

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche
Scientifique

Université Mohammed Seddik Ben Yahia - JIJEL



Faculté des Sciences et de la Technologie
Département d'Automatique

*Mémoire De Fin D'études Pour L'obtention Du
Diplôme De Master en Automatique*

Option : Automatique et systèmes

Thème :

Séparation aveugle complexe des sources

Présenté par :

Boukenicha Rokia

Encadré par :

Dr : Kemiha Mina

Année Universitaire : 2020- 2021

Dédicaces

Je dédie ce modeste travail

A mes chères parents : Pour votre amour, votre compréhension, votre patience, vos encouragements, vos prières et votre tendresse sont toujours sans limites pour moi, vous m'avez soutenu tout au long de mes études et vous avez tout sacrifié pour ma réussite, que Dieu vous garde en bonne santé.

A mes chères sœurs : Ratiba et Soumia.

A mes chères frères : Abdelmadjid et Aissa.

A mes chères : Selima et Meroua.

A mes amis proches et à tous ceux qui m'aiment.

Remerciement

*Avants tous je remercie Allah le tout puissant qui
m'a donné la force la volonté et le courage pour
accomplir ce travail.*

*Je tiens à remercier vivement madame **КЕМИНА . М**
mes éminent encadreur qui mes a permis d'enrichir
mes connaissances et mes a suivi et guidé avec
beaucoup de patience et de générosité tout au long
de mes travail de recherche.*

*Je remercie également les membres de jury qui ont
accepté d'examiner et de juger mes travail.*

*Je remercie s'étendent également à tous, nos
enseignants durant les années des études.*

Table des matières

Liste des symboles	i
Liste des abréviations.....	ii
Liste des Figures	iii
Liste des tableaux	iv
Introduction générale.....	1
Chapitre I : Décomposition en mode empiriques bivariée.	
I.1 Introduction	4
I.2 Définition	4
I.2.1 Signal stationnaire et non-stationnaire	4
I.2.2 La corrélation	5
I.2.3 La décorrélation.....	5
I.2.4 L'autocorrélation	5
I.2.5 La covariance	5
I.3 Méthodes d'analyse des signaux non stationnaires	5
I.3.1 Transformée de Fourier	5
I.3.2 Transformée de Fourier à fenêtre glissante	7
I.4 Transformée en Ondelette	8
I.5 Décomposition modale empirique (DME)	9
I.5.1 Principe de la décomposition	9
I.5.2 Tamisage (Processus de tamisage)	10
I.6 Décomposition en modes empiriques bivariée	12
I.6.1 Principe.....	12
I.6.2 Une enveloppe en 3 dimensions	13

I.6.3 Algorithme	14
I.7 Conclusion	14
Chapitre II : Méthodes de résolution du problème de la SAS.	
II.1 Introduction	15
II.2 Méthodes classiques de résolution de problème de SAS	15
II.2.1 Analyse en composantes principales (ACP)	15
II.2.2 Analyse en composantes indépendantes (ACI).....	16
II.2.3 Analyse en composantes indépendantes complexes (ACIC).....	17
II.3 les Hypothèses	18
II.3.1 Hypothèse 1	18
<i>Cumulant croisé</i>	19
<i>Divergence de Kullback-Leibler</i>	19
<i>Information mutuelle</i>	19
II.3.2 Hypothèse 2	20
<i>L'entropie différentielle marginale et conjointe</i>	20
<i>Néguentropie conjointe</i>	21
<i>Kurtosis</i>	21
II.4 Entropie	22
II.5 circularité	22
II.6 Méthodes de séparation des signaux à valeurs complexes	23
II.6.1 Méthodes de séparation basées sur la non-circularité.....	23
II.6.2 Méthodes de séparation basées sur la non-gaussianité	23
II.6.3 Méthodes de séparation basées sur la non-circularité et la non-gaussianité	24
II.7 Décomposition en composantes indépendantes basée sur la minimisation des bornes de l'entropie [42]	26
II.7.1 Principe	26

II.7.2 Principe d'estimation de l'entropie	29
<i>Borne 1 de l'entropie</i>	29
<i>Borne 2 de l'entropie</i>	29
II.7.3 Estimation de l'entropie par la décomposition QR.....	30
<i>Absorption de Q</i>	31
<i>Expression explicite de R</i>	32
II.8 Conclusion	33

Chapitre III : Applications et discussions.

III.1 Introduction	34
III.2 Position du problème	34
III.2.1 Principe	35
III.2.2 Nature du mélange.....	36
<i>Mélange instantané</i>	36
<i>Mélange convolutif</i>	37
III.2.3 Ambiguïtés de séparation	38
<i>Ambiguïté de permutation</i>	38
<i>Ambiguïté d'échelle</i>	39
III.3 Analyse en composantes indépendantes par minimisation des bornes de l'entropie et décomposition en modes empiriques bivariée	40
III.3.1 Principe	40
III.3.2 Les critères d'évaluation.....	42
III.4 Résultats et discussions	44
III.5 conclusion	58
Conclusion générale	59

Liste des symboles

$x(t)$	Signal
$X(f)$	Transformée de Fourier d'un signal $x(t)$
$X(\tau, f)$	Transformée de Fourier à court terme
$\psi_{a,b}(t)$	Ondelette
s	Vecteur de N sources
\mathbf{x}	Vecteur de M mélanges observés
\mathbf{z}	Vecteur de sources estimées
A	Matrice de mélange
W	Matrice de séparation
θ	Angle de circularité
P	Matrice de permutation
D	Matrice d'échelle
H	Entropie
$H^{[borne,I]}$	Borne 1 de l'entropie
$H^{[borne,II]}$	Borne 2 de l'entropie
cum_q	Cumulant d'ordre q
p_u	Densité de probabilité
$\Sigma \mathbf{u}_g$	Est la matrice de covariance du vecteur \mathbf{u}_g
$J(\mathbf{u})$	La néguentropie
$I(\cdot)$	Information mutuelle
$det(\cdot)$	Déterminant
$(\cdot)^T$	Transpose
$(\cdot)^H$	Conjugué transposé
$ \cdot $	Module

Liste des abréviations

SAS	Séparation Aveugle des Sources.
TF	Transformée de Fourier.
TFCT	Transformée de Fourier à court terme.
TO	Transformée en Ondelettes.
FMI	Fonction de mode intrinsèque.
DME	Décomposition en Modes Empirique.
DMEB	Décomposition en Modes Empirique Bivariées.
DMEBIR	Décomposition en Modes Empiriques Invariantes en Rotation.
ACP	Analyse en Composantes Principales.
ACI	Analyse en Composante Indépendantes.
ACI-MBE	Analyse en Composantes Indépendantes par Minimisation des Bornes de l'Entropie.
SAR	Rapport signal à artefacts (Signal to Artefacts Ratio).
SIR	Rapport signal à interférences (Signal to Interference Ratio).
SDR	Rapport signal à distorsions (Signal to Distortions Ratio).
SNR	Rapport signal sur bruit (Signal to Noise Ratio).

Liste des Figures

Chapitre I : Décomposition en mode empirique bivariée

Figure I.1: Représentation des signaux : (a) signal stationnaire et (b) signal non-stationnaire.	4
Figure I.2: Représentation des signaux et la TF : (a) signal stationnaire	6
Figure I.3: La transformée de Fourier à fenêtre glissante.	7
Figure I.4: La différence position d'une ondelette.	8
Figure I.5: Un exemple simple de décomposition en mode empirique (EMD) d'un signal à deux composantes.	11
Figure I.6: Principe des extensions bivariées.	13

Chapitre II: Méthodes de Résolution du Problème de la SAS

Figure II.1: Le but d'ACI.	17
--	----

Chapitre III: Applications et Discussions

Figure III.1: Configuration générale de la séparation aveugle de sources.	35
Figure III.2: Modèle des mélanges convolutifs.	38
Figure III.3: Séparation aveugle de sources combinant la décomposition modale empirique bivariée (DMEB) et l'analyse en composantes indépendantes complexe par minimisation des bornes de l'entropie (ACI-MBE).	42
Figure III.4: Exemple d'illustration de la séparation aveugle de mélanges convolutifs de deux signaux de parole par DMEB combinée avec ACI-MBE.	47
Figure III.5: Parties réelles et imaginaires de la transformée de Fourier des trames extraites du mélange et leurs FMI correspondantes.	49
Figure III.6: Estimation des trames des sources 1 et 2 dans le domaine fréquentiel.	50
Figure III.7: Sources estimées et leurs spectrogrammes.	52
Figure III.8: Configuration spatiale: localisation des sources et des capteurs dans la pièce(x, y et z en mètre).	53
Figure III.9: Représentation des sources estimées.	56

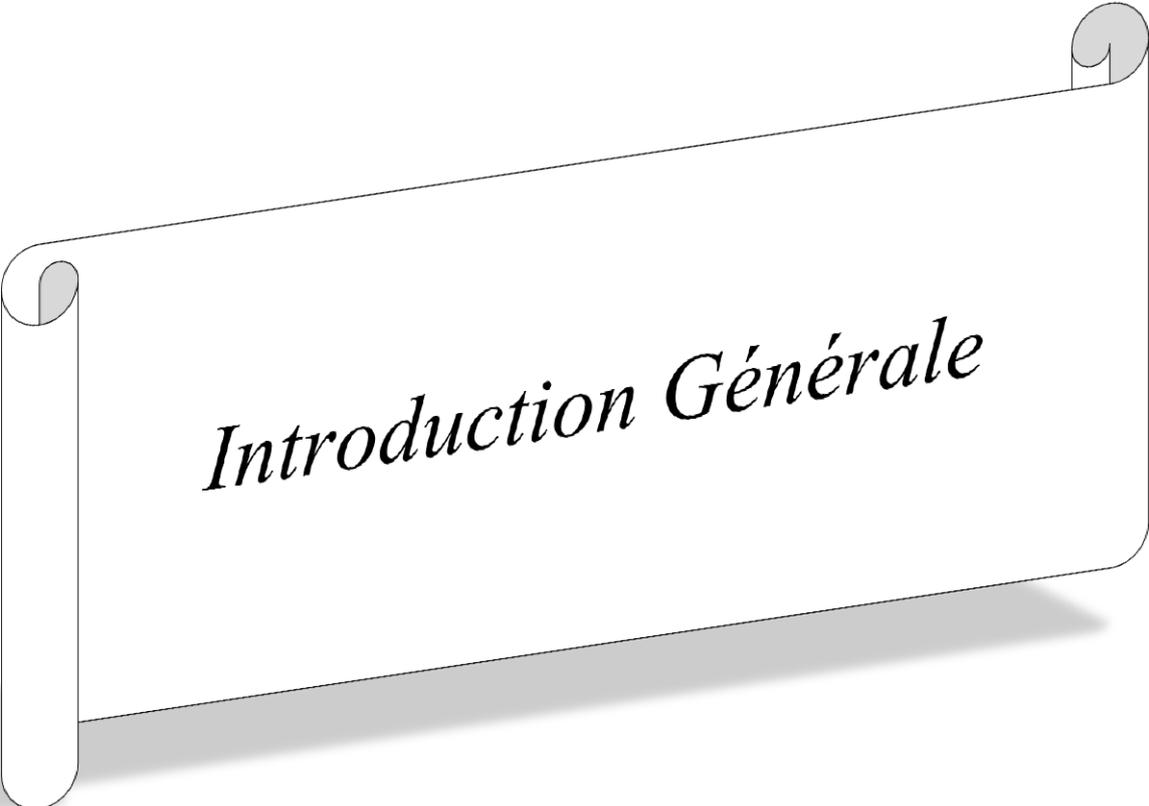
Liste des tableaux

Chapitre I : Décomposition en mode empirique bivariée

Tableau I. 1: Comparaison EMD avec autres méthodes..... 12

Chapitre III: Applications et Discussions

Tableau III. 1: Résumé les performances de la méthode de résolution de problème de séparation aveugle base sur ACI-MBE combiné avec le DMEB en comparaison avec celle base sur l'ACIF.....58



Introduction Générale

Introduction générale

La discipline du traitement de signal se distingue par la nature de données à traiter dans ce cadre : *signal*. Le signal est le support de l'information et le moyen de communication entre les hommes.

La séparation aveugle de sources (SAS) est un sujet de recherche son apparition à la fin des années 1980, Le mot « Aveugle » signifie que le signal source est inconnu (non observé) et que, soit les caractéristiques du système hybride ne sont pas connues à l'avance, soit qu'il n'y a qu'une petite quantité d'information a priori sur le signal source (comme la non Gaussienne et l'indépendance statistique).

La SAS est devenue un sujet important de la recherche et de développement dans de nombreux domaines , notamment : séparation de signal parole [1] , communications et traitement du signal [2] , traitement et reconnaissance d'image [3,4] , traitement de l'information géologique spatiale [5,6] , traitement du signal biomédicale [7,8] , analyse de documents texte [9] , les sciences de la Terre , l'extraction des signaux de l'Electrocardiogramme (ECG)... etc.

Le problème de la SAS peut être formulé dans le domaine temporel ou dans le domaine fréquentiel. Les méthodes temporelles de SAS sont complexes en termes de calcul. Les méthodes fréquentielles de SAS sont plus efficaces en termes de complexité de calcul. De plus, le mélange convolutif peut être transformé en un mélange instantané dans le domaine fréquentiel.

La décomposition en modes empiriques appelée DME est une nouvelle technique utilisée pour la décomposition des signaux non linéaires et non stationnaires.

La DME conventionnelle se limite à l'analyse des signaux scalaires. Ainsi, cette décomposition n'est pas directement applicable aux signaux à valeurs complexes ou bivariés. La décomposition en modes empiriques bivariée (DMEB) [10] est une variante de la DME complexe proposées pour décomposer des signaux à valeurs complexes. Il va l'avantage de donner le même nombre de FMI pour la partie réelle et la partie imaginaire des signaux à valeurs complexes.

Plusieurs algorithmes ont été proposés pour résoudre le problème de SAS dans le cas des signaux à valeurs complexes [11-13]. les algorithmes ACI complexes exploitent deux caractéristiques du signal qui sont la non-gaussianité et la non-circularité. Un nouvel

algorithme basé sur l'ACI par minimisation de la borne de l'entropie (ACI-MBE) a été introduit. La technique utilise la projection du gradient conjugué et des estimations précises de l'entropie et exploite efficacement à la fois la non-circularité et la non-gaussianité pour résoudre le problème de la SAS en minimisant l'information mutuelle [14]. Le principal avantage de la méthode (ACI-MBE) est qu'elle ne nécessite aucune connaissance préalable de la distribution des sources.

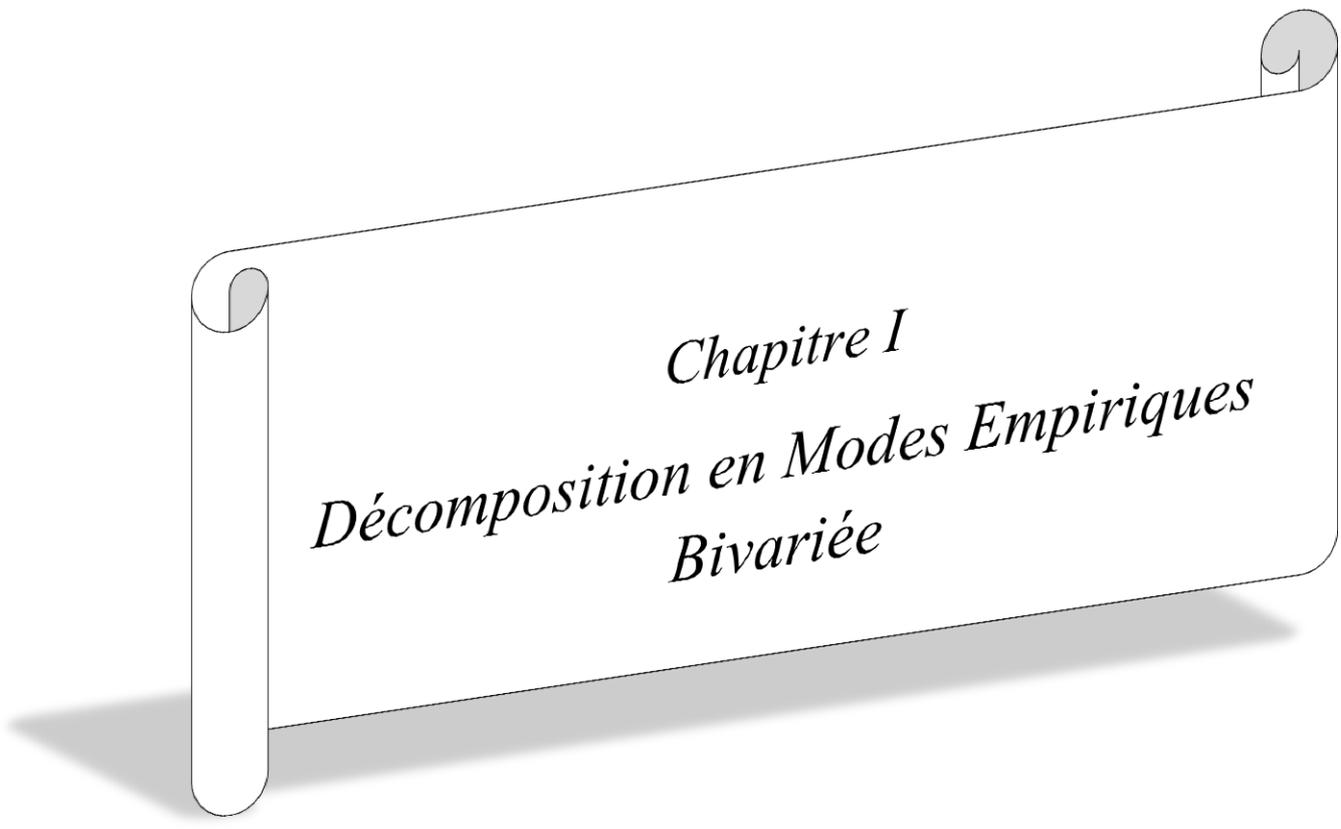
Dans ce mémoire, nous nous sommes intéressés à la résolution du problème de la SAS dans le domaine fréquentiel. Notre application porte sur le mélange convolutif des signaux audio. Notre contribution consiste à combiner l'algorithme de la DMEB qui offre le même niveau de décomposition de la partie réelle et la partie imaginaire du signal à décomposer avec l'algorithme ACI-MBE qui exploite à la fois la non-gaussianité et la non-circularité du signal. Le mélange convolutif est d'abord décomposé dans le domaine fréquentiel en un ensemble des FMIs en utilisant l'algorithme DMEB. Ensuite l'algorithme de l'ACI-MBE est appliqué pour l'extraction des sources indépendantes. Pour résoudre le problème de permutation nous avons utilisé l'algorithme récursif proposé par [15] qui consiste à utiliser la solution finale de la matrice de séparation dans la bande de fréquence précédente comme valeur initiale d'itération dans la bande de fréquence courante.

La mémoire est organisée en trois chapitres.

- Dans le premier chapitre , nous présentons les méthodes conventionnelles d'analyse des signaux comme TF, TFCT et TO, avec une étude de les nouvelles méthodes: dans le demain temporelle l'EMD et dans le demain fréquentielle le DMEB.

- Dans le deuxième chapitre , nous présente quelques méthodes de séparation de sources ACP, ACI et ACIC nous allons présenter les principales idées utilisées pour résoudre ce problème aussi le principe de la décomposition en composante indépendantes basée sur la minimisation des bornes de l'entropie.

- Dans le dernier chapitre , nous présentons le problème de séparation de sources en expliquant son principe , et la représentation des résultats de la simulation du combiné de la DMEB et ACI-MBE.



Chapitre I
Décomposition en Modes Empiriques
Bivariée

I.1 Introduction

Un signal est la représentation physique de l'information. Le signal peut être traité dans le domaine temporel ou fréquentiel.

Les principales méthodes utilisées dans l'analyse des signaux sont les méthodes conventionnelles telles que : la transformée de Fourier (TF), La transformée de Fourier à fenêtre glissante (Transformée de Fourier à court terme TFCT) et la transformée en ondelettes(TO).

Dans ce chapitre, nous présentons le principe des méthodes conventionnelles. Ainsi que les nouvelles méthodes introduites dans la littérature tel que : la décomposition en modes empiriques (DME) et la décomposition en modes empiriques bivariée (DMEB) qui présente une extension de la DME pour l'analyse des signaux à valeurs complexes.

I.2 Définition

I.2.1 Signal stationnaire et non-stationnaire

Un signal est dit stationnaire si ses composantes de fréquences ne changent pas avec le temps. Par contre , un signal non stationnaire est celui dont les composantes de fréquences changent avec le temps (le contenu de fréquences change d'un intervalle à un autre).

Figure(I.1) représente le signal stationnaire et le signal non stationnaire .

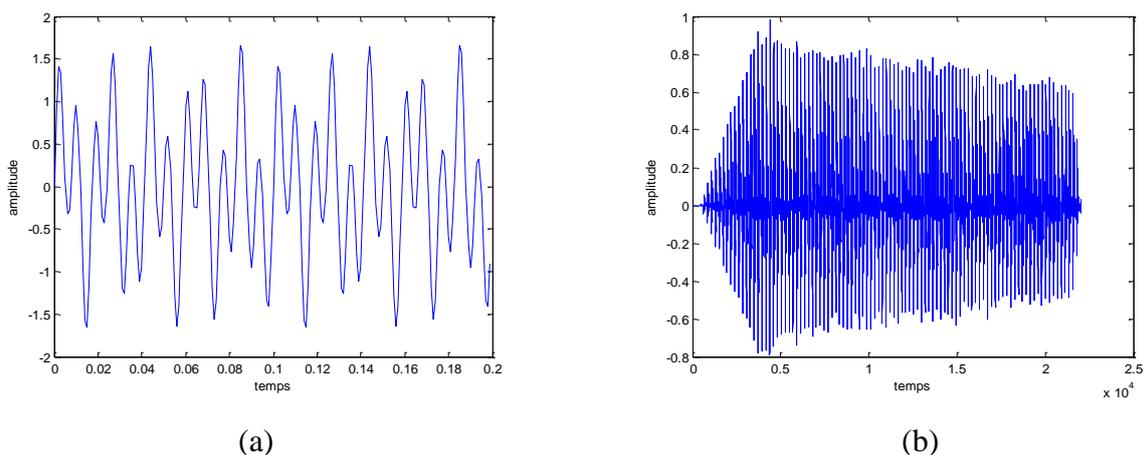


Figure I. 1: Représentation des signaux : (a) signal stationnaire et (b) signal non-stationnaire.

