

Classification de données EEG par algorithme évolutionnaire pour l'étude d'états de vigilance

Laurent Vezard^{*,**}, Pierrick Legrand^{*,**}, Marie Chavent^{*,**},
Frédérique Faïta-Aïnseba^{**}, Julien Clauzel^{**}

* IMB, UMR CNRS 5251 et INRIA Bordeaux Sud-Ouest, France
** Université Bordeaux Segalen, France
{prenom.nom}@inria.fr, frederique.faita@u-bordeaux2.fr

Résumé. L'objectif de ce travail est de prédire l'état de vigilance d'un individu à partir de l'étude de son activité cérébrale (signaux d'électro-encéphalographie EEG). La variable à prédire est binaire (état de vigilance "normal" ou "relaxé"). Des EEG de 44 participants dans les deux états (88 enregistrements), ont été recueillis via un casque à 58 électrodes. Après une étape de prétraitement et de validation des données, un critère nommé "critère des pentes" a été choisi. Des méthodes de classification supervisée usuelles (k plus proches voisins, arbres binaires de décision (CART), forêts aléatoires, PLS et sparse PLS discriminante) ont été appliquées afin de fournir des prédictions de l'état des participants. Le critère utilisé a ensuite été raffiné grâce à un algorithme génétique, ce qui a permis de construire un modèle fiable (taux de bon classement moyen par CART égal à $86.68 \pm 1.87\%$) et de sélectionner une électrode parmi les 58 initiales.

Introduction

L'activité électrique cérébrale se décompose en différents rythmes oscillatoires identifiés par leurs bandes de fréquences caractéristiques. Les principaux rythmes sont, par ordre croissant de fréquence : delta (1-3,5 Hz), thêta (4-8 Hz), alpha (8-12 Hz) et bêta (12-30 Hz). Les ondes alpha sont caractéristiques d'un état de veille diffuse chez les sujets sains. Ce sont ces ondes qui seront donc particulièrement observées et quantifiées pour discerner les états de veille normale et relaxée qui sont recherchés dans cette étude expérimentale. Le rythme oscillatoire alpha se manifeste sous forme de bouffées caractéristiques observables visuellement sur les ÉlectroEncéphaloGrammes (EEG), en particulier au-dessus des aires cérébrales occipitales, à l'arrière du crâne, mais aussi, dans certaines conditions, au niveau de sites d'enregistrements plus frontaux. La distribution de l'activité électrique corticale est donc à prendre en compte dans la caractérisation d'un rythme oscillatoire. Cette distribution peut être comparée entre les différentes études rapportées dans la littérature grâce à l'utilisation d'un système conventionnel de placement des électrodes, défini dans Jasper (1958) et représenté figure 1.

L'activité électrique cérébrale est non linéaire et non stationnaire, comme précisé dans Subasi et al. (2005). Les signaux EEG sont donc variables dans le temps. Ils sont quasiment systématiquement pré-traités avant d'être utilisés. Certains auteurs comme Ben Khalifa et al.

Classification de signaux EEG par algorithme évolutionnaire

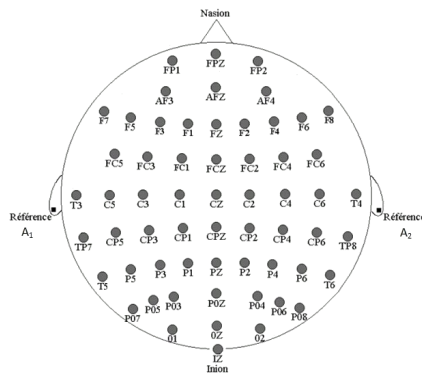


FIG. 1 – Représentation de la répartition des électrodes selon le système international 10/10

(2005) ou Cecotti et Graeser (2008) utilisent la transformée de Fourier tandis que d'autres comme Subasi et al. (2005) ou encore Hazarika et al. (1997) préfèrent utiliser une décomposition en ondelettes discrète. Shaker (2005) propose quant à lui d'utiliser dans un premier temps une décomposition en ondelettes et d'appliquer une transformée de Fourier au résultat.

La méthode de classification statistique la plus couramment utilisée pour prédire l'état de vigilance à partir de signaux EEG est l'utilisation de réseaux de neurones (Subasi et al. (2005) ou Vuckovic et al. (2002)). Cependant, l'inconvénient de cette approche est qu'elle nécessite de disposer de beaucoup plus d'individus que de variables. Pour éviter ce problème, Subasi et al. (2005) et Vuckovic et al. (2002) choisissent de découper leurs signaux en plusieurs parties, nommés "époques" (signaux de quelques secondes).

