les ICO sont des systèmes prometteurs pour la restauration de la communication et d'une certaine autonomie pour certains patients (Cecotti *et al.*, 2009b ; Volosyak *et al.*, 2009).

Actuellement, un des défis majeurs est de réduire l'ensemble des capteurs qui mesurent l'activité cérébrale de façon adaptative, personnalisée à l'utilisateur. Réduire le nombre de capteurs permet d'améliorer le confort de l'utilisateur lorsque les capteurs ne sont pas invasifs, c'est-à-dire, lorsqu'ils sont placés sur la surface du scalp. En effet, avec moins de capteurs le temps de préparation du patient requiert moins de temps pour le personnel soignant. De plus, la réduction du nombre de capteurs permet de diminuer le coût d'un casque EEG (électroencéphalographique) et de l'amplificateur de signaux qui nécessitera moins de canaux. La réduction du nombre de capteurs peut aussi augmenter la durée d'utilisation des casque EEG sans fil (Shih *et al.*, 2009). Par ailleurs, avec un nombre limité de capteurs, il serait possible d'améliorer la détection du P300 en focalisant les observations uniquement sur les zones les plus pertinentes. La localisation des électrodes est sous-optimale car elle est soumise à des standards, comme le système international 10-20 (Chatrian *et al.*, 1985).

Les méthodes de traitement du signal et de reconnaissance de formes sont généralement utilisées dans les ICO pour la détection de signaux cérébraux particuliers. Parmi ces méthodes, les modèles basés sur un apprentissage ont prouvé leurs intérêts grâce à leurs robustesses (Blankertz *et al.*, 2006 ; Müller *et al.*, 2004 ; Müller *et al.*, 2008). En effet, ces méthodes permettent une adaptation à la variabilité du signal en cours du temps et entre les sujets. Ainsi, les réseaux de neurones (Anderson *et al.*, 1995 ; Cecotti *et al.*, 2010 ; Felzer *et al.*, 2003 ; Haselsteiner *et al.*, 2000 ; Masic *et al.*, 1993 ; Masic *et al.*, 1995), les machines à vecteurs de support (SVM) (Blankertz *et al.*, 2002 ; Rakotomamonjy *et al.*, 2008) ont notamment été utilisés dans des ICO pour la classification de signaux EEG. Pour ces méthodes, la sélection d'un ensemble de caractéristiques d'entrée peut être déterminante pour les performances de classification. En effet, la réduction du nombre de capteurs permet naturellement de diminuer le nombre de caractéristiques. La réduction du nombre de capteurs pourrait donc permettre à la fois d'augmenter les performances de classification, de s'adapter à l'utilisateur, et de réduire les coûts de fabrication et les difficultés d'utilisation d'une ICO.

Il est important de distinguer sélection de capteurs et sélection de caractéristiques. En effet, un capteur correspond le plus souvent à un ensemble de caractéristiques. C'est le cas en particulier dans une ICO où la réponse cérébrale à détecter correspond souvent à un tenseur dont l'une des dimensions représente le domaine spatial (les capteurs), et les autres dimensions peuvent représenter le signal dans le domaine temporel et/ou fréquentiel. Pour éviter toute confusion dans la suite de cet article, nous assimilons la notion de capteur à celle d'une source de signal, à la différence des capteurs dédiés à la référence et à la masse.

Plusieurs types de stratégies existent pour la sélection de capteurs. Il est possible de sélectionner les capteurs à partir de connaissance *a priori* du problème ou à partir d'expériences antérieures. Dans ce cas, l'ensemble prédéfini de capteurs est fixe et ne peut pas s'adapter en fonction de particularités individuelles. Cette stratégie peut mettre en péril les performances du système pour certains sujets qui nécessitent un ensemble de capteurs personnalisé (Hoffmann *et al.*, 2008). Pour N capteurs, il existe 2^N ensembles possibles de capteurs. Trois approches peuvent être considérées pour la recherche d'un ensemble de capteurs. Avec la recherche exhaustive, on compare les performances de tous les ensembles possibles. Cette approche n'est pas réalisable

car l'ensemble des capteurs à tester est trop important même pour un N petit ($N \approx 10$). Avec la recherche aléatoire, la méthode commence avec un ensemble aléatoire et génère de nouveaux ensembles, comme l'algorithme Las Vegas (*Algorithms and Theory of Computation Handbook*, 1999). Enfin, la dernière approche ne garantit pas l'optimalité de la sélection. Ces méthodes sont basées sur des approches gloutons et récursives d'ajout et/ou de suppression de capteurs. Par exemple, l'élimination récursive de caractéristiques a été utilisée dans les ICO basées sur de la reconnaissance d'imagerie motrice (Lal *et al.*, 2004 ; Schroder *et al.*, 2005).

Dans cet article, nous considérons l'élimination récursive de capteurs et nous proposons une fonction de coût efficace déterminant quel capteur doit être éliminé à chaque étape de l'algorithme, c'est-à-dire une fonction qui détermine au mieux la pertinence d'un ensemble de capteurs. La pertinence des capteurs sélectionnés est évaluée lors de l'évaluation de l'ICO, en l'occurrence un clavier virtuel P300.

Le reste de cet article suit le plan décrit ci-après. Le paradigme du clavier virtuel P300 (CV-P300) est décrit dans la section suivante. La stratégie de sélection de capteurs et les différentes fonctions de coûts pour l'évaluation des ensembles de capteurs sont décrites dans la troisième section. La section quatre est dédiée quant à elle au calcul des filtres spatiaux, à l'évaluation du rapport signal sur signal plus bruit (RSSB), et au classifieur permettant la détection du P300. Le protocole expérimental est présenté dans la cinquième section. Les résultats de la sélection de capteurs pour les différentes fonctions de coûts sont comparés et analysés dans les deux dernières sections.

2. Le clavier virtuel P300

Le CV-P300 permet à un utilisateur d'écrire des symboles sur un écran d'ordinateur. L'interface graphique de cette ICO représentée par une matrice contenant tous les symboles est affichée à l'écran (Farwell *et al.*, 1988 ; Donchin *et al.*, 2000). Dans les expériences, nous considérons une matrice de taille 6×6 , permettant d'afficher les 26 caractères de l'alphabet latin et quelques autres caractères (Farwell *et al.*, 1988). Pour écrire un symbole, l'utilisateur porte son attention sur le caractère que la personne veut épeler.

Les lignes et les colonnes de la matrice sont flashées alternativement et de façon aléatoire. La visualisation du flash sur le symbole observé par l'utilisateur entraîne un potentiel cognitif, le P300, qui correspond à une onde positive dans le signal EEG, environ 300 ms après le début du flash (Hansenne, 2000a ; Hansenne, 2000b ; Polich, 2007). Les stimulations visuelles sont regroupées par bloc de 12 flashes (un flash pour chaque ligne et colonne de la matrice). Ces 12 flashes sont répétés sur N_{rep} répétitions pour chaque caractères. Ainsi, le système doit détecter la présence de $2 \times N_{rep}$ réponses P300 lors de la saisie d'un caractère.

L'identification d'un caractère par le CV-P300 est effectuée en deux étapes successives. Tout d'abord, il faut identifier la présence d'une réponse P300 ou non à chaque flash dans le signal EEG. Cette étape correspond à une classification binaire (présence ou absence de P300). Ensuite, il faut combiner ces résultats de classification pour obtenir le caractère sélectionné. Le caractère sélectionné est défini par un couple ligne/colonne. On note $V \in \mathbb{R}^{12 \times N_{rep}}$ la matrice contenant les

probabilités accumulées de la détection du P300 pour chaque flash et pour chaque répétition :

$$V(i, j) = \sum_{k=1}^j E_{P300}(P(i, k)) \quad [1]$$

où $P(i, k) \in \mathbb{R}^{N_f \times N_e}$ est le signal d'entrée pour le flash i , à la répétition k , $(i, k) \in \{1, \dots, 12\} \times \{1, \dots, N_{rep}\}$. N_f et N_e représentent respectivement le nombre de capteurs virtuels et le nombre d'échantillons dans le signal à traiter. Enfin, $E_{P300}(\cdot)$ représente le classifieur retournant une valeur de confiance entre 0 et 1 (1 signifie que le P300 a été détecté parfaitement, 0 signifie qu'aucun P300 n'est détecté).

