

**Université Saad Dahlab Blida**  
**Centre de Développement et Technologie Avancé**



Faculté des sciences

Département d'informatique

*Thème*

**Guidage d'un objet à partir des signaux  
cérébraux pour le développement d'une  
interface Cerveau-Machine**

**BOUMDADA Dalila**

**SERRADJ Nesma**

**En vue d'obtenir le diplôme de master**

Option : Ingénierie de logiciel

**Encadreur :**

**M. BOUCHAFFRA Djamel**

**Co-encadreur :**

**Mme : BENBLIDIA Nadja**

**Promotion**  
2014 / 2015



# Remerciement

Avant d'exposer le résultat de ce travail,

Nous exprimons, avec plaisir, nos reconnaissances  
et nos remerciements à tous ceux qui nous a aidé pour réaliser ce travail.

Au DIEU tout puissant pour la volonté,

la santé et patience qu'il nous a donné durant toutes ces années d'études.

Nous tenons d'abord à exprimer toute notre reconnaissance à notre encadreur  
monsieur BOUCHAFFRA Djamel pour avoir encadré, orienté, conseillé.

A notre promotrice madame BENBLIDIA Nadjia pour sa patience, sa disponibilité et  
surtout ses judicieux conseils,

qui ont contribué à alimenter notre réflexion

A l'équipe de recherche au niveau de la division ASM du  
CDTA, qui nous ont aidés durant notre démarche.

M. Eltahir ZEMOURI , M.Nabil et M. YEKHLEF Faysal.

A l'équipe de recherche au niveau de laboratoire de recherche

De département d'électronique a l'université Blida1.

En fin à toute personne, qui nous a aidés de près ou de loin pour réaliser ce travail.





# *Dédicace*

Afin d'être reconnaissant envers ceux qui m'ont appuyé  
et encouragé à effectuer ce travail  
de recherche, je dédie ce mémoire :

À mes très chers parents pour leur soutien moral,  
et pour tous les sentiments d'affection et d'amour  
qui représentent pour moi le pilier de tous mes efforts.

À ma très chère mère Om hani et  
à mon très cher père Mohamed qui n'ont cessé de me combler par leur amour et leur  
tendresse.

A mes frères et sœurs mes Souvenirs et mes espoirs dans la vie

A ma chère amie, sœur SOUNA Baya pour tous les merveilleux

Moments qu'on a passés ensemble

J'ai lui souhaite tout le bonheur de monde.

Je n'oublie pas tous mes autres amies

À tous les membres de ma famille sans aucune exception.

Et à tous ceux que ma réussite leur tient à cœur

*dalila*







# Dédicace

J'adresse mes sincères remerciements à ma chère Binôme

**BOUMDADA Dalila,**

la patience de me supporter durant ce mémoire, et qui m'a soutenu et encouragé pendant tous les moments difficiles vécus, je t'aime beaucoup ma chère et m'aidé à réaliser ce travail.

Je remercie mes très très chers parents, **Hamid et BELAOUD Farida**, qui ont toujours été là pour moi, « **Vous avez tout sacrifié pour vos enfants n'épargnant ni santé ni efforts. Vous m'avez donné un magnifique modèle de labeur et de persévérance. Je suis redevable d'une éducation dont je suis fier** ».

Je remercie mon grand et unique frère **Abdelkader**, et mes belles sœurs **Ilhem, Dalel, Khadidja, Manel et en fin Fatma el Zohra**, pour leur support moral et intellectuel et pour être toujours là pour moi.

Je tiens à remercier mes meilleures amies: **CHOUAOU Ferial Louisa et MAACHOU Zineb, TCHOUKATCH KBIR Zineb**, pour leur magnifique amitié, leur soutien inconditionnel et leur encouragement, j'espère que notre amitié grandisse encore, et dure très longtemps.

Je remercie tous mes Amies que j'aime tant, **MOUHOUS Nabila, KAROU Nadia, KACHOUNE Hadjer, HAMDANIA Amel, IKOUOUBEL Lydia,...**, Pour leur sincère amitié et confiance, et à qui je dois ma reconnaissance et mon attachement.

En fin à toute personne, qui m'a aidé de près ou

de loi pour réaliser ce modeste travail.

*Hesma*





## Résumé

Les interfaces cerveau-machine (ICM) sont des systèmes de communication et de contrôle directs. Elle s'appuie uniquement sur l'activité cérébrale d'une personne et un système électrique ou mécanique sans aucune intervention musculaire. Dans notre thèse, nous avons contribué à l'optimisation de certaines étapes et particulièrement l'extraction de caractéristiques de l'électroencéphalogramme (EEG) et la classification des tâches mentales dans une ICM. Cette dernière se base sur la mesure et l'analyse des signaux EEG récoltés sur le scalp d'un individu à l'aide d'électrodes sur son crâne, qui sont stockés dans une base de données qu'on a utilisées.

En fait, cette activité que nous avons dans cette dernière, change durant l'activité motrice, lors de la réalisation du mouvement ou lorsque le sujet imagine un mouvement. Du point de vue méthodologique, nous avons utilisé une technique d'extraction de caractéristiques destinée aux signaux EEG. Et maintenant, nous sommes en train d'explorer deux méthodes de la classification sur la base des vecteurs caractéristiques déjà construits. Le but principal de ce travail est d'extraire les caractéristiques des signaux EEG et le but secondaire est de classifier ces signaux, comme on a pris quelque mesure permettant de quantifier la performance des classificateurs afin de valider et déterminer le taux de classification de chacun proposés. En utilisant une base de données (BCI de troisième compétition), on a décrit cette dernière dans le quatrième chapitre. Enfin, nous avons implémenté sous MATLAB une interface qui permet de faciliter les échanges des données entre l'utilisateur du notre système et notre système ICM.

**Mots clé :** Activité cérébrale, Apprentissage de la machine, apprentissage supervisé, Autocorrélation, Imagerie motrice, Interface Cerveau-Machine, Rythmes sensorimoteurs, Syndrome d'enfermement, Système d'acquisition de données, Taxonomie des classifieurs.

**Abstract:**

The brain-machine interface (BCI) is a direct control communication system. It relies focus only on cerebral activity of a person and an electrical or mechanic system without any muscular action. In our work, we have contributed to optimize a certain steps and especially the extraction of features of the electroencephalogram (EEG) and the classification of mental tasks in a BCI. The last one is based on the measure and analyses of EEG signals collected on the scalp of individual using electrodes on his skull, which are stored in a database that we used.

In fact, the activity that we have in this latest, changes according to motor activity, at the realization of movements or when the subject imagines a movement. From a methodological viewpoint, we used a feature extraction technique for the EEG signals. Then we are exploring two methods of classification based on the feature vectors already built. The main purpose of this work is to extract the characteristics of EEG signals and the secondary goal is to classify these signals, as we have taken some measures to quantify the performance of classifiers to validate and determine the classification rate of each one suggested. Using a database (BCI third competition), we described it in the fourth chapter. Finally, we implemented a MATLAB interface to make the exchanges of data between the user of our system and our BCI easily.

**Keywords :** Brain activity , Learning Machine , autocorrelation, Brain Machine Interface , sensorimotor rhythms, data acquisition system , Taxonomy of classifiers.

## ملخص:

واجهة دماغ-آلة (و.د.آ) هو نظام الاتصالات والتحكم المباشر. تعتمد فقط على نشاط الدماغ لشخص وكذلك على نظام كهربائي أو ميكانيكي دون اتخاذ أي إجراء عضلي. في مذكرتنا هذه، ساهمنا في تعظيم الاستفادة من بعض الخطوات وخصوصا استخراج خصائص الرسم للتيار الكهربائي للدماغ (ر.ت.ك.د) وتصنيف المهام العقلية في و.د.آ. ويستند هذا الأخير على قياس وتحليل إشارات ر.ت.ك.د التي تم جمعها بأقطاب كهربائية موضوعة على فروة رأس متطوع، والتي يتم تخزينها في قاعدة البيانات التي استخدمناها.

في الواقع، هذا النشاط المخزن لدينا في هذه الأخيرة، يتغير أثناء النشاط الحركي، عند تنفيذ الحركة العضلية أو عندما يكون الموضوع يتخيل حركة ما. فمن جهة النظر المنهجية، استخدمنا تقنية استخراج خصائص للإشارات ر.ت.ك.د. الآن، نحن ندرس طريقتين للتصنيف على أساس ناقلات التي تحمل خصائص الإشارات ر.ت.ك.د المتم اجراؤها في الخطوة السابقة. والغرض الرئيسي من عملنا هذا هو استخراج خصائص إشارات ر.ت.ك.د والهدف الثانوي هو لتصنيف هذه الإشارات، كما اتخذت بعض التدابير لقياس أداء المصنفات المقترحة علينا للتحقق من صحته وتحديد معدل نتائجه الصحيحة. باستخدام قاعدة بيانات (المسابقة الثالثة ل و.د.آ)، التي دققنا في وصفها في الفصل الرابع. أخيرا، أنجزنا واجهة باستعمال MATLAB لتسهيل تبادل البيانات بين المستخدم وبين نظامنا و.د.آ.



## Plan de travail

Liste des Figures et Tableaux

<b>I. Introduction générale.....</b>	<b>2</b>
--------------------------------------	----------

### **II.CHAPITRE I : Etat de l'art**

1. Introduction.....	5
2. Concept général des interfaces cerveau-machine (ICM).....	5
2.1 Introduction.....	5
2.2 Principe d'un système ICM .....	6
3. Notions Neurophysiologiques.....	7
3.1 Cortex Cérébral.....	8
3.2 Rythme Cérébral.....	8
3.3 Mesure de l'activité cérébrale .....	9
3.3.1 L'électro-encéphalogramme (ÉEG) .....	10
3.3.2 Magnétoencéphalographie (MEG) .....	11
3.3.3 L'imagerie par résonance magnétique fonctionnelle (IRMf) .....	11
3.3.4 Les micro-électrodes.....	12
3.3.5 L'Electrocorticographie (ECoG) .....	12
3.4 Quelques définitions.....	13
4. Les applications dédiées aux ICMS .....	14
4.1 Contrôle de prothèse robotisée .....	14
4.2 P300 Speller.....	15
5. Conclusion.....	16

### **III.CHAPITRE II : Les méthodes d'extraction de caractéristiques et de classification pour les ICMS**

1. Introduction .....	18
2. Extraction des caractéristiques.....	18
2.1 Propriétés du signal EEG.....	18
2.2 Les méthodes d'extraction de caractéristiques.....	19

2.2.1 Méthodes temporelles.....	19
2.2.1.1 paramètres Hjorth.....	19
2.2.1.2. Paramètres autorégressifs.....	19
2.2.2 Méthodes fréquentielles.....	20
2.2.2.1 La méthode de "bandpower" BP .....	20
2.2.2.2. La densité spectrale de puissance (DSP).....	20
2.2.3 Méthodes temps-fréquences.....	21
2.2.3.1 Transformée de Fourier à Court Terme : spectrogramme.....	21
2.2.3.2. Les ondelettes.....	21
3. Classification des signaux EEG.....	22
3.1 Généralités et Taxonomie des classifieurs .....	23
3.2 Les méthodes de classification destinées pour les ICMs.....	24
3.2.1 Analyse Discriminante Linéaire.....	24
3.2.2 Séparateur à Vaste Marge.....	
3.2.3 Chaine de Markov Cachée.....	25
4 Enjeux actuels des ICMs et problématique du choix des méthodes adéquates.....	25
5 Conclusion.....	26

#### **IV.CHAPITRE III : Conception d'un système ICM**

1. Introduction .....	28
2. Analyse et extraction de caractéristiques des signaux non stationnaires et non linéaires par l'Ondelette.....	29
2.1 Introduction.....	29
2.2 Transformée en ondelettes.....	30
2.2.1 La transformée discrète en ondelettes (DWT).....	30
2.2.2 La multi-résolution.....	31
<b>3. Classification des signaux cérébraux par L'algorithme K-plus proche voisin KPPV.....</b>	<b>32</b>
4. Conclusion.....	34

## Liste des Figures

- Figure 1 :** Schéma générique d'un system BCI (inspiré par Jonathan R. Welpaw et al 2002)
- Figure 2 :** Le schéma bloc suivant illustre le cycle entre les étapes que l'on retrouve dans la majorité des systèmes BCI
- Figure 3 :** Cortex cérébral
- Figure 4 :** L'emplacement des électrodes
- Figure 5:** La technique de mesure MEG
- Figure 6 :** A) La mesure des réponses cérébrales au moyen de l'imagerie par résonance magnétique fonctionnelle (irmf). B) La détection des régions du cerveau impliquées dans la perception visuelle par l'irmf. [http://reflexions.ulg.ac.be/cms/c\\_5236/accueil](http://reflexions.ulg.ac.be/cms/c_5236/accueil)
- Figure 7:** Capteurs sous forme de fils implantés directement a l'intérieur du cortex. S.Colnat Coulbois
- Figure 8:** Une matrice d'électrodes espacées placée sur le cortex. <Http://futurepredictions.com/wp-content/uploads/2011/05/ecog.jpg>
- Figure 9 :** Positionnement des différentes technologies non invasives d'enregistrement de l'activité cérébrale en fonction de la résolution temporelle et spatiale. (l'étoile rouge – activité d'un neurone – représente un point de référence)
- Figure 10:** Contrôle de cette prothese par la pensee : Ouverture-fermeture (imagination de la main droite-gauche respectivement).
- Figure 11:** 'Ecran P300 Speller contenant [6x6] soit 36 symboles qui permet de dicter des mots par la pensée.
- Figure 13:** La séparation non linéaire d'un nuage de points. Figure de [45]
- Figure 14 :** Schéma générique du system proposée
- Figure 15:** Transformée en ondelette par multi résolution
- Figure 16 :** Décomposition de signal en approximations et détails
- Figure 17:** Plan de traitement des signaux EEG de notre système ICM
- Figure 18 :** Exemple d'un enregistrement (sujet 1).
- Figure 19 :** schéma de correspondance pour segmenter les enregistrements
- Figure 20 :** Décomposition d'un signal EEG en ondelettes [60]
- Figure 21 :** extraction des caractéristiques
- Figure 22 :** Décomposition de la BD IIIb en deux parties : l'apprentissage et le test
- Figure 23 :** Classification avec l'algorithme KPPV
- Figure 24 :** résultat les coefficients du signal



**Figure 25 :** resultat d'extraction caractéristiques de signale Résultat de l'extraction de caractéristiques (les colonnes sont les caractéristiques les lignes sont les essais)

**Figure 26 :** résultat de test

**Figure 27 :** paradigme de l'expérience de réalité virtuelle utilisée pour le sujet O3. [61]

**Figure 28:** Interface du système ICM

**Figure 29 :** Interface de l'apprentissage du système ICM

**Figure 30 :** Interface de Test du système ICM

### Liste des tableaux

**Tableau 1 :** Gamme de fréquences des rythmes du cerveau

**Tableau 2 :** vue globale de l'expérimentation

**Tableau 3 :** Familles d'ondelettes

**Tableau 4 :** vue globale de l'expérimentation [61]

# Introduction générale

## **Contexte général**

Certains patients atteints par un accident vasculaire cérébral grave restent dans un état de paralysie musculaire complète (LIS : Locked-In Syndrom). Le même handicap moteur très sévère touche les personnes atteintes de sclérose latérale amyotrophique (SLAS) durant les derniers stades de la maladie. Dans la plupart des cas, ces affections laissent toutes leurs facultés mentales aux personnes qui en sont atteintes, mais leur interdisent toute communication avec leur entourage. Les interfaces cerveau-machine sont l'approche qui semble actuellement la plus prometteuse pour pallier ce handicap.

Les interfaces cerveau-ordinateur, ou BCI (Brain Computer Interfaces) sont des systèmes permettant la communication entre une personne et un ordinateur sans intervention musculaire. Dans le monde plusieurs millions de personnes atteintes d'un handicap neuromusculaire sévère pourraient bénéficier de ces systèmes.

## **Objective et motivation**

L'objectif général de ce projet, c'est comprendre des approches et des concepts généraux sur les interfaces cerveau-machine. Nous intéresserons plus précisément aux systèmes qui utilisent une technique basée sur l'acquisition des signaux des potentiels d'action qui sont produits par le cortex cérébral, s'appelle électroencéphalographie. La compréhension des méthodes numériques et des approches de traitement des signaux digitaux est une nécessité pour pouvoir réaliser ce projet, alors l'amélioration de ce type de connaissance était une cible aussi. Tout autour du monde, il y a beaucoup de patients paralysés souffrent de maladies comme la sclérose latérale amyotrophique (SLA), le locked-in syndrome (LIS), les dystrophies musculaires, les blessures de la moelle épinière etc. Ils ont perdu leur capacité à se déplacer, certains entre eux, même si à communiquer avec le monde extérieur. Alors, il y a beaucoup d'efforts et de mains-d'œuvre dépensés pour prendre soin de leur vie quotidienne. D'un jour à l'autre, les nouvelles technologies sont découvertes par des universités ou les centres de recherche individuels. Ceci déclenche la nécessité d'un processus d'adaptation de cette nouvelle technologie à notre vie habituelle. La force qui nous pousse, est la possibilité de faire une petite contribution au domaine l'informatique médicale.



## Structure du rapport

Ce rapport sera constitué des 4 chapitres suivants:

**Chapitre 1 :** Etat de l'art, Nous essaierons d'expliquer brièvement les concepts des interfaces cerveau-machine ainsi que les différents travaux et applications réalisés dans ce domaine. Les bases neurologiques et les techniques générales d'imagerie cérébrale en accentuant électroencéphalographie.