Il existe d'autres approches qui visent à utiliser d'autres outils statistiques. Par exemple, Yeo et al. (2009) montrent que l'utilisation des Supports Vecteurs Machine est pertinente lorsqu'il s'agit de classer des signaux EEG. D'autres chercheurs proposent d'utiliser des modèles de type auto-régressif (AR) (Anderson et Sijercic (1996)) ou encore des chaînes de Markov cachées (Obermaier et al. (2001)).

Il existe donc différentes approches possibles, tant au niveau du pré-traitement qu'au niveau des outils statistiques à utiliser. Dans le travail présenté ici, la décomposition en ondelettes a été privilégiée afin de pré-traiter les données et un critère en a été extrait. Pour le calcul de ce critère, les signaux ont été conservés dans leur intégralité ce qui exclut une approche similaire à Subasi et al. (2005) ou Vuckovic et al. (2002). Des méthodes usuelles de classification supervisée (arbre binaire de classification, forêts aléatoires et autres) ont été utilisées sur ce critère afin de prédire l'état de vigilance des participants. Ce critère a ensuite été raffiné à l'aide d'un algorithme génétique afin d'améliorer la qualité de la prédiction obtenue.

1 Acquisition de données

Population : les 44 participants à cette étude, dont 26 femmes, étaient âgés de 18 à 35 ans et tous droitiers, afin d'éviter les variations des caractéristiques de l'EEG dues à l'âge ou à la dominance manuelle liée à une asymétrie fonctionnelle inter-hémisphérique.

Procédure : la passation expérimentale s'effectue individuellement, dans une pièce calme où chaque participant est installé dans un siège face à un écran d'ordinateur. Elle dure environ deux heures trente au total, en incluant la pose du casque, le lavage de tête et l'entretien explicatif final avec le participant. Elle suit 5 étapes :

1. Premier EEG : ce premier enregistrement de 3 minutes, réalisé les yeux ouverts avec une croix de fixation que le participant doit regarder au centre de l'écran pour éviter de bouger les yeux, constitue l'état de référence, considéré comme l'état de vigilance normal du participant.
2. Tâche pour le recueil de la Variation Contingente Négative (VCN) : Le participant a pour consigne de signaler le plus rapidement possible, en appuyant sur la barre "espace" du clavier placé devant lui, chaque apparition d'un carré venant se substituer à la croix de fixation sur l'écran. Un signal d'avertissement sonore (bip) précède, avec un délai fixe, chaque apparition du carré, ce qui permet ainsi au participant de préparer son appui. L'EEG du participant est enregistré pendant toute la durée de la tâche, constituée de 50 paires de stimuli "S1 : bip - S2 : carré". Le temps entre deux paires de stimuli est variable. Le but de cette tâche est précisé dans le paragraphe "extraction de la VCN".
3. Séance de relaxation : pendant cette phase, le participant est entièrement guidé par une bande sonore diffusée au moyen de haut-parleurs disposés dans la pièce d'expérience. Cette bande propose au participant de réaliser trois exercices d'auto-relaxation basés sur de la décontraction musculaire et de la visualisation mentale. Le but de la séance est d'amener le participant dans un bas niveau de vigilance, qualifié d'état "relaxé".
4. Second enregistrement EEG : un enregistrement de 3 minutes d'EEG, yeux ouverts avec croix de fixation est à nouveau réalisé, supposé refléter "l'état relaxé" du participant.
5. Seconde recueil de VCN : l'exercice de réponse rapide à l'apparition de carrés sur l'écran suite à des signaux d'avertissement sonore est reproduit en suivant exactement le même protocole que lors de l'étape 2 ci-dessus.

Extraction de la VCN : elle est réalisée en appliquant la méthode des potentiels évoqués. Une moyenne de tous les tracés recueillis suite à l'apparition du signal avertisseur (S1 : bip) jusqu'à celle du signal déclencheur de la réponse d'appui (S2 : carré) est effectuée. Ainsi, une déflexion négative du tracé, appelée Variation Contingente Négative (VCN, Walter et al. (1964)) émerge du bruit de l'activité électrique corticale générale. La VCN a la propriété de diminuer en amplitude quand le participant est moins vigilant, que cela soit parce qu'il est distrait (Tecce (1979)), privé de sommeil (Naitoh et al. (1971)) ou en train de s'endormir (Timsit-Berthier et al. (1981)). Ce résultat fondamental est illustré par la figure 2.

La comparaison de l'amplitude de la VCN entre les tâches réalisées aux étapes 2 et 5 sert de test pour décider si le participant a bien changé d'état, donc s'est effectivement relaxé. Seuls les cas positifs, dont l'amplitude de la VCN a significativement diminué, ont ainsi été sélectionnés pour l'analyse comparative de leurs EEG bruts (étapes 1 et 4) alors validés comme étant respectivement des enregistrements EEG en état "normal" et "relaxé".