À chaque répétition j , on peut déterminer les coordonnées (x_j, y_j) du symbole sélectionné en cherchant la ligne et la colonne ayant la plus grande probabilité d'avoir engendré un P300 :

$$x_j = \operatorname{argmax}_{1 \leq i \leq 6} V(i, j) \quad [2]$$

$$y_j = \operatorname{argmax}_{7 \leq i \leq 12} V(i, j). \quad [3]$$


On note par $E_{CV}(\{P(1, N_{rep}), \dots, P(12, N_{rep})\}) = (row, column)$, le symbole sélectionné.

3. La sélection des capteurs

3.1. Élimination récursive

	1	2	3	4	5	6
7	A	B	C	D	E	F
8	G	H	I	J	K	L
9	M	N	O	P	Q	R
10	S	T	U	V	W	X
11	Y	Z	1	2	3	4
12	5	6	7	8	9	—

(a) Interface graphique du CV-P300



(b) Potentiel évoqué cognitif P300

Figure 1. CV-P300. Fig. 2 : écran, Fig. 1(b) : moyenne de la réponse P300 sur le capteur localisé en Cz

La méthode pour sélectionner de façon personnalisée un sous-ensemble de capteurs est basée sur l'élimination récursive. À partir de l'ensemble total des capteurs, la méthode consiste à tester pour chaque capteur s'il est pertinent de le

supprimer de l'ensemble courant des capteurs. Un capteur peu pertinent est un capteur dont l'absence dans l'ensemble courant des capteurs modifie très peu un certain critère. Dans la version de l'élimination récursive que nous considérons, nous éliminons deux capteurs à chaque itération. L'élimination des capteurs continue jusqu'à ce qu'il ne reste que deux capteurs, c'est-à-dire les deux capteurs les plus significatifs. En effet, un capteur peu important va être éliminé lors des premières itérations alors que les capteurs à conserver sont éliminés lors des dernières étapes. Nous définissons le rang d'un capteur, $R(s)$, par $N_s/2 - i$ où i est l'itération où le capteur a été éliminé, N_s étant le nombre de capteurs. Par conséquent, plus le rang d'un capteur est élevé, plus le capteur est pertinent et doit être conservé.

3.2. Évaluation des ensembles de capteurs

Pour les critères d'évaluation d'un ensemble de capteurs, on distingue les critères dépendant et indépendant. Les critères dépendants sont basés sur une mesure du taux de reconnaissance pour établir la pertinence d'un ensemble de capteurs donné. Les critères indépendants ne sont pas basés sur le sens donné aux capteurs. Par conséquent, il est naturel de penser qu'un critère dépendant basé sur l'objectif à atteindre (par exemple, une bonne reconnaissance des symboles dans le CV-P300) pourrait donner une meilleure estimation des capteurs à choisir. Cependant, une telle stratégie nécessite l'évaluation des différents capteurs et elle est souvent plus coûteuse en temps de calcul. Les critères indépendants sont basés sur des mesures simples de distances, de mesures de cohérences, de dépendances statistiques... (Abe *et al.*, 2006). Dans le CV-P300, l'évaluation des sous-ensembles de capteurs peut être effectuée à trois niveaux : (i) une mesure globale du signal EEG, comme le RSSB, (ii) le taux de détection du P300 (E_{P300}), c'est-à-dire la capacité à détecter chaque réponse P300 individuellement, et (iii) la performance du CV-P300 ($E_{CV-P300}$), c'est-à-dire le taux de bonne classification. Ces critères peuvent être comparés, en utilisant ou non un pré-traitement comme l'utilisation de filtres spatiaux (SF). Nous distinguons quatre critères/fonctions de coût. Elles sont présentées dans le paragraphe suivant.

3.3. Fonction de coût basée sur le RSSB

La première fonction de coût est basée sur le rapport signal sur signal plus bruit (RSSB). Nous considérons un modèle algébrique du signal enregistré X qui est composé de trois parties : la réponse cognitive associée au P300 (D_1A_1), la réponse cognitive associée à chaque flash (cible et non-cible) (D_2A_2) et le bruit résiduel (H).

$$X = D_1A_1 + D_2A_2 + H. \quad [4]$$

où $X \in \mathbb{R}^{N_t \times N_s}$, N_t et N_s sont respectivement le nombre d'échantillons temporels et le nombre de capteurs. $A_1 \in \mathbb{R}^{N_1 \times N_s}$ et $A_2 \in \mathbb{R}^{N_2 \times N_s}$ sont des matrices représentant les potentiels évoqués cognitifs. N_e^1 et N_e^2 sont respectivement le nombre d'échantillons décrivant la réponse P300 et la réponse survenant à chaque flash. Dans les sections suivantes, N_e^1 et N_e^2 correspondent à 0.6 seconde. D_1 et D_2 sont deux

matrices réelles de Toeplitz, respectivement de taille $N_t \times N_1$ et $N_t \times N_2$. D_1 est telle que les éléments de sa première colonne soient nuls exceptés ceux correspondant aux instants de stimulations des lignes et colonnes cibles, qui ont une valeur égale à 1. Pour D_2 , les éléments de la première colonne sont nuls sauf ceux correspondant au début de chaque stimulus. N_1 et N_2 sont respectivement le nombre d'échantillons temporels représentant la cible (la réponse P300) et la réponse commune à tous les flashes. H est une matrice réelle de taille $N_t \times N_s$.

Le RSSB est alors défini par :

$$\text{RSSB} = \frac{\text{Tr}(\widehat{A}_1^T D_1^T D_1 \widehat{A}_1)}{\text{Tr}(X^T X)} \quad [5]$$

où \widehat{A}_1 correspond à l'estimation des moindres carré de A_1

$$\widehat{A} = \begin{bmatrix} \widehat{A}_1 \\ \widehat{A}_2 \end{bmatrix} = ([D_1; D_2]^T [D_1; D_2])^{-1} [D_1; D_2]^T X \quad [6]$$

où $[D_1; D_2]$ est une matrice de taille $N_t \times (N_1 + N_2)$ composée de D_1 et D_2 .

3.4. Fonction de coût basée sur la puissance du signal

La puissance $\mathcal{P}(i)$ du P300 sur le i^{eme} capteur s_i est estimé par :

$$\mathcal{P}(i) = \frac{1}{N_t} \widehat{a}_1^T(i) D_1^T D_1 \widehat{a}_1(i) \quad [7]$$

où $1 \leq i \leq N_s$ et $\widehat{A}_1 = [\widehat{a}_1(i), \dots, \widehat{a}_1(N_s)]$. La puissance totale \mathcal{P} du P300 est définie par :

$$\mathcal{P} = \sum_{i=1}^{N_s} \mathcal{P}(i). \quad [8]$$

3.5. Fonction de coût basée sur la détection du P300

Nous définissons la fonction de coût basée sur la reconnaissance du P300, Acc_{P300} , comme la moyenne du taux de reconnaissance de classification du P300 pour les différents nombres de répétitions possibles, pour chaque flash et pour N_{symp} symboles. Le taux de reconnaissance du classifieur prend aussi en compte la détection des non P300. Un classifieur linéaire bayésien est utilisé pour la classification binaire des réponses P300 (Hoffmann *et al.*, 2008 ; MacKay, 1992). Ces critères représentent la stratégie classique qui est généralement utilisée dans la littérature où les capteurs sont supprimés dans le but de maximiser le taux de reconnaissance du classifieur (Schroder *et al.*, 2005).

3.6. Fonction de coût basée sur la performance du CV-P300

Enfin, la fonction de coût basée sur le taux de reconnaissance de caractère du CV-P300, Acc_{CV} , est basé sur les performances de l'application. Acc_{CV} est défini comme

le taux de reconnaissance moyen des caractères pour les différents nombres de répétitions possibles. Ce taux de reconnaissance n'est pas le taux de reconnaissance du CV-P300 à la dernière répétition, il tient compte des différentes répétitions. Au niveau de la complexité, notons que le calcul de Acc_{CV} requiert les principales étapes de calcul de Acc_{P300} .