I.2.2 La corrélation

Soit x et y deux signaux de l'espace \mathcal{E} , leur fonction de corrélation est définie par la relation suivante :

$$\forall t \in \mathbf{R} \quad (x \odot y) = \int x(\tau) y(\tau + t) dt$$

Où : τ est le retard.

I.2.3 La décorrélation

La décorrélation est un terme général désignant tout processus utilisé pour réduire l'autocorrélation d'un signal.

I.2.4 L'autocorrélation

Lorsque x est égale à y , on parle de la fonction d'auto corrélation qui définit par la relation suivante :

$$\forall t \in \mathbf{R} \quad (x \odot x) = \int x(\tau) x(\tau + t) dt$$

I.2.5 La covariance

La covariance est une extension de la notion variance et la corrélation est une forme normalisée de la variance [16].

Soit X et Y deux variables aléatoires, la covariance est définie comme suit :

$$cov(X, Y) = E[(X - \mu_X)(Y - \mu_Y)]$$

I.3 Méthodes d'analyse des signaux non stationnaires

I.3.1 Transformée de Fourier

La plus célèbre et la plus ancienne des transformations est la TF. Lors de cette transformation, le signal est décomposé sur un ensemble de fonctions de base qui sont le cosinus, le sinus ou l'exponentielle imaginaire [17,18].

La transformée de Fourier d'un signal $x(t)$ est définie par :

$$X(f) = TF[x(t)] = \int_{-\infty}^{+\infty} x(t) e^{-j2\pi ft} dt \quad (\text{I.1})$$

Et La figure I.2 représenté la transformée de Fourier d'un signal stationnaire et un signal non stationnaire.

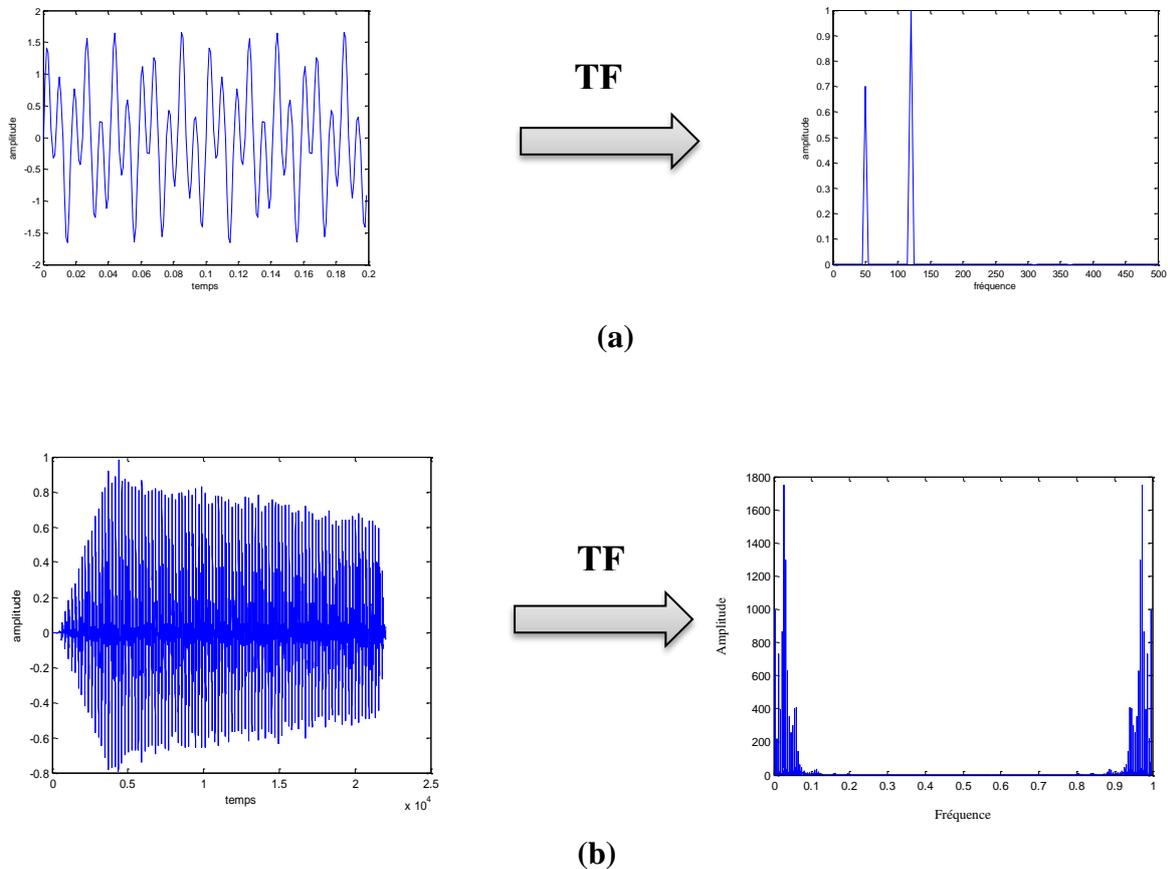


Figure I. 2: Représentation des signaux et la TF : (a) signal stationnaire

$$(x = 0.7 * \sin(2 * \pi * 50 * t) + 1 * \sin(2 * \pi * 120 * t)),$$

(b) signal non-stationnaire.

Malgré son immense succès, cette technique présente des inconvénients majeurs : Manque de localisation temporelle. En effet, l'analyse de Fourier permet de connaître les différentes fréquences existant dans un signal, c'est à dire son spectre, mais ne permet pas de savoir à quels instants ces fréquences ont été émises, donc la TF n'est pas l'outil adapté à l'étude de signaux non stationnaire.

I.3.2 Transformée de Fourier à fenêtre glissante

Il s'agit de la TF à fenêtre glissante (Transformée de Fourier à court terme, TFCT). Cette méthode, pouvant être adaptée aux signaux non-stationnaires, est très proche de l'analyse spectrale. On définit une fenêtre qui sera utilisée comme masque sur le signal et dans laquelle on considère le signal comme localement stationnaire, puis on décale cette fenêtre le long du signal afin de l'analyser entièrement [17,18]. La TFCT est exprimée par :

$$X(\tau, f) = \int_{-\infty}^{+\infty} x(t)g^*(t - \tau)e^{-j2\pi ft} dt \quad (\text{I.2})$$

$x(t)$ est le signal lui-même, $g(t)$ est la fonction fenêtre et g^* son complexe conjugué, et f joue le rôle d'une fréquence localisée autour de l'abscisse τ du signal temporel.

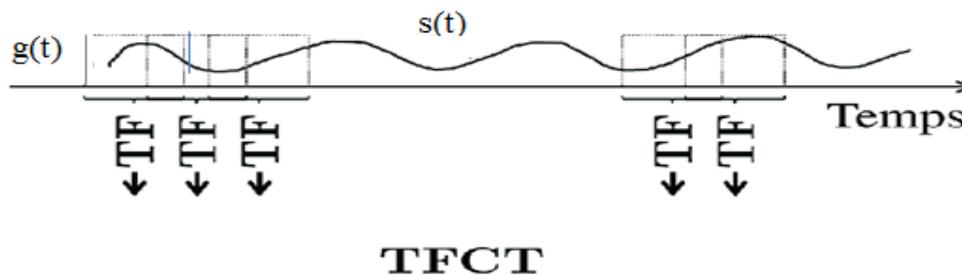


Figure I. 3: Transformée de Fourier à fenêtre glissante.

D'après (Figure I.3), on calcule un nouveau coefficient de la TFCT pour chaque valeur de f et de τ . On constate que la fenêtre g est indépendante de l'abscisse τ ce qui signifie que l'enveloppe de la fenêtre glissante sera constante: on aura donc une résolution fixe sur toute la durée du signal.

Ainsi, l'étude d'un signal avec la TFCT permet d'obtenir à la fois une information sur le temps et sur la fréquence, mais la résolution d'analyse est fixée par le choix de la taille de l'enveloppe :

- Si la fenêtre est trop petite, les basses fréquences n'y seront pas contenues.
- Si la fenêtre est trop, l'information sur les hautes fréquences est noyée dans l'information concernant la totalité de l'intervalle contenu dans la fenêtre.

Donc la taille fixe de la fenêtre est un gros inconvénient. L'outil idéal serait une fenêtre qui s'adapte aux variations de fréquence dans le signal à analyser. Cet outil existe, il s'agit de l'analyse en ondelettes.

I.4 Transformée en Ondelette

L'analyse en ondelette représente la prochaine étape logique: une technique de fenêtrage avec des régions de taille variable. L'analyse par ondelettes permet l'utilisation de longs intervalles de temps où nous voulons plus précis des informations de basse fréquence, et des régions plus courtes où nous voulons des informations de haute fréquence[19].

$$C(a, b) = \int_{-\infty}^{+\infty} x(t)\psi_{a,b}^*(t)dt = 0 \quad (\text{I.3})$$

Où $\psi_{a,b}^*$ le complexe conjuguée de $\psi_{a,b}$ qui présente les ondelettes filles données par l'équation suivante :

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}}\psi\left(\frac{t-b}{a}\right) \quad (\text{I.4})$$

a : facteur d'échelle pour la dilatation ψ .

b : le coefficient de translation.

La figure I.4 illustre visuellement une analyse par ondelette, d'un signal quelconque.

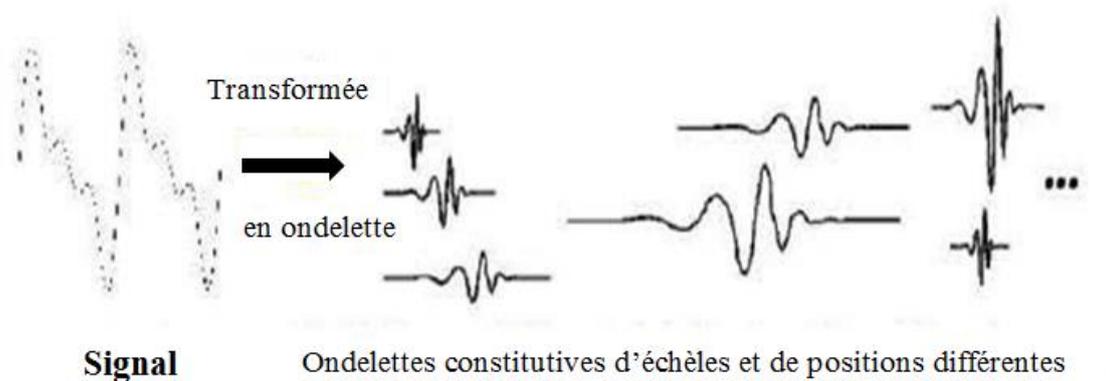


Figure I. 4: Différence position d'une ondelette.

La transformée en ondelette (TO) est un outil mathématique qui décompose un signal en fréquences en conservant une localisation temporelle. Le signal de départ est projeté sur un ensemble de fonctions de base qui varient en fréquence et en temps. Ces fonctions de base s'adaptent aux fréquences du signal à analyser.

I.5 Décomposition modale empirique (DME)

Contrairement aux représentations précédentes, la décomposition DME est locale, itérative et entièrement pilotée par les données (Approche basée sur les données) intrinsèque au signal. Le DME décompose d'une façon adaptative un signal en une somme de composantes oscillantes par l'utilisation d'un processus de tamisage. Chaque composante est une forme d'onde de moyenne nulle, modulée en amplitude et en fréquence nommée FMIs (Fonction de mode intrinsèque) traduite par la fonction modale intrinsèque (Processus de tamisage) (figure I.5). L'extraction des FMIs est non linéaire, mais leur recombinaison pour la reconstruction exacte du signal est linéaire. Le DME a montré ses capacités comme outil d'analyse adaptative multi-échelles des signaux non-stationnaires [11].

I.5.1 Principe de la décomposition

Le signal $x(t)$ peut alors s'écrire :

$$\mathbf{x}(t) = \sum_{j=1}^N \mathbf{FMI}_j + r_N(t) \quad (\text{I.5})$$

Où $\mathbf{FMI}_j(t)$ est la $j^{\text{ième}}$ oscillation, $r_N(t)$ est le résidu de la décomposition et N est le nombre de FMIs. Même si la notion de FMIs repose plus sur une intuition que sur une définition très rigoureuse, cette fonction doit respecter certains critères comme précisé ci-dessous.

Une FMI (ou mode empirique) est une fonction telle que :

$$\mathbf{FMI}: \begin{cases} \mathbf{R} \rightarrow \mathbf{R} \\ t \rightarrow \mathbf{FMI}_j(t) \end{cases} \quad (\text{I.6})$$

Qui vérifie les conditions suivantes :

a) De moyenne nulle.

b) Les nombres d'extrema et de passages à zéro diffèrent au plus de un (en d'autres termes, cela signifie qu'entre un minimum et un maximum successifs, une FMI passe par zéro).

Cette condition est nécessaire pour que la fréquence instantanée n'ait pas de fluctuations indésirables dues à l'asymétrie du signal.

Les deux conditions précédentes assurent l'unicité du mode oscillatoire de le FMI à chaque instant.

c) Une FMI suit une loi de modulation en amplitude et en fréquence (comportement oscillant) naturellement de type mono-composante.

I.5.2 Tamisage (Processus de tamisage)

Les différentes étapes du processus de tamisage sont exprimées comme suit :

Étape 1 : initialisation $j \leftarrow 1$ ($j^{\text{ième}}$ FMI), $r_j(t) \leftarrow x(t)$ (résidu).

Étape 2 : extraction de la $j^{\text{ième}}$ FMI :

(a) Identification de tous les extrema de $r_j(t)$.

(b) Interpolation entre les minima (resp. maxima) de $r_j(t)$ conduisant à une enveloppe $e_{min}(t)$ (resp. $e_{max}(t)$).

(c) Calcul de l'enveloppe moyenne $\mu(t) = (e_{min}(t) + e_{max}(t))/2$

(d) Extraction du détail $d(t) = r_j(t) - \mu(t)$

(e) Itération sur le détail $d(t)$ en répétant les étapes de (a) à (d) jusqu'à ce qu'un critère d'arrêt basé sur la déviation standard entre deux détails consécutifs soit inférieur à un seuil prédéfini conduisant à FMI_j

Étape 3 : mise à jour du résidu $\leftarrow j + 1$, $r_j(t) \leftarrow r_{j-1}(t) - FMI_j(t)$.

Étape 4 : itération sur le résidu en répétant les étapes 2 et 3 jusqu'à ce que le nombre d'extrema de $r_j(t)$ soit inférieur à 2.

Pour mieux illustré l'algorithme de DME, soit un signal à décomposer défini par la figure I.5. La figure (I.5) illustre les différentes étapes du processus de tamisage. La décomposition, réalisée sans aucune connaissance préalable des caractéristiques du signal, permet d'extraire correctement les contributions ainsi que la tendance (résidu) du signal.

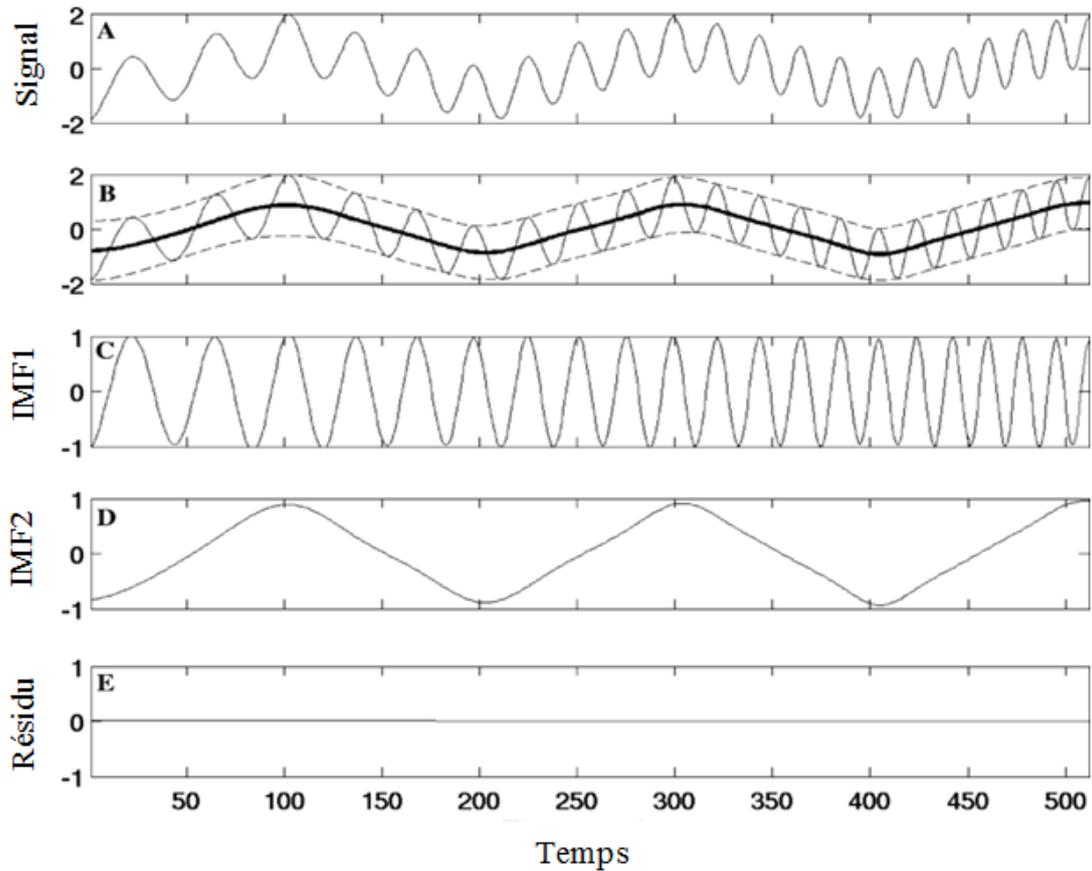


Figure I. 5: Exemple simple de décomposition en mode empirique (EMD) d'un signal à deux composantes.

A : Le signal analysé composé d'un signal triangulaire et signal sinusoïdal. B : Enveloppes supérieure et inférieure (lignes pointillées) du signal original et sa moyenne point par point des enveloppes (ligne épaisse). C-E : Trois FMI du signal. [20]

Le tableau suivante présenté une comparaison entre les méthodes : TF, TFCT , TO et DME .

	Fourier	TFCT	Ondelette	DME
Base	Non-adaptative	Non-adaptative	Non-adaptative	Auto-Adaptative
Non stationnaire	Non	Non	Non	Oui
Extraction de fonctionnalités	Non	Discrète: Non Continue: Oui	Discrète: Non Continue: Oui	Oui

Tableau I. 1: Comparaison EMD avec autres méthodes [55].

I.6 Décomposition en modes empiriques bivariée

I.6.1 Principe

La décomposition en modes empiriques bivariée est extension de la méthode DME pour les signaux complexe.

Plusieurs méthodes de DMEB ont été présentées. L'algorithme de décomposition en modes empiriques bivariée (DMEB) [10] utilise plusieurs projections (univariées) d'un signal complexe (bivarié) pour déterminer la moyenne locale.

Contrairement à la DME-RI [21], les multiples directions de projection de la DMEB peuvent échantillonner le plan complexe (bivarié) améliorant ainsi la précision et le rendant beaucoup mieux adapté pour les signaux ayant une dynamique de changement rapide que la DME-IR.

Dans ce travail, nous nous sommes intéressés à un algorithme qui donne des valeurs plus précises de la moyenne locale est le DME bivarié (DMED) introduit par Rilling et al. en 2007, [10] où les enveloppes correspondant aux multiples directions dans le plan complexe sont générées, puis moyennées pour obtenir la moyenne locale. L'ensemble des vecteurs de direction pour les projections sont choisis en des points équidistants le long du cercle unité.

I.6.2 Une enveloppe en 3 dimensions

Techniquement, les extensions bivariées reprennent le principe récursif de la DME mais avec de nouveaux opérateurs de tamisage calqués sur l'original. Ainsi, là où classiquement on soustrait au signal la moyenne des enveloppes supérieures et inférieures, les nouveaux opérateurs soustraient au signal l'« axe central » de son « enveloppe », qui est maintenant un tube tridimensionnel qui enveloppe le signal. En pratique, cet axe est en fait calculé à partir de ce qu'on pourrait appeler des « armatures latérales » du tube de la figure I.6 (b). Chacune de ces armatures est associée à une direction particulière et forme une ligne de crête de l'enveloppe dans cette direction. Ainsi, l'armature associée à la direction « vers le haut » pourrait être définie à tout instant comme le point de la section du tube dont l'altitude est maximale. Cependant, l'enveloppe n'étant pas connue a priori, les armatures sont calculées différemment. Dans l'esprit de la Figure I.6, on peut considérer que le tube enveloppe devrait être en tout point tangent au signal, ce qui implique que chacune des armatures latérales interpole un certain ensemble de points du signal.

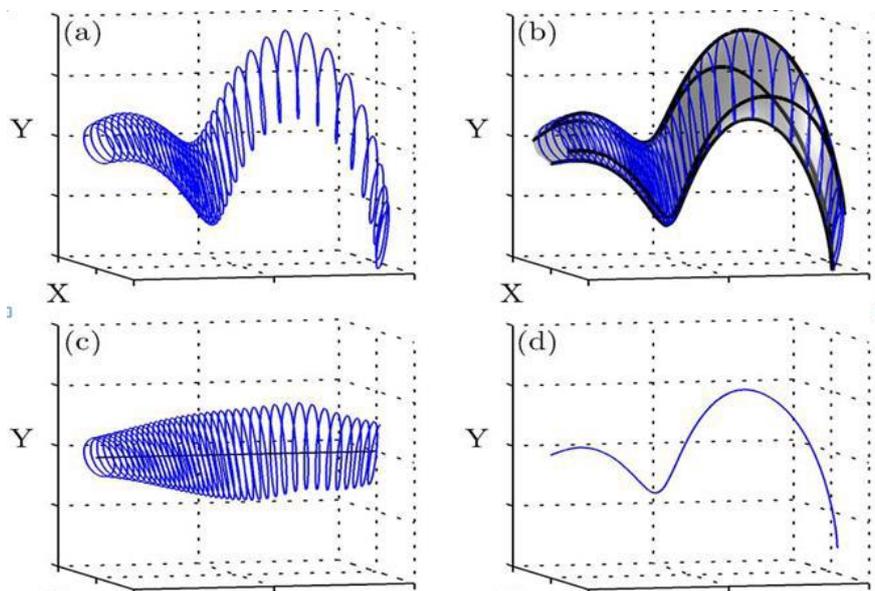


Figure I. 6: Principe des extensions bivariées.

(a) Signal rotatif. (b) Signal inclus dans son enveloppe 3D : lignes noires et épaisses représentent les courbes d'enveloppes utilisées pour calculer la moyenne. (c) Composante à rotation rapide. (d) Composante à rotation plus lente correspondant à la moyenne du tube dans (b) [10].