Données : elles sont constituées des 26 enregistrements de 3 minutes d'EEG bruts pour les 13 participants sélectionnés après l'étude de leurs VCN (un EEG "normal", obtenu lors de l'étape 1, et un EEG "relaxé", enregistré lors de l'étape 4, par participant). Chaque enregistrement

Classification de signaux EEG par algorithme évolutionnaire

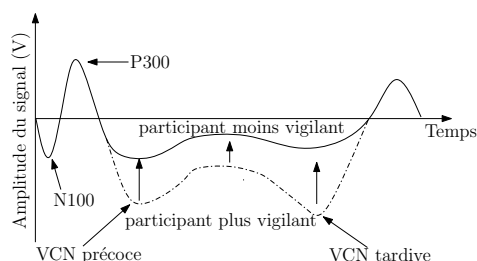


FIG. 2 – Représentation de la variation d'amplitude de la VCN en fonction de l'état de vigilance d'un participant

contient les variations de potentiel électrique recueillies avec une fréquence d'échantillonnage de 256 Hz (système d'acquisition Deltamed) à l'aide de 58 électrodes actives disposées sur un casque d'enregistrement (ElectroCap).

2 Pré-traitement des données

Les données sont en 3 dimensions (temps, électrodes, participants). L'approche envisagée est d'extraire un critère en 2 dimensions afin de pouvoir appliquer des outils de classification usuels. Pour ce faire, l'énergie du signal, obtenue par la décomposition en ondelettes, va être considérée. D'autres approches ont été testées pour pré-traiter les données (exposant de Hölder ponctuel, extraction des ondes alpha). Cependant, ces pré-traitements se sont révélés moins efficaces que le critère des pentes. Par souci de concision, ces approches ne seront pas décrites dans ce document.

La décomposition en ondelettes : la décomposition en ondelettes (Daubechies (1992) et Mallat (2008)) est une méthode très utilisée en analyse du signal. Son principal avantage est de permettre d'analyser l'évolution du contenu fréquentiel du signal dans le temps. Elle est donc plus adaptée que la transformée de Fourier pour l'analyse des signaux non stationnaires.

Une ondelette est une fonction $\psi \in L^2(\mathbb{R})$ telle que $\int_{\mathbb{R}} \psi(t) dt = 0$. La transformée en ondelettes continue d'un signal X peut s'écrire :

$$X(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} X(t) \psi^* \left(\frac{t-b}{a} \right) dt.$$

Dans cette expression, le terme a est appelé facteur d'échelle. C'est un terme qui représente l'inverse de la fréquence du signal. Le terme b est un terme de translation. Il introduit un décalage temporel. La fonction ψ est appelée ondelette mère et ψ^* est le complexe conjugué de ψ . L'ondelette mère est généralement une fonction continue et différentiable à support compact. Il existe plusieurs ondelettes mères telles que les ondelettes Daubechies ou Coiflets par exemple.

Il est également possible de définir la transformée en ondelettes discrète en partant de la précédente formule et en discrétisant les paramètres a et b . Ainsi, soit $a = a_0^j$, où a_0 est le paramètre de résolution tel que $a_0 > 1$ et $j \in \mathbb{N}$ et soit $b = kb_0 a_0^j$, où $k \in \mathbb{N}$ et $b_0 > 0$. Il est très fréquent de considérer la transformée en ondelettes dite "dyadique" qui correspond au cas

où $a_0 = 2$ et $b_0 = 1$. Dans ce cas, $j = 1, 2, \dots, n$, où n est le logarithme en base 2 du nombre de points formant le signal et $k = 1, 2, \dots, 2^{j-1}$. La transformée en ondelettes discrète dyadique s'écrit :

$$x_{j,k} = 2^{-\frac{j}{2}} \int_{-\infty}^{\infty} X(t)\psi(2^{-j}t - k)dt$$

où j est le niveau de décomposition (ou l'échelle) et k le décalage temporel. Le nombre de niveaux de décomposition maximal n correspond au \log_2 du nombre de points formant le signal. La transformée en ondelette discrète est plus rapide que la version continue en permettant tout de même une reconstruction exacte du signal initial par transformation inverse. La grille dyadique donne une représentation spatio-fréquentielle de la transformée en ondelettes discrète dyadique (figure 3). Sur cette figure, l'axe des abscisses correspond au temps et celui des ordonnées aux fréquences. Les ronds correspondent aux coefficients d'ondelettes. Les points du signal se situent en dessous du niveau le plus bas de décomposition. À chaque niveau supplémentaire (échelle supplémentaire), la fréquence est multipliée par deux.