4. Filtres spatiaux

En plus de la sélection de capteurs, il est possible de réduire le nombre de caractéristiques en déterminant des capteurs virtuels issus du filtrage spatial des capteurs initiaux. Ainsi, les fonctions de coûts définies dans les sections 3.3, 3.4, 3.5 et 3.6 peuvent être combinées avec l'utilisation de filtres spatiaux pour améliorer la qualité du signal. Les filtres spatiaux doivent permettre la mise en évidence des caractéristiques particulières du signal. De nombreuses méthodes existent dans la littérature pour la création de filtres spatiaux. On peut citer des approches assez simples utilisant des combinaisons bipolaires ou des Laplaciens pour supprimer le bruit commun à plusieurs capteurs (Müller-Putz *et al.*, 2005). Des filtres spatiaux adaptatifs utilisent l'analyse en composantes indépendantes (*Independent Component Analysis* (ICA)) (Xu *et al.*, 2004) ou des méthode statistiques comme *Common Spatial Pattern* (CSP) (Blankertz *et al.*, 2008 ; Brunner *et al.*, 2007 ; Tomioka *et al.*, 2006). Les filtres spatiaux peuvent être déterminés avec une approche générative comme la méthode de minimisation d'énergie (Friman *et al.*, 2007), ou avec une approche discriminante (Cecotti *et al.*, 2009a ; Cecotti *et al.*, 2010). Nous utilisons ici l'algorithme xDAWN pour créer les filtres spatiaux (Rivet *et al.*, 2008 ; Rivet *et al.*, 2009). La méthode considère deux hypothèses principales : il existe un potentiel évoqué synchronisé avec les flashes observés par l'utilisateur et ce potentiel peut être mis en valeur grâce à des filtres spatiaux.

Nous considérons les filtres spatiaux $U_1 \in \mathbb{R}^{N_s \times N_f}$ pour améliorer le RSSB de la réponse P300 ($D_1 A_1 U_1$), où N_f est le nombre de filtres spatiaux :

$$XU_1 = D_1 A_1 U_1 + D_2 A_2 U_1 + H U_1. \quad [9]$$

On définit le RSSB en fonction des filtres spatiaux par :

$$\text{RSSB}(U_1) = \frac{\text{Tr}(U_1^T \hat{A}_1^T D_1^T D_1 \hat{A}_1 U_1)}{\text{Tr}(U_1^T X^T X U_1)} \quad [10]$$

Le RSSB est maximisé par :

$$\hat{U}_1 = \text{argmax}_{U_1} \text{RSSB}(U_1). \quad [11]$$

La procédure pour calculer \hat{U}_1 et $\text{RSSB}(U_1)$ est la suivante. On remplace \hat{A}_1 par $B_1^T X$ où B_1^T est une partie de l'estimation des moindres carrés définie dans l'équation [6]. On applique alors une décomposition QR sur $D_1 = Q_1 R_1$ et $X = Q_x R_x$. On peut finalement exprimer l'équation [10] par :

$$\text{SSNR}(V_1) = \frac{\text{Tr}(V_1^T (Q_x^T B_1 R_1^T R_1 B_1^T Q_x) V_1)}{\text{Tr}(V_1^T V_1)}, \quad [12]$$

où $V_1 = R_x U_1$. V_1 est obtenu grâce au quotient de Rayleigh, qui correspond à la concaténation des N_f vecteurs propres associés aux N_f plus grandes valeurs propres de $Q_x^T B_1 R_1^T R_1 B_1^T Q_x$ (Golub *et al.*, 1996). Ces vecteurs sont estimés grâce à une SVD (*Singular Value Decomposition*) de $R_1 B_1^T Q_x = \Phi \Lambda \Psi^T$, Φ et Ψ étant deux matrices orthogonales, Λ est une matrice diagonales à valeurs positives ou nulles placées en ordre décroissant.

Après simplification, on obtient :

$$\text{SSNR}(V_1) = \frac{\text{Tr}(V_1^T (\Psi \Lambda^2 \Psi^T) V_1)}{\text{Tr}(V_1^T V_1)}. \quad [13]$$

De nouveau, on considère le quotient de Rayleigh pour V_1 dont la solution correspond aux N_f plus grandes valeurs propres de $\Psi \Lambda^2 \Psi^T$, c'est-à-dire Λ^2 . Notons que le dénominateur peut être réduit à la trace d'une matrice identité de taille $N_f \times N_f$, car Ψ et Q_x sont des matrices orthogonales. Le RSSB du signal pré-traité (après filtrage spatial), peut s'écrire :

$$\text{SSNR} = \text{Tr}(\Lambda^2) / N_f. \quad [14]$$

Enfin, la solution de l'équation [11] permet d'obtenir les filtres spatiaux qui sont ordonnés par ordre décroissant d'importance.

$$\widehat{U}_1 = R_x^{-1} \Psi. \quad [15]$$

Le signal après filtrage est finalement obtenu par :

$$\widehat{X} = X \widehat{U}_1. \quad [16]$$

La puissance du signal filtré est déterminé par :

$$PU = \frac{\text{Tr}(U_1^T \widehat{A}_1^T D_1^T D_1 \widehat{A}_1 U_1^T)}{N_t} \quad [17]$$

5. Protocole expérimental

5.1. Objectifs

Les objectifs des expériences sont d'évaluer et de comparer les différentes fonctions de coût qui ont été considérées pour l'élimination récursive des capteurs. Ces critères sont résumés dans le tableau 1. Les fonctions de coût définies dans les sections 3.3, 3.4, 3.5 et 3.6 sont utilisées sans ($C1$, $C2$, $C3$, $C4$) ou avec filtrage spatial (FS) ($C1_{FS}$, $C2_{FS}$, $C3_{FS}$, $C4_{FS}$). $C1$ et $C1_{FS}$ sont basés sur le RSSB. $C1$ et $C1_{FS}$ sont définies respectivement par les équations [5] et [14]. $C2$ et $C2_{FS}$ sont basés sur l'estimation de la puissance du signal définie dans les équations [8] et [17]. $C1_{FS}$ et $C2_{FS}$ étant équivalentes, nous utilisons uniquement $C1_{FS}$ dans les sections suivantes. $C3$ et $C3_{FS}$ sont basés sur Acc_{P300} défini dans la section 3.5. Enfin, $C4$

Tableau 1. Les différentes fonctions de coût pour l'élimination récursive

$C1$:			RSSB
$C2$:			Puissance
$C3$:			Acc_{P300}
$C4$:			Acc_{CV}
$C1_{FS}$:	FS	+	RSSB
$C2_{FS}$:	FS	+	Puissance
$C3_{FS}$:	FS	+	Acc_{P300}
$C4_{FS}$:	FS	+	Acc_{CV}

et $C4_{FS}$ sont basés sur Acc_{CV} défini dans la section 3.6. L'évaluation du CV-P300 au cours de plusieurs sessions doit permettre de déterminer la meilleure fonction de coût pour sélectionner les meilleurs sous-ensembles de capteurs à partir d'un nombre de capteurs désiré.

5.2. Acquisition des données et pré-traitement

Le signal EEG a été enregistré sur 20 sujets sains (13 hommes et 7 femmes) avec la plate-forme OpenViBE (Maby *et al.*, 2010). L'âge moyen des sujets est de 26 ans, avec une déviation standard de 5,7. Les sujets portaient un casque EEG de 32 capteurs (Chatrian *et al.*, 1985). L'activité EEG était enregistrée à partir de 32 électrodes actives (actiCap, Brain Products GmbH, Munich). Les électrodes pour la référence et la masse étaient placées respectivement sur le nez et le front. Pour tester les différents sous-ensembles de capteurs obtenus, nous considérons quatre sessions : la session d'apprentissage, contenant 50 caractères avec 10 répétitions et trois sessions de tests contenant 60 caractères avec 5, 8 et 10 répétitions. Le signal EEG est échantillonné à 100 Hz. Il est ensuite filtré entre 1 Hz et 12,5 Hz avec un filtre de Butterworth d'ordre 4. Le signal est ré-échantillonné à 25 Hz. Pour chaque capteur, le signal est normalisé pour obtenir une déviation standard égale à un.

