

**Ministère de L'enseignement Supérieur et de la Recherche Scientifique**

Université Mouloud Mammeri de Tizi-Ouzou

Faculté de Génie Electrique et d'Informatique

Département d'Electronique



# *Projet de fin d'études*

En vue d'obtention du diplôme d'ingénieur d'état en électronique  
Option : Communication

## **Thème**

**Analyse de la signature sous marine  
pour la classification des cibles sonar**

**Proposé et dirigé par :**

**M<sup>elle</sup> AIT OUZZOU H.**

**Présenté par :**

**M<sup>r</sup> BENCHABANE AZIZ .**

**M<sup>r</sup> FERRAS MOHAMED.**

Promotion 2008

# Dédicaces

*Je dedie ce travail :*

*A mes parents pour leurs sacrifices et leurs soutients .*

*A mes frères et sœurs*

*A mes amis :Mouloud, Karim, et toute personne que  
j' ai oublié.*

*A mon binôme et fidél ami Moh et sa familles.*

*A notre promotrice*

*Et a tous les étudiants de la prômo 2008.*

**AZIZ**

# Dédicaces

*Je dedie ce travail :*

*A mes parents pour leurs sacrifices et leurs soutients .*

*A mes frères et sœurs*

*A mes amis :Mouloud, Karim, et toute personne que j'ai oublié.*

*A mon binôme et fidél ami Aziz et sa familles.*

*A notre promotrice*

*Et a tous les étudiants de la prômo 2008.*

*Moh.F*

# Remerciements

**NOUS TENONS À REMERCIER :**

LE BON DIEU QUI NOUS A DONNÉ LA BONNE  
SANTÉ ET LA PERSÉVÉRANCE DURANT NOTRE  
CURSUS.

NOS PARENTS ET TOUS CEUX QUI NOUS ONT  
AIDÉ POUR MENER À TERME CE TRAVAIL .

NOTRE PROMOTRICE M<sup>ELLE</sup> AIT OUAZZOU H.

LES MEMBRES DE JURY.

# SOMMAIRE

Introduction.....	01
-------------------	----

## Chapitre I :

### Acoustique sous-marin-Traitement des données sonar

I-1-Définition .....	03
I-2- Historique du sonar.....	03
I-3- Applications .....	05
I-3-1- Application civil.....	05
I-3-2- application militaire.....	05
I-4- Comparaison avec le radar.....	05
I-4-1- La nature de l'onde.....	05
I-4-2- Célérité.....	06
I-5- Types de sonar.....	06
I-5-1- Sonar actif.....	06
I-5-2- Sonar passif.....	06
I-6- Traitement des données sonar.....	07
I-6-1- La banque de données sonar.....	08
I-6-2- Application de la transformée en ondelettes.....	10
I-6-3- Application du fenêtrage (Pondération).....	13
I-6-4- Application de la transformée de Fourier.....	19
I-6-5- Analyse en composantes principales - ACP.....	27

## Chapitre II :

### Approche proposée pour la classification

II-1- Introduction.....	31
II-2- Méthode des K plus proches voisins .....	31
II-2-1 Principe.....	31
II-2-2 Distances métriques.....	31
II-3- L'approche neuronale.....	32
II-3-1- Neurone biologique.....	32
II-3-2- Neurone formel.....	33
II-3-3- Fonction d'activation.....	34

II-3-4- Réseau de neurone.....	36
II-3-5- Apprentissage .....	37
II-3-6- Algorithme de rétro propagation.....	38
II-3-7- Etapes de l'algorithme de rétropropagation de l'erreur.....	39
II-4- Conclusion.....	41

## Chapitre III : Test et résultats

III-1- Introduction.....	42
III-2- Construction de la banque de données.....	42
III-3- Les paramètres des classifieurs.....	42
III-4- Evaluation des performances du classifieur.....	43
III-4-1- Diagramme de l'erreur.....	43
III-4-2- Matrice de confusion.....	43
III-5- Présentation des résultats obtenus.....	44
III-5-1 Quelques résultats obtenus par la rétro propagation.....	44
III.5.2 Quelques résultats obtenus par le 1 plus proche voisin.....	46
III-6- Conclusion.....	47
Conclusion.....	48

L'acoustique sous-marine est apparue comme un champ d'intérêt scientifique essentiellement après la deuxième guerre mondiale et a attiré ainsi un grand nombre de chercheurs scientifiques à travers le monde.

En navigation maritime, tout comme en navigation aérienne et routière, il est nécessaire de se repérer par rapport à son environnement fixe, mais aussi à l'environnement mobile.

L'instrument permettant d'obtenir ce champ d'observation dans le milieu sous marin est le SONAR (SOund Navigation And Ranging), dont nous verrons le principe plus en avant. Ce système est comparable à son « grand frère » (car plus ancien) : le RADAR (Radio Detection And Ranging), qui est plus connu. Le RADAR est employé dans tous les types de navigation, et permet de localiser les obstacles alentour (roches, mobiles,...). En navigation maritime, il est employé pour détecter des objets situés au-dessus de la surface (avion, hélicoptère, ...) et au niveau de la surface (bateaux, éléments géographique, ...). Toutefois, le RADAR ne fonctionne pas sous la surface de l'eau. En effet, il utilise des ondes électromagnétiques qui se propagent bien dans l'air. Or, dans l'eau, ces ondes sont très fortement atténuées, de l'ordre de 130 000 dB/Km à 10 KHz, [1]. Il est donc impensable d'utiliser des ondes électromagnétiques comme support de propagation dans l'eau. A celles-ci, il est préféré les ondes acoustiques qui peuvent se propager avec une atténuation nettement moindre, de l'ordre de 0.07 dB/Km à 1 KHz, [1]. On parle alors de système SONAR.

Les applications militaires de l'acoustique sous-marine sont diverses et mettent en jeu des traitements de plus en plus complexes de manière à satisfaire de nouveaux besoins en terme de sécurité. Les progrès technologiques associés à des capacités de stockage et de traitement de plus en plus importantes ont favorisé le développement de techniques innovantes à tous les niveaux de la chaîne de traitement sonar. Parmi les principales applications militaires citons la détection, la localisation, la classification, le suivi (tracking), et la communication. D'un autre côté, il peut être employé dans les applications civiles telles que la localisation des bancs de poissons, la cartographie du fond marin, la prospection sismique, et l'océanographie.

L'objectif de ce travail est de permettre de classifier des cibles sous-marines ou en surface en analysant les sons qu'ils produisent sous l'eau. Ainsi, après acquisition, la signature sous marine doit être traitée afin d'extraire les paramètres pertinents permettant la distinction entre les formes.

Concernant notre application, nous avons utilisé des données acoustiques sonar pour classifier des cibles sous marines. L'idée de base est de ne sélectionner que l'information intéressante par rapport à ce but. Nous avons proposé une approche pour la classification des cibles utilisant des fichiers son type sonar numériques, préalablement filtrés, comme données initiales mais pas en tant que vecteurs caractéristiques. Ces derniers sont obtenus par l'extraction de l'information pertinente en appliquant filtrage Hamming, la transformée en ondelette et compression par analyse en composantes principales. Le classifieur utilisé est neuronal basé sur l'algorithme de la Rétropropagation du gradient de l'erreur.

Le travail qui nous a été proposé sous le thème " **Analyse de la signature sous marine pour la classification des cibles sonar** ", sera présenté en trois chapitres

Dans le premier chapitre, nous présentons brièvement des notions générales sur le sonar, en donnant un aperçu sur les différents types de signatures acoustiques que nous avons utilisé. Nous présentons ensuite les détails des opérations de traitements appliquées aux données sonar qui sont : la pondération en utilisant la fenêtre Hamming, le débruitage en utilisant l'ondelette Daubechies 1 et enfin la compression par analyse en composantes principale (ACP).

Le second chapitre est consacré aux détails de l'approche que nous avons choisie pour la classification. Les méthodes retenues sont le 1 plus proche voisin et la Rétropropagation du gradient de l'erreur neuronale.

Nous présentons quelques résultats obtenus dans le troisième chapitre.

Enfin, une conclusion et des perspectives concluent le travail de ce mémoire.

## I.1 DEFINITION

L'acoustique sous marine est l'ensemble des techniques qui utilisent les ondes de vibrations mécaniques pour transmettre et recevoir de l'information dans le milieu marin, par des systèmes de détection appelés SONAR. De tous les supports d'énergie, se sont ces ondes qui se propagent le mieux dans l'eau. Les ondes électromagnétiques s'atténuent tellement vite que les portées obtenues en les utilisant sont extrêmement faibles pour la plupart des applications visées (le coefficient d'absorption est de l'ordre de  $1,3 \times 10^2 \sqrt{\nu}$  dB/km, [1]; où  $\nu$  la fréquence du signal en kHz) c'est-à-dire par exemple, de 130 000 dB/km pour 10 kHz. Qualifiées d'acoustique, ces ondes sont donc le principal moyen d'investigation dans le milieu sous-marin.

**Sonar** : acronyme anglais (*SO*und *N*avigation *A*nd *R*anging), désignant un système de détection fondé sur la réflexion des ondes sonores en milieu marin. Ce système est analogue au radar, qui est fondé sur la réflexion des ondes radio en milieu aérien (*Encyclopédie Larousse*). Plus simplement, un système sonar émet généralement des impulsions ultrasonores grâce à un appareil situé sur ou dans la coque et reçoit les ondes réfléchies par les obstacles à l'aide d'un capteur sensible.

## I.2 HISTORIQUE DU SONAR

L'idée du sonar est très ancienne, remonte aux savants grecs à l'instar de Pythagore qui s'est intéressé à la production du son dans l'eau donc à l'acoustique sous marine, ensuite à Leonardo Da Vinci qui a écrit dans un de ses livres : « Si tu arrêtes ton navire, que tu mette l'autre extrémité à l'oreille, tu entendra les navires très éloignés de toi », [1]. Et depuis le sonar et le traitement des signaux sonar ont connu de grands progrès, surtout durant le vingtième siècle où il furent liés au développement des capteurs que se soit les hydrophones qui écoutent (équivalent des microphones) ou les transmetteurs qui émettent (comme un transporteur) mais qui peuvent aussi écouter. Le principal phénomène physique mis en jeu est la piézo-électricité, [1], c'est-à-dire la transformation d'une contrainte mécanique (ou

acoustique) en électricité, et réciproquement. C'est Paul Langevin qui est le premier, à mettre ce phénomène en évidence en 1917 avec un quartz.

Compte tenu du progrès de l'électronique, il est possible de dire qu'à la période de développement des capteurs, à succédé une période de développement en traitement du signal (filtrage adaptatif, analyse spectrale,.....) à laquelle est en entrain de s'ajouter une période de traitement de l'information (multi antennes, multi cibles,.....) et l'importance de plus en plus grande de tout ce qui concerne l'architecture matérielle (parallélisme, redondance, communication,.....) et logicielles des récepteurs .

Un exemple de système de détection sonar est représentés en Figure I.1.

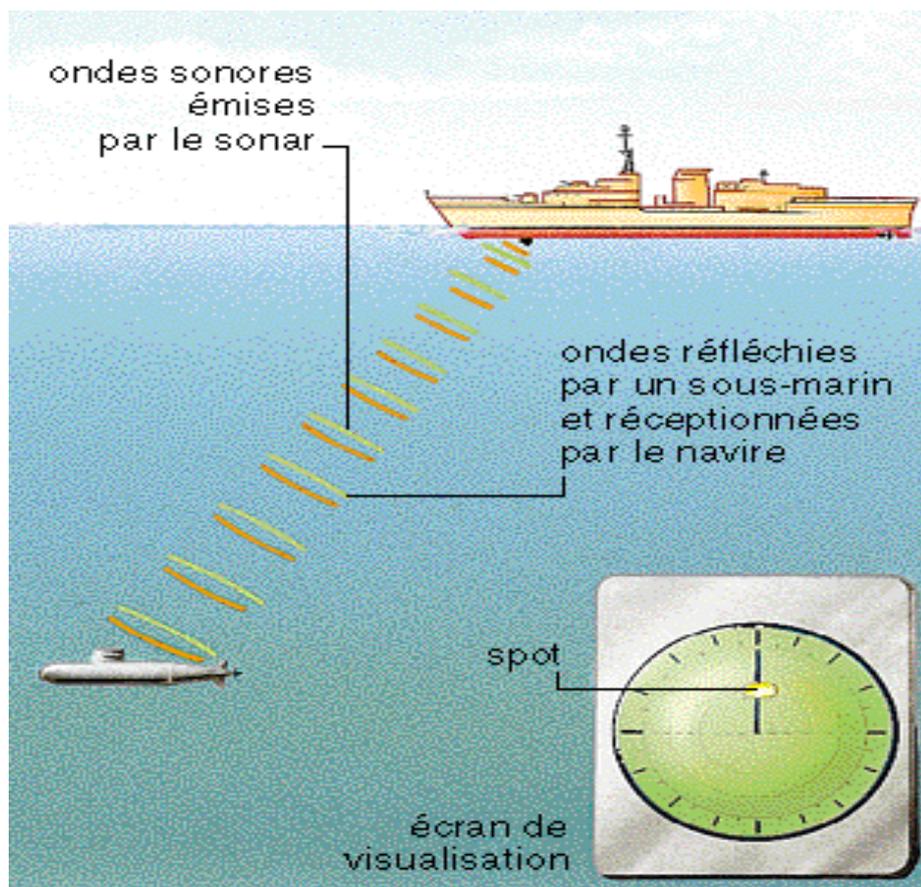


Figure I.1 : La détection d'un sous marin par un sonar mis dans un navire.

## I.3 APPLICATIONS

Les applications de l'acoustique sous-marine et du sonar sont nombreuses. Ces applications peuvent être décrites par les buts recherchés et divisées en deux parties : les applications civiles et les applications militaires.

### I.3.1 Applications civiles

- La prospection pétrolière à l'aide de grandes antennes linéaire ;
- La détection et la localisation de bancs de poissons avec le sonar de pêche ;
- La transmission d'information à l'aide de système de communication entre sous-marins, par exemple, un bâtiment de surface et un robot sous-marin ;
- L'établissement de cartes marines pour la navigation.

### I.3.2 Applications militaires

Plus complexe de part les systèmes mis en jeu et de la nature des tâches à effectuer qui sont caractérisées par la discrétion, essentiellement utilisé par le sous-marin. Nous citons ci-dessous quelques exemples d'application :

- la détection, la localisation et la reconnaissance d'objets ;
- le guidage d'une arme sous-marine (torpille) ;
- l'interception d'émission sonar ;
- la cartographie des fonds marins.

## I.4 COMPARAISON AVEC LE RADAR

Une rapide comparaison avec le RADAR est instructive et va permettre d'introduire quelques notions importantes.

### I.4.1 La nature de l'onde

Le sonar utilise les ondes acoustiques provoquées par la propagation d'une vibration mécanique pour transmettre et recevoir de l'information dans le milieu marin. Le radar utilise des ondes électromagnétiques qui n'ont pas besoin d'un support matériel : elles peuvent se propager dans le vide.

## I.4.2 La célérité

Les ondes acoustiques se propagent avec une célérité d'environ 1500  $m/s$  dans l'eau (330  $m/s$  dans l'air), [1]. Les ondes électromagnétiques se propagent à la vitesse de la lumière, soit  $3 \times 10^8$   $m/s$ , [1].

## I.5 TYPES DE SONAR

### I.5.1 : Le sonar actif

Un sonar actif émet des ondes acoustiques dont les caractéristiques sont connues. Le signal émis sera réfléchi par les corps à détecter sous forme d'écho. Le signal reçu va être traité pour déterminer et identifier la nature, la forme, la distance, la vitesse et même la trajectoire du corps intercepté. Ce type de sonar est souvent utilisé pour des applications civiles : travaux de recherche scientifique et la prospection des fonds marins.

Un exemple de sonar actif est illustré en Figure I.2.

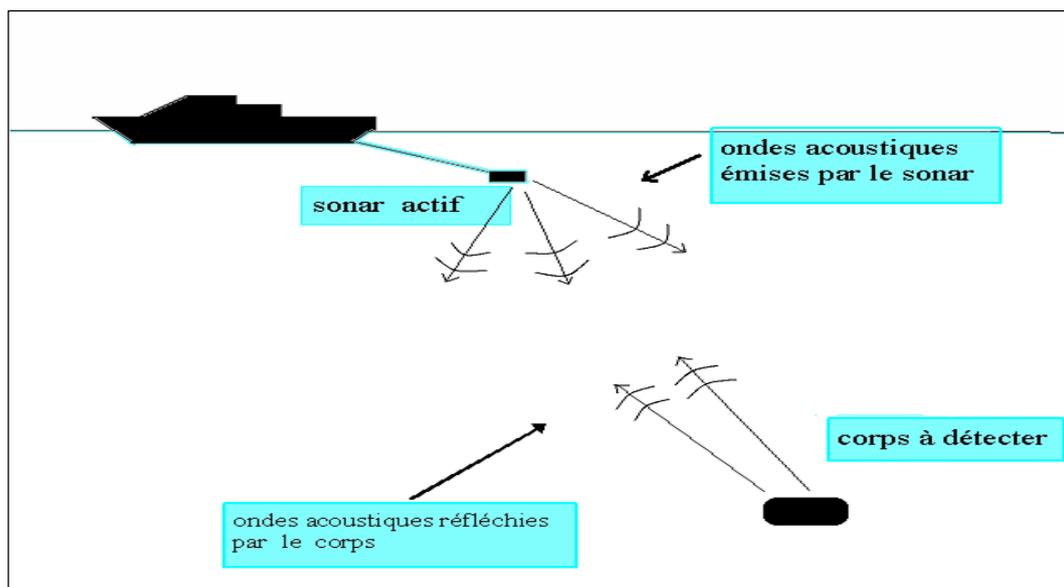


Figure I.2 : Principe d'un système sonar actif.

### I.5.2 Le sonar passif

Le sonar passif consiste à détecter les bruits rayonnés par la cible. Il est passif dans le sens qu'il n'émet pas de signal. C'est la technique de détection préférée des sous-marins qui conserve ainsi leur principal avantage : la discrétion.

Un exemple de sonar passif est illustré en Figure I.3.

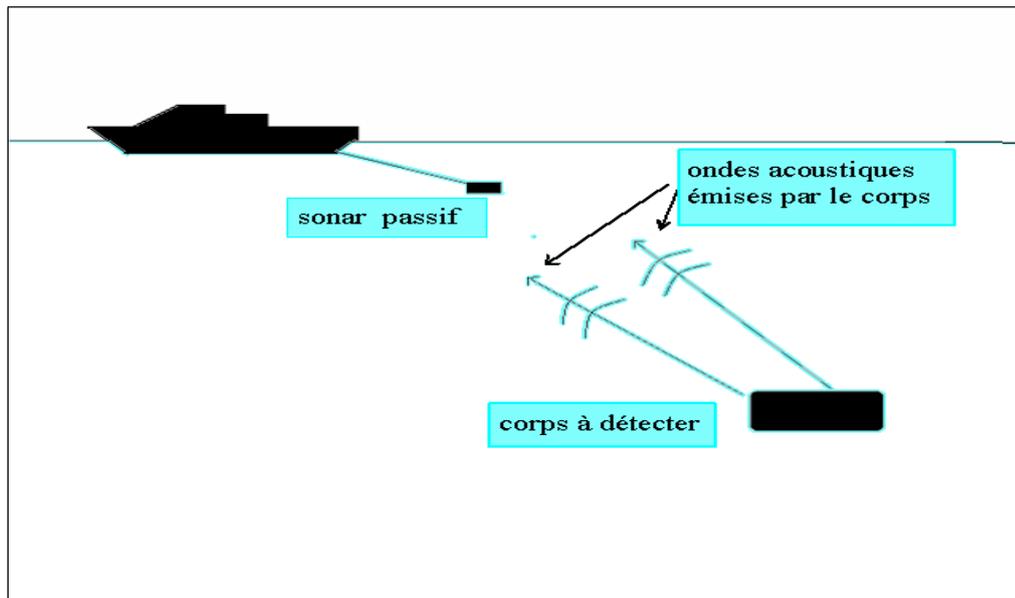


Figure I.3 : Le principe du sonar passif.

## I.6 TRAITEMENT DES DONNÉES SONAR

Le prétraitement des données est une étape importante car elle permet de sélectionner, dans l'espace de représentation, l'information nécessaire à l'application. Cette sélection passe par l'élimination du bruit dû aux conditions d'acquisition, la normalisation des données, et la suppression de la redondance.

Les données sonar brutes comportent du bruit (Voir Figure I.4). Les classifieurs exigent un nombre de caractéristiques relativement faible pour répondre aux impératifs du traitement en temps réel. Une opération de prétraitement sur les données brutes est donc nécessaire pour préparer la phase de classification. Par ailleurs, les données disponibles sont souvent entachées de bruit. Il est donc important de réduire le bruit et d'effectuer un traitement qui rend les données exploitables.

