

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

University Mohammed Seddik Ben Yahia - JIJEL



Faculté des Sciences et de la Technologie
Département d'Automatique

Mémoire de fin d'étude
Présenté pour l'obtention du diplôme de

Master Académique
En Automatique

Option : Automatique et Informatique Industrielle

Thème

FastICA basé sur la minimisation du
maximum de vraisemblance pour la
Séparation Aveugle de Source

Soutenu 19 juillet 2019

Présenté par:

- ❖ Bouklab Hanane
- ❖ Boulassel Anfel

Encadré par:

Dr. Kemiha Mina

Année universitaire : 2018/2019



Dédicaces

Je dédie ce travail en premier lieu à mon père Aissa qui a su me donner les bonnes bases pour affronter la vie, et à qui je dois tout simplement tout.

Mes dédicaces vont aussi pour ma chère mère Yamina la plus courageuse des femmes, à mes frères « yazid », « chaabane », « nouredine », « hossam ».

Ainsi que mes sœurs « Nassira », « wassila », « Ibtissam », « Amel ».

Aussi, je dédie ce travail à mon très chère Mari « Abdelkader », à qui j'exprime toute ma reconnaissance et ma profonde gratitude, pour sa générosité, son sacrifice au quotidien et son soutien et encouragements tout au long de me moi.

Enfin, je ne peux oublier pas tous l'étudiants master 2 automatique de promotion 2019.

Hanane

Dédicaces

D'un sentiment plein d'amour et fidèle , je dédie ce travail

A mes chères parents : Mohamed et Nadia, pour votre amour, votre compréhension, votre patience et votre tendresse sont toujours pour moi sans limite ,vous m'avez soutenu le long de mes études et vous avez tout sacrifié pour ma réussite , que Dieu vous garde en bon santé.

À mes sœurs Samia, Karima, Hanane, Amira, Khalissa ,Rawan et ma famille que j'adore, à tous mes neveux et nièces .

Enfin , je voudrais remercier tous mes amis et collègue qui étaient à mes cotés pendant ce temps.

Plan de travail du mémoire

Ce mémoire est articulé sur trois chapitres :

❖ Dans le premier chapitre, on rappelle la définition de la séparation aveugle de sources, en expliquant sans principe et nous donnons aussi son modèle mathématique puis citer les domaines d'application de SAS, nous présenterons les types du mélange, quelques hypothèses et les différents critères d'indépendance utilisés.

❖ Dans le deuxième chapitre, nous proposons de quelques méthodes de SAS et nous allons présenter les principalement utilisés pour résoudre ce problème

❖ Le chapitre trois expose les résultats de quelques exemples de simulation pour chaque algorithme étudié (FastICA, ICA), ainsi que la mesure de performance.

❖ Enfin, nous terminerons ce manuscrit par une conclusion générale dans laquelle sont résumés les travaux présentés dans cette mémoire et sont abordées les perspectives qu'ouvrent ces derniers pour de futurs travaux de recherches prometteurs.

Liste des figures

	N	Titpage
Figure I.1	Phénomène de mélanges de signaux.....	6
Figure I.2	Configuration générale de la séparation aveugle de sources.....	7
Figure I.3	Illustration d'un processus de séparation de deux sources à partir de deux observations.....	13
Figure II.1	Orthogonalité de deux droite D et P	22
Figure II.2	But d ICA	27
Figure III.1	Représentation des signaux sources.....	38
Figure III.2	Représentation des spectrogrammes des signaux source.....	40
Figure III.3	Représentation des signaux observés.....	42
Figure III.4	Représentation des signaux estimée.....	44
Figure III.4	Représentation spectrogrammes des sources estimées.....	46

Introduction Générale

La séparation de sources consiste à restaurer un ensemble de signaux sources à partir d'observations qui correspondent à des mélanges de ces sources. Les observations sont des mélanges des signaux sources reçues par des capteurs (microphone, sondes, cameras, antennes...).

La Séparation de Sources est dite Aveugle (SAS) lorsqu'un minimum d'information a priori est disponible. Le problème de SAS date du début des années 1980, il a été formalisé par les travaux de Ans, Hérault et Jutten[1] dans le cadre d'études neurobiologiques et peut-être indépendamment par Bar-Ness[1] dans le domaine des communications.

Ceci a suscité depuis de nombreuses publications et l'engouement de plusieurs communautés scientifiques. Les domaines d'application de la SAS sont variés : l'acoustique, l'audio, la parole, le domaine biomédical, l'astrophysique, la classification d'images, les télécommunications.

La difficulté de résolution du problème de la séparation de sources est reliée directement à la manière dont les sources sont mélangées à savoir mélange instantané ou convolutifs, et aussi la nature du mélange déterminée, sou-déterminée ou sur-déterminé. La difficulté est liée aussi au domaine de résolution du problème temporelle ou fréquentielle, ou selon les statistiques utilisées à savoir statistique d'ordre deux ou statistique d'ordre supérieure.

Plusieurs algorithmes ont été proposés pour résoudre ce problème de SAS. La méthode classique la plus répandue pour la résolution du problème de la SAS est appelée ICA (Analyse en composantes indépendantes).

Depuis plus d'une décennie, une petite communauté du domaine du traitement du signal développe des algorithmes pour l'analyse en composantes indépendantes et la séparation de sources. Dans ce mémoire, nous sommes intéressés à la résolution du problème

de la SAS basé sur la méthode FastICA basé sur la minimisation du maximum de vraisemblances.

La méthode FastICA basé sur le maximum de vraisemblance présentée est la méthode la plus utilisé pour résoudre les problèmes de la séparation aveugle des sources. A cause de ces avantage en terme de temps de calcule, d'efficacité ainsi que sa simplicité.

Dans ce travail, nous introduisant la méthode FASTICA basé sur la minimisation de du maximum de vraisemblances dans une problématique de séparation aveugle de source, nous nous somme intéresser aux mélanges instantanées des signaux de parole.

Les résultats de résolution de problème de la séparation aveugle de source (SAS) par la méthode FastICA basé sur le maximum de vraisemblance sont comparés avec celle obtenue par l'application de la méthode ACI (la méthode classique). Les performances des signaux estimées issue des deux méthodes sont comparés en en termes de qualité en utilisant BSSeval-toolbox, l'évaluation de performances de la méthode utilisés sont effectué dans un environnement bruité et non bruité.

Chapitre I

Généralités sur la séparation aveugle des sources

I.1. Introduction

La Séparation Aveugle de Sources (SAS) consiste à estimer les signaux sources qui sont à l'origine de ces mélanges à partir de signaux donnés qui sont des mélanges. L'estimation est effectuée sans informations a priori d'où le terme "aveugle".