5.3. Reconnaissance hors-ligne des symboles du CV-P300

Le CV-P300 est évalué avec différents sous-ensembles de capteurs obtenus grâce aux méthodes présentées dans la section précédente. Pour chaque ensemble de capteurs, le signal est filtré à l'aide des filtres spatiaux définis dans l'équation [15]. Le classifieur BLDA (MacKay, 1992), décrit dans la section 3.5, est utilisé pour la détection du P300. Nous considérons ici uniquement les quatre premiers capteurs virtuels lors de la classification (lorsque le nombre de capteurs est inférieur à 4, nous utilisons autant de capteurs virtuels que de capteurs). L'évaluation du CV-P300 permet de mesurer l'efficacité de la méthode de filtrage spatiale pour les ensembles de capteurs, de comparer les différentes fonctions de coûts, et de prouver l'intérêt de $C1_{FS}$ qui permet d'obtenir à la fois les filtres spatiaux et le RSSB.

6. Résultats

6.1. Performance du CV-P300

La figure 2 représente le taux de reconnaissance du CV-P300 pour la session de test $n^{\circ}3$ avec 10 répétitions, pour chaque méthode d'évaluation de capteurs et pour différents nombres de capteurs (de 2 à 32). Les méthodes de sélection de capteurs qui n'utilisent pas de filtres spatiaux donnent les moins bons résultats : entre 66.42 % ($C4$) et 89.58 % ($C1$) pour un ensemble de 8 capteurs. Avec 8 capteurs, le taux de reconnaissance moyen du CV-P300 est de 94.92 %, 94.00 % et 93.00 %, respectivement pour les méthodes $C1_{FS}$, $C3_{FS}$ et $C4_{FS}$. Ces résultats montrent qu'il est possible de réduire le nombre de capteurs de 32 à 8 sans trop diminuer les performances. En effet, le taux de reconnaissance le plus élevé est obtenu avec 32 capteurs, où il atteint 95.83 % de reconnaissance.

L'un des aspects les plus significatifs est l'importance des filtres spatiaux pour la sélection de capteurs. En effet, lorsque l'on réduit le nombre de capteurs à 8, les filtres spatiaux améliorent la reconnaissance du CV-P300 par 5.34 %, 11.25 % et 26.58 %, respectivement pour $C1_{FS}$, $C3_{FS}$ et $C4_{FS}$. Ces résultats justifient l'utilisation des filtres spatiaux estimés par l'algorithme xDAWN.

Au niveau du choix de la fonction de coût, $C1_{FS}$ est suffisant pour créer des ensembles de capteurs pertinents pour un CV-P300. La différence de performance entre $C1_{FS}$ et $C3_{FS}$ est faible. Cette différence n'étant pas significative, il n'est pas possible de déterminer la meilleure méthode en termes de performance.

Cependant, la complexité de la méthode (temps de calcul) est moindre avec $C1_{FS}$. Ce critère basé sur le RSSB après filtrage spatial ($C1_{FS}$) s'effectue en une étape grâce à l'algorithme xDAWN. En effet pour obtenir les filtres spatiaux, il faut maximiser le RSSB. Par conséquent, l'obtention des filtres spatiaux fournit aussi le RSSB. Cette solution permet donc d'éviter des étapes de classifications supplémentaires comme Acc_{P300} ($C3_{FS}$) ou Acc_{CV} ($C4_{FS}$).

La fonction basée sur le taux de reconnaissance des symboles du CV-P300 ($C4_{FS}$) donne les moins bons résultats. Ces résultats peuvent s'expliquer par le faible nombre de symboles qui est pris en compte pour déterminer la pertinence d'un sous-ensemble. Une autre raison pourrait être l'utilisation de l'intersection des lignes et des colonnes pour déterminer les performances, ignorant ainsi les performances individuelles du classifieur (le système peut reconnaître correctement la ligne ou la colonne mais pas les deux en même temps).

Le taux de reconnaissance du CV-P300 en fonction du nombre de répétitions est présenté dans la figure 3. Plus le nombre de répétitions est élevé, plus le taux de reconnaissance est élevé. Notons que le taux de reconnaissance demeure acceptable avec au moins 5 répétitions. Les meilleures performances sont obtenues avec $C1_{FS}$ et $C3_{FS}$ avec respectivement 87.08 % et 87.75 % avec seulement 5 répétitions.

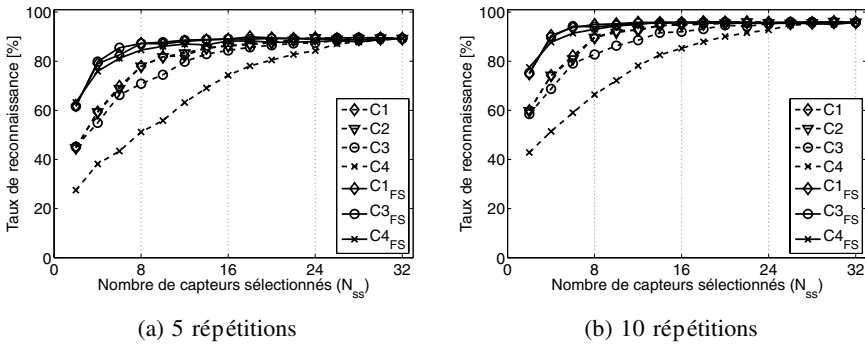


Figure 2. Taux de reconnaissance du CV-P300 en fonction du nombre de capteurs sélectionnés




Figure 3. Taux de reconnaissance du CV-P300 en fonction de nombre de répétitions, avec 8 capteurs

6.2. Impact des filtres spatiaux

L'évolution de chaque fonction de coût définie dans la section 3.2 en fonction du nombre de capteurs sélectionnés est présentée dans la figure 4. Pour la figure 4(a), la performance de classification est calculée grâce aux fonctions définies dans les sections 3.5 et 3.6, respectivement pour les fonctions de coût ($C3$, $C3_{FS}$) et ($C4$, $C4_{FS}$). Comme prévu, les fonctions de coût décroissent lorsque le nombre de capteurs présents pour $C3_{FS}$ et $C4_{FS}$ augmente. Par ailleurs, les valeurs de $C3_{FS}$ sont toujours inférieures à $C4_{FS}$, soulignant la difficulté d'atteindre de hautes performances pour la reconnaissance du P300. Avec des filtres spatiaux en guise de pré-traitement, la réduction du nombre de caractéristiques permet d'augmenter le taux de reconnaissance en évitant un sur-apprentissage. Dans la figure 4(b), l'évolution des valeurs pour $C1$ et $C1_{FS}$ diminue en fonction du nombre de capteurs restant durant l'élimination récursive. Par ailleurs, ces observations montrent que le filtrage spatial permet de réduire l'influence du bruit en gardant un RSSB élevé tout en diminuant le nombre de capteurs. L'impact des filtres spatiaux est plus grand

lorsque le nombre de capteurs est petit (inférieur à 8). En effet, la différence entre $C1$ et $C1_{FS}$ est important dans ces conditions. Avec la méthode de sélection utilisée avec $C1$, les capteurs avec les RSSB les plus faibles sont supprimés à chaque itération. Cette stratégie glouton qui se concentre sur le RSSB de chaque capteur n'est pas optimale. Par ailleurs, les performances $C1$ et $C2$ sont quasiment équivalentes.