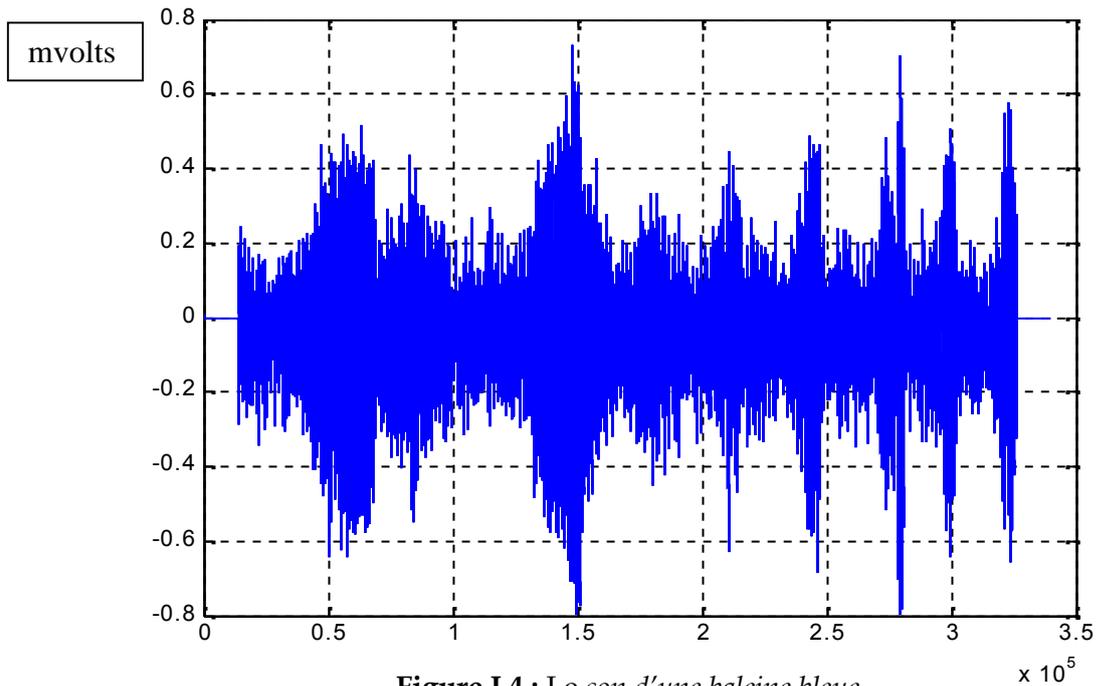


Figure I.4 : Le son d'une baleine bleue.

Dans ce qui suit, nous présentons les méthodes avec lesquelles nous avons traité les données sonar pour sélectionner les caractéristiques pertinentes des cibles à classifier.

### I.6.1 La banque de données sonar

Nous disposons d'un ensemble de fichiers son type sonar que nous avons téléchargé d'un site de l'armée navale américaine.

Nous présentons ci-dessous les différents sons des formes ou classes à classifier.

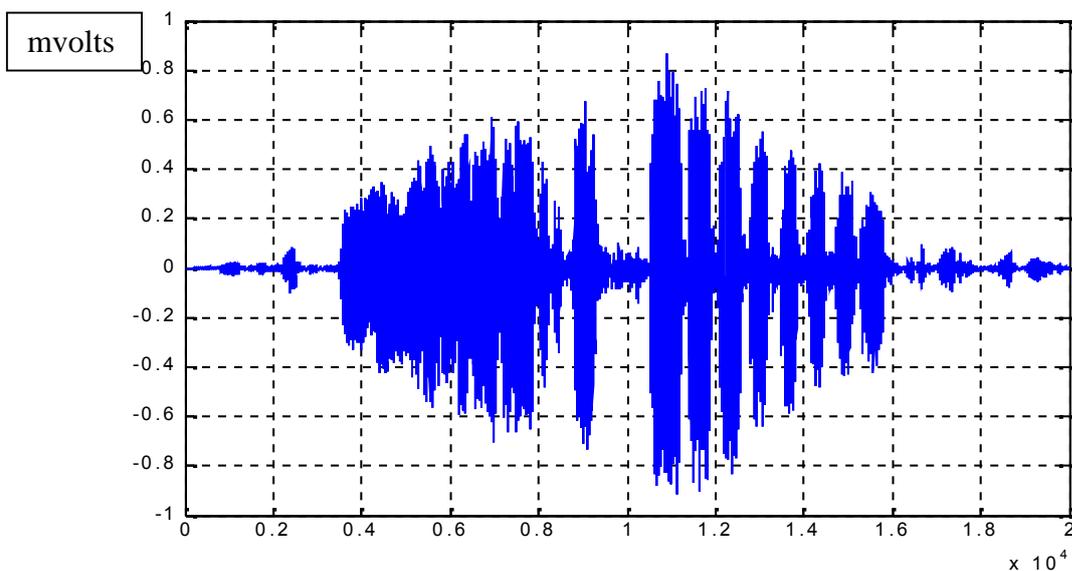
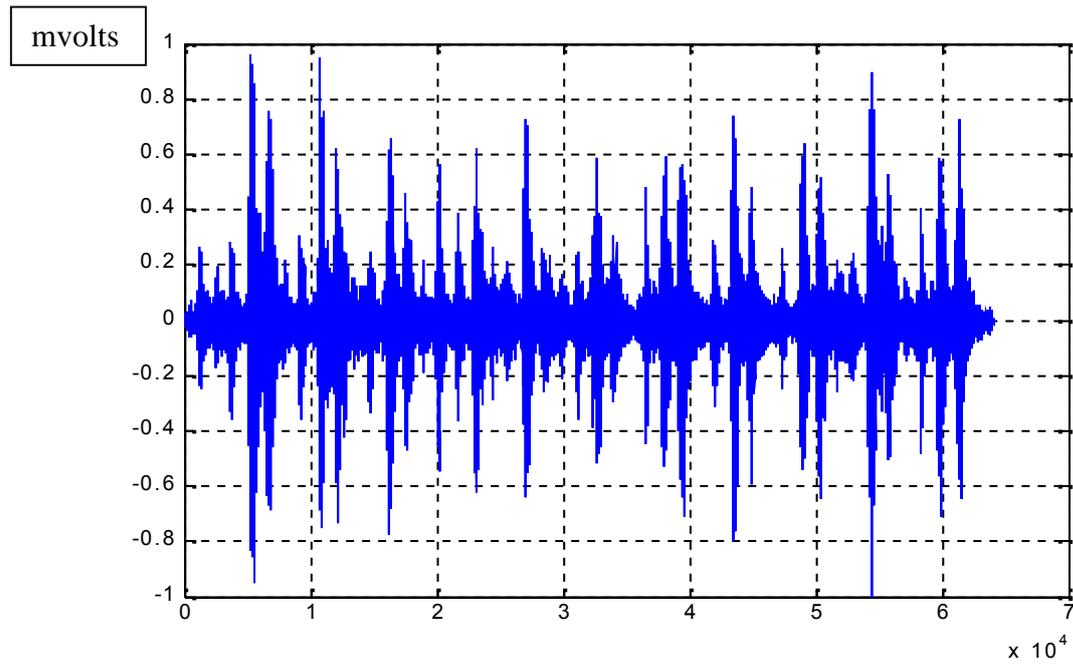
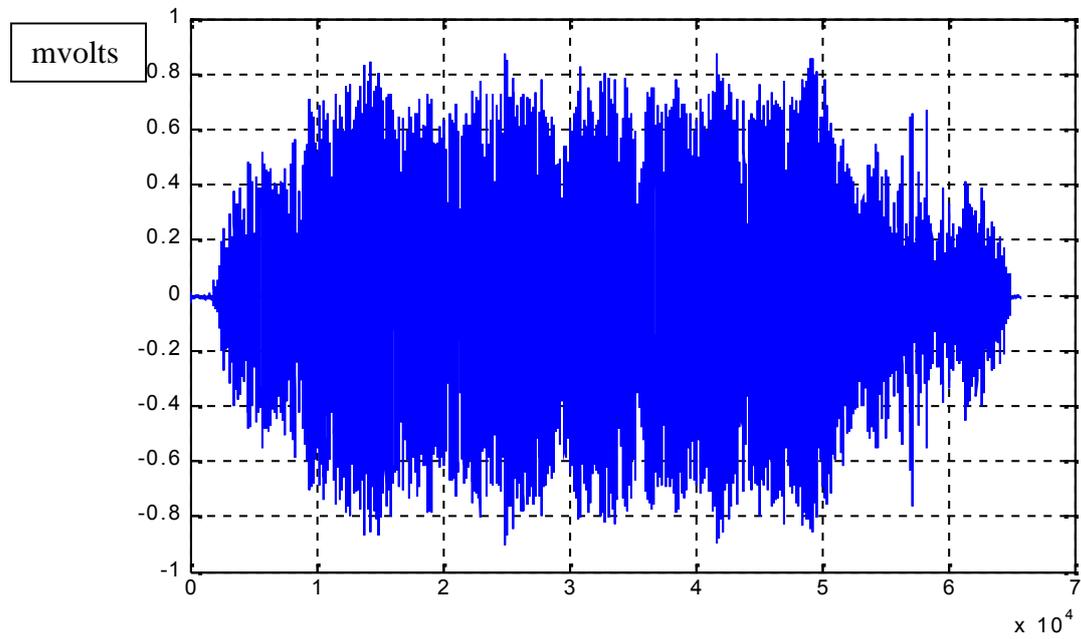


Figure I.5 : Le son d'un dauphin.



**Figure I.6 :** *Le son d'un tanker.*



**Figure I.7 :** *Le son d'un sous marin.*

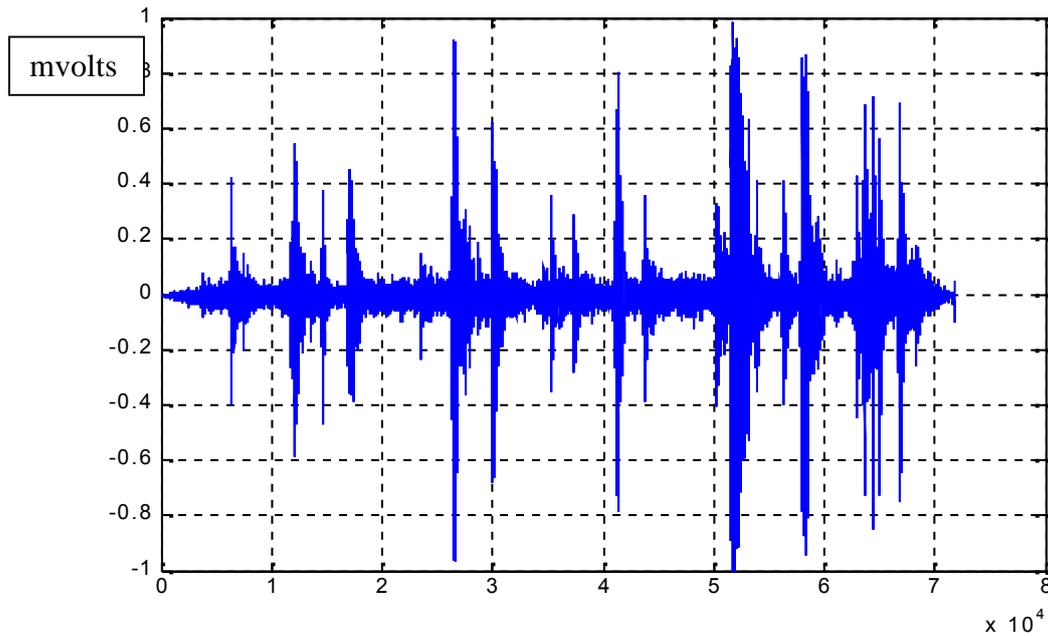


Figure I.8 : Le son d'une séparation d'un iceberg.

Nous constatons que chacun de ces signaux à une représentation temporelle particulière, mais on peut extraire quelques paramètres communs entre eux et les classer ainsi dans des groupes.

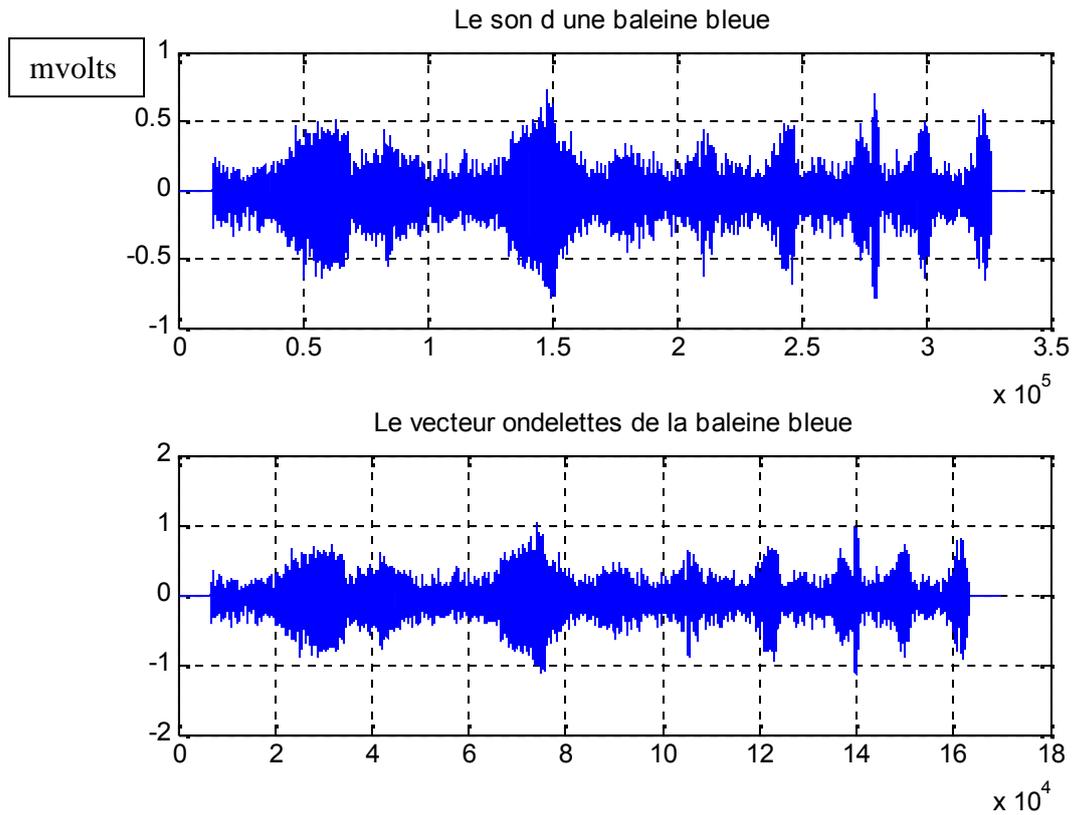
Par exemple pour les signaux issus des machines (bateau, sous-marin,...) et qui ont une représentation temporelle presque régulière stationnaire et cela est dû principalement à la périodicité et à la continuité du bruit issu du fonctionnement des moteurs. Nous pouvons également mettre les signaux des animaux marins (baleine, dauphin,...) dans un autre groupe.

### I.6.2 Application de la transformée en ondelettes

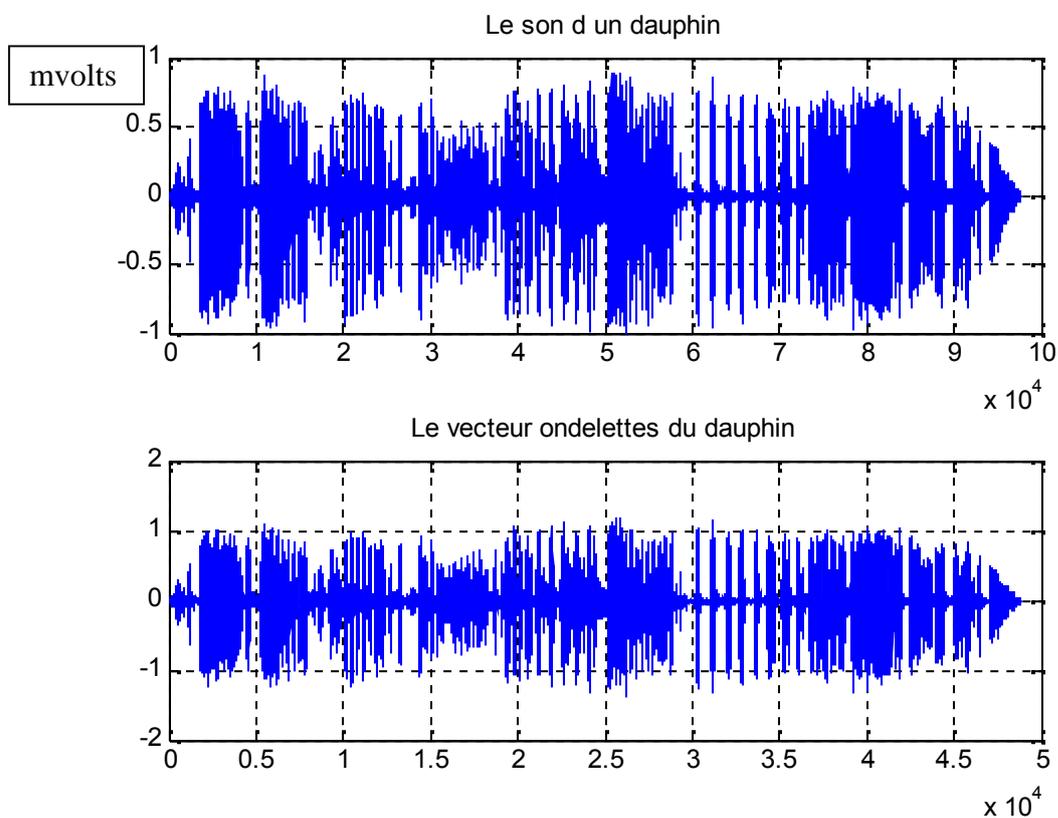
Nous avons utilisé la décomposition en ondelettes pour filtrer les sons sonar et réduire les dimensions des vecteurs (les sons).

D'après la bibliographie, [3], on utilise souvent l'ondelette Daubechies 1 pour filtrer et spécialement pour débruiter les données.

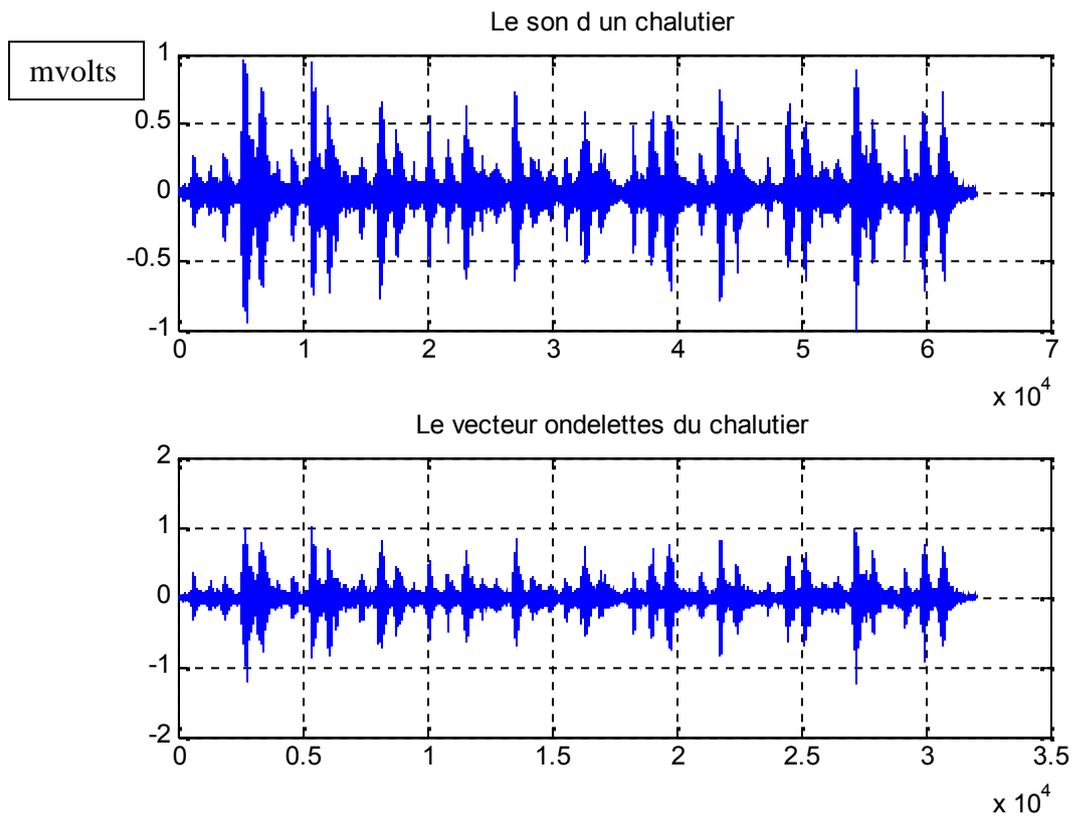
Concernant notre application, nous avons effectué une décomposition à un seul niveau. La dimension du vecteur résultant est réduite de moitié. Les figures ci-dessous donnent quelques exemples.