La séparation aveugle de sources occupe un volume très important dans le traitement du signal, elle utilise de nombreuses parties de la théorie de signal. Nous allons quelques notions de base de la séparation de sources ainsi les différentes définitions, les hypothèses et les types de mélanges.

Nous présentons l'état de l'art de la SAS, nous présentons aussi les fondements de la séparation telle que les types des mélanges et les hypothèses existant dans la littérature.

I.2. Applications

La séparation de sources est l'objet de développements accrus étant donné l'intérêt qu'elle présente dans plusieurs situations et dans différentes applications. Dans ce paragraphe, nous essaierons d'énumérer quelques applications de séparation de sources :

- En biomédecine, pour l'ECG par exemple, une étude récente a été développée [1]. Par ailleurs, Deville [2] présente un panorama des applications biomédicales des méthodes de séparation aveugle de source des signaux ECG et EEG.
- En astronomie et en traitement d'images astronomiques, la séparation de source a été employée par Nuzillard [3].

➤ Dans [4] et [5] une solution du problème de la séparation aveugle de sources a été présenté, avec application aux signaux audio.

➤ En électrotechnique, la séparation de sources a aussi été utilisée ; Capdevielle et al. [6], Fabry [7] et Gellé et al. [8] la méthode de la SAS a été appliquée aux machines tournantes.

➤ Un autre domaine de séparation de sources est la télécommunication. J. M. F. Xavier [9] adopte une modélisation.

➤ En rehaussement de parole, W. Bobillet et al. [10] utilisent également la séparation de sources ; ils prennent en compte le bruit (coloré additif) et essaient de le supprimer.

➤ Dans son système optique, composé de microprocesseur, d'une électronique de puissance (50W) et d'une antenne travaillant à 10GHz, Smith [11] et al. ont implémenté et utilisé une approche adaptative de séparation de sources.

I.3. Principe

Le plus souvent dans notre environnement, plusieurs sources de signal (point de départ) émettent dans cet environnement des signaux qui, en se propageant vers un Point d'arrivée [12], subissent une transformation par le milieu de propagation et s'associent pour composer des mélanges complexes.

Typiquement, on retrouve ce problème en traitement de signal sous le thème de séparation de sources comme le montre **la figure(1.1)**.



FIG1.1 : Phénomène de mélanges de signaux

Le problème de la SAS est décrit comme suite : soit $\mathbf{s}(t) = [s_1(t), \dots, s_N(t)]^T$ un vecteur de N sources indépendantes à l'instant t . Le vecteur $\mathbf{x}(t) = [x_1(t), \dots, x_M(t)]^T$ de M observation de mixture instantanée est défini par :

$$\mathbf{x}(t) = \mathbf{A}\mathbf{s}(t) \quad (1.1)$$

\mathbf{A} Est la matrice de mixture 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

$$\mathbf{z}(t) = \mathbf{W}\mathbf{x}(t) \quad (1.2)$$

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

La figure (1.2) illustre le problème de la SAS.

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.

Et selon les caractéristiques de sources considérées :

- stationnaires, cyclo-stationnaires ou non-stationnaires.
- Statistiquement mutuellement indépendants ou corrélés ou non.

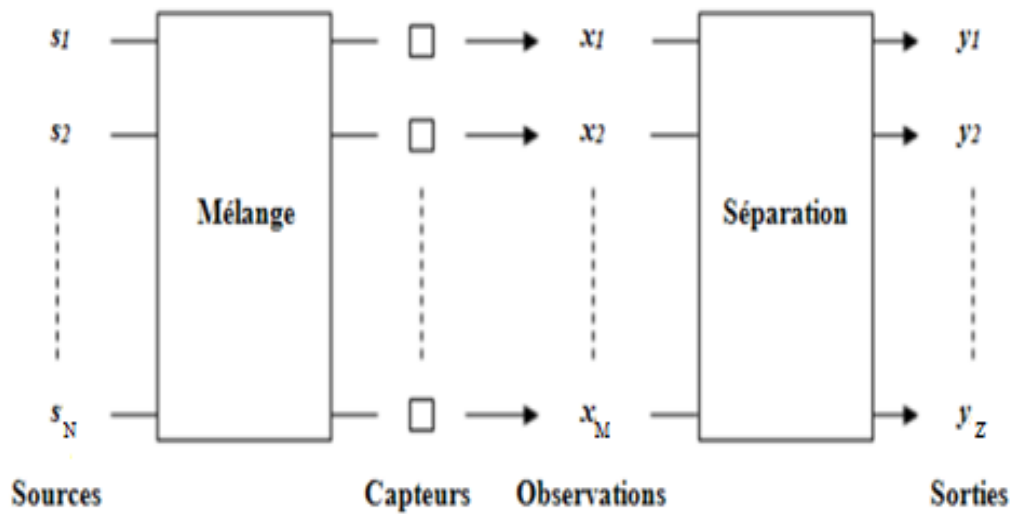


FIG. 1.2 : Configuration générale de la séparation aveugle de sources.

I.4. Les hypothèses nécessaires

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

I.4.1. Hypothèse 1

Presque toutes les procédures de séparation aveugle de sources supposent que, Statistiquement les sources sont mutuellement indépendantes. Différents critères de dépendance peuvent être trouvés dans la littérature à savoir :

1.4.1.1. Cumulant

Soit la première fonction caractéristique qui notée par $\phi_u(\mathbf{v})$ d'une variable aléatoire u définis par l'équation suivante :

$$\phi_u(\mathbf{v}) = \mathbf{E}[e^{i\mathbf{u}\mathbf{v}}] \quad (1.3)$$

Soit la deuxième fonction caractéristique qui notée par $\psi_u(\mathbf{v})$ variable aléatoire u définis par l'équation suivante :

$$\psi_u(\mathbf{v}) = \ln(\phi_u(\mathbf{v})) \quad (1.4)$$

Les cumulants (d'ordre q) de la variable aléatoire u sont définis par l'équation suivante :

$$cum_q(\mathbf{u}) = (-j)^q \frac{d^q \psi_{\mathbf{u}}(v)}{d(v)^q} \Big|_{v=0} \quad (1.5)$$

✓ Si u_i sont des variables indépendantes, alors les cumulants croisés d'ordre positif de u_i sont nuls.

✓ Si u_i est une variable aléatoire gaussienne, alors tous ses cumulants d'ordre $q > 2$ sont nuls.

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.

1.4.1.2. 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 :

$$D(p_u, p_v) = \int_{-\infty}^{+\infty} p_u(x) \log \frac{p_u(x)}{p_v(x)} dx \quad (1.6)$$

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.