I.6.3 Algorithme

Le processus de la DMEB nécessite de projeter un signal multiple sur un ensemble de directions puis d'appliquer le processus de tamisage de la DME standard aux composantes projetées. Le processus fondamental de la DMEB est résumé comme suit:

1. Initialiser le résidu $k \leftarrow 1$ (k^{th} FMI); $r_k(t) \leftarrow x(t)$

2. Extraire la $k^{ième}$ FMI :

2.1. Estimation des courbes d'enveloppe

2.1.1. Projeter le signal à valeur bivariée $r_k(t)$ sur la direction φ_k où $\varphi_k = \frac{2k\pi}{K}$ for $k = 1..K$

$$P_{\varphi_k}(t) = r e(e^{-i\varphi_k} r_k(t))$$

2.1.2. Extraire l'emplacement $\{t_j^k\}$ du maxima de $p_{\varphi_k}(t)$

2.1.3. Interpoler l'ensemble $\{(t_j^k, r_k(t_j^k))\}$ Pour obtenir la courbe d'enveloppe dans la direction φ_k

2.2. Calculer la moyenne de toutes les courbes d'enveloppe $\mu(t) = \frac{1}{K} \sum_k e_{\varphi_k}(t)$

2.3. Soustraire la moyenne pour obtenir $d(t) = r_k(t) - \mu(t)$

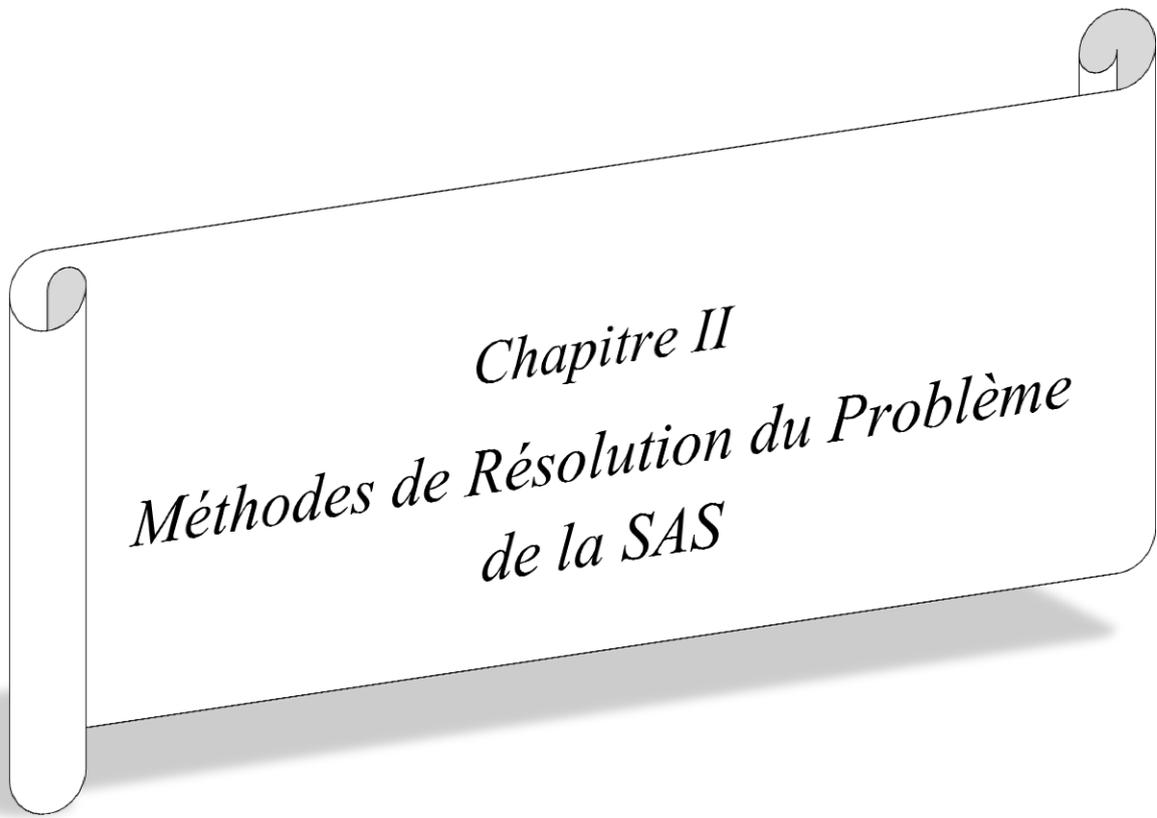
2.4. Itérer sur le détail $d(t)$ En répétant les étapes 2.1 à 2.3 jusqu'à ce que le critère d'arrêt basé sur l'écart-type entre deux détails consécutifs soit inférieur à un seuil prédéfini conduisant à FMI_k

3. Mettre à jour le résidu $k \leftarrow k + 1$; $r_k(t) \leftarrow r_{k-1}(t) - FMI_k(t)$

4. Itérer sur le résidu en répétant les étapes 2 et 3 jusqu'à ce que le nombre d'extrema de $r_k(t)$ soit inférieur à 2.

I.7 Conclusion

Dans ce chapitre, nous avons étudié les principales méthodes utilisées dans l'analyse des signaux. Tel que la transformée de Fourier (TF), la transformée de Fourier à Court Terme (TFCT), la Transformée en ondelettes (TO). La décomposition en modes empiriques (DME) qui décompose le signal en un nombre fini de composantes ou oscillations FMIs extraites des données, et la décomposition en modes empiriques bivariée (DMEB). La DMEB est un outil puissante pour le traitement des signaux complexe, où décomposer les parties réelles et imaginaires et son avantage est donne le même nombre de FMIs pour la partie réelle et la partie imaginaire des signaux à valeurs complexes.



Chapitre II
Méthodes de Résolution du Problème
de la SAS

II.1 Introduction

La séparation aveugle de sources possède de nombreuses applications, notamment dans les domaines du traitement du signal de parole. Dans ce domaine, la séparation aveugle de sources concerne par exemple la séparation d'extraits ou le rehaussement de la parole pour la téléphonie mobile ou pour l'élaboration de prothèses auditives.

Dans ce chapitre, nous allons présenter des méthodes de résolution du problème de la séparation aveugle de sources. Nous détailleront les méthodes classiques de résolution telle que l'analyse en composante principale et l'analyse en composantes indépendantes.

Aussi l'analyse en composantes indépendantes par minimisation des bornes de l'entropie (ACI-MBE) qui exploite conjointement la non-gaussianité et la non-circularité des signaux.

II.2 Méthodes classiques de résolution de problème de SAS

II.2.1 Analyse en composantes principales (ACP)

L'Analyse en composantes principales, appelée aussi «analyse géométrique des données » ou « analyse des corrélations », en abrégé ACP est un outil extrêmement puissant de synthèse de l'information.

L'ACP est une méthode descriptive elle ne s'appuie pas sur un modèle probabiliste. Cette technique utilise comme principe une transformation des variables initiales en de nouvelles variables non corrélées. Ces nouvelles variables sont appelées les Composantes Principales. Chaque composante principale est une combinaison linéaire des variables initiales

Soit le vecteur $X = [X_1, \dots, X_M]^T$, de moyenne μ et de matrice de covariance C_X . Le but de l'ACP est de déterminer des nouvelles variables Y_1, \dots, Y_N , combinaisons linéaires des variables initiales, tout en maximisant la variance. Les Y_i sont appelées des composantes principales et elles sont disposées dans l'ordre décroissant de la variance.

Chaque composante Y_i est une combinaison linéaire des X_i telle que :

$$Y_i = a_{1i}X_1 + a_{2i}X_2 + \dots + a_{iM}X_M \quad (\text{II.1})$$

$A_i = [a_{1i}, \dots, a_{iM}]^T$ est un vecteur de constantes.

La variance de Y_i s'écrit comme :

$$\begin{aligned}\text{Var}(Y_i) &= \text{Var}(A_i^T X) \\ &= A_i^T \text{Var}(X) A_i \\ &= A_i^T C_X A_i\end{aligned}$$

La première composante principale Y_i est choisie de telle sorte que cette dernière ait la plus grande variance possible, cette contrainte revient à résoudre le problème d'optimisation suivant :

$$\begin{array}{ll}\text{Maximiser} & A_i^T C_X A_i \\ \text{Sous la contrainte} & A_i^T A_i = 1\end{array}$$

II.2.2 Analyse en composantes indépendantes (ACI)

L'analyse en composantes indépendantes est un prolongement de l'analyse en composantes principales, mais dans laquelle la décorrélation des observations est remplacée par une hypothèse plus forte qui est l'indépendance des sources.

Pour cette estimation, la méthode d'analyse en composantes indépendantes (ACI) a été proposée dans [22]. Dans le cadre de l'ACI, les sources s_1, s_2, \dots, s_N sont supposées être des variables aléatoires indépendantes avec une fonction de densité de probabilité conjointe p_s telle que :

$$p_s(s_1, s_2, \dots, s_N) = \prod_{n=1}^N p_{s_n}(s_n) \quad (\text{II.2})$$

où p_{s_n} est la fonction de densité de probabilité marginale de s_n .

La séparation des sources nécessite un moyen de mesurer l'indépendance, ce qui n'est pas trivial car l'indépendance statistique est vérifiée par la fonction de densité de probabilité, généralement inconnue et difficile à estimer. Dans ce contexte, les méthodes d'ACI ont alors l'intention de trouver une matrice de séparation, appelée aussi matrice de dé mixage, W telle que les sources estimées :

$$Y = W X \quad (\text{II.3})$$

Soient aussi indépendantes que possible. En effet, il est montré dans [23] que l'indépendance conduit à une matrice W qui satisfait :

$$WA = PD \quad (\text{II.4})$$

Où P est une matrice de permutation et D est une matrice diagonale si au plus une des sources est générée à partir d'une distribution gaussienne. Autrement dit, maximiser l'indépendance entre les sources estimées conduit à une estimation de S à une permutation et un facteur d'échelle près.

La représentation de but d'ACI dans la figure II.1.

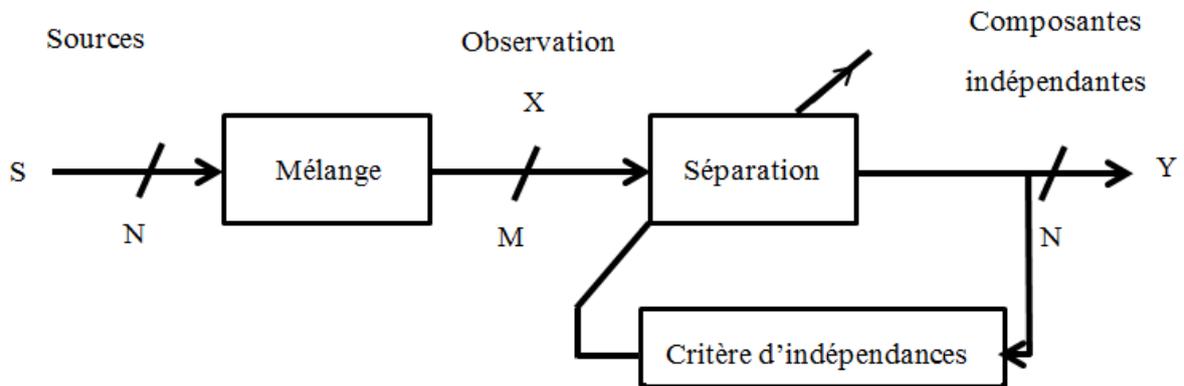


Figure II. 1: Le but d'ACI.

II.2.3 Analyse en composantes indépendantes complexes (ACIC)

L'analyse en composantes indépendantes à valeurs complexes est largement utilisée dans un certain nombre d'applications telles que les communications, les radars et le traitement des signaux biomédicaux. En général, on peut obtenir une ACI complexe (ACIC) en exploitant les deux types suivants de propriétés du signal: la non-gaussianité ou la non-circularité. Mais, tous les algorithmes d'ACIC existants exploitent seulement un des types.

Le problème d'ACI dans le domaine complexe suppose que sources sont combinées linéairement à travers une matrice de mélange complexe A et sont disponibles via le vecteur X observé :

$$\mathbf{X} = \mathbf{A} \mathbf{S} \quad (\text{II.5})$$

Les sources $s(t) = [s_1(t), \dots, s_N(t)]^T$ sont supposées non-gaussiennes et mutuellement indépendantes, avec des variances unitaires et des moyennes nulles. En d'autres termes, la matrice de covariance $E[ss^H] = I$ où H dénote l'opérateur transposé complexe conjugué. Cependant, aucune hypothèse n'est faite sur la circularité des sources. Dans les méthodes ACI rapide standard [24], les sources sont considérées circulaires, avec une pseudo-covariance, $E[ss^T] = 0$. Il est courant d'orthogonaliser initialement les données par une transformation V de blanchiment qui est présente un décorrélation suivie par un changement d'échelle.

Telle que :

$$\mathbf{x} = \mathbf{V} \mathbf{A} \mathbf{s} \quad (\text{II.6})$$

Le vecteur sources estimées $\mathbf{z} = \mathbf{W}^H \mathbf{x}$ est avec les composantes z_i données par :

$$z_i = \mathbf{w}_i^H \mathbf{x}, \quad i = 1, \dots, N \quad (\text{II.7})$$

Où w_i représente la $i^{\text{ème}}$ colonne de \mathbf{W} . La solution optimale une seule composante complexe non nulle avec une amplitude unitaire et une phase inconnue :

$$\mathbf{u}_i = [\mathbf{0}, \dots, e^{j\varphi}, \mathbf{0}, \dots, \mathbf{0}]^T \quad (\text{II.8})$$

Où est le $j^{\text{ème}}$ élément de la colonne du vecteur.

II.3 les Hypothèses

Les hypothèses suivantes sont habituellement requises, Dans le but de simplifier et permettre de résoudre le problème de la séparation aveugle de sources.

II.3.1 Hypothèse 1

Toutes les procédures de séparation aveugle de sources supposent que, statistiquement, les sources sont mutuellement indépendantes. (Par définition, deux variables aléatoires sont indépendantes lorsque leur densité de probabilité est égale au produit de leurs densités marginales). Différents critères de dépendance peuvent être trouvés dans la littérature à savoir :

a. Cumulant croisé

Soient $\Phi_u(v)$ et $\psi_u(v)$ la première et la deuxième fonctions caractéristiques d'une variable aléatoire u définies respectivement par $\Phi_u(v) = E[e^{iuv}]$ et $\psi_u(v) = \ln(\Phi_u(v))$. Les cumulants (d'ordre q) de la variable aléatoire u sont définis par

$$\text{cum}_q(u) = (-j)^q \left. \frac{d^q \psi_u(v)}{dv^q} \right|_{v=0} \quad (\text{II.9})$$

Les cumulants sont bien adaptés pour indiquer la dépendance entre les variables u_i , $i = 1, \dots, p$ du vecteur u . En effet, l'indépendance revient à avoir tous les cumulants croisés égaux à zéro.

En réalité, il est impossible d'utiliser les cumulants pour mesurer la dépendance dans le sens absolu, car cela demande d'inspecter une infinité de cumulants.

b. Divergence de Kullback-Leibler

La divergence de Kullback-Leibler est la mesure de distorsion entre deux fonctions de densité de probabilité $p_u(x)$ et $p_v(x)$, elle est donnée par :

$$\delta(p_u, p_v) = \int_{-\infty}^{+\infty} p_u(x) \log \frac{p_u(x)}{p_v(x)} dx \quad (\text{II.10})$$

La divergence est toujours positive, et égale à zéro si et seulement si $p_u(x) = p_v(x)$. Ainsi, la divergence de Kullback-Leibler mesure l'écart entre les deux lois de probabilité.

c. Information mutuelle

L'information mutuelle est une mesure de l'information que les membres d'un ensemble de variables aléatoires ont sur les autres variables aléatoires de l'ensemble, défini par l'équation suivante :

$$I(p_u) = \int p_u(v) \log \frac{p_u(v)}{\prod_i^k p_{u_i}(v_i)} dv \quad (\text{II.11})$$

Avec u le vecteur de composante de u_i ($i=1, \dots, \dots, k$).

L'information mutuelle est mesurée, la divergence de Kullback-Leibler entre $p_u(x)$ et $\prod_i^k p_{u_i}(v_i)$ c'est-à-dire $I(\mathbf{p}_u) = \mathbf{0}$.

II.3.2 Hypothèse 2

Parmi les sources, au plus une peut avoir une distribution gaussienne. Intuitivement, la distribution gaussienne est trop simple, car ses cumulants d'ordre supérieur à deux sont nuls. Dans les algorithmes qui utilisent la non-gaussianité, la fonction coût de l'algorithme sera optimisée de telle sorte que les signaux séparés soient aussi non-gaussiens que possible, ce qui les rend aussi indépendants que possible. Par conséquent, cette technique nécessite des méthodes pour mesurer la non-gaussianité des signaux après chaque itération. Les différentes mesures utilisées pour mesurer la non-gaussianité sont :

a. L'entropie différentielle marginale et conjointe

L'entropie différentielle conjointe H_u est la quantité d'information (scalaire) d'un vecteur aléatoire $u = (u_1, \dots, u_k)^T$ de densité de probabilité conjointe $P_u(u)$ définie par $H_u = - \int_{-\infty}^{+\infty} p_u(\xi) \ln[p_u(\xi)] d\xi$

Où $\xi = (\xi_1, \dots, \xi_k)^T$ est un vecteur de variables d'intégration muettes.

De la même manière, chacune des composantes u_i du vecteur, de densité de probabilité marginale $p_{u_i}(u_i)$, apporte une quantité d'information, quantifiée par l'entropie différentielle marginale $H(u_i)$ donnée par :

$$H_{u_i} = - \int_{-\infty}^{+\infty} p_{u_i}(\xi_i) \ln[p_{u_i}(\xi_i)] d\xi_i \quad (\text{II.12})$$

Soient u_g et u deux vecteurs aléatoires de distributions gaussiennes et quelconques.

L'entropie conjointe $H(u)$ vérifie l'inégalité :

$$H(u) < H(u_g) = \frac{1}{2} \ln \left\{ (2\pi e)^n \det \sum u_g \right\} \quad (\text{II.13})$$

Où $\sum u_g$ est la matrice de covariance du vecteur u_g .

La définition de l'entropie marginale et conjointe peut être utilisée pour définir une mesure de non-gaussianité d'un vecteur aléatoire de distribution quelconque par rapport à un vecteur de distribution gaussienne.

b. Néguentropie conjointe

La néguentropie est définie par :

$$J(\mathbf{u}) = H(\mathbf{u}_g) - H(\mathbf{u}) \quad (\text{II.14})$$

De la même manière, on définit la néguentropie marginale entre une variable aléatoire quelconque u_i et une gaussienne u_{g_i} par $J(u_i) = H(u_{g_i}) - H(u_i)$. La néguentropie est une information scalaire, positive et qui s'annule seulement si le vecteur aléatoire suit une distribution gaussienne. Dans le cas contraire, le vecteur aléatoire suit une distribution non gaussienne.

c. Kurtosis

Le kurtosis appelé aussi cumulants d'ordre 4 d'une variable aléatoire centrée ($X + Y - E[Y]$) est défini comme suit :

$$\mathit{kurt}(X) = E[X^4] - 3(E[X^2])^2 \quad (\text{II.15})$$

Pour simplifier encore plus la forme du kurtosis, on peut supposer que X a été normalisée pour avoir une variance unitaire. Le kurtosis s'écrit par :

$$\mathit{kurt}(X) = E[X^4] - 3 \quad (\text{II.16})$$

Le kurtosis vaut zéro pour une variable gaussienne et est non nul pour la grande majorité des variables aléatoires. Il est important de noter que le kurtosis peut être positif ou négatif. Les variables aléatoires avec un kurtosis négatif sont appelées sous-gaussiennes et celles avec un kurtosis positif sont appelées sur-gaussiennes. Une mesure de non-gaussianité est donnée par la valeur absolue du kurtosis. Le carré du kurtosis peut aussi être utilisé. Cette nouvelle mesure est nulle pour une variable gaussienne alors qu'elle est positive pour la plupart des variables non-gaussiennes.

II.4 Entropie

La notion de l'entropie a été introduite dans les années 50 par Shannon [25,26].

Soit X une variable aléatoire discrètes ayant une probabilité $p(x)$, $X \in x$ avec x un ensemble dénombrable. Alors, l'entropie de X , notée $H(X)$ est définie par :

$$H(X) = \sum_{x \in X} p(x) \log_2 \left(\frac{1}{p(x)} \right) \quad (\text{II.17})$$

Dans le cas continu, l'entropie s'exprime comme :

$$H(X) = \int p(x) \log_2 \left(\frac{1}{p(x)} \right) dx \quad (\text{II.18})$$

L'entropie d'une variable aléatoire est une mesure quantitative de l'incertitude, ou de la quantité d'information, associée aux valeurs prises par la variable aléatoire.

II.5 circularité

La notion de circularité et l'importance de cet attribut dans le traitement du signal ont été mises en évidence dans [27]. Ces concepts ont été étendus dans [28] aux vecteurs aléatoires et aux processus aléatoires complexes. La circularité concerne les statistiques d'un élément complexe d'un vecteur z , c'est-à-dire la relation entre sa partie réelle et sa partie imaginaire. Le degré de non circularité peut être quantifié par la mesure de circularité r définie comme l'amplitude du quotient de circularité donnée par :

$$\rho(z) = r e^{j\theta} = \frac{\tau_z^2}{\sigma_z^2} \quad (\text{II.19})$$

Où σ_z^2 et τ_z^2 sont respectivement la variance complexe standard formée par les éléments diagonaux des matrices de covariance et la pseudo-variance formée par les éléments diagonaux de la matrice de pseudo-covariance. Le degré de non circularité dans le signal complexe [29] est donné par:

$$r = |\rho(z)| = \frac{|\tau_z^2|}{\sigma_z^2} \quad (\text{II.20})$$

Où θ est l'angle de circularité donné par :

$$\theta = \arg(\rho(\mathbf{z})) \quad (\text{II.21})$$

L'angle θ indique l'orientation de la distribution. Pour un signal purement circulaire, $r = 0$, et θ ne fournit pas d'informations supplémentaires sur la distribution. D'autres mesures de non-circularité sont également définies et peuvent être utilisées. Les mesures proposées dans [30] sont bornées entre 0 et 1. Une mesure similaire donnée par $1-r$ a été définie dans [31], le test GLRT (circularity generalized likelihood ratio test) a été aussi proposé. Ce test considère les hypothèses suivantes :

$$\begin{cases} \text{pcov}(\mathbf{x}) = \mathbf{0}, \text{ le vecteur est circulaire} \\ \text{pcov}(\mathbf{x}) \neq \mathbf{0}, \text{ le vecteur est non circulaire} \end{cases} \quad (\text{II.22})$$

Où pcov est la matrice pseudo-covariance symétrique complexe du vecteur \mathbf{x} .