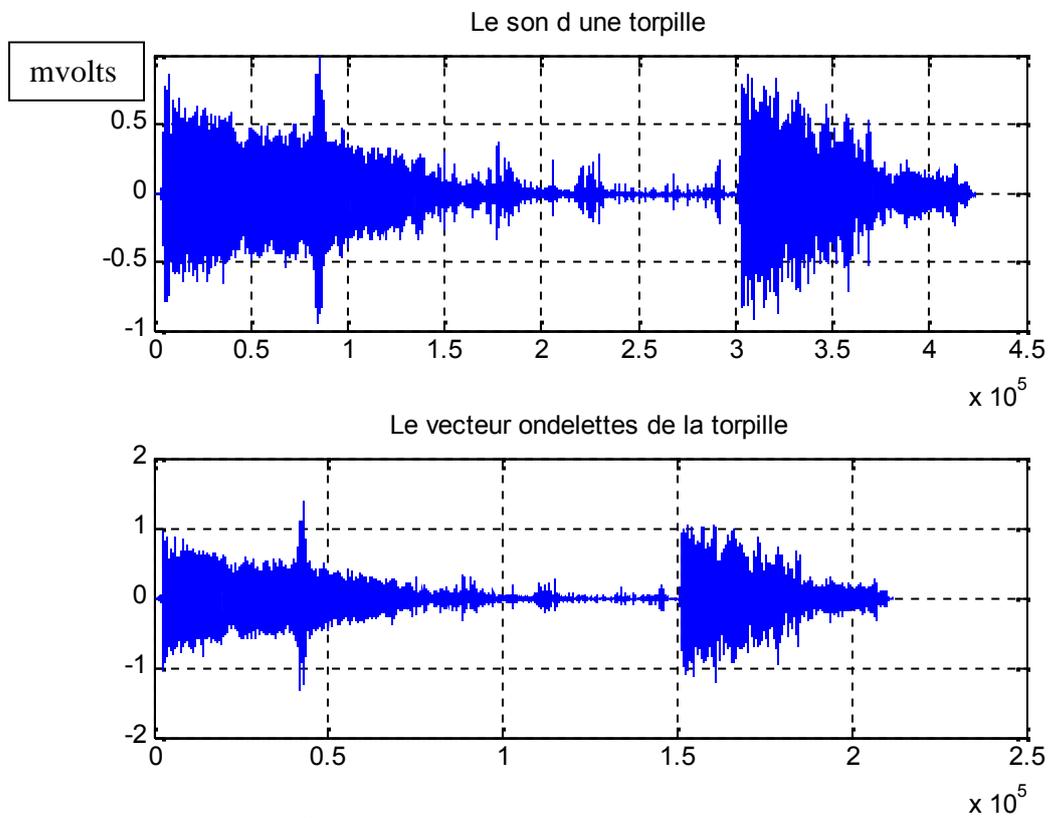
**Figure I.9 :** *Enregistrement d'une baleine bleue et sa décomposition en ondelettes.*



**Figure I.10 :** *Enregistrement d'un dauphin et sa décomposition en ondelettes.*



**Figure I.11 :** *Enregistrement d'un bateau (chalutier) et sa décomposition en ondelettes.*



**Figure I.12 :** *Enregistrement d'une torpille et sa décomposition en ondelettes.*

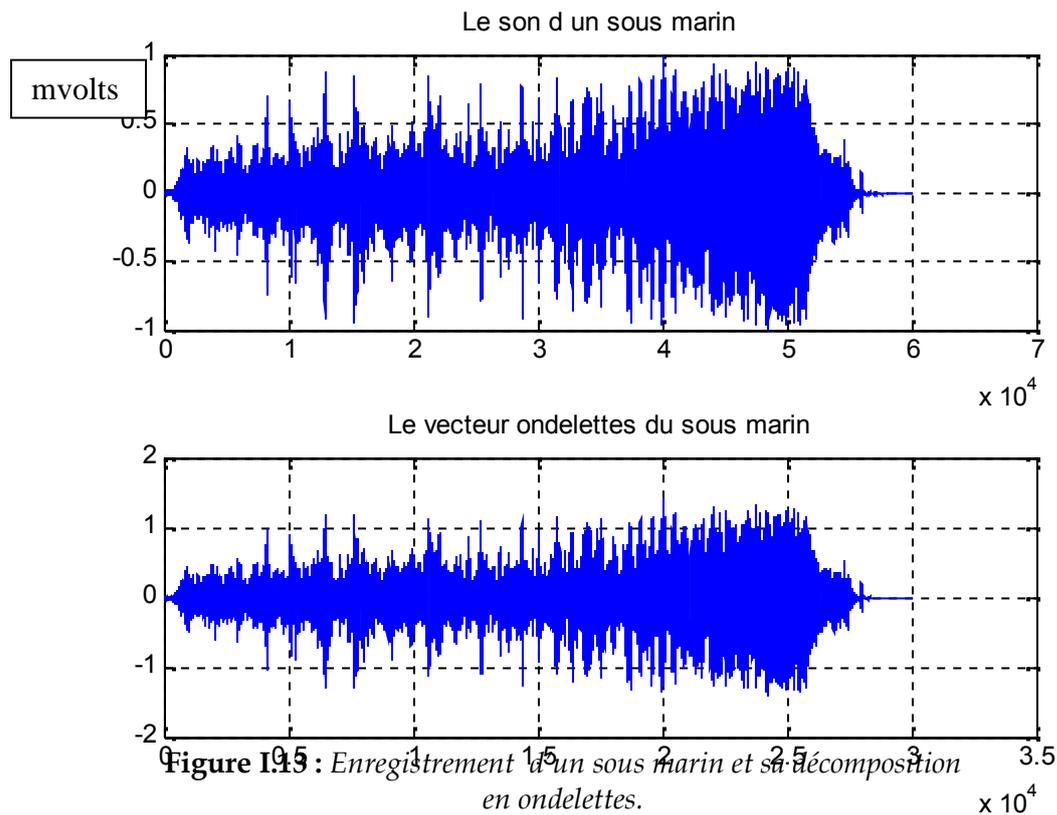


Figure I.15 : Enregistrement d'un sous marin et sa décomposition en ondelettes.

A partir des Figures I.9, I.10, I.11, I.12 et I.13, nous constatons qu'au moyen de la décomposition en ondelettes, nous séparons le signal utile du bruit. La fonction ondelette a sélectionné l'information utile par un filtre passe bas tandis que les bruits par un filtre passe haut. Dans ce qui suit, le traitement est appliqué au résultat obtenu par la décomposition en ondelettes.

### 1.6.3 Application du fenêtrage (Pondération)

L'opération du fenêtrage est nécessaire car la décomposition du vecteur en plusieurs trames est inévitable. Par conséquent, le vecteur à décomposer est multiplié par une porte rectangulaire ce qui fait apparaître des lobes secondaires dans le spectre du signal à décomposer.

Pour pallier à ce problème, d'autres fenêtres sont utilisées autres que la porte rectangulaire telles la fenêtre Hamming, Hanning, Blackman, Bartlett,..... Ces fenêtres transforment les  $(n)$  éléments symétriques en vecteur  $(W)$ ,  $n$  est entier.

**La fenêtre Hamming, [4]**

$$W[k+1] = 0,54 - 0,46 \cos\left(2\pi \frac{k}{n-1}\right) ; \quad k = 0, 1, \dots, n-1. \quad (I.1)$$

**La fenêtre Hanning, [4]**

$$W[k+1] = 0,5\left[1 - \cos\left(2\pi \frac{k}{n-1}\right)\right] ; \quad k = 0, 1, \dots, n-1. \quad (I.2)$$

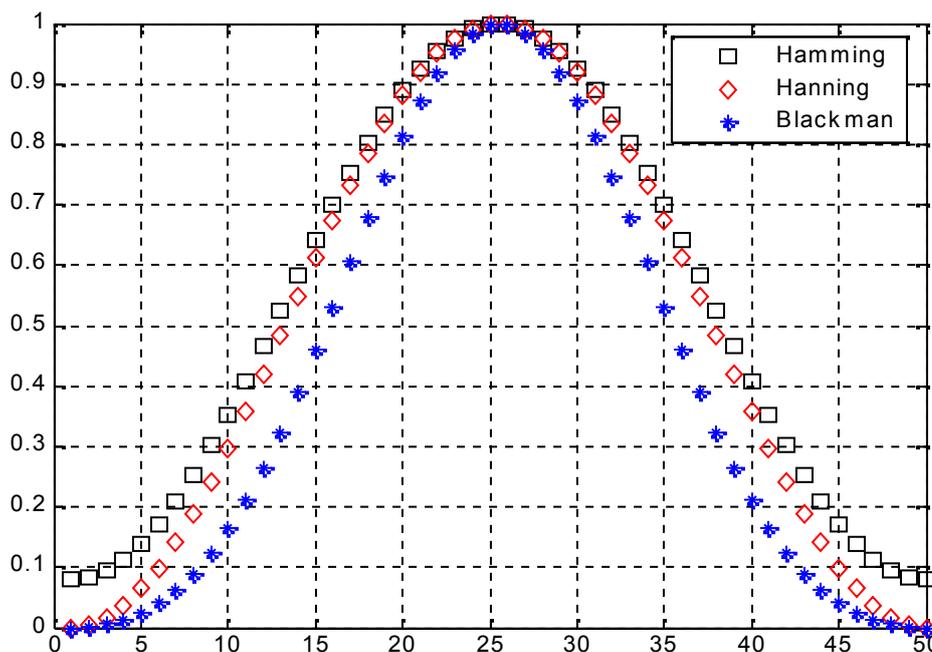
**La fenêtre Blackman, [4]**

$$W[k+1] = 0,42 - 0,5 \cos\left(2\pi \frac{k}{n-1}\right) + 0,08 \cos\left(4\pi \frac{k}{n-1}\right) ; \quad k = 0, \dots, n-1 \quad (I.3)$$

**La fenêtre de Gauss, [4]**

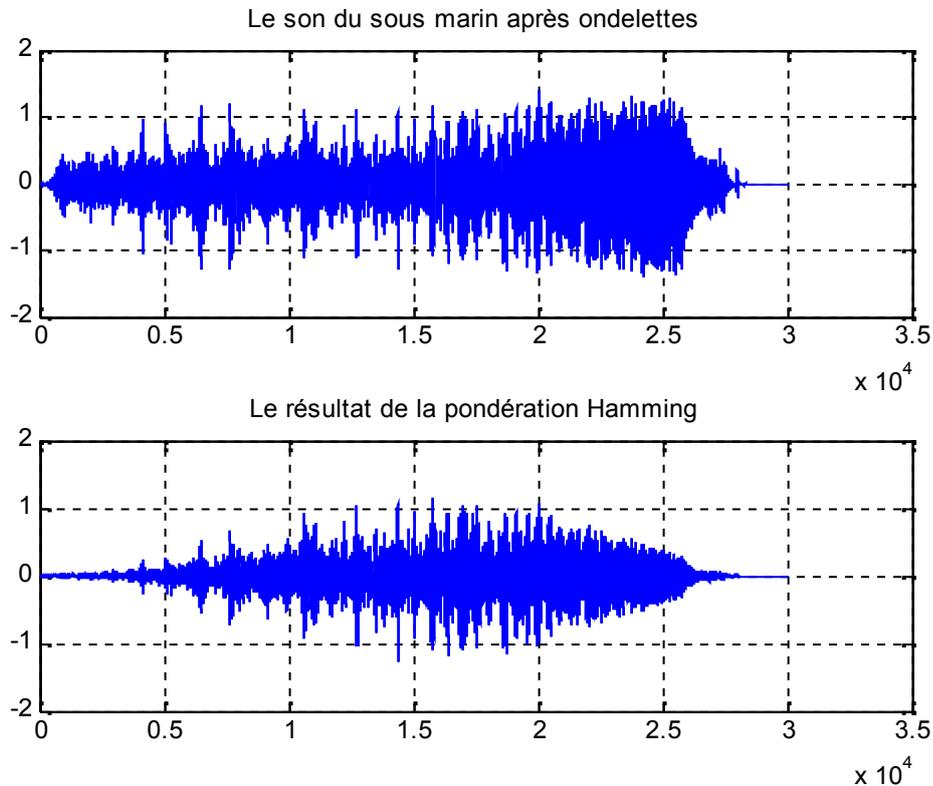
$$W[k+1] = \exp\left[-\frac{1}{2} \left(\alpha \frac{k - \frac{n}{2}}{\frac{n}{2}}\right)^2\right] \quad (I.4)$$

Nous donnons des exemples de fenêtrages de pondération. Voir Figure I.14  
Concernant notre application, nous avons transformé le vecteur en une matrice en utilisant une fenêtre Hamming avec un chevauchement entre les trames de 50%.

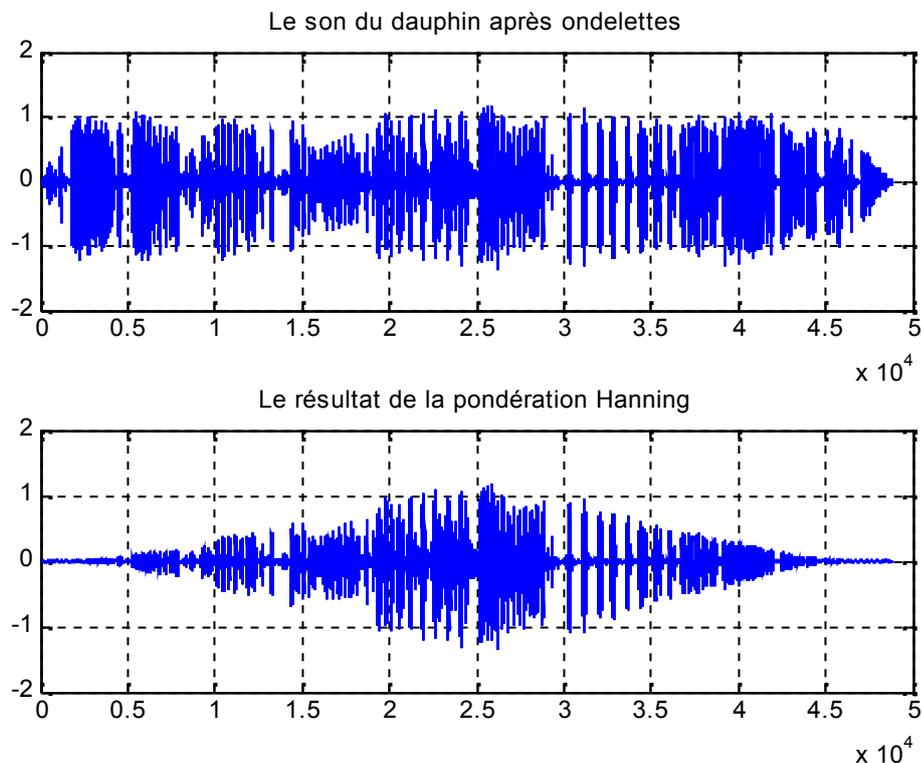


**Figure I.14 :** Exemple de trois fenêtrages de pondération. Hamming, Hanning et Blackman.

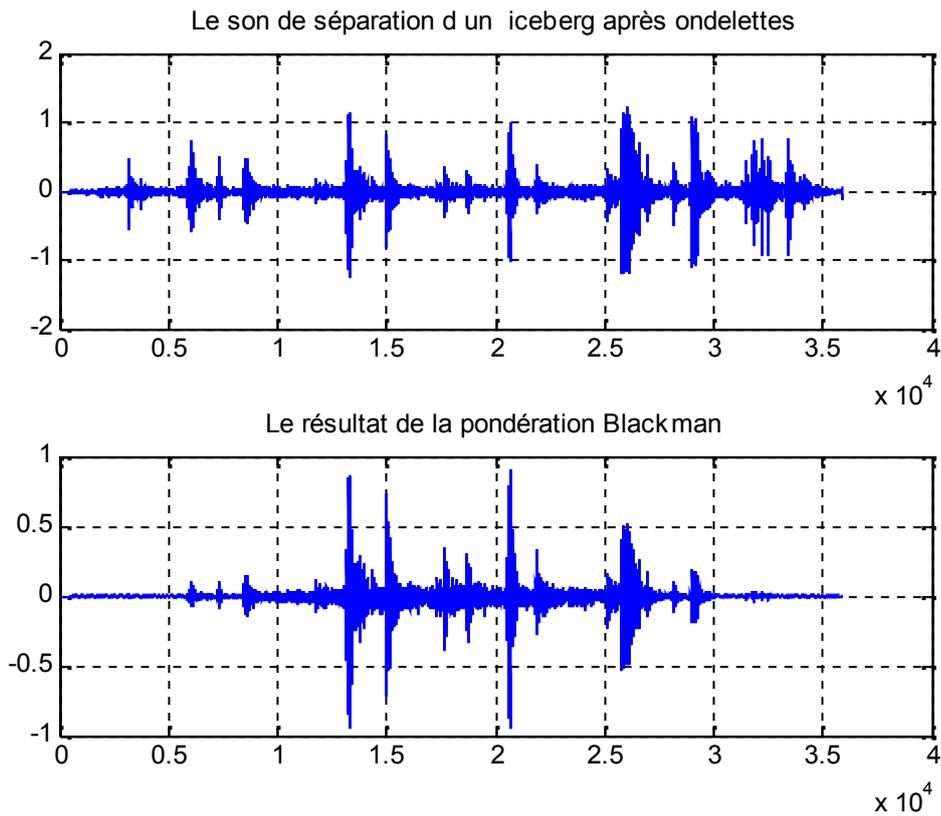
Les Figures suivantes donnent des exemples de pondération de quelques signaux temporels sonar.



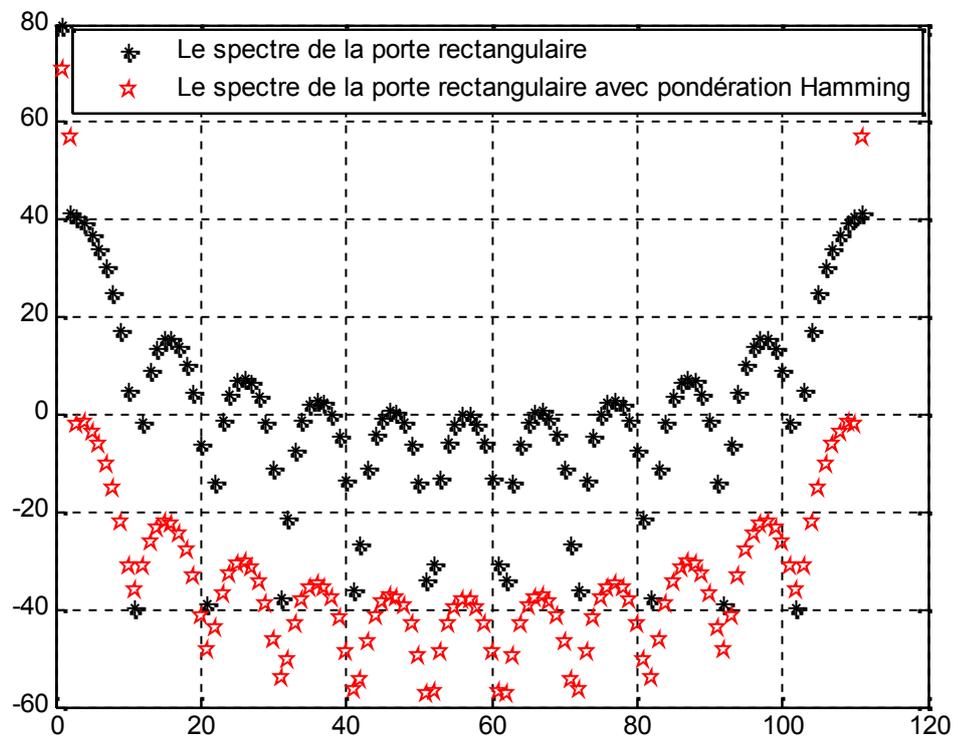
**Figure I.15 :** Exemple de pondération Hamming appliqué au signal d'un sous marin.



**Figure I.16 :** Exemple de pondération Hanning appliqué au signal d'un dauphin.



**Figure I.17 :** Exemple de pondération Blackman appliqué au signal de séparation d'iceberg.



**Figure I.18 :** Réduction des niveaux des lobes secondaires en pondérant la porte rectangulaire par Hamming.

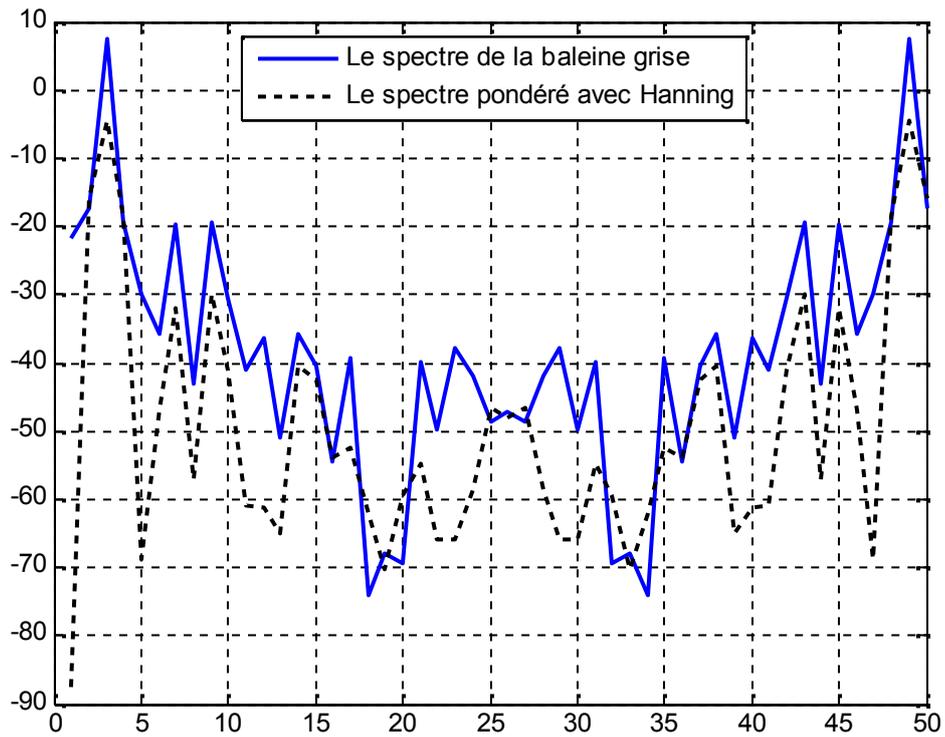


Figure I.19 : Réduction des niveaux des lobes secondaires du spectre de la baleine grise avec Hanning.