**Chapitre 2 :** Les méthodes d'extraction de caractéristiques et de classification pour les ICMs. nous allons développer dans ce chapitre les concepts généraux de la partie comportant la phase d'extraction de caractéristiques et de classification.

**Chapitre 3 :** Conception d'un système ICM. dans ce chapitre on va présenter les méthodes appliquées pour la conception de notre système qui sont la méthode d'ondelette pour l'extraction des caractéristiques, et les méthodes support Vecteur machine (SVM) et K-plus Proche Voisin(KPP) pour la classification.

**Chapitre 4 :** Réalisation, test et évaluation. Nous allons parler dans ce chapitre de notre système ICM qu'on a développé, en montrant notre environnement de travail, évaluation des résultats et les interfaces réalisées.

# CHAPITRE I

Etat de l'art

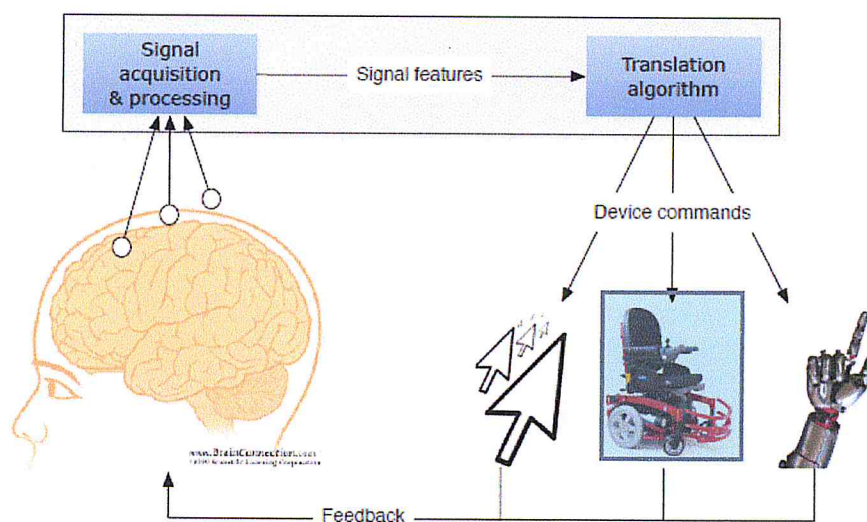
## 1. Introduction

Ce chapitre constitue une mise en contexte. Il procure les éléments utiles à la compréhension du sujet de recherche de cette thèse. Nous commencerons tout d'abord par définir d'une manière globale le concept des Interfaces Cerveau-Machines(ICMs). Ensuite on décrira les bases neurologique et les techniques générales d'imagerie cérébrale en accentuant électroencéphalographie Enfin, nous présenterons quelques exemples des applications dédiées aux ICMs qui sont dans différents domaines : de handicapé, de la robotique et le multimédia (réalité virtuelle, jeux et autres applications).

## 2. Concept général des interfaces cerveau-machine(ICM)

### 2.1 Introduction

De nos jours, les ICMs attirent de formidables espoirs dans la recherche. Leur objectif est de restaurer le rapport entre un signal génère par une activité neuronale d'un individu (transmission via la perception visuelle ou l'attention) et son traitement (identification de la tâche réalisée). En effet, un ICM est un système De communication et de contrôle qui ne dépend pas des "outputs" neuromusculaires standard du cerveau. L'intention de l'utilisateur est véhiculée par les signaux cérébraux (comme les EEG) à la place des nerfs et des muscles. Cette approche se divise en deux parties : une partie qui concerne la mesure de l'activité cérébrale d'un individu (chapitre 1). L'autre nécessite une analyse et un traitement des signaux EEG récoltés (chapitre 2). La conception d'une ICM est schématisée par la figure 1 :

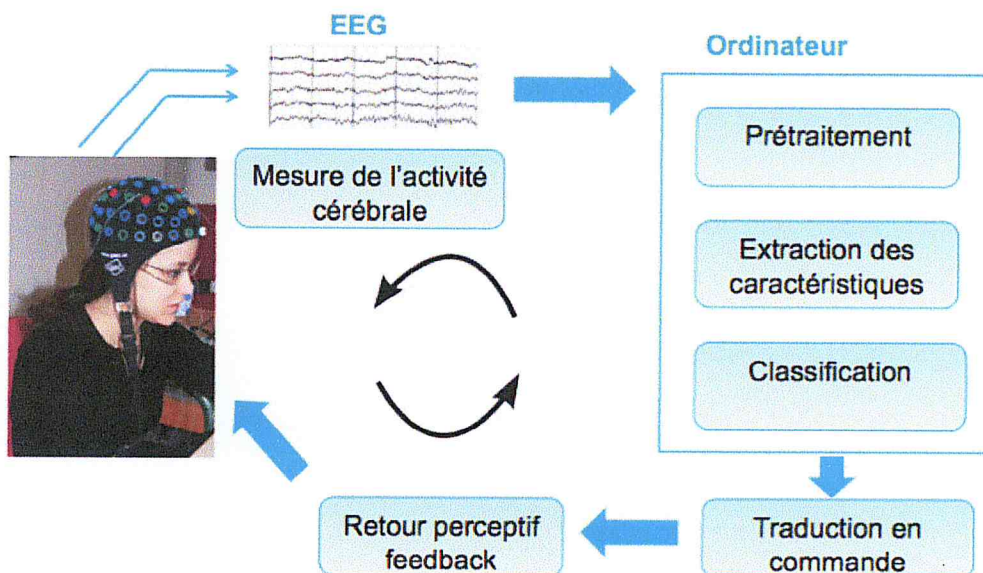


**Figure 1** : schéma générique d'un system BCI (inspiré par Jonathan R. Welpaw et al 2002)



## 2.2 Principe d'un système ICM

Le schéma suivant illustre le design d'un système BCI générique. Les signaux cérébraux reflétant l'**activité cérébrale** sont enregistrés à partir du cuir chevelu, de la **surface corticale** ou directement à l'intérieur du cerveau et sont traités afin de détecter des signaux caractéristiques particuliers, qui reflètent l'intention de l'utilisateur. Ces signaux caractéristiques sont ensuite traduits en commandes, qui permettent de contrôler, par exemple, le déplacement d'un curseur, d'une chaise roulante ou encore d'une neuroprothèse. Finalement, un retour (**feedback**), la plupart du temps sous forme visuelle, reflétant l'interprétation de son intention, indique à l'utilisateur le résultat de l'opération.



**Figure 2 :** Le schéma bloc suivant illustre le cycle entre les étapes que l'on retrouve dans la majorité des systèmes ICM

Si nous voulons expliquer brièvement ces phases :

- **Mesure de l'activité cérébrale :** Il existe plusieurs techniques pour mesurer des activités électriques de cérébral cortex. Dans le cadre de notre travail on utilisera EEG.
- **Prétraitement des données :** les signaux EEG étant réputés pour leurs bruits, l'étape de prétraitement est donc essentielle pour nettoyer les signaux de tout parasite.


- **Extraction de caractéristiques** : Le but de cette étape est de garder les informations les plus appropriés qui représentent une tâche mentale dans un signal. Cette phase permet de construire un vecteur caractéristique représentatif de cette tâche.
- **Classification**: La classification des signaux est réalisée sur les vecteurs caractéristiques déjà définis à l'étape précédente. Cette étape consiste à allouer une classe à chaque tâche mentale du sujet.
- **Traduction en commande** : Quand nous classifions les signaux, il faut la traduire en une commande bas niveau afin de contrôler un système comme par exemple contrôler une prothèse ou déplacer dans un environnement virtuel.
- **Feedback** : Cette dernière phase consiste à renvoyer au sujet un retour soit par une information visuelle ou sonore sur la tâche mentale effectuée.

### 3. Les Notions Neurophysiologiques

La neurophysiologie est l'étude des fonctions du système nerveux reposant sur tous les niveaux de description, du niveau moléculaire jusqu'au niveau le plus intègre des réseaux neuronaux. Le domaine des ICMs repose essentiellement sur des connaissances dans le domaine de neuroscience afin de bien étudier l'activité cérébrale générée par un individu.

#### 3.1 Cortex Cérébral

Le cortex correspond à la partie recouvrant certains organes. Le cortex cérébral est un tissu organique aussi appelée substance grise, recouvrant les deux hémisphères du cerveau sur une épaisseur de quelques millimètres. Le cortex cérébral est composé de différentes couches, plus ou moins nombreuses selon la région de l'hémisphère recouverte. Le cortex cérébral règne sur ce qu'on nomme les « fonctions nerveuses élaborées » et est regroupé en aires ayant des fonctions différentes notamment sensorielles, motrices et d'association. Le cortex cérébral participe à de nombreuses fonctions cognitives notamment entre autres, certains sens, le langage, les actions volontaires de la motricité et la mémoire. (cf. figure 3)



**Figure 3 :** Cortex cérébral

### 3.2 Rythme Cérébral

Les principaux rythmes cérébraux et activités cérébrales se classent selon leur fréquence

Nom	Gamme de fréquence (Hz)	l'activité mentale
Alpha	8-13	la relaxation et la concentration
Theta	4-7.5	inconscient; inspiration et de méditation profonde
beta	14-26	La pensé; l'attention et la résolution de problèmes concrets
Delta	0.5-4	sommeil profond
Gamma	30-45	le mouvement des doigts, les orteils et la langue

**Tableau 1 :** Gamme de fréquences des rythmes du cerveau



### 3.3 Mesure de l'activité cérébrale

#### 3.3.1 L'électro-encéphalogramme (ÉEG)

Le principe de fonctionnement d'EEG est basé sur des différences potentielles sur les différentes régions du cortex cérébral. Nous mesurons ces différences potentielles en disposant sur l'ensemble du cuir chevelu de 10 à 20 électrodes, petites plaques métalliques reliées par des fils à l'appareil d'enregistrement. Celui-ci mesure le potentiel électrique détecté par chaque électrode et compare les électrodes deux à deux, chaque comparaison se traduisant par un tracé appelé dérivation. La réactivité électroencéphalographique est évaluée au moyen d'épreuves simples : ouverture des yeux, hyperpnée (respiration ample et lente), stimulation lumineuse intermittente obtenue grâce à des éclairs lumineux brefs et intenses dont la fréquence est progressivement croissante. Dans nos jours, la technique EEG est utilisée souvent pour des applications d'ICM car elle n'a pas besoin de la chirurgie et même si les solutions professionnelles sont déjà chères, il existe aussi des systèmes EEG commercialisés qui ne sont pas trop chers.

L'électroencéphalographie (EEG) est une méthode d'exploration cérébrale qui mesure l'activité électrique du cortex cérébral par des électrodes placées sur le crâne.

La position des électrodes est décrite par une nomenclature internationale appelée système 10-20, où les électrodes impaires sont à gauche, les électrodes paires à droite, les électrodes z au milieu et les lettres reflètent la position (F pour frontal, P pour pariétal, etc.). Au total, 30 électrodes sont placées sur le cuir chevelu du patient. Comme pour l'ECG, les dérivations peuvent être bipolaires (le signal est la différence entre un pôle + et un pôle -) ou unipolaires (le signal ne provient que d'un pôle, le pôle opposé est commun à toutes les dérivations). On parle alors de montage référentiel.



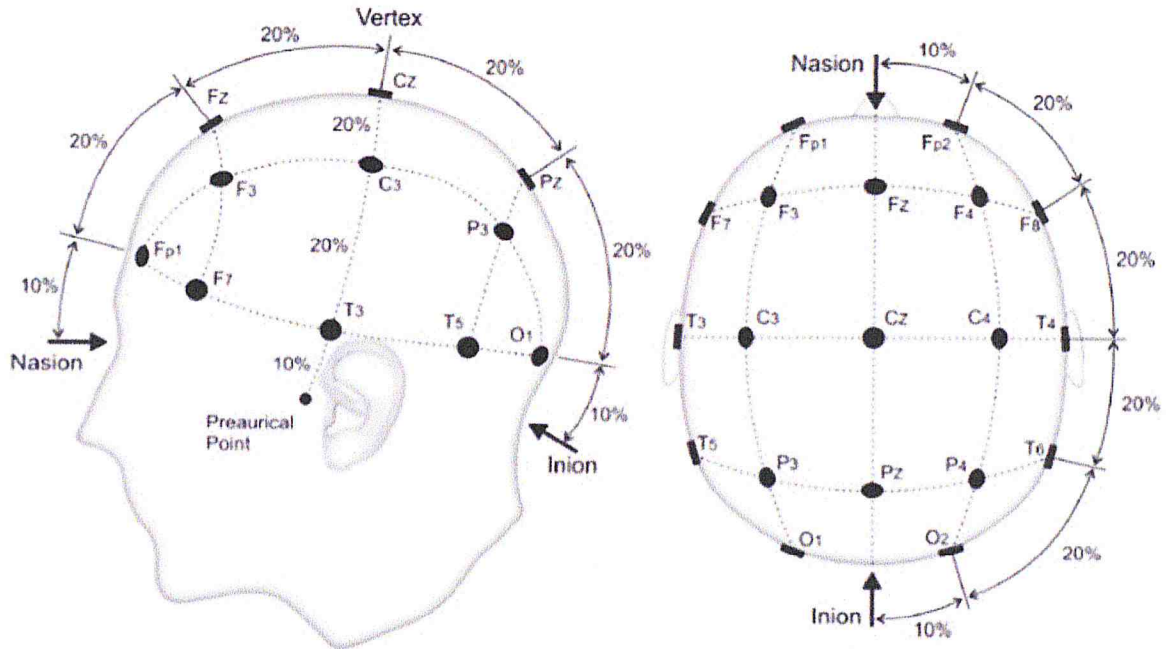


Figure 4 :l'emplacement des électrodes

Cette méthode présente aussi bien des avantages que des inconvénients. Au nombre des avantages du EEG, nous pouvons citer :

- Sa bonne résolution temporelle : phénomènes électriques rapides ou relativement haute fréquence.
- Une mise en place facile et non invasive : possibilité d'étude de l'activité sur des sujets valides et non valides sans aucune intervention chirurgicale dans plusieurs environnements.
- Cout réduit : cout de l'EEG relativement réduit par rapport à d'autres techniques existantes de mesure de l'activité cérébrale.

En revanche, l'EEG est limite dans sa résolution spatiale et sa gamme de fréquence. D'ailleurs, Il peut être contamine par des artefacts soit musculaires (EMG) soit oculaires (EOG) qui peuvent erroné le signal.

Il existe plusieurs autres technologies qui permettent d'observer l'activité cérébrale on cite:

### 3.3.2 Magnétoencéphalographie (MEG)

La MEG est une technique de mesure non invasive des champs magnétiques produits par l'activité électrique des neurones du cerveau. Cette technique est employée dans divers

domaines avec une visée clinique en neurologie (notamment pour l'étude de l'épilepsie), en cardiologie, ainsi que dans la recherche en neurosciences cognitives



Figure 5: La technique de mesure MEG

### 3.3.3 L'imagerie par résonance magnétique fonctionnelle (IRMf)

L'imagerie par Résonance Magnétique fonctionnelle (IRMf) est actuellement en plein essor vu les perspectives qu'elle offre dans l'étude du fonctionnement du cerveau. Cette technique permet d'identifier d'une manière non invasive les zones du cortex activées lors d'une simulation donnée tout en calculant une grandeur quantifiant le niveau d'oxygénation du sang dans le cerveau. Aujourd'hui, l'IRMf s'est imposée comme la méthode de référence pour les études du fonctionnement cérébral humain et en particulier des fonctions cognitives.

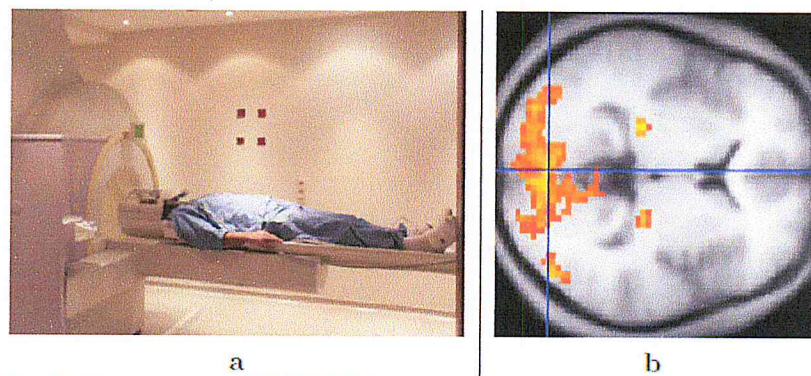


Figure 6 : a) La mesure des réponses cérébrales au moyen de l'imagerie par résonance magnétique fonctionnelle (IRMf). b) La détection des régions du cerveau impliquées dans la perception visuelle par l'IRMf.

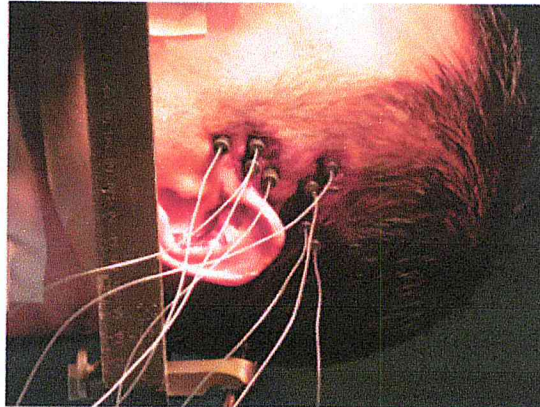
(<http://reflexions.ulg.ac.be/cms/c/5236/accueil>)

### 3.3.4 Les micro-électrodes

Les micro-electrodes sont des capteurs invasifs mises au point dans le but de restaurer la mobilité chez l'être humain. Ces capteurs sont implantés directement dans la matière grise



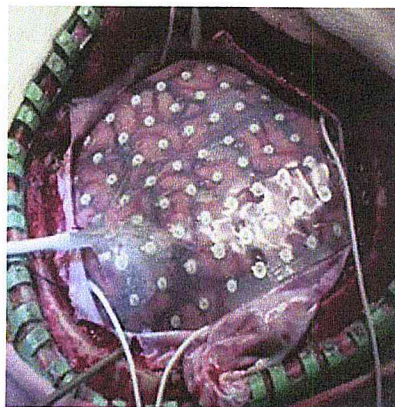
du cerveau humain après une intervention chirurgicale très délicate afin de mesurer l'activité électrique produite par les neurones du cortex.