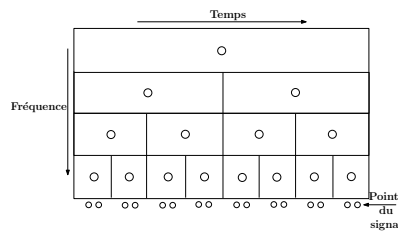


FIG. 3 – Grille dyadique

Énergie d'un signal : la décomposition en ondelettes permet également de calculer l'énergie d'un signal pour chaque niveau de décomposition. Ainsi, l'énergie e_j^2 du signal X à l'échelle j est donnée par :

$$e_j^2 = \sum_{k=1}^{2^{j-1}} x_{j,k}^2, \forall j \in \{1, \dots, 2^{j-1}\}.$$

En d'autres termes, à partir de la grille dyadique, l'énergie associée à l'échelle j (niveau de décomposition j) est égale à la somme des carrés des coefficients de la ligne j . L'utilisation de l'énergie du signal fait perdre la temporalité. Il aurait été possible d'obtenir ce résultat à l'aide d'une transformée de Fourier, cependant, la décomposition en ondelettes discrète offre plus de possibilités pour la suite des travaux.

Critère des pentes : pour un participant i donné ($i = 1, \dots, 13$) dans un état donné (normal ou relaxé), chaque électrode fournit un signal X^m ($m = 1, \dots, 58$). Une décomposition en ondelettes discrète dyadique est réalisée sur ce signal en considérant 15 échelles. À partir des coefficients obtenus, les énergies du signal sont calculées pour chacune des fréquences. La figure 4 représente ces énergies en fonction de la fréquence.

Classification de signaux EEG par algorithme évolutionnaire

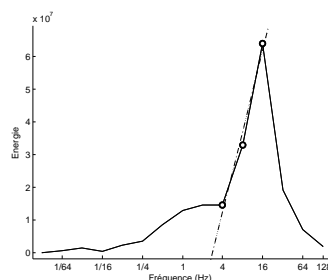


FIG. 4 – Représentation des énergies du signal X^m , obtenues à l'aide d'une décomposition en ondelettes discrète dyadique de X^m , en fonction de la fréquence. Une régression est effectuée entre 4, 8 et 16 Hz (droite en pointillés)

Les ondes Alpha sont comprises entre 8 et 12 Hz. Ainsi, conformément à la littérature, seules les énergies calculées pour 4, 8 et 16 Hz vont être utilisées (cercles noirs sur la figure 4). Une régression simple va alors être effectuée (droite en pointillés sur la figure 4) et le coefficient directeur va être conservé. Ce coefficient est représentatif de l'évolution de l'énergie du signal dans les fréquences considérées. En répétant ce procédé pour chacune des électrodes, 58 coefficients (un par électrode) sont obtenus pour un individu dans un état donné. Ainsi, une matrice de taille 26×58 est obtenue, représentant le critère des pentes. Les méthodes usuelles de classification vont pouvoir être utilisées sur cette matrice en 2 dimensions.

3 Premiers résultats

La pertinence du critère des pentes est illustrée sur la figure 5. La figure 5(a) fournit pour chaque participant, dans son état de vigilance "normal" et son état de vigilance "relaxé", la somme du critère des pentes sur toutes les électrodes. Il apparaît que, pour un individu donné, le critère des pentes est presque toujours plus faible lorsque l'individu est dans l'état normal que lorsqu'il est dans l'état relaxé. Ainsi, en comparant pour un individu donné les valeurs du critère des pentes pour l'état relaxé et normal, il est possible de distinguer efficacement les deux états. Cependant, pour un nouvel individu dont un seul enregistrement est connu, le problème reste à traiter. La seconde figure (donnée en 5(b)) fournit pour chaque électrode, la somme du critère des pentes des participants en état de vigilance "normal" et des participants en état de vigilance "relaxé". Le constat précédent se retrouve également au niveau des électrodes. En effet, pour une électrode donnée, le critère des pentes est plus élevé lorsque l'on considère l'enregistrement obtenu par cette électrode après la relaxation. Ainsi, le critère des pentes permet de discriminer efficacement les deux états de vigilance pour un individu donné. Cependant, il existe une forte variabilité inter-individuelle.

Les méthodes de classification usuelles ont été utilisées dans un premier temps afin de prédire l'état de vigilance des participants. Les performances prédictives des k plus proches voisins (notés KPPV), arbres binaires de décision (CART), forêts aléatoires (FA), PLS discriminante (PLSDA) et sparse PLS discriminante (SPLSDA) ont été étudiées. Le logiciel R et