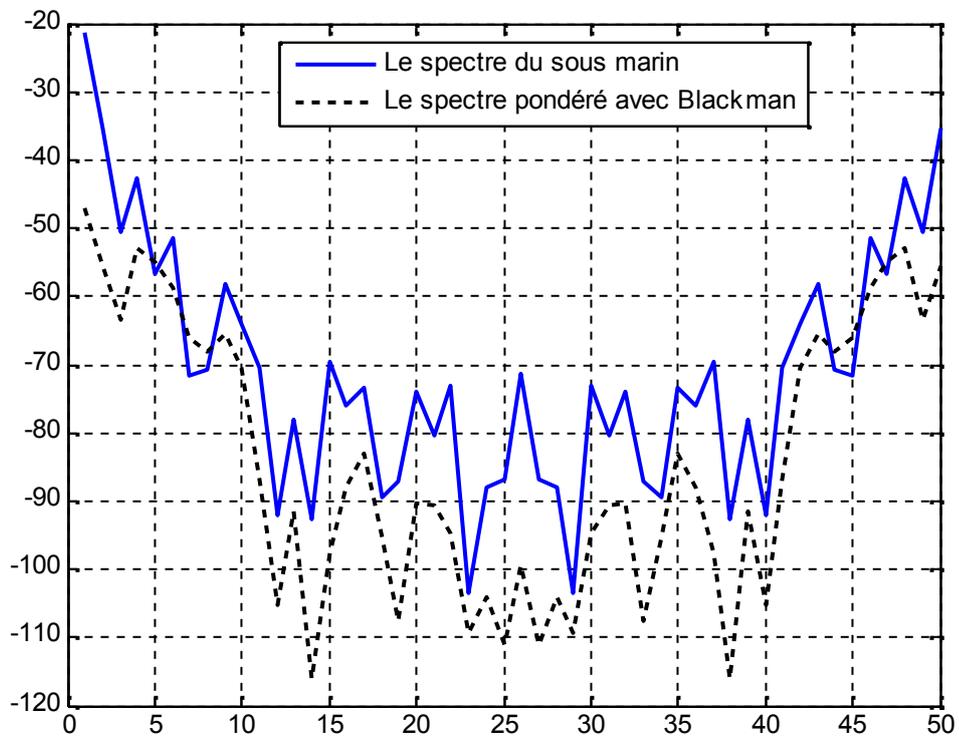
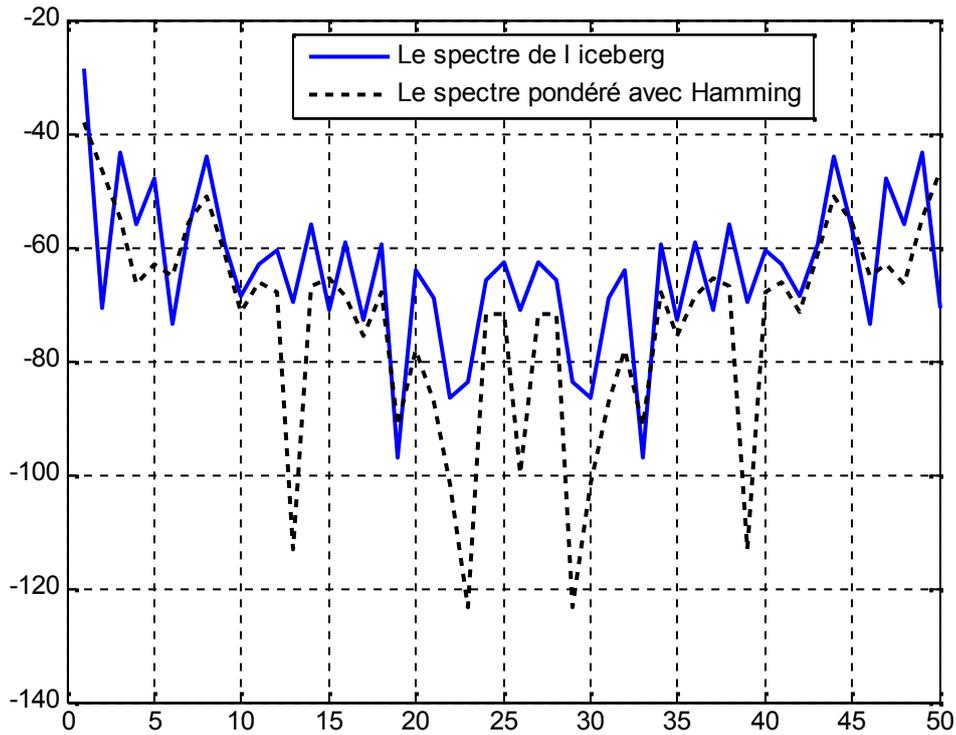
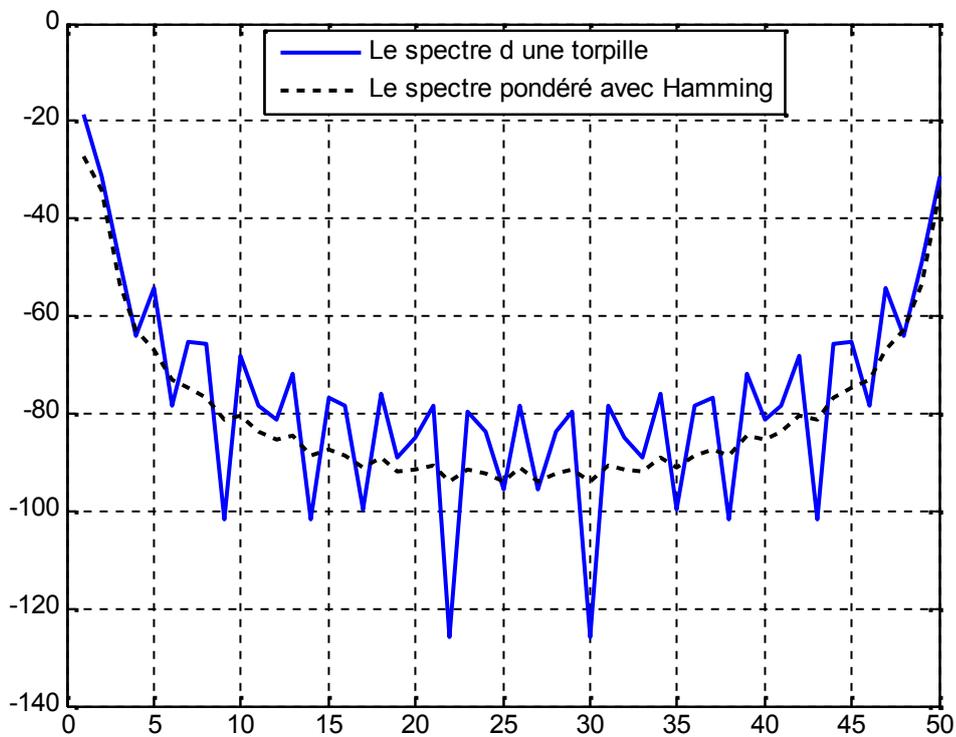


Figure I.20 : Réduction des niveaux des lobes secondaires du spectre du sous marin avec Blackman.



**Figure I.21 :** Réduction des niveaux des lobes secondaires du spectre de l'iceberg avec Hamming.



**Figure I.22 :** Réduction des niveaux des lobes secondaires du spectre d'une torpille avec Hamming.

Les Figures I.15, I.16 et I.17 montrent l'effet de la pondération sur les signaux sonar dans le domaine temporel. Le signal résultant prend pratiquement la forme de la fenêtre de pondération.

L'analyse des Figures I.18, I.19, I.20, I.21 et I.22 montre l'efficacité du fenêtrage. Le niveau des lobes secondaires a chuté de 40 dB pour la porte rectangulaire avec Hamming, de 10 dB pour l'iceberg avec Hamming. De cette façon, les fréquences noyées auparavant par ces lobes vont apparaître dans le spectre du signal pondéré.

### Remarque :

Nous tenons à rappeler que nous avons appliqué la pondération sur les vecteurs issus de la décomposition en ondelettes.

#### I.6.4 Application de la transformée de Fourier

Les Figures I.4, I.5, I.6, I.7 et I.8 donnent la représentation temporelle des signaux sonar. Les signaux peuvent être représentés dans le domaine fréquentiel en utilisant la transformée de Fourier (le spectre).

Concernant notre application, nous appliquons la transformée de Fourier unidimensionnelle. Les Figures suivantes donnent quelques exemples de représentations fréquentielles.

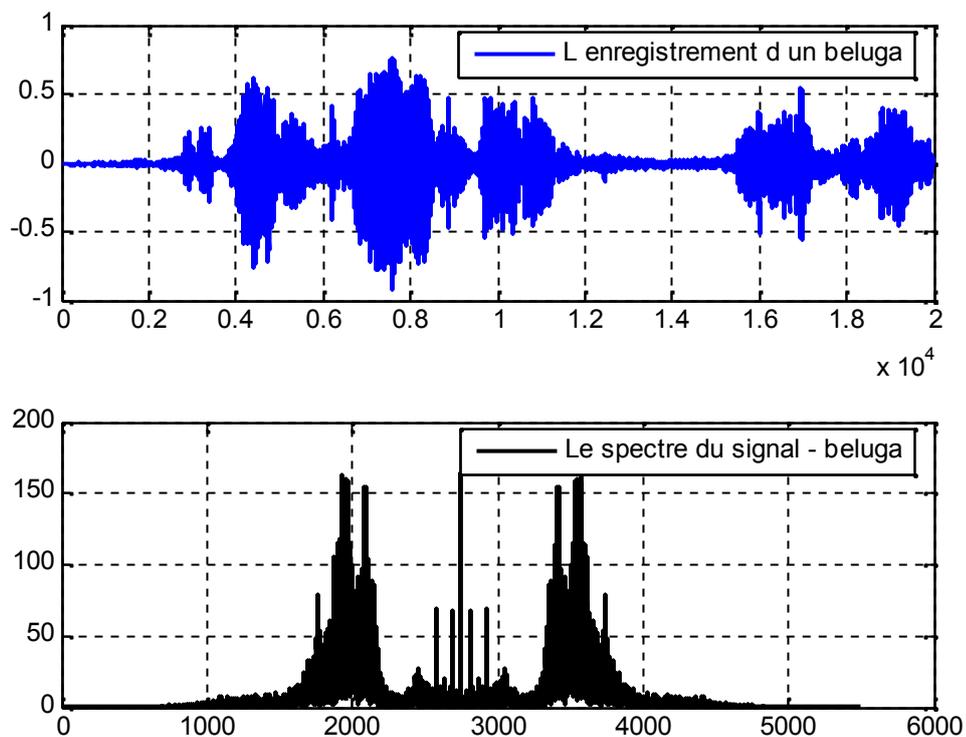


Figure I.23 : La transformée de Fourier – signal beluga.

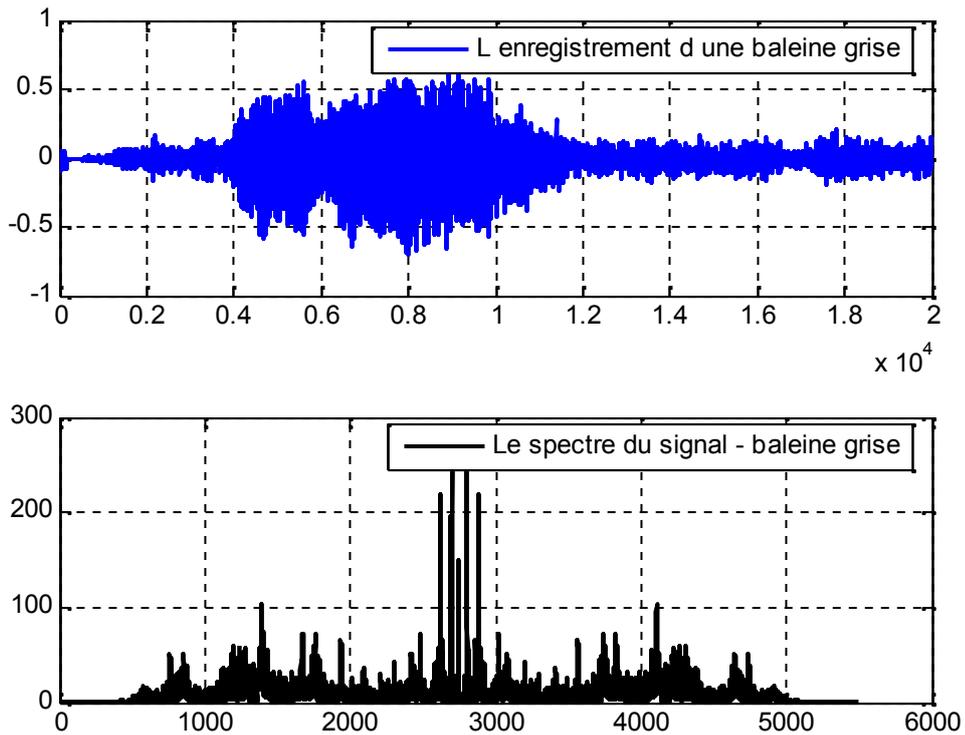


Figure I.24 : La transformée de Fourier – signal baleine grise.

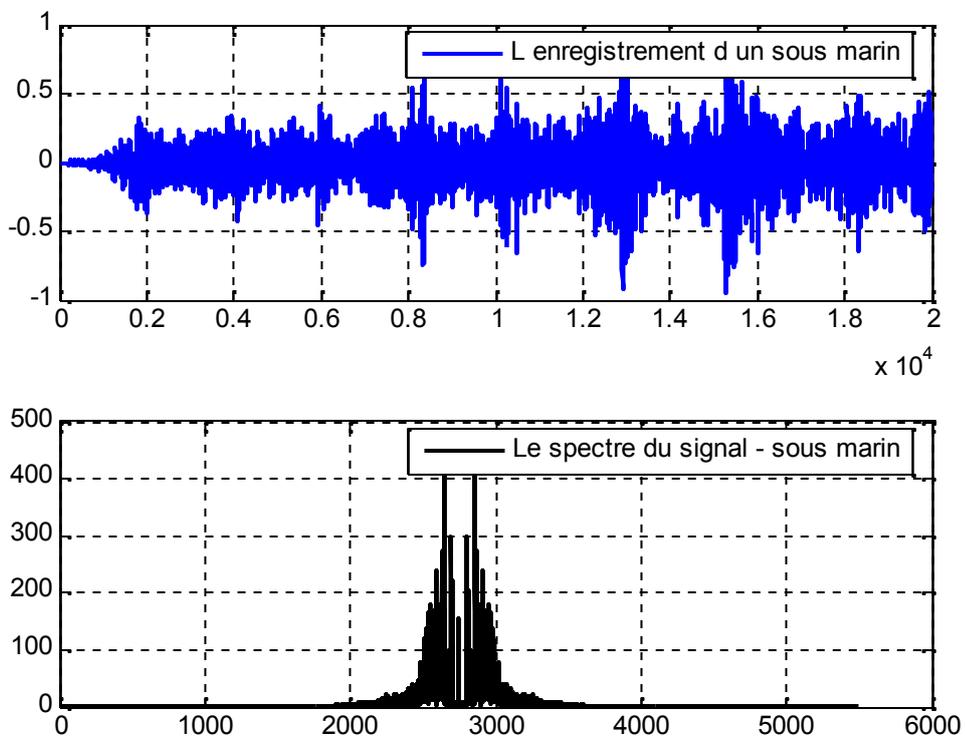


Figure I.25 : La transformée de Fourier – signal sous marin.

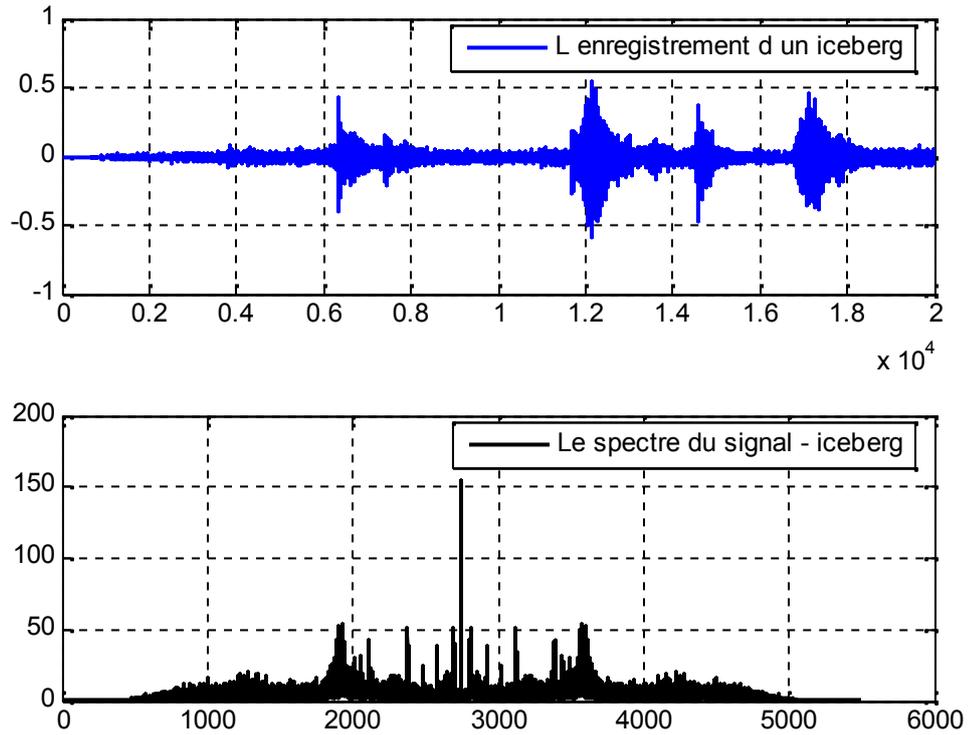


Figure I.26 : La transformée de Fourier – signal iceberg.

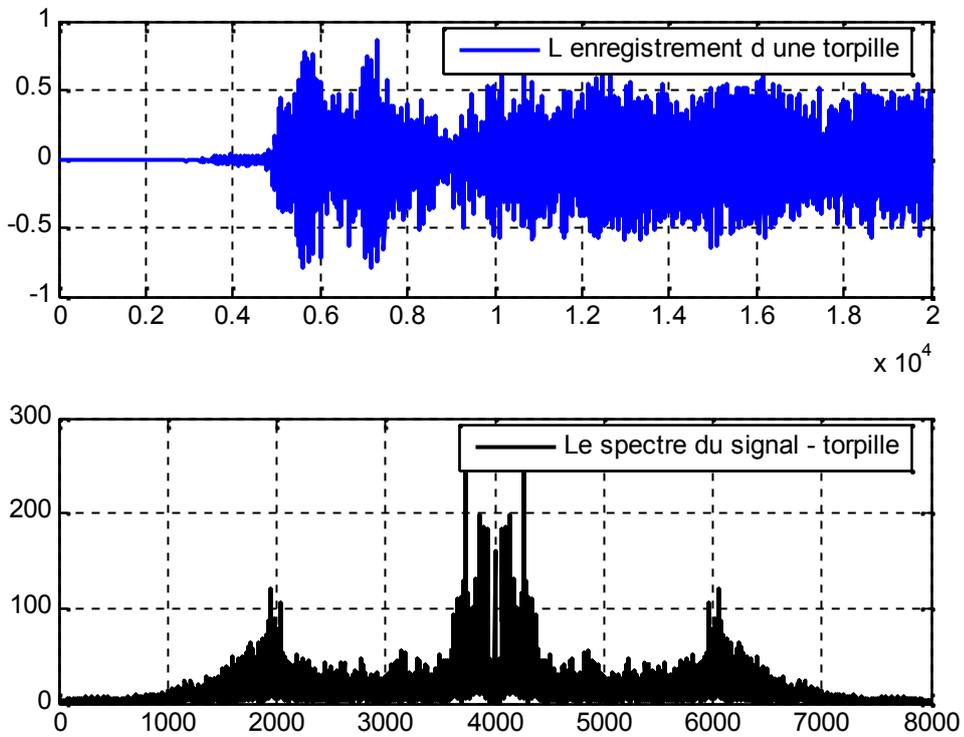


Figure I.27 : La transformée de Fourier – signal torpille.

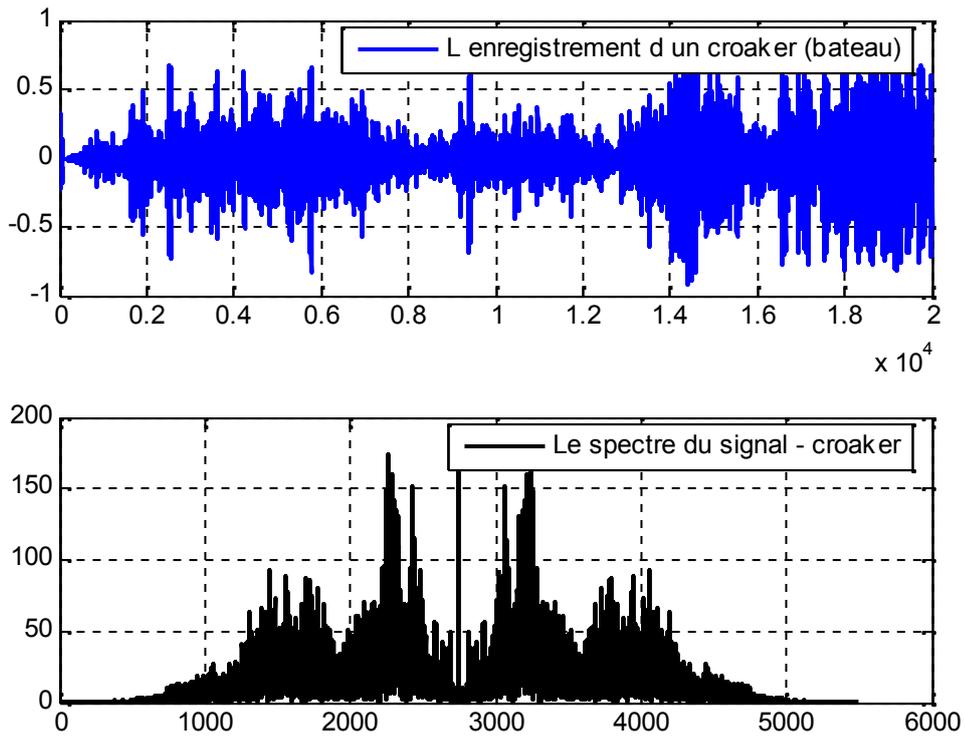


Figure I.28 : La transformée de Fourier – signal croaker.

