



HAL
open science

Classification des potentiels évoqués par corrélation de Pearson dans une interface cerveau-ordinateur

François Cabestaing, Theresa M Vaughan, Dennis J Mcfarland, Jonathan R Wolpaw

► **To cite this version:**

François Cabestaing, Theresa M Vaughan, Dennis J Mcfarland, Jonathan R Wolpaw. Classification des potentiels évoqués par corrélation de Pearson dans une interface cerveau-ordinateur. Quatrième conférence sur les Nouvelles Technologies au service de l'homme, HANDICAP'2006, Jun 2006, Paris, France. pp.184-189. hal-00521113

HAL Id: hal-00521113

<https://hal.science/hal-00521113v1>

Submitted on 25 Sep 2010

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.

Classification des potentiels évoqués par corrélation de Pearson dans une interface cerveau-ordinateur

François Cabestaing*, Theresa Vaughan†, Dennis McFarland†, Jonathan Wolpaw†

*Laboratoire d'Automatique, Génie Informatique & Signal, CNRS UMR-8146, Université des Sciences et Technologies de Lille, 59655 Villeneuve d'Ascq CEDEX. (fcab@ieec.org)

†Laboratory of Nervous System Disorders, PO Box 509, Wadsworth Center, NYSDOH, Empire State Plaza, Albany, NY 12201-0509

Abstract— Dans cette communication, nous décrivons et évaluons les performances d'une technique d'apprentissage des coefficients d'un classifieur linéaire utilisé dans une interface cerveau-ordinateur. Les signaux de l'électroencéphalogramme d'un individu sont analysés au moyen de cette technique afin de mettre en évidence les réponses de ce dernier à des stimuli visuels. Le traitement et la classification des signaux sont utilisés afin d'implanter un système de communication palliative permettant à l'individu d'épeler des mots. Les performances de la méthode de classification ont été évaluées par une expérimentation sur huit personnes.

I. INTRODUCTION

Une interface cerveau-ordinateur (BCI : Brain Computer Interface) est un système qui permet la communication directe, sans nécessiter d'intervention musculaire, entre une personne et un ordinateur. Cette technique vise principalement à permettre à des personnes souffrant d'un handicap neuromusculaire sévère de communiquer avec leur entourage. Pour les personnes verrouillées dans leur corps (locked-in), suite à une perte complète du contrôle de l'activité musculaire, le BCI est la technique de communication assistée qui semble la plus prometteuse. Certains patients atteints de maladies dégénératives comme la SLA (Sclérose Latérale Amyotrophique), lesquels perdent toute mobilité volontaire dans les phases ultimes de la maladie, ont expérimenté cette technique. Dans le monde, on considère que plusieurs millions de personnes pourraient bénéficier des systèmes BCI.

Le schéma de principe d'un BCI est présenté sur la figure 1. L'activité cérébrale de l'individu est mesurée par le biais de signaux électriques, captés soit sur le cuir chevelu (EEG : Électroencéphalogramme), soit à la surface du cortex (ECoG : Électrocorticogramme), soit encore directement sur les neurones (SNA : Single Neuron Activity). Les signaux enregistrés sont traités par le système, lequel traduit ensuite l'activité cérébrale détectée en ordres qui pourront être transformés en actions par l'ordinateur.

L'équipe du "Laboratory of Nervous System Disorders" au Wadsworth Center du Département de la Santé de l'état de New York aux USA a proposé de nombreux paradigmes permettant d'utiliser au mieux les informations extraites des signaux d'un électroencéphalogramme (EEG) afin de réaliser un BCI [1]. Une première approche consiste à analyser l'amplitude des rythmes liés normalement à l'activité musculaire,

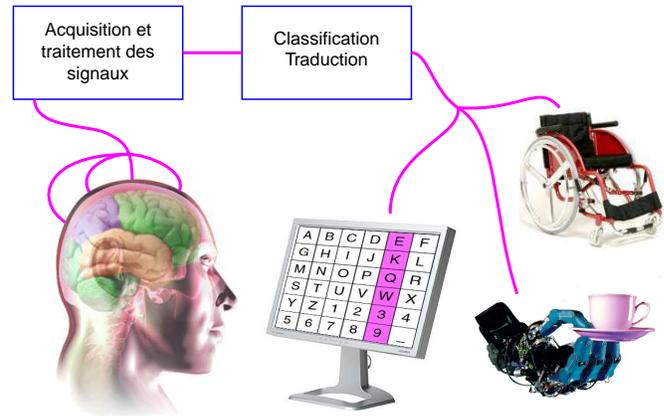


Fig. 1. Schéma de principe d'une interface cerveau-ordinateur

lesquels sont détectés principalement dans les aires sensorimotrices du cortex [2]. Par exemple, l'amplitude du rythme μ est modifiée lorsqu'un individu bouge, mais également lorsqu'il imagine qu'il réalise un mouvement. Après un entraînement, souvent assez long, un utilisateur peut apprendre à contrôler l'amplitude de ses rythmes sensorimoteurs afin de contrôler le BCI. Cette approche a été utilisée par l'équipe du Wadsworth Center afin de permettre le contrôle d'un curseur se déplaçant sur l'écran de l'ordinateur, en une ou plus récemment deux dimensions.