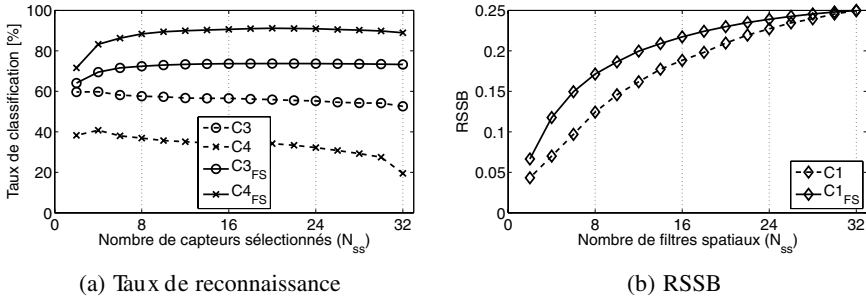


Figure 4. Evolution des différentes fonction de coût en relation du nombre de capteurs sélectionnés

6.3. Reconnaissance du CV au cours des sessions

Nous présentons à la figure 5 le taux de reconnaissance pour les trois sessions en fonction du nombre de capteurs sélectionnés. L'objectif est de vérifier si la performance du CV-P300 reste stable au cours des sessions. Dans la colonne de gauche, le nombre de répétitions est différent pour chaque session. La différence entre 8 et 10 répétitions est relativement faible. Lorsque l'on utilise uniquement 5 répétitions, on observe une diminution des performances du CV-P300. Ainsi, le taux de reconnaissance entre 10 et 5 répétitions diminue en moyenne de 7.42 %. Dans la colonne de droite, nous limitons l'évaluation à 5 répétitions pour évaluer la stabilité de la méthode au cours des sessions. Pour $C1_{FS}$ et $C3_{FS}$, la performance est stable entre les trois sessions. Cependant, on observe d'avantage de différences avec $C4_{FS}$. Ces différences montrent que le critère basé sur la performance du CV-P300 est moins robuste au cours du temps.

6.4. Analyse du choix des capteurs

Pour une meilleure compréhension de la sélection de capteurs et de leur impact en fonction des sujets, nous proposons d'évaluer les différences et les similarités des sous-ensembles de capteurs déterminés pour chaque sujet. La figure 6 illustre les différences entre sujets. Cette figure contient la moyenne du rang des capteurs de chaque sujet (a). Nous définissons une fonction binaire de classement $R_b(s)$ qui est égale à 1 si le capteur est sélectionné et 0 sinon. La moyenne, la déviation standard (D.S.) de R_b pour les 20 sujets avec un sous-ensemble de 8 capteurs sont présentés figure 6, respectivement dans les colonnes (b), (c). La première colonne représente la

moyenne pour tous les sujets et sous-ensembles de capteurs. La sélection moyenne des capteurs est très similaire entre les méthodes $C1_{FS}$ et $C3_{FS}$, comme déjà observé avec une nette sélection des capteurs localisés en P_z , O_z , et P_8 . Cette observation se retrouve avec la fonction R_b , colonne (b), qui se limite à la moyenne entre les sujets pour les sous-ensembles de capteurs de taille 8. P_z , O_z et P_8 sont sélectionnés comme étant les trois capteurs communs aux méthodes $C1_{FS}$ et $C3_{FS}$. En effet, P_z , O_z et P_8 sont sélectionnés 14, 13 et 14 fois avec $C1_{FS}$ pour les 20 sujets. Pour $C4_{FS}$, la localisation idéale des capteurs est plus difficile à déterminer. Pour $C1_{FS}$ et $C3_{FS}$, la D.S. est faible sur la partie frontale, ces capteurs ne sont pratiquement jamais sélectionnés. Sur la partie occipitale et pariétale, la D.S. est plus élevée.




Figure 5. Reconnaissance du CV-P300 pour les différentes sessions de test. La fonction de coût est $C1_{FS}$ pour (a,b), $C3_{FS}$ pour (c,d) et $C4_{FS}$ pour (e,f)

Dans la section 3.1, la définition du rang des capteurs permet d'obtenir une valeur entre 1 et $N_s/2$. Nous proposons d'introduire une nouvelle fonction de classement qui retranscrit mieux l'importance d'un capteur en fonction du nombre désiré de capteurs. Cette fonction permet de renseigner si un capteur s doit être sélectionné ou non.

On définit ainsi la fonction de classement $R_1(s)$:

$$R_1(s) = \frac{1}{2} \left(\tanh \left(\frac{1 + R(s) - (N_s - N_{ds})/2}{\sigma_s} \right) + 1 \right) \quad [18]$$

où N_s est le nombre total de capteur et N_{ds} représente le nombre de capteurs désirés. σ_s est une constante permettant de lisser la décision des capteurs à sélectionner. Si $R_1(s)$ est proche de 1 alors s est un capteur significatif. Inversement, si la valeur de $R_1(s)$ est proche de 0, s n'est pas important. Notons que l'on considère $(N_s - N_{ds})/2$ car on enlève deux capteurs à chaque étape de l'élimination récursive des capteurs. La figure 7 représente la fonction de classement R_1 en fonction de la fonction R avec différents choix de paramètres.

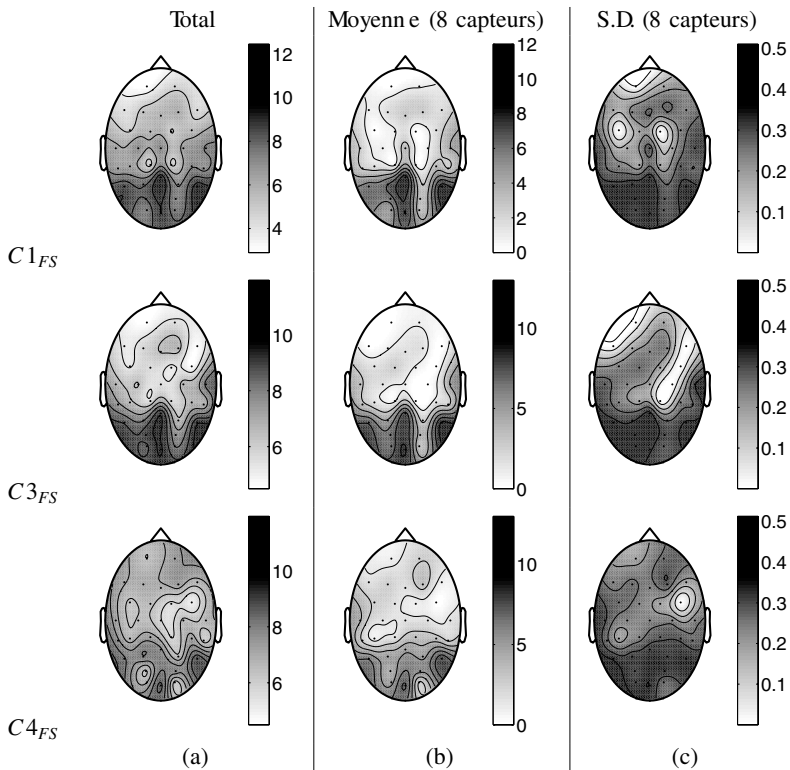


Figure 6. Pertinence de chaque capteur. Un gris foncé signifie l'importance des capteurs et leur sélection fréquenté parmi les 8 meilleurs capteurs. Inversement, un gris clair dénote une faible importance du capteur

La figure 8 présente pour trois sujets la fonction de classement R_1 où $N_{ds} = 8$, pour la sélection de 8 capteurs, et $\sigma_s = 4$. Cette figure présente également la forme d'onde moyenne du P300 associé à chaque capteur (l'onde commence 0.6s après un flash cible). Les formes d'onde du P300 sont estimées grâce à \hat{A}_1 . Ces résultats mettent en évidence les différences entre sujets qui se traduisent par des différences dans le choix des sous-ensembles de capteurs.

Le tableau 2 présente les 8 meilleurs capteurs pour $C1_{FS}$, $C3_{FS}$ et $C4_{FS}$. Chaque cellule du tableau représente la position du capteur sur le scalp dans le système 10-20 et la fréquence d'apparition comme l'un des 8 meilleurs capteurs pour les 20

sujets. Les 8 meilleurs capteurs des méthodes $C1_{FS}$ et $C3_{FS}$ sont presque identiques. La seule différence est CP_6 pour $C1_{FS}$ et T_8 pour $C3_{FS}$. Notons cependant que ces deux capteurs sont très proches l'un de l'autre. Les méthodes $C1_{FS}$ et $C3_{FS}$ convergent sur des ensembles de capteurs très proches, ce qui explique leurs performances très proches.