II.6 Méthodes de séparation des signaux à valeurs complexes

Dans de nombreuses applications pratiques telles que le traitement des signaux audio dans le domaine fréquentiel, les signaux sont complexes et, par conséquent, nous avons besoin d'algorithmes pour résoudre le problème de la SAS à valeurs complexes.

II.6.1 Méthodes de séparation basées sur la non-circularité

L'algorithme de transformation non corrélative généralisée [32] est une généralisation de la transformée fortement corrélative [33,34]. Il permet d'utiliser des fonctions plus robustes pour générer les matrices de dispersion, mais les sources doivent avoir des spectres distincts comme dans l'algorithme de la transformée fortement corrélative. Tout vecteur aléatoire complexe \mathbf{x} peut être transformé en utilisant une matrice carrée non singulière C^{-1} telle que :

$$\mathbf{s} = [\mathbf{s}_1, \dots, \mathbf{s}_N]^T = C^{-1}\mathbf{x} \quad (\text{II.23})$$

Où la matrice C^{-1} représente la transformée de contrainte forte [33,34].

II.6.2 Méthodes de séparation basées sur la non-gaussianité

Ce sont les méthodes qui exploitent uniquement la non-gaussianité en supposant que la source est circulaire explicitement ou implicitement, parmi ces méthodes, on distingue :

➤ **La diagonalisation conjointe des matrices propres [35].**

Elle est basée sur l'utilisation de cumulants d'ordre quatre impliquant à la fois les auto-cumulants et les cumulants croisés. La fonction coût est donnée par :

$$J(\mathbf{y}) = \sum_{ijkl \neq iikl} |\text{cum}\{\mathbf{y}_i, \mathbf{y}_j, \mathbf{y}_k, \mathbf{y}_l\}|^2 \quad (\text{II.24})$$

Maximiser cette fonction revient à diagonaliser conjointement un ensemble de matrices. L'algorithme de diagonalisation conjointe nécessite aussi un blanchiment des observations.

➤ **Analyse en composantes indépendantes complexes rapide :**

L'algorithme d'analyse en composantes indépendantes complexes (ACIC) rapide est l'une des méthodes les plus populaires pour l'exécution de l'ACI lorsqu'il s'agit de sources à valeurs complexes [36]. Contrairement aux études effectuées dans [37,38], l'ACIC utilise des non linéarités générales moins sensibles aux valeurs aberrantes.

II.6.3 Méthodes de séparation basées sur la non-circularité et la non-gaussianité

Ce sont des méthodes qui prennent en compte à la fois la non-gaussianité et la non-circularité.

➤ **Analyse en composantes indépendantes rapide non circulaire.**

Cette méthode étend l'algorithme d'analyse en composantes indépendante rapide [39] en exploitant les informations de second ordre contenues dans la matrice de pseudo-covariance dans l'optimisation à point fixe et en utilisant les mêmes fonctions que l'algorithme d'analyse en composantes indépendantes rapide, mais en modifiant la procédure d'optimisation pour tenir compte des sources non circulaires.

L'ajout de l'information dans la matrice de pseudo-covariance à l'algorithme à point fixe affecte également le paysage de la surface d'optimisation de manière à garantir la convergence. Ensuite, une analyse rigoureuse de la stabilité locale est effectuée pour quantifier les effets de la non-circularité sur la performance. La fonction coût de l'algorithme d'analyse en composantes indépendantes rapide et l'algorithme d'analyse en composantes indépendantes rapide non-circulaire est donnée par :

$$J(\mathbf{w}) = E\{G(|\mathbf{w}^H \mathbf{x}|^2)\} \quad (\text{II.25})$$

Où $G: \mathbb{R} \rightarrow \mathbb{R}$ est une fonction uniforme et lisse et $\mathbf{w} \in \mathbb{C}^N$ avec $\|\mathbf{w}\| = 1$. La fonction coût donnée n'utilise pas la phase des sources indiquant que toute information de non-circularité est perdue comme c'est le cas pour l'algorithme d'analyse en composantes indépendantes rapide. Les informations de phase sont récupérées dans la mise à jour du point fixe de l'algorithme d'analyse en composantes indépendantes rapide non-circulaire par l'utilisation explicite de la matrice de pseudo covariance.

➤ **Algorithme complexe à points fixes.**

Une autre mise à jour du point fixe pour l'ACI complexe, proposée par les auteurs dans [37], est l'algorithme ACI rapide à point fixe basé sur la fonction coût du kurtosis qui utilise la forte transformation non corrélative; Aucune hypothèse de circularité n'est nécessaire car les matrices de covariance et de pseudo-covariance sont diagonalisées en utilisant la forte transformation non corrélative plutôt que le blanchiment conventionnel de la matrice de covariance seule.

➤ **Maximisation du kurtosis.**

Dans [40], l'auteur a étudié des algorithmes de séparation de sources à valeurs complexes basés sur le kurtosis en utilisant la méthode d'optimisation du gradient et de Newton. L'algorithme a été conçu pour des sources à valeurs complexes et a ainsi surpassé l'algorithme d'analyse en composantes indépendantes complexes rapide avec la non-linéarité basée sur le kurtosis.

➤ **Minimisation de l'entropie [41]**

L'algorithme ACI-MBE complexe utilise le principe de la minimisation de l'information mutuelle pour effectuer la séparation des sources. L'ACI-MBE complexe estime la limite la plus étroite de l'entropie. L'ACI-MBE complexe permet obtenir une estimation fiable des bornes de l'entropie en résolvant la distribution d'entropie maximale qui maximise l'entropie sous certaines contraintes. Parmi toutes les estimations de l'entropie, seul le minimum est utilisé comme estimation finale de l'entropie.

II.7 Décomposition en composantes indépendantes basée sur la minimisation des bornes de l'entropie [42]

II.7.1 Principe

Pour effectuer la séparation des N sources indépendantes, la méthode ACI-MBE minimise l'information mutuelle $I(\mathbf{z}_1; \dots; \mathbf{z}_N)$ définie comme :

$$I(\mathbf{z}_1; \dots; \mathbf{z}_N) = \sum_{n=1}^N H(\mathbf{z}_n) - \log |\det(\mathbf{W})| - H(\mathbf{x}) \quad (\text{II.26})$$

Où $H(\mathbf{z}_n)$ est l'entropie de la $n^{\text{ème}}$ source séparée, et $H(\mathbf{x})$ est l'entropie des signaux observés.

Dans les approches de l'ACI unitaires, le blanchiment des mélanges permet d'avoir $|\det(\mathbf{W})| = 1$ sous la contrainte d'une matrice de séparation orthogonale. La contrainte d'orthogonalité garantit les propriétés de stabilité et de convergence des algorithmes d'ACI. La fonction coût à minimiser devient :

$$I(\mathbf{z}_1; \dots; \mathbf{z}_N) = \sum_{n=1}^N H(\mathbf{z}_n) - H(\mathbf{x}) \quad (\text{II.27})$$

Sous la contrainte unitaire, on a $\mathbf{W}\mathbf{W}^H = \mathbf{I}$, où \mathbf{I} est la matrice identité. Même si elle est couramment utilisée, la contrainte unitaire limite l'espace de recherche pour la matrice de séparation optimale et peut donc conduire à une performance non optimale [14].

Lors du développement des mises à jour de l'algorithme ACI-MBE complexe, le problème de minimisation $I(\mathbf{z}_1, \dots, \mathbf{z}_N)$ par rapport à $\mathbf{W} = [\mathbf{W}_1, \dots, \mathbf{W}_N]^H$ est divisé en une série de sous-problèmes de minimisation de $I(\mathbf{z}_1, \dots, \mathbf{z}_N)$ par rapport à chacun des vecteurs ligne w_n , $n = 1, \dots, N$. Ce dernier est un problème plus facile à résoudre et fournit une meilleure performance lorsqu'on estime séparément l'entropie de chaque source. Par conséquent, il faut mettre à jour w_n , tandis que w_m , $m = 1, \dots, n-1, n+1, \dots, N$ sont maintenus constants.

Pour cette tâche, la fonction coût est écrite en fonction de w_n seulement, alors $|\det(W)|$ est exprimé comme :

$$|\det(W)| = |Sh_n^H w_n| \quad (\text{II.28})$$

Où $S = \sqrt{|\det(W_n W_n^H)|}$, avec W_n dénotant la matrice obtenue en supprimant le vecteur de la $n^{\text{ième}}$ rang de W . Pour supprimer l'ambiguïté d'échelle inhérente à la solution de l'ACI, dans [14] les auteurs supposent que tous les vecteurs lignes de son de longueur unitaire ($\|w_n\| = 1$) Ce qui implique que les sources sont de variance unitaire puisque les mélanges sont pré-blanchis.

La fonction coût conduit à un problème d'optimisation restreint, qui n'est qu'une fonction de w_n .

$$\min \hat{H}(z_n) - 2\log|h_n^H w_n| + c \quad (\text{II.29})$$

Où $z_n = w_n x$ et $2\log|h_n^H w_n|$ peut être considéré comme une fonction de pénalité qui essaie de maintenir w_n orthogonal à tous les autres vecteurs lignes de la matrice de séparation W .

Soit $J_n(w_n) = \hat{H}(z_n) - 2\log|h_n^H w_n| + c$. Le problème d'optimisation peut être écrit comme la fonction lagrangienne suivante :

$$L_n(w_n, \lambda) + \lambda(w_n^H w_n - 1) \quad (\text{II.30})$$

Les dérivés de Wirtinger sont utilisées pour calculer les gradients conjugués [43] donnés par :

$$\frac{\partial J_n(w_n)}{\partial w_n^*} = \frac{\partial \hat{H}(z_n)}{\partial w_n^*} - \frac{h_n}{w_n^H h_n} \quad (\text{II.31})$$

Et

$$\frac{\partial L_n(w_n, \lambda)}{\partial w_n^*} = \frac{\partial J_n(w_n)}{\partial w_n^*} + \lambda w_n \quad (\text{II.32})$$

Où le multiplicateur lagrangien λ est un nombre réel, le terme $\frac{\partial \bar{H}(z_n)}{\partial w_n^*}$ dans le gradient conjugué est strictement colinéaire à w_n alors, il est supprimé puisqu'il ne contribue pas.

Le gradient conjugué projeté sur la surface de contrainte $\|w_n\| = 1$ est calculé comme suit :

$$\mathbf{u}_n = \frac{\mathbf{u}_n^+}{\|\mathbf{u}_n^+\|} \quad (\text{II.33})$$

Avec

$$\mathbf{u}_n^+ = \frac{\partial J_n(w_n)}{\partial w_n^*} - \text{Re} \left\{ w_n^H \frac{J_n(w_n)}{w_n^*} \right\} w_n \quad (\text{II.34})$$

Il est clair que le gradient conjugué projeté normalisé u_n est un vecteur de longueur unitaire et il est orthogonal au précédent w_n . Finalement, la mise à jour de w_n est donnée par :

$$w_n^{[\text{nouveau}]} = \frac{w_n - \mu u_n}{\|w_n - \mu u_n\|} \quad (\text{II.35})$$

Où $\mu > 0$ représente le pas.

L'algorithme ACI-MBE est résumé comme suit :

Pour $n = 1, \dots, N$

1. Calculer le vecteur h_n qui est un vecteur unité obtenu par la procédure d'orthogonalisation de Gram-Schmidt, et qui satisfait $W_n h_n = 0$ où $W_n = [W_1, \dots, W_{n-1}, W_{n+1}, \dots, W_N]^H$.

2. Estimer l'entropie de $z_n = w_n^H x$. L'estimation de l'entropie des variables aléatoires complexes est basée sur le principe de l'entropie maximale introduit dans [44].

Plusieurs maxima d'entropie sont calculés, puis délimités par des calculs numériques. L'estimation de l'entropie finale est la plus étroite, ce qui est obtenu lorsque la néguentropie estimée est toujours non négative. Pour la procédure d'estimation, un estimateur de l'entropie flexible basé sur la décomposition QR est utilisé.

3. Calculer le gradient conjugué défini par l'équation (II.31).

4. Calculer le gradient conjugué projeté sur la contrainte de surface $\|w_n\| = 1$ par l'équation (II.33).

5. Mettre à jour par équation (II.35).

L'algorithme ACI-MBE complexe répète la procédure sur différents vecteurs ligne de jusqu'à la convergence donnée par :

$$1 - \max(\text{abs}[\text{diag}(W_n^{\text{nouveau}} W^H)]) \leq \varepsilon \quad (\text{II.36})$$

II.7.2 Principe d'estimation de l'entropie

Dans le développement de l'algorithme de l'ACI-MBE, les auteurs dans [14] ont proposé une nouvelle procédure pour l'estimation de l'entropie.

Soit la variable aléatoire complexe $z = z_R + jz_I$, où $E[z_R] = E[z_I] = 0$. Par définition, l'entropie de z est donné par $H(z) \triangleq H(z_R, z_I) = -E[\log p(z_R, z_I)]$. Où $p(z) \triangleq p(z_R, z_I)$ est la densité de probabilité de z et E désigne l'espérance.

a. Borne 1 de l'entropie

Les auteurs dans [14] considèrent la décomposition linéaire suivante :

$$\begin{bmatrix} u \\ v \end{bmatrix} = B^{-1} \begin{bmatrix} z_R \\ z_I \end{bmatrix} \quad (\text{II.37})$$

Où u et v sont deux variables aléatoires de moyenne nulle. Il est facile d'observer que la décomposition conduit à la limite supérieure suivante :

$$\begin{aligned} H(z) &= \log|\det(B)| + H(u, v) \leq \log|\det(B)| + H(u) + H(v) \\ &= H^{\text{borne,1}}(z, B) \end{aligned} \quad (\text{II.38})$$

Où l'égalité est valable si et seulement si u et v sont statistiquement indépendantes, les bornes de l'entropie sont écrites en fonction de B .

b. Borne 2 de l'entropie

Dans ce cas, on considère la décomposition suivante :

$$\begin{bmatrix} z_R \\ z_I \end{bmatrix} = B \begin{bmatrix} u \\ v \end{bmatrix} = Br \begin{bmatrix} \cos \theta \\ \sin \theta \end{bmatrix} \quad (\text{II.39})$$

Où B est une matrice non-singulière, r et θ sont l'amplitude et l'argument de $u + jv$, la décomposition conduit à la borne d'entropie suivante :

$$\begin{aligned} H(\mathbf{z}) &= \log|\det(B)| + H(u, v) \leq \log|\det(B)| + E[\log r] + H(r, \theta) \\ &= H^{[borne, II]}(\mathbf{z}, B) \end{aligned} \quad (\text{II.40})$$

Dans les deux décompositions données par les équations (II.37) et (II.39), toute mise à l'échelle et changement des signes de u et v peut être absorbée par B . Ainsi, sans perte de généralité, on suppose toujours que est normalisé tel que :

$$\det(B) > 0, E[u^2] = E[v^2] = 1 \text{ et } E[r^2] = 2 \quad (\text{II.41})$$

II.7.3 Estimation de l'entropie par la décomposition QR

Pour une matrice non-singulière B , il faut déterminer les borne d'entropie de $H(u)$ et $H(v)$. Comme u et v sont normalisées et de moyennes nulles et, on peut utiliser directement la limite d'entropie maximale développée dans [14] qui consiste à calculer plusieurs entropies maximales puis borner l'entropie des estimations en utilisant le calcul numérique.

Le nouvel estimateur de l'entropie suppose qu'il existe $K^{[I]}$ fonctions de mesure $G_k^I(x), k = 1, \dots, K^{[I]}$, pour la détermination de la première borne d'entropie, et $K^{[II]}$ fonctions de mesure $G_k^{II}(x), k = 1, \dots, K^{[II]}$, pour déterminer la seconde.

Pour toute matrice non-singulière B satisfaisant la condition d'échelle donnée en (II.41), on peut obtenir les $(K^I)^2$ bornes d'entropie du premier type et $K^{[II]}$ du second type par :

$$\begin{aligned} &H_{k_1, k_2}^{[borne, I]}(\mathbf{z}, B) \\ &= \log \det(B) + \log 2\pi e - V_{k_1}^{[I]} \left\{ E \left[G_{k_1}^{[I]}(u) \right] \right\} \\ &\quad - V_{k_2}^{[I]} \left\{ E \left[G_{k_2}^{[I]}(v) \right] \right\} \end{aligned} \quad (\text{II.42})$$

Et

$$\mathbf{H}_k^{[borne,II]}(\mathbf{z}, \mathbf{B}) = \log \det(\mathbf{B}) + \log 2\pi e - V_k^{[II]} \left\{ E \left[G_k^{[II]}(\mathbf{r}) \right] \right\} \quad (\text{II.43})$$

Où $k_1, k_2 = 1, \dots, K^I$, $k_1, k_2 = 1, \dots, K^{II}$, et $V_{k_1}^{[I]} \left\{ E \left[G_{k_1}^{[I]}(u) \right] \right\}$ et $V_{k_2}^{[I]} \left\{ E \left[G_{k_2}^{[I]}(v) \right] \right\}$

Représentent la négentropie de $G_k^{[I]}$ et $G_k^{[II]}$ respectivement. L'estimation de l'entropie finale est la plus étroite lorsque la négentropie estimée est toujours non négative.

Parmi toutes ces bornes d'entropie possibles, la plus étroite est utilisée comme estimation finale de $H(\mathbf{z})$ définie par :

$$\hat{H}(\mathbf{z}) = \min \left(\min_{1 \leq k_1, k_2 \leq K^{[I]}} H_{k_1, k_2}^{[borne, I]}(\mathbf{z}), \min_{1 \leq k \leq K^{[II]}} H_k^{[borne, II]}(\mathbf{z}) \right) \quad (\text{II.44})$$

Où

$$H_{k_1, k_2}^{[borne, I]}(\mathbf{z}) = \min_{\mathbf{B}} H_{k_1, k_2}^{[borne, I]}(\mathbf{z}, \mathbf{B}) \quad (\text{II.45})$$

Et

$$H_k^{[borne, II]}(\mathbf{z}) = \min_{\mathbf{B}} H_k^{[borne, II]}(\mathbf{z}, \mathbf{B}) \quad (\text{II.46})$$

L'estimateur d'entropie donné dans l'équation (II.44) exige d'abord la solution optimale \mathbf{B} , ce qui n'est pas pratique pour une mise en œuvre de l'algorithme de l'ACI. En considérant la décomposition QR tel que $\mathbf{B} = \mathbf{Q}\mathbf{R}$, où \mathbf{Q} est une matrice orthogonale de dimension 2×2 , et \mathbf{R} une matrice triangulaire inférieure de même dimension, on constate que \mathbf{Q} peut être absorbée par la matrice de séparation et qu'on peut obtenir une expression explicite pour \mathbf{R} . Cette observation simplifie grandement l'utilisation de l'estimateur d'entropie donné par l'équation (II.44). Les éléments diagonaux de \mathbf{R} doivent être positifs de sorte que la décomposition QR soit unique puisque est non-singulière.

En outre, on a $\det(\mathbf{Q}) = 1$, puisque $\det(\mathbf{R}) = 1$ et $\det(\mathbf{B}) = 1$ sont positifs, conduisant à un $\det(\mathbf{Q})$ positif. Par conséquent \mathbf{Q} représente aussi une matrice de rotation.

a. Absorption de \mathbf{Q}

Sachant que $\mathbf{z} = \mathbf{W}^H \mathbf{x}$ dénote la source estimée. A partir des équations précédentes, on peut écrire :

$$\begin{bmatrix} \mathbf{u} \\ \mathbf{v} \end{bmatrix} = \mathbf{R}^{-1} \mathbf{Q}^T \begin{bmatrix} \mathbf{z}_R \\ \mathbf{z}_I \end{bmatrix} \quad (\text{II.47})$$

Où \mathbf{Q} est définie par :

$$\mathbf{Q} = \begin{bmatrix} \cos \vartheta & -\sin \vartheta \\ \sin \vartheta & \cos \vartheta \end{bmatrix} \quad (\text{II.48})$$

Où ϑ est l'angle de rotation. Alors on peut écrire :

$$\mathbf{Q}^T \begin{bmatrix} \mathbf{z}_R \\ \mathbf{z}_I \end{bmatrix} = \begin{bmatrix} \text{Re}[\exp(j\vartheta)\mathbf{z}] \\ \text{Im}[\exp(j\vartheta)\mathbf{z}] \end{bmatrix} = \begin{bmatrix} \text{Re}\{[\exp(j\vartheta)\mathbf{w}]^H \mathbf{x}\} \\ \text{Im}\{[\exp(j\vartheta)\mathbf{w}]^H \mathbf{x}\} \end{bmatrix} \quad (\text{II.49})$$

On constate que la matrice de rotation orthogonale \mathbf{Q} peut être absorbée par le vecteur de Séparation. Comme \mathbf{w} est inconnu et à estimer à partir des mélanges, les auteurs dans [14] supposent simplement que $\mathbf{Q} = \mathbf{1}$ et $\mathbf{B} = \mathbf{R}$.

b. Expression explicite de \mathbf{R}

La matrice triangulaire inférieure \mathbf{R} peut être déterminée de façon unique par les statistiques de second ordre de \mathbf{z} et les conditions de mise à l'échelle données dans (II.41). Dans le premier type de distribution de l'entropie maximale, \mathbf{u} et \mathbf{v} sont statistiquement indépendants, ce qui implique que u et v sont décorrélés.