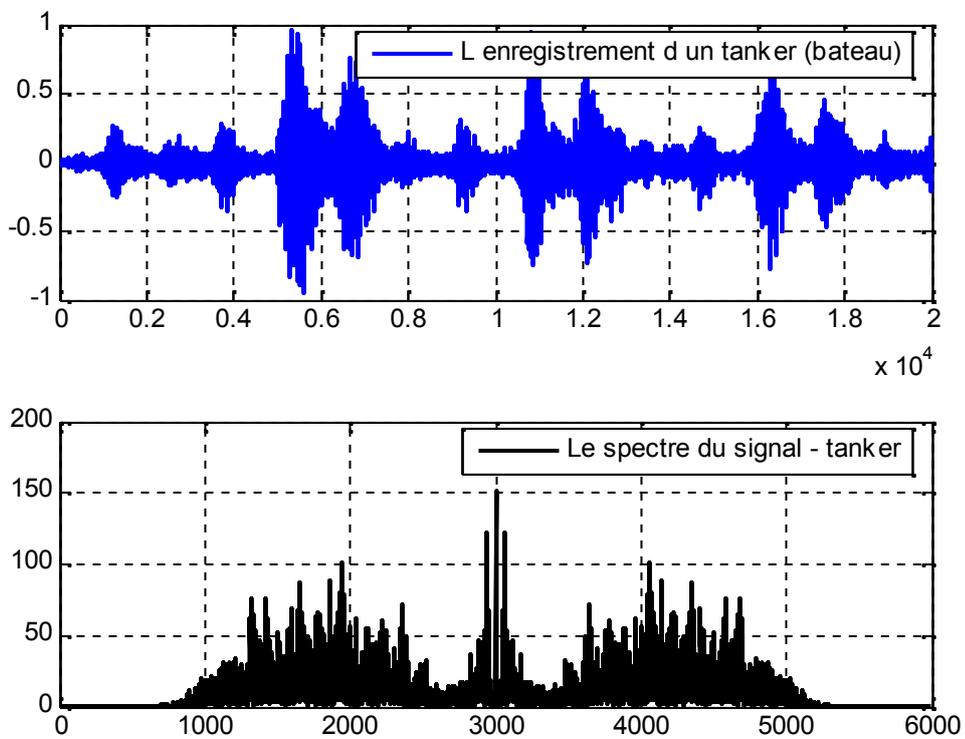


Figure I.29 : La transformée de Fourier – signal tanker.

Les Figures I.23, I.24, I.25, I.26, I.27, I.28 et I.29 donnent le module de la transformée de Fourier (le spectre) de quelques baleines et bateaux.

Les courbes représentent une infinité de composantes. Nous constatons que ces données sonar sont riches en informations. Les spectres sont plus au moins larges.

Nous présentons dans ce qui suit les spectrogrammes de quelques signaux sonar. Le spectrogramme donne l'analyse temps - fréquence d'un signal.

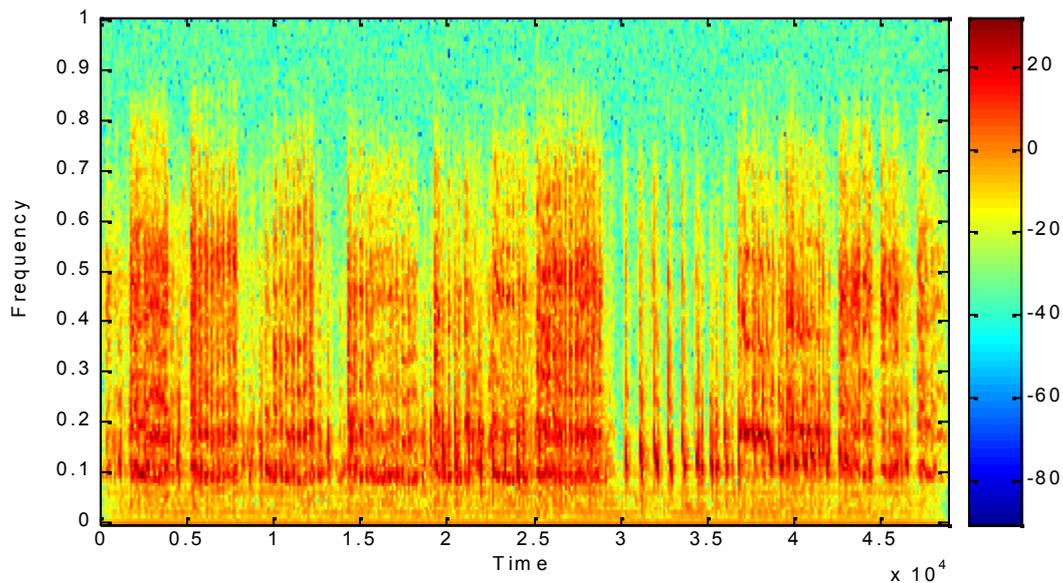


Figure I.30 : Le spectrogramme du signal dauphin.

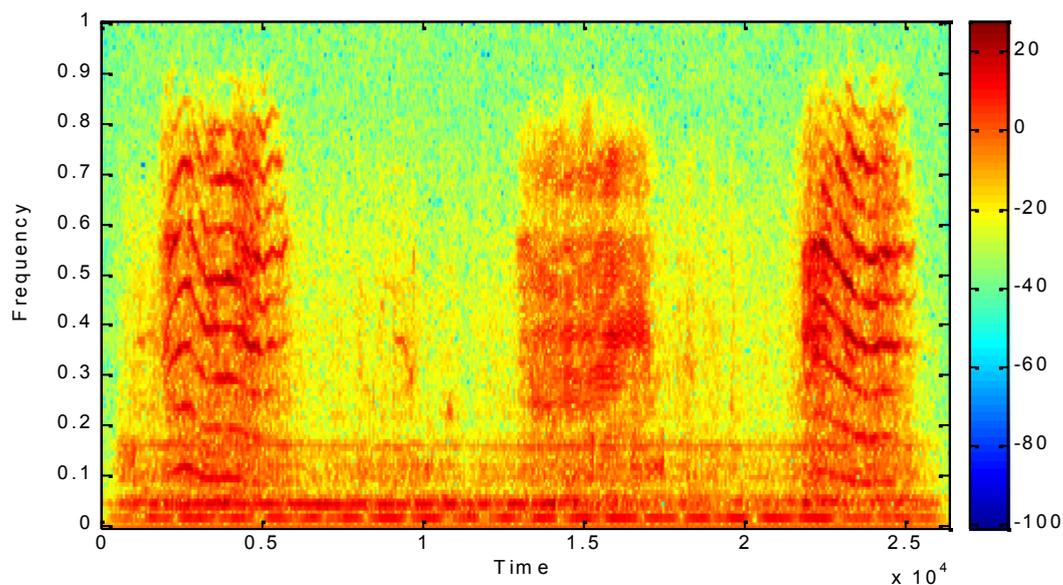


Figure I.31 : Le spectrogramme du signal baleine grise.

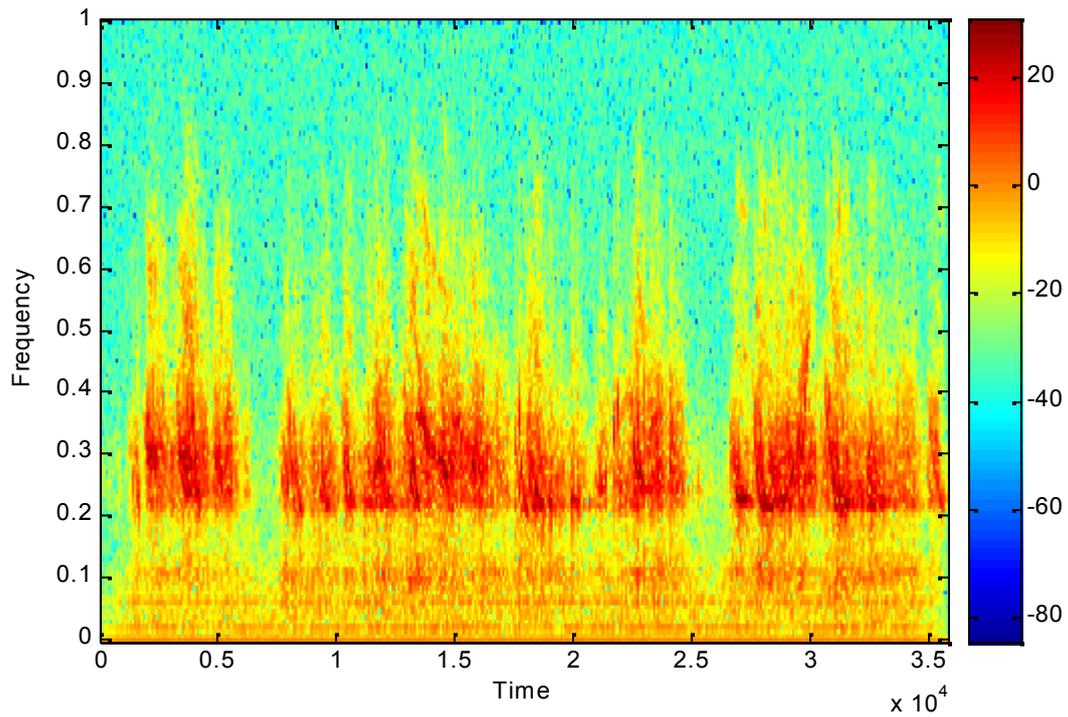


Figure I.32 : Le spectrogramme du signal beluga.

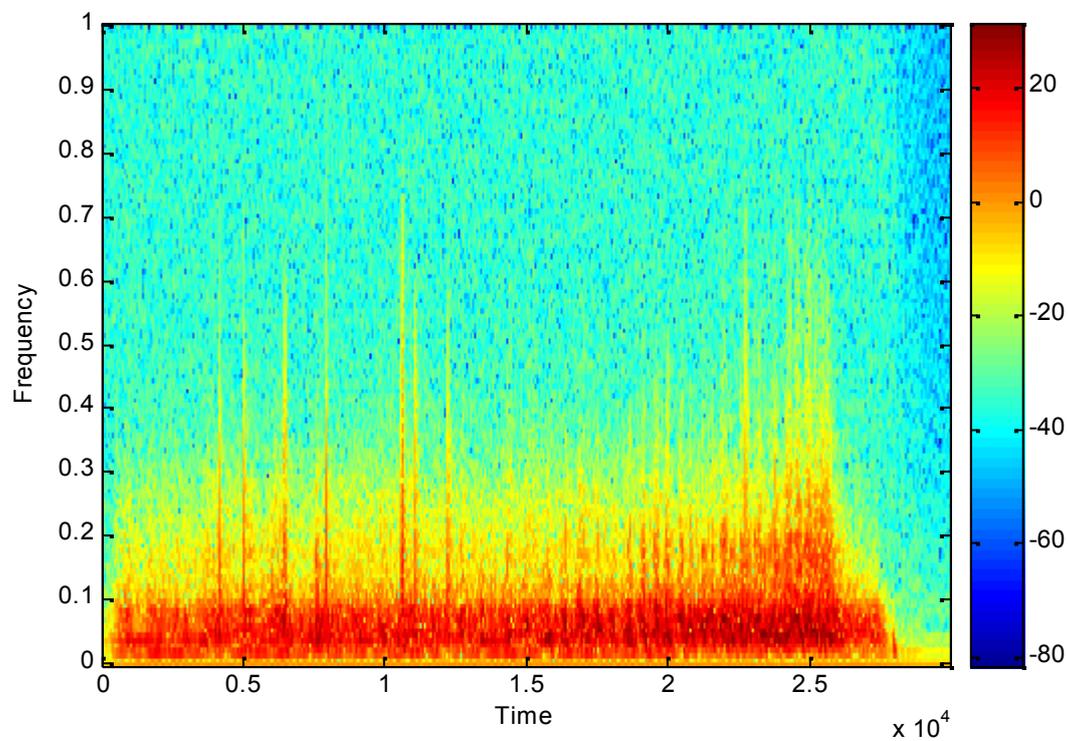


Figure I.33 : Le spectrogramme du signal sous marin.

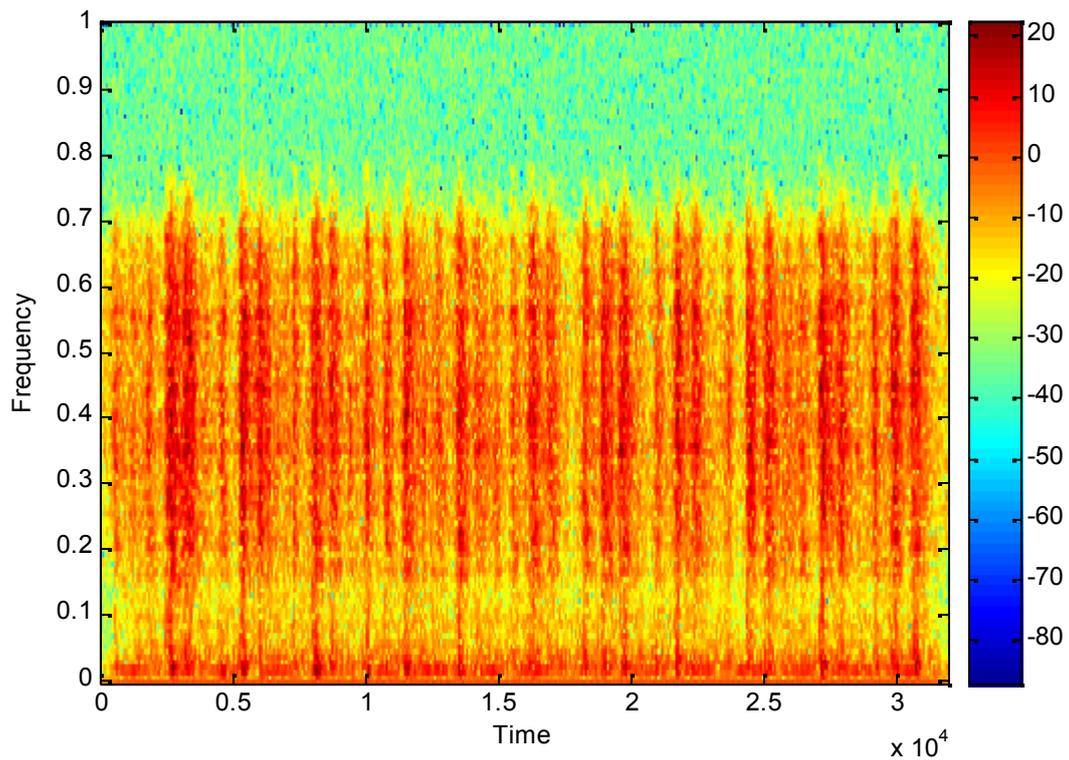


Figure I.34 : Le spectrogramme d'un signal bateau (tanker).

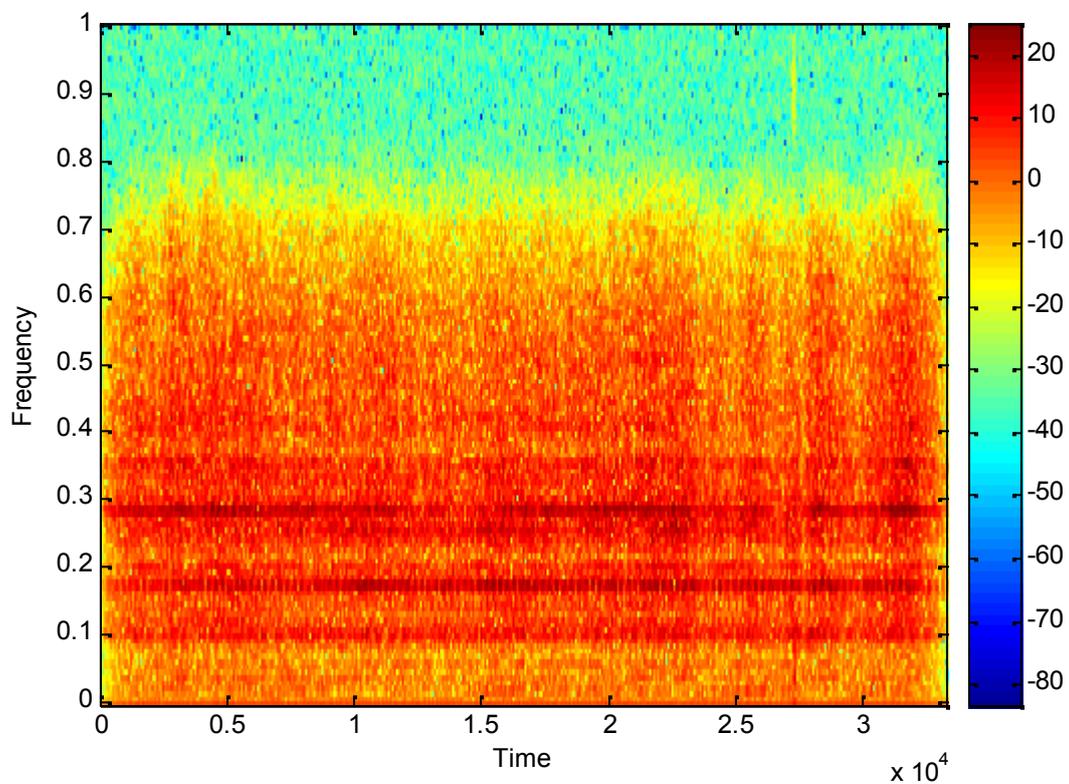


Figure I.35 : Le spectrogramme d'un signal bateau (snorkel).

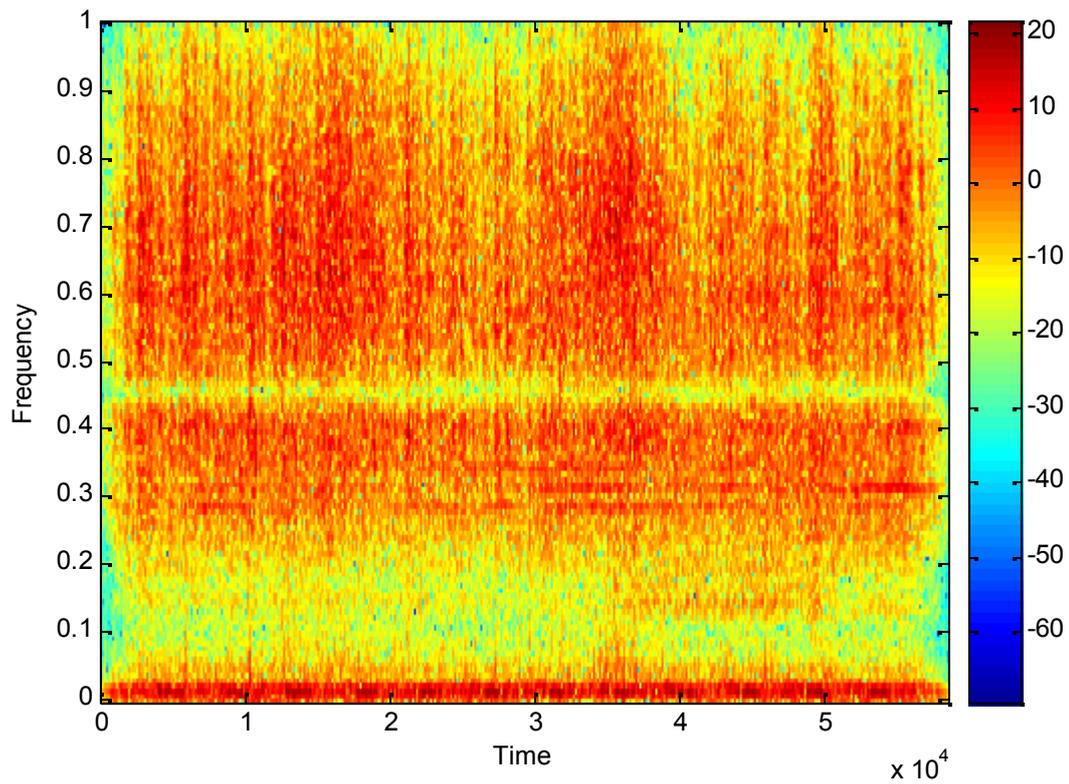


Figure I.36 : Le spectrogramme d'un signal bateau (tug).

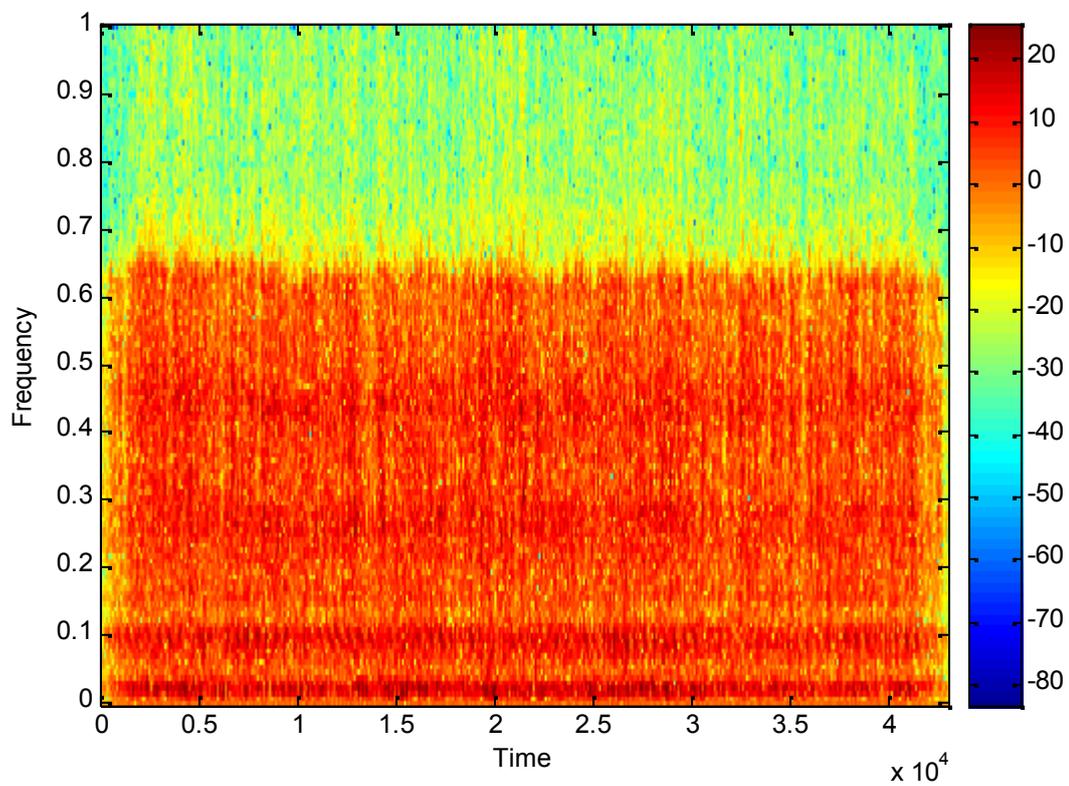


Figure I.37 : Le spectrogramme d'un signal bateau (shrimp).

