

# Analyse des EEG pour les interfaces cérébrales

Mayssa Hammami<sup>a</sup>, Sylvain Chevallier<sup>a</sup>

<sup>a</sup>LISV - Université Versailles-St Quentin

## Abstract

Dans les unités de soins intensifs les patients ont souvent une assistance respiratoire mécanique. En absence de communication, le patient (intubé ou inconscient) peut rencontrer des difficultés et un inconfort respiratoire. Dans le présent projet on propose, à partir des EEG, un outil de rehaussement et de classification du signal d'intérêt. Cet outil permettra une interface cerveau-machine (BCI) de commander automatiquement la ventilation mécanique. On introduit l'utilisation de la géométrie riemannienne et les matrices de covariance pour l'extraction de l'informations spatiales des signaux EEG. On utilise des filtres spatiaux, afin d'améliorer le signal, et on détecte les Event-Related Potential ERP. Les ERP nous sert ensuite à classifier les données.

**Keywords:** Assistance respiratoire, EEG, Géométrie Riemannienne, xDAWN, CSP, Classification des données

## 1. Introduction

Les interfaces cerveau-machine (BMI : Brain-Machine interface) sont des interfaces qui contrôlent les machines à partir des ondes cérébrales. Les BMI sont constituées d'une entrée sous forme d'un sous-système qui fait l'acquisition et la numérisation des ondes EEG (électroencéphalographique), cette acquisition est faite par des électrodes. Ensuite, un autre sous-système utilise des algorithmes pour traiter ces signaux et les traduire en commande machine. Enfin un sous-système qui assure le retour à l'utilisateur pour faciliter l'apprentissage [1]. Les BMI permettent au patient de communiquer ou contrôler son environnement extérieur sans utiliser les nerfs et les muscles comme sortie mais de commander la machine à partir des signaux cérébraux [2].

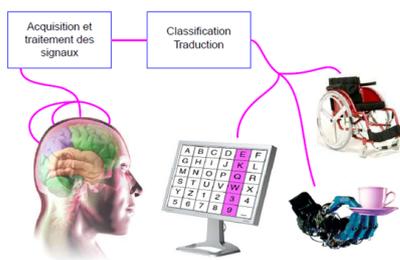


Figure 1: Structure d'une interface cérébrale, image tirée de [1]

Les patients hospitalisés utilisent souvent des ventilations mécaniques comme un support respiratoire, jusqu'à 50% des patients dans les unités de soins intensifs [3]. Ces machines peuvent perdre la synchronisation du rythme respiratoire et mènent le patient dans un état psychique d'anxiété et de dyspnée. Ces derniers sont des causes majeures des troubles de stress post-traumatique [4]. Les patients sont en effet souvent intubés et incapables de parler, voire inconscients et donc sans possibilité d'exprimer leurs troubles respiratoires. Afin de

résoudre ce problème, l'idéal est d'utiliser la sortie neurale de la respiration pour contrôler le temps et la pression de ventilation [5]. Certaines approches utilisent l'électromyographie (EMG) [6] et d'autres les EEG pour construire une interface cerveau-ventilateur. Cette méthode utilise l'activation corticale due à la compensation inspiratoire suite à une désynchronisation entre la machine et le rythme respiratoire du patient [7].

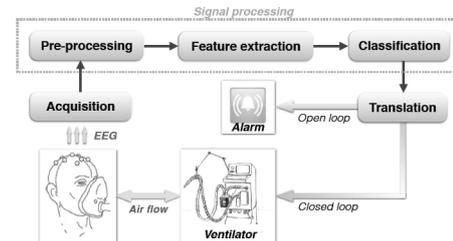


Figure 2: Diagramme en bloc de l'interface cerveau-ventilateur proposé par [7]

L'EEG est un enregistrement de l'activité électrique du cerveau au cours du temps. Il présente l'état du cerveau et les différents niveaux d'éveil. L'EEG est variable d'un sujet à un autre. Dans la pratique, l'enregistrement des EEG se fait simultanément dans des zones différentes du cuir chevelu en produisant un ensemble de mesure des différences de potentiel.

Les potentiels évoqués (*Event-Related Potential* ou ERP) sont une réponse du cerveau à un stimulus. Ils présentent une méthode puissante pour étudier l'esprit humain et le cerveau [8]. Cette variation de potentiel est tellement petite qu'on ne peut pas la distinguer par une inspection visuelle, il est nécessaire de faire la moyenne pour la distinguer de l'arrière-plan. La moyenne obtenue des ERP est constituée des variations positives et négatives appelé des pics et des ondes. Les pics positifs sont labélisés par P et les pics négatifs par N. Un nombre associé indique la latence du pic en millisecondes, par exem-

47 ple P300 est un pic positif à 300ms ou N100 est un pic négatif 89  
 48 à 100ms après l'événement concerné [9]. Les événements qui 90  
 49 génèrent des potentiels évoqués sont de différente nature, par 91  
 50 exemple après la présentation d'une image à un sujet, si celui-ci 92  
 51 reconnaît un visage dans l'image, on pourra observer une N100. 93

52 Les paramètres qui contrôlent les oscillations dans 94  
 53 les réseaux neuronaux peuvent changer en générant des 95  
 54 phénomènes nommés *Event-Related Desynchronisation* (ERD)  
 55 et *Event-Related Synchronisation* (ERS). D'une façon générale,  
 56 les réponses des neurones corticaux sont représentés par les  
 57 ERP dus à des changements extérieurs, alors que les ERD sont  
 58 liés l'activité interne des interactions locales entre les neurones  
 59 et les interneurons contrôlent les composantes fréquentielles de  
 60 l'EEG en cours [10]. Dans les expériences d'imagerie motrice  
 61 (IM), on demande au sujet de penser à bouger sa main droite  
 62 ou sa main gauche sans exécuter réellement le mouvement.  
 63 L'imagination de ce mouvement génère un ERD dans la région  
 64 pré-motrice du cerveau qui contrôle la main et un ERS dans  
 65 la région qui contrôle l'autre main. Figure 3 nous montre la  
 66 variation du signal EEG au niveau des régions pré-motrices  
 67 de la main droite et de la main gauche. L'imagerie motrice de  
 68 la main droite (couleur verte) génère une variation visible du  
 69 signal EEG au niveau de la région pré-moteur gauche. Aussi 96  
 70 on trouve un ERS au niveau au niveau de la région pré-moteur  
 71 droite lors d'une imagerie motrice de la main gauche (couleur 97  
 rouge) [11].

