

# Classification d'EEG pour les Interfaces Cerveau-Machine

Alain RAKOTOMAMONJY, Vincent GUIGUE, Gregory MALLET, Victor ALVARADO

Laboratoire Perception Systèmes et Informations CNRS FRE2645,  
INSA de Rouen, 76801 Saint Etienne du Rouvray , France  
Alain.Rakotomamonjy@insa-rouen.fr

**Résumé** – Cet article propose une méthodologie pour la classification de signaux électro-encéphalogrammes (EEG) dans le cadre des interfaces cerveau-machine. L'algorithme que nous proposons est basé sur une approche mettant en oeuvre un mélange de classifieurs SVM linéaire. Chaque SVM est entraîné sur une partie des données d'apprentissage provenant d'une même session d'acquisition des données. Ainsi, le mélange de SVM permet de prendre en compte la variabilité des EEGs lors des différentes sessions de mesures. Combiner à une méthode permettant de sélectionner automatiquement les canaux EEGs pertinents, nous montrons que notre algorithme constitue l'état de l'art pour les données provenant de la compétition BCI 2003.

**Abstract** – This paper proposes a methodology for classifying EEG signals in the context of Brain-Computer Interfaces. The proposed algorithm is based on a mixture of linear Support Vector Machines. Each SVM has been trained on part of the dataset which has been acquired during a single session. Hence, the mixture of SVM is able to cope with the variability of the EEG signals for different acquisition sessions. Combined with a channel selection algorithm, we show that our result is the state of the art result for the data we used which is part of the BCI 2003 competition .

## 1 Introduction

Certaines personnes atteintes de maladies neurologiques peuvent être totalement paralysées car elles ne peuvent plus contrôler leurs muscles. Pour ces personnes, seule l'utilisation de leur activité cérébrale et les signaux qui en découlent permettent de communiquer. L'objectif de la recherche sur les interfaces cerveau-machine est le développement de la technologie pouvant améliorer cette communication.

Dans cet article, nous nous intéresserons aux interfaces cerveau-machine permettant d'épeler un mot. Ces interfaces sont basées sur l'apparition de potentiels évoqués dans les électro-encéphalogrammes (EEG) en réponse à certains stimuli visuels. Cet interface génère donc des stimuli auxquels le patient est supposé répondre, et c'est grâce à ces réponses que la communication cerveau-machine se fait. Le problème réside donc dans la reconnaissance des signaux EEG contenant ou non des potentiels évoqués en réponse aux stimuli.

Notre objectif ici, est de proposer une méthodologie permettant de discriminer ces signaux EEG. Sachant que la difficulté réside dans le faible rapport signal sur bruit et dans la variabilité des types de réponses, notre approche essaye de tenir compte de ces écueils . Ainsi, nous étudions de manière systématique les canaux EEG utiles pour la discrimination et développons une technique de classification utilisant un mélange de classifieurs SVM.

## 2 Méthodologie

L'objectif de cette étude est de développer un système de reconnaissance des potentiels évoqués permettant de tenir compte de la variabilité des signaux, mais tout d'abord nous allons décrire le principe de l'interface cerveau-machine ainsi que les

signaux issus de cet interface.

### 2.1 L'interface cerveau-machine et les potentiels évoqués

L'interface cerveau-machine que nous utilisons est le *BCI P300 speller* qui est un interface permettant d'épeler des mots. Originellement développé par Farwell et al. [FD88], il est basé sur le protocole suivant : il est demandé à un patient de fixer une matrice  $6 \times 6$  composée de caractères. Plusieurs stimuli visuels sont alors engendrés par l'illumination dans un ordre aléatoire des 12 lignes et colonnes. Le patient doit alors compter le nombre de fois où la ligne ou la colonne du caractère qu'il souhaite épeler s'illumine ; le fait de compter ainsi génère un potentiel évoqué avec un phénomène appelé P300 (apparaissant 300 ms après le stimulus visuel). D'après ce principe, le caractère désiré est illuminé 2 fois parmi les 12 illuminations de la matrice (ligne et colonne). Notre objectif est donc de reconnaître parmi les 12 signaux la présence ou non d'un P300 dans les signaux réponses à un stimulus. Une illustration de la matrice d'épellation est présenté dans la figure (1).

Etant donné que les EEG ont un faible rapport signal sur bruit, il est nécessaire de rendre plus robuste le protocole d'épellation à travers un processus répétitif. Ainsi, le protocole suivi est d'épeler 15 fois le même caractère avant de passer au caractère suivant.