**Figure 7:** Capteurs sous forme de fils implantés directement à l'intérieur du cortex. S.Colnat Coulbois

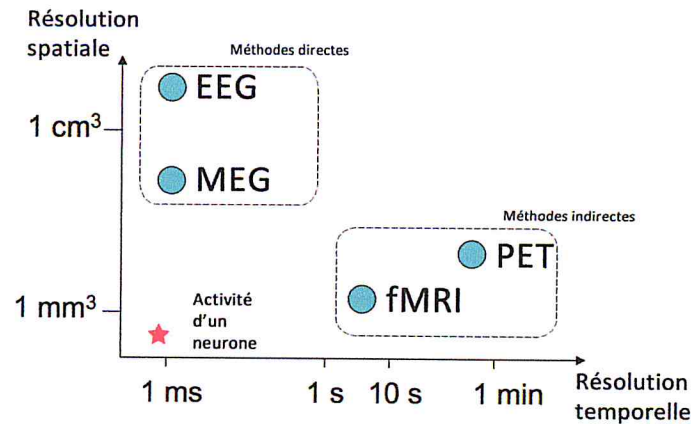
### 3.3.5 Electrocorticographie (ECoG)

L'électrocorticographie est une technique d'imagerie partiellement invasive. Elle mesure l'activité électrique à la manière de l'électroencéphalographie mais avec une matrice d'électrodes espacées, implantée à l'intérieur de la boîte crânienne entre le cortex et la dure-mère (voir figure 8). Ces électrodes se caractérisent par leur bonne performance et leur stabilité à long terme.



**Figure 8:** Une matrice d'électrodes espacées placée sur le cortex. <http://futurepredictions.com/wp-content/uploads/2011/05/ecog.jpg>

On positionné ces technologies selon le schéma suivante :



**Figure 9** : Positionnement des différentes technologies non invasives d'enregistrement de l'activité cérébrale en fonction de la résolution temporelle et spatiale. (L'étoile rouge – activité d'un neurone – représente un point de référence)

### 3.4 Quelques définitions

**a. La résolution spatiale** : c'est la capacité du système à discriminer ou séparer entre deux ou plusieurs tâches mentales spatialement proches.

**b. La résolution temporelle** : c'est la fréquence de la couverture temporelle d'un système d'acquisition. Ce critère est très important dans le domaine des ICMs.

Dans la suite de cette section, nous présenterons les techniques les plus en ICM pour mesurer l'activité cérébrale selon le critère de l'enregistrement (invasif, non invasif) bien que nos travaux de thèse utilisent seulement les signaux EEG.

**c. Méthodes Directes** : Les méthodes directes mesurent directement l'activité électrique des neurones. Elles offrent une bonne résolution temporelle, mais une résolution spatiale plutôt moyenne.

**d. Méthodes Indirectes** : Les méthodes indirectes ne mesurent pas directement l'activité électrique cérébrale, mais utilisent des indicateurs comme par exemple la consommation d'oxygène ou De glucose induite par l'activité des neurones. Elles offrent une bonne résolution spatiale, mais une résolution temporelle insuffisante. Les dispositifs permettant l'enregistrement des activités électriques du cerveau chez l'être humain sont catégorisés en dispositifs invasifs, partiellement invasifs ou non invasifs. Chaque catégorie présente ses avantages, et bien entendu ses inconvénients.

**e. Dispositifs invasifs** : Les technologies invasives ont initialement été mises au point afin de restaurer des fonctionnalités défaillantes chez l'homme, comme par exemple la vue [1] ou la mobilité [2]. Ce type de dispositif est connecté de manière directe à la matière grise du cerveau, ce qui nécessite donc des interventions de neurochirurgie pour la mise en place. Si le fait que le contact soit



fait directement à la matière grise du cerveau permette d'obtenir la meilleure qualité de signal qu'il soit, avec le temps, des kystes se forment, et réduisent voir annulent totalement le signal.

**f. Dispositifs partiellement invasifs :** A la différence des systèmes invasifs, les dispositifs partiellement invasifs ne pénètrent pas dans la masse cérébrale, mais se contentent de fonctionner grâce à un composant implanté dans la boîte crânienne du patient, c'est-à-dire à la surface corticale.

**g. Dispositifs non invasifs :** La dernière catégorie est dite non invasive. On peut également qualifier ce genre de dispositifs de "légers". En effet, Leur mise en place peut être extrêmement simple et rapide, n'impose quasiment aucun effort de la part de son utilisateur, et ne présente aucun risque pour son intégrité physique. Si dans le domaine clinique il est tout de même souvent nécessaire d'avoir le crâne rasé afin de garantir un bon rapport signal/bruit, et que la pose des électrodes peut nécessiter de longues minutes, certains dispositifs orientés grand public donnent tout son sens au qualificatif "léger". En effet, si l'on prend pour exemple le casque EPOC+ d'Emotiv, il suffit d'humidifier à l'aide d'une solution saline les capteurs du casque, puis l'utilisateur n'a plus qu'à simplement le poser sur sa tête. Il faut bien avouer que ce genre d'appareil est très pratique. Cependant, il est nécessaire de garder à l'esprit que la qualité du signal ne peut pas rivaliser avec celle issue des dispositifs invasifs et partiellement invasifs. Cela vient évidemment du fait que le signal est altéré par la traversée de la boîte crânienne.

#### 4. Applications dédiées aux ICMs

Le concept des ICMs a permis la réalisation et le développement de plusieurs applications. L'évolution vers cette symbiose entre l'homme et la machine semble désormais irréversible, porteuse d'autant d'espoirs que de dangers. Car si cette symbiose peut être appliquée dans le domaine de handicap pour redonner aux personnes atteintes une certaine autonomie de vie, elle pourrait aussi être employée dans d'autres domaines notamment la robotique et le multimédia (les jeux et la réalité virtuelle). Les applications développées dépendent principalement de la vitesse et de la précision du signal de l'activité cérébrale enregistrée lors de l'application ICM.

##### 4.1 Contrôle de prothèse robotisée

En 1999, Guger et ses collègues ont déjà démontré qu'il est possible de contrôler une prothèse de main robotisée par la pensée et sans recours aux techniques invasives [3]. Dans ces travaux, cette prothèse de main présentée dans la figure 10 peut être fermée ou ouverte selon l'état de la pensée. En fait le principe est le suivant : il est demandé au sujet d'imaginer de bouger sa main gauche ou droite selon un stimulus. Lorsque les signaux cérébraux caractérisent l'imagination de la main gauche alors la prothèse se ferme, tandis


que si le système reconnaît les signaux de la main droite la prothèse dans ce cas l'a s'ouvre. Ces deux tâches mentales sont reconnues correctement avec un taux qui varie entre 80% et 90% selon le sujet.



**Figure 10:** Contrôle de cette prothèse par la pensée : ouverture-fermeture (imagination de la main droite-gauche respectivement).

#### 4.4 P300 Speller

Le P300 speller : est la communication la plus répandue depuis 1988 proposée par Farwell et Donchin [4] qui permet de saisir un texte sur un écran. Ce traitement remplace le clavier traditionnel par un autre virtuel. Ce dernier est constitué d'une matrice [6 x 6] soit 36 symboles. Les lignes et les colonnes vues sur la figure 11 qui constituent la matrice, s'intensifiaient d'une manière aléatoire plusieurs fois par secondes. L'utilisateur doit focaliser son attention sur le symbole souhaité en comptant le nombre de ses intensifications. Cette tâche cognitive de comptage entraîne la génération d'ERP de type P300 détectée par l'ICM, ce qui permet à cette dernière de sélectionner la ligne et la colonne contenant le symbole désiré. En fait, les effets de la taille de la matrice et l'intervalle de temps séparant deux séquences successives jouent un rôle important dans les performances du P300 speller [5].



**Figure 11:** Écran P300 Speller contenant [6x6] soit 36 symboles qui permet de dicter des mots par la pensée



L'interface P300 speller a été appliquée aussi en 2006 par Sellers et ses collègues sur des patients atteints du syndrome d'enfermement (ALS). Effectivement, le taux de reconnaissance obtenus par deux patients souffrants de ce syndrome est le même qui est obtenu par des personnes valides [5].

## 5. Conclusion

Ce chapitre nous a permis de donner au lecteur une vue globale sur la définition et le fonctionnement des ICMs, Une fois que nous avons compris tous, Nous avons expose les notions de base dans les domaines de neurophysiologie et d'electrophysiologie afin de mieux adapter le fonctionnement du cerveau de l'activité cérébrale a notre travail. A la suite de cette section, nous avons définit les différentes méthodes qui existent dans chaque partie du cycle qui constitue le fonctionnement d'une ICM. Toutes les notions electrophysiologiques que nous venons de définir dans la section ne sont pas exhaustives puisque le domaine de neurophysiologie est un domaine très vaste et très riche donc seuls qui nous intéressent et qui sont utilisées dans la conception d'une ICM durant les dernières années de recherche étaient mentionnées. Finalement, nous avons présenté un état de l'art sur l'utilisation des ICMs en citant quelques applications développées jusqu'alors, en nous attachant plus particulièrement et en premier lieu a celle dédiées a l'aide aux personnes atteintes d'un handicap moteur sévère dans la communication ainsi que dans le contrôle de machines.

# CHAPITRE II

Les méthodes d'extraction de caractéristiques et de  
classification pour les ICMs



## Chapitre II : Les méthodes d'extraction de caractéristiques et de classification pour les ICMs

### 1. Introduction

Dans ce chapitre, nous allons développer les concepts généraux de la partie comportant la phase d'extraction de caractéristiques et de classification. Ce chapitre se divise en deux principales parties une qui définit les méthodes d'extraction de caractéristiques, et l'autre les méthodes de classification utilisées dans les ICMs.

### 2. Extraction des caractéristiques

L'extraction des caractéristiques est une étape fondamentale du processus de L'ICM, préalable à la classification. L'analyse de ce type de signaux s'avère très Compliquée due à la nature du signal et très importante dans le raisonnement Scientifique qui mène à concevoir le système ICM. Ci-dessous, nous présentons Les caractéristiques et les propriétés du signal EEG qui vont être extraites dans Cette phase ainsi que les différentes méthodes temporelles, fréquentielles et temps fréquence utilisées pour cette tâche.

#### 2.1 Propriétés du signal EEG

L'EEG se caractérise généralement par son faible rapport signal sur bruit car il est altère par des perturbations extra-cérébrales et électromagnétiques, par son non-linéarité et son non stationnarité [6]. L'activité cérébrale est considérée comme un processus stochastique dynamique, et cela est due aux facteurs biologiques et techniques. En ce qui concerne les facteurs biologiques, l'activité cérébrale change suite à la fatigue et l'attention du sujet, à la progression d'une maladie et au processus d'entraînement. Tans dis que les facteurs techniques sont en général lies au bruit que produit l'amplificateur, au bruit ambiant, et a la variation de l'impédance des électrodes [7]. Il ne faut pas oublier aussi que la variation temporelle générée par les séries de temps du signal EEG doit être prise en compte pendant l'extraction des caractéristiques. Pour ceci, trois principales approches ont été proposées pour extraire les informations temporelles [8]

- Extraction des caractéristiques sur plusieurs segments** : au cours du temps et les concaténer en un seul vecteur caractéristique.
- Combinaison des classifieurs sur des segments différents de temps** : c'est-à-dire réaliser l'extraction de caractéristiques et appliquer la classification sur plusieurs segments de temps pour enfin combiner les résultats des différents classifieurs [9] [10].

## Chapitre II : Les méthodes d'extraction de caractéristiques et de classification pour les ICMs

•**Classification dynamique** : elle consiste à extraire les caractéristiques de plusieurs segments de temps pour construire une séquence temporelle de vecteurs caractéristiques. Cette séquence peut être classifiée en utilisant un classifieur dynamique [11] [10] La première approche est la plus utilisée, c'est la raison pour laquelle les vecteurs caractéristiques sont souvent de grande taille [8]. Les différentes méthodes temporelles, fréquentielles et temps-fréquence utilisées pour l'extraction des caractéristiques dans le domaine des ICMs présentées ci-dessous

### 2.2 Les méthodes d'extraction de caractéristiques

#### 2.2.1 Méthodes temporelles

Puisque l'EEG comparé aux autres techniques d'investigations, fournit des informations en temps réel avec une très bonne résolution temporelle à l'ordre de la milliseconde, alors l'information temporelle présentée dans le signal est prometteuse et non négligeable. En d'autres termes, les variations temporelles du signal EEG sont donc considérées comme des caractéristiques significatives.

Les méthodes temporelles utilisées dans les systèmes ICMs sont adaptées particulièrement à la description des phénomènes neurophysiologiques se trouvant dans un signal EEG avec une signature de temps précise et spécifique comme le P300 [12] ou la désynchronisation du rythme mu déclenchée notamment lors de l'imagerie motrice [13].

##### 2.2.1.1 paramètres Hjorth

Pour caractériser certaines mesures dans le signal EEG Hjorth propose une méthode en 1970 pour calculer trois méthodes à savoir l'activité, la mobilité et la complexité [14]. Les paramètres appelés Hjorth sont calculés à partir de la dispersion du signal EEG ainsi que sa première et seconde dérivée. Ils caractérisent la dynamique temporelle du signal.

##### 2.2.1.2. Paramètres autorégressifs

Le modèle autorégressif (AR) décrit le signal stationnaire EEG avec peu de coefficients. Les valeurs de ces derniers décrivent les propriétés de la variation temporelle du signal.

Les paramètres (AR) estimés sur plusieurs petits segments du signal EEG sont des grandeurs du domaine du temps tout en supposant que le signal courant est une combinaison linéaire de ses valeurs précédentes [15, 16].



## **Chapitre II : Les méthodes d'extraction de caractéristiques et de classification pour les ICMs**

### **2.2.2 Méthodes fréquentielles**

Dans le domaine fréquentiel, le signal EEG est représenté en fonction de la répartition statistique de sa fréquence et de son amplitude. Certaines tâches mentales comme l'imagerie motrice provoquent la variation de l'amplitude de certains rythmes. En outre, le signal potentiel évoqué visuel (SSVEP) est défini par des oscillations contenant des fréquences synchronisées avec la fréquence du stimulus. C'est pour cette raison, que l'information fréquentielle intégrée dans le signal EEG est étudiée par les méthodes définies ci-dessous.

#### **2.2.2.1 La méthode de "bandpower" BP**

L'une des méthodes fréquentielles les plus connues dans les ICMs pour l'extraction des caractéristiques est la méthode de BP. Cette méthode se base sur la variabilité de certains rythmes obtenus surtout lors de l'imagerie motrice pour avoir une puissance dans les bandes de fréquence. Par ailleurs, cette méthode de BP permet en premier lieu d'appliquer un filtre numérique passe-bande dans une bande de fréquence appropriée à chaque sujet lors de l'imagerie motrice. Les caractéristiques déterminées par la méthode de BP sont généralement calculées préalablement car elles sont spécifiques à chaque sujet. Ces caractéristiques vont ainsi décrire les propriétés pertinentes des phénomènes physiologiques qui existent dans le signal EEG. Avec la méthode de BP, les caractéristiques extraites du signal EEG représentent la puissance dans certaines bandes de fréquence et plus précisément la puissance des rythmes sensorimoteurs mu et beta. Dans le cas du phénomène de SSVEP, les caractéristiques extraites par cette méthode représentent la fréquence de la stimulation visuelle dans la partie occipitale [17]. Cette méthode a été utilisée avec succès dans le domaine des ICMs pour classifier l'imagerie motrice [18, 19, 20, 21], le P300 [22] et les tâches cognitives [23].

#### **2.2.2.2. La densité spectrale de puissance (DSP)**

Le signal EEG est représenté en fonction de la répartition statistique de sa fréquence et de son amplitude. La densité spectrale de puissance (DSP) est une méthode qui représente par ailleurs la répartition de la puissance sur l'axe des fréquences. Les caractéristiques générées par cette méthode sont calculées soit par le calcul du carré du module de la transformée de Fourier, divisée par le temps d'intégration  $T$ , soit par le calcul de la transformée de Fourier de la fonction d'auto-corrélation.

### **2.2.3 Méthodes temps-fréquences**

L'analyse du signal EEG par les méthodes monodimensionnelles temporelle ou fréquentielle, présente des faiblesses dues à sa nature non-stationnaire. Par conséquent, dans cette section

## Chapitre II : Les méthodes d'extraction de caractéristiques et de classification pour les ICMs

nous définirons des techniques pour représenter le signal EEG en temps-fréquence. Le principal avantage de ces représentations est de garder les informations fréquentielles en suivant les variations temporelles du signal. Alors qu'avec les méthodes fréquentielles, le signal est considéré comme étant un signal dans un état stationnaire.

### 2.2.3.1 Fourier à Court Terme : spectrogramme

L'analyse de la Transformée de Fourier à Court Terme en anglais Short-Time Fourier Transform (STFT) est une possibilité d'analyse des signaux EEG dans le domaine temps-fréquences [24]. C'est avec cette technique que l'image complexe des ondes de l'EEG est divisée en composantes d'oscillation de base du domaine du temps en domaine des fréquences. Cette méthode est une transformation liée aux transformées de Fourier utilisée pour déterminer la fréquence sinusoïdale et la phase d'une section locale d'un signal.