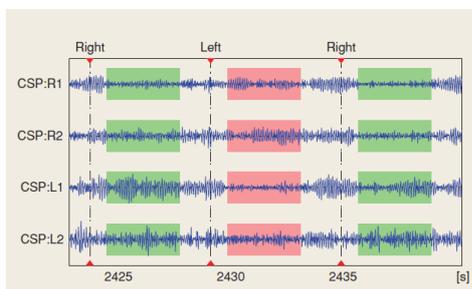


Figure 3: Les différents états des sigaux EEG au niveau du pré-moteur suite à 109  
 une expérience d'imagerie motrice [11] 110

72 La respiration génère elle aussi des ERP et des ERD/S, mais 113  
 73 pas dans le cas de la respiration naturelle. Un ERP est visi- 114  
 74 ble, composé d'un N100 et d'un P300, mais uniquement lors- 115  
 75 que la respiration est retenue ou dans le cas d'un inconfort re- 116  
 76 spiratoire. Il est possible d'observer un ERD, appelé potentiel 117  
 77 pré-inspiratoire (PPI) juste avant l'inspiration. Ainsi, on peut- 118  
 78 détecter la gêne ou l'inconfort respiratoire à partir des, ERP, des 119  
 79 PPI. Évidemment, il est aussi possible de détecter cette gêne à 120  
 80 partir des signaux musculaires, mais les données capteurs sont 121  
 82 complexes à analyser. 122

83 Pour les expériences menées dans ce travail, la respiration 123  
 84 est détectée à partir d'un capteur EtCO2 qui mesure la con- 124  
 85 centration finale de CO2 respiratoire et le taux de respiration. 125  
 86 Ce capteur utilise le principe de la spectroscopie d'absorption 126  
 87 infrarouge pour déterminer la concentration de CO2 (DirectIn- 127  
 88 dustry). 128

Le rapport est organisé de la façon suivante, la section 2  
 présente les travaux pertinents sur le traitement de signal en  
 EEG ainsi que les approches existantes en BCI pour la respira-  
 tion. La section 3 explique la contribution du présent projet et  
 les difficultés rencontrées. Ensuite, les sections 4 et 5 détaille  
 l'expérience faite à l'hôpital Raymond-Poincaré de Garches et  
 les résultats obtenues par l'outil proposé. Enfin, dans la dernière  
 section on trouve une conclusion et perspective.

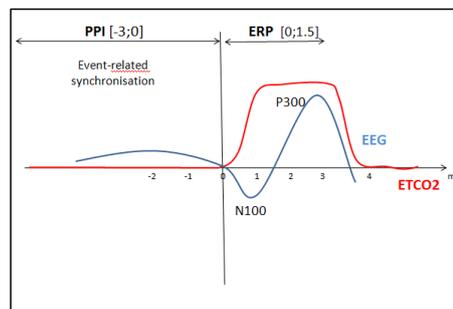


Figure 4: Schéma explicatif

## 2. Travaux connexes

98 Le domaine de la commande des BCI avec des signaux EEG  
 99 est devenu un centre d'intérêt scientifique majeur [12]. Au-  
 100 jourd'hui plusieurs algorithmes existent pour mieux traiter les  
 101 EEG et les transformer en commande machine [13]. Cependant,  
 102 il y a plusieurs verrous scientifiques pour les BCI comme les er-  
 103 reurs de détection des ondes cérébrales par les algorithmes dûs  
 104 à la variabilités des ondes cérébrales entre les utilisateurs [14]  
 105 ou le rapport signal sur bruit faible et l'existence de nombreu-  
 106 ses sources de bruit [15]. La variabilité temporelle des ondes  
 107 cérébrales d'un utilisateur, de l'ordre de l'heure, est aussi un  
 108 facteur de complexité. Plusieurs approches réussite propose à  
 cet effet de travailler avec les matrices de covariances au lieu de  
 traiter directement l'espace d'entrée.

### L'algorithme xDAWN

L'algorithme xDAWN [15] permet d'améliorer la détection  
 de potentiels évoqués en estimant un filtre spatial. Une  
 expérience utilisant une interface cerveau-machine basé sur les  
 P300 montre la possibilité de commander un ordinateur ou  
 n'importe quelle machine à partir de l'activité cérébrale. Cete  
 expérience permet au patient d'épeler les lettres sans utiliser  
 ses muscles. Elle a été réalisé sur 3 sujets males (deux français  
 et un allemand) qui n'ont pas de maladie neurologique et n'ont  
 jamais eu une expérience similaire. Le patient choisi les mots à  
 prononcer sur l'écran d'un ordinateur en choisissant des lett-  
 res séquentiels dans une matrice 6 × 6. La concentration du  
 patient sur une lettre, qui est concentré sur la tâche, entraine  
 l'apparition d'un potentiel évoqué qui correspond à un pic po-  
 sitif après 300ms du stimulus, un P300.

La Figure(a) présente l'image affichée sur l'écran pour le  
 sujet et la Figure (b) représente le signal EEG au niveau de  
 l'électrode Cz: la courbe en ligne continue est la moyenne

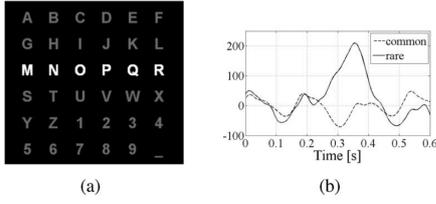


Figure 5: Image affichée sur l'écran et signal EEG[15]

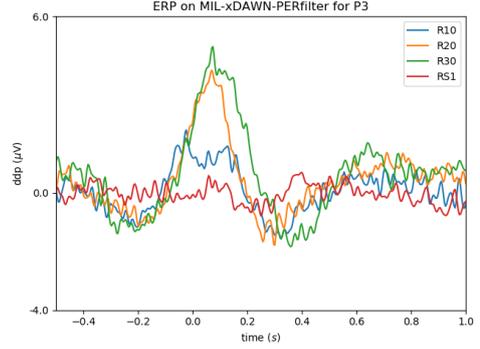


Figure 7: Signal EEG filtré avec l'algorithme xDawn-Sujet "MIL" électrode P3

129 lors d'un stimulus alors que la courbe en trait discontinu est  
 130 la moyenne du signal en absence de stimuli. La principal prob-  
 131 lème est que les signaux EEG enregistrés contiennent les po-  
 132 tentiels évoqué P300 mais aussi d'autres signaux liés à l'activité  
 133 cérébrale, musculaire... Par conséquent le rapport signal bruit  
 134 SNR du potentiel P300 devient très faible et la détection de  
 135 l'événement devient très difficile.