Les signaux utilisés dans cet article sont issus d'expériences d'épellation de mot réalisées au sein du Wadsworth Institute [SMH<sup>+</sup>04] et constituent la base de données d'une compétition sur les interfaces cerveau-machine [BMC<sup>+</sup>04]. Ces signaux ont été acquis grâce à un scalp de 64 canaux échantillonnés à une cadence de 240 Hz et correspondent à l'épellation par un même individu, lors de 3 différentes sessions, de respective-



FIG. 1 – La matrice d'épellation des mots avec une colonne illuminée

ment 5, 6 et 8 mots.

Les signaux correspondant aux deux premières sessions d'acquisition sont utilisés pour apprendre le modèle de reconnaissance des signaux P300 tandis que la troisième session sera réservée pour le test. Ainsi, la base d'apprentissage est composée de 7560 signaux réponse à un stimulus, décrits sur 64 canaux. Dans la mesure où le phénomène que l'on cherche à reconnaître apparaît autour de 300 ms après le stimulus visuel, nous ne nous intéressons ici qu'à la fenêtre temporelle de 666 ms après le stimulus. Par ailleurs, afin de réduire le rapport signal sur bruit, chaque canal a été filtré par un filtre passe-bande d'ordre 8 et de fréquences de coupure de 0.1 Hz et 20 Hz. Le signal est ensuite décimé en accord avec la fréquence de coupure haute. Ainsi, la représentation d'un signal une réponse à un stimulus est un vecteur de 896 éléments constitué par la concaténation des 64 signaux issus des canaux après filtrage et décimation.

Les figures (2) et (3) donnent un exemple de représentations des signaux obtenus pour un canal donné après ce premier prétraitement. La figure (2) représente les variations des échantillons à l'aide de boîtes à moustaches [Sap90]. Il est possible de distinguer la présence des P300 dans les signaux à travers les variables 7 et 8 correspondant aux échantillons se situant autour de 300 ms. En effet, la valeur médiane de ces variables sont clairement plus élevées en présence des P300. La figure (3) propose une représentation bidimensionnelle des signaux à l'aide de ces 2 variables. Cette nouvelle représentation corrobore le fait que les variables 7 et 8 ont tendance à être plus élevées pour les signaux où le P300 est présent. D'un autre côté, il confirme le fait que le problème de discrimination est difficile car les 2 ensembles de signaux sont fortement superposés.

## 2.2 Discrimination des signaux EEG

Après ce premier prétraitement, les signaux peuvent être présentés directement à un classifieur qui dans notre cas sera un Séparateur à Vaste Marge (SVM) [CST00]. Cette approche est celle proposée par Kaper et al. [KMG<sup>+</sup>04], et les résultats obtenus sont très satisfaisants dans la mesure où l'ensemble des mots de la base de test sont correctement reconnus en utilisant seulement 5 séquences d'illuminations. Cependant, cette approche ne permet pas de tenir compte de la variabilité des signaux EEG, ni de celle des potentiels évoqués et des conditions d'acquisitions. Un exemple de cette variabilité est illustré sur la figure (4). Cette figure représente les mêmes signaux que ceux de la figure (3) avec en superposition des signaux sans P300 issus d'une autre session d'acquisition. Cette figure

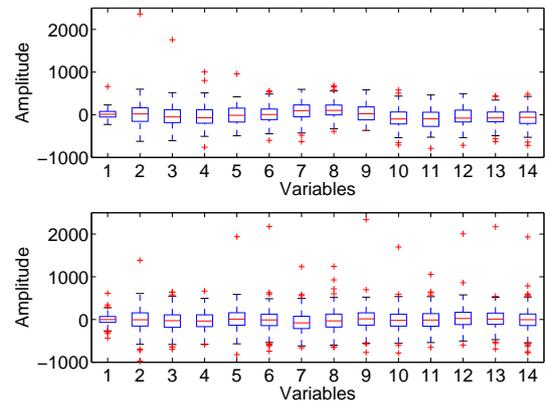


FIG. 2 – Boîtes à moustaches correspondant aux 14 échantillons d'un canal donné dans le cas de signaux avec P300 (en haut) et sans P300 (en bas).

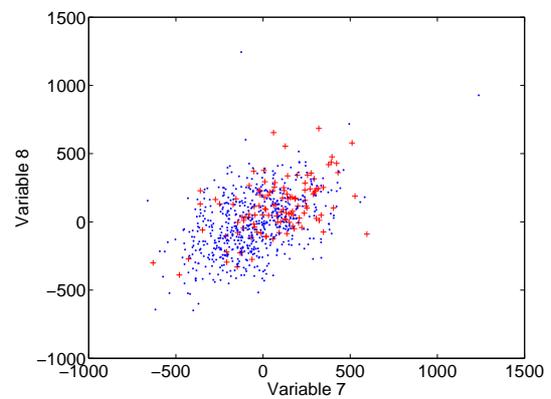


FIG. 3 – Représentations des signaux avec P300 (en '+' rouge) et sans P300 (en '.' bleu) en fonction des échantillons 7 et 8.

illustre que mélanger des signaux de différentes sessions d'acquisitions aura tendance à mélanger les 2 classes de signaux et donc à rendre le problème de discrimination plus difficile encore.