### 2.2.3.2. Les ondelettes

Près de 20 ans les chercheurs ont commencé à utiliser des ondelettes (wavelets) comme une alternative à la transformée de Fourier pour l'analyse des signaux acoustiques et sismiques qui posent habituellement des singularités et des transitoires irrégulières [25]. Contrairement à la transformée régulière de Fourier (par exemple les diverses manifestations de longues fonctions trigonométriques), l'analyse en ondelettes fonctionne avec translation et dilatation d'une fonction locale unique  $w$ , appelée l'ondelette mère. Un avantage de la transformée en ondelettes en comparaison avec la transformée de Fourier est que les coefficients d'ondelettes reflètent de manière simple et précise des propriétés de la fonction sous-jacent. Dans le cadre des ICMs, plusieurs travaux ont élaboré la méthode d'ondelette pour caractériser les informations dans le signal EEG [26, 27, 28].

L'ondelette est une technique de décomposition similaire. Elle permet de réduire la taille d'information numérique en mettant en évidence certaines propriétés liées à une activité cérébrale particulière. L'analyse de l'ondelette  $\Psi(t)$  se fait dans un domaine temporel pour la sélection du signal traité. Le facteur d'échelle  $a$  joue le rôle de l'inverse de la fréquence. En fait, plus  $a$  est petit moins l'ondelette est étendue dans le domaine temporel, donc la fréquence centrale de son spectre est élevée. Les ondelettes sont des fonctions  $\Psi_b$ , à très particulières représentant les oscillations les plus courtes et les plus élémentaires dans un signal. Cette fonction est définie par deux dimensions  $b$  et  $a$  représentant respectivement le paramètre de la translation temporelle et l'échelle.

$$\psi_{a,b}(t) = a^{-\frac{1}{2}} \psi\left(\frac{t-b}{a}\right) \quad 2.2.1$$



## Chapitre II : Les méthodes d'extraction de caractéristiques et de classification pour les ICMs

L'ondelette  $\Psi_{b,a}$  est positionnée autour de la fréquence  $f_0/2$ .

La transformée en ondelette est un outil temps fréquence, puisque l'ondelette  $\Psi_{b,a}$  est positionnée autour de la fréquence  $f_0/2$ . Dans le cadre des ICMs, plusieurs travaux ont élaboré la méthode de la transformée en ondelette pour caractériser les informations temps fréquentielles dans le signal EEG [26, 27, 28].

### 3. Classification des signaux EEG

Nous arrivons à l'étape de classification qui définit comment à partir des caractéristiques, déjà sélectionnées dans l'étape précédente, reconnaître l'état mental, d'un individu. Lors des deux dernières décennies, le domaine de l'apprentissage artificiel est devenu l'un des domaines scientifiques les plus féconds. Le but de cette étape dans le cycle d'ICM est de classer ou d'attribuer une classe à un vecteur caractéristique construit précédemment. Un des objectifs de cette thèse est d'étudier les méthodes de classification "classifieurs" adaptées au domaine des ICMs. Pour une présentation plus détaillée sur les notions de base de l'apprentissage ainsi que les différentes méthodes de classification. Dans le domaine des ICMs, les signaux neurophysiologiques enregistrés doivent être traduits en commandes simples destinées pour un ordinateur ou autre dispositif. L'approche la plus simple pour cartographier les signaux est l'apprentissage artificiel. La finalité de ces connaissances est d'attribuer automatiquement une classe ou un label à chaque tâche effectuée. Dans la suite de cette section, nous proposerons quelques concepts de bases de l'apprentissage artificiel puis nous présenterons la taxonomie des différents classifieurs. Enfin, nous achèverons cette section par une présentation des méthodes de classification destinées pour concevoir des ICMs.

#### 3.1 Généralités et Taxonomie des classifieurs

Dans l'apprentissage artificiel, on distingue classiquement l'apprentissage supervisé de celui non supervisé. Les algorithmes qui cherchent à produire automatiquement des règles ou des modèles à partir d'une base de données d'apprentissage contenant des exemples (caractéristiques déjà sélectionnées dans l'étape précédente), sont appelés des algorithmes d'apprentissage supervisé. Le but de ces algorithmes est de généraliser pour des entrées inconnues ce qu'ils ont pu apprendre grâce aux données déjà traitées préalablement. Une base d'apprentissage est un ensemble de couples entrée-sortie  $(x, y)$  avec  $x \in X$  : entrées et  $y \in Y$  : sorties désirées.  $X$  est un ensemble arbitraire souvent des vecteurs avec des valeurs réelles calculées durant la phase précédente à l'aide des méthodes d'extraction de caractéristiques  $c$ .

a.  $d \quad X = \mathbb{R}^D$ . Le but de ces algorithmes supervisés est de généraliser pour des entrées

## Chapitre II : Les méthodes d'extraction de caractéristiques et de classification pour les ICMs

inconnues ce qu'ils ont pu apprendre grâce aux données déjà traitées préalablement. Avec ce type d'algorithme, deux cas se présentent :

- $Y = 1...K$  : Lorsque l'ensemble des valeurs de sorties est fini c'est à dire des mesures qualitatives. On parle dans ce cas du problème de classification qui cherche à attribuer à chaque classe  $K$  une étiquette.
- $Y = R$  : Lorsque la sortie que l'on cherche à estimer est une mesure quantitative dans un ensemble continu de réel.

### Taxonomie des classifieurs

Dans cette partie qui présente la taxonomie des classifieurs, deux problèmes de classification doivent être retenus : le fléau de la dimension pour qualifier le problème de l'augmentation explosive du volume des données EEG au cours du temps et le compromis biais-variance.

- Génératif / discriminatif : Les classifieurs génératifs "exemples bayes, Modèles de Markov caches" permettent d'apprendre les modèles de chaque classe. Ils calculent la Vrai semblance (likelihood) de chaque classe et choisissent par la suite le meilleur. La fonction discriminante ajuster peut résulter d'un modèle probabiliste.

Quant aux classifieurs discriminatifs, comme les Séparateurs à Vaste Marge (Support Vector Machines (SVMs)), sont exprimés directement en utilisant des points de données issus de l'ensemble d'apprentissage [29] [30].

- Statistique / dynamique : Les classifieurs statistiques (exemples : Perceptron multi couches, Support Vector Machines (SVMs)) permettent de classifier un unique vecteur caractéristiques sans prendre en considération l'information temporelle durant l'apprentissage. Contrairement aux classifieurs statiques, les classifieurs dynamiques (exemple les Modèles de Markov cachent [31]), l'information temporelle qui existe dans le signal EEG est prise en compte durant la classification.

- Régularisation : La régularisation consiste à limiter le problème de sur apprentissage. Les méthodes de régularisation peuvent être qualifiées d'actives, car elles ne cherchent pas à limiter la complexité du réseau, mais elles contrôlent la valeur des poids pendant l'apprentissage.

### 3.2 Les méthodes de classification destinées pour les ICMs

Cette section est consacrée à la présentation d'un ensemble de méthodes de classification utilisées dans le contexte des ICMs.



## **Chapitre II : Les méthodes d'extraction de caractéristiques et de classification pour les ICMs**

### **3.2.1 Analyse Discriminante Linéaire**

L'Analyse Discriminante Linéaire (Linear Discriminant Analysis (LDA)) est une technique d'analyse discriminante prédictive. Cette méthode permet de prédire l'appartenance d'un échantillon à une classe déjà prédéfinie a priori par un ensemble de caractéristiques. D'une manière plus pratique, cette méthode cherche à trouver une projection des données d'origine sur un espace plus réduit (lignes, hyperplans ou hyper cubes) pour que les échantillons de différents classes soient bien séparés.

LDA est une technique rapide, simple à implémenter, à comprendre et fournit de bons résultats surtout sur des données linéairement séparables. En conséquence, elle a été largement utilisée dans la communauté des ICMs plus précisément dans l'imagerie motrice [32, 33, 34, 35], P300 [36], les ICMs asynchrones [37] et multi classes [38].

### **3.2.2 Séparateur à Vaste Marge**

Les séparateurs à vaste marge (en anglais Support Vector Machine, SVM) sont un ensemble de techniques d'apprentissage supervisé destinées à résoudre des problèmes de discrimination et de régression. Les SVM sont une généralisation des classifieurs linéaires.

Les SVM ont été développés dans les années 1990 à partir des considérations théoriques de Vladimir Vapnik sur le développement d'une théorie statistique de l'apprentissage : la théorie de Vapnik Chervonenkis [39]. Les SVM ont rapidement été adoptés pour leur capacité à travailler avec des données de grandes dimensions, le faible nombre d'hyper paramètres, leurs garanties théoriques, et leurs bons résultats en pratique.

Les SVM ont été appliqués à de très nombreux domaines (bio-informatiques, recherche d'information, vision par ordinateur, finance....) [40]. Selon les données, la performance des machines à vecteurs de support est de même ordre, ou même supérieure, à celle d'un réseau de neurones ou d'un modèle de mélanges gaussiens.

### **3.3.3 Chaîne de Markov Cachée**

Le modèle de Markov caché (HMM) est un outil puissant pour la modélisation statistique des séquences génératives qui peut être caractérisé par un processus sous-jacent générant une séquence observable. Les HMMs ont été appliqués dans de nombreux domaines liés au traitement du signal en particulier en traitement de la parole [39]. Les HMMs connaissent actuellement un net regain d'intérêt dans le domaine des ICMs, Plusieurs travaux ont utilisé la méthode de classification HMM dont [40, 41, 42]



### 4 Enjeux actuels des ICMs et problématique du choix des méthodes adéquates

Comme nous venons de voir dans les sections précédentes, de nombreuses méthodes et approches ont été appliquées dans la conception des ICMs. Mais il apparaît néanmoins que les ICMs sont assez loin d'être robuste pour que leur développement dans la vie quotidienne soit possible. Plusieurs Algériens sont touchés directement ou indirectement par une maladie du cerveau. D'ailleurs, ces maladies neuro-dégénératives graves deviendront bientôt une des premières causes de mortalité dans le monde. Malheureusement, l'utilisation d'un tel système comme l'ICM destiné pour les personnes atteintes de ces maladies reste extrêmement négligeable en Algérie. Cependant, pourrions-nous mettre au point un système d'acquisition qui permet de capter l'activité cérébrale sur chaque zone du cerveau tout en gardant une résolution temporelle très exacte proche de la milliseconde, et concevoir une ICM lisant chacune de nos pensées sans délai ? La réponse à une telle question reste néanmoins un peu difficile car l'utilisation de l'ICM est jusqu'à présent confrontée à plusieurs contraintes. Le rapport signal sur bruit des signaux EEG, que nous utilisons et qui sont les plus répandus dans la conception des ICMs, est généralement faible et difficile à interpréter correctement. En plus, la conception de l'ICM touche plusieurs domaines divers tels que le traitement de signal, la neurophysiologie et l'apprentissage artificiel. Pour bien maîtriser un système ICM il faut collecter le savoir de plusieurs connaisseurs et experts de chaque domaine. Rien n'est moins sur, l'étude du cerveau et de son fonctionnement nous sont encore relativement pas très clair, plus précisément l'analyse du signal qu'il le produit est confrontée à plusieurs challenges : par exemple réussir à traduire exactement l'imagerie motrice produite par le sujet. En outre, il est difficile pour qu'un sujet réalise une tâche mentale stable au cours du temps. Les problématiques de la thèse peuvent s'énoncer comme

- L'étude des phénomènes neurophysiologiques correspondants à l'imagerie motrice.
- L'étude du signal EEG adapté à l'imagerie motrice effectuée par le sujet. Cette étude se fait par le choix des meilleures méthodes d'extraction de caractéristiques et de classifications pour mieux traduire le phénomène neurophysiologique en commande bas niveau.

## **Chapitre II : Les méthodes d'extraction de caractéristiques et de classification pour les ICMs**

### **5 Conclusion**

Dans ce chapitre, nous espérons avoir donné les bases et les connaissances suffisantes pour comprendre les méthodes d'extraction de caractéristiques et de classification utilisées pour concevoir les systèmes ICMs. Le phénomène neurophysiologique que nous avons opté dans notre thèse est l'imagerie motrice. Nous présenterons dans le chapitre qui suit les algorithmes de traitement des données. Sachant que le signal EEG est non stationnaire, pour ce faire nous avons alors choisi la méthode d'ondelette comme méthode d'extraction des caractéristiques conçue pour ce type de signaux. En ce qui concerne la classification, nous avons appliqué le classifieur KPPV : K-Plus Proche Voisin.

# CHAPITRE III

Conception d'un system ICM

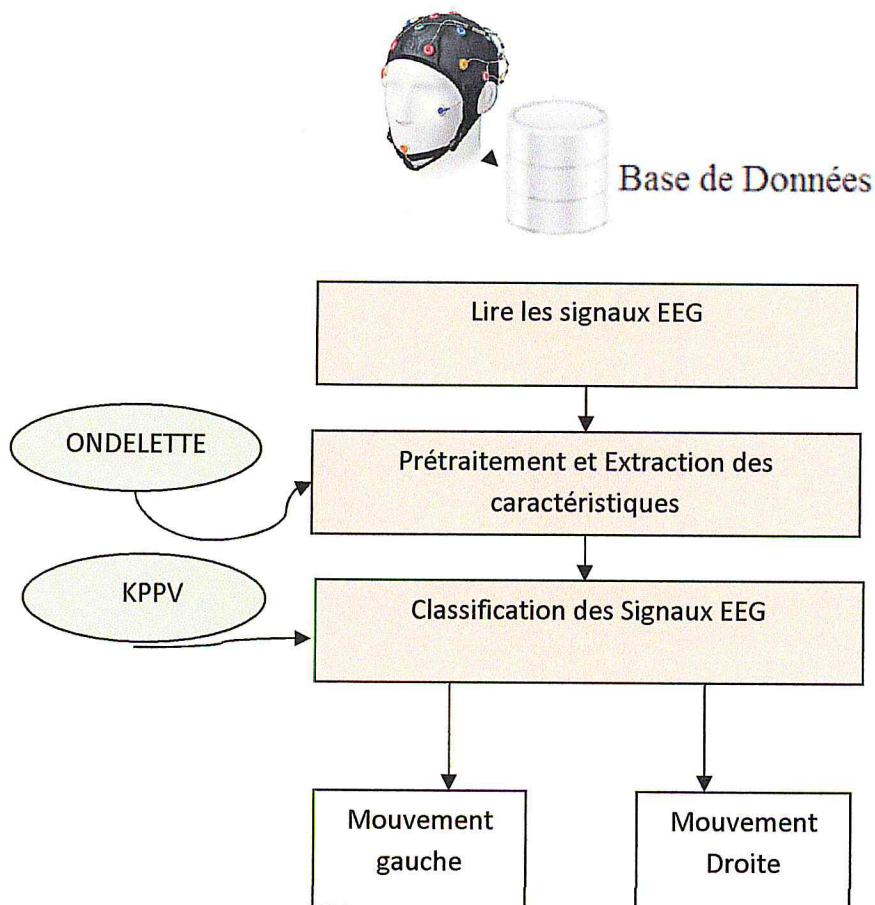


## 1 Introduction

Du fait du cadre du démonstrateur (Guidage d'un objet à partir des signaux cérébraux EEG), un système de deux classes, permettant ainsi de contrôler les 2 directions :

- Mouvements de la main gauche pour tourner à gauche
- Mouvements de la main droite pour tourner à droite

L'objectif est donc de mettre en place un système ICM basé sur l'imagerie motrice, dont les signaux cérébraux seront acquis par EEG et sont stockés dans une base de donnée .la phase d'acquisition et prétraitement de ses signaux c'est une étape déjà réalisé. La **Figure 14** Montre un schéma générique du notre système proposé pour le développement d'une interface cerveau-machine.



**Figure 14 :** Schéma générique du system proposé

## **2. Analyse et extraction de caractéristiques des signaux non stationnaires et non linéaires par l'Ondelette.**

### **2.1 Introduction**

Nous avons déjà présente la plupart des méthodes d'extraction de caractéristiques Conçues pour la conception des ICMs dans le chapitre II. En fait, les méthodes Conçues pour quantifier les fréquences des rythmes sensorimoteurs. Sont généralement des méthodes fréquentielles ou temps-fréquentielles. Pour extraire la bande de puissance de certains rythmes à partir du signal EEG et les exploiter comme caractéristiques, plusieurs techniques ont également été utilisées dans la littérature des ICMs. Le chercheur Herman et ses collègues [47] ont démontré que les approches comme Welch et Yule-Walker basées sur la densité spectrale de puissance, dominant principalement les autres approches étudiées. Cependant, ces approches se fondent sur une certaine linéarité et l'hypothèse de la stationnarité. En effet, elles consistent à moyenner plusieurs estimations spectrales (en utilisant la transformée de Fourier (TF)) par un fenêtrage dans des segments courts de données. En général, la précision du calcul de la (TF) est étroitement liée au choix de la durée du segment de signal. En revanche, ce choix est difficile dans l'analyse du signal EEG due a son non linéarité et non stationnarité. La transformée en ondelettes est une approche pour le traitement des signaux non linéaires et non stationnaires [48]. Elle est caractérisée par l'étude de la fréquence ainsi que par l'échelle du temps. Cependant, Le chercheur Herman et ses collègues ont prouvé que l'utilisation de la densité spectrale de puissance est meilleure que la transformée en ondelettes. Quelques années plus tard, le chercheur Brodu et ses collègues [49] ont démontré que lorsque la résolution temps-fréquence est correctement sélectionnée, l'ondelette de Morlet devient la technique d'extraction la plus efficace. En fait, ils ont justifié les résultats en utilisant la validation croisée des paramètres d'ondelettes de Morlet tout en gardant plus de bandes de fréquence. Quoique, les approches de la transformée en ondelettes sont plus efficaces que la transformée de Fourier, elles montrent beaucoup d'ambiguïté dans la décomposition du signal ; et cette décomposition est non adaptative. De plus, elles nécessitent la spécification d'un noyau ou d'une fonction de base. Avec ces méthodes, la présence de termes d'interférences nuit à la lisibilité des représentations obtenues et bien sur dans notre système ICM aux caractéristiques que nous pouvons extraire pour bien classifier les imageries motrices effectuées.