Dans le second type, $u + jv$ est strictement circulaire, ce qui implique que $u + jv$ est circulaire de second ordre. Ainsi, dans les deux distributions de l'entropie maximale, u et v sont décorrélés, c'est-à-dire $E[uv] = 0$ sachant que u et v sont également de moyennes nulles. Puis, en considérant la décomposition :

$$\begin{bmatrix} \mathbf{z}_R \\ \mathbf{z}_I \end{bmatrix} = \mathbf{R} \begin{bmatrix} \mathbf{u} \\ \mathbf{v} \end{bmatrix} \quad (\text{II.50})$$

Et la condition de mise à l'échelle donnée par l'équation (II.41), on a :

$$\mathbf{E} \left\{ \begin{bmatrix} \mathbf{z}_R \\ \mathbf{z}_I \end{bmatrix} \begin{bmatrix} \mathbf{z}_R & \mathbf{z}_I \end{bmatrix} \right\} = \begin{bmatrix} \sigma_R^2 & \rho \\ \rho & \sigma_I^2 \end{bmatrix} = \mathbf{R}\mathbf{R}^T \quad (\text{II.51})$$

Le produit $\mathbf{R}\mathbf{R}^T$ définit une factorisation de Cholesky puisque \mathbf{R} est une matrice triangulaire inférieure et la matrice de covariance est une matrice symétrique et définie positive. On peut résoudre (II.51) pour obtenir :

$$\mathbf{R}^{-1} = \begin{bmatrix} \frac{1}{\sigma_R} & \mathbf{0} \\ -\frac{\rho}{\sigma_R\sqrt{\Delta_1}} & \frac{\sigma_R}{\sqrt{\Delta_1}} \end{bmatrix} \quad (\text{II.52})$$

Où $\Delta_1 = \sigma_R^2\sigma_I^2 - \rho^2$,

Par conséquent, toutes les expressions explicites de et peut être facilement obtenues par

$$u = \frac{z_R}{\sigma_R}, v = -\frac{\rho z_R}{\sigma_R\sqrt{\Delta_1}} + \frac{\sigma_R z_I}{\sqrt{\Delta_1}} \text{ et } r = \sqrt{u^2 + v^2} = \sqrt{\frac{\Delta_1}{\Delta_2}} \text{ et } \Delta_2 = z_R^2\sigma_I^2 + z_I^2\sigma_R^2 + 2z_R z_I \rho$$

Les bornes de l'entropie deviennent

$$\begin{aligned} H_{k_1, k_2}^{[borne, I]}(\mathbf{z}) &= 0.5 \log \det(\Delta_1) + \log 2\pi e - V_{k_1}^{[I]} \left\{ \mathbf{E} \left[\mathbf{G}_{k_1}^{[I]}(\mathbf{u}) \right] \right\} \\ &\quad - V_{k_2}^{[I]} \left\{ \mathbf{E} \left[\mathbf{G}_{k_2}^{[I]}(\mathbf{v}) \right] \right\} \end{aligned} \quad (\text{II.53})$$

Et

$$H_k^{[borne, II]}(\mathbf{z}) = 0.5 \log \det(\Delta_1) + \log 2\pi e - V_k^{[II]} \left\{ \mathbf{E} \left[\mathbf{G}_k^{[II]}(\mathbf{u}) \right] \right\} \quad (\text{II.54})$$

II.8 Conclusion

Dans ce chapitre nous avons présenté les quelques méthodes de résolution du problème de la SAS. Le principe des méthodes les plus courantes appliquées à la séparation des sources tel que: (ACP) est l'une des plus anciennes et des plus largement utilisées. Son idée est simple : réduire la dimensionnalité d'un ensemble de données, et (ACI) est une technique statistique dont l'objectif est de décomposer un signal aléatoire multi variable en une combinaison linéaire de signaux indépendants (les signaux sources), aussi (ACIC) pour les signaux à valeurs complexes en se basant sur les méthodes exploitant la non-circularité et la non-gaussianité des signaux. Aussi le principe de la Décomposition en composante indépendantes basée sur la minimisation des bornes de l'entropie.



Chapitre III
Applications et Discussions

III.1 Introduction

Après avoir présenté la méthode de la décomposition en modes empiriques bivariée (DMEB) et l'analyse en composantes indépendantes par minimisation des bornes de l'entropie (ACI-MBE) qui exploite conjointement la non-gaussianité et la non-circularité.

Dans ce chapitre, la combinaison de ces deux algorithmes est introduite comme alternative pour résoudre le problème de la séparation aveugle de signaux de mélanges convolutifs de signaux de parole.

Les performances de l'approche proposée sont testées sur des signaux de parole réelle choisis parmi les bases de données disponibles et comparées aux performances de la séparation basée sur l'algorithme conventionnel de l'analyse en composantes indépendantes fréquentielle (ACIF).

III.2 Position du problème

La séparation aveugle de sources (SAS) est une puissante méthode en traitement du signal qui a été proposée à la fin des années 80 [45].

Dans les applications scientifiques et techniques, de nombreux signaux observés peuvent être perçus comme un mélange d'une pluralité de signaux sources, c'est-à-dire que le signal mélange observé est une série de sorties de capteurs, chacun recevant différentes combinaisons de signaux sources. La principale tâche de la SAS est donc de récupérer le signal source qui nous intéresse à partir des données observées Figure III.1.

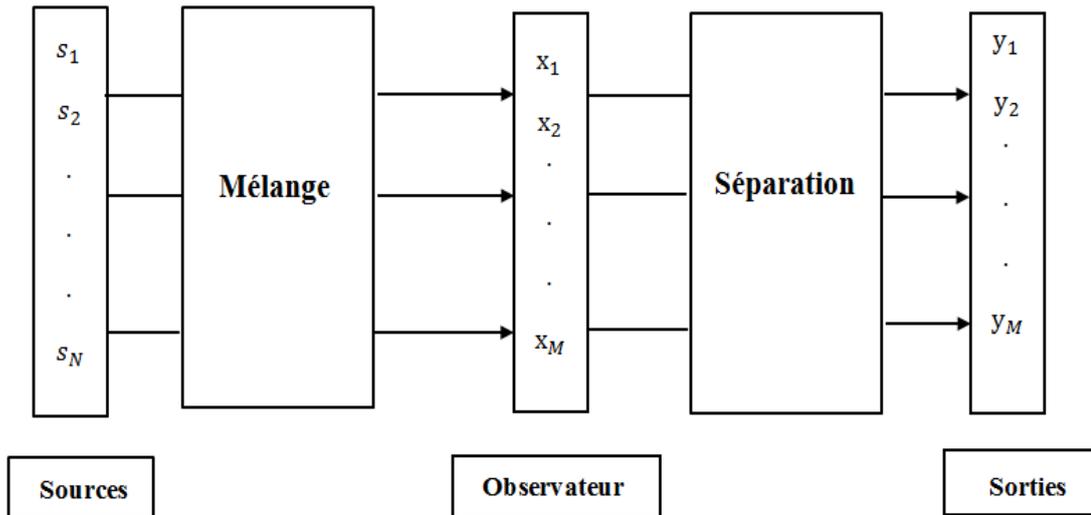


Figure III.1: Configuration générale de la séparation aveugle de sources.

III.2.1 Principe

Le principe de la séparation aveugle de sources peut être énoncé comme suit : Soit $\mathbf{s}(t) = [s_1(t), \dots, s_N(t)]^T$ un vecteur de N sources indépendantes à l'instant discret t .

Le vecteur $\mathbf{x}(t) = [x_1(t), \dots, x_M(t)]^T$ de M mélanges observés est modélisé (dans le cas du mélange instantané) par :

$$\mathbf{x}(t) = \mathbf{A}\mathbf{s}(t) \quad (\text{III.1})$$

Où \mathbf{A} est la matrice de mélange de dimension $(M \times N)$.

L'objectif d'estimer le vecteur $\mathbf{z}(t)$ des N signaux source à partir de M observation par l'estimation de la matrice de séparation \mathbf{W} avec

$$\mathbf{z}(t) = \mathbf{W}\mathbf{x}(t) \quad (\text{III.2})$$

Où $\mathbf{z}(t) = [z_1(t), \dots, z_N(t)]^T$ et $\mathbf{W} = [\mathbf{W}_1, \dots, \mathbf{W}_N]^T$.

La séparation aveugle de sources possède plusieurs degrés de difficulté :

- Selon le type du système de mélange envisagé :
 - système linéaire ou non-linéaire.
 - mélange instantané ou convolutifs.
 - modèle de mélange sur-déterminé ou sous-déterminé.
- Selon les caractéristiques de sources considérées :
 - stationnaires, ou non-stationnaires.
 - Statistiquement mutuellement indépendants ou corrélés ou non.

La détermination du mélange représente le rapport entre le nombre de sources et le nombre de capteurs. Les mélanges peuvent être classés en trois catégories :

- le mélange est déterminé : si $N=M$
- le mélange est sur-déterminé : si $N<M$
- le mélange est sous-déterminé : si $N>M$

III.2.2 Nature du mélange

La nature du mélange représente les hypothèses que l'on fait sur l'environnement acoustique dans lequel l'enregistrement est effectué.

On définit trois hypothèses sur le mélange qui correspondent aux trois scénarios précédents :

- mélange instantané.
- mélange convolutif.

a. Mélange instantané

Le mélange instantané C'est le cas le plus simple et les plus répondu dans la littérature. Les observations $x_i(t)$ du capteur i à l'instant t s'écrit comme une combinaison linéaire des sources au même instant t . Le mélange est donné par l'équation :

$$\mathbf{x}_i(t) = \sum_{j=1}^N \mathbf{a}_{ij} s_j(t) \quad (\text{III.3})$$

Avec $i = 1, \dots, M$

Peut être formulé sous forme matricielle comme suit :

$$\mathbf{x}(t) = \mathbf{A}s(t) \quad (\text{III.4})$$

Où \mathbf{A} est la matrice mélange ayant pour éléments les coefficients de la combinaison linéaire a_{ij} .

Le modèle d'un mélange instantané est donné sur la figure (III.2).

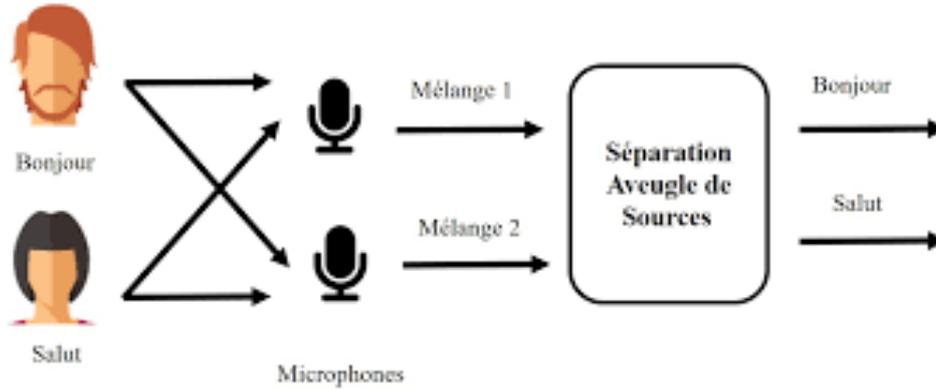


Figure III.2: Modèle de mélange instantané.

b. Mélange convolutif

Le mélange convolutif se produit dans des scénarios acoustiques en raison de la propagation du son dans l'espace et des trajets multiples générés par les réflexions du son par les différents objets, en particulier dans les salles et les environnements fermés. Le modèle de mélange convolutif est donné par l'équation :

$$x_i(t) = \sum_{j=1}^N \sum_{k=0}^{\infty} a_{ij}(t) s_j(t - k) \quad (\text{III.5})$$

Avec $i = 1, \dots, M$

Le modèle de mélange convolutifs peut être formulé sous forme matricielle comme suit :

$$\mathbf{x}(t) = \mathbf{A}(t) * \mathbf{s}(t) \quad (\text{III.6})$$

Le modèle des mélanges convolutifs des sources est plus proche d'un modèle de mélanges réel. Supposons qu'il existe des sources statistiquement indépendantes reçues par capteurs après le processus de mélange par convolution (figure III.3).

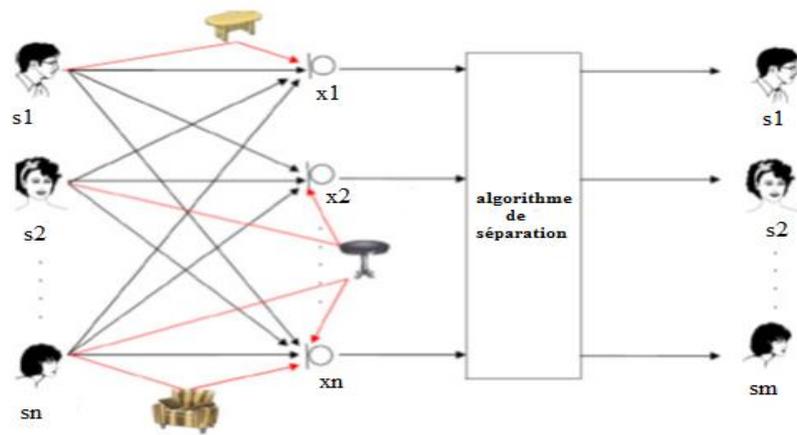


Figure III.3: Modèle des mélanges convolutifs.

III.2.3 Ambiguïtés de séparation

Séparer aveuglement les sources contenues dans leurs mélanges sont entachés d'ambiguïté. En effet, la séparation peut être obtenue avec une infinité de solutions [46,47]. Nous allons, dans les sous-sections suivantes, montrer l'ambiguïté du modèle de séparation. Nous montrons par ailleurs pour chaque cas, instantané ou convolutif, le comportement de l'ambiguïté et son incidence sur la reconstruction des sources.

a. Ambiguïté de permutation

L'estimation de la matrice inverse des filtres n'est pas unique. Ceci peut être vu sur le modèle de mélange (cas instantané) en permutant par exemple deux colonnes (*e.g.* d'indice 1 et 2) dans la matrice de mélange :

$$\begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_M \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1N} \\ a_{21} & a_{22} & \dots & a_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ a_{M1} & a_{M2} & \dots & a_{MN} \end{bmatrix} \begin{bmatrix} s_2 \\ s_1 \\ \vdots \\ s_N \end{bmatrix} \quad (\text{III.7})$$

En utilisant la propriété de commutativité de l'opération de multiplication et de l'opération d'addition, nous pouvons écrire :

$$\begin{aligned}
\begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_M \end{bmatrix} &= \begin{bmatrix} a_{12}s_2 \\ \vdots \\ a_{M2}s_2 \end{bmatrix} + \begin{bmatrix} a_{11}s_1 \\ \vdots \\ a_{M1}s_1 \end{bmatrix} + \cdots + \begin{bmatrix} a_{1N}s_N \\ \vdots \\ a_{MN}s_N \end{bmatrix} \\
&= \begin{bmatrix} a_{12} & a_{11} & \cdots & a_{1N} \\ a_{22} & a_{21} & \cdots & a_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ a_{M2} & a_{M1} & \cdots & a_{MN} \end{bmatrix} \begin{bmatrix} s_2 \\ s_1 \\ \vdots \\ s_N \end{bmatrix}
\end{aligned} \tag{III.8}$$

Nous constatons, par rapport à la matrice de mélange initiale et par rapport aux vectrices sources initiales, qu'il y a eu une permutation de la première ligne avec la deuxième et un changement d'ordre entre les sources d'indice 1 et 2, tout en conservant le même vecteur des mélanges. En notant la nouvelle matrice de mélange \tilde{A} et les nouvelles vectrices sources \tilde{S} et le vecteur mélange s'écrira :

$$\begin{aligned}
\mathbf{X} &= \tilde{A}\tilde{S} \\
&= AP\tilde{S} \\
&= APP^{-1}S \\
&= AIS \\
&= AS
\end{aligned} \tag{III.9}$$

On conclut que la multiplication à droite de la matrice de mélange par une matrice de permutation ne change pas les mélanges, mais implique que l'ordre des sources est indéterminé.

b. Ambiguïté d'échelle

Nous avons vu dans la sous-section précédente que la permutation de deux colonnes dans la matrice de mélange et de deux sources, ne change en rien les mélanges. Nous allons voir dans cette section, que de même, la multiplication d'une colonne (de la matrice de mélange) et la division d'une source par un scalaire ne changera pas le vecteur mélanges :

$$\begin{aligned}
\mathbf{x} &= s_1\mathbf{a}_1 + s_2\mathbf{a}_2 + \cdots + s_N\mathbf{a}_N \\
&= \left(\frac{\mathbf{1}}{\alpha_1}s_1\right)(\alpha_1\mathbf{a}_1) + \left(\frac{\mathbf{1}}{\alpha_2}s_2\right)(\alpha_2\mathbf{a}_2) + \cdots + \left(\frac{\mathbf{1}}{\alpha_N}s_N\right)(\alpha_N\mathbf{a}_N)
\end{aligned}$$

$$\begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_M \end{bmatrix} = \begin{bmatrix} \alpha_1 a_{12} & \alpha_2 a_{11} & \dots & \alpha_N a_{1N} \\ \alpha_1 a_{22} & \alpha_2 a_{21} & \dots & \alpha_N a_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ \alpha_1 a_{M2} & \alpha_2 a_{M1} & \dots & \alpha_N a_{MN} \end{bmatrix} \begin{bmatrix} s_1/\alpha_1 \\ s_2/\alpha_2 \\ \vdots \\ s_N/\alpha_N \end{bmatrix} \quad (\text{III.10})$$

En factorisant ces scalaires dans une matrice, nous obtenons une matrice diagonale qu'on note D . En notant cette fois la nouvelle matrice de mélange \tilde{A} et le nouveau vecteur source \tilde{S} .

$$\begin{aligned} \mathbf{X} &= \tilde{A}\tilde{S} \\ &= A\tilde{P}\tilde{S} \\ &= ADD^{-1}\mathbf{S} \\ &= A\mathbf{S} \\ &= A\mathbf{S} \end{aligned} \quad (\text{III.11})$$

Nous concluons que la multiplication des colonnes de la matrice de mélange par un scalaire ne change pas les mélanges, mais montre que l'amplitude des sources est indéterminée.

III.3 Analyse en composantes indépendantes par minimisation des bornes de l'entropie et décomposition en modes empiriques bivariée

III.3.1 Principe

Dans ce travail, nous nous sommes intéressés au mélange convolutif. Le mélange convolutif dans le domaine temporel est transformé en un mélange instantané dans le domaine fréquentiel :

$$\mathbf{X}(f) = \mathbf{A}(f)\mathbf{S}(f) \quad (\text{III.12})$$

Où f désigne la fréquence, $\mathbf{A}(f)$ est une matrice complexe $M \times N$ dont les éléments sont les réponses fréquentielles de la source i au capteur j , $\mathbf{X}(f)$ est un vecteur complexe $M \times 1$ dont les éléments $\mathbf{X}_j(f)$ sont les transformées de Fourier des signaux de mélange $x_j(t)$.

Et $\mathbf{S}(f)$ est un vecteur complexe de dimension $N \times 1$ dont les éléments $\mathbf{S}_j(f)$ sont les transformées de Fourier des signaux de source $s_i(t)$.

Etant donné que la séparation du signal est effectuée fréquence par fréquence, on utilise une transformée de Fourier de courte terme (TFCT). Le modèle de mélange de chaque trame peut être écrit comme suit :

$$\mathbf{X}(f, m) = \mathbf{A}(f)\mathbf{S}(f, m) \quad (\text{III.13})$$

Où m désigne l'indice de trame, $\mathbf{X}(f, m)$ et $\mathbf{S}(f, m)$ sont des vecteurs complexes correspondant à la trame m : $\mathbf{S}(f, m) = [S_1(f, m) \dots S_N(f, m)]^T$, $\mathbf{X}(f, m) = [X_1(f, m) \dots X_M(f, m)]^T$. La solution du problème de SAS dans le cas des mélanges convolutifs consiste à rechercher pour chaque intervalle de fréquences la matrice de séparation $\mathbf{W}(f)$ qui fournit une estimation des signaux sources:

$$\mathbf{Z}(f, m) = \mathbf{W}(f)\mathbf{X}(f, m) \quad (\text{III.14})$$

Où $\mathbf{Z}(f, m)$ désigne l'estimation du vecteur $\mathbf{S}(f, m)$ des signaux source $\mathbf{Z}(f, m) = [Z_1(f, m) \dots Z_N(f, m)]^T$.

Le problème de la SAS pour les mélanges convolutifs peut être résolu dans le domaine fréquentiel en utilisant la version complexe de la méthode de l'ACI [36,48] combinée avec l'algorithme de la DMEB. Tout d'abord, les mélanges convolutifs dans le domaine fréquentiel sont décomposés en un ensemble de FMIs à l'aide de l'algorithme de DMEB, la principale caractéristique de la DMEB est qu'elle aboutit à un nombre égal des FMIs des parties réelle et imaginaire du signal. La DMEB est appliquée dans le domaine fréquentiel pour décomposer les parties réelles et imaginaires de la transformée de Fourier de chaque trame des mélanges observés en un ensemble de FMIs. Puis l'algorithme de l'ACI complexe est appliqué pour extraire les sources indépendantes.

La méthode proposée est résumée par l'organigramme représenté par la figure III.4. Les différentes étapes de la méthode combinant la DMEB et l'ACI-MBE sont les suivantes [49]:

1. Calculer la transformée de Fourier de chaque trame des signaux de mélange observés. La longueur de trame est fixée à 1024 échantillons.
2. Appliquer la DMEB à la transformée de Fourier de chaque trame des mélanges observés. Ainsi, pour chaque trame, nous obtenons deux ensembles de FMIs correspondant aux parties réelles et imaginaires de la transformée de Fourier.
3. Extraire les composantes indépendantes dans le domaine fréquentiel en utilisant l'algorithme ACI-MBE.
4. Résoudre l'ambiguïté de permutation.

5. Calculer la transformée de Fourier inverse pour obtenir les composantes indépendantes dans le domaine temporel.

Plusieurs algorithmes ont été proposés pour résoudre l'ambiguïté de permutation. Dans ce travail, nous utilisons la méthode proposée dans [15].

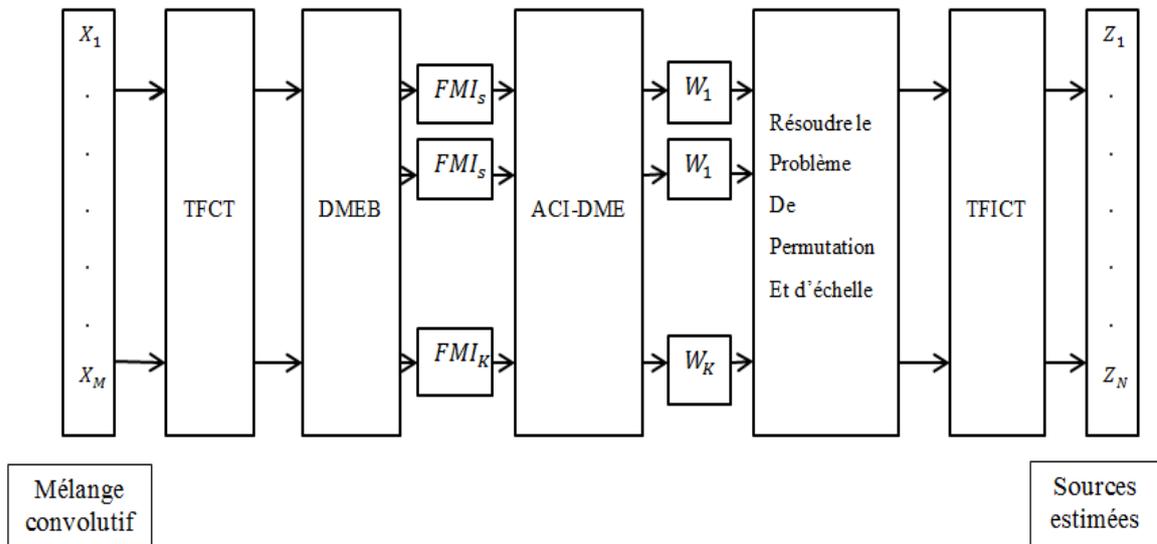


Figure III.4: Séparation aveugle de sources combinant la décomposition modale empirique bivariée (DMEB) et l'analyse en composantes indépendantes complexe par minimisation des bornes de l'entropie (ACI-MBE). ($M=N$).