Nous proposons donc une méthode différente de celle de Kaper et al. [KMG<sup>+</sup>04] dans la mesure où nous allons développer une fonction de discrimination associée à chaque mot (et donc session d'acquisition) de la base d'apprentissage. Ainsi, la reconnaissance d'un nouveau signal sera effectuée par l'ensemble des classifieurs dont les réponses sont ensuite fusionnées pour décider de la classe finale du signal.

Ainsi, pour les signaux  $\{x_i, y_i\}_{i=1, \dots, \ell}$  associés à l'épellation d'un mot donné, la fonction de discrimination SVM est obtenue en suivant les étapes suivantes.

Tout d'abord les signaux d'entrée sont normalisés de sorte qu'ils soient centrés et de variance unitaire. Ensuite un processus de sélection de canaux est mis en oeuvre.

Parmi l'ensemble des 64 canaux, Kaper et al. [KMG<sup>+</sup>04] utilisent un nombre restreint et prédéfini de canaux. Cette approche suppose que l'activité cérébrale associée à la réponse aux stimuli soit localisée sur les mêmes parties du cerveau quelles que soient les conditions d'acquisitions. Dans ce papier, nous nous proposons de tenir compte de cette variabilité en sélectionnant automatiquement les canaux pertinents. Cette sélection se fait grâce à un algorithme d'élimination successive des canaux basé sur un critère de sélection.

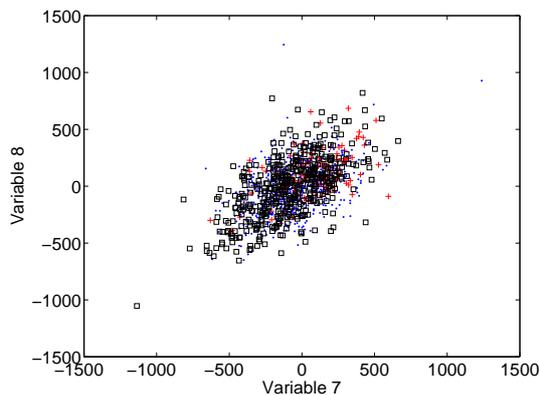


FIG. 4 – Représentations des signaux avec P300 (en '+' rouge), sans P300 (en '.' bleu) pour lors le l'épélation d'un même en fonction des échantillons 7 et 8. D'autres signaux sans P300 provenant d'une autre session d'acquisitions sont également représentés en carré noir.

La méthodologie suivie est la suivante : un SVM linéaire est appris à partir des exemples de signaux EEG  $\{x_i, y_i\}$  relatifs au mot concerné. La performance de ce SVM est évaluée sur les signaux des 10 autres mots de la base d'apprentissage. L'élimination de canal se fait en supprimant un canal de la description des signaux, en ré-apprenant un SVM et en évaluant les performances de ce nouveau classifieur à travers le critère :

$$C_{sel} = \frac{VP}{VP + FP + FN}$$

où  $VP$ ,  $FP$  et  $FN$  sont respectivement le taux de vrai positifs, faux positifs et faux négatifs. Le canal qui est éliminé est celui dont la suppression permet de maximiser le critère  $C_{sel}$ . Ce processus est ainsi répété tant que tout les canaux ne sont pas éliminés. Ainsi, cet algorithme permet de trier les canaux par ordre de pertinence en fonction du critère  $C_{sel}$  en fonction de leur ordre d'élimination. La figure (5) représente pour deux sessions d'acquisitions différentes les variations du critère  $C_{sel}$  lors du processus d'élimination en fonction du nombre de canaux. Comme prévu, l'allures de ces courbes sont globalement concaves dénotant ainsi le fait que plusieurs canaux ont tendance à bruite le problème de discrimination. Par ailleurs, ces courbes corroborent également la variabilité du problème puisque qu'elles montrent clairement qu'en fonction de la session d'acquisition (et donc des signaux utilisés pour l'apprentissage), les performances optimales nécessitent plus ou moins de canaux.