## 2.2 Transformée en ondelettes

Une ondelette est une fonction élémentaire, à valeurs réelles ou complexes, très concentrée à la fois en temps et en fréquence [49]. Elle doit répondre à deux critères :

1- Elle doit avoir un support compact, c'est-à-dire qu'elle se localise sur un petit intervalle de temps.

2- Elle doit être de moyenne nulle.

$$\int_{-\infty}^{+\infty} \psi(t)dt = 0 \dots\dots\dots 2.2.1$$

C'est la condition d'admissibilité car c'est cette condition qui a donné le nom d'ondelette.

La transformée en ondelettes d'un signal s(t) est définie par la formule :

$$C_{a,b} = \int_{-\infty}^{+\infty} s(t) \cdot \psi_{a,b}(t)dt \dots\dots\dots 2.2.2$$

La transformée en ondelettes d'un signal s(t) est la famille C(a,b) des coefficients d'ondelettes qui dépend des deux paramètres a et b. Suivant les besoins de l'analyse du signal s(t), les paramètres (a,b) peuvent être utilisés de façon continue (TOC) ou discrète (TOD).

Dans notre travail on a utilisé ses paramètres d'une façon discrète.

Il ya plusieurs ondelettes mères utilisées pour le calcul de la transformée en ondelette des signaux analysés. Chacune d'entre elles a un domaine d'application défini de la forme du signal étudié, dans notre travail on a appliqué l'ondelette de Daubechies.

### 2.2.1 La transformée discrète en ondelettes (DWT)

Nous présentons dans cette partie les notions fondamentales sur la DWT qui sont utiles pour la définition et l'optimisation des espaces de représentation (pour plus de détails, voir les ouvrages [Abry, 1997 ; Mallat, 1999]). Etant donné un signal x et une ondelette mère  $\psi$  vérifiant les conditions d'admissibilité suivantes :

$$\int_{-\infty}^{+\infty} \psi(t)dt = 0 \dots\dots\dots 2.2.3$$

$$\int_0^{+\infty} \frac{|\psi^\wedge(\xi)|^2}{\xi} dt < +\infty \dots\dots\dots 2.2.4$$

la DWT est une transformée non redondante qui décompose le signal x sur la base d'ondelettes discrètes correspondant à toutes les versions de  $\psi$  dilatées et décalées suivant une grille dyadique. Elle fournit un ensemble de coefficients :



$$DWT_{x(j,k)} = \langle x(t), \Psi_{j,k}(t) \rangle \dots\dots\dots 2.2.5$$

$$\text{Avec : } \Psi_{j,k}(t) = 2^{-j/2} \Psi\left(\frac{t-2^j k}{2^j}\right) \dots\dots\dots 2.2.6$$

j et k correspondant aux indices d'échelle et de temps. L'ondelette  $\psi_{j,k}$  analyse le signal à l'échelle  $2^j$  autour de l'instant  $2^j k$ . En termes fréquentiels, la DWT réalise un banc de filtre : l'analyse aux grandes échelles rend compte du comportement bas fréquences du signal tandis que l'analyse aux petites échelles met en évidence son comportement aux hautes fréquences. La longueur de bande des filtres d'analyse n'est pas uniforme mais correspond à un découpage dyadique de l'axe fréquentiel.

**2.2.2 La multi-résolution**

Cette technique consiste à décomposer le signal avec la transformée en ondelette en passant par deux filtres. L'un est un passe bas pour avoir les approximations qui représentent l'allure générale du signal, et l'autre est un passe haut pour avoir ses détails.

Les coefficients d'approximation  $A_{j,k}$ , de l'équation (2.2.7), à la résolution  $2^{j-1}$  sont obtenus à partir des coefficients d'approximation à la résolution  $2^j$  par filtrage en utilisant un filtre de réponse impulsionnelle  $h[n]$  suivi d'un décimateur d'ordre 2, et les coefficients de détail  $d_{j,k}$  sont obtenus à partir des coefficients d'approximation  $A_{j,k}$ , de l'équation (2.2.8), par filtrage en utilisant un filtre de réponse impulsionnelle  $g[n]$  suivi d'un décimateur d'ordre 2 .

$$A_{j,k} = \sqrt{2} \sum_{-\infty}^{+\infty} h[n] A_{j-1,2k+n} \dots\dots\dots 2.2.7$$

$$D_{j,k} = \sqrt{2} \sum_{-\infty}^{+\infty} g[n] A_{j-1,2k+n} \dots\dots\dots 2.2.8$$

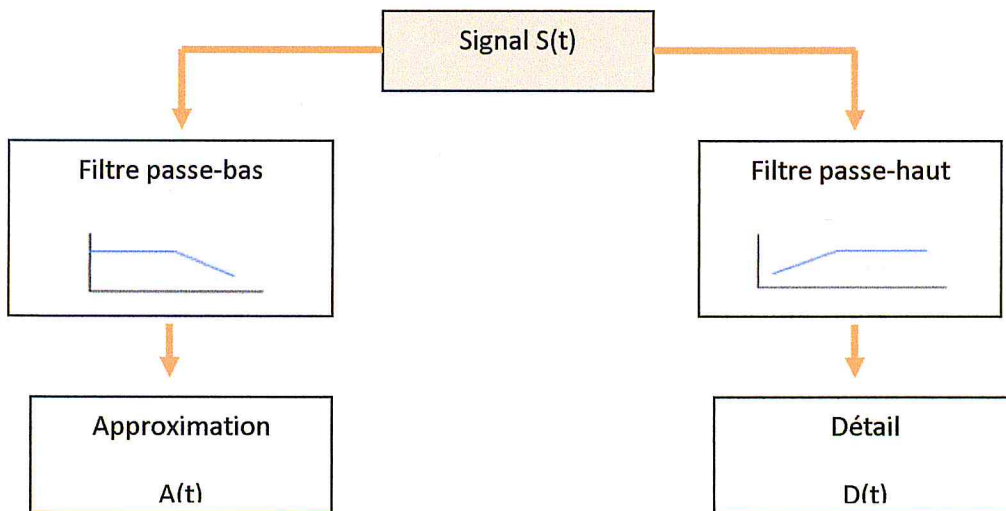


Figure 15. Transformée en ondelette par multi résolution

La forme générale de signal au cours de la décomposition est illustrée dans la figure (16)

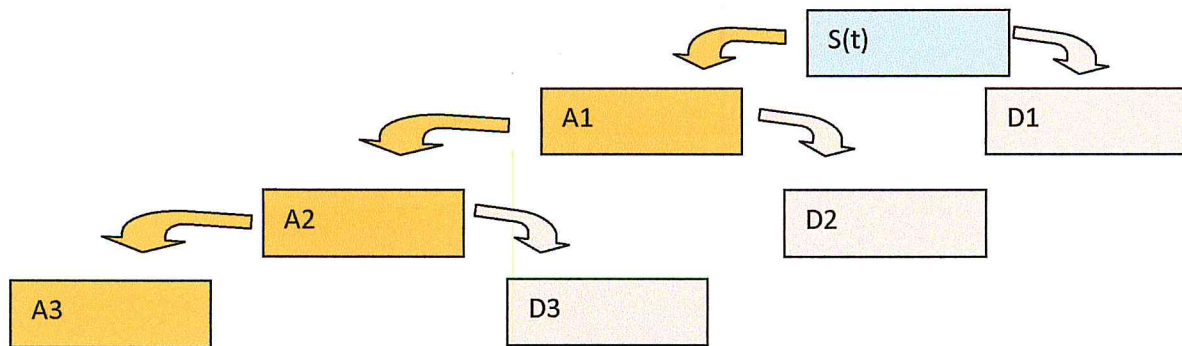


Figure 16 Décomposition de signal en approximations et détails

Donc le signal décomposé s'écrit sous la forme:  $S(t) = D1 + D2 + D3 + A3$  Ici le niveau présenté est de valeur 3 comme exemple.

### 3. Classification des signaux cérébraux par L'algorithme K-plus proche voisin KPPV

Dans le domaine des ICMs, les signaux neurophysiologiques enregistrés doivent être traduits en commandes simples destinées pour un ordinateur ou autre dispositif. L'approche la plus simple pour cartographier les signaux est l'apprentissage artificiel. La finalité de ces connaissances est d'attribuer automatiquement une classe ou un label à chaque tâche effectuée. Dans ce travail on a appliqué la méthode K-Plus Proche voisins (KPPV) afin de classifier nos signaux en deux classes 1 qui représente le mouvement de la main gauche 2 qui représente le mouvement de la main droite. Pour valider notre résultat nous sommes entrainés d'appliquer la méthode SVM pour vérifier l'efficacité de la méthode KPPV.

#### L'algorithme K-plus proche voisin KPPV

L'algorithme KPPV figure parmi les plus simples algorithmes d'apprentissage artificiel. Dans un contexte de classification d'une nouvelle observation  $x$ , l'idée fondatrice simple est de faire voter les plus proches voisins de cette observation. La classe de  $x$  est déterminée en fonction de la classe majoritaire parmi les  $k$  plus proches voisins de l'observation  $x$ . La méthode KPPV est donc une méthode à base de voisinage.



Algorithme 1-PP La méthode du plus proche voisin est une méthode non paramétrique où une nouvelle observation est classée dans la classe d'appartenance de l'observation de l'échantillon d'apprentissage qui lui est la plus proche, au regard des covariables utilisées. La détermination de leur similarité est basée sur des mesures de distance.

Formellement, soit L l'ensemble de données à disposition ou échantillon d'apprentissage :

$$L = \{(y_i, x_i), i = 1, \dots, nL\}$$

où  $y_i \in \{1, \dots, c\}$  dénote la classe de l'individu  $i$  et le vecteur  $x_i = (x_{i1}, \dots, x_{ip})$  représente les variables prédictives de l'individu  $i$ . La détermination du plus proche voisin est basée sur une fonction distance arbitraire  $d(\cdot, \cdot)$ .

La distance euclidienne ou dissimilarité entre deux individus caractérisés par  $p$  covariables est définie par:

$$d((x_1, x_2, \dots, x_p), (u_1, u_2, \dots, u_p)) = \sqrt{(x_1 - u_1)^2 + (x_2 - u_2)^2 + \dots + (x_p - u_p)^2} \dots \dots \dots 3.1.2$$

Ainsi, pour une nouvelle observation  $(y, x)$  le plus proche voisin  $(y(1), x(1))$  dans l'échantillon d'apprentissage est déterminé par :

$d(x, x(1)) = \min_i (d(x, x_i))$  et  $\hat{y} = y(1)$ , la classe du plus proche voisin, est sélectionnée pour la prédiction de  $y$ . Les notations  $x(j)$  et  $y(j)$  représentent respectivement le  $j$ ème plus proche voisin de  $x$  et sa classe d'appartenance. Parmi les fonctions distance types, la distance euclidienne est définie comme suit :

$$d(x_i, x_j) = (\sum_{s=1}^p (X_{is} - X_{js})^2)^{1/2} \dots \dots \dots 3.1.3$$

La méthode est justifiée par l'occurrence aléatoire de l'échantillon d'apprentissage. La classe  $Y(1)$  du voisin le plus proche  $x(1)$  d'un nouveau cas  $x$  est une variable aléatoire. Ainsi la probabilité de classification de  $x$  dans la classe  $y(1)$  est  $P[Y(1) / x(1)]$ . Pour de grands échantillons d'apprentissage, les individus  $x$  et  $x(1)$  coïncident de très près, si bien que  $P[y(1)/x(1)] \approx P[y/x]$  Ainsi, la nouvelle observation (individu)  $x$  est prédite comme appartenant à la vraie classe  $y$  avec une probabilité égale approximativement à  $P[y/x]$ .

**Algorithme KPPV**

Une première extension de cette idée, qui est largement et communément utilisée en pratique, est la méthode des  $k$  plus proches voisins. La plus proche observation n'est plus la seule observation utilisée pour la classification. Nous utilisons désormais les  $k$  plus proches observations. Ainsi la décision est en faveur de la classe majoritairement représentée par les  $k$



voisins. Soit  $K_r$  le nombre d'observations issues du groupe des plus proches voisins appartenant à la classe  $r$

$$\sum_{k=1}^c K_r = k \dots\dots\dots 3.1.4$$

Ainsi une nouvelle observation est prédite dans la classe  $l$  avec :

$l = \text{max}_r(K_r)$  Ceci évite que la classe prédite ne soit déterminée seulement à partir d'une seule observation. Le degré de localité de cette technique est déterminé par le paramètre  $k$  : pour  $k=1$ , on utilise la méthode du seul plus proche voisin comme technique locale maximale, pour  $k \rightarrow n_l$  on utilise la classe majoritaire sur l'ensemble intégral des observations (ceci impliquant une prédiction constante pour chaque nouvelle observation à classifier). Quelques règles sur le choix de  $k$  : Le paramètre  $k$  doit être déterminé par l'utilisateur :  $k \in \mathbb{N}$ . En classification binaire, il est utile de choisir  $k$  impair pour éviter les votes égalitaires. Le meilleur choix de  $k$  dépend du jeu de donnée. En général, les grandes valeurs de  $k$  réduisent l'effet du bruit sur la classification et donc le risque de sur-apprentissage, mais rendent les frontières entre classes moins distinctes. Il convient donc de faire un choix de compromis entre la variabilité associée à une faible valeur de  $k$  contre un 'oversmoothing' ou surlissage (i.e gommage des détails) pour une forte valeur de  $k$ . Un bon  $k$  peut être sélectionné par diverses techniques heuristiques, par exemple, de validation-croisée. Nous choisirons la valeur de  $k$  qui minimise l'erreur de classification.

#### 4. Conclusion

Ce chapitre nous a permis de valider l'approche d'extraction de caractéristiques que nous avons proposée pour la conception d'une ICM plus robuste et plus efficace. Avec deux classifieurs, nous avons pu valider les sessions d'enregistrement de notre jeu de données. Puisque l'imagerie motrice requiert beaucoup d'entraînement et de concentration de la part des sujets. La phase d'implémentation sera présentée dans le prochain chapitre.

# CHAPITRE IV

Réalisation, test et évaluation

## 1. Introduction

Après avoir introduit tous les concepts théoriques nécessaires pour la réalisation de ce projet, ce chapitre va nous permettre de présenter, le plus justement possible, notre système ICM. Ainsi que, de décrire l'environnement mis en place et les outils utilisés, de présenter les algorithmes utilisés et les interfaces réalisées et d'évaluer les résultats obtenus après la réalisation des tests sur notre Système ICM.

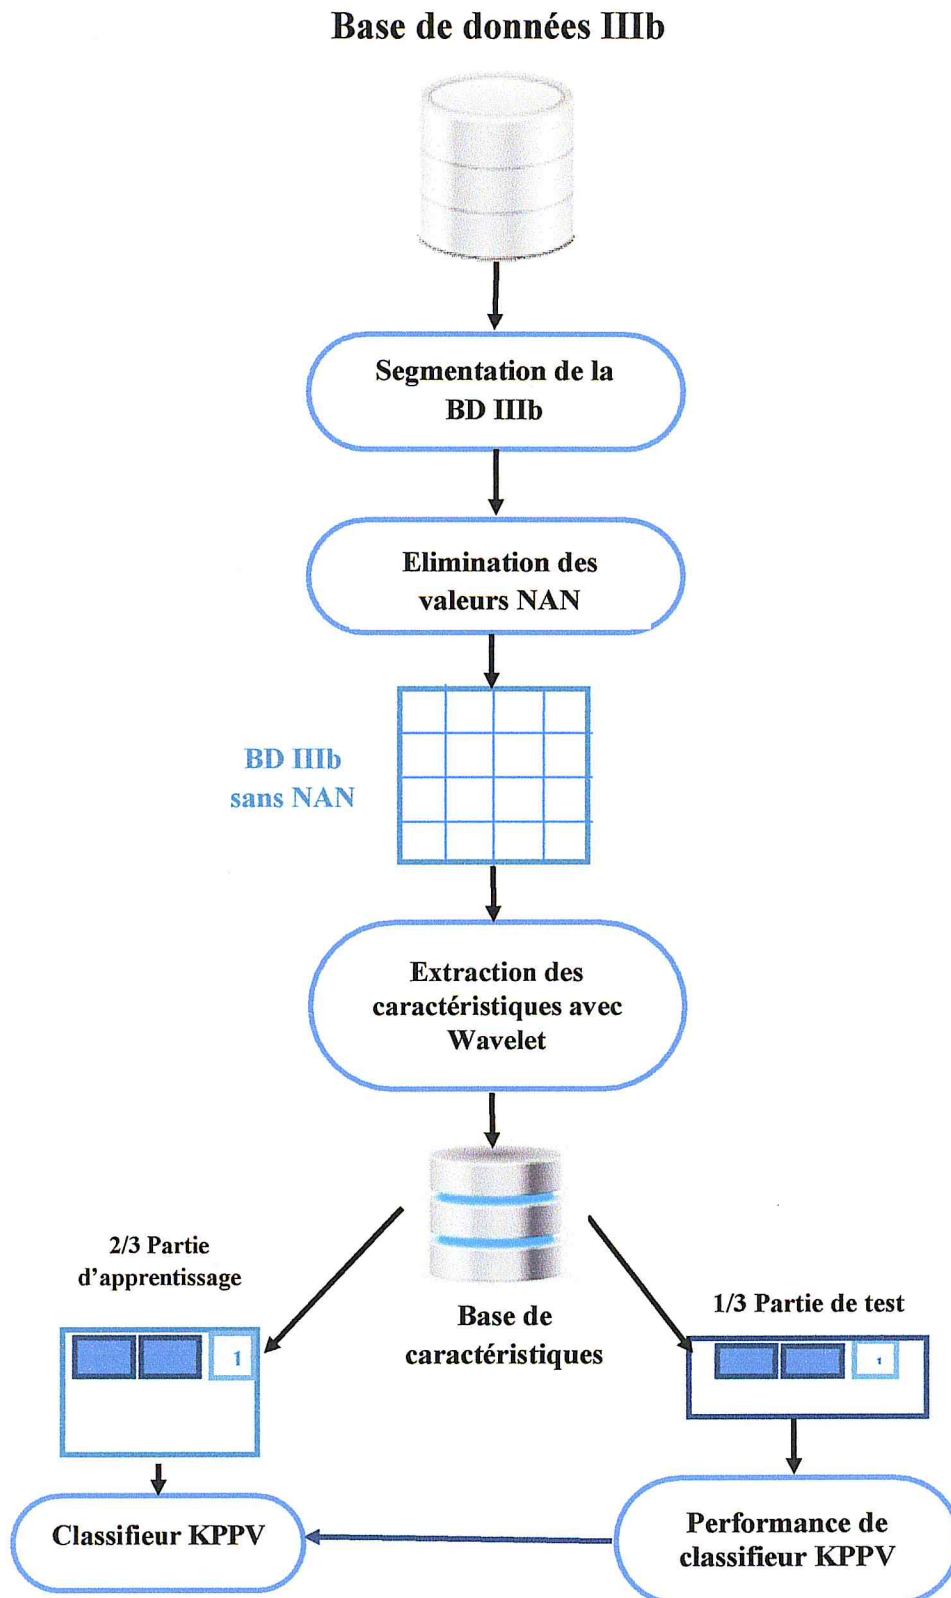
## 2. Système proposé

### 2.1 Introduction

Afin de bien valider l'étape de classification, il faudra en premier lieu étudier l'extraction de vecteurs caractéristiques discriminants à partir des signaux bruts.

