

IMPLEMENTACIÓN EN MATLAB DE LOS ALGORITMOS DE SEPARACIÓN DE SEÑALES (ICA) BASADOS EN EL ANÁLISIS DE COMPONENTES INDEPENDIENTES: ICATOOBOX2.0.

J.M. Górriz¹, C.G. Puntonet², J.C. Méndez¹, M. Salmerón² y M.J. Cazalla²

¹Universidad de Cádiz. juanmanuel.gorriz@uca.es

²Universidad de Granada. carlos@atc.ugr.es

RESUMEN

En el presente trabajo exponemos el diseño de una herramienta para la separación ciega de señales usando el entorno visual de MatLab. Además se presenta un método novedoso de separación de señales que híbrida el análisis de componentes independientes (ICA) con Algoritmos Genéticos (GAs). ICA ha sido propuesto para la resolución del problema de separación ciega de fuentes mientras que los GAs son técnicas eficientes de inteligencia artificial (AI) de optimización de problemas variados. El algoritmo propuesto mezcla ambos campos siendo su eficiencia indispensable en aquellas aplicaciones donde se presenta una alta dimensionalidad y restricciones temporales (aplicaciones de tiempo real por ejemplo en biomedicina, finanzas, etc.).

1. INTRODUCCIÓN

La filosofía del Análisis de Componentes Independientes fue planteada, por primera vez, por Barlow en 1961. En su trabajo las unidades neuronales de una red poseían como rasgo principal la independencia estadística, dado un conjunto de entradas a la misma. Basándose en esta idea tanto Linsker [1992] como Nadal y Parga [1994], propusieron un aprendizaje sobre redes neuronales no supervisado aplicando el concepto de minimización de la información mutua entre las salidas y entradas.

Sin embargo fue en 1995 cuando Bell y Sejnowski aplicaron este concepto a la separación de fuentes proponiendo una regla de aprendizaje basado en el gradiente para maximizar la información mutua en una red neuronal. De esta forma resurgió un periodo de intensa investigación en la separación ciega de fuentes, periodo que se había iniciado unos años atrás, en 1986, cuando autores como Herault y Jutten habían conseguido separar fuentes independientes mediante el uso de redes neuronales de realimentación que usaban como algoritmo de aprendizaje el algoritmo de Hebb de 1986. Avances sobre el tema se sucedieron años después con importantes contribuciones como las de Cichocki y Unbehauen [1994] y Karhunen y Joutsensalo [1994]. Además el grupo de investigación de Cardoso aportó grandes avances basándose en un gran número de aproximaciones y procedimientos algebraicos [1993], estimaciones de máximos de probabilidad [1994] y [1997], análisis de estabilidad [1998], etc.

En 1994 Comon propuso funciones de energía relacionadas con la minimización de la información mutua con lo que dio a conocer de forma general el Análisis de Componentes Independientes, término que fue usado por primera vez por este autor. En este mismo año comienza un nuevo enfoque, dado por Puntonet, en la resolución del problema considerando el carácter geométrico de la distribución de las señales en el espacio. En el campo de las comunicaciones, la separación de fuentes viene como consecuencia del uso del mismo medio físico por parte de distintas señales

siendo la situación crítica cuando el canal presenta ruido de amplitud parecida a las señales de interés siendo las técnicas de separación de señales básicas en el preprocesado del conjunto, un ejemplo se encuentra en trabajos de Cardoso y Comon en el 1996. Además en la separación de hablantes, nos interesaría reproducir el efecto Cocktail Party que consiste en que las personas somos capaces de seleccionar las conversaciones que llaman nuestra atención en un entorno ruidoso. Una de las aplicaciones de más importancia es la eliminación de redundancia en conjuntos grandes de datos, fenómeno que es capaz de reproducir también el hombre y que ha sido estudiado por diversos autores hasta la fecha mediante el análisis de componentes principales. La importancia de la reducción de la redundancia se remonta a Attneave en 1954 aunque fue con Barlow [1989] y Linsker [1993] donde alcanzaron su mayor difusión en el desarrollo de algoritmos no supervisados y construcción de códigos dispersos de la información