Une autre approche possible pour réaliser un BCI, qui a été proposée initialement par Farwell et Donchin, consiste à détecter dans les signaux d'EEG les potentiels évoqués (ERP : Event Related Potentials) par des stimuli perçus par l'individu [3]. En particulier, les ERP de type P300, qui apparaissent lorsque l'individu réagit de façon cognitive et volontaire à un stimulus visuel, auditif ou tactile, ont été largement utilisés pour contrôler des BCI. L'intérêt des BCI exploitant les ERP est qu'ils ne nécessitent pas de phase d'apprentissage de la part de l'utilisateur, puisque ces réponses sensorielles sont innées. Les potentiels P300 sont évoqués principalement lorsque l'individu réagit à un stimulus rare apparaissant sporadiquement parmi des stimuli plus courants (Oddball paradigm [4]).

Un paradigme visuel ingénieux, respectant la condition liée à la rareté du stimulus, consiste à présenter à l'utilisateur une matrice de symboles et à lui demander de focaliser son

attention sur l'un d'entre eux (cf. figure 2). Durant l'essai, les lignes et les colonnes de la matrice sont intensifiées dans un ordre aléatoire et l'utilisateur doit compter le nombre d'intensifications affectant le symbole sur lequel il se focalise. L'intensification d'une ligne ou d'une colonne constitue le stimulus de base, les stimuli rares correspondant à l'intensification de la ligne et de la colonne contenant le symbole d'intérêt. Chez la majorité des individus, les stimuli rares évoquent un ERP de type P300, qui peut être détecté par le BCI. Ce paradigme a été exploité par de nombreuses équipes afin de constituer un BCI permettant d'épeler des mots.

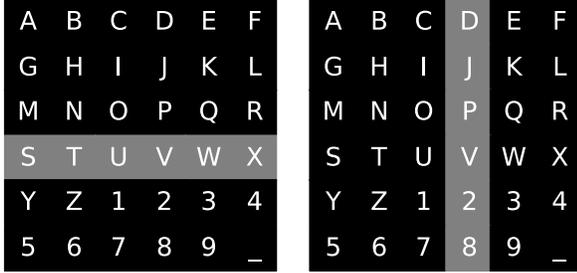


Fig. 2. Matrice de symboles, ici alphanumériques, dont les lignes et les colonnes sont intensifiées individuellement de façon aléatoire durant une séquence

Les stimuli rares, qui correspondent à une intensification de la ligne ou de la colonne contenant le symbole sur lequel l'utilisateur focalise son attention, entraînent l'apparition d'un ERP, qu'il s'agit de détecter dans les signaux. La détection d'un ERP permet ensuite de remonter au stimulus qui a entraîné son apparition, lequel est qualifié de stimulus cible. Les stimuli périodiques, qui correspondent à des lignes ou des colonnes ne contenant pas le symbole sélectionné, sont qualifiés de non-cible. Les signaux d'EEG sont enregistrés en continu, chaque signal étant échantillonné et numérisé afin d'être traité par le système. L'ensemble des valeurs de tous les signaux, dans une fenêtre de durée limitée débutant à l'instant d'intensification d'une ligne ou d'une colonne, est appelée réponse temporelle à un stimulus.

Dans ce travail, nous nous intéressons à la détermination du type de stimulus, cible ou non-cible, ayant mené à l'enregistrement d'une réponse temporelle donnée. Dans la première partie de l'article, nous montrons qu'une technique de classification linéaire permet d'atteindre cet objectif. Nous rappelons le principe des classifieurs linéaires et expliquons pourquoi les techniques standard d'apprentissage posent problème dans notre application. Dans la deuxième partie, nous montrons comment les coefficients d'un classifieur linéaire peuvent être déterminés par une analyse statistique des réponses temporelles contenues dans un ensemble d'apprentissage limité. Enfin, dans la dernière partie, nous présentons les résultats de classification obtenus grâce à la méthode proposée sur des données expérimentales enregistrées sur huit individus.

II. TECHNIQUE DE CLASSIFICATION

Dans cette partie, nous décrivons la technique utilisée pour déterminer le type de stimulus, cible ou non-cible, au moyen

des échantillons de la réponse temporelle. Le vecteur poids d'un classifieur linéaire est déterminé à l'aide d'une technique simple mais efficace, dans laquelle les axes de l'espace des attributs sont traités indépendamment les uns des autres.