En deuxième lieu, nous appliquons sur ces vecteurs caractéristiques la classification afin de leurs attribuer automatiquement une classe indiquant l'état mental. Nous avons déjà propose une méthode d'extraction de caractéristiques basée sur transformer en ondelette dans le chapitre précédent (chapitre III). Cette approche met en évidence les caractéristiques au moyen de la transformation temps fréquence. Dans ce chapitre, nous allons étudier et interpréter les résultats de classifieur déjà présentes dans le chapitre III, KPPV. Afin de valider la méthode d'extraction de caractéristiques que nous venons de proposer. Ce classifieur doit être appliqué sur notre propre jeu de données qui comporte l'imagination des mouvements de la main gauche et droite de 3 sujets. Pour atteindre notre objectif, on a réalisé un système qui contient **trois** principales fonctionnalités, la première consiste La lecture et la segmentation des signaux EEG. La deuxième l'extraction des caractéristiques avec l'ondelette enfin la classification par la méthode KPPV. Voir figure 19





**Figure 17 :** Plan de traitement des signaux EEG de notre système ICM

## 2.2 La lecture et la segmentation des signaux EEG

Après la réception des signaux EEG par un système d'acquisition. Les signaux sont enregistrés dans des formats différents comme par exemple .gdf, .mat et .ASCII. Dans notre cas la base de données a le format .mat. Pour chaque sujet, les échantillons (les sessions, les essais) sont tous concaténés. Ainsi, pour les segmentés chaque block correspond à un essai, nous utilisons la class TRIG qui fait cette correspondance en donnant à chaque essai son début dans la classe S. voir les figures 20,21.

	1	2	3	4	5
1	0.1232	0.0976			
2	3.8454	-1.4645			
3	6.9083	-2.3799			
4	6.2489	-1.6232			
5	2.8330	0.0610			
6	-0.0603	1.2571			
7	-0.4391	1.2448			
8	1.1847	0.6468			
9	3.3825	0.5370			
10	3.4795	0.5248			
11	2.6857	-1.0862			
12	1.0140	-3.6979			
13	0.2448	-4.9794			
14	0.5745	-5.0648			
15	0.5499	-3.3318			
16	-1.1347	-0.4760			

Figure 18. Exemple d'un enregistrement (sujet 1).

Premier colonne représente les amplitudes enregistrées par l'électrode C3, tandis que l'autre colonne représente les amplitudes enregistrées par l'électrode par l'électrode C4.

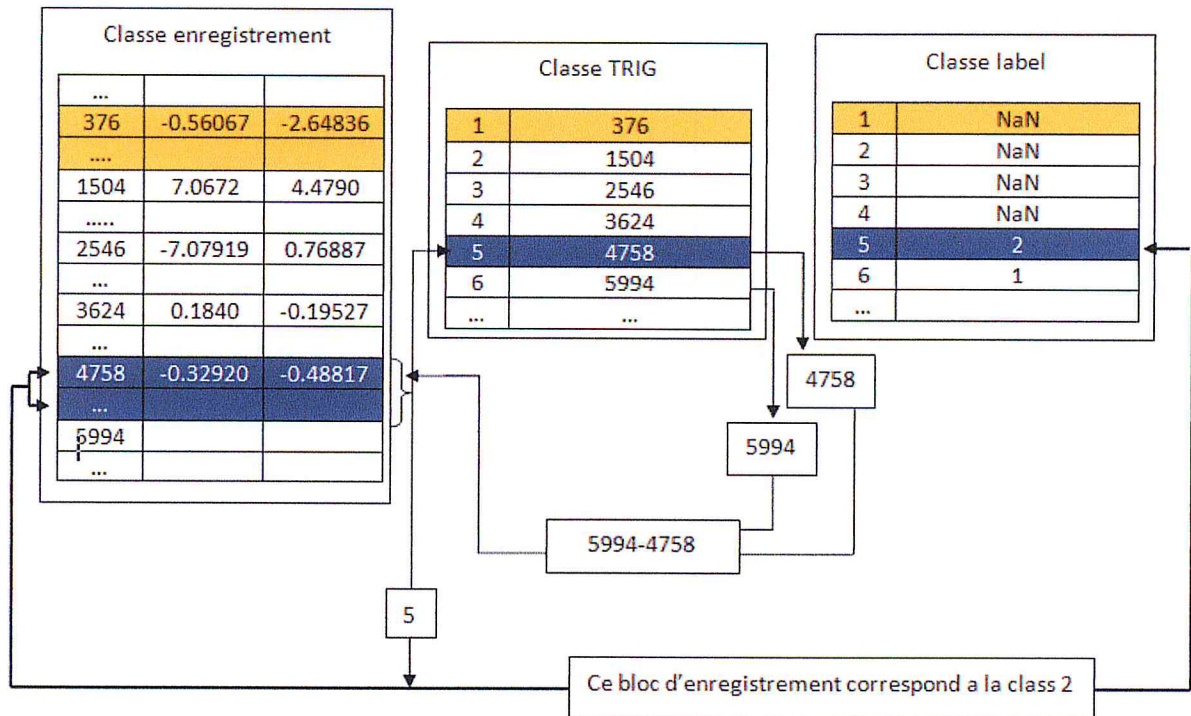


Figure 19 : schéma de correspondance pour segmenter les enregistrements

Après la segmentation de signal, nous avons préparé notre base pour la deuxième étape qui est l'extraction des caractéristiques avec l'ondelette.

### 2.3 Extraction des caractéristiques avec l'ondelette

Une fois que les données sont enregistrées et prétraitées, vient l'étape de l'extraction des caractéristiques. Cette étape est indispensable dans le fonctionnement des ICMs car la quantité de données de l'activité cérébrale mesurée est importante. Au fait, le but de cette méthode est de trouver une meilleure représentation des signaux EEG tout en gardant les informations les plus pertinentes d'écrivant les propriétés d'une tâche mentale effectuée. Ces informations sont appelées caractéristiques ou features dans notre cas les caractéristiques sont la puissance du signal.



### 2.3.1 Décomposition en ondelettes

Les ondelettes sont des outils puissants en analyse mathématique et dans des domaines plus appliqués tels que le traitement du signal et des images, notamment grâce à leurs applications en compression et en débruitage [Mallat, 1999]. Considérons un signal mesuré discret  $x(k)$  (avec  $k = 1; \dots; N$  où  $N$  est la longueur du signal) comme une ligne de la matrice  $X$ . Ce signal peut être modélisé comme la somme d'une partie informative  $c$  et d'un bruit  $n$  (considéré comme un processus aléatoire)  $x(k) = c(k) + n(k)$ . Pour pouvoir extraire les caractéristiques d'un signal EEG on a utilisé méthode s'appelle Wavedec qu'elle s'appartient à la famille d'ondelette, cette dernière est une boîte à outils qui se trouve par défaut dans MATLAB, son rôle et importance est l'extraction des coefficients afin de l'utiliser pour l'extraction des caractéristiques.

#### Syntaxe

```
[detail, Longueur] = wavedec (X, N, 'db1')
```

#### Explication :

`[detail, Longueur] = wavedec (X, N, 'db1')` : return la décomposition de signal  $X$  au niveau  $N$ , en utilisant 'vname'.

$N$  : Doit être un entier strictement positif dans notre cas en appliquons le troisième niveau de détail. La structure de décomposition des paramètres de sortie contient le vecteur de détail d'ondelette 'detail' et le vecteur d'approximation  $L$  et qui correspondre au coefficient utilisé pour l'extraction des caractéristiques du signal ici nous avons présenté les caractéristiques de sujet 1.

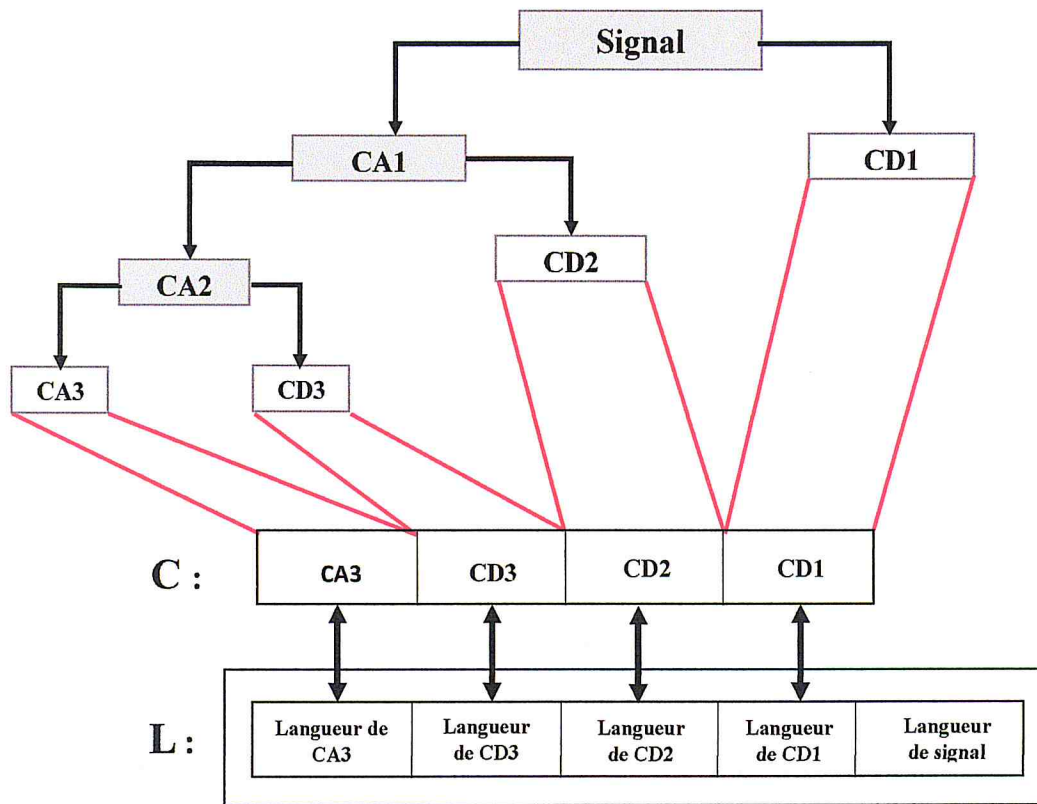
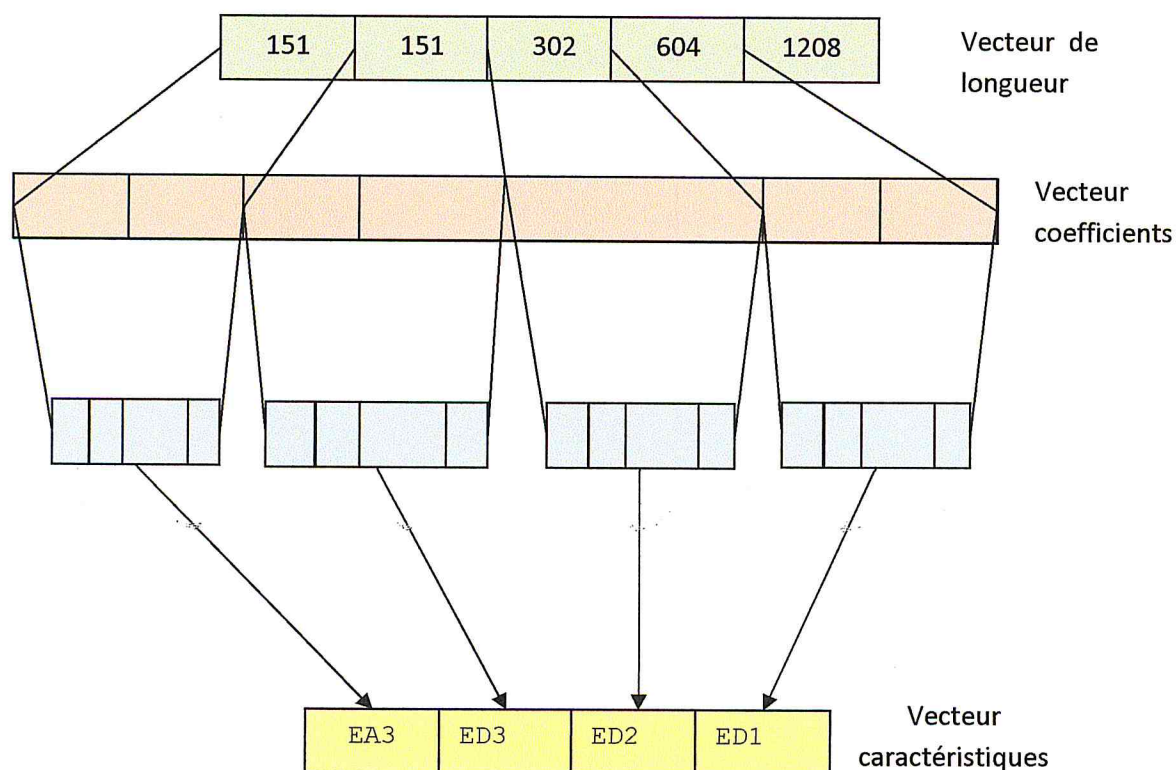


Figure 20 : Décomposition d'un signal EEG en ondelettes [60]

### 2.3.2 Extraction des caractéristiques

Après l'extraction de vecteur de coefficient et le vecteur de longueur, nous avons minimisé Le nombre de coefficient par le calcul de la puissance. Le schéma suivant montre cette étape.



**Figure 21 :** extraction des caractéristiques

## 2.4 Classification des signaux EEG

Pour concevoir un système ICM la classification est considérée comme un élément crucial.

Afin d'utiliser le classifieur KPPV, il faut tout d'abord découper notre base de données IIIb qui a été obtenue après l'application de l'ondelette, en deux parties : deux tiers (2/3) pour la partie d'apprentissage, et un tiers (1/3) pour la partie de test, comme voir la figure 22 :



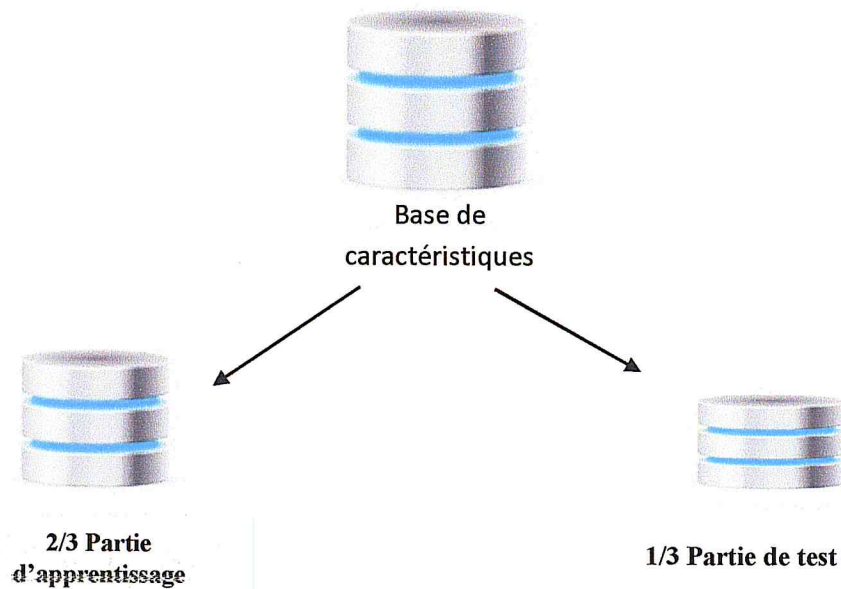


Figure 22 : Décomposition de la BD IIIb en deux parties : l'apprentissage et le test

#### 2.4.1 Phase d'apprentissage

L'apprentissage de la machine consiste à entraîner la machine, pour qu'elle sache avant le test les classes des signaux correspondantes, en utilisant le classificateur KPPV.