1.4.1.3. Information mutuelle

Cette méthode calcule l'information mutuelle entre un vecteur et ses composantes aléatoires par l'équation suivante :

$$I(\mathbf{p}_u) = \int p_u(\mathbf{v}) \log \frac{p_u(\mathbf{v})}{\prod_i^k p_{u_i}(v_i)} d\mathbf{v} \quad (1.7)$$

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

L'information mutuelle est mesurée, la divergence de Kullback-Leibler entre $p_u(\mathbf{v})$ et $\prod_{i=1}^k p_{u_i}(v_i)$, c'est-à-dire $I(p_u) = 0$.

1.4.2. Hypothèse 2

Dans Le cas d'un processus, au plus une source peut être gaussienne. Différents critères de dépendance peuvent être trouvés dans la littérature à savoir :

1.4.2.1. Mesures de non gaussianité

Pour utiliser non gaussianité dans estimation ICA, nous devons avoir une mesure quantitative de non gaussianité d'un variable aléatoire dites y . Pour simplifier, nous supposons qu' y est centré (zéro-moyenne) et a le désaccord égal à 1 [13].

1.4.2.1.1. Néguentropie conjointe

La néguentropie est définie par :

$$J(\mathbf{u}) = H(\mathbf{u}_g) - H(\mathbf{u}) \quad (1.8)$$

De la même manière, on définit la néguentropie marginale entre une variable aléatoire quelconque u_i et une gaussienne u_{gi} par $J(u_i) = H(u_{gi}) - H(u_i)$. 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 [14].

1.4.2.1.2. Kurtosis

Appelé aussi cumulant d'ordre 4 d'une variable aléatoire. Le kurtosis d'une variable aléatoire centrée ($\mathbf{X} = \mathbf{Y} - E[\mathbf{Y}]$) est défini comme suit :

$$kurt(\mathbf{X}) = E[\mathbf{X}^4] - 3(E[\mathbf{X}^2])^2 \quad (1.9)$$

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 :

$$\mathbf{kurt}(X) = E[X^4] - 3 \mathbf{(1.10)}$$

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.

I.5. Détermination du mélange

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 :

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

I.6. 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 distingue les types de mélanges suivants :

- mélange instantané.
- mélange anéchoïques.

➤ Mélange convolutifs.

I.6.1. Mélange instantané

Le mélange instantané c'est le cas le plus simple et le plus répandu dans la littérature. Les observations s'écrivent comme une combinaison linéaire des sources. Le mélange est donné par l'équation :

$$X_i(t) = \sum_{j=1}^N (a_{ij}S_j(t)) \quad (1.11)$$

Avec $i = [1, 2, 3, \dots, M]$.

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

$$X(t) = AS(t). \quad (1.12)$$

Ou :

- $S(t) = [s_1(t), \dots, s_N(t)]^T$.

est le vecteur des N sources inconnues au Temps t.

- $X(t) = [x_1(t), \dots, x_M(t)]^T$.

est le vecteur des M signaux observés au Temps t.

- A est la matrice qui possède les coefficients de la combinaison linéaire des sources a_{ij} .

I.6.2. Mélange anéchoïques

Les mélanges linéaires à retard, dits aussi anéchoïques, sont quant à eux une généralisation du cas précédent. Dans ce cas les observations s'écrivent comme une combinaison des sources à des échantillons décalés.

Le mélange est donné par l'équation :

$$\mathbf{X}_i(\mathbf{n}) = \sum_{j=1}^N (\mathbf{a}_{ij} \mathbf{s}_j(\mathbf{t} - \mathbf{n}_{ij})) \quad (1.13)$$

Avec $i = [1, 2, 3, \dots, M]$.

- \mathbf{a}_{ij} représenter les coefficients de la combinaison linéaire.
- \mathbf{n}_{ij} représente le retard.

Par exemple pour des signaux acoustiques lorsque le temps de propagation jusqu'au capteur n'est pas négligeable.

I.6.3. Mélange convolutifs

La transformation subie par les sources dans le canal de propagation sera définie par l'opération de convolution, cette opération nécessite l'utilisation d'un filtre. Mesurons un signal mélange qui est égal à la somme des filtres des sources sur ce capteur.

Le mélange est donné par l'équation :

$$\mathbf{X}_i(\mathbf{t}) = \sum_{j=1}^N (\mathbf{a}_{ij} * \mathbf{s}_j = \sum_{k=1}^N (\mathbf{f} \mathbf{a}_{ij}(k) \mathbf{s}_j(\mathbf{t} - k))) \quad (1.14)$$

Avec $i = [1, 2, 3, \dots, M]$.

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

$$X(t) = A(t) * S(t) \text{ (1.15)}$$




FIG.1.3 : Illustration d'un processus de séparation de deux sources à partir de deux observations.

I.7. Ambiguïté de séparation

Séparer aveuglement les sources contenues dans leurs mélanges sont entaché d'ambiguïté. En effet, la séparation peut être obtenue avec une infinité de solutions [15]. Nous allons, dans les sous-sections suivantes, montrer l'ambiguïté du modèle de séparation. Nous montrons par ailleurs pour chaque cas, instantané ou convolutifs, le comportement de l'ambiguïté et son incidence sur la reconstruction des sources.

I.7.1. 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.

$$\mathbf{x} = \sum_{j=1}^P \mathbf{S}_j \mathbf{h}_j \quad (1.16)$$

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

$$\begin{aligned} \mathbf{x} &= \mathbf{S}_1 \mathbf{h}_1 + \mathbf{S}_2 \mathbf{h}_2 + \dots + \mathbf{S}_p \mathbf{h}_p \\ &= \mathbf{S}_2 \mathbf{h}_2 + \mathbf{S}_1 \mathbf{h}_1 + \dots + \mathbf{S}_p \\ \mathbf{h}_p &= \begin{bmatrix} \mathbf{h}_{12} \mathbf{S}_2 \\ \vdots \\ \mathbf{h}_{p2} \mathbf{S}_2 \end{bmatrix} + \begin{bmatrix} \mathbf{h}_{11} \mathbf{S}_1 \\ \vdots \\ \mathbf{h}_{p1} \mathbf{S}_1 \end{bmatrix} + \dots + \begin{bmatrix} \mathbf{h}_{1p} \mathbf{S}_p \\ \vdots \\ \mathbf{h}_{pp} \mathbf{S}_p \end{bmatrix} \\ &= \begin{bmatrix} \mathbf{h}_{12} \mathbf{h}_{11} & \dots & \mathbf{h}_{12} \\ \mathbf{h}_{12} \mathbf{h}_{11} & \dots & \mathbf{h}_{12} \\ \vdots & \vdots & \ddots \\ \mathbf{h}_{12} \mathbf{h}_{11} & \dots & \mathbf{h}_{12} \end{bmatrix} \begin{bmatrix} \mathbf{S}_2 \\ \mathbf{S}_1 \\ \vdots \\ \mathbf{S}_p \end{bmatrix} \quad (1.17) \end{aligned}$$

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 H et les nouvelles vectrices sources S et le vecteur mélange s'écrira :

$$\begin{aligned}
 \mathbf{X} &= \tilde{\mathbf{H}}\tilde{\mathbf{s}} \\
 &= \mathbf{HP}\tilde{\mathbf{s}} \\
 &= \mathbf{HPP}^{-1}\mathbf{s} \\
 &= \mathbf{HI} \\
 &= \mathbf{Hs} \quad (1.18)
 \end{aligned}$$

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.