A. Classifieur linéaire

Dans le cas de deux classes, un classifieur linéaire est une fonction $h(\cdot)$ définissant une injection entre l'espace des attributs \mathcal{X} , un sous-ensemble de \mathbb{R}^n , et l'ensemble des étiquettes $\mathcal{Y} = \{-1, +1\}$. Elle est définie au moyen d'un vecteur poids $\mathbf{w} \in \mathbb{R}^n$ et d'un décalage $b \in \mathbb{R}$, par l'expression :

$$h(\mathbf{x}) = \text{sign}(\mathbf{w}^T \mathbf{x} + b) = \begin{cases} +1 & \text{if } \mathbf{w}^T \mathbf{x} + b > 0 \\ -1 & \text{if } \mathbf{w}^T \mathbf{x} + b < 0 \end{cases} \quad (1)$$

$\mathbf{w}^T \mathbf{x} + b = 0$ est l'équation d'un hyperplan qui divise \mathbb{R}^n en deux sous-espaces correspondant aux classes. Par exemple, avec $n = 2$ un classifieur linéaire est défini par une droite qui divise le plan en deux demi-plans, comme indiqué sur la figure 3.

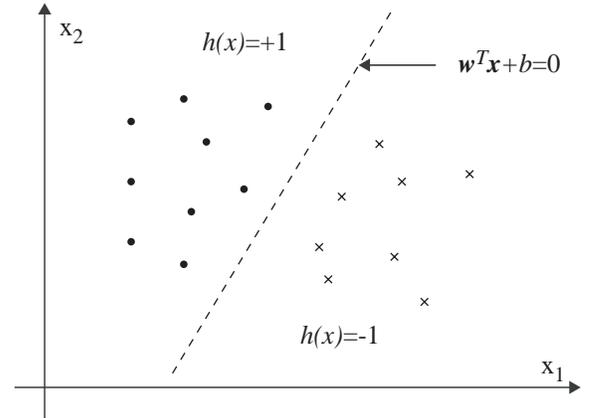


Fig. 3. Classifieur linéaire 2D, séparation des éléments en deux classes

Dans notre cas, l'objectif de la classification est de déterminer, à partir des réponses temporelles enregistrées sur l'ensemble des électrodes, si le stimulus correspond à une cible ou pas. Considérons les réponses moyennes à des stimuli cible et non-cible enregistrées sur l'électrode Cz, représentées sur la figure 4. Au vu de ces courbes, il apparaît clairement que seuls certains échantillons de la réponse temporelle sont significatifs pour discriminer le type de stimulus. Si les deux valeurs, sur les réponses moyennes cible et non-cible, sont égales pour un même échantillon, ce dernier ne peut pas être utilisé pour déterminer le type de stimulus. En revanche, si les deux valeurs sont différentes, l'échantillon correspondant peut être utilisé pour les discriminer, à condition toutefois que la variance associée reste faible.

De ce fait, un classifieur linéaire basique peut être défini sur la base d'un nombre limité d'échantillons, repérés comme significatifs sur certaines électrodes spécifiques [3]. Le vecteur poids du classifieur est déterminé de façon empirique en utilisant les réponses moyennes aux stimuli cible et non-cible. Par exemple, on peut utiliser les échantillons du signal fourni par l'électrode Cz entre 200ms et 600ms après le stimulus,

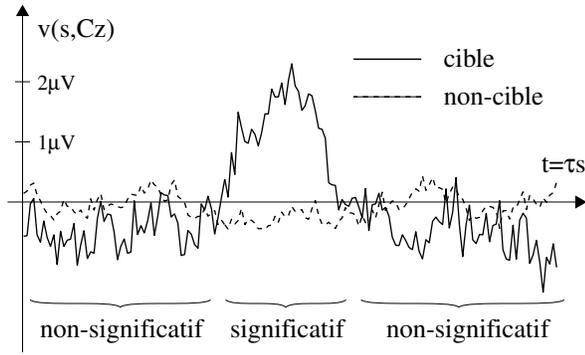


Fig. 4. Réponses moyennes à des stimuli cible et non-cible, relevées sur l'électrode Cz de l'EEG

car elle permet de détecter des potentiels évoqués (ERP : Event Related Potential) de type P300. Statistiquement, pour un ERP de type P300, l'échantillon prend une valeur plus élevée pour un stimulus cible que pour un stimulus non-cible. Dans ce cas, on affecte une valeur positive au poids appliqué à cet échantillon, afin d'obtenir un terme également positif dans le produit scalaire $\mathbf{w}^T \mathbf{x}$ de l'équation (1). Les échantillons significatifs et les coefficients associés doivent être déterminés pour chaque individu, du fait de la haute variabilité des localisations spatiales et temporelles des ERP.

Plutôt que de sélectionner des échantillons particuliers, nous proposons d'utiliser tous les échantillons de tous les signaux comme attributs dans le classifieur linéaire. La réponse temporelle à un stimulus est alors représentée par un vecteur, noté \mathbf{x} , à $n_e \times n_s$ coordonnées, incluant tous les échantillons de tous les signaux. n_e est le nombre d'électrodes installées sur le bonnet d'EEG, chacune délivrant un signal numérisé en n_s échantillons. Avec un taux d'échantillonnage τ , la durée d'une réponse temporelle enregistrée vaut dans ce cas n_s/τ . Par exemple, avec 64 électrodes numérisées à 300Hz, une réponse d'une seconde est décrite par un vecteur à 19200 coordonnées. Il faut souligner qu'avec cette représentation, l'ordre temporel des échantillons est perdu, puisque les coordonnées d'un vecteur ne sont pas ordonnées.