#### 2.4.2 Phase de Tests

Une fois les modèles sont construits pour chaque imagerie motrice, vient ensuite l'étape de la validation des données de test par rapport aux modèles déjà construits qui est une base d'apprentissage. Et tester la performance du classifieur KPPV.

La figure 23 montre les deux phases dans la classification avec KPPV

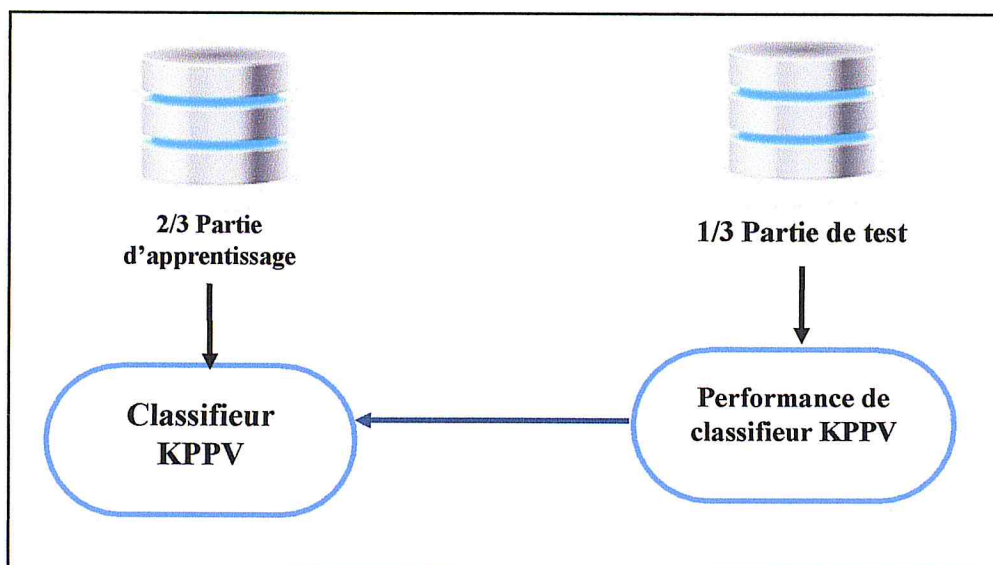


Figure 23 : Classification avec l’algorithme KPPV

### 3. Représentation des résultats

#### 3.1 Resultat de l’application de l’ondelette

	1	2	3	4	5	6	7	8	9	10	11
1	-2.0661	10.5144	11.7486	18.7807	14.7343	-0.8968	-1.2151	8.6842	3.3587	-7.4561	-0.3
2	-10.4896	0.6213	6.6061	6.8262	-0.9450	-5.1909	0.4660	2.6148	-0.6472	-4.0733	5.7
3	-9.5066	-9.7996	4.6011	-6.5940	-18.7248	-0.0863	0.7209	-6.5493	4.4077	5.8758	6.5
4	-21.1021	-9.9470	19.5185	-10.6061	-10.9556	-1.4714	-1.5404	-2.0539	-2.4644	-7.1412	9.4
5	4.1365	-1.1510	-2.4282	-1.5172	-13.2740	-1.1002	-11.3711	2.2799	10.4524	-10.3865	9.2
6	4.7291	3.6903	5.5058	-3.1111	-0.9061	3.6288	-3.3478	14.3568	9.2868	4.4147	-0.5
7	-5.8975	-1.6598	-11.5773	-11.3318	-8.5700	-5.5007	-12.7168	0.7135	0.0583	-4.9486	7.4
8	-10.5500	-3.1067	1.4196	2.2912	-6.3300	-4.9708	-3.4821	-1.5318	2.6709	-3.7928	5.4
9	-4.8324	-0.5815	0.7486	7.4116	3.4752	11.2398	13.2096	6.8032	1.6980	0.0402	-6.9
10	0.5609	12.5348	5.2642	0.2675	4.7939	4.2847	5.7431	1.3204	-8.9448	-6.8219	-12.3
11	-8.3365	8.9074	-12.4808	17.7685	-9.7831	-10.7664	-6.3732	-4.2496	3.6914	-1.3106	3.3
12	-8.7992	5.9201	5.7658	2.6067	5.2469	5.0614	2.0668	-5.5188	2.8608	-3.2837	2.5
13	-4.8279	-4.7328	-3.4685	5.6331	-13.2822	-15.8506	0.8391	6.5747	5.0078	10.2676	8.9
14	-13.8957	1.0178	-11.8358	-1.6095	-8.1120	-0.9450	6.7183	13.9809	4.8456	5.6180	7.3
15	-5.0267	-9.3037	1.6715	-0.3227	-5.0176	3.9629	-2.9630	-3.7268	8.8388	-6.4894	-3.1
16	-5.7734	-5.4670	-3.6375	10.4701	-5.1790	-4.5528	-4.6439	-9.1563	9.6881	-3.8921	0.7
17	-7.2226	-1.7511	5.9907	4.1923	-3.7747	1.7195	-1.1031	-0.2785	2.3155	15.4457	2.4
18	-11.3973	14.0251	20.0509	0.0992	0.5092	-0.0345	6.5673	-9.7873	1.4714	4.8068	-18.0
19	8.9558	16.2008	-2.5187	9.3914	-0.0024	-11.9534	-6.2302	-0.0413	-12.8164	-10.4217	3.5
20	-1.2643	7.4605	0.0259	6.0107	0.7292	-4.0129	4.6558	6.3170	0.0388	-8.0775	0.7

Figure 24 : résultat les coefficients du signal

Les vecteurs de détails, les lignes correspondre au essai les colonnes les coefficients extraite par l'ondelette

	1	2	3	4
1	8.8154e+03	3.5349e+03	2.1586e+03	744.3687
2	7.7511e+03	2.3931e+03	1.7950e+03	635.5294
3	7.8967e+03	5.2643e+03	2.7241e+03	1.0709e+03
4	1.5215e+04	4.2389e+03	1.9003e+03	797.2458
5	9.1003e+03	3.5219e+03	2.2024e+03	836.8217
6	4.8544e+03	3.5401e+03	2.0393e+03	807.6674
7	1.4284e+04	5.6580e+03	2.4631e+03	1.0317e+03
8	1.0964e+04	2.9582e+03	1.5298e+03	594.5938
9	1.1021e+04	3.2594e+03	2.2688e+03	842.7558
10	9.9849e+03	4.1102e+03	2.2404e+03	806.2034
11	1.8183e+04	7.2506e+03	3.4484e+03	1.2424e+03
12	1.5640e+04	4.4484e+03	2.5203e+03	783.9366
13	6.7091e+03	5.0755e+03	2.8317e+03	891.2017
14	8.7414e+03	1.0926e+04	5.0725e+03	1.7313e+03
15	6.2574e+03	2.9354e+03	1.9107e+03	709.0826
16	6.9923e+03	6.0616e+03	2.6309e+03	989.2576
17	7.0925e+03	2.3371e+03	1.6791e+03	596.7555
18	6.9522e+03	4.2864e+03	3.1673e+03	1.1183e+03
19	7.0386e+03	2.8416e+03	2.0608e+03	666.5667
20	4.5704e+03	4.7899e+03	3.1354e+03	908.6668

**Figure 25** : resultat d'extraction caractéristiques de signale

Résultat de l'extraction de caractéristiques (les colonnes sont les caractéristiques les lignes sont les essais)





## 5. Données utilisés

### 5.1 Présentation de l'environnement du travail Matlab

Matlab (**MATrixLABoratory**) est un logiciel pour effectuer des calculs numériques. Il a été conçu initialement pour faciliter le traitement des matrices mais il est maintenant utilisé dans tous les domaines des sciences qui nécessitent de faire des calculs.

#### Intérêts :

- ✓ Programmation infiniment plus rapide pour le calcul et pour l'affichage
- ✓ Une librairie très riche
- ✓ Possibilité d'inclure un programme en C/C++
- ✓ Langage interprété : Pas de compilation donc pas d'attente pour compiler
- ✓ Possibilité d'exécuter du code en dehors du programme
- ✓ Code facile à comprendre et très lisible
- ✓ Une aide très bien faite

#### Inconvénients :

- Vitesse de calcul moins rapide qu'en C/C++
- Payant (équivalent gratuit SCILAB)
- Application auto-exécutable peu pratique

De manière générale, Matlab est utilisé pour faire des expériences de calcul très rapidement. Certains programmes qui nécessiteraient 1 journée de programmation en C/C++ peuvent se réaliser en 1h sous Matlab. Par contre, une fois programmé, le temps de calcul sous Matlab peut être 100 fois supérieur à celui du C/C++. De ce fait, on ne l'utilise que très peu pour réaliser un produit fini destiné aux particuliers. [60]

## 5.2 Base de données IIIb

### 5.2.1 Description

Pour afin de atteindre notre but nous avons utilisé une base de donnée nommée **DATASET IIIb**, obtenue depuis le site d'une troisième compétition des ICM (**BCI compétition III**) et ses données sont non stationnaires et qu'elle contient 2-classe, et de 3 jusqu'à 4 sessions pour 3 sujets différents.

### 5.2.2 Enregistrement des EEG

EEG-données provenant de trois différents sujets au cours d'une expérience BCI. L'expérience se compose de 3 sessions pour chaque sujet. Chaque session compose de 4 à 9 essais. Les données de tous les essais sont été concaténées et converties au format GDF, et ASCII et MATLAB. On a utilisé le format MATLAB. Les enregistrements ont été effectués avec un amplificateur d'EEG de **g.Tec** bipolaire.






Figure 27 : paradigme de l'expérience de réalité virtuelle utilisée pour le sujet O3. [61]

### 5.2.3 Format des données

Les données sont stockées dans le format GDF et qui peut être chargé dans MATLAB en utilisant la commande `[s, HDR] = load (nom de fichier)`. La donnée S peuvent contenir NaN (Not a Number), ces NaN indiquent les pauses entre les pistes ou saturation du convertisseur analogique-numérique. Tous les événements sont stockés selon le tableau d'éventcodes. Le début de chaque essai ( $T = 0s$  selon la figure 1.) Peuvent être obtenus à partir de HDR.TRIG ; les classlabels sont stockés dans HDR.Classlabel. HDR.Classlabel peut les valeurs contenir de « 1 », « 2 » ou « NaN ». Les valeurs '1' et '2' indiquent les étiquettes de l'ensemble de la formation. La base de données BCI IIIb a été prétraitée, ses signaux EEG étaient échantillonnés à 125Hz, ils étaient filtrés entre 0,5 et 30 Hz avec Notchfilter (filtrage moyen), donc on peut passer à l'étape d'extraction des caractéristiques sans d'avoir problème de la mauvaise résolution du signal

Subject	Feedback	Feedback presentation	Channels	Number of trials	Classes
O3	Virtual reality [2]	4-8 s	C3, C4	640	Left-right
S4	Basket, adaptive classifier [3]	4-7 s	C3, C4	1080	Left-right
X11	Basket, adaptive classifier [3]	4-7 s	C3, C4	1080	Left-right

Tableau 4: vue globale de l'expérimentation [61]

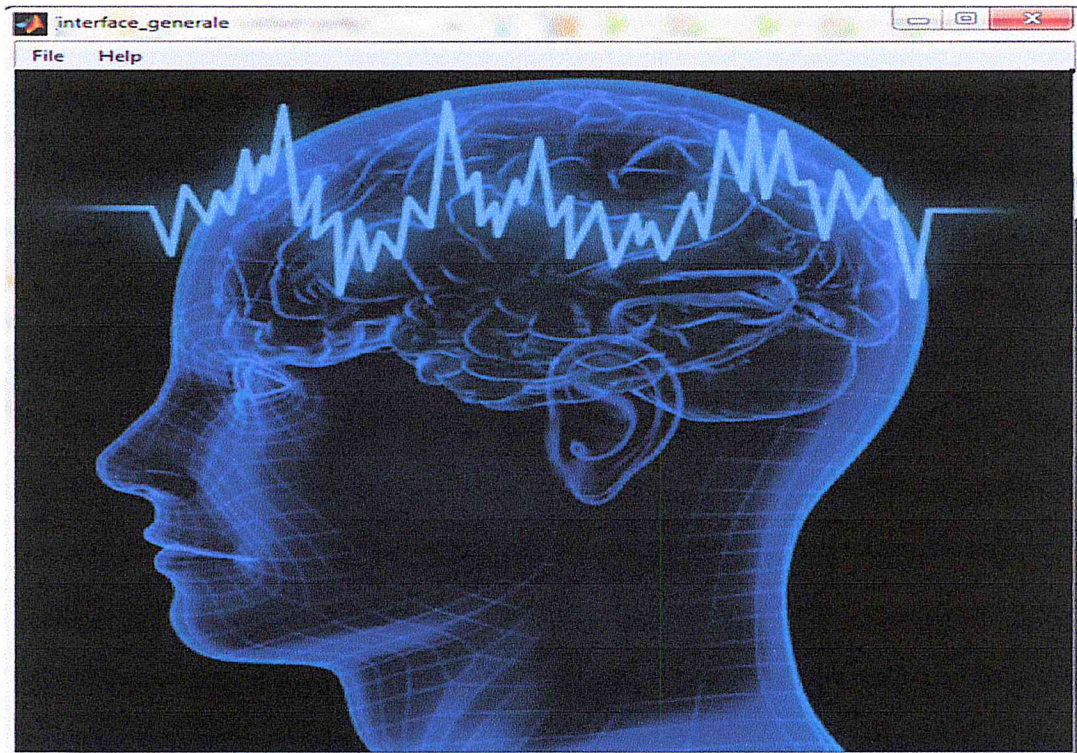


## 6. Interfaces réalisées

Afin de faciliter l'échange des données d'utilisateur avec notre système ICM, nous avons réalisés les interfaces suivantes sous MATLAB :

### 6.1 Interfaces générale

La figure ci-dessous présente l'interface générale de notre système ICM, qu'elle contienne un menu pour les phases d'apprentissage et de test.



**Figure 28:** Interface du système ICM

## 6.2 Interfaces apprentissage

L'interface ci-dessous permet de visualiser le fonctionnement de l'apprentissage de notre système ICM, comme la figure 27 montre.



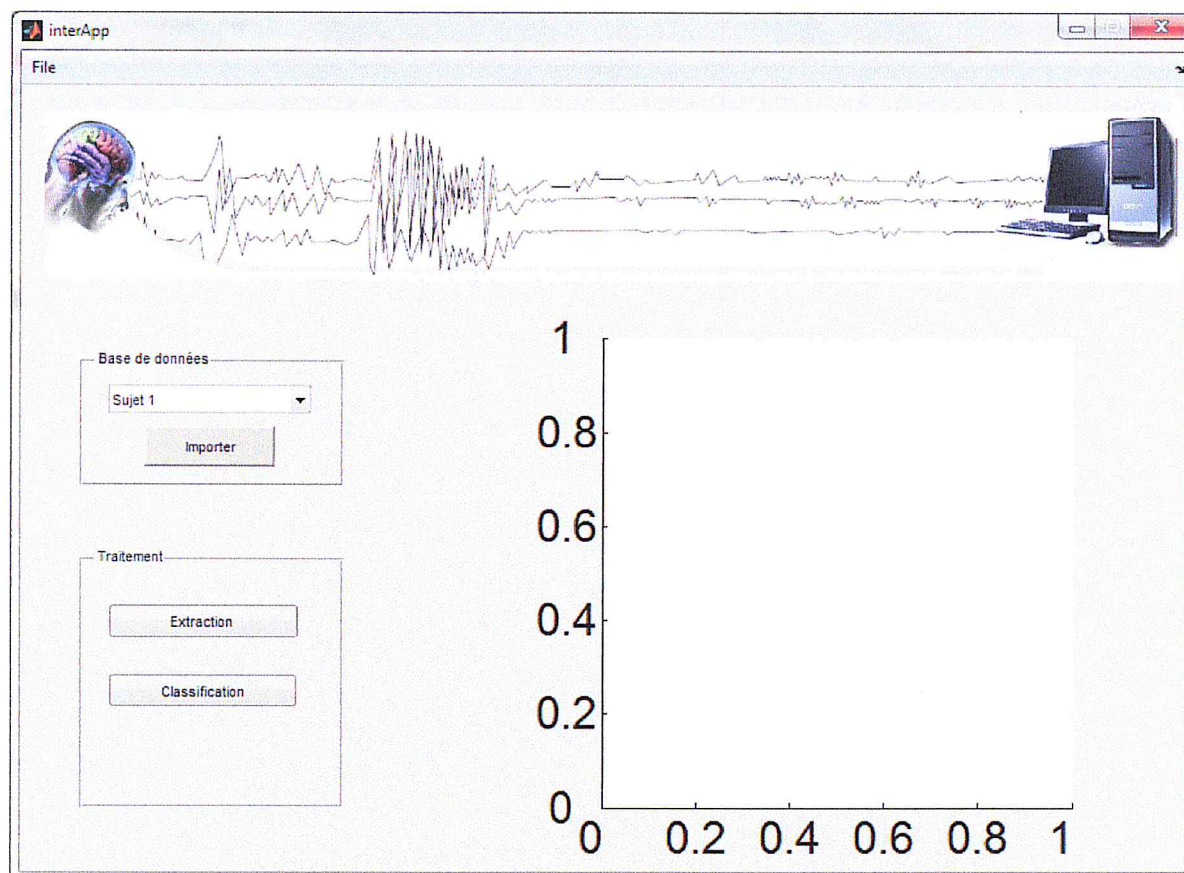


Figure 29 : Interface de l'apprentissage du système ICM

### 6.3 Interfaces de test

L'interface ci-dessous permet de visualiser le fonctionnement de test de notre système ICM comme la figure 28 suivante montre :