III.3.2 Les critères d'évaluation

BSSEval (pour *Blind Source Séparation Evaluation*) [50] est une boîte à outils qui permet de calculer des critères objectifs de qualité de séparation de sources, à partir des sources originales et des sources estimées.

Nous décrivons brièvement ici le principe de construction de ces indicateurs.

La différence entre les sources sx_k et leurs estimée $s\hat{x}_k$ est décomposé en trois composantes :

$$\mathbf{x}_k - \hat{\mathbf{x}}_k = \mathbf{e}_k^{target} + \mathbf{e}_k^{interf} + \mathbf{e}_k^{artif} \quad (\text{III.15})$$

- \mathbf{e}_k^{target} (t) est une déformation autorisée de la source cible si (t).
- \mathbf{e}_k^{interf} (t) est une déformation autorisée des sources qui explique les interférences des sources non désirées.

- e_k^{artif} (t) est un terme "artefact" qui peut correspondre à des artefacts de l'algorithme de séparation tels que musical bruit, etc. ou simplement aux déformations induites par l'algorithme de séparation qui ne sont pas autorisées.

Où les trois composantes sont respectivement l'erreur par rapport à la cible, la composante d'interférence et la composante d'artéfact. Ces composantes sont calculées par projection de \hat{x}_k sur divers sous espaces par exemple,

e_k^{artif} est obtenu par projection de \hat{x}_k sur divers sous espaces engendré par les $x_l, l = [1, k]$.

Une fois ces composantes obtenues, on calcule divers rapports d'énergies qui quantifient la qualité de séparation, à partir de définitions similaires au rapport signal sur bruit :

- le SDR (*Signal to Distorsion Ratio*) qui évalue la qualité globale de l'estimation, défini comme suite :

$$SDR = 10 \log_{10} \frac{\|S_{target}\|^2}{\|e_{interf} + e_{noise} + e_{artif}\|^2} \quad (III.16)$$

- le SIR (*Signal to Interference Ratio*) qui mesure le rejet d'interférences, défini comme suite :

$$SIR = 10 \log_{10} \frac{\|S_{target}\|^2}{\|e_{interf}\|^2} \quad (III.17)$$

- le SAR (*Signal to Artéfact Ratio*) qui évalue le rejet d'artéfacts, défini comme suite :

$$SAR = 10 \log_{10} \frac{\|S_{target} + e_{interf} + e_{noise}\|^2}{\|e_{interf}\|^2} \quad (III.18)$$

Ces indicateurs, largement utilisés par la communauté scientifique, permettent de comparer de nombreuses méthodes. Ils apparaissent comme des indicateurs significatifs des rejets d'artéfacts et d'interférences, même si certains phénomènes (comme le masquage perceptif) ne sont pas toujours bien pris en compte par ces quantités.

III.4 Résultats et discussions

Dans cette partie ACI-MBE et DMEB sont introduit pour résoudre le problème de la séparation aveugle des sources de mélange convolutif. La résolution est effectuée dans le domaine fréquentiel.

Par exemple d'illustration, la méthode proposée est utilisée pour séparer un mélange convolutif de deux signaux de parole. Les figures III.5(a) et III.5(b) présenté les signaux sources, et les figures III.5(c) et III.5(d) Présenté leurs spectrogrammes respectifs.

Les sources sont convolutivement mélangées en utilisant la matrice de mélange décrite par sa transformation en z :

$$A(z) = \begin{bmatrix} 1 + 0.08z^{-1} + 0.5z^{-2} & 0.8 + 0.7z^{-1} + 0.4z^{-2} \\ 0.7 + z^{-1} + 0.6z^{-2} & 1 + 0.9z^{-1} + 0.3z^{-2} \end{bmatrix} \quad (\text{III.19})$$

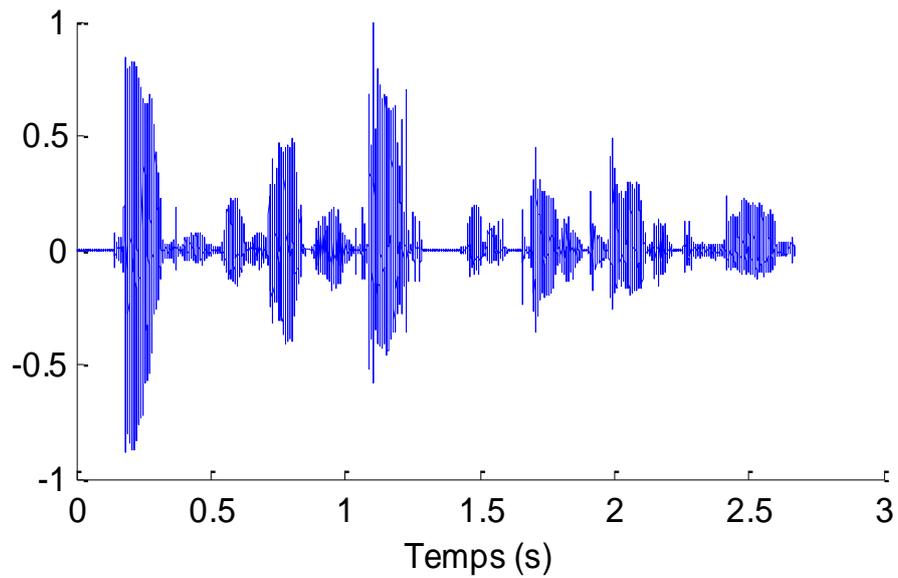
Les figures III.5(e) et III.5(f) présenté les signaux de mélange observés.

La figure III.6(a) et III.6(c) présente les parties réelles et imaginaires de la transformée de Fourier des trames extraites des deux signaux de mélange et leurs FMI correspondants III.6(b) et III.6(d).

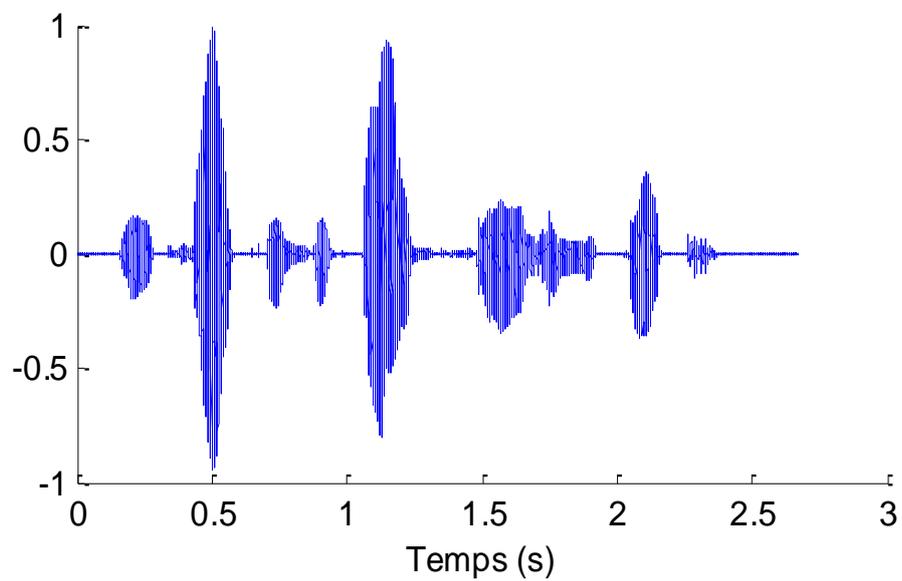
Les figures III.7(a) et III.7(b) montant les parties réelles et imaginaires des sources estimées correspondant aux deux trames de signaux de mélange dans le domaine fréquentiel.

Les figures III.8(a) et III.8(b) montant les sources estimées et les figure III.8(c) et III.8(d) Présenté leurs spectrogrammes, les signaux estimés sont très semblables aux signaux sources.

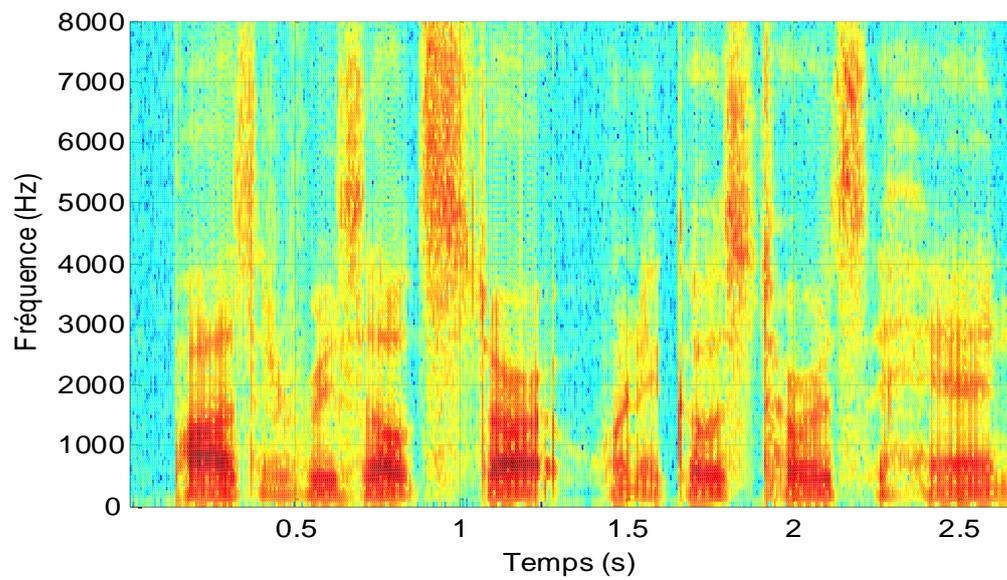
La DMEB combinée avec l'ACI-MBE complexe fournit une estimation précise des signaux sources.



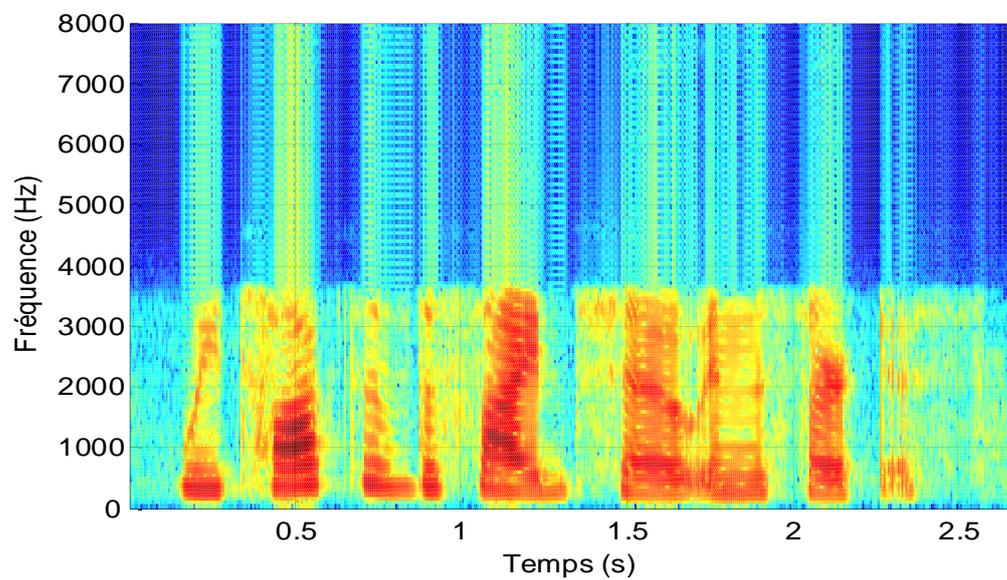
(a) : Représentation de la source 1.



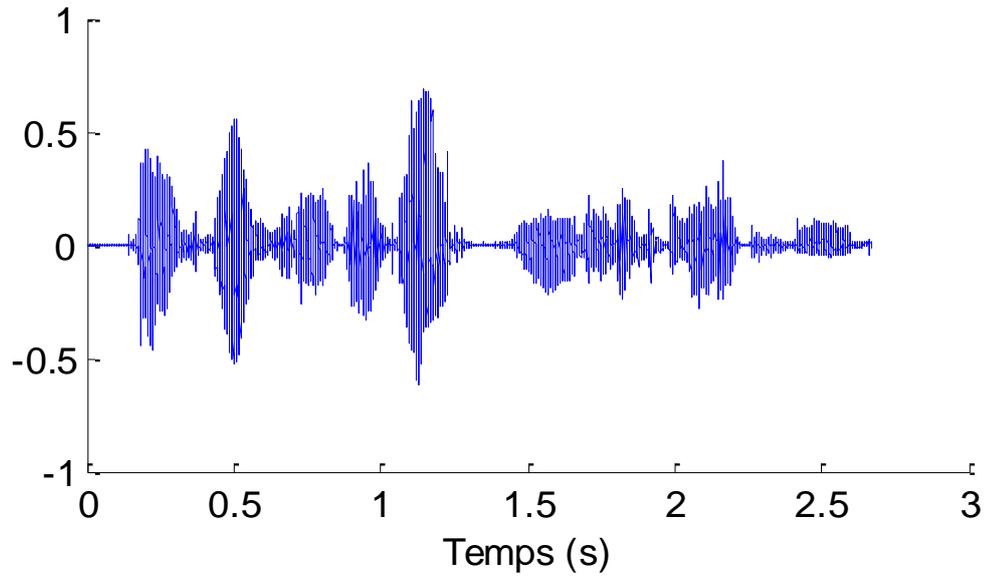
(b) : Représentation de la source 2.



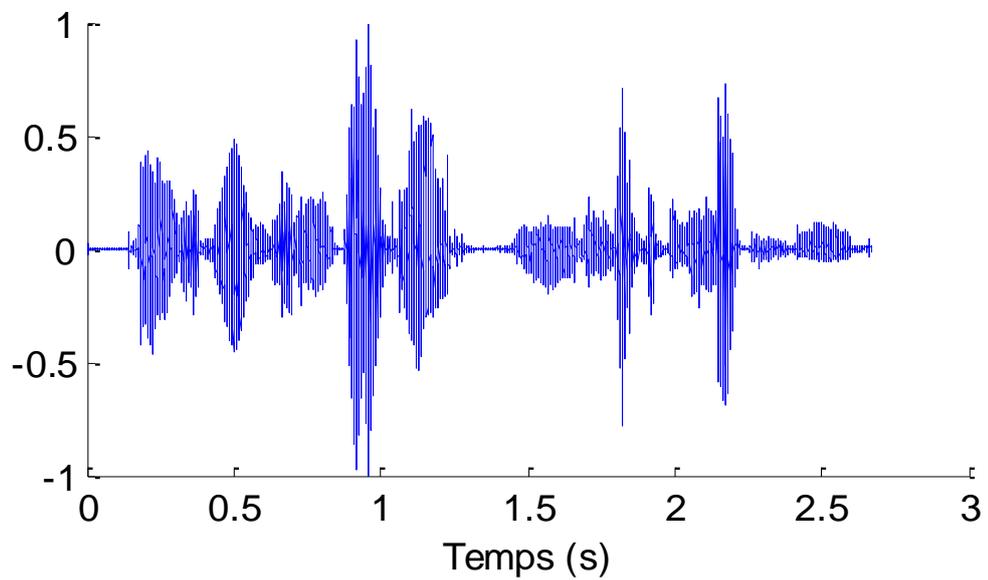
(c) : Spectrogramme de la source 1.



(d) : Spectrogramme de la source 2.

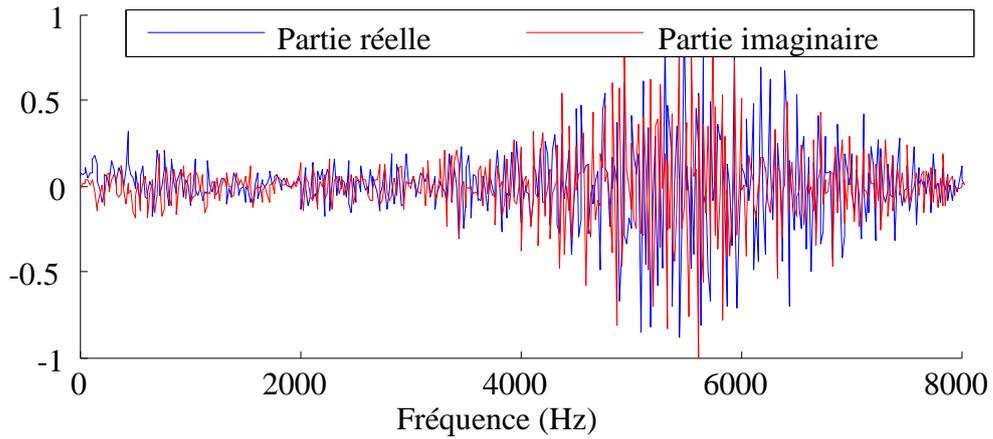


(e) : Signal observé 1.

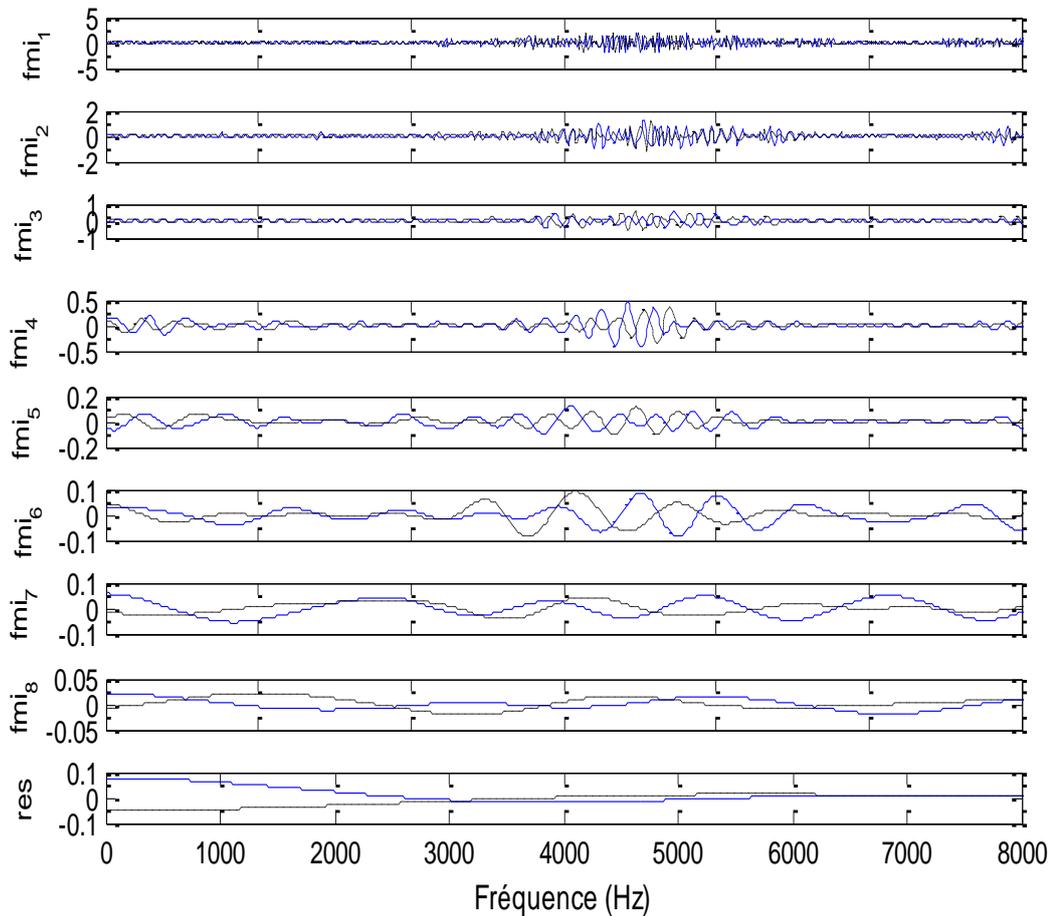


(f) : Signal observé 2.

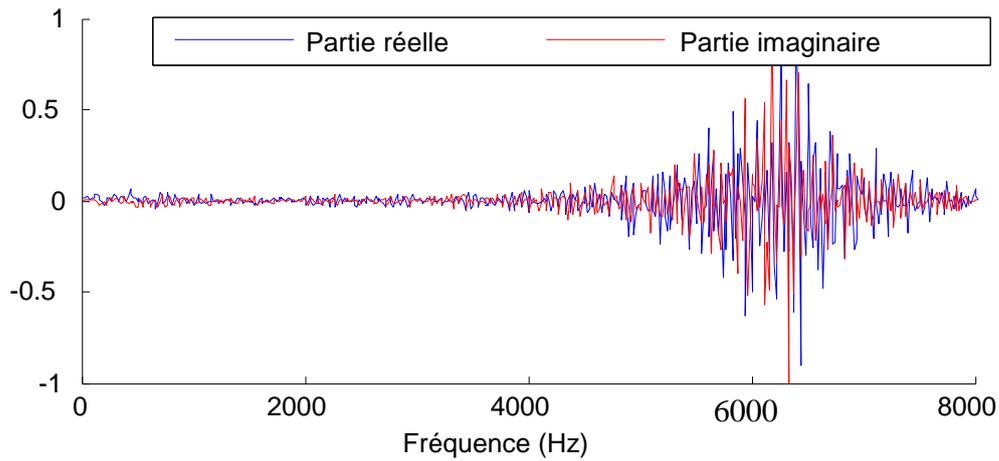
Figure III.5: Exemple d'illustration de la séparation aveugle de mélanges convolutifs de deux signaux de parole par DMEB combinée avec ACI-MBE.