B. Inconvénients des techniques d'apprentissage

Dans le cas supervisé, les paramètres d'un classifieur sont appris en utilisant un ensemble d'apprentissage, composé de paires $(\mathbf{x}_i, y_i) \in \mathcal{X} \times \mathcal{Y}$ d'éléments \mathbf{x}_i de l'espace des attributs pour lesquels les étiquettes y_i sont connues. Cet ensemble est utilisé dans sa totalité par les techniques d'apprentissages globales (batch), ou élément par élément par les techniques itératives (online). Le lecteur peut se référer à [5] pour une présentation détaillée des techniques d'apprentissage.

L'analyse discriminante de Fisher est la méthode de référence pour l'apprentissage de type batch [6]. Tous les échantillons de l'ensemble d'apprentissage sont projetés sur la droite orthogonale à l'hyperplan défini par \mathbf{w} , afin de définir les deux ensembles $m^+ = \{\mathbf{w}^T \mathbf{x}_i \mid y_i = +1\}$ et $m^- = \{\mathbf{w}^T \mathbf{x}_i \mid y_i = -1\}$ correspondant aux deux classes. En se référant à cette droite, les deux classes sont bien séparées lorsque les deux barycentres sont éloignés alors que les variances des positions

dans les deux ensembles sont faibles. Afin de déterminer le meilleur hyperplan de séparation, Fisher propose de maximiser le critère :

$$J(\mathbf{w}) = \frac{[\text{avg}(m^+) - \text{avg}(m^-)]^2}{\text{var}(m^+) + \text{var}(m^-)}, \quad (2)$$

dans laquelle $\text{avg}(\cdot)$ et $\text{var}(\cdot)$ représentent respectivement la valeur moyenne et la variance des positions de tous les points d'un ensemble.

Parmi les méthodes d'apprentissage itératif, la plus simple et la plus largement utilisée est la technique d'apprentissage du perceptron, décrite par Rosenblatt [7]. Les éléments de l'ensemble d'apprentissage, qui dans ce cas n'est pas obligatoirement défini a priori, sont utilisés les uns après les autres afin de mettre à jour le vecteur poids du classifieur linéaire. Notons \mathbf{w}_k le vecteur poids estimé en utilisant les k premiers éléments de l'ensemble d'apprentissage, et \hat{y}_k l'estimation de la classe obtenue grâce à \mathbf{x}_k . Si le classifieur fait une erreur pour l'un des éléments de l'ensemble d'apprentissage, c'est à dire si la valeur prédite \hat{y}_k est différente de la valeur réelle y_k , le vecteur poids est mis à jour en utilisant la règle :

$$\mathbf{w}_{k+1} = \mathbf{w}_k + \eta y_k \mathbf{x}_k, \quad (3)$$

dans laquelle η est une constante appelée taux d'apprentissage.

Ces méthodes d'apprentissage très connues, et celles qui leur sont équivalentes, ne sont pas adaptées dans notre cas, soit parce qu'elles nécessitent un nombre trop important de calculs, soit parce que l'ensemble d'apprentissage ne contient pas assez d'éléments. En effet, l'ensemble d'apprentissage contient un nombre limité, habituellement quelques centaines, de réponses associées à un type de stimulus, alors que l'espace des attributs est de dimension bien supérieure, de l'ordre d'une dizaine de milliers. Maximiser le critère discriminant de Fisher nécessite de calculer une matrice de corrélation croisée, matrice carrée de taille $n_e n_s \times n_e n_s$, et de l'inverser. Ce calcul nécessiterait des heures de traitement pour une matrice carrée de taille 19200×19200 même sur un ordinateur puissant, et le résultat serait probablement non significatif du fait de l'accumulation, durant l'algorithme itératif d'inversion de la matrice, des inévitables imprécisions de calcul. D'autre part, pour les méthodes d'apprentissage itératif, se pose le problème de la taille limitée de l'ensemble d'apprentissage. Apprendre plusieurs milliers de coefficients par une méthode itérative nécessite au minimum un nombre comparable d'éléments dans l'ensemble d'apprentissage. On considère souvent qu'il faut disposer de dix fois plus d'échantillons que de coefficients à apprendre, ce qui est loin d'être le cas dans notre application.