I.7.2. 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 :

$$\begin{aligned}
 \mathbf{X} &= \mathbf{S}_1\mathbf{h}_1 + \mathbf{S}_2\mathbf{h}_2 + \dots + \mathbf{S}_p\mathbf{h}_p \quad (1.19) \\
 &= \left(\frac{1}{\alpha_1}\mathbf{s}_1\right)(\alpha_1\mathbf{h}_1) + \left(\frac{1}{\alpha_2}\mathbf{s}_2\right)(\alpha_2\mathbf{h}_2) + \dots + \left(\frac{1}{\alpha_p}\mathbf{s}_p\right)(\alpha_p\mathbf{h}_p)
 \end{aligned}$$

$$= \begin{bmatrix} \alpha_1 h_{11} & \alpha_2 h_{12} & \dots & \alpha_p h_{1p} \\ \alpha_1 h_{21} & \alpha_2 h_{22} & \dots & \alpha_p h_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ \alpha_1 h_{p1} & \alpha_2 h_{p2} & \dots & \alpha_p h_{pp} \end{bmatrix} \begin{bmatrix} S_1 \\ \alpha_1 \\ S_2 \\ \alpha_2 \\ \vdots \\ S_p \\ \alpha_p \end{bmatrix}$$

I.7.3. Ambiguïté de filtrage

Le plus souvent, la séparation de mélanges convolutifs de sources est ramenée à un ensemble de séparations instantanées. Ceci est réalisé par le passage dans le domaine de Fourier, où nous obtenons un modèle de mélange instantané à chaque fréquence. Comme nous l'avons vu, des ambiguïtés peuvent ainsi se produire à chaque fréquence ce qui implique un filtrage des signaux dans le temps; Ceci bien évidemment sans remettre en cause le procédé de séparation de sources.

$$\begin{aligned} x &= \mathbf{h} * \mathbf{s} \xrightarrow{Tf} x(\mathbf{f}) = (\mathbf{H}(\mathbf{f})\mathbf{F}(\mathbf{f})) (\mathbf{F}(\mathbf{f})^{-1}\mathbf{s}(\mathbf{f})) \\ &= (\mathbf{H} * \mathbf{F}) * (\mathbf{F}^{-1} * \mathbf{s}) = \widetilde{\widetilde{\mathbf{H}}} * \widetilde{\widetilde{\mathbf{s}}} \quad (1.20) \end{aligned}$$

En conséquence, la séparation des mélanges convolutifs peut être accomplie à un filtrage pressans remettre en cause la démarche de séparation. Il faut par ailleurs noter que cette ambiguïté est la plus complexe et présente une grande gêne à la reconstruction des sources.

$$\begin{aligned} \mathbf{x} &= (\mathbf{HDP})(\mathbf{P}^{-1}\mathbf{D}^{-1}\mathbf{s}) \\ &= (\mathbf{HDP})\mathbf{y} \\ &= \mathbf{G}^{-1}\mathbf{y} \quad (1.21) \end{aligned}$$

I.7.4. Ambiguïté complète

Conclusion :

Dans ce chapitre nous avons donné une vue générale sur le problème de la séparation des sources. Nous avons commencé par la définition sur le problème de la séparation de sources et les domaines d'application. Ensuite, nous avons modélisé le problème de la séparation de sources dans le cas des mélanges instantanés et convolutifs. Nous avons ainsi représenté de quelques hypothèses et les différents critères d'indépendance utilisés.

Les méthodes de résolution du problème de SAS

II.1. Introduction

La séparation de source est un problème général dans le traitement du signal dont le principe consiste à retrouver les signaux sources à partir des signaux mélanges.

Ce problème possède plusieurs degrés de difficulté, selon les caractéristiques des sources et surtout du mélange.

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

Aussi, nous nous sommes intéressés à la méthode de séparation appelée FastICA basé sur le maximum de vraisemblance. Avant de présenter le principe de la méthode, nous présentons les définitions de quelques notions de bases.

II.2. Bref historique

➤ dans [12] les auteurs proposent de rechercher d'un sous-espace dans lequel un indice de projection est maximisé est estimée, la contribution est basée sur la méthode FastICA

➤ Le premier travail dans le domaine de séparation aveugle de source a été présenté par Héroult et Jutten dans les années 80 [14].

➤ Les travaux de P. Comon en 1994 ont permis de formaliser le lien entre la méthode d'analyse en composantes indépendantes (ICA) et le problème de la séparation aveugle de source (BSS) dans le cadre d'un mélange linéaire[14].

➤ En 1995 Bell et Sejnowski ont particulièrement popularisé la méthode de l'ICA depuis l'article : « An information-maximization approach to blind separation and blind deconvolution » [14].

II.3. Définitions

Les méthodes de résolutions du problème de la séparation aveugle peuvent être classées selon plusieurs critères à savoir le domaine de résolution, dans le domaine fréquentiel ou temporel, ou les statistiques utilisées savoir statistique d'ordre deux ou d'ordre supérieur.

Avant de présenter les méthodes de résolution, nous présentons quelques définitions.

II.3.1. La corrélation

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

$$\forall t \in \mathbb{R} \quad (x \otimes y) = \int x(\tau) y(\tau + t) d\tau \quad (\text{II.1})$$

Où : τ est le retard.

II.3.2. La décorrélation

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

II.3.3. L'autocorrélation

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

$$\forall t \in R \quad (x \otimes x) = \int x(\tau)x(\tau + t) d\tau \quad (\text{II.2})$$

II.3.4. Espérance mathématique

L'espérance mathématique d'une variable aléatoire réelle est intuitivement la valeur que l'on s'attend à trouver en moyenne.

Dans le cas où la valeur aléatoire possède une densité de probabilité l'espérance est la moyenne des valeurs pondérées par cette densité.

Donc l'espérance mathématique d'une variable aléatoire est l'intégrale de cette variable selon la mesure de probabilité, de l'espace probabilisé de départ [15], elle est définie par la relation suivante :

$$E(X) = \int p_X(x)x dx \quad (\text{II.3})$$

II.3.5. La covariance

La covariance entre deux variables aléatoires est un nombre permettant de quantifier leurs écarts conjoints par rapport à leurs espérances respectives.