Finalement, la fonction de décision associée à un mot de la base d'apprentissage est obtenue en utilisant les données  $\{x_i, y_i\}$  du mot concerné et les  $N$  canaux les plus pertinents au sens du critère  $C_{sel}$ , ce nombre  $N$  étant déterminé de manière *ad hoc* ou automatique en choisissant les canaux qui maximisent le critère.

Chaque fonction de décision  $f_k(x)$  ( $k$  allant de 1 à 11 ce qui correspond aux 11 mots des sessions d'acquisition de la base d'apprentissage) permet de reconnaître la présence ou non un phénomène de P300 dans un EEG. Cependant, la reconnaissance d'un caractère nécessite une procédure plus complexe. En effet, un signal  $x$  (un ensemble de signaux EEG obtenus sur plusieurs canaux) associé à l'illumination de la ligne ou colonne  $i$  de la matrice est présenté après traitement à l'entrée de chaque SVM. Si on dénote respectivement par  $S_{Ligne}(i)$  et

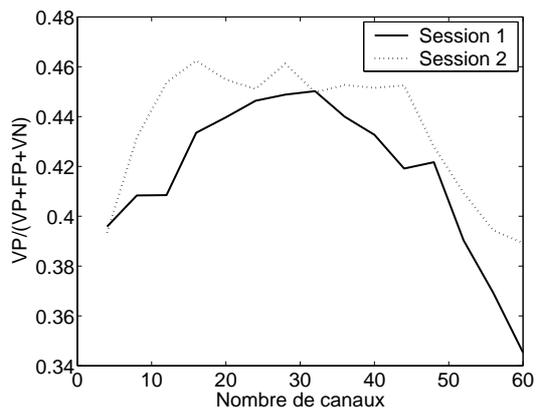


FIG. 5 – Variations du critère  $C_{sel}$  pour deux sessions d'acquisition différentes en fonction du nombre de canaux lors du processus d'élimination de canal. Dans le premier cas, le critère est maximisé en utilisant 32 canaux et 16 dans le deuxième cas.

$S_{Col}(i)$  le score associé à la  $i$ -ème ligne et la  $i$ -ème colonne de la matrice, après chaque illumination de cette ligne ou colonne, ce score est incrémenté en fonction des réponses des différentes fonctions de décision selon :

$$S_{Ligne}(i) = S_{Ligne}(i) + \sum_k f_k(x)$$

Ces scores sont itérativement mis à jour lors des 15 séquences d'illuminations de la matrice disponibles pour la reconnaissance d'une lettre. A la fin des 15 séquences d'illumination, la ligne (respectivement colonne) présentant un score maximal est considérée comme étant la ligne (respectivement colonne) contenant le caractère désiré.

### 3 Résultats

Cette méthodologie a donc été appliquée aux données de la compétition BCI 2003 [BMC<sup>+</sup>04] et les résultats sont présentés dans le tableau (1). La première ligne de résultats présente les performances obtenues par un des meilleurs participants à la compétition. L'approche de Bostanov consiste à représenter les signaux EEG sur un plan temps-échelle grâce à une transformée en ondelettes continues, à extraire ensuite des caractéristiques de ce plan et à classer ces caractéristiques par une analyse discriminante linéaire. La deuxième ligne de résultats correspond à un algorithme similaire à celui de Kaper et al [KMG<sup>+</sup>04] : après avoir choisi a priori des canaux et filtré les signaux en utilisant le même filtre que celui décrit ci-dessus, une frontière de décision unique obtenue par un SVM linéaire est apprise en utilisant l'ensemble des données d'apprentissage (toutes sessions confondues). Les résultats montrent que les algorithmes de Bostanov et al. et Kaper et al. ont une performance équivalente. Par ailleurs, en prenant l'ensemble des canaux pour l'algorithme de Kaper, on constate que les résultats ont tendance à être moins bons. Cela justifie donc le fait que les nombres de canaux doit être effectivement réduit.

Les 4ème et 5ème ligne de résultats prennent en compte la variabilité des signaux et des conditions d'acquisition des données d'apprentissage, à travers une aggrégation de SVM comme décrit dans la partie précédente. Il est intéressant de voir que, en utilisant les canaux choisis par Kaper, notre ap-

Algorithmes	Nombres de séquences utilisées							
	1	2	3	4	5	6	7	10
Bostanov [Bos04]	11	5	2	1	1	0	0	0
10 canaux preselectionnées et un SVM unique	14	6	6	0	1	0	0	0
tout les canaux et un SVM unique	14	10	9	5	5	5	1	0
10 canaux preselectionnées et un SVM par session	13	8	3	1	2	0	0	0
tout les canaux et un SVM par session	7	4	3	0	0	0	0	0
4 canaux pertinents et un SVM par session	8	7	4	0	1	0	0	0
10 canaux pertinents et un SVM par session	8	5	5	1	0	1	0	0
26 canaux pertinents et un SVM par session	4	2	0	0	0	0	0	0
30 canaux pertinents et un SVM par session	5	3	0	0	0	0	0	0
Nb de canaux pertinents optimal pour $C_{sel}$ et un SVM par session	4	2	1	0	0	0	0	0