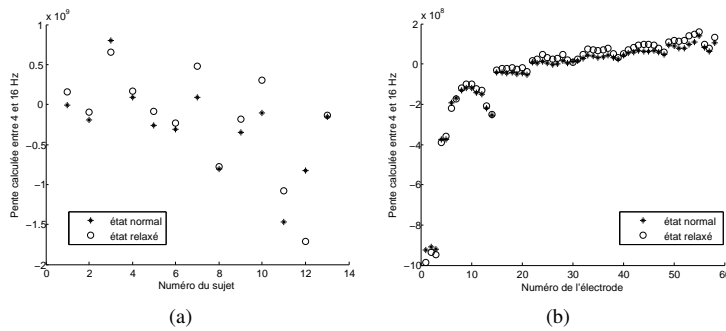


FIG. 5 – Critère des pentes sommé sur toutes les électrodes pour chacun des 13 individus (à gauche) et sur tous les participants pour chaque électrode (à droite)

ses packages "class", "rpart", "randomForest", "pls" et "spl" ont respectivement été utilisés pour tester ces méthodes. Les forêts aléatoires ont été appliquées en fixant le nombre d'arbres à 15000 et en laissant les autres paramètres par défaut. Les paramètres des autres méthodes ont été fixés en appliquant une validation croisée de type 10 folds sur l'échantillon d'apprentissage (nombre de voisins pour les k plus proches voisins, complexité de l'arbre pour la méthode CART, nombre de composantes pour la PLS discriminante, nombre de composantes et valeur du paramètre de seuillage pour la sparse PLS discriminante). La méthode PLS a été adaptée à la classification en recodant la variable à prédire (état de vigilance) à l'aide d'une matrice formée par les indicatrices des modalités ("normal" ou "relaxé"). Pour pouvoir comparer les résultats, ces méthodes ont été évaluées sur les mêmes échantillons (apprentissage et test). Une validation croisée de type 5 folds a été utilisée pour calculer un taux de bon classement. Cette opération a été répétée 100 fois afin d'étudier la stabilité des méthodes de classification vis à vis du découpage.

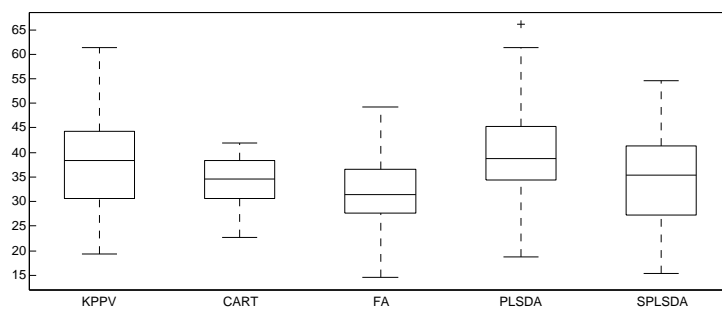


FIG. 6 – Taux de bon classement pour les méthodes de classification sur le critère des pentes

Les résultats obtenus sont illustrés par les boxplots en figure 6. Il apparaît que les taux de bon classement moyens sont décevants. Ils ne dépassent pas les 40% pour la majorité des méthodes. De plus, les importants écarts types obtenus témoignent de l'influence du découpage

sur les résultats. Dans le cas d'une prédiction binaire, ces résultats ne peuvent être satisfaisants. Il est probable que la variabilité inter-individuelle constatée sur la figure 5(a) ait nui aux performances des méthodes de classification. Cette variabilité inter individuelle est très difficile à inclure dans les méthodes de classification avec les données disponibles pour cette étude. L'étape de pré-traitement a donc été raffinée afin d'obtenir de meilleurs taux de bon classement. Plus précisément, un algorithme génétique a été défini pour le calcul des pentes afin de déterminer l'électrode et les fréquences qui fournissent la meilleure discrimination.

4 Amélioration par algorithme génétique

Le but est donc d'améliorer le critère des pentes. En raison des résultats décevants obtenus en réalisant une régression sur les énergies calculées entre 4 et 16 Hz (ondes alpha), l'approche va être révisée. La meilleure plage de fréquences (non nécessairement contiguës) pour effectuer la régression va être recherchée. De la même façon, jusqu'à présent toutes les électrodes ont été conservées. Cependant, un des objectifs de ce travail est d'éliminer des électrodes afin de diminuer le temps de pose du casque. Ainsi, la meilleure combinaison électrode / fréquences, au sens de la qualité de la prédiction obtenue, est recherchée. Il y a 58 électrodes et 15 niveaux de décomposition. Il existe donc $58 * 2^{15} = 1900544$ façons de choisir une électrode et une plage de fréquence. Pour éviter de les parcourir de manière exhaustive, l'approche envisagée est d'utiliser un algorithme génétique.

Principe général d'un algorithme génétique : il s'agit d'un algorithme d'optimisation basé sur la théorie darwinienne de l'évolution (Holland (1975) et De Jong (1975)). L'idée générale est qu'une population de solutions potentielles va améliorer ses caractéristiques au fil du temps par le biais de mutations génétiques et de croisements afin de s'adapter au mieux à son environnement. D'un point de vue algorithmique, le principe général est donné par la figure 7.