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 :

$$\text{cov}(X, Y) = E[(X - \mu_X)(Y - \mu_Y)] \quad (\text{II.4})$$

II.3.6. La Décomposition en valeurs singulières SVD

Soit A une matrice de taille $m \times n$ et de rang r , on peut décomposer A comme suit :

$$A = UDV^T = \sigma_1 u_1 v_1^T + \dots + \sigma_r u_r v_r^T \quad (\text{II.5})$$

Avec :

- U et V deux matrices orthogonales.
- D matrice diagonale formée par les r valeurs singulières $\sigma_1 \dots \dots \dots \sigma_r$.

Pour faire cette décomposition, nous avons suivi les étapes suivantes :

- Etape 01 : calcule les valeurs singulières σ_i .
- Etape 02 : la diagonalisation par la relation suivante $AV_r = U_r D_r$.
- Etape 03 : la décomposition par la relation suivante $A = UDV^T$.

II.3.7. L'orthogonalité

Deux vecteurs x et y d'un espace vectoriel euclidien sont dits orthogonaux si leur produit scalaire est nul.




Figure II.1 : l'orthogonalité de deux droite D et P.

II.3.8. Poursuite de projection

La poursuite de projection est une méthode d'analyse des données multivariées qui relève des statistiques. Donc c'est une méthode statistique d'analyser de données en grande dimension cherchant aux projections sur un espace de dimension faible.

II.3.9. La densité spectral de puissance PDF

La densité spectral de puissance d'un signal est la transformée de Fourier de la fonction d'auto corrélation. Elle représente la répartition de la puissance sur l'axe des fréquences. Donc la densité spectral de puissance définit par la relation suivante :

$$S_x(f) \triangleq \lim_{n \rightarrow \infty} \left(\frac{E[|x_T(f)|^2]}{2T} \right) \quad (\text{II.6})$$

Dans la théorie des processus aléatoires, le théorème de Wiener-Kintchine : la densité spectral de puissance d'un processus aléatoire dont la valeur moyenne et la fonction d'auto corrélation sont invariantes dans le temps est égale à la transformée de Fourier de sa fonction d'auto corrélation statistique [17].

On définit ce théorème par la relation suivante :

$$S_x(f) = \int_{-\infty}^{+\infty} R_{xx}(\tau) e^{-2\pi i f \tau} d\tau \quad (\text{II.7})$$

Il existe deux grandes approches pour l'estimation spectrale. La première contient des méthodes dites non-paramétriques qui sont basées sur le périodogramme. La seconde classe contient des méthodes dites paramétriques qui utilisent un modèle du signal. Par la suite, nous citons quelques méthodes d'estimation de la DSP.

A méthode non paramétrique

➤ **Corrélation** La densité spectral de puissance peut se calcule par la transformée de Fourier de signal lui-même :

$$S_{xx}(f) = \lim_{T \rightarrow \infty} \frac{E[|x(f,T)|^2]}{2T} \quad (\text{II.8})$$

$x(f, T)$ est la transformée de Fourier de la tranche $(-T, +T)$ de la réalisation de signal x

➤ **le periodogramme** est une méthode d'estimation de la densité spectrale de puissance d'un signal. La méthode directe de calcul du periodogramme utilise la transformée de Fourier rapide (*FFT*) du signal.

$$p = \frac{|fft(s)|^2}{N} \quad (\text{II.9})$$

Cette méthode permet de calculer rapidement la densité spectrale de puissance.

➤ **Le périodogramme modifié** Dans le periodogramme modifié, la fenêtrage de pondération est remplacée par une fenêtrage générale

➤ **La méthode de Bartlett** La méthode de Bartlett consiste à moyenner le periodogramme. Elle produit un estimateur consistant du spectre.

B méthodes paramétriques

➤ **Modèle autorégressif (AR)** consiste à modéliser la densité spectrale de puissance par un filtre tous pole. Le model est définit comme suite :

$$X_t = \frac{\delta^2}{|1 + \sum_{i=1}^p a_i z_i|} \quad (\text{II.10})$$

Avec :

Φ : les paramètres du modèle.

C : une constante.

ε_t : un bruit blanc.

➤ **Modèle à moyenne mobile (MA)** consiste à modéliser la densité spectrale de puissance par un filtre tous zéro. Le modèle est défini comme suite :

$$S_{MA} = \delta^2 \left| 1 + \sum_{i=0}^{\alpha} a_i z_i \right|^2 \quad (\text{II.11})$$

➤ **Modèle autorégressif à moyenne mobile (ARMA)** Les modèles ARMA consistent à avoir une partie autorégressive et une partie à moyenne mobile. Le modèle est défini par la formule suivante

$$ARMA = \sum_{i=0}^a b_i |n-1| + \sum_{i=0}^a a_i y(n-1) \quad (\text{II.12})$$

II.4. méthodes classiques de résolution de problème de SAS

II.4.1. Analyse en composantes principales (PCA)

L'analyse en composante principale (PCA) est une méthode de la famille d'analyse des données et plus généralement de la statistique multi-variée qui consiste à transformer des variables corrélées en nouvelles variables décorrélées les unes des autres [12], ces nouvelles variables sont les composantes principales.

L'espace PCA est constitué de K composantes, les composantes principales sont orthonormées, non corrélées et représentent la direction de la variance maximale.

Les premières composantes principales (PC_1) de l'espace PCA représentent la direction de la variance maximale des données, la deuxième composante principale (PC_2) possède la plus grande variance.

La PCA peut être utilisée comme solution de mélange instantanée dans la séparation aveugle de sources. Il existe deux méthodes pour calculer les composantes principales, la première dépend du calcul de la matrice de covariance, tandis que la seconde utilise la méthode SVD [12].

II.4.2. Le blanchiment

C'est une étape importante pour un certain nombre de méthodes de la SAS, Dans la recherche d'un vecteur aux composantes indépendantes, il est fréquent de commencer par une étape dite de blanchiment des observations [13].

Un vecteur est dit "blanc" si ses composantes sont décorrélées et de puissance égale à un, pour décorrélérer les composantes du vecteur $X(t)$ en forçant leur puissance à être unitaire. Pour ce faire, on doit chercher une matrice W dite de "blanchiment" rendant le vecteur $X_b(t) = WX(t)$ blanc, ce qui implique que la matrice de covariance du vecteur $X_b(t)$ doit être égale à l'identité.

La PCA peut également être utilisée pour effectuer le blanchiment comme un prétraitement.

II.4.3. Analyse en composantes principales orientée (OPCA)

Cette méthode représente l'extension de l'analyse en composantes principales, en maximisant la puissance de deux signaux plutôt que la puissance d'un seul signal.

Par rapport à d'autres méthodes utilisant les statistiques du deuxième ordre, cette approche permet d'éviter l'étape de pré-blanchiment [12].