136 L'algorithme xDAWN permet d'avoir une estimation du  
 137 sous-espace évoqué (où se trouvent la majorité des P300) simple  
 138 et non supervisé. Par cette méthode les potentiels évoqués  
 139 s'améliorent en projetant le signal brut EEG sur les sous-  
 140 espaces estimés.

141 Soit  $x_j(t)$  le signal EEG enregistré par la  $j^{\text{ème}}$  électrode en  
 142 fonction de temps.  $X \in \mathbb{R}^{N_t \times N_s}$  la matrice des signaux EEG en-  
 143 registrés et ayant comme entré  $x_j(i)$  où  $N_t$  est la durée de l'essai  
 144 et  $N_s$  est le nombre d'électrode utilisées dans l'expérience. Soit  
 145  $a_j(t)$  est le signal ERP en fonction de temps et soit  $A \in \mathbb{R}^{N_t \times N_s}$   
 146 la matrice des signaux ERP ayant (i,j)ème entré  $a_j(i)$ . Le fait  
 147 que le signal contient un ERP, on peut avoir le modèle suivant:

$$X = DA + N$$

148  $D \in \mathbb{R}^{N_t \times N_e}$  est une matrice dont la première ligne est définie  
 149 par  $D_{\tau_k,1} = 1$  ou  $\tau_k$  est le début du  $k^{\text{ème}}$  stimulus avec  $1 < k <$   
 150  $K$ ,  $K$  est le nombre total des stimuli. Alors que tous les autres  
 151 éléments de la matrice  $D$  sont nuls.

152 On a appliqué l'algorithme xDAWN sur un enregistrement  
 153 des signaux EEG de l'électrode P3 (se situe dans la région ar-  
 154 rière gauche du crâne) d'un sujet qui s'appelle "MIL". On peut  
 155 remarquer la différence entre le signal brut ,qui est trop bruité,  
 et le signal filtré qui nous montre bien le pic du ERP.

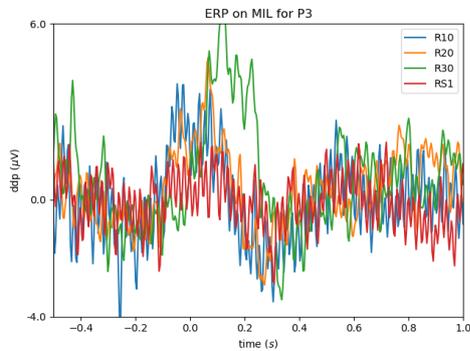


Figure 6: Signal EEG brut du sujet "MIL" électrode P3

### Common Spatial Pattern (CSP)

159 Le CSP est un algorithme qui est très utilisé dans domaine  
 160 du pré-traitement des signaux EEG. C'est une technique qui  
 161 analyse les données multi-entrées et qui s'appuie sur deux con-  
 162 ditions (deux classes). Il représente un filtre spatial qui a pour  
 163 but de chercher des combinaisons linéaires entre les électrodes  
 164 pour maximiser la variance entre les classes. Le CSP est ef-  
 165 ficace dans la détection des ERD, tout en diminuant la di-  
 166 mension des données [16]. Une classification s'appuyant sur  
 167 prétraitement par CSP exige un choix du nombre de filtre, qui  
 168 est un hyperparamètre, c'est-à-dire qui affecte directement le  
 169 résultat de la classification. L'approche du CSP vise à constru-  
 170 ire un filtre spatial optimal,  $W = [w_1, \dots, w_N]$ , à partir des si-  
 171 gnaux  $X = [x_1, \dots, x_N]^T$  où  $N$  est le nombre d'électrodes. Le  
 172 signal filtré est  $X_{CSP} = [x_{csp1}, \dots, x_{cspN}]^T$  suivant la transfor-  
 173 mation  $x_{cspj} = w_j^T X$ ,  $j = [1, \dots, N]$  où  $w_j$  est un vecteur propre qui  
 satisfait:

$$w_j^T C^L w_j = \lambda_j^L, w_j^T C^K w_j = \lambda_j^K, \lambda_j^L + \lambda_j^K = 1$$

174 où  $C^L$  et  $C^K$  sont les matrices de covariances estimées de deux  
 175 classe (dans notre étude inspiration et expiration) des signaux  
 176 EEG [17]. On présente dans la figure 8 un exemple de filtrage  
 177 CSP en 2D. On a deux séries d'échantillons: la première série  
 178 est représentée par des croix s et la deuxième est représentée par  
 179 des cercles bleus. Dans la figure (a), on visualise la distribution  
 180 des données avant le filtrage. Les deux ellipses montrent les co-  
 181 variances estimées et les lignes pointillées montrent la direction  
 182 des projections CSP  $w_j(j = 1, 2)$ . Dans la figure (b) on trouve  
 183 la distribution des échantillons après filtrage CSP. Sachant que  
 184 les deux classes ne sont pas corrélées en même temps, l'axe hor-  
 185 izontal donne la plus grande variance dans la classe rouge et la  
 186 petite variance dans la classe bleue. Pour l'axe vertical la plus  
 187 grande variance dans la classe bleue et la plus petite variance  
 188 dans la classe rouge [11].