Figure 7. Fonction de classement des capteurs ($R1$) en fonction de R . N_{ds} représente le nombre de capteurs désiré

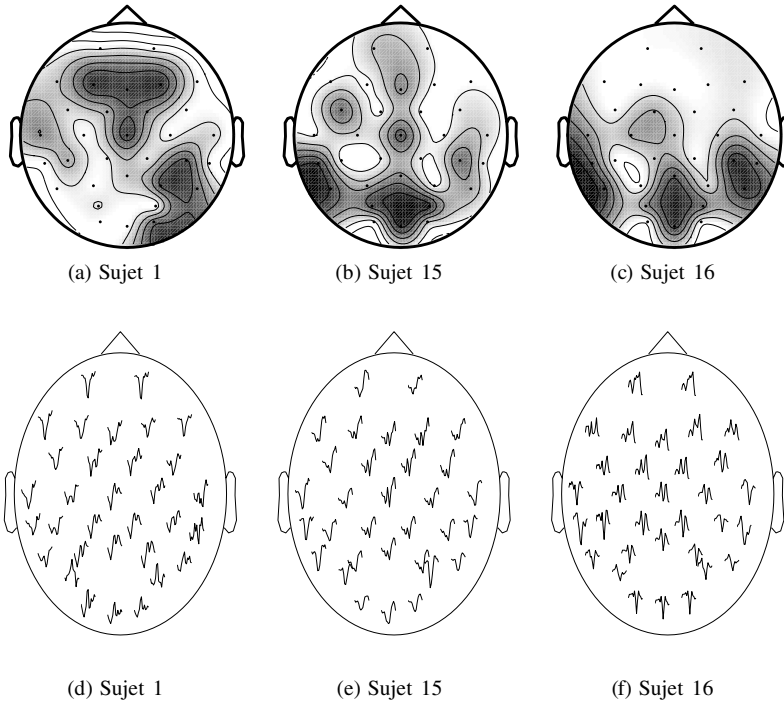


Figure 8. Rang de chaque capteur (a), (b) et (c) ; réponse P300 pour chaque capteur, basée sur l'estimation de \hat{A}_1 (d), (e) et (f)

Tableau 2. Top 8 des capteurs pour $C1_{FS}$, $C3_{FS}$, et $C4_{FS}$. Chaque cellule représente la position d'une électrode dans le système international EEG 10-20, et le nombre de fois où l'électrode a été sélectionnée comme l'un des 8 meilleurs capteurs pour les 20 sujets

Rang	1	2	3	4	5	6	7	8
$C1_{FS}$	P_Z ; 14	P_8 ; 14	O_Z ; 13	P_3 ; 11	P_7 ; 10	PO_9 ; 9	O_1 ; 9	CP_6 ; 7
$C3_{FS}$	O_Z ; 15	P_Z ; 14	P_8 ; 14	P_7 ; 12	O_1 ; 12	PO_9 ; 10	T_8 ; 9	P_3 ; 9
$C4_{FS}$	P_8 ; 13	O_Z ; 11	P_7 ; 9	P_Z ; 8	F_4 ; 7	P_3 ; 7	P_4 ; 7	PO_{10} ; 7




Figure 9. Impact de la sélection adaptative de la sélection de capteurs (session 3, 10 répétitions) pour la méthode $C1_{FS}$

Pour chaque sujet, une comparaison de la performance du CV-P300 est effectuée entre l'ensemble commun à tous les sujets des 8 meilleurs capteurs (commun), les 8 meilleurs capteurs pour chaque sujet (individuel), et l'ensemble total des 32 capteurs (tout) dans la figure 9. Ces résultats correspondent au taux de reconnaissance du CV-P300 sur la session 3, avec 10 répétitions. La sélection adaptative permet d'obtenir en général les meilleurs résultats. C'est particulièrement le cas pour les sujets 1, 6 et 12. La sélection de capteurs personnalisée est essentielle pour le sujet 1 car les performances sont alors largement améliorées. Pour plusieurs sujets (2, 3, 4, 13, 14), le taux de reconnaissance est quasi identique pour les 3 ensembles de capteurs. Naturellement, l'utilisation de tous les capteurs permet d'obtenir les meilleurs résultats en moyenne, mais dans le cadre d'un système utilisant peu d'électrodes, ces résultats justifient l'utilisation d'une méthode adaptative.

7. Discussion

Bien que le problème de la sélection de caractéristiques soit un problème largement discuté dans la littérature, le problème de sélection de capteurs dans les ICO et plus particulièrement pour les CV-P300 n'a pas été exploré complètement. En effet, l'approche classique pour déterminer les ensembles de capteurs était d'utiliser des ensembles prédéfinis comme dans (Krusienski *et al.*, 2008) où quatre ensembles de capteurs étaient analysés et comparés. Contrairement à ce type d'approche, la

méthode proposée permet de déterminer des ensembles de capteurs sans *a priori* sur leurs positions. Cette stratégie pourrait donc être utilisée pour d'autres ICO. De plus, un avantage certain de la méthode $C1_{FS}$ est de ne pas nécessiter de classifieur. Les expériences sur 20 sujets ont montré qu'il est possible d'obtenir des performances acceptables pour une application en ligne avec uniquement 8 capteurs, avec un taux de reconnaissance d'environ 94 % avec 10 répétitions.

L'analyse du choix des capteurs pour la fonction de coût $C1_{FS}$ (RSSB avec filtres spatiaux) a démontré que plusieurs capteurs sont communs à tous les sujets. Pour les différents sous-ensembles de 8 capteurs qui sont personnalisés pour chaque sujet, 5 capteurs sont communs à la moitié des sujets (P_z, P_8, O_z, P_3, P_7). Ces capteurs sont la partie pariétale, à la fois au centre (P_z) et sur les côtés (P_8 et P_7). Un capteur est localisé sur la partie occipitale (O_z). Ces capteurs sont conformes à d'autres études du CV-P300 où la sélection de capteurs était *a priori* (Krusiński *et al.*, 2008) ou lors de l'apprentissage du classifieur (Cecotti *et al.*, 2010).

Les résultats décrits dans la section 6.3 mettent en évidence la robustesse des capteurs au cours du temps. En effet, dans une application clinique et commerciale, une chute des performances entre deux sessions serait un problème critique pour la fiabilité de l'ICO. La variation entre les sujets pourraient être un désavantage pour la réalisation d'un casque EEG avec un positionnement et un nombre limité de capteurs même si pour un casque spécialisé pour le P300, il serait judicieux de placer une majorité des capteurs sur la partie occipitale et pariétale en particulier P_z, P_8, P_7 et O_z . Un casque avec un nombre limité de capteurs devrait idéalement autoriser le déplacement de ces capteurs. La procédure d'élimination récursive des capteurs se termine lorsqu'il ne reste plus de capteurs à éliminer.

Une sélection des capteurs adaptées pour chaque sujet est cependant nécessaire pour obtenir des performances optimales avec un nombre réduit de capteurs. Lorsque l'on considère des ensembles de capteurs adaptatifs, la performance moyenne avec huit capteurs est équivalente à celle avec 32 capteurs. Il serait également possible de diminuer le nombre de capteurs jusqu'à 4 tout en gardant des performances acceptables (supérieure à 80 %).

Pour la sélection de capteurs, plusieurs contributions ont été proposées. Tout d'abord, il est observé qu'il est contre-performant d'utiliser l'étape de reconnaissance des symboles lors de l'évaluation des sous-ensembles de capteurs. De plus, il est également possible de s'affranchir d'un classifieur pour la détection du P300 comme critère d'évaluation. Un critère basé sur la détection du P300 permet d'obtenir des sous-ensembles de capteurs pertinents, cependant l'évaluation du RSSB est suffisante. L'utilisation du RSSB qui est totalement indépendante du problème montre que la technique proposée peut être étendue à d'autres paradigmes d'ICO, comme pour de l'imagerie motrice.