Algunos autores han aplicado ICA al análisis de series temporales bursátiles, para el análisis de amplios conjuntos de datos, entre ellos destaca Back [1997] donde transforma las señales observadas de stock en un nuevo espacio de componentes estadísticamente independientes, extrayendo propiedades interesantes en los mismos y Górriz en 2003 donde usa ICA con teoría estadística para la predicción de series temporales. Además, basándose en este tipo de análisis, podemos encontrar otros campos diversos donde se ha aplicado ICA, por ejemplo, al tratamiento de imágenes en Astronomía, análisis de señales volcánicas, etc. Finalmente ICA ha sido aplicado satisfactoriamente en sensores electrónicos de material genético (Górriz y Frey en 2002 "DNA sensors"), como un método de separación de las distintas señales recibidas. El efecto electroquímico de solapamiento de las señales ("Electrochemical Crosstalk") puede degradar la calidad de las señales en los sensores. Para evitarlo se puede incrementar la distancia entre sensores vecinos, sin embargo esto disminuye la densidad de sensores, lo cual no es favorable en la medida. Otra posibilidad es limitar el tiempo de medida de 10 minutos a 10 segundos introduciendo restricciones adicionales sobre el ensayo o la operación del chip. ICA evita las anteriores restricciones para una densidad de sensores fija.

2. CONCEPTOS FUNDAMENTALES.

La separación de fuentes es un problema importante en el campo del procesamiento de señales [1], [2]. Por regla general, las señales recibidas por sensores son mezclas que proceden de varias fuentes independientes, las cuales, al transmitirse por un medio material pueden sufrir alteraciones debidas a dicho medio recibándose en los sensores una información que es una mezcla de las originales. El objeto de la separación de fuentes consiste en tomar estas mezclas y obtener a partir de ellas las señales originales puras. Esta técnica puede ser aplicada en campos tales como el procesamiento de señales en radar, sonar, biomedicina, finanzas y en la voz, para realzar la señal original perturbada sobre otras señales (tales como señales orgánicas, voz, ruidos de motores, etc.). Inicialmente este problema fue planteado por Jutten y Herault [3], según cuyos trabajos, algún tipo de sistema de separación existe en el sistema nervioso central dado que las señales que circulan a través de los tejidos nerviosos son, generalmente, mezclas de información heterogénea. Así por ejemplo, el efecto denominado "cocktail-party" nos demuestra que en una reunión donde estén hablando varias personas a la vez o haya ruido, nuestro cerebro es capaz de seleccionar una o varias de entre las voces de las personas que están hablando y escuchar lo que están diciendo. En general, las señales mezcladas se observan a través de unos sensores, los cuales obtienen una información transformada ($e_k(t)$, $k = 1, 2, \dots, p$) y que no coincide con la original. El problema consiste en, a partir

de estas observaciones ($e_k(t)$), reconstruir las señales originales ($s_{o_i}(t)$), trabajando bajo una serie de hipótesis, siendo usuales las siguientes:

- Las fuentes ($s_{o_i}(t)$, $i = 1, 2, \dots, p$) son desconocidas y estadísticamente independientes.
- El número de sensores (p) es igual al número de fuentes.
- Se modela la influencia del medio material de manera lineal mediante una matriz de mezcla A .

Bajo estas hipótesis, se dice que la separación de fuentes es ciega (“Blind Separation”), puesto que no hay información alguna sobre ellas [4] y lineal, puesto que las mezclas son una combinación lineal de las fuentes. En principio, este problema no tendría solución ya que se trataría de resolver un sistema de p ecuaciones con p^2 incógnitas sin conocer dichas incógnitas ni sus coeficientes.

Este trabajo consiste en el diseño de una herramienta gráfica reúne un conjunto de técnicas geométrico-estadísticas para la separación en componentes independientes. El trabajo se resume como sigue: En la sección II se resumen los métodos que el programa implementa y los entornos más adecuados para su aplicación en la sección 3 resumimos las características técnicas del programa destacando su capacidad para trabajar con señales de audio, en formato texto, formato propio de MatLab, etc. Por último en la sección 4 se exponen resultados experimentales del entorno ICAToolbox2.0. creado y por último en la sección V se establecen las conclusiones del trabajo.

3. MÉTODOS ICA IMPLEMENTADOS EN EL ENTORNO ICAToolbox2.0.

Los algoritmos de separación ciega de fuentes se clasifican según el método de separación en Algoritmos ICA Estadísticos (aquellos que usan propiedades estadísticas, por ejemplo cumulantes, kurtosis, etc., de las salidas observadas en la búsqueda de la independencia estadística de ellas) y Algoritmos ICA Geométricos (aquellos que usan la distribución geométrica de las señales provenientes de las fuentes para la estimación de los parámetros de la matriz de mezclas).