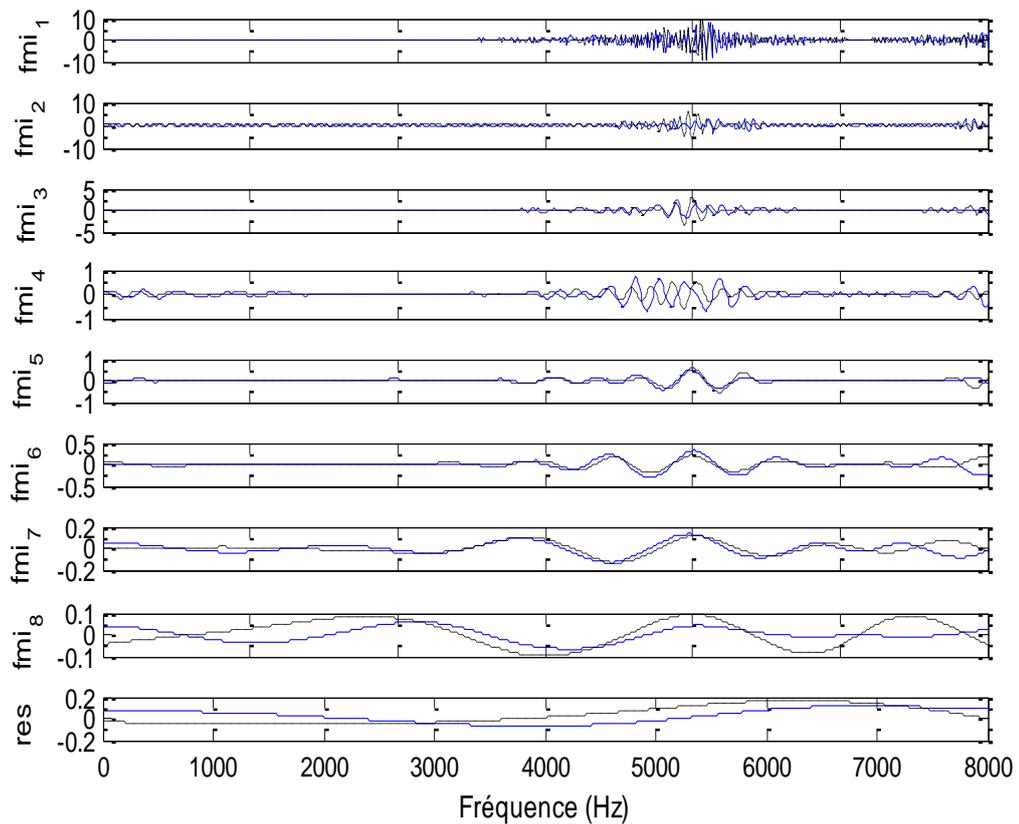
(a) : Transformée de Fourier d'une trame du signal observé 1.



(b) : FMIs et résidu de la TF d'une trame du signale observé 1.

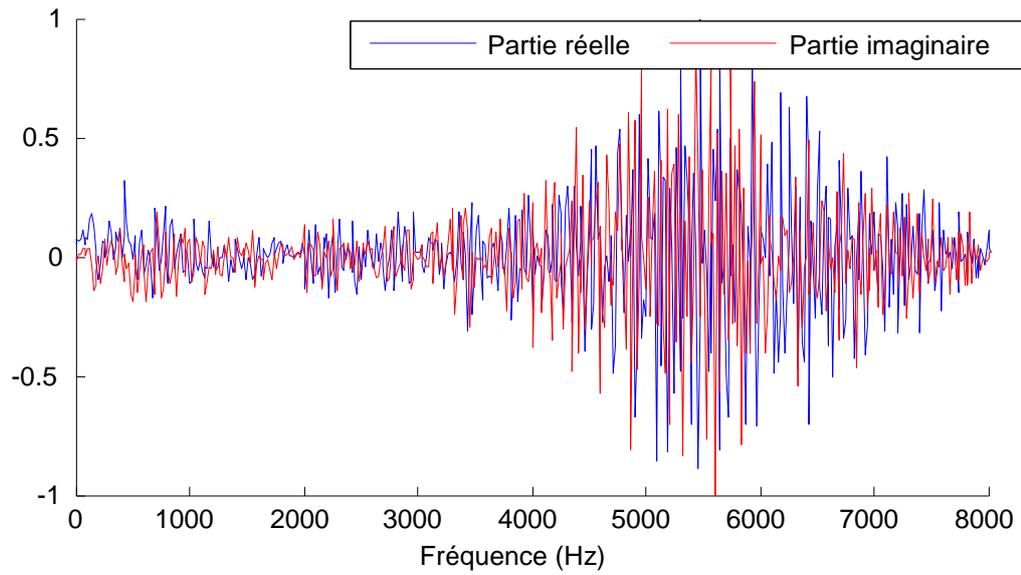


(c) : Transformée de Fourier d'une trame du signal observé 2.

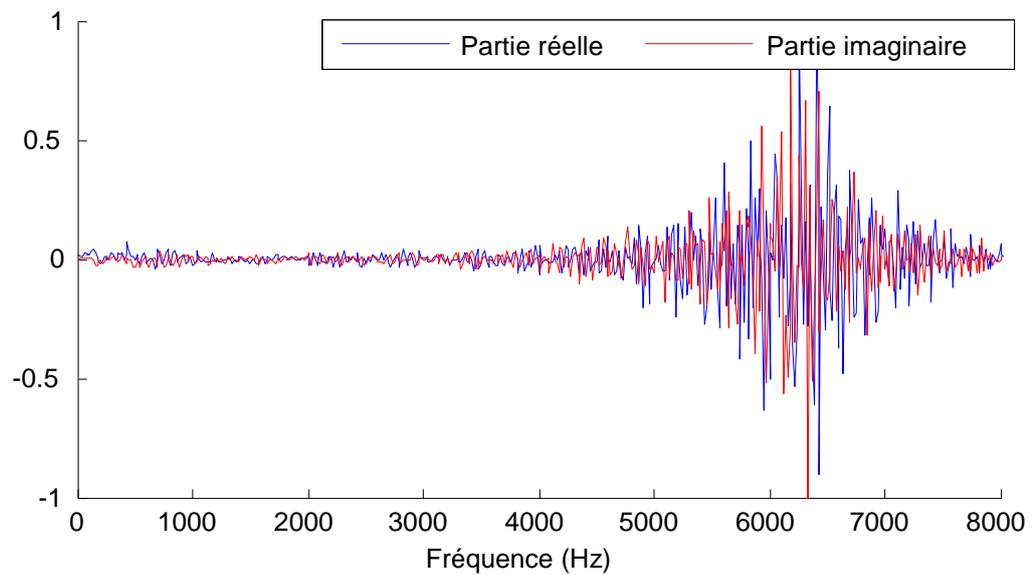


(d) : FMIs et résidu de la transformée de Fourier d'une trame du signal observé 2.

Figure III.6: Parties réelles et imaginaires de la transformée de Fourier des trames extraites du mélange et leurs FMIs correspondantes.

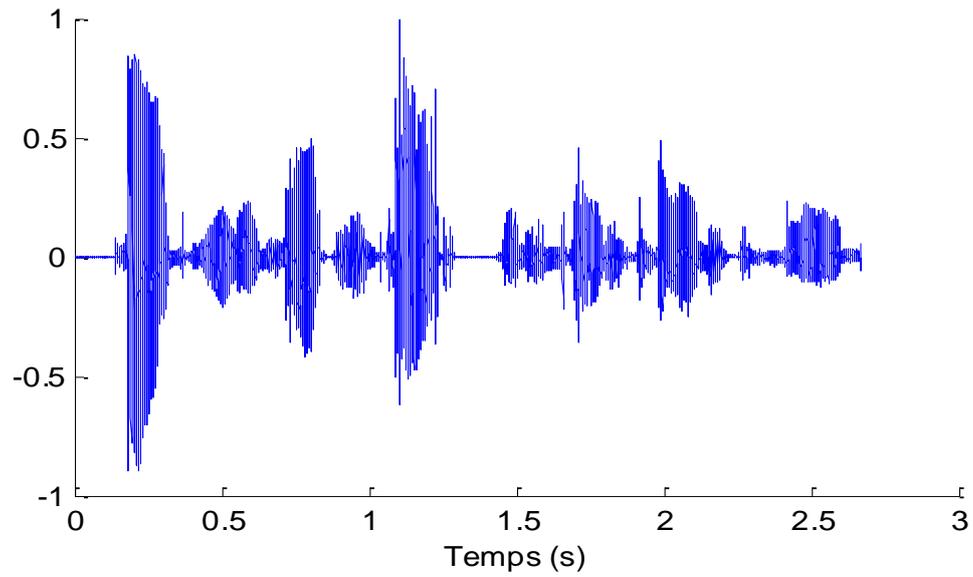


(a) : Trame estimée de la source 1.

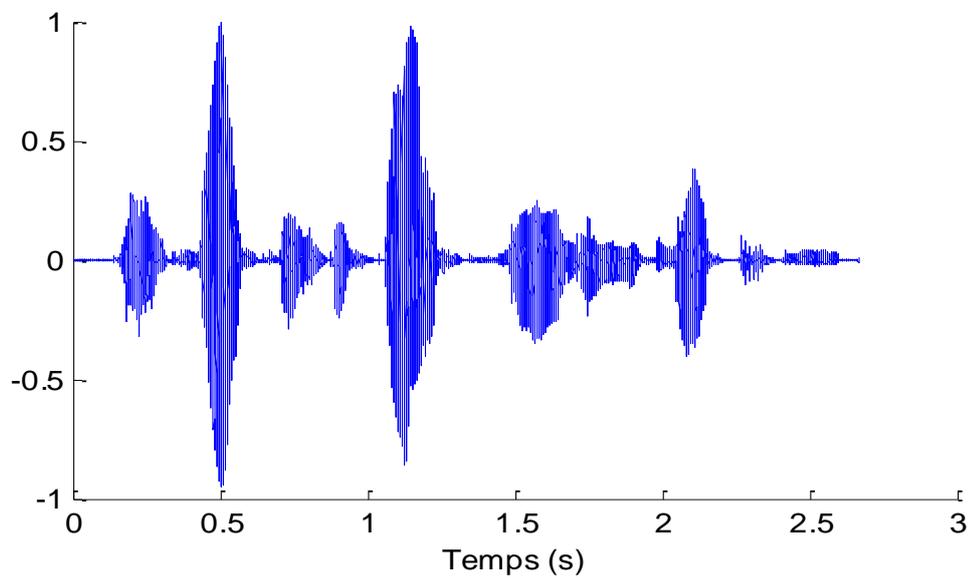


(b) : Trame estimée de la source 2.

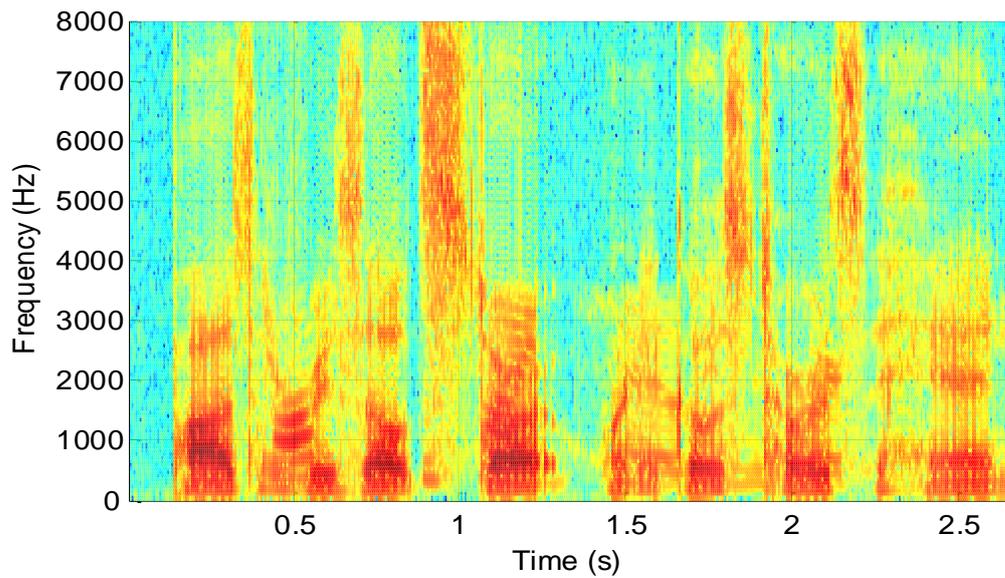
Figure III.7: Estimation des trames des sources 1 et 2 dans le domaine fréquentiel.



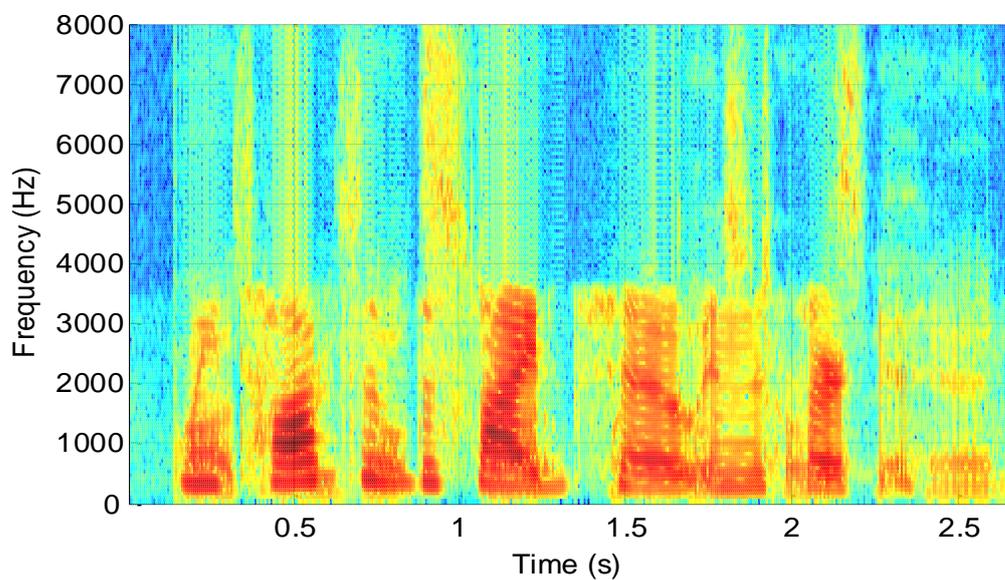
(a) : Source estimée 1.



(b): Sources estimée 2.



(c) : Spectrogramme de la source estimée 1.



(d) : Spectrogramme de la source estimée 2.

Figure III.8: Sources estimées et leurs spectrogrammes.

Les signaux audio sont mélangés selon le modèle décrit dans [51]. Les signaux observés sont acquis par deux microphones repartis dans une pièce. Le milieu de propagation est réverbérant. La localisation des sources s_1 et s_2 et des microphones m_1 et m_2 dans la pièce est illustrée par la figure III.9.

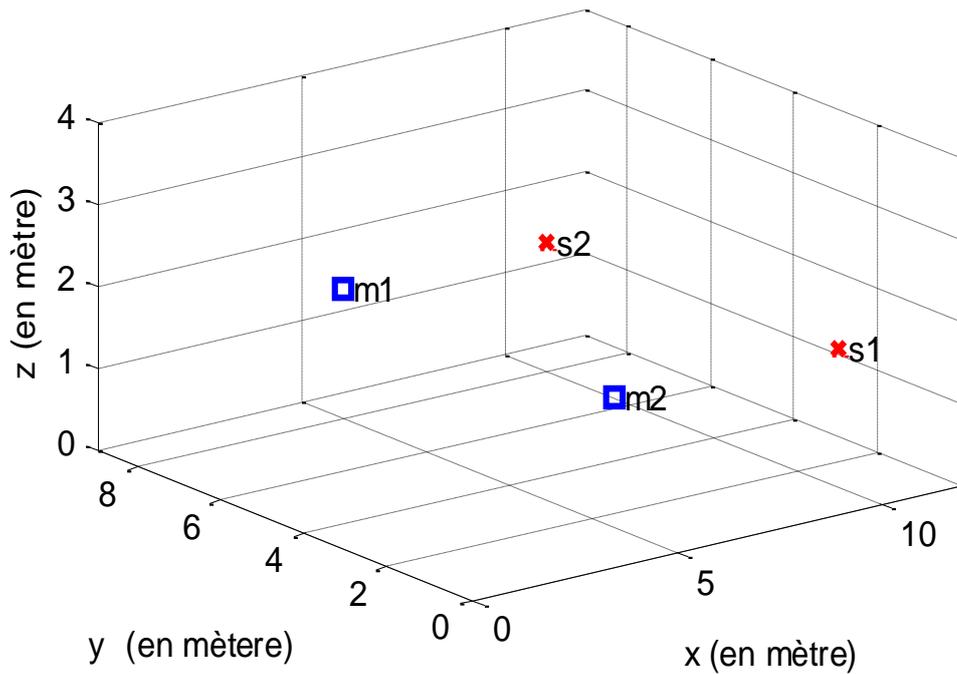
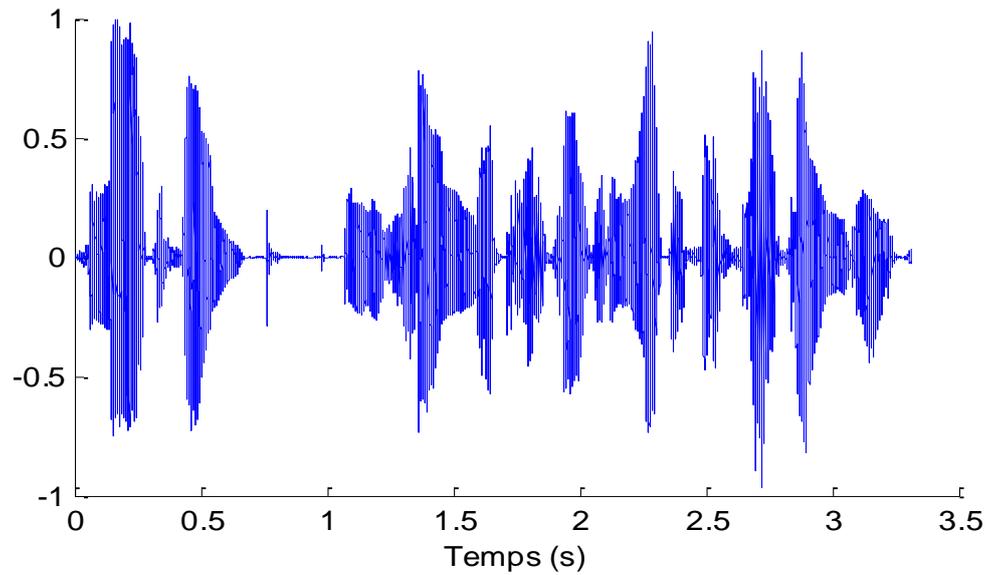
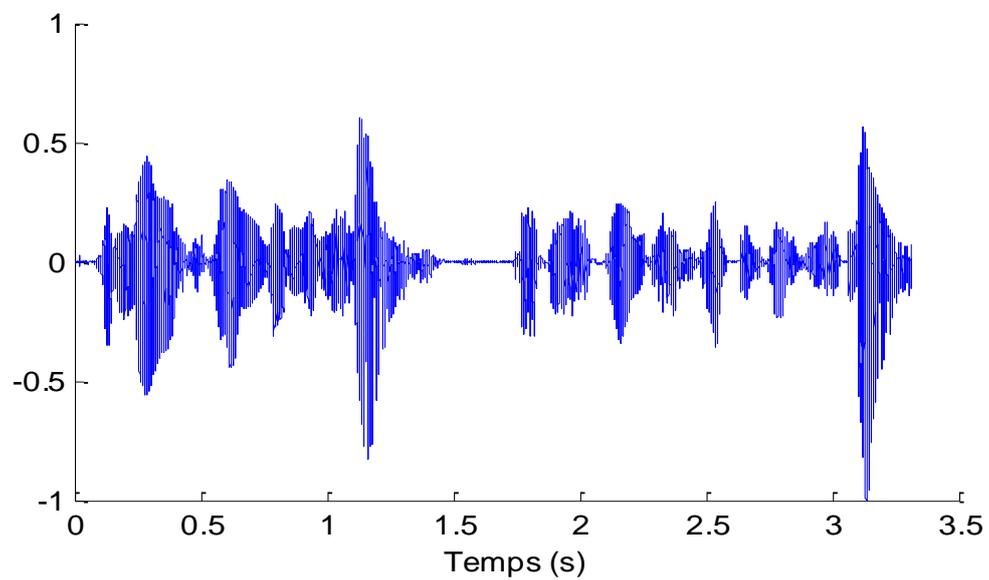


Figure III.9: Configuration spatiale: localisation des sources et des capteurs dans la pièce (x , y et z en mètre).

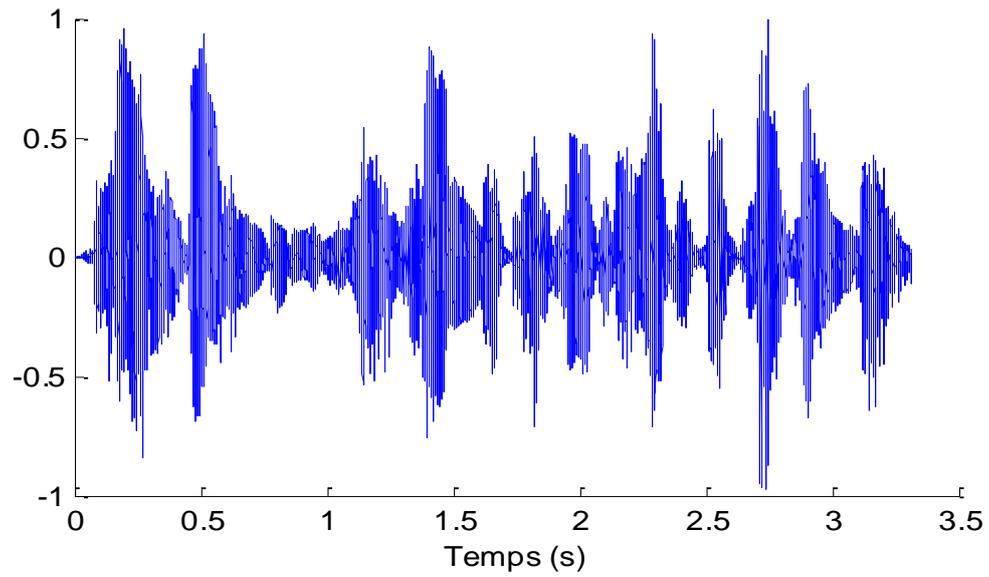
Les figures III.10(a) et III.10(b) montrent les signaux sources, les figures III.10(c) et III.10(d) montrent les signaux observés. Les signaux estimés sont donnée par les figures III.10(e) et III.10(f).