### Géométrie Riemannienne

189 Dans le domaine de l'apprentissage automatique et du trai-  
 190 tement de signal, une approche courante est de poser le pro-  
 191 blème en terme géométrique pour développer des programmes  
 192 et optimiser des solutions. Les matrices symétriques définies  
 193 positives (SPD) offrent un espace géométrique où il est possi-  
 194 ble de développer de tels travaux. Les matrices de covariance  
 195

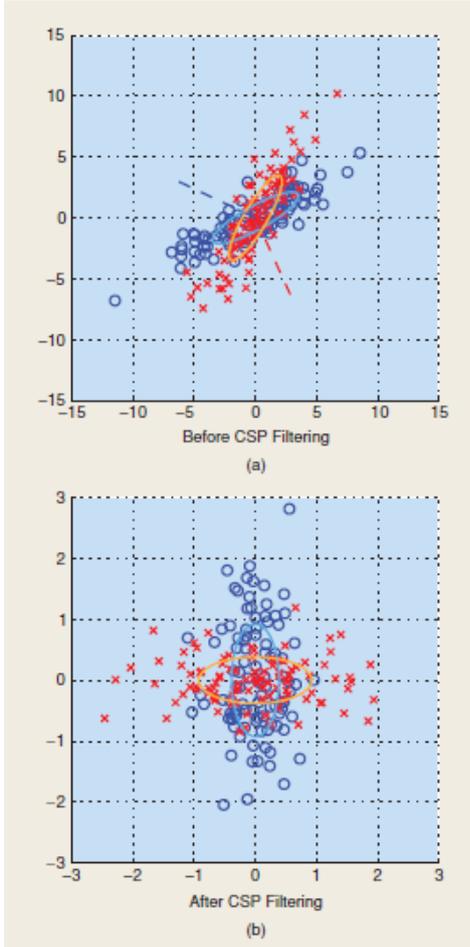


Figure 8: Exemple de filtre CSP [11]

196 sont dans un sous-espace des matrices SPD, qui lui aussi est un  
197 sous-espace de l'espace Euclidien.

198 Les signaux EEG sont généralement analysés sur une cour-  
199 te durée de temps, où se trouve le ERP ou le ERD, de l'ordre  
200 de la seconde. Soit  $X \in R^{E \times T}$  une époque où  $E$  est le nombre  
201 d'électrodes et  $T$  la durée de l'époque. La matrice de covariance  
202  $\Sigma$  appartient à [18]:

$$M_c = \{\Sigma \in R^{C \times C} : \Sigma = \Sigma^T \text{ and } X^T \Sigma X > 0, \forall X \in R^C / 0\}$$

203 L'intérêt de travailler dans le sous-espace des matrices de co-  
204 variance est qu'il est possible d'utiliser des distances qui sont  
205 invariantes à la congruence. Dans le cas des EEG, cela signifie  
206 que la distance ne change pas, quelque soit la recombinaison  
207 linéaire des électrodes ou quelque soit le filtre spatial appliqué  
208 (comme xDAWN ou CSP). En pratique, cela permet donc de se  
209 passer de l'étape de prétraitement qui vise à déterminer le meil-  
210 leur filtre spatial possible pour un utilisateur et une situation  
211 donnés.

212 Dans le domaine de la ventilation mécanique un outil a été  
213 développé, par [7] pour détecter l'inconfort respiratoire en ana-  
214 lysant les signaux EEG. Cette approche utilise la géométrie

215 Riemannienne. Ainsi, les matrices de covariances permettent  
216 la classification des données respiratoires. Cette étude a été  
217 développée en se basant sur l'imagerie motrice et la détection  
218 de la désynchronie respiratoire à partir des ERD et ERS.

### 219 PyRiemann

220 PyRiemann est une librairie d'apprentissage de Python qui  
221 permet la classification des biosignaux avec la géométrie Rie-  
222 manienne. En utilisant la géométrie des matrices de covariance,  
223 PyRiemann permet de fournir une interface de classification et  
224 manipulation des signaux multivariés comme les EEG, EMG...

### 225 Espace Tangent

226 Soit  $P$  un point qui appartient à l'espace des matrices SPD  
227  $\mathcal{P}(n)$  qui est une variété différentiable Riemannienne  $\mathcal{M}$  [19].  
228 Pour chaque point  $P \in \mathcal{P}(n)$ , on peut donc définir un espace  
229 tangent composé par l'ensemble des vecteurs tangents de  $P$ . La  
230 dérivée à  $t = 0$  de la géodésique  $\Gamma_i(t)$  et la projection exponentielle  
231  $P_i = \exp_P(S_i)$  est le vecteur tangent  $S_i$ . La figure 9 permet  
de montrer l'espace tangent graphiquement [20].

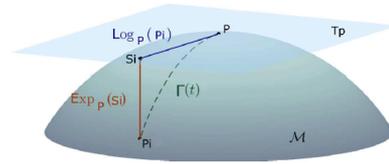


Figure 9: L'espace tangent à un point P[20]

## 232 233 3. Contributions

234 On s'intéresse à analyser les signaux  
235 électroencéphalographie EEG pour les interfaces cérébrales.  
236 Cette analyse nous permettra d'avoir un système de contrôle  
237 cérébral de l'assistance respiratoire pour les patients hospita-  
238 lisés. Dans notre démarche d'analyse, on utilise la géométrie  
239 Riemannienne pour l'analyse des EEG et la détection des ERP.  
240 La détection des ERP nous permet de repérer le déclenchement  
241 de la respiration, et selon l'amplitude on peut savoir le type  
242 de respiration. Ensuite on définit des époques (des intervalles  
243 de temps qui encadre l'ERP) afin de faire des traitements qui  
244 permettent de classifier les différentes données.

245 Il est certain qu'on a des algorithmes de rehaussement des  
signaux qui nous permettront de bien détecter les ERP et de  
définir les époques, mais ce n'est pas toujours le cas. On peut  
trouver plusieurs contraintes:

Les signaux sont différents d'un sujet à un autre. On trouve  
des signaux où, avec l'algorithme xDAWN, l'ERP n'est pas très  
visible.

Le patient peut bouger la tête ou cligner les yeux ce qui  
mène à une perturbation brusque du signal. Une électrode peut  
être mal disposée ce qui peut perturber les traitements appliqué  
au sujet. Le patient peut faire deux inspirations successives fi-  
gure 13. La détection du début d'inspiration à partir de la chaîne  
ETCO2 devient difficile.