Nous constatons d'après les Figures I.30, I.31, I.32, que le son produit par les mammifères marins est plus au moins aigu.

La Figure I.33 montre que la signature acoustique du sous marin est faible en amplitude, moins riche en fréquence, entachée de bruit (moteurs, hélices,...). Ceci est dû à la réflexion des ondes sur l'acier.

Les Figures I.34, I.35 et I.36 et I.37 donne les spectrogrammes de trois petits bateaux de surfaces. Ces Figures montrent que la distribution des fréquences dans le temps est quasi uniforme. L'amplitude est quasi constante (minimum 11 heures d'enregistrement). Ceci est dû essentiellement aux pales des hélices. Les pales tournent à une vitesse constante donc une seule fréquence de rotation. Ainsi l'écho incident vers le sonar est pratiquement le même et se répète pendant l'enregistrement. De plus, le signal est bruité par les moteurs, les hélices, la houle, etc. Cependant, un spécialiste en détection sonar (oreille d'or) peut différencier entre les petits bateaux (chalutier par exemple) et les grands navires en écoutant l'écho seulement. D'ailleurs, on peut même reconnaître le type du bateau en calculant la fréquence de répétition afin de déterminer la dimension des pales et des hélices.

### I.6.5 Analyse en composantes principales - ACP

L'ACP est un outil très utilisé pour traiter les données à des fins de classification. Le but est d'extraire l'information pertinente à partir des données appartenant à un espace  $R^N$  et de la représenter dans un espace  $R^M$  tel que  $M < N$ , autrement dit l'ACP représente un algorithme linéaire de compression, [3].

Les étapes à suivre pour effectuer l'analyse en composantes principales (ACP) sont:

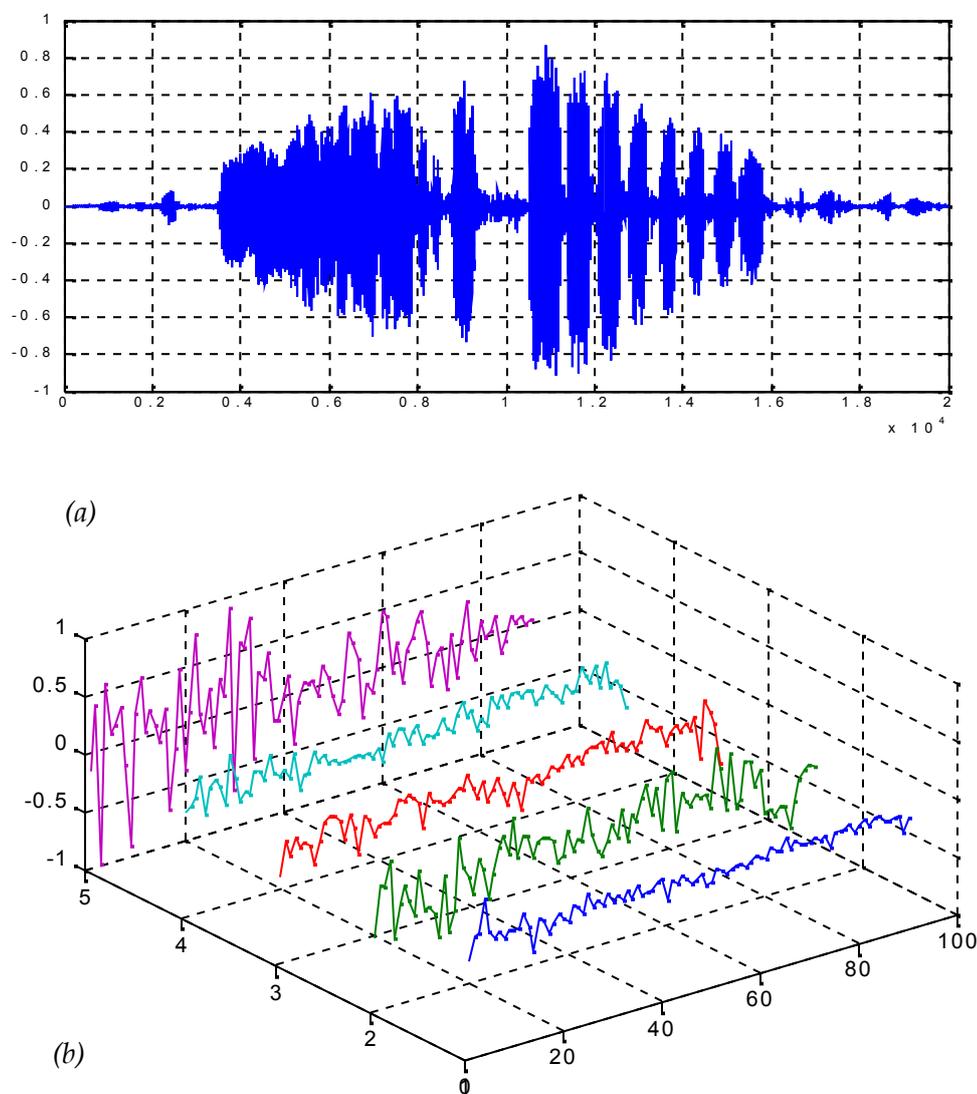
1. Centrer et réduire la matrice initiale de données. En pratique, les données sont hétérogènes i.e. les unités des variables sont différentes.
2. Calculer la matrice de variance covariance.
3. Diagonaliser la matrice C et extraire les valeurs propres et les vecteurs propres.
4. Trier les valeurs propres (et les vecteurs propres correspondants) par ordre décroissant

5. Une fois les composantes principales déterminées, on peut calculer les valeurs de ces composantes pour chaque individu.

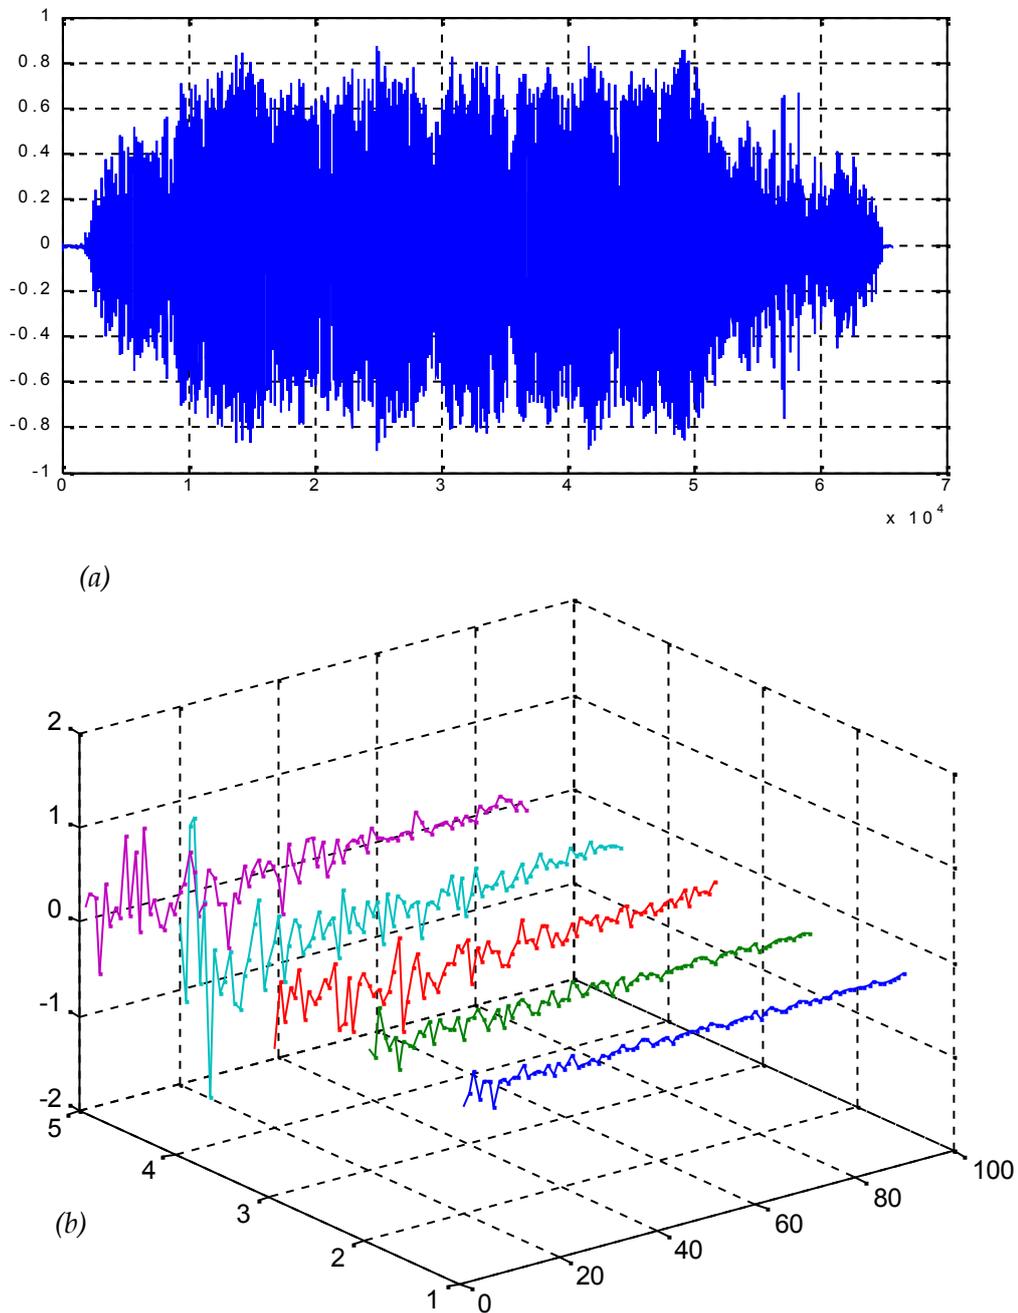
6. Retenir alors les  $M$  premiers vecteurs propres correspondant aux  $M$  premières plus grandes valeurs propres (pour notre application,  $N=484$ ,  $M=90$ ), [3].

L'avantage de l'utilisation de la compression par l'ACP est que les premiers vecteurs propres correspondent à l'information utile pour la classification tandis que les vecteurs propres restants, peuvent correspondre à des composantes aléatoires telles que les bruits.

Les Figures I.38 et I.39 donnent quelques résultats obtenus après les traitements (décomposition en ondelettes, pondération Hamming, et enfin l'analyse en composantes principales) appliqués aux données sonar.



**Figure I.38 :** (a) L'enregistrement du dauphin.  
(b) Le résultat obtenu après les trois opérations de traitement.



**Figure I.39 :** (a) *L'enregistrement du sous marin.*  
(b) *Le résultat obtenu après les trois opérations de traitement.*

Dans ce chapitre, nous avons détaillé les opérations de prétraitements appliqués aux données sonar. Elles se résument comme suit :

- Pondération Hamming;
- Compression et filtrage par ondelettes;
  
- Compression par analyse en composantes principales (ACP).

Ainsi, à partir d'un vecteur de l'enregistrement du dauphin de 60000 éléments, nous lui avons appliqué l'ondelette Daubechies1 (db1) pour obtenir un autre vecteur de 30000 éléments. Nous avons traité ce dernier par la fenêtre de Hamming ensuite l'ACP obtenant ainsi un autre vecteur de 90 éléments en gardant 99,88% en moyenne d'information utile. Ce dernier vecteur est la donnée caractéristique supposée pertinente qui va être utilisée ultérieurement à des fins de classification.

## II.1 INTRODUCTION

Nous avons présenté dans le chapitre précédent les prétraitements effectués sur notre banque de données sonar. Le but de l'étape précédente est d'extraire l'information essentielle caractérisant la signature de la cible à classer, et de la présenter sous la forme la plus concentrée possible au classifieur.

Les techniques de classification possibles, pour les données sonar, sont nombreuses. Deux méthodes sont présentées dans ce chapitre :

- Le 1 plus proche voisin ;
- La Rétropropagation du gradient de l'erreur des réseaux de neurones.

Les vecteurs de données sont divisés en deux ensembles : données d'apprentissage et données de test. Les vecteurs d'apprentissage constituent 75% de l'ensemble de données, les 25% restant forment l'ensemble test. Le choix des vecteurs de test s'effectue de façon aléatoire.

## II.2 MÉTHODE DES K PLUS PROCHES VOISINS

C'est une méthode de comparaison basée sur le calcul des distances métriques entre les vecteurs.

### II.2.1 Principe

La loi du plus proche voisin assigne à un vecteur la classe ou l'étiquette d'un autre vecteur qui lui est proche au sens d'un critère. Ce dernier est basé sur la minimisation d'une distance métrique.

Soit  $p \in Y_t$ , un vecteur profil à classer. La classe  $C = k$  est assignée au vecteur  $p$  si et seulement si :

$$D(p, y_j) < D(p, y_k), j = 1, \dots, L, j \neq k \quad (\text{II.1})$$

$D$  : La distance métrique.

$L$  : Le nombre total des vecteurs d'apprentissage.

De façon générale, nous pouvons calculer plusieurs voisins (les  $k$  plus proches voisins ou vecteurs similaires) au vecteur  $p$ . Dans ce cas là, nous prenons les  $k$  distances métriques dans le sens ascendant, [2].

### II.2.2 Distances métriques

La distance métrique est une fonction  $D(, )$  de  $R^D \times R^D$  à  $R$ . Soient  $a$ ,  $b$  et  $c$  trois vecteurs de même longueur  $d$ . La distance métrique doit satisfaire ce qui suit :

- $D(a, b) \geq 0$

- $D(a, b) = 0$  si et seulement si  $a = b$
- $D(a, b) = D(b, a)$
- $D(a, b) + D(b, c) \geq D(a, c)$

Pour notre application, nous utilisons la distance euclidienne qui est définie

comme suit :

$$D(a, b) = \|a - b\| = \sqrt{\sum_{i=1}^d (a_i - b_i)^2} \quad (\text{II.2})$$

Le but de ce travail est la discrimination **rigoureuse** des différentes cibles avec le minimum de confusion. Pour cela, nous considérons le cas du 1 plus proche voisin.

## II.3 L'APPROCHE NEURONALE

### II.3.1 Le neurone biologique

Le neurone est une cellule composée d'un corps cellulaire et d'un noyau. Le corps cellulaire se ramifie pour former ce que l'on nomme les dendrites. Celles-ci sont parfois si nombreuses que l'on parle alors de chevelure dendritique ou d'arborisation dendritique. C'est par les dendrites que l'information est acheminée de l'extérieur vers le soma, corps du neurone. L'information traitée par le neurone chemine ensuite le long de l'axone (unique) pour être transmise aux autres neurones. La transmission entre deux neurones n'est pas directe. En fait, il existe un espace intercellulaire de quelques dizaines d'Angstrom ( $10^{-9}$  m) entre l'axone du neurone afférent et les dendrites (on dit une dendrite) du neurone déférent. La jonction entre deux neurones est appelée la synapse, [5] (Figure II.1).

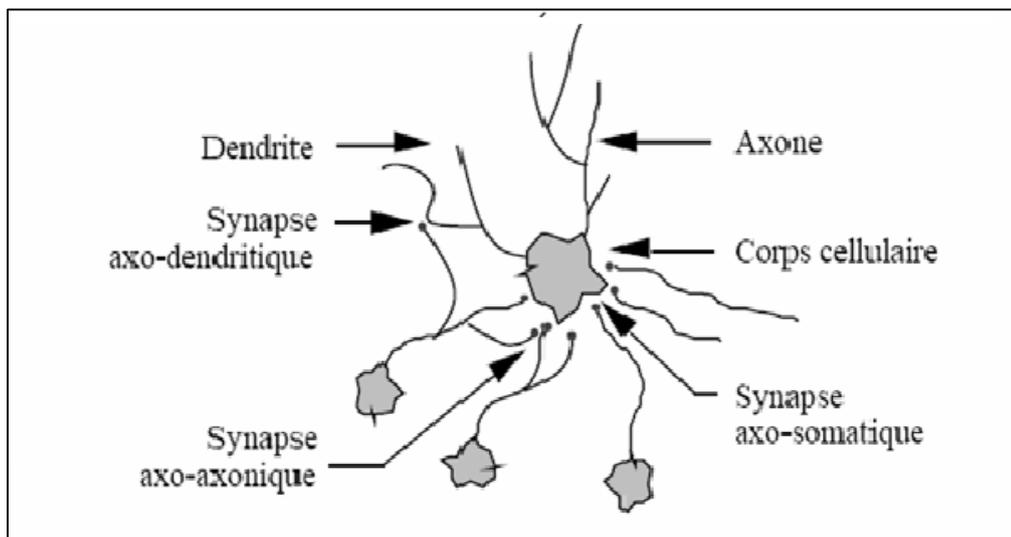


Figure II .1 : Un neurone biologique.

### II.3.2 Le neurone formel

Les réseaux de neurones formels sont des structures (la plupart du temps simulées par des algorithmes exécutés sur des ordinateurs d'usage général, parfois sur des machines ou même des circuits spécialisés) qui prennent leur inspiration (souvent de façon assez lointaine) dans le fonctionnement élémentaire des systèmes nerveux. Ils sont utilisés essentiellement à résoudre des problèmes de classification, de reconnaissance de formes, d'association, d'extraction de caractéristiques, d'identification. Ils deviennent des compléments aux méthodes classiques, et sont même susceptibles de se substituer à celles-ci avec un taux de succès supérieur, [7]. Un schéma classique d'un neurone formel est illustré à la Figure II.2.

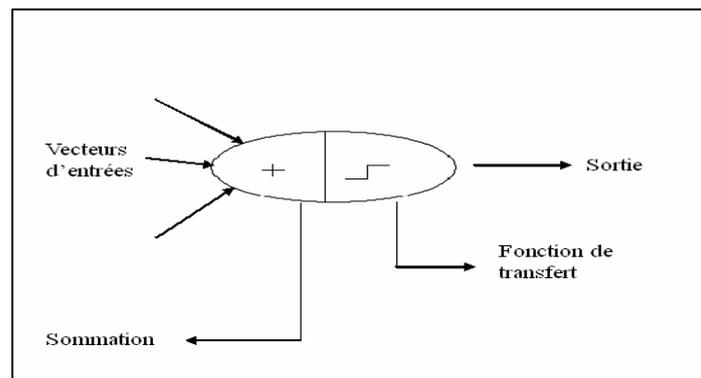


Figure II.2 : Schéma classique d'un neurone.

Un neurone formel fait une somme pondérée des potentielles d'action qui lui parvient (chacun de ces potentiel est une valeur numérique qui présente l'état du neurone qui lui émis), puis s'active suivant la valeur de cette somme pondérée. Si celle-ci dépasse un certain seuil, le neurone est activé et transmet une réponse (sous forme de potentiel d'activation) dont la valeur est celle de son activation, si le neurone n'est pas activé, il ne transmet rien, [7].

Le modèle du neurone formel peut être constitué comme illustré à la Figure II.3.

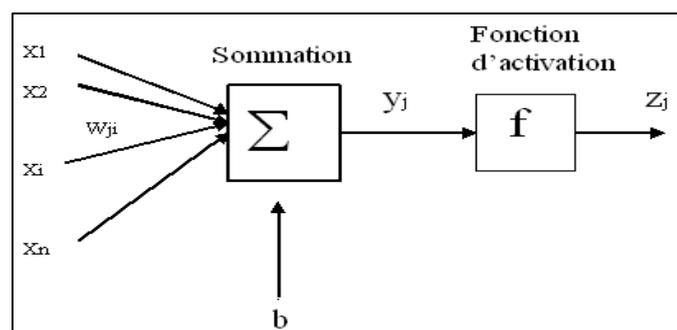


Figure II.3 : Modèle d'un neurone formel.