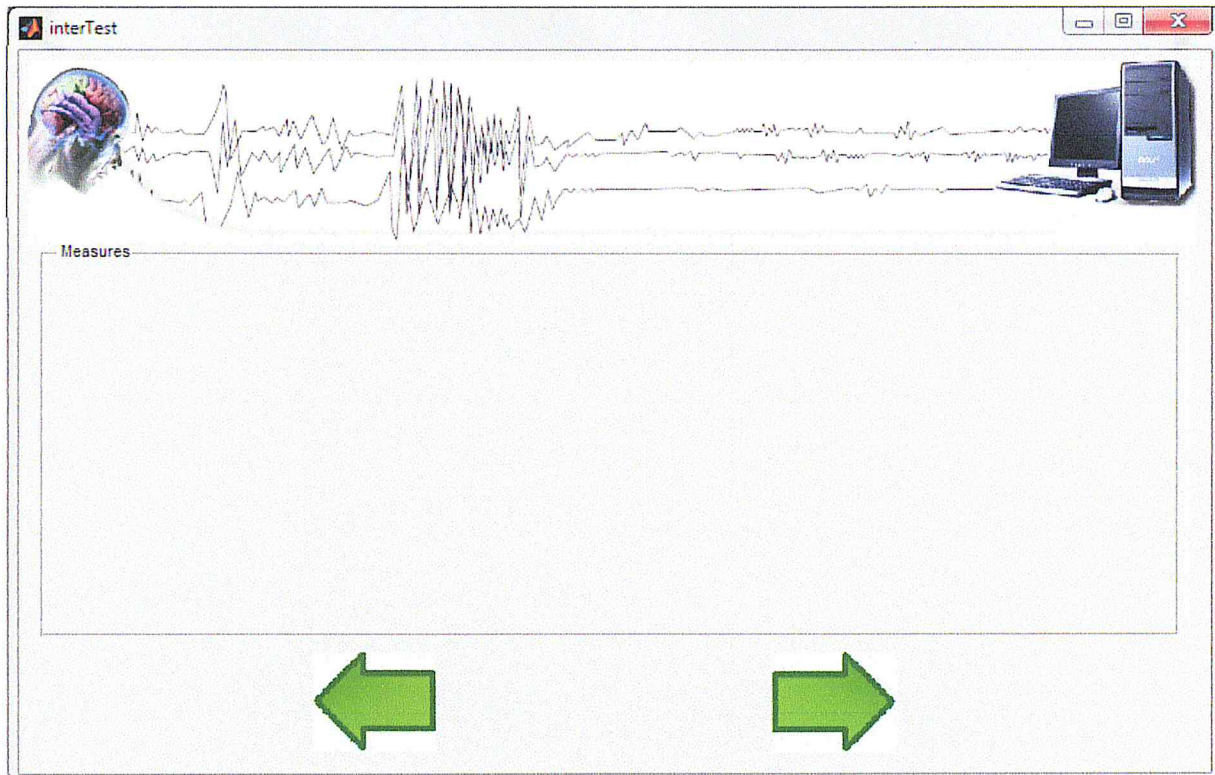


Figure 30 : Interface de Test du système ICM

## 6. Conclusion

On a parlé dans ce chapitre à propos de résultat les fonctionnements nécessaire classification avec KPPV et on a trouvé que le pourcentage de ses erreurs est ... pour trois sujets déferents,

On n'a pas cité dans ce chapitre notre démonstration de la phase d'acquisition avec le casque c.-à-d. un apprentissage et un test en ligne, puisque malheureusement les moyens pour qu'on fasse cette phase-là, n'étaient pas disponibles avant le dépôt de notre thèse. Donc on va la faire et la cité lors de notre soutenance avec ses documentations manquant dans ce chapitre.

Ce thème que nous avons choisi et le système ICM que nous avons développé c'était pour la première fois en Algérie, donc cette version est simple elle contienne juste un seul classificateur et qui le KPPV et nous sommes en train d'explorer le SVM pour qu'elle sera développée dans notre travail de future.

# Conclusion générale



## Conclusion générale

Nous nous sommes intéressés durant ce travail de thèse aux interfaces cerveau machine non invasives utilisant des mesures de l'activité cérébrale par électroencéphalographie (EEG) et plus précisément aux ICM basées sur l'imagination d'actions motrices.

Pour les travaux futurs, les mêmes expériences doivent être effectuées à d'autres sujets de comprendre comment il généralise à travers des sujets puisque l'objectif est de trouver un ensemble de prétraitement des mesures qui peuvent appliquer à tout nouvel objet pour une augmentation des performances. Dans le même sens, ce travail doit être répété avec d'autres classificateurs comme l'analyse discriminante linéaire (LDA) ou les réseaux de neurones afin de déterminer si les résultats se généralisent ainsi à d'autres classificateurs.

En général, ces résultats indiquent un ensemble complet automatisés d'étapes prétraitement de signal EEG qui peuvent le mieux augmenter la performance de signal, et aussi les ICMs nécessitent l'utilisation de méthodes d'apprentissage statistique pour la reconnaissance de signaux. Il est possible d'imaginer un grand nombre de tâches motrices différentes pour contrôler une ICM. Certaines tâches étant mieux discriminées que d'autres, il est important d'utiliser des tâches adéquates. Malheureusement les tâches qui permettent le meilleur contrôle ne sont pas identiques pour tous les sujets.

# Bibliographie

## Bibliographie

- [1] S. Kotler, "Vision Quest - A half century of artificial-sight research has succeeded. And now this blind man can see.," *Wired magazine*, Septembre 2002.
- [2] PR Kennedy and RA Bakay, "Restoration of neural output from a paralyzed patient by a direct brain connection," in *Neuroreport.*, 1998, vol. 9, pp. 1707--1711.
- [3] Guger C, Harkam W, Pfurtscheller G, and Hertenæs C. "Prosthetic Control by an EEG-based Brain-Computer Interface (BCI)." AAATE 5th European Conference for the Advancement
- [4] Farwell L and Donchin E. "Talking off the top of your head : toward a mental prosthesis utilizing event-related brain potentials." *Electroencephalography and Clinical Neurophysiology*, 70(6) :510–523, December 1988.
- [5] Sellers E W, Krusienski D J, McFarland D J, Vaughan T M, and Wolpaw J R. "A P300 event-related potential brain-computer interface (BCI) : the effects of matrix size and inter stimulus interval on performance." *Biological psychology*, 73(3) :242–52, October 2006.
- [6] Lo M-T, Tsai P-H, Lin P-F, Lin C, and Hsin Y-L. "The Nonlinear and nonstationary Properties in EEG Signals : Probing the Complex Fluctuations by Hilbert-Huang Transform". *Advances in Adaptive Data Analysis*, 1 :461–482, 2009.
- [7] J Wolpaw. "Brain' "A computer interfaces for communication and control." *Clinical Neurophysiology*, 113(6) :767–791, June 2002.
- [8] Lotte F, Congedo M, L'ecuyer A, Lamarche F, and Arnaldi B. "A review of classification algorithms for EEG-based braincomputer interfaces." *Journal of neural engineering*, 4(2) :R1–R13, June 2007.
- [9] Penny W.D and Roberts S.J. "EEG-based communication via dynamic neural network models." In *International Joint Conference on Neural Networks*, pages 3586—3590, 1999.
- [10] Lemm S, Schafer C, and Curio G. "BCI Competition 2003–Data set III : probabilistic modeling of sensorimotor mu rhythms for classification of imaginary hand movements." *IEEE Trans Biomed Eng*, 51(6), 2004.
- [11] Obermaier B, Guger C, Neuper C, and Pfurtscheller G. "Hidden Markov models for online classification of single trial EEG data." *Pattern Recognition Letters*, 22(12) :1299–1309, October 2001.
- [12] Hoffmann U, Mesin V-J, Ebrahimi T, and Diserens K. "An efficient P300-based brain-computer interface for disabled subjects." *Journal of neuroscience methods*, 167(1) :115–25, January 2008.
- [13] Schloegl A, Lugger K, and Pfurtscheller G. "Using adaptive autoregressive parameters for a brain-computer-interface experiment." In *Proceedings 19th International Conference IEEE/EMBS*, pages 1533–1535, 1997.
- [14] Hjorth B. "EEG analysis based on time domain properties." *Electroencephalography and Clinical Neurophysiology*, 29(3) :306–310, 1970.



- [15] Niedermeyer E and Da Silva F L. "Electroencephalography : basic principles, clinical applications, and related fields". Lippincott Williams & Wilkins, 3rd edition, 1993.
- [16] Jansen B.H, Bourne J.R, and Ward J.W. "Autoregressive estimation of short segment spectra for computerized EEG analysis.". *Biomedical Engineering, IEEE Transactions on*, pages 630—638, 1981.
- [17] Gao X, Xu D, Cheng M, and Gao S. "A BCI-based environmental controller for the motion-disabled.". *IEEE transactions on neural systems and rehabilitation engineering : a publication of the IEEE Engineering in Medicine and Biology Society*, 11(2) :137–40, June 2003.
- [18] McFarland D J, Lefkowitz A T, and Wolpaw J R. "EEG-based brain 'A' computer interface (BCI) with digital signal processing technology.". *behav. res. meth. Instrum comput*, 29 :337–345, 1997.
- [19] Pfurtscheller G, Neuper C, Flotzinger D, and Pregenzer M. EEG-based discrimination between imagination of right and left hand movement. *Electroencephalography and Clinical Neurophysiology*, 103(6) :642–651, December 1997.
- [20] Trad D, Al-ani T, Monacelli E, Jemni M, and Delaplace S. "Feature extraction based on empirical mode decomposition and band power approaches for motor imagery tasks classification.". *IADIS International Conference Interfaces and Human Computer Interaction*, 2011.
- [21] Trad D, Al-ani T, Monacelli E, Jemni M, and Delaplace S. "Nonlinear and nonstationary framework for feature extraction and classification of motor imagery.". *Rehabilitation Robotics (ICORR), IEEE International Conference on*, pages 1 – 6, 2011.
- [22] Guger C, Daban S, Sellers E, Holzner C, Krausz G, Carabalona R, Gramatica F, and Edlinger G. "How many people are able to control a P300-based brain-computer interface (BCI) ?". *Neuroscience letters*, 462(1) :94–8, October 2009.
- [23] Palaniappan R. "Brain computer interface design using band powers extracted during mental tasks.". *Neural Engineering*, 2005. *Conference Proceedings. 2nd International IEEE EMBS Conference on*, pages 321—324, 2005.
- [24] Jacobsen E and Lyons R. "the sliding DFT.". *IEEE Signal Processing Magazine*, 20(2) :74–80, March 2003.
- [25] Grossmann A and Morlet J. "Decomposition of Hardy Functions into Square Integrable Wavelets of Constant Shape.". *J. Math. Anal.*, 15 :723 – 736, 1984.
- [26] Qin L and He B. "A wavelet-based time-frequency analysis approach for classification of motor imagery for brain-computer interface applications.". *Journal of neural engineering*, 2(4) :65– 72, December 2005.
- [27] Xu B. "Pattern Recognition of Motor Imagery EEG using Wavelet Transform.". *Journal of Biomedical Science and Engineering*, 01(01) :64–67, 2008.
- [28] Hsu W-Y and Sun Y-N. "EEG-based motor imagery analysis using weighted wavelet transform features.". *Journal of neuroscience methods*, 176(2) :310–8, January 2009.

- [18] Bashashati A, Fatourechhi M, Ward R K, and Birch G E. "A survey of signal processing algorithms in brain-computer interfaces based on electrical brain signals." *Journal of Neural Engineering*, 4(2), 2007.
- [29] Ng A and Jordan M. "On generative vs. discriminative classifiers : A comparison of logistic regression and naive bayes". In *Proceedings of Advances in Neural Information Processing*, 2002.
- [30] Rubinstein Y D and Hastie T. "Discriminative vs Informative Learning." In *Proceedings of the Third International Conference on Knowledge Discovery and Data Mining*, pages 49–53, 1997.
- [31] Rabiner L. R. "A tutorial on hidden Markov models and selected applications in speech recognition." *Proceedings of the IEEE*, 1990.
- [32] Hsu W-Y. "EEG-based motor imagery classification using enhanced active segment selection and adaptive classifier." *Computers in Biology and Medicine*, 41 :633–639, 2011.
- [33] Trad D, Al-ani T, Monacelli E, and Delaplace S. "Nonlinear and nonstationary framework for feature extraction and classification of motor imagery." *IEEE International Conference on Rehabilitation Robotics Rehab Week Zurich*, 2011.
- [34] Lugger K, Flotzinger D, Schlögl A, Pregenzer M, and Pfurtscheller G. Feature extraction for on-line EEG classification using principal components and linear discriminants. *Medical and Biological Engineering and Computing*, 36(3) :309–314, 1998.
- [35] Pfurtscheller G and Neuper C. "Motor imagery and direct brain-computer communication." *Proceedings of the IEEE*, 89(7) :1123–1134, July 2001.
- [36] Bostanov V. "BCI Competition 2003–Data sets Ib and IIb : feature extraction from event-related brain potentials with the continuous wavelet transform and the t-value scalogram." *IEEE transactions on bio-medical engineering*, 51, 2004.
- [37] Scherer R, Müller G R, Neuper C, Graimann B, and Pfurtscheller G. "An asynchronously controlled EEG-based virtual keyboard : improvement of the spelling rate." *IEEE transactions on bio-medical engineering*, 51(6) :979–84, June 2004.
- [38] Garrett D, Peterson DA, Anderson CW, and Thaut MH. "Comparison of linear, nonlinear, and feature selection methods for EEG signal classification." *IEEE Trans Neural Syst Rehabil Eng*, 11 :141–144, 2003.
- [39] Rabiner L.R. "A tutorial on hidden Markov models and selected applications in speech recognition." *Proceedings of the IEEE*, 77(2) :257–286, 1989.
- [40] Obermaier B, Guger C, Neuper C, and Pfurtscheller G. "Hidden Markov models for online classification of single trial EEG data." *Pattern Recognition Letters*, 22(12) :1299–1309, October 2001.
- [41] Lee H and Choi S. "PCA+HMM+SVM for EEG pattern classification." In *Seventh International Symposium on Signal Processing and Its Applications*, 2003. *Proceedings*, volume 1, pages 541–544 vol.1. IEEE, 2003.
- [42] Yan T, Tang J, Andong G, and Wang W. "Classifying EEG Signals Based HMM-AR." In *2nd International Conference on Bioinformatics and Biomedical Engineering*, number 4, pages



2111–2114. IEEE, May 2008.

- [43] Joël Dumoulin , GERBIL – Gesture Recognition using a Brain Lightweight Headset . Institut des technologies de l’information et de la communication. Page 18 , 21 , IEEE. Septembre-Février 2010
- [45] Bernhard Schölkopf, Alexander J. Smola, Learning With Kernels: Support Vector Machines, Regularization, Optimization and Beyond, 2002, MIT Press.
- [46] Vladimir Vapnik et A. Lerner, Pattern Recognition using Generalized Portrait Method, Automation and Remote Control, 1963
- [47] Herman P, Prasad G, McGinnity T. M, and Coyle D. ”Comparative analysis of spectral approaches to feature extraction for eeg-based motor imagery classification.”. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 16 :317–326, 2008.
- [48] SG Mallat. A theory for multiresolution signal decomposition : the wavelet representation. Pattern Analysis and Machine Intelligence, IEEE Transactions on, 11(7) :674 – 693, 1989.
- [49] Ayad Mouloud :” Etude comparative d’algorithmes de la transformée en ondelettes: Application à l’analyse des signaux empiriques ». Thèse de magister. Université Ferhat Abbas Sétif. 2005
- [50] Albert Cohen : « Les bases d’ondelettes », Technique de l’ingénieur AF 210, 2002.
- [51] Yves Meyer, Stéphane Jaffard, Olivier Rione : « L’analyse par ondelettes ». Pour la science. Septembre 1987. mensuel N°119, pp. 28-37.
- [52] Michel Misiti, Yves Misiti, : « Les ondelettes et leurs applications ». Edition Hermes, Paris 2003.
- [53] Mahgoun Hafida : « Analyse et caractérisations des signaux vibratoires cyclostationnaire».Thèse de magister, IOMP, Université Ferhat Abbas Sétif,2000.
- [57] Garrett D, Peterson DA, Anderson CW, and Thaut MH. ”Comparison of linear, nonlinear, and feature selection methods for EEG signal classification.”. IEEE Trans Neural Syst Rehabil Eng, 11 :141–144, 2003.
- [58] Rakotomamonjy A and Guigue V. ”Ensemble of SVMs for improving brain-computer interface p300 speller performances.”. in international conference on artificial neural networks, 2005.
- [59] Trad D and Al-ani T. ”Signal processing and classification approaches for Brain-computer interface.”. In Vernon S. Somerset, editor, Intelligent and Biosensors, pages 25–66. InTech, 2010.
- [60] Disponible en ligne : <http://www.samuelboudet.com/fr/matlab>



[61]

Disponible en ligne :  
[http://www.bbcj.de/competition/iii/#data\\_set\\_iiib](http://www.bbcj.de/competition/iii/#data_set_iiib)