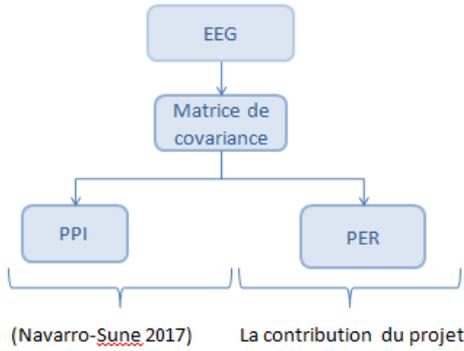


Figure 10: Schéma explicatif de la contribution du projet

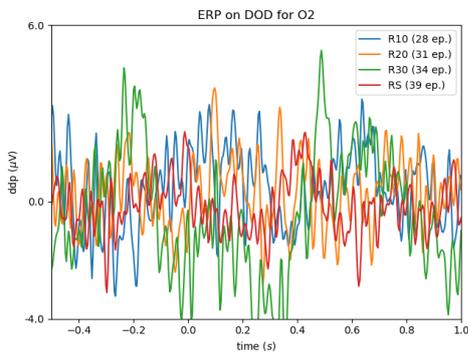


Figure 11: Signal ERP du sujet DOD enregistré avec l'électrode O2 et non filtré

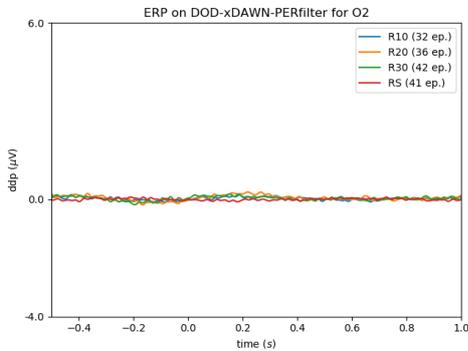


Figure 12: Le même signal mais filtré avec xDAWN.

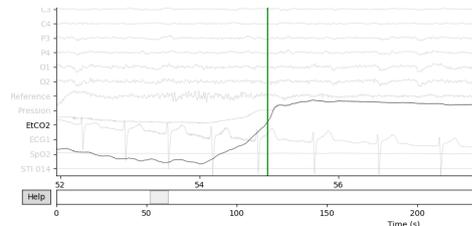


Figure 13: Détection d'une inspiration normale au niveau du capteur EtCO2

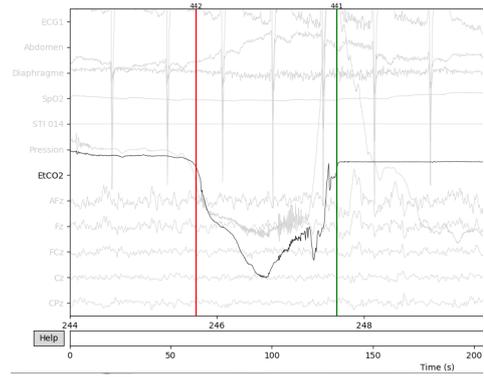


Figure 14: Détection de deux inspirations successives au niveau du capteur EtCO2

## 258 4. Expérience

259 L'expérience a été faite à l'hôpital Raymond-Poincaré de  
 260 Garches et elle a été suivie par des médecins et des techni-  
 261 ciens spécialistes en neurosciences. La base de données est con-  
 262 stituée de 15 sujets sains qui n'ont aucune expérience avec des  
 263 expériences respiratoires ou neurophysiologiques. Les sujets  
 264 sont assis sur une chaise de l'hôpital Garches et respirent d'une  
 265 façon continue dans des tubes. Notant bien que les patients  
 266 ventilés mécaniquement en soins intensifs doivent être en po-  
 267 sition semi-assis ou semi-allongée pour diminuer le risque de  
 268 l'infraction inspiratoire et augmenter le confort des patients. On  
 269 demandait aux sujets de ne pas bouger la tête ou le corps pour  
 270 avoir des bons résultats. Il s'agit de deux tubes, un tube pour in-  
 271 spiration et un autre pour l'expiration. Chaque tube est équipé  
 272 d'une valve qui contrôle le diamètre de tube d'où le niveau de  
 273 difficulté respiratoire. Le tube d'expiration est équipé aussi par  
 274 un capteur ETCO2 (Déterminer la qualité de CO2 expiré). 20  
 275 électrodes ont été placées suivant le système international 10-20.  
 276 En commandant les valves sur les deux tubes, chaque sujet sub-  
 277 issait quatre expériences : \* RS: Une respiration normale \*  
 278 R10: Une respiration assez difficile \* R20: Une respiration plus  
 279 difficile \* R30: Une respiration extrêmement difficile

## 280 5. Résultats

281 Après enregistrement des signaux EEG on a un ensemble de  
 282 données de différentes électrodes. On traite ces données en ap-  
 283 pliquant des filtres et des algorithmes de rehaussement du si-  
 284 gnal (xDAWN). Ensuite on détecte les événements de respira-  
 285 tion et expiration à l'aide du signal ETCO2. Ayant localisé les  
 286 événements qui nous intéressent, on définit des époques qui re-  
 287 présentent un intervalle de temps encadrant l'événement. On a  
 288 choisi que l'époque commence avant l'événement respiratoire  
 289 de 0.5 seconde et se termine après 1s. Ainsi on a une liste  
 290 d'époques qui contiennent des signaux EEG liés à la respiration.