Où :

$X_i$  : représentent les vecteurs d'entrée du neurone ( $j$ )

$W_{ji}$  : les poids de ces vecteurs

$b$  : le seuil du neurone ( $b=0$ , dans notre application)

$$y_j = \sum_{i=1}^n W_{ji} \cdot X_i + b \quad (\text{II.3})$$

$Z_j$  : la fonction du neurone (sigmoïde-logarithmique dans notre application)

$$Z_j = 1 / (1 + \exp(-Y_j)) \quad (\text{II.4})$$

### II.3.3 La fonction d'activation

La fonction d'activation du neurone définit son état interne en fonction de son entrée totale. Le comportement d'un neurone dépend essentiellement du choix de sa fonction d'activation. Différentes fonctions de transfert, pouvant être utilisées comme fonction d'activation du neurone sont :

a) la fonction linéaire, [7]:

$$y = \beta n \quad (\text{II.5})$$

$\beta > 0$

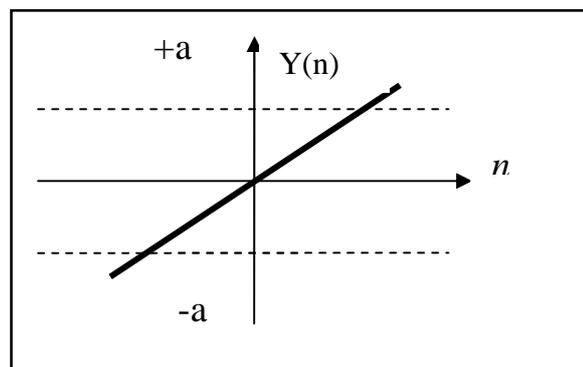


Figure II.4 : fonction de transfert linéaire

b) La fonction tan sigmoïde, [7]:

$$y = \frac{1}{2} (\exp(-2 \cdot n)) - 1 \quad (\text{II.6})$$

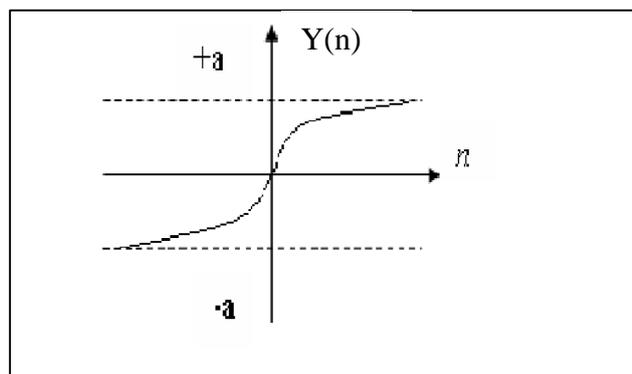


Figure II.5 : fonction de transfert tangente sigmoïde

c) La fonction sigmoïde, [7]

$$y = 1/(1+\exp(-n)) \quad (\text{II.7})$$

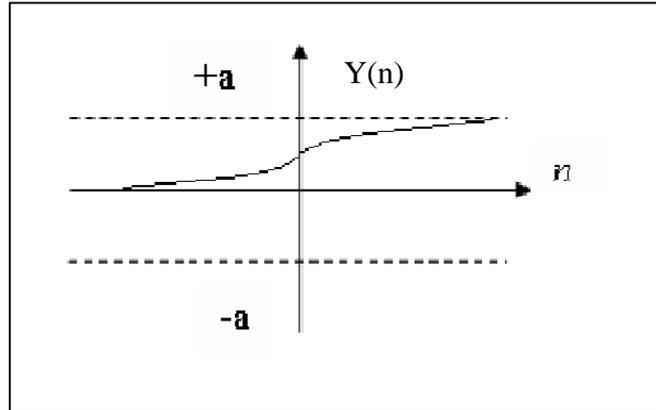


Figure II.6 : fonction de transfert logarithmique sigmoïde.

d) La fonction a(n), [7]

$$\begin{aligned} y &= +a && \text{si } n \geq 0 \\ y &= -a && \text{sinon} \end{aligned} \quad (\text{II.8})$$

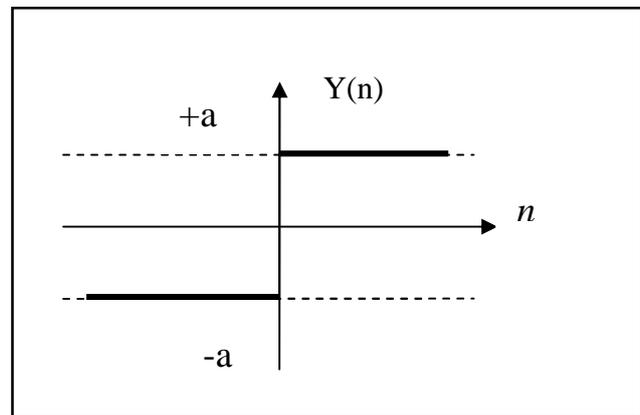


Figure II.7 : fonction de transfert du signe

e) La fonction seuil, [7]

$$\begin{aligned} y &= 1 && \text{si } n \geq 0 \\ y &= 0 && \text{sinon} \end{aligned} \quad (\text{II.9})$$

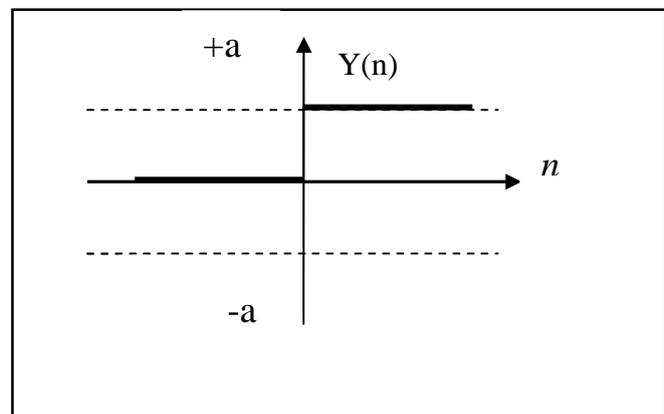


Figure II.8 : fonction de transfert du seuil

### II.3.4 Réseaux de neurones

Concernant notre application, nous nous intéressons uniquement aux réseaux de neurones de type perceptrons multicouches (multilayers perceptron) « MLP », appropriés à l'apprentissage supervisé.

La Figure II.9 représente un schéma synoptique d'un réseau de neurones.

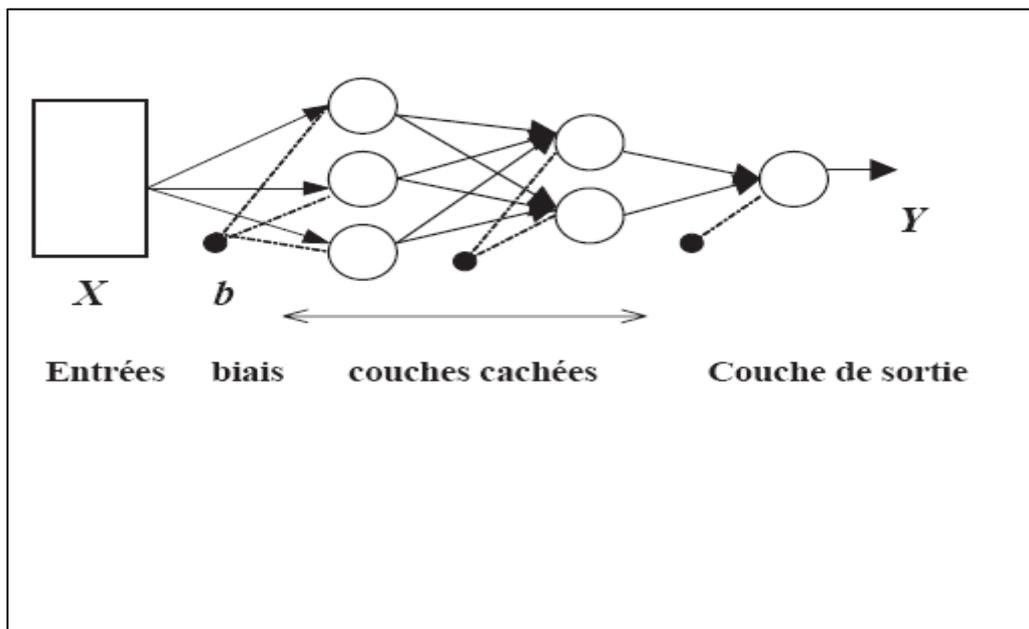


Figure II.9 : Schéma d'un réseau de neurone.

a) La couche d'entrée :

Elle reçoit les données que l'on veut utiliser. Sa taille est donc directement déterminée par le nombre de variables d'entrées.

b) La couche cachée :

La seconde couche est la couche cachée, dans le sens qu'elle n'a pas de contact direct avec l'extérieur. Les fonctions d'activations sont en général non linéaires.

Le choix de sa taille (nombre de neurones) n'est pas implicite et doit être ajusté.

c) La couche de sortie :

La dernière couche est appelée couche de sortie, elle donne le résultat obtenu après introduction des données d'entrées dans la première couche cachée.

La taille de cette couche est directement déterminée par le nombre de formes (classes) désirées.

### II.3.5 : Apprentissage

L'apprentissage est une phase du développement du réseau de neurones durant laquelle on calcule les poids des neurones de telle manière que les sorties du réseau soient aussi proches que possibles des sorties désirées. L'apprentissage fait appel à des exemples de comportement du processus de classification.

L'apprentissage est dit **supervisé** lorsque les exemples sont constitués de couples de valeurs du type : (valeur d'entrée, valeur de sortie désirée). Tout le problème de l'apprentissage supervisé consiste à faire rapprocher la sortie réelle de la sortie désirée, donc déterminer les valeurs des poids des neurones capables de prédire le même vecteur de sortie à partir du même vecteur d'entrée.

L'apprentissage est qualifié de **non supervisé** lorsque seules les valeurs d'entrée sont disponibles. Dans ce cas, les exemples présentés à l'entrée provoquent une auto adaptation du réseau afin de produire des valeurs de sortie qui soient proche en réponse pour des valeurs d'entrées similaires.

Durant l'apprentissage, les poids sont ajustés itérativement pour minimiser la fonction de performance mesurant l'écart entre les sorties effectives  $S(k)$  et les sorties désirées  $D(k)$ ; l'erreur la plus couramment employée est l'erreur quadratique, [7]

$$E_k = 1/2 \sum_{K=1}^M (D_k - S_k)^2 \quad \text{erreur de l'exemple } k. \quad (\text{II.10})$$

( $S_k, D_k$ ) sont successivement la sortie réelle et la sortie désirée de la couche  $k$ ).

Dans ce chapitre, nous allons décrire l'algorithme d'apprentissage, il utilise le gradient de la fonction de performance pour déterminer comment ajuster les poids pour minimiser l'erreur.

Le problème pour un réseau à une ou plusieurs couches cachées est d'évaluer les valeurs optimales des poids des connexions.

La solution proposée est de rétropropager l'erreur proportionnellement aux poids.

La Rétropropagation comprend donc deux phases :

- présentation d'un exemple et propagation des activations vers la sortie.
- Calcul de l'erreur de sortie et propagation vers l'entrée.

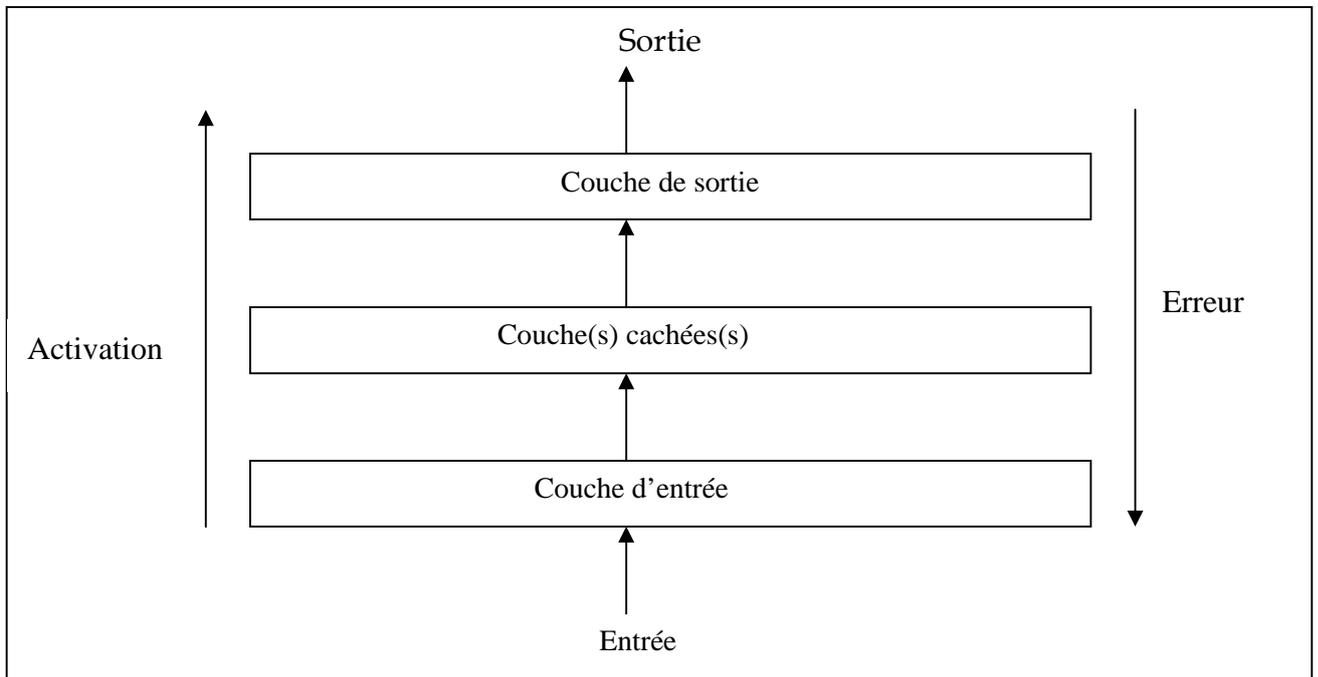


Figure II.10 : L'erreur d'un MLP se calcul dans le sens inverse de sa propagation

### II.3.6 Algorithme de Rétropropagation

Le principe de l'algorithme de Rétropropagation consiste à ajuster les poids dans le sens inverse du gradient de la fonction de performance, [7], comme suit :

$$\Delta W_{j,i} = -\partial E / \partial W_{j,i} \quad (\text{II.11})$$

Pour avoir un bon fonctionnement de l'algorithme de Rétropropagation, il a eu d'introduire deux paramètres en plus, qui sont :

- **le pas d'apprentissage (a) :**

Il sert à faire converger les poids vers une solution, en effectuant des sauts discret pour les poids, il prend des valeurs comprises dans l'intervalle [0.1 , 1], [2].

- **le momentum (δ) :** (coefficient d'inertie)

Il sert à réduire le temps d'apprentissage dans le cas où on utilise un grand pas d'apprentissage, il prend des valeurs comprises dans l'intervalle [0.6 , 0.9], [2].

### II.3.7 Etapes de l'algorithme de Rétropropagation de l'erreur

Les étapes principales de cet algorithme sont classées comme suit :

- 1- Initialisation des poids synaptiques  $W_{ji}$ ,  $W_{kj}$  avec des valeurs aléatoires faibles.
- 2- Application des valeurs d'entrée et des vecteurs de sortie désirée.
- 3- Calcul des activations des cellules cachées :  $Y_j = \sum_{i=1}^N W_{ji} \cdot X_i$
- 4- Calcul des sortie des cellules cachées :  $Z_j = f_j(Y_j)$
- 5- Calcul des activations des cellules de sorties par :  $V_k = \sum_{j=1}^L W_{kj} \cdot Z_j$
- 6- Calcul des sorties des cellules de sortie par :  $S_k = f_k(V_k)$
- 7- Calcul de l'erreur quadratique :  $E = 1/2 \sum_{K=1}^M (D_k - S_k)^2$
- 8- Adaptation des poids de la couche de sortie (mise à jour)

$$\begin{aligned}
 E / W_{kj} &= - (D_k - S_k) (D_k - S_k) / W_{kj} \\
 &= - (D_k - S_k) (S_k / W_{kj}) \\
 &= - \text{err}(k) ((S_k / V_k) (V_k / W_{kj})) \\
 &= - \text{err}(k) F'_k(V_k) (V_k / W_{kj}) \\
 &= - \text{err}(k) (F'_k(V_k)) Z_j
 \end{aligned}$$

$$W_{kj} = -n \quad E / W_{kj}$$

$$W_{kj} = n [ \text{err}(k) (F'_k(Y_k)) (-a) Z_j ] \quad \text{(II.12)}$$

$$W_{kj}(t+1) = W_{kj} + W_{kj}(t) + (m * W_{kj}) \quad \text{(II.13)}$$

Ou :

$W_{kj}(t)$  : est l'ancienne valeur des poids de la couche de sortie.

$W_{kj}(t+1)$  : est la nouvelle valeur des poids après l'adaptation.

9-Adaptation des poids de la couche cachée :

$$\begin{aligned}
 E / W_{ji} &= 1/2 \sum_{k=1}^M (D_k - S_k)^2 / W_{ji} \\
 &= - \sum_{k=1}^M (S_k / W_{ji}) (D_k - S_k) \\
 &= - \sum_{k=1}^M \text{err}(k) (S_k / W_{ji}) \\
 &= - \sum_{k=1}^M \text{err}(k) [(S_k / V_k) (V_k / Z_j) (Z_j / Y_j) (Y_j / W_{ji})] \\
 &= - \sum_{k=1}^M \text{err}(k) (F'_k(V_k)) W_{kj} (F'_j(Y_j)) X_i \\
 &= - X_i F'_j(Y_j) \sum_{k=1}^M \text{err}(k) (F'_k(V_k)) W_{kj} \\
 W_{ji} &= n [F'_j(Y_j) X_i \sum_{k=1}^M \text{err}(k) (F'_k(V_k)) (-a) W_{kj}] \quad \text{(II.14)}
 \end{aligned}$$

$$W_{ji}(t+1) = W_{ji} + W_{ji}(t) + (m * W_{kj}) \quad \text{(II.15)}$$

Ou :

$W_{ji}(t)$  : est l'ancienne valeur des poids de la couche cachée.

$W_{ji}(t+1)$  : est la nouvelle valeur des poids après l'adaptation.

$W_{ji}$  : poids reliant le nœud  $i$  au nœud  $j$

$W_{kj}$  : poids reliant le nœud  $j$  au nœud  $k$

$n$  : le nombre de cellules de la couche d'entrée

$L$  : le nombre de cellules de la couche cachée

$m$  : le nombre de cellules de la couche de sortie

$F_j$  : la fonction d'activation du neurone  $j$  de la couche de cachée

$Z_k$  : sortie de cellule  $k$  de la couche cachée

$F_k$  : la fonction d'activation de la cellule  $k$  de la couche de sortie

$D_k$  : la sortie désire de la cellule  $k$

$\text{err}(k)$  : erreur de la cellule  $k$  de la couche de sortie

## II.4 CONCLUSION

Ce chapitre a fait l'objet de l'approche proposée pour la classification des cibles sonar. Deux méthodes ont été retenues :

- Les  $k$  plus proches voisins (kppv);
- Algorithme de Rétropropagation du gradient des réseaux de neurones.

### III.1 INTRODUCTION

Nous avons présenté dans les chapitres précédents notre approche de classification ainsi que les prétraitements effectués sur notre banque de données. Le but de l'étape de prétraitement, est d'extraire l'information essentielle caractérisant la signature acoustique à classifier, et de la présenter sous la forme la plus concentrée possible au classifieur.

Il est important de remarquer que le problème traité dans ce travail est la classification supervisée, c'est-à-dire pour laquelle l'utilisateur connaît et le système utilise l'information concernant l'appartenance aux classes des vecteurs d'apprentissages. Nous disposons donc d'un ensemble de vecteurs étiquetés, qui vont être présentés au classifieur afin que celui-ci puisse en déduire une règle de décision optimisant un certain critère.

### III.2 CONSTRUCTION DE LA BANQUE DE DONNEES

Nous proposons une banque de donnée composée de trois (03) classes qui sont : classe 1 : sous marin, classe 2 : mammifères marins (dauphin, baleines), classe 3 : bateaux de surfaces (chalutiers). Le résultat du traitement appliqué est un ensemble de matrices de dimension (101\*90) ; c à d, 101 vecteurs de 90 éléments chacun. Les vecteurs de chaque matrice (classe) sont pris de façon aléatoire.

### III.3 LES PARAMÈTRES DES CLASSIFIEURS

Nous utilisons un perceptron à une seule couche cachée. La fonction d'activation est la sigmoïde. Le nombre de neurones en entrée est 90 (taille du vecteur). Le nombre de neurones en sortie est 3 (3 classes). Le nombre de neurones dans la couche cachée est déterminé par tâtonnement. Concernant le 1 plus proche voisin, nous utilisons la distance Euclidienne comme distance métrique.

Les vecteurs d'entrée appartiennent à (03) classes différentes réparties sur des matrices de (101\*90) chacune. Dans la phase de l'apprentissage, nous prenons d'une manière aléatoire 76 (75% de l'ensemble) vecteurs parmi les 101 possibles, les 25 (25% de l'ensemble) restants de chaque matrice sont retenus pour la généralisation (le test).

Les performances de classification, sont déterminées par :

- Le diagramme de l'erreur quadratique et la matrice de confusion pour la méthode neuronale.
- La matrice de confusion pour le 1 plus proche voisin.

## III.4 ÉVALUATION DES PERFORMANCES DE CLASSIFICATION

### III.4.1 Diagramme de l'erreur

C'est une représentation de l'erreur quadratique en fonction du nombre d'itérations, calculée dans la phase d'apprentissage. Le calcul de l'erreur se fait après propagation du vecteur de l'entrée vers la sortie. La sortie obtenue (réelle) est souvent différente de la sortie désirée. Dans ce cas, cette erreur est rétropropagée, c'est-à-dire propagée de la sortie vers l'entrée en recalculant les valeurs des poids synaptiques (mise à jour des poids). Cette procédure est itérée plusieurs fois (parfois jusqu'à 100000 itérations). A chaque introduction d'un vecteur, l'erreur est calculée et comparée à la valeur précédente. Le but est de minimiser cette erreur. Par conséquent, la convergence de l'algorithme est assurée par un nombre très grand d'itérations afin d'éviter un minimum local. Il est évident que dans le cas idéal, nous obtenons une courbe qui décroît rapidement vers une valeur très proche de zéro.

### III.4.2 Matrice de confusion

Elle est de dimension  $N * N$  (où  $N$  est le nombre de classe de sortie, (égal à 3 dans notre cas). Cette matrice est calculée pour les vecteurs d'apprentissage et pour ceux du test. Son élément  $m_{ij}$ , est égal au nombre de vecteurs de la classe  $i$  qui sont affectés dans la classe  $j$ , comme indiqué en Figure III.1. Idéalement cette matrice ne devrait contenir que des « 1 » sur la diagonale et des « 0 » partout ailleurs.

	C1	C2	C3
C1	$C1/C1$	$C2/C1$	$C3/C1$
C2	$C1/C2$	$C2/C2$	$C3/C2$
C3	$C1/C3$	$C2/C3$	$C3/C3$

**Figure III.1 :** Matrice de confusion,  $N = 5$ .

Nous définissons le paramètre  $P_{cc}$ , qui représente la probabilité de classification correcte qui est donné par la moyenne de la diagonale de la matrice de confusion, [6].