8. Conclusion

Plusieurs fonctions de coût pour l'évaluation d'un ensemble de capteurs pour une ICO de type P300 ont été évaluées et comparées. Ces fonctions étaient définies suivant différents niveaux d'analyse : l'application avec le taux de reconnaissance du

CV-P300, le classifieur avec le taux de reconnaissance du P300, et l'aspect traitement du signal avec l'évaluation du RSSB. Les résultats ont clairement indiqué que les meilleures stratégies considèrent toujours l'utilisation de filtres spatiaux comme pré-traitement. Les deux meilleures fonctions de coûts sont basées sur l'évaluation du SSNR et la reconnaissance du P300, montrant l'inutilité de baser la fonction de coût sur les résultats finaux de l'application. Alors que l'utilisation du RSSB et de la reconnaissance du P300 procurent des résultats quasi équivalents après filtrage spatial, il faut noter que l'évaluation du RSSB se traduit directement après l'évaluation de filtres spatiaux. Par conséquent, l'étape supplémentaire de classification du P300 est facultative pour l'évaluation d'un ensemble de capteur. L'évaluation du RSSB permet d'obtenir à la fois des ensembles de capteurs pertinents mais aussi de diminuer le temps de calcul lors de l'élimination récursive des capteurs.

Remerciements

Nous remercions les ANR du programme TecSan (projet RoBIK ANR-09-TECS-013) et du programme DEFIS (projet Co-Adapt ANR-09-EMER-002) pour leur aide au financement de ce projet.

Bibliographie

Algorithms and Theory of Computation Handbook, CRC Press LLC, 1999.

Abe N., Kudo M., Toyama J., Shimbo M. (2006), « Classifier-independent feature selection on the basis of divergence criterion », *Pattern Anal. Appl.*, vol. 9, n° 2, p. 127-137.

Allison B. Z., Wolpaw E. W., Wolpaw J. R. (2007), « Brain-computer interface systems: progress and prospects », *Expert Review of Medical Devices*, vol. 4, n° 4, p. 463-474.

Anderson C. W., Devulapalli S. V., Stolz E. A. (1995), « Determining Mental State from EEG Signals Using Parallel Implementations of Neural Networks », *IEEE Workshop on Neural Networks for Signal in Processing*, Cambridge, MA, USA, p. 475-483.

Birbaumer N., Cohen L. G. (2007), « Brain-computer interfaces: communication and restoration of movement in paralysis », *Journal of Physiology-London*, vol. 579, n° 3, p. 621-636.

Blankertz B., Curio G., Müller K.-R. (2002), « Classifying single trial EEG: Towards brain computer interfacing », In T. G. Diettrich, S. Becker, and Z. Ghahramani, editors, *Advances in Neural Inf. Proc. Systems (NIPS 01)*, vol. 14, p. 157-164.

Blankertz B., Dornhege G., Lemm S., Krauledat M., Curio G., Müller K.-R. (2006), « The Berlin brain-computer interface: EEG-based communication without subject training », *IEEE Trans. on Neural Systems and Rehabilitation Engineering*, vol. 14, n° 2, p. 147-152.

Blankertz B., Kawanabe M., Tomioka R., Hohlefeld F., Nikulin V., Müller K.-R. (2008), « Invariant Common Spatial Patterns: Alleviating Nonstationarities in Brain-Computer Interfacing », *Advances in Neural Information Processing Systems*.


Brunner C., Naehm M., Leeb R., Graimann B., Pfurtscheller G. (2007), « Spatial filtering and selection of optimized components in four class motor imagery EEG data using independent components analysis », *Pattern Recognition Letters*, vol. 28, n° 8, p. 957-964.

- Cecotti H., Gräser A. (2009a), « Neural network pruning for feature selection – Application to a P300 Brain-Computer Interface », *European Symposium on Artificial Neural Networks*, p. 473-478.
- Cecotti H., Gräser A. (2010), « Convolutional neural networks for P300 Detection with Application to Brain-Computer Interfaces », *IEEE Trans. Pattern Analysis and Machine Intelligence*.
- Cecotti H., Volosyak I., Gräser A. (2009b), « Evaluation of an SSVEP based Brain-Computer Interface on the command and application levels », *4th IEEE EMBS International Conference on Neural Engineering*.
- Chatrian G. E., Lettich E., Nelson P. L. (1985), « Ten percent electrode system for topographic studies of spontaneous and evoked EEG activity », *Am J EEG Technol.*, vol. 25, p. 83-92.
- Donchin E., Spencer K. M., Wijesinghe R. (2000), « Assessing the speed of a P300-based brain-computer interface », *IEEE Trans. Neural Sys. Rehab. Eng.*, vol. 8, n° 2, p. 174-179.
- Farwell L., Donchin E. (1988), « Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials », *Electroencephalogr. Clin. Neurophysiol.*, vol. 70, p. 510-523.
- Felzer T., Freisieben B. (2003), « Analyzing EEG signals using the probability estimating guarded neural classifier », *IEEE Trans. on Neural Systems and Rehab. Eng.*
- Friman O., Volosyak I., Gräser A. (2007), « Multiple channel detection of steady-state visual evoked potentials for brain-computer interfaces », *IEEE Trans. Biomed. Eng.*, vol. 54, n° 4, p. 742-750.
- Golub G. H., Van Loan C. F. (1996), *Matrix Computations*, 3rd ed. Johns Hopkins University Press.
- Hansenne M. (2000a), « Le potentiel évoqué cognitif P300 (I) : aspects théorique et psychobiologique », *Neurophysiol Clin*, vol. 30, p. 191-210.
- Hansenne M. (2000b), « Le potentiel évoqué cognitif P300 (II) : variabilité interindividuelle et application clinique en psychopathologie », *Neurophysiol Clin*, vol. 30, p. 211-231.
- Haselsteiner E., Pfurtscheller G. (2000), « Using time dependent neural networks for EEG classification », *IEEE Trans. Rehab. Eng.*, vol. 8, n° 4, p. 457-463.
- Hoffmann U., Vesin J. M., Diserens K., Ebrahimi T. (2008), « An efficient P300-based brain-computer interface for disabled subjects », *Journal of Neuroscience Methods*, vol. 167, n° 1, p. 115-125.
- Krusienski D. J., Sellers E. W., McFarland D., Vaughan T. M., Wolpaw J. R. (2008), « Toward Enhanced P300 Speller Performance », *Journal of Neuroscience Methods*, vol. 167, p. 15-21.
- Lal T. N., Schroder M., Hinterberger T., Weston J., Bogdan M., Birbaumer N., Scholkopf B. (2004), « Support vector channel selection in BCI », *IEEE Trans. Biomed. Engineering*, vol. 51, n° 6, p. 1003-1010.
- Maby E., Gibert G., Aguera P.-E., Perrin M., Bertrand O., Mattout J. (2010), « The Open-ViBE P300-Speller scenario: a thorough online evaluation », *In Human Brain Mapping Conference*.
- MacKay D. J. C. (1992), « Bayesian interpolation », *Neural Comput.*, vol. 4, n° 3, p. 415-447.
- Masic N., Pfurtscheller G. (1993), « Neural network based classification of single-trial EEG data », *Artificial Intelligence in Medicine*, vol. 5, n° 6, p. 503-513.