III. TECHNIQUE DE RÉGLAGE PROPOSÉE

Le coefficient de corrélation de Pearson, habituellement noté r , est un outil d'analyse statistique que nous utilisons pour vérifier si un échantillon d'une réponse temporelle est significatif. Ce coefficient, qui mesure la corrélation entre deux séries $X = x_i, 1 \leq i \leq n_i$ et $Y = y_i, 1 \leq i \leq n_i$, est calculé

au moyen de l'équation :

$$r = \frac{n_i \sum x_i y_i - \sum x_i \sum y_i}{\sqrt{[n_i \sum x_i^2 - (\sum x_i)^2][n_i \sum y_i^2 - (\sum y_i)^2]}}. \quad (4)$$

r reflète le degré de proportionalité entre les deux séries par une valeur comprise entre -1 et $+1$. Si toutes les valeurs de la première série sont strictement proportionnelles à celles de la seconde, r vaut $+1$ ou -1 . Si les valeurs des deux séries ne présentent pas de corrélation, r est égal à zéro.

Notons n_i le nombre d'éléments dans l'ensemble d'apprentissage et Y la série de valeurs y_i , $1 \leq i \leq n_i$ définissant le type de stimulus pour chaque élément, avec $+1$ pour un stimulus cible et -1 pour un stimulus non-cible. $X(s, e)$ est la série de valeurs $x_i(s, e)$, $1 \leq i \leq n_i$, prises dans les n_i réponses temporelles par l'échantillon particulier s du signal de l'électrode e . Nous calculons le coefficient de corrélation de Pearson $r(s, e)$ entre les séries $X(s, e)$ et Y selon l'équation 4. Plus la valeur absolue de $r(s, e)$ est élevée, plus l'échantillon correspondant est discriminant en ce qui concerne le type de stimulus. Cette propriété se vérifie par exemple sur la courbe de la figure 5, laquelle représente les valeurs des coefficients $r(s, e)$ pour tous les échantillons s de l'électrode $e=Cz$.

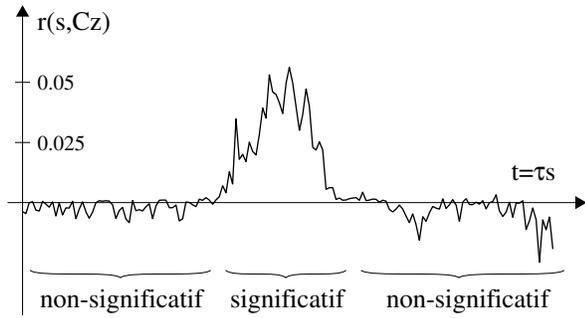


Fig. 5. Coefficient de corrélation de Pearson en fonction du temps, électrode Cz

Plutôt que de sélectionner les échantillons les plus significatifs de la réponse temporelle, nous utilisons tous les coefficients $r(s, e)$ en tant que coordonnées du vecteur poids w d'un classifieur linéaire défini sur un espace d'attributs de dimensions $n_e \times n_s$. Si un échantillon est significatif, sa valeur sera multipliée par un coefficient non nul et accumulée. D'autre part, la valeur de cet échantillon dans la réponse moyenne à un stimulus cible peut être soit inférieure soit supérieure à la valeur du même échantillon dans la réponse moyenne à un stimulus non-cible. Le signe de $r(s, e)$ permet de tenir compte de cette propriété, puisque le produit $r(s, e)x(s, e)$ est statistiquement positif pour un échantillon d'une réponse cible.

Cette technique de réglage des coefficients du classifieur, qui est une approche de type batch, utilise de façon indépendante l'information contenue sur chaque axe de l'espace des attributs. Elle est très efficace en termes de temps de calcul, puisque sa complexité est en $o(n)$, où n est la dimension de l'espace des attributs. En comparaison, les techniques batch standard, comme la maximisation du discriminant de Fisher, ont une complexité en $o(n^3)$. Cependant, il faut noter que

cette méthode ne permet pas d'aboutir à une solution qui maximiserait un quelconque critère d'optimalité, ce qui n'en fait pas à proprement parler une technique d'apprentissage.

IV. ÉVALUATION DES PERFORMANCES ET DISCUSSION

A. Acquisition des données expérimentales

Huit personnes (six hommes et deux femmes d'âges compris entre 24 et 50 ans) ont utilisé le système BCI afin de fournir les données utilisées dans cette expérimentation. Certains avaient déjà utilisé un BCI, mais aucun n'avait d'expérience particulière avec un système exploitant les ERP. Les données, acquises durant cinq sessions indépendantes pour chaque utilisateur, ont été enregistrées dans des conditions expérimentales identiques, sur une durée totale de plusieurs mois.

L'utilisateur était assis en face d'un moniteur vidéo afin d'observer directement la matrice de symboles alphanumériques présentée à la figure 2. Il devait focaliser son attention sur un symbole particulier et compter le nombre d'intensifications de ce caractère cible. Toutes les données ont été collectées dans le mode qualifié de recopie, dans lequel le symbole cible est spécifié par l'ordinateur. Durant chaque session, l'utilisateur devait épeler neuf mots ou séries de symboles, à savoir les huit mots uniques de la phrase « The quick brown fox jumps over the lazy dog » et un nombre de trois chiffres. Ces séries ont été choisies afin de balayer au mieux tous les symboles présentés dans la matrice. Les colonnes et les lignes étaient intensifiées pendant 100 millisecondes avec une périodicité de 175 millisecondes. Pour une lettre, chaque colonne et chaque ligne de la matrice étaient intensifiées 15 fois, dans un ordre aléatoire, ce qui correspond à 180 stimuli dont 30 étaient des cibles.