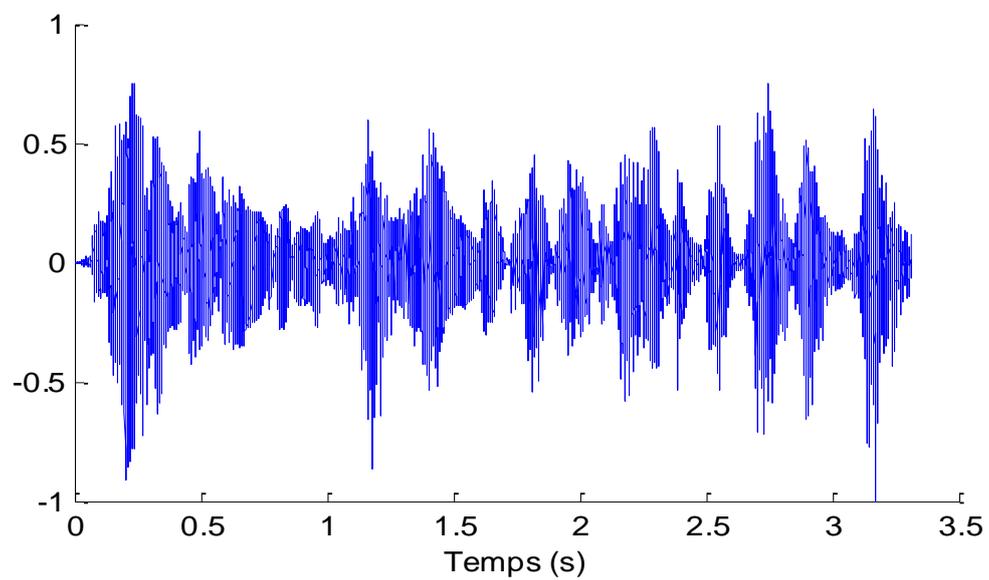
(a) : Représentation de la Source 1.



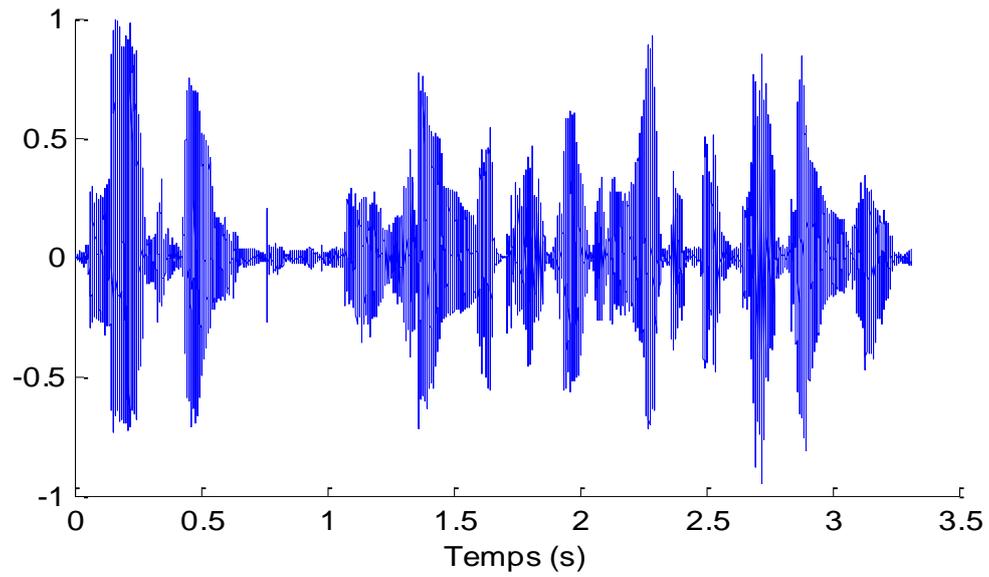
(b) : Représentation de la Source 2.



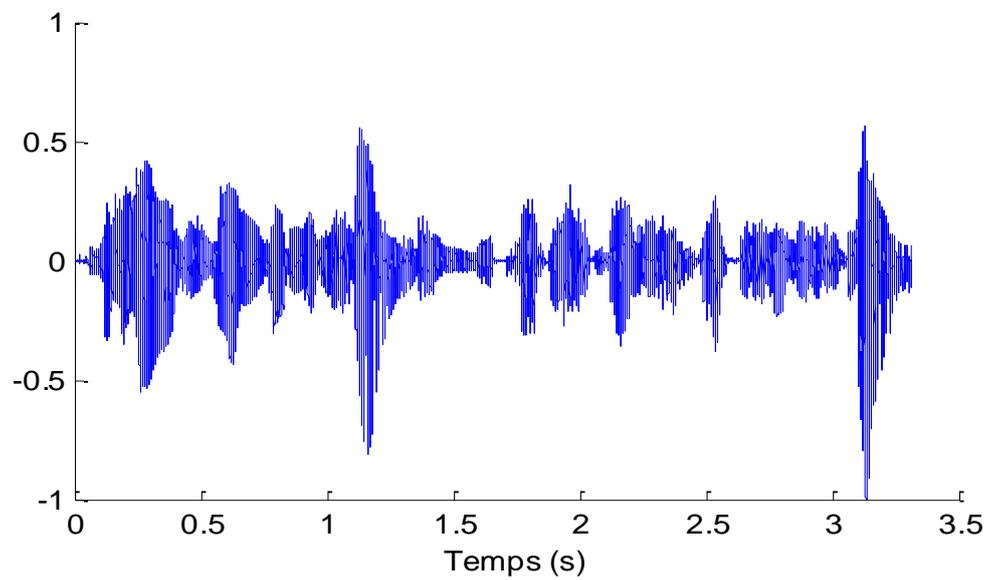
(c) : Signal observée 1.



(d) : Signal observée 2.



(e) : Source estimée 1.



(f) : Source estimée 2.

Figure III.10: Représentation des sources estimées.

Les performances de l'approche proposée sont évaluées et comparées aux performances de la méthode conventionnelle de séparation dans le domaine fréquentiel (ACIF). Deux ensembles de signaux acoustiques comprenant des mélanges convolutifs sont construits.

Le premier ensemble de signaux audio est construit à partir de la base de données TIMIT[53](Cette base de données est un produit de DARPA TIMIT, elle a été conçue pour fournir des données phonético-acoustiques de la parole pour le développement et l'évaluation des systèmes automatiques de la reconnaissance de la parole), en simulant des mélanges convolutifs en utilisant les enregistrements de deux phrases de 3 secondes échantillonnées à 16 kHz prononcées par des locuteurs masculins et féminins.

Un ensemble de 4 mélanges bruyants est simulé en corrompant des mélanges propres à un rapport signal sur bruit (RSB) (en anglais signal-to-noise ratio (SNR)) allant de 5 dB à 10 dB. Le deuxième ensemble de données de parole est construit en simulant des mélanges convolutifs utilisant 20 paires de phrases choisies au hasard dans la base de données NOIZEUS [54].

Comme le montre les figures, les signaux estimés sont fortement semblable aux signaux sources, et permet de voir que la méthode utilise permet de d'avoir les signaux estimés en réservant le contenu fréquentiel des signaux. Pour évaluer la qualité des signaux estimés, nous nous concentrons sur les critères d'évaluations à savoir SIR, SAR et le SDR pour les mélanges convolutifs pour des raisons de simplicité, Le tableau III.1 résume les valeurs de SAR SIR et SDR obtenues en appliquant la méthode ACI-MBE combiné avec DMEB et ACIF.

Afin de mesurer la distorsion entre les sources originales et les sources estimées, le rapport signal sur bruit d'amélioration (improvement signal to noise ration, ISNR) est calculé. L'ISNR est défini comme :

$$ISNR = SNR_{sortie} - SNR_{entrée} \quad (III.20)$$

Le SNR d'entrée et de sortie est défini comme

$$SNR_{entrée} = 10 \log \frac{\sum_t |s(t)|^2}{\sum_t |x(t) - \hat{s}(t)|^2} \quad (III.21)$$

Et

$$SNR_{sortie} = 10 \log \frac{\sum_t |s(t)|^2}{\sum_t |s(t) - \hat{s}(t)|^2} \quad (\text{III.22})$$

Où $x(t)$ est le mélange observé, $s(t)$ est la source originale et $\hat{s}(t)$ est la source estimée.

Tableau III. 1: Résumé les performances de la méthode de résolution de problème de séparation aveugle base sur ACI-MBE combiné avec le DMEB en comparaison avec celle base sur l'ACIF.

		SIR	SAR	SDR	ISNR
SNR= 5 dB	ACI-MBE combiné avec DMEB	18.1	11.2	14.9	7.1
	ACIF	15.7	7.1	11	4.8
SNR=10 dB	ACI-MBE combiné avec DMEB	20.2	14.3	15.1	12.3
	ACIF	15.5	9.3	8.7	8.1

Les résultats du tableau III.1 nous montre que les résultats obtenus dans les critères SIR, SAR et SDR par l'algorithme ACI-MBE combiné avec DMEB plus performances que l'algorithme ACIF, et les résultats pour SNR=10 plus performances que SNR=5.

III.5 conclusion

Dans ce chapitre nous avons présenté une nouvelle méthode combinant les algorithmes DMEB et l'ACI-MBE pour la séparation aveugle de mélanges convolutifs dans le domaine fréquentiel. La DMEB est utilisée pour décomposer les mélanges complexes en un ensemble de FMIs à partir duquel les composantes indépendantes sont extraites à l'aide de l'algorithme ACI-MBE. La méthode proposée a été testée sur des ensembles de signaux audio construits à partir des bases de données TIMIT et NOIZEUS.



Conclusion Générale

Conclusion générale

Dans ce mémoire nous nous sommes intéressés à la résolution du problème de la séparation aveugle de source des mélanges convolutifs de sources de parole. De nombreuses techniques ont été étudiées et simulé fait l'étude de la séparation aveugle de sources de parole.

Le problème de la SAS possède plusieurs degrés de difficulté selon le domaine de résolution au selon le type de mélange.

Au début nous nous sommes intéressés à La décomposition modale empirique qui permet de décomposer un signal non stationnaire et non linéaire en un ensemble de signaux dite FMI (Fonction de Mode Intrinsèque). Il permet d'estimer l'amplitude et la fréquence instantanée pour chaque composante.

DME est une technique innovante et plus avantageuse pour la détection des singularités des signaux par rapport aux autres techniques d'analyse de signaux non linaires et non stationnaires telles que la TF, TFCT et TO.

Ainsi La décomposition en modes empiriques bivariée lequel est extension de la méthode DME pour les signaux complexe, qui donner le même nombre de FMIs pour la partie réelle et la partie imaginaire des signaux à valeurs complexes.

Ensuit nous avons présenté les méthodes classique de la résolution du problème de SAS tell que ACP et ACI et l'analyse en composantes indépendantes par minimisation des bornes de l'entropie (ACI-MBE) qui exploitent la non-circularité et la non-gaussianité.

Dans le dernier chapitre, nous avons combiné les méthodes citées au chapitre 1 et 2, nous avons effectué simulations de la méthode et nous avons montré que cette méthode donne des résultats de simulation acceptables.

Les résultats de simulation ont montré que la méthode ACI-MBE combiné avec DMEB permettent d'avoir des sources estimé fortement semblable aux sources originales. Concernant la qualité des signaux estimés, les résultats montrent qu'ACI-MBE avec DMEB permet d'avoir une estimation plus précise des sources en termes de SAR, SIR et SDR.

Références Bibliographiques

- [1] E. Vincent , (2005) Musical source separation using time-frequency source priors. *IEEE Transactions on Speech and Audio Processing*, 14(1) , 91–98.
- [2] X. Zhang , and B. Hu , (2000) An application of blind signal separation in wireless digital communication. *Journal of China Institute of Communications*, 21(2) , 73–77.
- [3] M. Turk , and A. Pentland , (1991) Face recognition using eigenfaces . *Proceedings of IEEE Conferences on Computer Vision and Pattern Recognition* , Maui, HI, pp. 586–591.
- [4] J.C. Ma , Y.L. Niu , and H.Y. Chen , (2006) *Blind Signal Processing*, National Defence Industry Press , Beijing.
- [5] H.L. Si, and L.M. Zhang , (2002) *Intelligent Visual Image Processing* , Shanghai Science and Technology Education Press, Shanghai.
- [6] H.Z. Cao , and X.C. Yu , (2009) Mixed pixel decomposition . *Journal of Remote Sensing* , 13(2), 217–224.
- [7] S. Choi , (2005) Blind source separation and independent component analysis: a review. *Neural Information Processing-Letters and Reviews*, 6(1), 157.
- [8] L.W. Fan , H.W. Tang , and Y.Y. Tang, (2003) Applying independent component analysis to fMRI data analysis. *Journal of Dalian University of Technology*, 1(4) , 399–402.
- [9] X. Wei , L. Xin , and G. Yihong , (2003) Document clustering based on non-negative matrix factorization.
- [10] G. Rilling , P. Flandrin , P. Gonçalves , J. M. Lilly, «Bivariate Empirical Mode Decomposition ». *IEEE Signal Process. Lett.* **14**(12) 936-939 (2007).
- [11] H. Mahgoun , *analyse non stationnaire des signaux vibratoires dans la surveillance des machines et la prévention des défaillances*. Thèse de doctorat en sciences en Mécanique de Précision, Université FERHAT ABBAS – SETIF UFAS (Algérie), 2013.
- [12] G. Rilling , *Décompositions modales empiriques contributions à la théorie l'algorithmie et l'analyse de performances*. thèse de doctorat, Ecole normale supérieure de Lyon, 2007.

- [13] L.-E. Di Persia , D.-H. Milone , Using multiple frequency bins for stabilization of FD-ICA algorithms. *Signal Process.* **119**(c), 162-168 (2016).
- [14] X. Li , T. Adali, Independent component analysis by entropy bound minimization. *IEEE Trans. Signal Process.* **58**(10) , 5151–5164 (2010).
- [15] P. Xie , S.L. Grant , A Fast and Efficient Frequency-Domain Method for Convolutional Blind Source Separation. *In proceeding of Region 5 Conference, IEEE* (2008).
- [16] A. Hyvarinen and E. OJA. «Independent component analysis :algorithms and applications ».Helsinki university of technology.
- [17] M. Brucher , « *La transformée de Fourier rapide et d'une de ses dérivées* », <http://matthieu-brucher.developpez.com/>, Mai, 2007.
- [18] H. Florent : « *La transformée de Fourier en traitement d'images* », Avril 2007.
- [19] H. Weiping and R. Linggard , “Speech Signal Deconvolution Using wavelets Filter Banks”, WAA '01, Lecture Notes in Computer Science (LNCS), Y. Y. Tang et al. (Eds.), LNCS 2552, pp. 248-256, 2001.
- [20] H. Liang , S. L. Bressler , E. A. Buffalo , R. Desimone · P. Fries. « Empirical mode decomposition of field potentials from macaque V4 in visual spatial attention ». *Biol Cybern.* 2005, vol. 92, p. 380–392.
- [21] M.UB. Altaf , T. Gautama, T. Tanaka , D. P.Mandic, « Rotation Invariant Complex Empirical Mode Decomposition ». *In proceeding of ICASSP07* (2007), pp 1009-1012.
- [22] P. Comon. Independent component analysis, a new concept ? *Signal processing*, 36(3) :287–314, 1994.
- [23] G. Darmois. Analyse générale des liaisons stochastiques : etude particulière de l'analyse factorielle linéaire. *Revue de l'Institut international de statistique*, pages 2–8, 1953.
- [24] E. Bingham and A. Hyvärinen. A fast fixed point algorithm for independent component analysis of complex valued signals. *Journal of Neural Systems*, **10**, 1– 8 (2000).
- [25] T. M. Cover and J. A. Thomas. *Elements of Information Theory*. Wiley- Interscience, New York, NY, USA, 1991.

- [26] S. Ihara . *Information Theory for Continuous Systems*. World Scientific , 1993.
- [27] F.D. Neeser and J.L. Massey, Proper complex random processes with applications to information theory. *IEEE Trans. Inf. Theory*, **39**,1293–1302 (1993).
- [28] B. Picinbono , On circularity. *IEEE Trans. Signal Process*, **42**, 3473–3482 (1994).
- [29] M. Novey and T. Adalı. On extending the complex FastICA algorithm to noncircular sources. *IEEE Trans.Signal Process*. **56**(5) 2148–2154 (2008).
- [30] P. J. Schreier. Bounds on the degree of impropriety of complex random vectors. *Signal Process. Lett*, **15**,190–193 (2008).
- [31] E. Ollila. On the circularity of a complex random variable. *Signal Process. Lett* , **15**, 841–844 (2008).
- [32] E. Ollila and V. Koivunen , Complex ICA using generalized uncorrelating transform. *Signal Process*. **89** (4), 365–377 (2009).
- [33] L. De Lathauwer , B. De Moor, On the blind separation of non-circular sources. *In EUSIPCO* (2002).
- [34] J. Eriksson and V. Koivunen , Complex-valued ICA using second order statistics. In *Machine Learning for Signal Processing , 2004. Proceedings of the 2004 14th IEEE Signal Processing Society Workshop* (2004) pp. 183–192.
- [35] J.-F. Cardoso and A. Souloumiac , Blind beamforming for non-Gaussian signals. In *IEE Proceedings of Radar and Signal Process*. **140**(6) pp. 362–370 (1993).
- [36] A. Hyv'arinen , J. Karhunen, and E. Oja, *Independent Component Analysis* , Wiley, New York (2001).
- [37] S.-C. Douglas , Fixed-point algorithms for the blind separation of arbitrary complex-valued non-Gaussian signal mixtures. *EURASIP J Adv Signal Process*. **2007**(1), 83–83 (2007).
- [38] H. Li , T. Adalı , Gradient and fixed-point complex ICA algorithms based on kurtosis maximization. *In Proc. IEEE Workshop on Machine Learning for Signal Processing (MLSP)* (2006), pp. 85–90.

- [39] M. Novey and T. Adalı, On extending the complex FastICA algorithm to noncircular sources. *IEEE Trans. Signal Process.* **56**(5) pp. 2148–2154 (2008).
- [40] H. Li and T. Adalı , A class of complex ICA algorithms based on the kurtosis cost function. *IEEE Trans. Neural Netw*, vol. **19** (3) 408–420 (2008).
- [41] X.-L. Li and T. Adalı , Complex independent component analysis by entropy bound minimization . *IEEE Tran. Circuits and Systems I: Regular Papers.* **57**(7) 1417–1430 (2010).
- [42] M. KEMIHA , « *séparation de mélange de signaux de parole* ». Thèse de doctorat en électronique. Université MOHEMED SEDDIK BEN YAHIA- JIJEL ,2017.
- [43] T. Adalı , H. Li, M. Novey , and J.-F. Cardoso , Complex ICA using nonlinear functions. *IEEE Trans. Signal Process.* **56** (9) 4536–4544 (2008).
- [44] E.-T. Jaynes , Information theory and statistical mechanics , *Physical review.* **106**(4), 620–630 (1957).
- [45] J. Herault , and J. Jutten . « Space or time adaptive signal processing by neural network models », in AIP Conference Proceedings 151 on Neural Networks for Computing, American Institute of Physics Inc, 1986, pp. 206–211.
- [46] L. Tong , R. W. Liu, V. C. Soon , Y. F. Huang , “Indeterminacy and identifiability of blind identification”, *IEEE Trans. on Circuit and Systems*, 499-509, 1991.
- [47] I. Bradaric , A. P. Petropulu, and K. I. Diamantaras , “On resolving the column permutation ambiguity in the estimates of MIMO system response”, *Conference on Information Sciences and Systems*, 2000.
- [48] E. Bingham , A. Hyv arinen, A fast fixed-point algorithm for independent component analysis of complex valued signals. *Int. J. Neural Syst.* **10**,1–8 (2000).
- [49] M. Kemiha , A. Kacha , Complex blind source separation. *Circuit syst signal process* (2017). Doi 10.1007/s00034-017-0539-0
- [50] E. Vincent , R. Gribonval , and C. F evotte , “Performance measurement in blind audio source separation,” *IEEE Trans. Speech and Audio Proc.*, 2005, to appear.
- [51] Dr.ir. Emanu , A.P. Habets Room impulse response Room Impulse Response Generator (2010).

- [52] B. Mijovic , M. De Vos, I. Gligorijevic , S. Van Huffel , Combining DME with ICA for Extracting Independent Sources from Single Channel and Two-Channel Data. *In proceeding of 32nd Annual International Conference of the IEEE EMBS* (2010).
- [53] TIMIT database. <https://catalog ldc.upenn.edu/ldc93s1>.
- [54] NOIZEUS database <http://ecs.utdallas.edu/loizou/speech/noizeus/>
- [55] M. Misiti , Y. Misiti, G. Oppenheim , J-M. Poggi , Wavelet Toolbox , For Use with MATLAB , 1997.

Résumé

La Séparation aveugle de sources (SAS) est un sujet de grand intérêt dans le domaine du traitement du signal. La séparation aveugle de source consiste à estimer les signaux de sources uniquement à partir des mélanges observés. Mot aveugle signifie on n'a pas besoin d'information sur les signaux source original sauf leurs indépendances statiques. Dans cette mémoire, nous étudiée la séparation aveugle de mélanges convolutifs de Sources. Pour la séparation des mélanges de parole. Nous avons présenté le principe de nouvelle méthode qui combiné la décomposition en modes empiriques bivariée (DMEB) et l'analyse en composante indépendantes basée sur la minimisation des bornes de l'entropie (ACI-MBE).

Abstract

Blind source separation (BSS) is a subject of great interest in the field of signal processing. Blind source separation consists in estimating the source signals only from the observed mixtures. Blind word means no information is needed about the original source signals except their static independence. In this memory, We studied the blind separation of convolutional mixtures of Sources. For the separation of speech mixtures. We have presented the principle of a new method which combines the bivariate empirical mode decomposition (BEMD) and independent component analysis based on the entropy bound minimization (ICA-EBM).

المخلص

يعد فصل المصدر الأعمى موضوعًا ذا أهمية كبيرة في مجال معالجة الإشارات. يتكون فصل المصدر الأعمى من تقدير إشارات المصدر فقط من المخاليط المرصودة. تعني الكلمة العمياء عدم الحاجة إلى معلومات حول إشارات المصدر الأصلية باستثناء استقلاليتها الثابتة. في هذه المذكرة ، درسنا الفصل الأعمى للخلائط التلافيفية للمصادر. لفصل مخاليط الكلام. لقد قدمنا مبدأ الطريقة الجديدة التي تجمع بين أسلوب التحلل التجريبي ثنائي المتغير وتحليل المكون المستقل بناءً على التقليل المرتبط بال انتروبيا.