291  
 292 Dans la figure 15, les événements d'inspiration sont marqués  
 293 avec des traits verts et les expirations avec des traits rouges. On

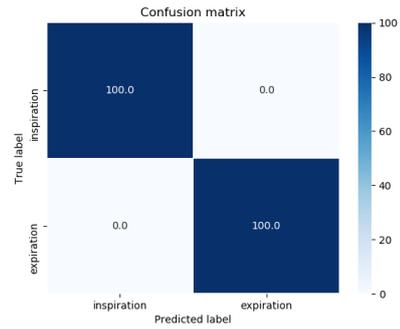
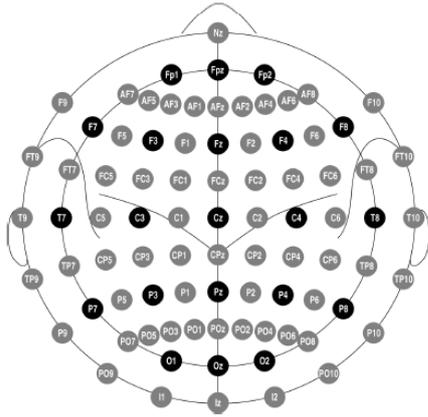


Figure 17: Matrice de confusion du sujet DOD

Figure 15: Les positions et les labels des électrodes dans le système 10-20. Cercles noirs indiquent les électrodes placées. Cercles gris indiquent les positions ajoutées dans l'extension du système 10-10.[21]

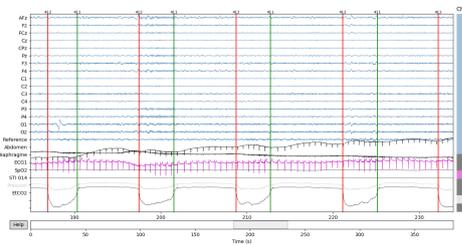


Figure 16: Signaux EEG du sujet "DOD" sous la condition R10

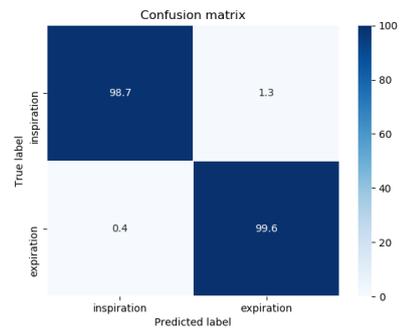


Figure 18: Matrice de confusion du sujet "BEB"

294 concatène les listes d'époque de chaque condition d'un seul sujet  
 295 pour obtenir à la fin une seule liste qui contient toutes les  
 296 époques de toutes les conditions (Rs,R10,R20,R30). Dans cette  
 297 étape, notre but est de faire un apprentissage automatique qui  
 298 permet de prédire la respiration d'un sujet donnée. Dans un premier  
 299 lieu, le programme divise la liste des époques sur 10 parties.  
 300 Il s'entraîne sur 9  $Y_{train}$  et prédit le 10<sup>ème</sup>. Si la prédiction  
 301 est égale à la condition de respiration du  $Y_{est}$ , l'occurrence  
 302 est égale à 1 si non elle est nulle. Ensuite on répète la même  
 303 expérience tout en changeant le  $Y_{est}$  et les  $Y_{train}$ . Enfin on a  
 304 une occurrence moyenne d'inspiration et de respiration. On a  
 305 utilisé dans cet apprentissage supervisé la géométrie Riemannienne  
 306 et les classifieurs suivants: analyse discriminante linéaire  
 307 dans l'espace tangent, distance minimum à la moyenne et une  
 308 regression logistique.

309 On a appliqué cet algorithme sur tous les sujet et on a trouvé  
 310 les résultats suivantes:

### 311 Classification

312 Dans cette partie on essaye de classifier les échantillons  
 313 des données suivant le type et la condition de respiration  
 314 (R10,R20,R30,RS). Pour ce fait, on a projeté les données sur  
 315 un plan tangent. Ce plan a été choisi par l'algorithme principal  
 316 component analysis (PCA) qui détermine les axes ( $\varphi_1$  et  $\varphi_2$ )  
 317 les plus représentatifs des données. Dans les figures 18 et 19 on  
 318 a projeté les données sur un plan Euclidien 2D en utilisant le  
 319 Laplacian Eigenmaps.

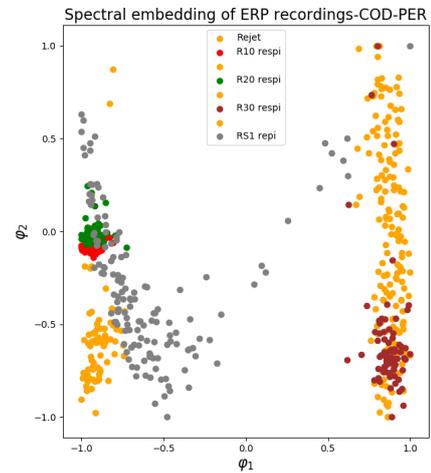


Figure 19: Projection des données ERP dans le plan tangent du sujet "COD"

325 On peut remarquer, à partir de la figure 18, qu'on peut distinguer  
 326 et classifier les différentes données ERP. Les inspirations  
 327 RS (couleur gris), R10 (couleur rouge) et R20 (couleur vert)  
 328 sont bien d'un seul côté  $\varphi \in [-1, 0]$  et les expirations correspon-  
 329 dantes de l'autre côté  $\varphi \in [0, 1]$ . On a trouvé chez 92, 85% des  
 330 sujets l'inspiration R30 ou R20 devient dans la partie  $\varphi \in [0, 1]$

Sujet	Inspiration	Expiration
BEB	98,7	99,6
COD	100,0	99,9
DIL	100,0	100,0
DOD	100,0	100,0
FAI	100,0	100,0
FAM	99,4	99,6
FRB	100,0	99,9
HEP	100,0	99,9
ISB	100,0	99,0
LIF	100,0	100,0
MAH	100,0	100,0-
MIL	100,0	100,0
RAA	100,0	99,6
SAB	99,4	99,4

Table 1: tableau des résultats en précision

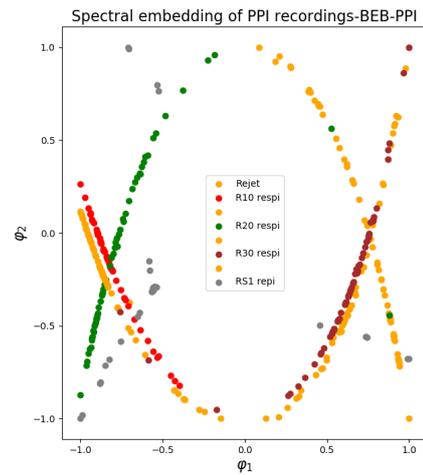


Figure 21: Projection des données PPI dans le plan tangent du sujet "BEB"

326 et expiration R30 ou R20 dans la partie  $\varphi \in [-1, 0]$  (figure 19).  
 327 Ce phénomène peut être expliqué par le changement de la condi-  
 328 tion de respiration qui devient difficile pour le sujet. Donc on  
 329 a un moyen pour détecter le l'inconfort et le type de respiration  
 330 à partir de cette classification. Cependant, cette conclusion n'est  
 331 pas toujours vrai puisqu'on a trouver un sujet SSAB" qui a tou-  
 332 tes les inspirations dans le domaine  $\varphi \in [-1, 0]$  et l'expiration  
 ou rejet dans  $\varphi \in [0, 1]$ . Mais on a toujours des classes claires.