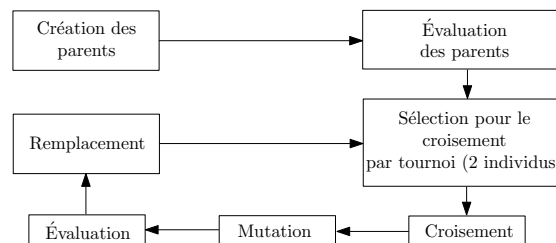


FIG. 7 – Boucle évolutionnaire

Le but de ces algorithmes est d'optimiser une fonction d'évaluation (fitness) sur un espace de recherche. Des individus (appelés "parents" et correspondant à des points de l'espace de recherche) vont être créés afin de former une population diversifiée. Ils sont représentés par des génomes (codes binaires ou réels, de taille fixe ou variable). À l'aide d'opérateurs de mutation et de croisement, les parents vont donner naissance à des enfants qui vont être évalués à leur tour. Les meilleurs individus (enfants et/ou parents inclus) vont survivre. L'algorithme est itéré jusqu'à ce que tous les individus soient identiques (convergence de l'algorithme).

4.1 Choix algorithmiques

Dans ce travail, le génome est composé de 16 variables : la première, un entier variant de 1 à 58, caractérise le numéro de l'électrode choisie et les 15 autres, binaires, correspondent à l'inclusion (ou non) de chaque fréquence dans la régression pour le calcul du critère des pentes. Un exemple de génome est donné figure 8. Chaque génome définit l'électrode et les fréquences sur lesquelles effectuer la régression.

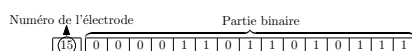


FIG. 8 – Exemple d'un génome dans l'algorithme génétique

Principales fonctions : les principales fonctions sont la mutation et le croisement. Pour créer un enfant, 2 parents sont aléatoirement sélectionnés. Un tournoi est effectué afin de ne garder que le meilleur individu (celui possédant la meilleure évaluation). La pression de sélection n'est pas forte (le meilleur parmi 2) afin de conserver un maximum de diversité parmi la population. La sélection et le tournoi sont répétés à deux reprises afin de disposer de deux parents "vainqueurs". Ces deux parents vont alors être croisés. L'enfant va hériter de l'électrode qui se trouve à mi chemin entre les électrodes de ses deux parents. Pour le croisement des fréquences, il s'agit d'un "et" logique un peu modifié afin d'équilibrer l'obtention de 1 et de 0. En effet, dans ce "et" modifié, lorsqu'un 1 et un 0 sont croisés (dans cet ordre), un 1 est obtenu. Une fois l'enfant créé, une mutation lui est appliquée. Chaque composante du génome de l'enfant va muter avec une probabilité de 1/8. Ainsi, chaque enfant va être, en moyenne, affecté par deux mutations. Lorsque la mutation atteint le numéro de l'électrode, cela implique le tirage aléatoire d'un nouveau numéro d'électrode pour l'enfant. Pour la partie binaire, une mutation correspond au changement de la variable binaire (le 0 devient 1 et inversement).

Fonctions d'évaluation : la combinaison électrodes / plage de fréquences qui permet de prédire au mieux l'état de vigilance des participants est recherchée. Ainsi, il paraît naturel de se baser sur le taux de bon classement (TBC). La fonction de fitness va permettre de calculer un TBC pour chaque génome. Ces derniers seront alors classés par ordre décroissant de TBC. Afin de comparer chaque génome, il faut utiliser les mêmes échantillons pour calculer le TBC. Une validation croisée de type 5 folds est utilisée. L'étape d'évaluation va être reproduite pour chaque enfant à chaque itération. Ainsi, il est nécessaire de n'utiliser, comme fonction d'évaluation, que des méthodes de classification rapides. Dans ce travail, deux méthodes d'évaluation ont été testées. La première, le single variable classifier (SVC) présentée dans Guyon et Elisseeff (2003) est une méthode permettant de réaliser une prédiction à partir d'une seule variable. La moyenne de chaque modalité (normal ou relaxé) est calculée sur les individus de l'échantillon d'apprentissage pour la variable (critère). Les individus de l'échantillon test sont alors affectés à la classe correspondant à la moyenne la plus proche. La prédiction obtenue est comparée à la réalité et donne un TBC. La seconde méthode, les arbres binaires de décision (CART), est présentée dans Breiman et al. (1984). Ici, l'algorithme est utilisé avec une seule variable ce qui garantit la rapidité d'exécution.

Classification de signaux EEG par algorithme évolutionnaire

Critère d'arrêt : l'algorithme s'arrête si l'une des trois conditions est remplie :

- Le nombre d'itérations dépasse 1000.
- Les parents sont identiques depuis 10 générations.
- Le nombre de différences parmi les parents est inférieur à 3.