### III.5 PRÉSENTATION DES RÉSULTATS OBTENUS

Dans ce qui suit, nous considérons pour les deux méthodes :

**Test 1 :** Les vecteurs classifiés appartiennent à la banque de données utilisée pour l'apprentissage (75% de l'ensemble) ;

**Test 2 :** Les vecteurs classifiés appartiennent à la banque de données utilisée pour le test (25% restant) ;

#### III.5.1 Quelques résultats obtenus par la Rétropropagation

Dans ce qui suit, nous considérons :

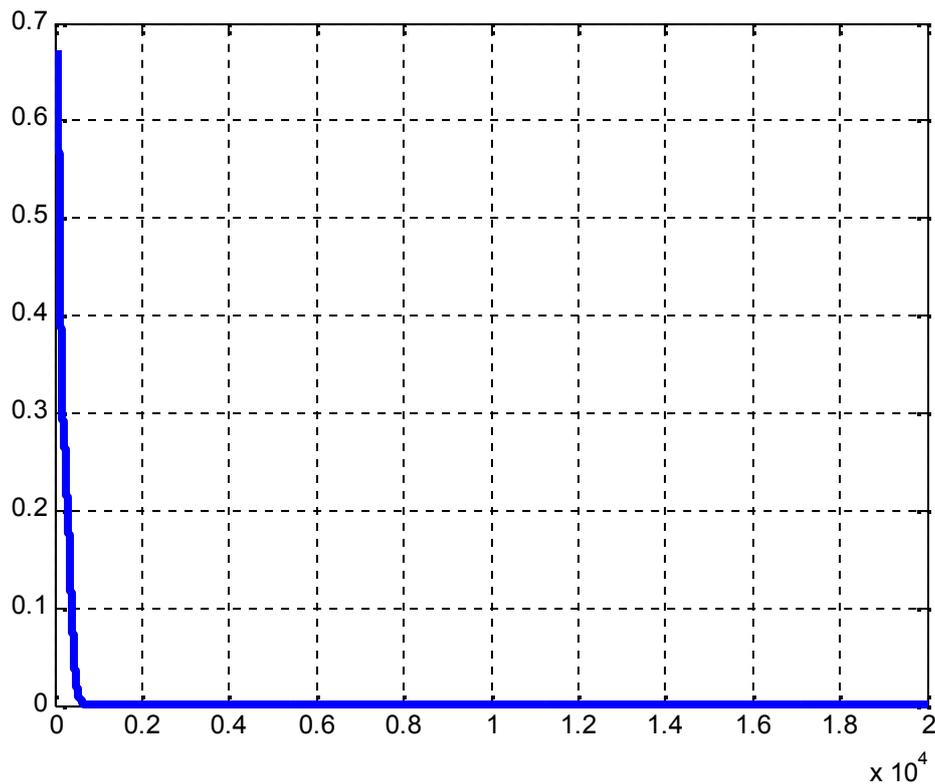
**It :** le nombre d'itérations ;

**nn :** le nombre de neurones de la couche cachée;

**a :** le pas d'apprentissage ;

**mom :** le momentum ;

**Err :** la dernière valeur de l'erreur.



**Figure III.2 :** Evolution de l'erreur quadratique.

$It = 20000$  ,  $a = 0.1$  ,  $mom = 0,997$  ,  $nn = 4$  ,  $err = 2.0726e-007$

<b>1.0000</b>	<b>0</b>	<b>0</b>
<b>0.0263</b>	<b>0.9079</b>	<b>0.0658</b>
<b>0.0263</b>	<b>0.0395</b>	<b>0.9342</b>
<b>Pcc=0.9474</b>		

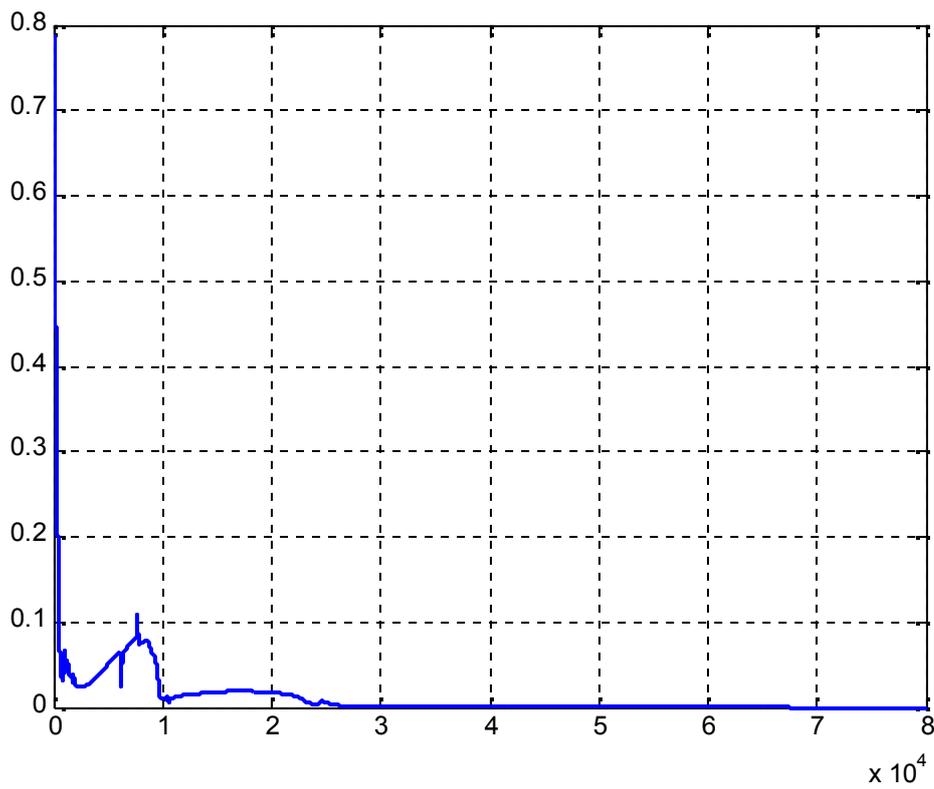
(a)

<b>1</b>	<b>0</b>	<b>0</b>
<b>1</b>	<b>0</b>	<b>0</b>
<b>1</b>	<b>0</b>	<b>0</b>
<b>Pcc=0.3333</b>		

(b)

**Figure III.3 :** Le résultat de la classification avec les matrices de confusion.(a) Test 1, (b) Test 2.

D'après la Figure III.2, l'erreur est minimisée au delà de 1000 itérations. En utilisant les données test 1 nous obtenons  $Pcc = 0,9474$  (Voir Figure III.3). Ce résultat est prévisible car les données sont utilisées lors de l'apprentissage. Cependant, les données test 2 sont mal classées. Ceci peut être interprété par le nombre insuffisant d'itérations. Par conséquent, nous devons augmenter le nombre d'itérations.



**Figure III.4 :** Evolution de l'erreur quadratique.  
 $I_t = 80000$  ,  $a = 0.1$  ,  $mom = 0,997$  ,  $nn = 4$  ,  $err = 1.1802e-025$

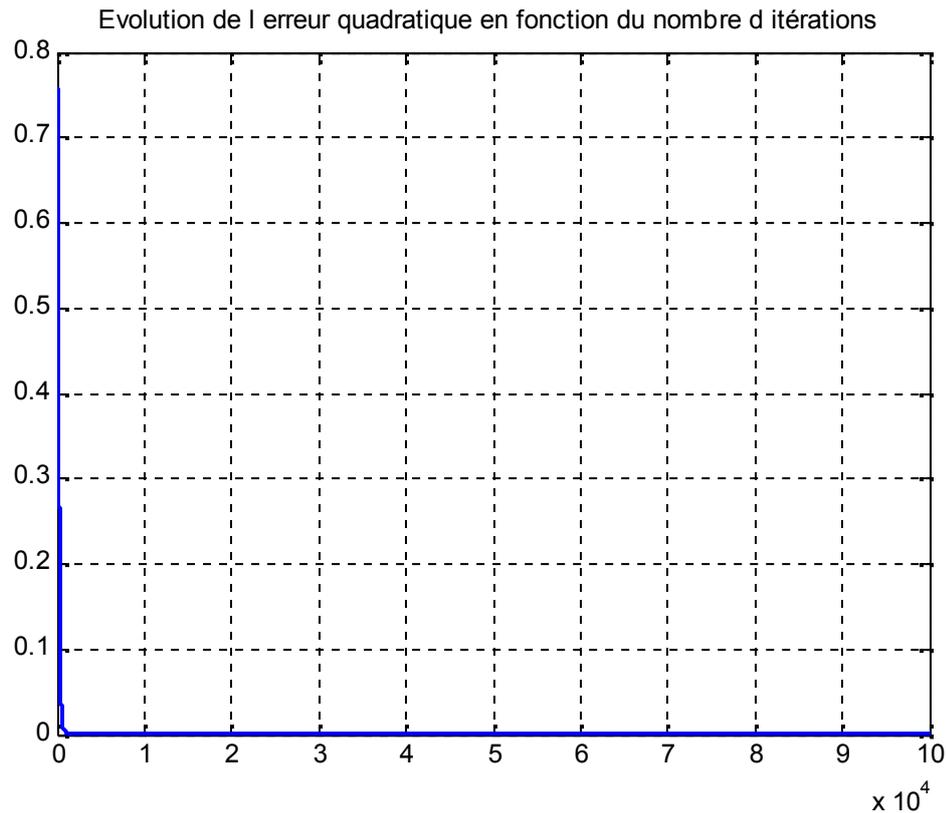
<b>0.8816</b>	<b>0.1053</b>	<b>0.0132</b>
<b>0.0658</b>	<b>0.9211</b>	<b>0.0132</b>
<b>0.0132</b>	<b>0.0789</b>	<b>0.9079</b>
<b>Pcc=0.9035</b>		

(a)

<b>0.8000</b>	<b>0.1600</b>	<b>0.0400</b>
<b>0.9600</b>	<b>0.0400</b>	<b>0</b>
<b>0.8800</b>	<b>0.1200</b>	<b>0</b>
<b>Pcc=0.2800</b>		

(b)

**Figure III.5 :** Le résultat de la classification avec les matrices de confusion.(a) Test 1, (b) Test 2.



**Figure III.6 :** Evolution de l'erreur quadratique.

It = 100000 , a = 0.1 , mom = 0,999 , nn = 4 , err = 2.1506e-004

0.9737	0.0132	0.0132
0	0.8816	0.1184
0	0.0789	0.9211
<b>Pcc=0.9254</b>		

(a)

0.9600	0	0.0400
0.9600	0.0400	0
1	0	0
<b>Pcc=0.3333</b>		

(b)

**Figure III.7 :** Le résultat de la classification avec les matrices de confusion.(a) Test 1, (b) Test 2.

D'après les Figures III.5 III.7, nous constatons que les vecteurs sont toujours mal classés malgré le nombre important d'itérations. Un cas particulier pour la classe 1 (classe des sous marins) où l'on note une probabilité supérieure à 90%.

Ceci peut être interprété par le mauvais choix :

- de la méthode de traitement (ACP, ondelettes);
- du classifieur neuronal;
- des paramètres du réseau tel le momentum, le pas d'apprentissage,.....

Notant que pour trouver les paramètres optimaux, il faut tâtonner et essayer plusieurs valeurs de façon empirique.

### III.5.2 Quelques résultats obtenus par le 1 plus proche voisin

0.8800	0	0.1200	0.7200	0.0400	0.2400
0.3200	0.6000	0.0800	0.3200	0.5600	0.1200
0.3600	0.4000	0.2400	0.4400	0.1600	0.4000
Pcc=0.5733			Pcc=0.56		

1	0	0	0.7600	0.0800	0.1600
0.2000	0.6800	0.1200	0.2000	0.6000	0.2000
0.4400	0.2000	0.3600	0.4000	0.2800	0.3200
Pcc=0.68			Pcc=0.56		

**Figure III.8 :** Le résultat de la classification avec les données Test 2.

D'après la Figure III.8, nous constatons que les vecteurs de la classe 1 sont toujours les biens classés. La confusion réside dans les données de la classe 3. Ce mauvais résultat est peut être dû au choix de la distance métrique ou simplement au choix de la méthode elle même.

### III.6 CONCLUSION

Les résultats obtenus par les deux méthodes montrent que les données que nous avons utilisées ne sont pas discriminantes. De plus la méthode de rétropropagation est empirique. Il faut exécuter au moins une centaine de fois pour aboutir aux paramètres optimaux. La méthode du 1 plus proche voisin donne les meilleurs résultats en terme de probabilité de classification correcte.

## ***BILAN***

L'approche de classification proposée dans ce mémoire, porte sur l'analyse de la signature acoustique sonar et la classification des cibles sonar.

Une étape de prétraitement des données s'impose avant la phase de classification. Les prétraitements effectués sont :

- La pondération qui permet de réduire les niveaux des lobes secondaires,
- la décomposition en ondelettes;
- l'analyse en composantes principales (ACP).

Deux classifieurs ont été proposés pour la phase décisionnelle :

1 - La méthode du 1 plus proches voisins, qui est simple et basée sur le calcul des distances métriques entre vecteurs. Nous avons choisi d'utiliser la distance Euclidienne.

2- Le classifieur neuronal : Pour notre application, nous avons choisi l'algorithme de la Rétropropagation du Gradient d'un réseau à une seule couche cachée de neurones. La mise en oeuvre de cet algorithme impose le choix de certains paramètres, qui ont une influence directe sur les résultats de la classification. Les paramètres optimaux ont été déterminés de façon empirique. Cette procédure a pour effet d'alourdir le processus d'entraînement.

Les meilleurs résultats en termes de classification ont été obtenus par la méthode du 1 plus proche voisin. Les résultats obtenus de façon générale ne sont pas satisfaisants. L'apprentissage du réseau de neurones est très lent. La lenteur de l'apprentissage est un détail d'une importance primordiale, car la plupart des applications de reconnaissance s'exécutent en temps réel.

## *PERSPECTIVES*

Les premières perspectives concernent bien évidemment la banque de données utilisée. En effet, il convient de tester l'approche proposée sur une banque de données réelles brutes pour valider et confirmer les résultats avancés.

Dans un souci d'amélioration des performances, il convient de fusionner les résultats de classification des différents classifieurs (Fonctions à bases radiales "RBF", Machines à vecteurs de support "SVM", ...etc.).

De plus, plusieurs méthodes peuvent être utilisées conjointement à savoir RBF/HMM, SOM / MLP,...etc. Les approches hybrides permettent de renforcer la qualité de la reconnaissance.

De plus, une éventuelle perspective consiste à fusionner plusieurs données sonar acquises à partir de sites différents, de la même cible à identifier.

Pour réduire la confusion entre les différentes cibles, le choix des vecteurs caractéristiques est très important. Pour ce faire, nous proposons la densité spectrale de puissance, les moments d'ordre  $n$  comme paramètres pertinents.

## **BIBLIOGRAPHIE :**

### **I -OUVRAGES :**

-[1], Michel BOUVET, “**Traitement des signaux pour les systèmes sonar**“, MASSON, 1992.

-[2], R.van Der Heiden and F.C.A. Geon, “**The box-metric for nearest neighbor classification Improvement**“, *Pattern Recognition*, 30(2), 1997.

-[3], G.E.P. Box and D.R. Cox “**An Analysis of transformation**“  
*Journal of the Royal Statistical Society, Series B*, 26:211-252, 1964.

-[4], MATLAB Function, Matlab 7.0

-[5], M elle. Haddad. Akila, Thèse ingénieur sur « **Méthode de classification automatique** », Université de Mouloud Mammeri, Tizi Ouzou, 2003.

-[6], Mr. Smail. Farid et Mr. Badji.Djamel, Thèse ingénieur sur « **Application des réseaux de neurone pour la classification des cibles radar non coopératives au moyen de leurs images ISAR** », Université de Mouloud Mammeri Tizi Ouzou, 1997.

-[7], Melle.Ouslimani.F, Thèse ingénieur sur “**Classification des signaux par les réseaux de neurones**“, Université de Mouloud Mammeri Tizi Ouzou,2003.

### **II – SITES INTERNET :**

-[Réf web1] :<http://www.cernade.dauphine.fr>

« Introduction aux réseaux de neurones »

-[Réf web2] :<http://www.univ-lille3.fr>

« Apprentissage automatique : les réseaux de neurones »



# LISTE DES FIGURES

## Chapitre I : Acoustique sous marine-Traitement des données sonar

<b>Figure I.1 :</b> <i>La détection d'un sous marin par un sonar mis dans un navire.....</i>	04
<b>Figure I.2 :</b> <i>Principe d'un système sonar actif.....</i>	06
<b>Figure I.3 :</b> <i>Le principe du sonar passif.....</i>	07
<b>Figure I.4 :</b> <i>Le son d'une baleine bleue.....</i>	08
<b>Figure I.5 :</b> <i>Le son d'un dauphin.....</i>	08
<b>Figure I.6 :</b> <i>Le son d'un tanker.....</i>	09
<b>Figure I.7 :</b> <i>Le son d'un sous marin.....</i>	09
<b>Figure I.8 :</b> <i>Le son d'une séparation d'un iceberg.....</i>	10
<b>Figure I.9 :</b> <i>Enregistrement d'une baleine bleue et sa décomposition en ondelettes.....</i>	11
<b>Figure I.10 :</b> <i>Enregistrement d'un dauphin et sa décomposition en ondelettes.....</i>	11
<b>Figure I.11 :</b> <i>Enregistrement d'un bateau (chalutier) et sa décomposition en ondelettes.....</i>	12
<b>Figure I.12 :</b> <i>Enregistrement d'une torpille et sa décomposition en ondelettes.....</i>	12
<b>Figure I.13 :</b> <i>Enregistrement d'un sous marin et sa décomposition en ondelettes.....</i>	13
<b>Figure I.14 :</b> <i>Exemple de trois fenêtres de pondération. Hamming, Hanning et Blackman.....</i>	14
<b>Figure I.15 :</b> <i>Exemple de pondération Hamming appliqué au signal d'un sous marin.....</i>	15
<b>Figure I.16 :</b> <i>Exemple de pondération Hanning appliqué au signal d'un dauphin.....</i>	15
<b>Figure I.17 :</b> <i>Exemple de pondération Blackman appliqué au signal de séparation d'iceberg.....</i>	16
<b>Figure I.18 :</b> <i>Réduction des niveaux des lobes secondaire en pondérant la porte rectangulaire par Hamming.....</i>	16
<b>Figure I.19 :</b> <i>Réduction des niveaux des lobes secondaires du spectre de la baleine grise avec Hanning.....</i>	17
<b>Figure I.20 :</b> <i>Réduction des niveaux des lobes secondaires du spectre du sous marin avec Blackman.....</i>	17
<b>Figure I.21 :</b> <i>Réduction des niveaux des lobes secondaires du spectre de l'iceberg avec Hamming.....</i>	18
<b>Figure I.22 :</b> <i>Réduction des niveaux des lobes secondaires du spectre d'une torpille avec Hamming.....</i>	18
<b>Figure I.23 :</b> <i>La transformée de Fourier – signal beluga.....</i>	19
<b>Figure I.24 :</b> <i>La transformée de Fourier – signal baleine grise.....</i>	20
<b>Figure I.25 :</b> <i>La transformée de Fourier – signal sous marin.....</i>	20
<b>Figure I.26 :</b> <i>La transformée de Fourier – signal iceberg.....</i>	21
<b>Figure I.27 :</b> <i>La transformée de Fourier – signal torpille.....</i>	21
<b>Figure I.28 :</b> <i>La transformée de Fourier – signal croaker.....</i>	22
<b>Figure I.29 :</b> <i>La transformée de Fourier – signal tanker.....</i>	22
<b>Figure I.30 :</b> <i>Le spectrogramme du signal dauphin.....</i>	23
<b>Figure I.31 :</b> <i>Le spectrogramme du signal baleine grise.....</i>	23
<b>Figure I.32 :</b> <i>Le spectrogramme du signal beluga.....</i>	24
<b>Figure I.33 :</b> <i>Le spectrogramme du signal sous marin.....</i>	24
<b>Figure I.34 :</b> <i>Le spectrogramme d'un signal bateau (tanker).....</i>	25
<b>Figure I.35 :</b> <i>Le spectrogramme d'un signal bateau (snorkel).....</i>	25
<b>Figure I.36 :</b> <i>Le spectrogramme d'un signal bateau (tug).....</i>	26
<b>Figure I.37 :</b> <i>Le spectrogramme d'un signal bateau (shrimp).....</i>	26
<b>Figure I.38 :</b> (a) <i>L'enregistrement du dauphin.</i> (b) <i>Le résultat obtenu après les trois opérations de traitement.....</i>	28
<b>Figure I.39 :</b> (a) <i>L'enregistrement du sous marin.</i> (b) <i>Le résultat obtenu après les trois opérations de traitement.....</i>	29

## Chapitre II : Approche proposée pour la classification

<b>Figure II.1</b> : Un neurone biologique.....	32
<b>Figure II.2</b> : Schéma classique d'un neurone.....	33
<b>Figure II.3</b> : Model d'un neurone formel.....	33
<b>Figure II.4</b> : fonction de transfert linéaire.....	34
<b>Figure II.5</b> : fonction de transfert tangente sigmoïde.....	34
<b>Figure II.6</b> : fonction de transfert logarithmique sigmoïde.....	35
<b>Figure II.7</b> : fonction de transfert du signe.....	35
<b>Figure II.8</b> : fonction de transfert du seuil.....	35
<b>Figure II.9</b> : Schéma d'un réseau de neurone.....	36
<b>Figure II.10</b> : L'erreur d'un MLP se calcul dans le sens inverse de sa propagation.....	38

## Chapitre III: Tests et résultats

<b>Figure III.1</b> : Matrice de confusion, $N = 5$ .....	44
<b>Figure III.2</b> : Evolution de l'erreur quadratique. It = 20000, a = 0.1 , mom = 0,997 , nn = 4 , err = 2.0726e-007.....	45
<b>Figure III.3</b> : Le résultat de la classification avec les matrices de confusion.(a) Test 1, (b) Test 2.....	45
<b>Figure III.4</b> : Evolution de l'erreur quadratique. It = 80000, a = 0.1 , mom = 0,997 , nn = 4 , err = 1.1802e-025.....	46
<b>Figure III.5</b> : Le résultat de la classification avec les matrices de confusion.(a) Test 1, (b) Test 2.....	46
<b>Figure III.6</b> : Evolution de l'erreur quadratique. It = 100000 , a = 0.1 , mom = 0,999 , nn = 4 , err = 2.1506e-004.....	47
<b>Figure III.7</b> : Le résultat de la classification avec les matrices de confusion.(a) Test 1, (b) Test 2.....	47
<b>Figure III.8</b> : Le résultat de la classification avec les données Test 2.....	48