Les signaux d'EEG étaient captés au moyen d'un bonnet (Electro-Cap International Inc.) intégrant 64 électrodes organisées selon la nomenclature internationale 10-20. Toutes les électrodes étaient référencées par rapport au lobe de l'oreille droite et mises à la terre sur le mastoïde droit. Les signaux étaient amplifiés d'un facteur 20.000 (amplificateur SA Electronics), filtrés par un passe-bande 0,1 – 60Hz, échantillonnés à 240Hz et enregistrés. Tous les aspects liés à la collecte de données et à la génération de stimuli étaient gérés par le logiciel BCI2000 [8].

B. Protocole de validation et de comparaison

Nous considérons que le potentiel évoqué par un stimulus doit apparaître dans les 800 millisecondes suivant le stimulus afin qu'il soit significatif. Cette durée correspond à 192 échantillons par électrode lorsque le signal est numérisé à 240Hz. Quand on prend en compte les 64 électrodes, cela amène le système à traiter 12288 éléments caractéristiques pour chaque réponse. Dans la plupart des autres méthodes de classification des réponses, la première étape consiste à éliminer des dimensions dans l'espace des attributs afin de permettre un apprentissage des paramètres du classifieur. La réduction de dimension est obtenue en sous-échantillonnant les signaux, soit dans le domaine temporel, soit dans le domaine spatial, soit dans les deux domaines simultanément.

Afin de vérifier le bien-fondé de ces sous-échantillonnages et de valider simultanément notre méthode de classification, nous avons analysé les données dans les quatre configurations suivantes :

- 1) en utilisant les 12288 dimensions de l'espace initial des attributs, soit 64 électrodes à 240Hz.
- 2) en considérant seulement 8 électrodes, sélectionnées par les experts comme les plus susceptibles de contenir des ERP, afin de limiter à 1536 les dimensions de l'espace.
- 3) en sous-échantillonnant les signaux à 20Hz, grâce à un filtrage passe-bas et à une décimation, ce qui ramène le nombre d'attributs à 1024.
- 4) en utilisant simultanément les deux réductions précédentes, soit 8 électrodes échantillonnées à 20Hz, afin d'obtenir uniquement 128 attributs.

Comme nous disposons des données de cinq sessions pour chaque individu, plusieurs combinaisons d'apprentissage et de test étaient envisageables. Nous avons retenu deux options, l'une consistant à apprendre les paramètres du classifieur sur les données de la première session et à les tester sur les quatre sessions restantes, l'autre à apprendre les coefficients sur chaque session et à les tester uniquement sur la session suivante. Dans ces conditions, nous disposons de sept couples (apprentissage, test) pour chaque individu. Pour un apprentissage, toutes les réponses disponibles dans la session sont utilisées, soit 35 symboles à raison de 180 stimuli par symbole, ce qui correspond à 6300 éléments dans l'ensemble d'apprentissage

La performance de la technique d'analyse proposée a été évaluée en déterminant le taux de bonne classification pour chacun des couples (apprentissage, test) décrits précédemment. Nous avons également étudié l'évolution du taux de bonne classification en fonction du nombre de stimuli analysés, lequel dépend du nombre d'intensifications de chaque ligne et chaque colonne (compris entre un et quinze).

C. Résultats d'apprentissage

Un exemple de résultat d'apprentissage, pour une unique session d'un individu dans les quatre configurations de l'espace des attributs, est présenté dans la figure 6. Chaque image représente le vecteur poids du classifieur, la dimension horizontale correspondant au numéro d'échantillon dans le temps, la dimension verticale au numéro d'électrode, et le niveau de gris de l'image à la valeur absolue du poids déterminé pour l'axe correspondant de l'espace des attributs. Plus le niveau de gris se rapproche du blanc, plus le poids est élevé, ce qui signifie que l'axe correspondant de l'espace est significatif en terme d'information discriminante.

On vérifie aisément sur ces images que certains échantillons de la réponse temporelle sont très discriminants, aux alentours du soixante-cinquième à 240Hz et du sixième à 20Hz. Ces échantillons correspondent assez précisément à un décalage de 300 millisecondes, ce qui confirme leur relation avec des ERP de type P300. On constate également que la diminution de résolution, soit spatiale, soit temporelle, permet d'aboutir