- Masic N., Pfurtscheller G., Flotzinger D. (1995), « Neural network-based predictions of hand movements using simulated and real EEG data », *Neurocomputing*, vol. 7, n° 3, p. 259-274.
- Müller K.-R., Krauledat M., Dornhege G., Curio G., Blankertz B. (2004), « Machine learning techniques for brain-computer interfaces », *Biomed Tech*, vol. 49, n° 1, p. 11-22.
- Müller K.-R., Tangermann M., Dornhege G., Krauledat M., Curio G., Blankertz B. (2008), « Machine learning for real-time single-trial EEG-analysis: From brain-computer interfacing to mental state monitoring », *J Neurosci Methods*, vol. 167, n° 1, p. 82-90.
- Müller-Putz G. R., Scherer R., Brauneis C., Pfurtscheller G. (2005), « Steady-state visual evoked potential (SSVEP)-based communication: impact of harmonic frequency components », *Journal of Neural Engineering*, vol. 2, n° 1, p. 123-130.
- Polich J. (2007), « Updating P300: An integrative theory of P3a and P3b », *Clinical Neurophysiology*, vol. 118, p. 2128-2148.
- Rakotomamonjy A., Guigue V. (2008), « BCI Competition III: Dataset II – Ensemble of SVMs for BCI P300 speller », *IEEE Trans. Biomedical Engineering*, vol. 55, n° 3, p. 1147-1154.
- Rivet B., Souloumiac A., Attina V., Gibert G. (2009), « xDAWN algorithm to enhance evoked potentials: application to brain-computer interface », *IEEE Trans Biomed Eng.*
- Rivet B., Souloumiac A., Gibert G., Attina V. (2008), « P300 speller Brain-Computer Interface: Enhancement of P300 evoked potential by spatial filters », *In Proc. EU-SIPCO*.
- Schroder M., Lal T. N., Hinterberger T., Bogdan M., N. Jeremy Hill J. N., Birbaumer N., Rosenstiel W., Schoolkopf B. (2005), « Robust EEG Channel Selection across Subjects for Brain-Computer Interfaces », *EURASIP Journal on Applied Signal Processing*, vol. 19, p. 3103-3112.
- Shih E. I., Shoeb A. H., Gutttag J. V. (2009), « Sensor selection for energy-efficient ambulatory medical monitoring », *In Proc. of the 7th International Conference on Mobile Systems, Applications and Services*, p. 347-358.
- Tomioka R., Hill N. J., Blankertz B., Aihara K. (2006), « Adapting Spatial Filter Methods for Nonstationary BCIs », *Workshop on Information-Based Induction Sciences (IBIS)*, 6.
- Volosyak I., Cecotti H., Valbuena D., Gräser A. (2009), « Evaluation of the Bremen SSVEP based BCI in real world conditions », *11th International IEEE Conference on Rehabilitation Robotics*, p. 322-331.
- Xu N., Gao X., Hong B., Miao X., Gao S., Yang F. (2004), « BCI Competition 2003–Data set IIb: enhancing P300 wave detection using ICA-based subspace projections for BCI applications », *IEEE Trans Biomed Eng*, vol. 51, n° 6, p. 1067-1072.

Article reçu le 20/09/2010

Accepté le 14/03/2011



Hubert Cecotti est docteur en informatique de l'université Nancy 2 (2005). Il est ensuite enseignant en informatique dans les universités de Nancy, France. En 2008 et 2009, il est chercheur post-doc (Marie-Curie Fellow) dans le projet européen Brainrobot, à l'Institut d'automatisme de l'université de Brême en Allemagne. En 2010, il est chercheur post-doc CNRS dans le projet ANR RoBIK au Gipsa-lab à Grenoble, France. Il est actuellement chercheur post-doc à l'université de Californie, à Santa-Barbara aux États-Unis. Ses problématiques de recherche comprennent l'apprentissage statistique, les réseaux de neurones, la reconnaissance de l'écriture et les interfaces cerveau-ordinateur.

Bertrand Rivet effectue ses études à l'École normale supérieure de Cachan (France) au sein du département Electronique, Electrotechnique et Automatique de 1999 à 2003. Il est reçu à l'agrégation de physique appliquée en 2002 et obtient un DEA de traitement du signal de l'université Paris-XI (France) en 2003 et soutient sa thèse à l'Institut national polytechnique de Grenoble (France) en 2006. Il est actuellement maître de conférences en traitement du signal à Phelma (Institut polytechnique de Grenoble) et est membre de GIPSA-lab. Ses recherches concernent le traitement statistique des signaux biomédicaux, la séparation de sources avec des applications en interfaces cerveau-machine et en séparation de sources audiovisuelles.



Marco Congedo est né à Bari, Italie, en 1972. En 2003 il obtient son doctorat en psychologie expérimentale avec une spécialité en statistiques à l'université du Tennessee (Knoxville). Entre 2003 et 2006, il effectue son post-doc en France à l'Institut national de recherches en informatique et automatique (INRIA) et France Telecom R&D. Depuis 2007, le docteur Congedo est chargé de recherche au Centre national de la recherche scientifique (CNRS) au Gipsa Lab, Grenoble.

Marc Congedo a reçu de nombreuses récompenses, bourses d'étude et fonds de recherche. Son champ d'étude porte sur l'électroencéphalographie (EEG), la neuro-imagerie temps-réel (neurofeedback et interface cerveau-machine) ainsi que sur les outils statistiques multivariés appliqués à l'analyse EEG, tels que les solutions inverses et la séparation de source aveugle.

Le docteur Congedo est membre de l'ISNR (International Society for Neurofeedback and Research), et éditeur consultant pour la revue scientifique Journal of Neurotherapy.



Christian Jutten est né à Epernay (Marne) en 1954. Il est docteur-ingénieur en 1981 (Institut national polytechnique de Grenoble – INPG), puis docteur ès sciences en 1987 (université Joseph-Fourier – UJF – et INPG). Il est successivement assistant (1982) et maître-assistant (1983) à l'ENSER Grenoble, professeur invité à l'Ecole polytechnique fédérale de Lausanne (EPFL) de mars à septembre 1989, puis professeur à l'UJF en 1989. De 1993 à 2010, il est directeur ou directeur-adjoint de son laboratoire (TIRF, LIS puis GIPSA-lab). Au niveau national, il est chargé de mission pour le traitement du signal et des images au ministère de la recherche (1996-1999) et au département STIC du CNRS (2003-2006).

Depuis près de 30 ans, il travaille sur les problèmes de séparation de sources (SAS) et ses travaux dans ce domaine sont internationalement reconnus. Ses travaux actuels sur l'ACI et la BSS portent sur des problèmes théoriques (mélanges non linéaires, mélanges sous-déterminés, sources parcimonieuses) et des applications (réseaux de capteurs chimiques, extraction audio-visuelle de la parole, extraction non-invasive de signaux biomédicaux, sismique).

Il organise en 1999, la première conférence internationale sur la séparation de sources (ICA 1999), conférence qui a été organisée par la suite un peu partout dans le monde, et se tiendra en Israël en 2012.

Il est membre de deux comités techniques de l'IEEE.

Il a obtenu le prix du meilleur papier de la revue *Signal Processing* en 1991, la médaille Blondel de la SEE (1997) et le grade de Fellow IEEE (2008). En septembre 2008, il a été nommé pour 5 ans membre senior de l'IUF.



Olivier Bertrand est ingénieur de Telecom Paris-Tech (1981) et a obtenu son doctorat en génie biologique et médical en 1985 à Lyon. Il est actuellement directeur du Centre de recherche en neurosciences de Lyon (CRNL, Univ. Lyon1/INSERM U1028/CNRS UMR5292) et responsable de l'équipe « Dynamique cérébrale et Cognition ». Ses activités de recherche se situent dans le domaine des neurosciences cognitives et de la neuro-imagerie fonctionnelle, en particulier à l'aide de l'EEG de surface et intracérébrale et de la MEG, pour étudier les réseaux oscillatoires dans la perception, l'attention et dans le cadre des interfaces cerveau-machine.



Emmanuel Maby, docteur en traitement du signal et télécommunications de l'université de Rennes 1 (2003), post-doctorant en neuro-imagerie temps réel dans l'équipe « Dynamique cérébrale et Cognition » du Centre de recherche en neurosciences de Lyon. Ses centres d'intérêts tournent autour des interfaces cerveau-machine non invasives. Ses activités de recherche comprennent l'acquisition et le traitement des signaux électro- et/ou magnéto-encéphalographiques en temps réel.



Jérémie Mattout est chargé de recherche à l'INSERM et travaille depuis 2007 dans l'équipe « Dynamique cérébrale et Cognition » du Centre de recherche en neurosciences de Lyon. Ingénieur et docteur en neurosciences cognitives, son expertise porte sur les méthodes d'analyse des données de neuro-imagerie. Depuis son arrivée à Lyon, il dédie ses recherches au nouveau domaine des interfaces cerveau-machine et à l'utilisation en temps réel des techniques d'électrophysiologie chez l'homme.