Pour calculer le nombre de différences, les génomes de la population à l'itération i sont stockés dans une matrice, notée P^i . Soit P_j^i la colonne j de la matrice P^i . Pour la partie binaire, le nombre de différences pour la colonne P_j^i correspond à $\min(\# \text{ de } 0 \text{ dans } P_j^i, \# \text{ de } 1 \text{ dans } P_j^i)$. Pour le numéro de l'électrode, le nombre de différences correspond au nombre d'individus qui ont une électrode différente de l'électrode majoritairement choisie parmi la population. Pour une population donnée, le nombre de différences correspond à la somme des différences pour la partie concernant l'électrode et la partie binaire.

4.2 Résultats

L'algorithme est lancé 100 fois sous Matlab pour chaque évaluation avec 300 parents et 150 enfants. Les taux de bon classement obtenus par CART (moyenne de $86.68 \pm 1.87\%$) dépassent significativement ceux obtenus par SVC ($83.49 \pm 2.37\%$). Certains des meilleurs génomes sont à égalité à la fin de l'algorithme (du fait du faible nombre d'individus et de la méthode d'évaluation). Il est donc nécessaire de choisir un génome (BEST) parmi ceux qui obtiennent le même score. Ainsi, les meilleurs génomes à la fin de chaque lancement de l'algorithme sont stockés. Le génome qui apparaît le plus souvent est considéré comme le BEST pour la méthode d'évaluation considérée. Les deux BEST (pour CART et SVC) obtiennent un taux de bon classement égal à 89,33%. Pour CART, le BEST est obtenu en réalisant la régression entre 1/8, 1/4, 2, 4 et 64 Hz sur l'électrode F4 (zone frontale droite, voir sur la figure 1). Pour SVC, le BEST est obtenu à partir de l'électrode F2 (zone frontale droite) et la régression entre 1/32, 1/16, 2, 4, 8, 64 et 128 Hz. Les fréquences choisies pour ces génomes sont plus étendues que celles utilisées lors de l'étude préliminaire. Enfin, la population de l'algorithme évolutionnaire converge en moins de 50 itérations en moyenne pour les deux méthodes. Un tableau récapitulatif est donné en table 1.

Méthode d'évaluation	TBC		Meilleur génome		
	moyenne	écart type	électrode sélectionnée	fréquences sélectionnées (en Hz)	TBC
CART	86.68	1.87	F4	1/8, 1/4, 2, 4 et 64	89,33%
SVC	83.49	2.37	F2	1/32, 1/16, 2, 4, 8, 64 et 128	89,33%

TAB. 1 – Tableau récapitulatif des résultats

Ces résultats montrent que les TBC obtenus par l'algorithme génétique sont meilleurs que ceux obtenus (voir figure 6) avec le critère des pentes calculé pour les fréquences entre 4 et 16 Hz (ondes alpha). Il apparaît également qu'il est plus pertinent d'utiliser une régression sur les fréquences 1/8, 1/4, 2, 4 et 64 pour le signal de l'électrode F4 et le classifieur CART. Pour la suite de ces travaux, cette électrode et cette plage de fréquences seront utilisées pour le calcul du critère des pentes. L'arbre de décision de CART, construit sur l'échantillon formé par les 26 signaux (13 participants de l'étude dans les deux états de vigilance) sera utilisé comme classifieur pour prédire l'état de vigilance d'un nouvel individu.

Conclusion

Dans cet article, une méthode permettant de prédire l'état de vigilance de participants à l'aide de leur activité cérébrale a été étudiée. Dans un premier temps, un critère basé sur la littérature du domaine a été envisagé. Au vu des résultats décevants obtenus avec ce critère, un algorithme génétique a été réalisé afin de le raffiner. Cela a permis d'obtenir un modèle fiable (taux de bon classement moyen égal à $86.68 \pm 1.87\%$). L'algorithme a également permis de sélectionner une électrode parmi les 58 initiales.

Il apparaît maintenant nécessaire de confronter les résultats obtenus par l'algorithme génétique aux modèles disponibles en électrophysiologie humaine. Il sera également intéressant d'augmenter le nombre de participants inclus dans l'étude. En effet, cela permettra d'améliorer la précision de l'estimation du TBC et ainsi de diminuer le nombre de génomes à égalité à la fin de l'algorithme génétique.

Il est possible d'améliorer l'algorithme génétique proposé dans cet article. En effet, l'amélioration du croisement ainsi que l'introduction de nouvelles méthodes d'évaluation sont autant de pistes qui restent à explorer. De plus, l'utilisation d'une combinaison d'électrodes optimale (au sens du TBC obtenu) est étudiée actuellement. Enfin un dernier point intéressant sera de tester l'utilisation de règles de décision permettant d'estimer, pour un nouveau sujet sa probabilité d'être dans l'état de vigilance normal ou relaxé.