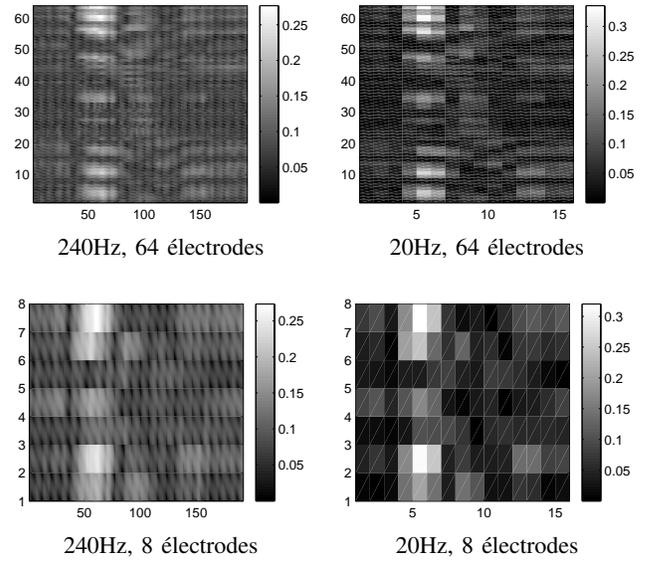


Fig. 6. Résultats d'apprentissage dans quatre configurations. Le vecteur poids du classifieur est représenté par une image : l'abscisse est le numéro d'échantillon, l'ordonnée le numéro d'électrode, le niveau de gris est proportionnel à la valeur absolue du coefficient

à des vecteurs poids dont les représentations ont des allures très similaires quand ils sont représentés par une image.

D. Taux de classification correcte

Le taux de classification correcte permet de vérifier le bon comportement de la méthode d'apprentissage proposée. Dans la table I, nous indiquons les taux de classification correcte obtenus pour les huit individus (A-H) avec les sept couples (session d'apprentissage, session de test) disponibles. On constate que la méthode permet d'obtenir des taux de classification correcte très satisfaisants, bien qu'ils soient fortement liés à l'aptitude de l'individu. Il n'y a pas d'évolution significative du taux au cours des sessions, ce qui confirme que l'apparition des ERP est un processus inné peu influencé par l'apprentissage.

	1->2	1->3	1->4	1->5	2->3	3->4	4->5
A	66,67	55,56	44,44	36,11	69,44	41,67	41,67
B	78,38	75,68	71,05	72,97	59,46	78,95	64,86
C	86,11	80,56	83,33	88,89	66,67	88,89	88,89
D	66,67	86,11	75	30,56	75	72,22	36,11
E	97,22	96,55	97,22	97,22	100	100	100
F	62,16	77,42	57,89	78,38	83,87	68,42	83,78
G	86,11	80,56	100	91,67	88,89	97,22	94,44
H	66,67	63,89	16,67*	83,33	72,22	11,11*	83,33

TABLE I

TAUX DE CLASSIFICATION CORRECTE (EN %) POUR CHAQUE INDIVIDU EN FONCTION DU COUPLE (SESSION D'APPRENTISSAGE, SESSION DE TEST)

* DURANT LA SESSION 4, L'INDIVIDU H N'A PAS PARFAITEMENT MAINTENU SON ATTENTION SUR LA TÂCHE

Sur la figure 7, nous avons représenté l'évolution du taux de classification correcte en fonction du nombre de séries d'intensification utilisé pour la reconnaissance. On vérifie que le taux augmente avec le nombre de séries, ce qui s'explique aisément par l'effet d'atténuation du bruit lorsqu'on réalise une moyenne sur plusieurs mesures. On constate également la disparité existant entre les individus en termes d'ERP,

puisque certains sont capables d'atteindre des taux excellents, de l'ordre de 70 à 100%, avec seulement six séries d'intensifications, alors que pour d'autres l'évolution du taux en fonction du nombre d'intensifications est très progressive.

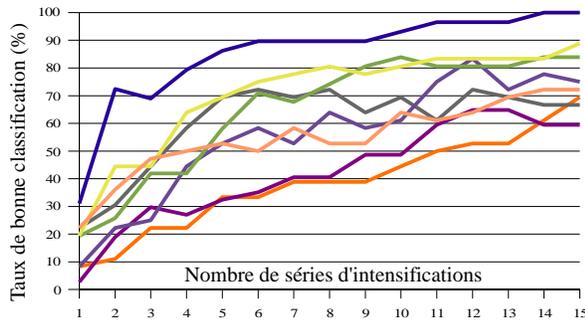


Fig. 7. Évolution du taux classification correcte en fonction du nombre d'intensifications

Comme nous l'avons indiqué précédemment, la méthode a été appliquée sur des données dans quatre configurations de résolution spatiale et temporelle. On peut ainsi comparer les taux de classification correcte obtenus en fonction de la dimension de l'espace des attributs. Le résultat de cette comparaison est synthétisé dans le tableau II, qui présente l'évolution du pourcentage moyen de classification correcte pour chaque individu sur toutes les sessions lorsqu'on passe d'une configuration de résolution à une autre.