II.4.4. Statistiques d'ordre deux

Le problème de la séparation de sources revient à la recherche de composantes indépendantes dans un mélange linéaire. On peut proposer une solution qui consiste à rendre les observations indépendantes à l'ordre deux en exploitant la matrice d'auto-covariance de ces observations [13].

La matrice d'auto-covariance est définie par la relation suivante :

$$S = UDU^* \text{ (II.13)}$$

Avec :

- D est une matrice diagonale.
- U est une matrice unitaire.

II.4.5. Analyse en Composantes Indépendantes : ICA

II.4.5.1. principe

L'ACI d'un vecteur aléatoire x consiste à estimer le modèle données par l'équation (1.1), par une transformation linéaire $y = C x$, avec la seule connaissance a priori l'indépendance statistique. L'algorithme ICA le plus largement usagés pour le linéaire mélange.

L'équation (1.1) représenté le modèle statistique qu'est appelée analyse en composantes indépendantes. Ces composantes ne sont pas directement observables et la matrice observé de mélange est supposée non connue [12].




Figure II.2 : Le but d'ICA

Soit $[s_1, \dots, s_N]$ un vecteur des variables aléatoires indépendantes, avec une fonction de densité de probabilité conjointe p_s défini comme suit :

$$p_s(s_1, \dots, s_N) = \prod_{n=1}^N p_{s_n}(s_n) \quad (\text{II.14})$$

Avec p_{s_n} est la fonction de densité de probabilité .

La séparation des sources nécessite de mesurer l'indépendance, ce qui n'est pas vérifié car l'indépendance statistique est vérifiée par la fonction de densité de probabilité qui est inconnue et difficile à estimer [15]. Dans ce cas nous allons trouver une matrice de démixage W défini par la relation suivante :

$$Y = WX \quad (\text{II.15})$$

telle que les sources estimées soient aussi indépendantes que possible [15]. Par conséquent, cette indépendance conduit à une matrice W qui satisfait :

$$WA = PD \quad (\text{II.16})$$

Où

- P est une matrice de permutation
- D est une matrice diagonale

II.4.5.2. inconvénient de l'ICA

L'analyse en composantes indépendantes ne peut rien apporter à l'analyse de données gaussiennes puisque l'indépendance se réduit alors à la décorrélation. On pourrait dire que l'ICA est l'art d'intégrer l'information non gaussienne dans la recherche de composante [12].

II.4.5.3. mesure de l'indépendance

Le critère d'indépendance est basé sur beaucoup de méthodes, nous allons expliquer dans la suite :

II.4.5.3.1. Non-Gaussianité des variables

➤ Pour que l'analyse en composantes indépendantes soit possible, les composantes indépendantes doivent être non-gaussiennes.

➤ Nous supposons que la matrice du mélange est orthogonale et les signaux s_i sont gaussiens, et x_1 et x_2 sont gaussiens, non corrélés, de variance unitaire.

Leur densité est donnée par l'équation suivante :

$$p(\mathbf{x}_1 + \mathbf{x}_2) = \frac{1}{2\pi} e^{-\frac{x_1^2 + x_2^2}{2}} \quad (\text{II.17})$$

➤ La distribution de toute transformation orthogonale de (x_1, x_2) gaussiens a la même distribution que (x_1, x_2) , et X_1 et X_2 sont indépendants [12].

➤ Impossible d'estimer le modèle de l'ICA qu'avec une transformation orthogonale, si les variables sont gaussiennes.

II.4.5.3.2. Maximisation du caractère non gaussien

Cette méthode est l'un des critères les plus utilisés en ACI, car il est possible de séparer les signaux sources indépendantes. L'idée générale est de retrouver les sources les moins gaussiennes possibles [15].

II.4.5.3.3. Minimisation de l'information mutuelle

L'information mutuelle est la mesure théorique de l'information naturelle de l'indépendance d'une variable aléatoire, nous pouvons utiliser comme critère pour la recherche de l'ICA. Nous définissons l'ICA du vecteur aléatoire \mathbf{x} comme une

transformation inversible de l'équation (1.1), ou la matrice est déterminée de manière à minimiser l'information mutuelle des éléments transformés s_i .

On définit l'information mutuelle par :

$$I(\mathbf{y}) = -H(\mathbf{y}) + \sum_{j=1}^l H(y_j) \quad \text{avec } j=\{1, \dots, l\}^T \quad (\text{II.18})$$

Où : H présente l'entropie

Cette quantité est toujours positive, et s'annule si et seulement si les variables aléatoires y_j sont statistiquement indépendantes.

La relation (2.9) peut être réécrite en fonction de la négentropie par la relation suivante :

$$I(\mathbf{y}) = C - \sum_{j=1}^l J(y_j) \quad (\text{II.19})$$

Où : C est une constante ne dépendant pas de \mathbf{W} . Ceci montre la relation entre la Négentropie et l'information mutuelle [16].

II.4.5.3.4. Maximum de vraisemblance

le maximum de vraisemblance est un estimateur utilisé pour inférer les paramètres de la loi de probabilité. l'inconvénient de la maximisation de la vraisemblance est la non-connaissance des densités de probabilité des signaux sources [12], pour résoudre ce problème nous allons supposer qu'elles sont des connaissances à priori.

Le log du maximum de vraisemblance est donné par la formule suivante

$$\text{Log}(L) = \sum_{t=1}^T \sum_{i=1}^n \log f_i(\mathbf{w}_i^T \mathbf{x}(t)) + T \log(|\det \mathbf{W}|) \quad (\text{II.20})$$

Où :

- ✓ f_i est la fonction de densité de \mathbf{x} .
- ✓ Le terme $\log(|\det \mathbf{W}|)$ dans la vraisemblance vient des règles classiques pour la transformation linéaire des variables aléatoires et leurs densités.

II.4.6. Fastica basé sur le maximum de vraisemblance

II.4.6.1. Principe

Considérons le problème de l'estimation de la densité à partir d'échantillons. On désire estimer une certaine distribution vraie $p(x)$ à partir des échantillons $X_1; X_2 \dots; X_n$. L'approche du maximum de vraisemblance consiste à utiliser un estimateur de densité d'une forme paramétrique, par exemple $\hat{p}(x; w)$.