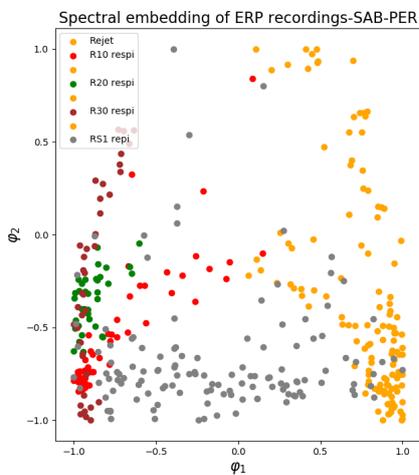


Figure 20: Projection des données ERP dans le plan tangent du sujet "SAB"

### Classification avec les PPI

333 Dans cette partie on a essayé de développer un algorithme  
 334 qui permet de classifier les données en se basant sur le Potentiel  
 335 pré-inspiratoire. Pour cette méthode on a utilisé la géométrie  
 336 riemannienne et le filtre spatial CSP. On a choisi un intervalle  
 337 de temps égale à  $[-3, 0]$  et on a projeté les échantillons sur le  
 338 plan tangent. On a appliqué cet algorithme sur tous les sujets et  
 339 on a eu les résultats suivantes.  
 340  
 341 En se basant sur les données PPI on peut trouver des clas-  
 342

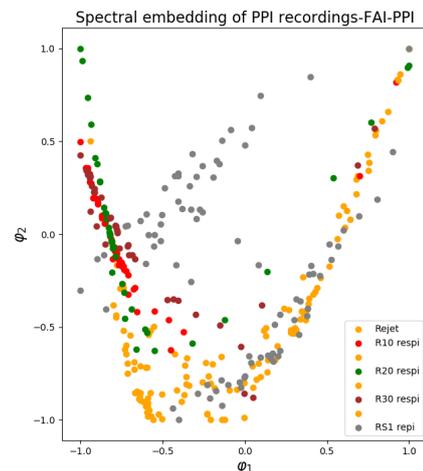


Figure 22: Projection des données PPI dans le plan tangent du sujet "FAI"

343 ses claires, figure 20, et on peut remarquer le même résultat  
 344 obtenu avec les ERP. Cependant, on remarque aussi que cette  
 345 méthode ne marche qu'avec quelque sujet ("BEB" et "COD").  
 346 Pour la plus part des sujets on a eu une mauvaise classification.  
 347 Il y a un chevauchement de différentes données de respiration  
 348 (figure 21). Notant que le l'intervalle de temps choisi pour cet-  
 349 te analyse est important. On a déterminé cette valeur après des  
 350 essais sur  $t \in [-1.5, 0]$ ,  $t \in [-1.5, -0.5]$  et  $t \in [-2.5, -1]$ .

## 6. Conclusion et Perspective

Dans ce projet de recherche un nouvel outil de détection  
 d'inconfort respiratoire a été réalisé. Cet outil se base sur  
 l'utilisation de la détection des ERP et la géométrie Riemanni-  
 enne. On a aussi utilisé des filtres spatiaux adaptatifs qui servent

356 à rehausser le rapport signal sur bruit. On a réussi avec les al-  
357 gorithmes (apprentissage supervisé) à prédire la respiration des  
358 sujets et à classifier les données ERP dans un plan tangent. Avec  
359 une base de données plus grande on peut concevoir un système  
360 qui surveille et contrôle la ventilation mécanique automatique-  
361 ment.