	A	B	C	D	E	F	G	H
Changement du nombre d'électrodes (64->8), taux d'échantillonnage constant								
Variation moyenne du taux par rapport au tableau I								
64->8 (240)	+10,19	-4,46	+8,89	+10,79	+2,73	+12,21	+4,92	+8,47
64->8 (20)	+9,02	-5	+8,99	+8,86	+3,77	+12,17	+5,79	+7,46
Changement du taux d'échantillonnage (240->20), nombre d'électrodes constant								
Variation moyenne du taux par rapport au tableau I								
240->20 (64)	+0,53	-1,29	-2,75	-1,75	-3,09	-2,44	-3,25	-0,53
240->20 (8)	-0,63	-1,83	-2,65	-3,68	-2,05	-2,48	-2,38	-1,53

TABLE II

VARIATION DU TAUX DE CLASSIFICATION CORRECTE (EN %) EN FONCTION DU CHANGEMENT DE RÉOLUTION SPATIALE ET TEMPORELLE

Considérons d'abord l'intérêt du changement de résolution spatiale. La sélection d'électrodes permet une augmentation très significative du taux de classification correcte pour sept des huit individus, allant jusqu'à une amélioration de 12% pour l'individu F. Nous pensons que cette amélioration est due à la diminution du bruit introduit par les électrodes non significatives, lesquelles ne sont pas totalement éliminées par la méthode d'apprentissage qui n'est pas optimale. En revanche, pour l'individu B, le passage à huit électrodes entraîne une détérioration de 4,5% du taux de classification correcte. La diminution a priori du nombre d'électrodes prises en compte est donc justifiée, si elle est réalisée en fonction des caractéristiques de l'individu.

Considérons ensuite l'intérêt de la réduction de résolution obtenue par sous-échantillonnage temporel des signaux. On constate qu'elle entraîne globalement un détérioration du taux

de bonne classification, même si cette détérioration reste limitée à environ 3% avec nos données expérimentales. Cela tend à prouver l'intérêt de conserver tous les échantillons initiaux des signaux comme attributs traités par le classifieur. Le sous-échantillonnage élimine, de façon non adaptée à l'individu, des informations disponibles initialement dans les signaux. Il est plus judicieux de laisser la technique d'apprentissage se charger de cette sélection des données significatives.

V. CONCLUSION

Dans cet article, nous avons décrit une technique de classification des réponses temporelles à des stimuli visuels qui peut aisément être intégrée dans une interface cerveau-ordinateur. Sa complexité algorithmique est faible par rapport aux techniques d'apprentissage plus complexes décrites dans la littérature. D'autre part, elle peut traiter les signaux bruts issus du système d'acquisition, sans qu'il soit nécessaire de diminuer a priori la quantité d'informations par un sous-échantillonnage des données. Nous avons montré, sur des données expérimentales, qu'en diminuant le nombre d'électrodes utilisées dans l'étape de classification on peut améliorer le taux de bonne classification de façon notable, mais que la diminution de la cadence d'échantillonnage entraîne au contraire une diminution de ce taux.

REMERCIEMENTS

Les auteurs remercient la Région Nord-Pas de Calais, le FEDER, l'IRRH (Institut Régional de Recherche sur le Handicap), l'Institut National de la Santé des USA (NIH, subventions NICHD HD30146 et NIBIB/NINDS EB00856) et la fondation James S. McDonnell. Ils remercient particulièrement le Dr. Elizabeth Winter Wolpaw pour l'aide apportée à l'amélioration du manuscrit.

REFERENCES

- [1] J. R. Wolpaw, D. J. McFarland, T. M. Vaughan, and G. Schalk, "The Wadsworth Center brain-computer interface (BCI) research and development program," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 11, no. 2, pp. 1-4, 2003.
- [2] J. R. Wolpaw and D. J. McFarland, "Control of a two-dimensional movement signal by a noninvasive brain-computer interface in humans," *Proceedings of the National Academy of Science of the USA*, vol. 101, no. 51, pp. 17 849-17 854, 2004.
- [3] L. A. Farwell and E. Donchin, "Talking off the top of your head : A mental prosthesis utilizing event-related brain potentials," *Electroencephalography and Clinical Neurophysiology*, vol. 70, pp. 510-513, 1988.
- [4] D. Friedman, Y. M. Cycowicz, and H. Gatea, "The novelty P3 : an event-related brain potential (ERP) sign of the brain's evaluation of novelty," *Neuroscience & Biobehavioral Reviews, Elsevier*, vol. 25, pp. 355-373, 2001.
- [5] R. O. Duda, P. E. Hart, and D. G. Stork, *Pattern Classification, second edition*. Wiley-Interscience Publication, 2000.
- [6] R. A. Fisher, "The statistical utilization of multiple measurements," *Annals of Eugenics*, vol. 8, pp. 376-386, 1938.
- [7] F. Rosenblatt, "The perceptron : a probabilistic model for information storage and organization in the brain," *Psychological Review*, vol. 65, pp. 386-408, 1958.
- [8] G. Schalk, D. J. McFarland, T. Hinterberger, N. Birbaumer, and J. R. Wolpaw, "BCI2000 : A general-purpose brain-computer interface (BCI) system," *IEEE Transactions on Biomedical Engineering*, vol. 51, pp. 1034-1043, 2004.