Étant donné le vecteur de paramètre w , cela constituera la densité de probabilité estimée. Afin d'estimer w correctement, nous trouvons une valeur qui minimise la mesure de la différence entre $p(x)$ et $\hat{p}(x; w)$. Une mesure de différence appropriée est la divergence asymétrique donnée par la formule suivante :

$$G[p, \hat{p}] = \int p(x) \log \frac{p(x)}{\hat{p}(x; w)} dx = H[p] - \int p(x) \log \hat{p}(x; w) dx. \quad (\text{II.21})$$

C'est l'entropie de la distribution d'entrée (fixe) p moins la probabilité de \hat{p} étant donné \hat{p} , et le w qui minimise ce qui maximise la probabilité d'où le terme. Bien que G ne nous soit pas disponible, on peut obtenir une estimation.

$$\tilde{G} = H[p] - \log \hat{p}(x; w). \quad (\text{II.22})$$

L'estimation de la matrice de séparation w est décrite par un algorithme défini ultérieurement

II.4.6.2. Avantage de FastICA basé sur le maximum de vraisemblance

L'algorithme trouve directement des composants indépendants de (pratiquement) tout type non gaussien, distribution utilisant une non-linéarité quelconque g . Cela contraste avec de nombreux algorithmes [12].

Les composantes indépendantes peuvent être estimées une par une, ce qui équivaut à peu près à la poursuite d'une projection. Ceci est utile dans l'analyse de données exploratoire et diminue la charge de calcul de la méthode dans les cas où seule une partie des composants indépendants doit être estimée [12].

Les performances de la méthode peuvent être optimisées en choisissant une non-linéarité appropriée g . En particulier, on peut obtenir des algorithmes robustes et / ou à variance minimale [12].

FastICA est basé sur l'optimisation d'une fonction du contraste qui mesure le non-Gaussianité des sources.

II.4.6.3. la méthode de calcul de maximum de vraisemblance

II.4.6.3.1. La probabilité

Est une méthode utiliser pour estimer le modèle ICA[16], cette estimation dépend de principe de l'info max, cette dernière est équivalente à la minimisation de l'information mutuelle[].

Le modèle estimer par l'approche de la probabilité maximale définit comme suit :

$$L = \sum_{t=1}^T \sum_{i=1}^n \log f_i (w_i^T x(t)) + T \log(|\det W|) \text{ (II.23)}$$

II.4.6.3.2. Principe infomax

Un principe d'estimation pour le modèle ICA lié au maximum de vraisemblance est le principe de l'info max [17] basé sur la maximisation de l'entropie.

Ce principe définit par la relation suivante :

$$L = H(\varphi_1(W_1^T x), \dots, \varphi_n(W_n^T x)) \text{ (II.24)}$$

Si φ_i sont bien choisis, dans ce cas il permet également de l'estimation du modèle de l'ICA.

II.4.6.3.3. Rapport à l'information mutuelle

Pour voir le lien entre les vraisemblances et l'information mutuelle, considérons l'attente de la log-vraisemblance définit comme suit :

$$\frac{1}{T} E\{L\} = E\{\log f_i(w_i^T x(t))\} + T \log(|\det W|) \quad (\text{II.25})$$

Réellement, si les f_i étaient égaux aux distributions réelles de $w_i^T x$ [16], le premier terme serait égal à

$$\sum_i H(w_i^T x) \quad (\text{II.26})$$

Donc la probabilité serait égale à la négative d'information mutuelle.

II.4.6.4. Algorithme

L'algorithme de fastICA basé sur le maximum de vraisemblances est défini par les étapes suivantes :

1-centrer les données pour obtenir leur moyenne nulle.

2- Calculer la matrice de corrélation $C = E\{xx^T\}$.

3-choisir une matrice initial W .

4-calculer

$$y = Wx. \quad (\text{II.27})$$

$$\beta_i = -E\{y_i g(y_i)\}, \quad i = \{1, \dots, n\} \quad (\text{II.28})$$

$$\alpha_i = -1/(\beta_i - E\{g'(y_i)\}), \quad i = \{1, \dots, n\} \quad (\text{II.29})$$

5- mettre à jour la matrice de séparation par

$$W \leftarrow W + \text{diag}(\alpha_i) [\text{diag}(\beta_i) + E\{g(y)y^T\}] W. \quad (\text{II.30})$$

6-décorrélérer et normaliser par

$$W \leftarrow (WCW^T)^{-1/2} W. \quad (\text{II.31})$$

7- si ne converge pas retourner à l'étape 3.

La matrice W doit être orthogonale après chaque étape, dans cette version matricielle il est naturel d'orthogonalité la matrice W symétriquement.

Conclusion

Dans ce chapitre nous avons présenté le principe des méthodes de décomposition en Sous-espaces appliquées à la séparation de sources. Ces méthodes sont : PCA, OPCA ICA, et Fastica. Nous avons tout d'abord, donné une idée générale sur les méthodes PCA et OPCA. Ensuite nous avons présenté le principe de l'analyse en composantes indépendantes ICA et les différents Principales approches de cette méthode classique. Finalement nous avons parlé à propos d'une méthode très efficace pour la séparation aveugle s'appelle FastICA qui est basé sur le maximum de vraisemblance.

Résultats et discussion

III.1. Introduction

La séparation aveugle de source peut être résolue par plusieurs méthodes, L'analyse en composantes indépendantes (ACI) est légitimement utilisée malgré le nombre restreint de travaux [18], devant sa popularité en traitement de signal.

Dans ce travail, nous introduisant la méthode FastICA basé sur la minimisation de du maximum de vrai dans une problématique de séparation aveugle de source, nous nous somme intéresser aux mélanges instantanées des signaux de parole.

Les résultats de résolution de problème de la séparation aveugle de source (SAS) par la méthode FastICA basé sur le maximum de vraisemblance sont comparés avec celle obtenue par l'application de la méthode ACI (la méthode classique). Dans un environnement sans bruit, les performances des signaux estimées issue des deux méthodes sont comparés en en termes de qualité en utilisant BSSeval-toolbox , l'évaluation de performances de la méthode utilisés sont effectué dans un environnement bruité aussi.

III.2. Les critères d'évaluation

BSSEval (pour *Blind Source Séparation Evaluation*) [18], 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 :

$$\mathbf{x}_k - \hat{\mathbf{x}}_k = \mathbf{e}_k^{target} + \mathbf{e}_k^{interf} + \mathbf{e}_k^{artif} \quad (\text{III.1})$$

- \mathbf{e}_k^{cible} (t) est une déformation autorisée de la source cible si (t).

- \mathbf{e}_k^{interf} (t) est la contribution de l'intervention d'autres Sources présentes.

- \mathbf{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 $\hat{\mathbf{x}}_k$ sur divers sous espaces par exemple, \mathbf{e}_k^{artif} est obtenu par projection de $\hat{\mathbf{x}}_k$ sur divers sous espaces engendré par les x_l , $l \in [1, k]$. 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 :

$$SDR = 10 \log_{10} \frac{\|s_{cible}\|^2}{\|e_{interf} + e_{bruit} + e_{artif}\|^2} \quad (\text{III.2})$$

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

$$SIR = 10 \log_{10} \frac{\|e_{cible}\|^2}{\|e_{interf}\|^2} \quad (\text{III.3})$$

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

$$SAR = 10 \log_{10} \frac{\|e_{cible} + e_{interf} + e_{bruit}\|^2}{\|e_{interf}\|^2} \quad (\text{III.4})$$


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.3. Résultats et discussions


Dans cette partie ICA et FastiCA basé sur le maximum de vraisemblance sont introduit pour résoudre le problème de la séparation aveugle des sources de mélange instantanées. La résolution est effectuée dans le domaine temporel. Les signaux sources sont choisis à partir des bases de données TIMIT (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).