TAB. 1 – Nombre de caractères erronés dans les mots de la base test en fonction du nombre de séquences utilisées et les algorithmes.

proche ne permet pas d'améliorer les performances de reconnaissances. Sans sélection de canal, tous les caractères de la base de test sont reconnus avec seulement 4 séquences. Par rapport à ceux donnés précédemment, ces résultats démontrent clairement que la prise en compte de la variabilité permet d'améliorer considérablement les résultats et que fixer a priori les canaux pertinents est une approche trop peu flexible vis à vis d'un problème aussi variable que la classification d'EEG.

Les résultats de notre algorithme sont présentés sur les dernières lignes du tableau (1). Après avoir sélectionné les canaux pertinents et effectué l'apprentissage pour chaque SVM associé à une session d'acquisition, nous avons testé les performances en fonction du nombre de canaux pertinents utilisés. Si ce nombre de canaux est fixé a priori, on constate que les performances peuvent être excellentes (aucune erreur de reconnaissance pour 3 séquences) tandis que si ce choix est fait de manière automatique c'est-à-dire en choisissant les canaux qui maximisent  $C_{sel}$ , l'ensemble des caractères de test sont reconnus sur 4 séquences et le nombre d'erreurs pour 1, 2, et 3 séquences est très correct et constitue l'état de l'art sur ce problème.

## 4 Conclusions

Cet article a présenté une méthodologie pour la classification de signaux EEG issus d'un interface cerveau-machine. Le problème de classification est intimement lié à l'interface et consiste ici à reconnaître des signaux contenant des P300 en réponse à un stimulus visuel. La difficulté majeure d'un tel problème est la variabilité des données qui est induite par les variations des conditions d'acquisitions et de l'état d'esprit de l'utilisateur. Dans notre approche, nous avons tenu compte de cette variabilité grâce à un mélange de classifieurs et à une sélection automatique des canaux EEG pertinents. Les résultats ont démontré que notre algorithme est très prometteur et nos perspectives vont maintenant nous orienter vers la prise en compte de la variabilité des signaux entre différents utilisateurs.

**Remerciements :** Ce travail est financé en partie par le programme IST de la Communauté Européenne, avec le réseau d'excellence PASCAL, IST-2002-506778. Cette publication reflète uniquement le point de vue des auteurs.

## Références

- [BMC<sup>+</sup>04] B. Blankertz, K-R Müller, G. Curio, T. Vaughan, G. Schalk, J. Wolpaw, A. Schlögl, C. Neuper, G. Pfurtscheller, T. Hinterberger, M. Schröder, and N. Birbaumer. the BCI competition 2003 : Progress and perspectives in detection and discrimination of eeg single trials. *IEEE Trans. Biomed. Eng.*, 51(6) :1044–1051, 2004.
- [Bos04] V. Bostanov. BCI competition 2003-data sets Ib and Iib : feature extraction from event-related brain potentials with the continuous wavelet transform and the t-value scalogram. *IEEE Transactions on Biomedical Engineering*, 51(6) :1057–1061, 2004.
- [CST00] N. Cristianini and J. Shawe-Taylor. *Introduction to Support Vector Machines*. Cambridge University Press, 2000.
- [FD88] L. Farwell and E. Donchin. Talking off the top of your head : toward a mental prosthesis utilizing event-related brain potentials. *Electroencephalography and Clinical Neurophysiology*, 70(6) :510–523, 1988.
- [KMG<sup>+</sup>04] M. Kaper, P. Meinicke, U. Grossekhoefer, T. Lingner, and H. Ritter. BCI competition 2003 - dataset Iib : Support vector machines for the P300 speller paradigm. *IEEE Transactions on Biomedical Engineering*, 51(6) :1073– 1076, 2004.
- [Sap90] G. Saporta. *Probabilités, Analyse de données et Statistique*. Editions Technip, 1990.
- [SMH<sup>+</sup>04] G. Schalk, D. McFarland, T. Hinterberger, N. Birbaumer, and J. Wolpaw. BCI2000 : a general-purpose brain-computer interface (BCI) system. *IEEE Transactions on Biomedical Engineering*, 51(6) :1034–1043, 2004.