- 362 [1] M. hélène Bekaert, C. Botte-Lecocq, F. Cabestaing, A. Rakotomamonjy,<sup>433</sup>  
363 Les interfaces Cerveau-Machine pour la palliation du handicap moteur<sup>434</sup>  
364 sévère, Sciences et Technologies pour le Handicap 3 (1) (2009) 95–121,<sup>435</sup>  
365 doi:10.3166/sth.3.95-121, URL <https://doi.org/10.3166/2Fsth>.<sup>436</sup>  
366 3.95–121.<sup>437</sup>
- 367 [2] J. R. Wolpaw, N. Birbaumer, D. J. McFarland, G. Pfurtscheller, T. M.<sup>438</sup>  
368 Vaughan, Brain–computer interfaces for communication and control,<sup>439</sup>  
369 Clinical neurophysiology 113 (6) (2002) 767–791.<sup>440</sup>
- 370 [3] A. Carlucci, J.-C. Richard, M. Wysocki, E. Lepage, L. Brochard, Non-<sup>441</sup>  
371 invasive Versus Conventional Mechanical Ventilation, American Jour-<sup>442</sup>  
372 nal of Respiratory and Critical Care Medicine 163 (4) (2001) 874–<sup>443</sup>  
373 880, doi:10.1164/ajrccm.163.4.2006027, URL <https://doi.org/10.1164/2Fajrccm>.<sup>444</sup>  
374 163.4.2006027.<sup>445</sup>
- 375 [4] P. Leung, A. Jubran, M. J. Tobin, Comparison of assisted ventilator modes<sup>446</sup>  
376 on triggering patient effort, and dyspnea., American Journal of Respira-<sup>447</sup>  
377 tory and Critical Care Medicine 155 (6) (1997) 1940–1948, doi:10.1164/<sup>448</sup>  
378 ajrccm.155.6.9196100, URL <https://doi.org/10.1164/2Fajrccm>.  
379 155.6.9196100.
- 380 [5] C. Sinderby, P. Navalesi, J. Beck, Y. Skrobik, N. Comtois, S. Friberg,  
381 S. B. Gottfried, L. Lindström, Neural control of mechanical ventilation in  
382 respiratory failure, Nature medicine 5 (12) (1999) 1433.
- 383 [6] M. Raux, C. Straus, S. Redolfi, C. Morelot-Panzini, A. Couturier, F. Hug,  
384 T. Similowski, Electroencephalographic evidence for pre-motor cortex  
385 activation during inspiratory loading in humans, The Journal of Physi-  
386 ology 578 (2) (2007) 569–578, doi:10.1113/jphysiol.2006.120246, URL  
387 <https://doi.org/10.1113/2Fjphysiol>.2006.120246.
- 388 [7] X. Navarro-Sune, A. L. Hudson, F. D. V. Fallani, J. Martinerie, A. Witon,  
389 P. Pouget, M. Raux, T. Similowski, M. Chavez, Riemannian Geometry  
390 Applied to Detection of Respiratory States From EEG Signals: The Basis  
391 for a Brain–Ventilator Interface, IEEE Transactions on Biomedical Engi-  
392 neering 64 (5) (2017) 1138–1148, doi:10.1109/tbme.2016.2592820, URL  
393 <https://doi.org/10.1109/2Ftbme>.2016.2592820.
- 394 [8] S. J. Luck, An introduction to the event-related potential technique, MIT  
395 press, 2014.
- 396 [9] C. E. M. van Beijsterveldt, D. I. Boomsma, Genetics of the human electro-  
397 encephalogram (EEG) and event-related brain potentials (ERPs): a re-  
398 view, Human Genetics 94 (4) (1994) 319–330, doi:10.1007/bf00201587,  
399 URL <https://doi.org/10.1007/2Fbf00201587>.
- 400 [10] G. Pfurtscheller, F. L. da Silva, Event-related EEG/MEG synchroniza-  
401 tion and desynchronization: basic principles, Clinical Neurophysiology  
402 110 (11) (1999) 1842–1857, doi:10.1016/s1388-2457(99)00141-8, URL  
403 <https://doi.org/10.1016/2Fs1388-2457%2899%2900141-8>.
- 404 [11] B. Blankertz, R. Tomioka, S. Lemm, M. Kawanabe, K. Robert Muller,  
405 Optimizing Spatial filters for Robust EEG Single-Trial Analysis, IEEE  
406 Signal Processing Magazine 25 (1) (2008) 41–56, doi:10.1109/msp.2008.  
407 4408441, URL <https://doi.org/10.1109/2Fmsp>.2008.4408441.
- 408 [12] E. Niedermeyer, F. L. da Silva, Electroencephalography: basic principles,  
409 clinical applications, and related fields, Lippincott Williams & Wilkins,  
410 2005.
- 411 [13] E. K. Kalunga, S. Chevallier, Q. Barthélemy, K. Djouani, E. Monac-  
412 celli, Y. Hamam, Online SSVEP-based BCI using Riemannian geometry,  
413 Neurocomputing 191 (2016) 55–68, doi:10.1016/j.neucom.2016.01.007,  
414 URL <https://doi.org/10.1016/2Fj.neucom>.2016.01.007.
- 415 [14] B. Blankertz, C. Sanelli, S. Halder, E.-M. Hammer, A. Kübler, K.-R.  
416 Müller, G. Curio, T. Dickhaus, Predicting BCI performance to study BCI  
417 illiteracy .
- 418 [15] B. Rivet, A. Souloumiac, V. Attina, G. Gibert, xDAWN Algorithm to  
419 Enhance Evoked Potentials: Application to Brain–Computer Interface,  
420 IEEE Transactions on Biomedical Engineering 56 (8) (2009) 2035–2043,  
421 doi:10.1109/tbme.2009.2012869, URL <https://doi.org/10.1109/2Ftbme>.  
422 2009.2012869.
- 423 [16] J. Müller-Gerking, G. Pfurtscheller, H. Flyvbjerg, Designing optimal spa-  
424 tial filters for single-trial EEG classification in a movement task, Clinical  
425 Neurophysiology 110 (5) (1999) 787–798, doi:10.1016/s1388-2457(98)  
426 00038-8, URL [https://doi.org/10.1016/2Fs1388-2457%2898%  
427 2900038-8](https://doi.org/10.1016/2Fs1388-2457%2898%2900038-8).
- 428 [17] Y. Yang, S. Chevallier, J. Wiart, I. Bloch, Automatic selection of the num-  
429 ber of spatial filters for motor-imagery BCI, in: The proceeding of 20th  
430 European Symposium on Artificial Neural Networks, Computational Intelli-  
431 gence and Machine Learning (ESANN 2012), 109–114, 2012.
- 432 [18] A. Barachant, S. Bonnet, M. Congedo, C. Jutten, Classification of co-  
variance matrices using a Riemannian-based kernel for BCI applications,  
Neurocomputing 112 (2013) 172–178, doi:10.1016/j.neucom.2012.12.039,  
URL <https://doi.org/10.1016/2Fj.neucom>.2012.12.039.
- [19] W. Förstner, B. Moonen, A Metric for Covariance Matrices, in:  
Geodesy-The Challenge of the 3rd Millennium, Springer Berlin Hei-  
delberg, 299–309, doi:10.1007/978-3-662-05296-9\_31, URL [https://doi.org/10.1007/2F978-3-662-05296-9\\_31](https://doi.org/10.1007/2F978-3-662-05296-9_31), 2003.
- [20] A. Barachant, S. Bonnet, M. Congedo, C. Jutten, Multiclass  
Brain–Computer Interface Classification by Riemannian Geometry,  
IEEE Transactions on Biomedical Engineering 59 (4) (2012) 920–928,  
doi:10.1109/tbme.2011.2172210, URL <https://doi.org/10.1109/2Ftbme>.  
2011.2172210.
- [21] R. Oostenveld, P. Praamstra, The five percent electrode system for  
high-resolution EEG and ERP measurements, Clinical Neurophysiol-  
ogy 112 (4) (2001) 713–719, doi:10.1016/s1388-2457(00)00527-7, URL  
<https://doi.org/10.1016/2Fs1388-2457%2800%2900527-7>.