III.3.1. Séparation de mélange instantanée sans bruit


Soit les signaux de parole choisis aléatoirement à partir de TIMITL illustre par la **figure (3.1)**, les signaux sources sont de la durée de 3 seconds et de fréquence d'échantillonnage 8 et 16khz.



A : Représentation de la source 1




B : Représentation de la source 2




C : Représentation de la source 3

La figure III.1 Représentation des signaux sources.


Nous introduisant le spectrogramme des signaux sources pour confirmer que le contenu spectral est réservé en comparant les signaux sources avec les signaux estimée. Le Spectrogramme est un diagramme associant à chaque instant t d'un signal, son spectre de fréquence .c'est un outil de visualisation utilisant la technique de la transformée de Fourier. Le spectrogramme permet de mettre en évidence les différentes composantes fréquentielles du signal à, une instante donnée.



A : spectrogramme de source 1



B: spectrogramme de la source 2




C: spectrogramme de la source 3

La figure III.2 : Présente les spectrogrammes des signaux source


Les signaux sources sont instantanément mélangé en utilise une matrice dimension de mélange de dimension 3X3choisie aléatoirement tel que :

$$\begin{cases} y_1 = a_{11}s_1 + a_{12}s_2 + a_{13}s_3 \\ y_2 = a_{21}s_1 + a_{22}s_2 + a_{23}s_3 \\ y_3 = a_{31}s_1 + a_{32}s_2 + a_{33}s_3 \end{cases} \quad (3.5)$$


Les signaux mélangés observés obtenues sont illustre par **la figure 3.3**.



A: signal observe 1




B: signal observe 2




C: Signal observé 3

La figure III.3 présente les signaux observés.


L'application de la méthode FastICA basé sur le maximum de vraisemblance pour résoudre le problème de séparation de signaux de parole instantanément mélangé permet d'avoir les signaux estimée illustre par **la figure (3.4)**.



A:signal estimée 1




B: signal estimée 2




C: signal estimée 3

Figure III.4 : Représentation des signaux estimée.


La figure (3.5) spectrogramme des signaux estimés.



A : Spectrogramme de la source estimé 1.



B : Spectrogramme de la source estimé 2.



C : Spectrogramme de la source estimé 3.

Figure 3.5 Représentation spectrogrammes des sources estimées.

Comme le montre **la figure (3.1) et (3.4)**, les signaux estimés sont fortement semblable aux signaux sources. **Les figure (3.2) et (3.5)** 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 et le SDR pour les mélanges instantanés pour des raisons de simplicité, même le SAR est important pour illustrer le niveau de l'artefact dans les estimations. Le tableau 1 résume les valeurs de SAR SIR et SDR obtenues en appliquant la méthode fastICA base sur le maximum de vraisemblance et ICA classique.

Le Tableau 1 : Résumé les performances de la méthode de résolution de problème de séparation aveugle base sur FastICA en comparaison avec celle base sur l'ACI.

	SAR	SIR	SDR
FastICA base sur la minimisation du maximum de vraisemblances (dB)	16.31	29.73	21.03
ICA (dB)	13.5	22.9	18.7

Les résultats du tableau (**tableau 1**) montre que les valeurs des paramètres SAR SIR et SDR obtenue par la méthode fastICA base sur le maximum de vraisemblance sont plus élevés que celle obtenue par la méthode ICA classique. Les signaux estimée à partir de la méthode fastICA base sur le maximum de vraisemblance possède une meilleurs qualité et ligibilité que celui estimée par la méthode ICA classique.

III.3.2. Séparation de mélange instantané avec bruit

Pour tester l'efficacité de la méthode FastICA basé sur maximum de vraisemblance dans un environnement bruitée, nous utilisons les mélanges instantanées corrompu par un bruit blanc gaussien, puis nous faisons varier le SNR d'entrée de 5 à 15 dB avec un pas de 5 dB, ensuite nous allons évaluer le SNR de sortie moyen des sources estimées.

Le SNR de sortie est décrit par l'expression suivante :

$$SNR = \frac{P_S}{P_N} = \frac{\int_{-\infty}^{\infty} P_S(f) df}{\int_{-\infty}^{\infty} P_N(f) df} = \frac{\int_{-\infty}^{\infty} P_S(f) df}{N_0 B_T} \quad (\text{III.6})$$

Les valeurs obtenues sont présenté dans le tableau 2.

Le **Tableau 2** : illustration des performances de la méthode de résolution de problème de séparation aveugle basé sur FastICA avec bruit et en comparaison avec celle basé sur l'ACI.

	SNR d'entrée		
	5 dB	10 dB	15 dB
FastICA basé sur MV (dB)	9.8	13.8	18.3
ICA (dB)	7.9	12.3	16.8

Comme le montre le tableau 2, La méthode de fastICA base sur le maximum de vraisemblance permet d'avoir un SNR sortie plus élevé que celui obtenue par l'application de la méthode ICA classique. La méthode fastICA base sur le maximum de vraisemblance considère le bruit blanc gaussien ajoute comme artéfact et comme interférence, la méthode considère comme méthode d'optimisation consiste à estimer une matrice séparation pour mieux estimée les signaux.

Conclusion

Dans ce chapitre, nous avons présenté une nouvelle méthode de séparation aveugle de sources d'un mélange instantanée basée sur le maximum de vraisemblance d'ordre 2 a été proposée pour Le SAS qui s'appelle FastICA.

En applique Cette méthode sur trois signaux source pour voire les performances de notre algorithme et fait une comparaison avec l'algorithme de la méthode classique (ICA).

Dans ce travail, nous avons introduit la méthode de FastICA basé sur le maximum de vraisemblance pour séparer les mélanges de signaux de parole, au début, nous nous sommes intéressés à la séparation de mélange instantané. Les signaux sont construits à partir des bases de données disponibles en ligne. Les résultats ont été comparés à ceux obtenus par la méthode classique ACI en termes de qualité de signal.

On travaille aussi sur la séparation de mélange instantané avec la méthode FastICA basé sur le maximum de vraisemblance dans un environnement bruité. En ajoutant un bruit centré, on compare avec la méthode classique ACI.

Les résultats de simulation montrent que la méthode FastICA est plus efficace et plus précise des sources en termes de SIR, SAR et SDR.

J'ai à la maison. kzx