Remerciements : Les auteurs veulent remercier Vérane Faure, stagiaire au sein de l'équipe, pour son aide précieuse lors de l'acquisition des données et Leonardo Trujillo pour ses conseils.

Références

- Anderson, C. et Z. Sijercic (1996). Classification of EEG signals from four subjects during five mental tasks. *Proceedings of the Conference on Engineering Applications in Neural Networks, London, United Kingdom*, 407–414.
- Ben Khalifa, K., M. Bédoui, M. Dogui, et F. Alexandre (2005). Alertness states classification by SOM and LVQ neural networks. *International Journal of Information Technology 1*, 131–134.
- Breiman, L., J. Friedman, R. Olshen, et C. Stone (1984). Classification and regression trees. *Wadsworth Advanced Books and Software*.
- Cecotti, H. et A. Graeser (2008). Convolutional neural network with embedded fourier transform for EEG classification. *International Conference on Pattern Recognition, Tampa, Florida*, 1–4.
- Daubechies, I. (1992). *Ten Lectures on Wavelets*. SIAM.
- De Jong, K. A. (1975). *An Analysis of the Behavior of a Class of Genetic Adaptive Systems*. Ph. D. thesis, University of Michigan.
- Guyon, I. et A. Elisseeff (2003). An introduction to variable and feature selection. *Journal of Machine Learning Research 3*, 1157–1182.
- Hazarika, N., J. Chen, C. Tsoi, et A. Sergejew (1997). Classification of EEG signals using the wavelet transform. *Signal Processing 59*, 61–72.

Classification de signaux EEG par algorithme évolutionnaire

- Holland, J., H. (1975). *Adaptation in Natural and Artificial Systems*. Ann Arbor, University of Michigan Press.
- Jasper, H. H. (1958). Report of the committee on methods of clinical examination in electroencephalography. *Electroencephalography and clinical neurophysiology* 10, 1 – 370.
- Mallat, S. (2008). *A Wavelet Tour of Signal Processing*. (3rd ed.). Academic Press.
- Naitoh, P., L. C. Johnson, et A. Lubin (1971). Modification of surface negative slow potential (CNV) in the human brain after total sleep loss. *Electroencephalography and Clinical Neurophysiology* 30, 17–22.
- Obermaier, B., C. Guger, C. Neuper, et G. Pfurtscheller (2001). Hidden markov models for online classification of single trial EEG data. *Pattern recognition letters* 22, 1299–1309.
- Shaker, M. (2005). EEG waves classifier using wavelet transform and fourier transform. *International Journal of Biological and Life Sciences*, 85–90.
- Subasi, A., M. Akin, K. Kiyimik, et O. Erogul (2005). Automatic recognition of vigilance state by using a wavelet-based artificial neural network. *Neural Comput and Applic* 14, 45–55.
- Tecce, J. J. (1979). A CNV rebound effect. *Electroencephalography and Clinical Neurophysiology* 46, 546–551.
- Timsit-Berthier, M., A. Geronio, et H. Mantanus (1981). Inversion de polarité de la variation contingente négative au cours d'état d'endormissement. *EEG Neurophysiol* 11, 82–88.
- Vuckovic, A., V. Radivojevic, A. Chen, et D. Popovic (2002). Automatic recognition of alertness and drowsiness from EEG by an artificial neural network. *Medical Engineering and Physics* 24, 349–360.
- Walter, W. G., R. Cooper, V. Aldridge, W. C. McCallum, et A. Winter (1964). Contingent negative variation : An electric sign of sensorimotor association and expectancy in the human brain. *Nature* 203, 380–384.
- Yeo, M., X. Li, K. Shen, et E. Wilder-Smith (2009). Can SVM be used for automatic EEG detection of drowsiness ? *Safety Science* 47, 115–124.

Summary

The goal of this work is to predict the alertness of an individual by analyzing the brain activity (electroencephalographic data EEG) captured through 58 electrodes. Alertness is characterized as a binary variable that can be in a "normal" state or "relaxed" state. We collected data from 44 subjects in both states of alertness, giving a total of 88 records. After a pre-processing step and data validation, we analysed each record using a proposed "slope criterion" in order to discriminate the alertness states. Afterwards, several common methods for supervised classification (k nearest neighbors, decision trees (CART), random forests, PLS and discriminant sparse PLS) were applied as predictors for the state of alertness of each subject. The proposed "slope criterion" was further refined using a genetic algorithm to select the most important EEG electrodes from the 58 that were analysed, which allowed us to build an accurate predictive model that achieved a classification accuracy of $86.68 \pm 1.87\%$ when combined with the CART classifier.