3.1. Métodos ICA Geométricos (inspirados en [4]):

3.1.1. LatticeIca

Es un método de separación geométrica de señales desarrollado en el Departamento de Arquitectura y Tecnología de los Computadores de Ingeniería Informática en la Universidad de Granada. En este método se estudia el espacio de representación de las señales dividiéndolo en un conjunto de rectángulos, formando un entramado, y se usan el estudio de estas divisiones y sus relaciones para obtener la matriz de mezcla de la separación.

3.1.2. Método Geométrico por Sectores

Está basado en la división del espacio de la señal en sectores, escogiendo aquellos en los que se hayan agrupado más puntos, pues son los que tendrán la recta que contiene la pendiente que nos dará la matriz de separación. Este método geométrico ha sido desarrollado para la división de 2 señales mezcladas mediante una mezcla lineal instantánea y asume todas las hipótesis indicada para todos los métodos geométricos.

3.1.3. Método Separación de Neuronas

Ha sido desarrollado para la separación de “n” señales mezcladas mediante una mezcla lineal instantánea. Este método consiste en el emplazamiento de una neurona en cada uno de los extremos de los ejes de las señales que se moverá adaptativamente y de manera auto-organizativa para indicar la pendiente que necesitamos para obtener la matriz de separación. Es un método genérico para N dimensiones.

3.1.4. Método de las Medias Ponderadas Cuadráticas

Evolución del anterior como un intento de acelerar la ejecución para el cálculo de la pendiente de los ejes principales. Al igual que el anterior, es un método genérico para la separación de N señales y tras dividir el espacio asociado a las señales que forman la mezcla en hipercuadrantes, tratamos de determinar la pendiente en cada hipercuadrante que nos servirá para obtener la matriz de mezcla.

3.2. Métodos ICA Estadísticos:

3.2.1. Jade

Es el acrónimo para Joint Approximate Diagonalization of Eigen-matrices que se puede traducir como Unión de Diagonalizaciones aproximadas de automatrices. Fue desarrollado por J. F. Cardoso [5] y es uno de los mejores métodos de separación de señales. Usa técnicas estadísticas y analíticas del problema, llegando a usar estadísticas de 4º orden.

3.2.2. FastIca

Este algoritmo fue desarrollado por Aapo Hyvärinen y Erkki Oja [6] y recibe el nombre por la rapidez con que trabaja, mucho mayor que el resto de algoritmos. Es otro de los mejores algoritmos de separación de señales, y el algoritmo es una adaptación de un algoritmo de punto fijo de una regla de aprendizaje de una red neuronal, encontrando las señales una a una. Al igual que Jade usa técnicas estadísticas y analíticas, llegando a estadísticas de 4º orden.

3.2.3. Basado en cumulantes

Algoritmos quasi-Newton ICA que generalizan de los algoritmos basados en FastIca con técnicas estadísticas de hasta sexto orden.

3.2.4. SeekGenetic

Algoritmo Híbrido [7] de búsqueda estadístico-genética basado en el uso de operadores de mutación que fuerzan la ergodicidad de la cadena de Markov asociada a la búsqueda y operadores reductores que guían dicha búsqueda. Apropiado para aplicaciones en tiempo real y en búsquedas en grandes espacios.

4. DESCRIPCIÓN DE LA ICATOOBOX 2.0

La herramienta desarrollada presenta una interfaz que permite la visualización de señales presentadas en distinto formato (.wav, .txt, etc.) , la generación de histogramas, mezclas ficticias y la aplicación de los métodos expuestos en la sección II. Como detalle fundamental de la herramienta destacamos su capacidad para tratar con un gran número de señales mediante la aplicación del método SeekGenetic y el estudio comparativo entre los distintos métodos implementados. A continuación vamos a hacer una descripción del entorno desarrollado tratando de abarcar todas las partes de este:

4.1. Interfaz Principal:

En la ventana principal (Fig 1.) del entorno de Icatoolbox2.0. podemos destacar la presencia de un menú en la parte superior que nos permite cargar proyectores (entornos ya creados), señales en múltiples formatos, modificar los parámetros de los modelos de separación (constantes de convergencia, parámetros de aprendizaje, etc.) y por último acceder a una amplia ayuda que explica profundamente como usar el programa y los contenidos teóricos del mismo. El elemento gráfico en el panel junto con los botones de control nos permite reproducir la señal, hallar su histograma, borrarla e incluso representarla frente a otra (Plot2D) al seleccionar dos señales cargadas en el entorno “Loaded Signals” (Fig. 2).

En el cuadro inferior se esquematiza paso a paso el proceso de generación de señales, mezcla (para comprobar la validez de los métodos), separación y comprobación de métodos en cuanto a calidad de separación y tasa de convergencia.

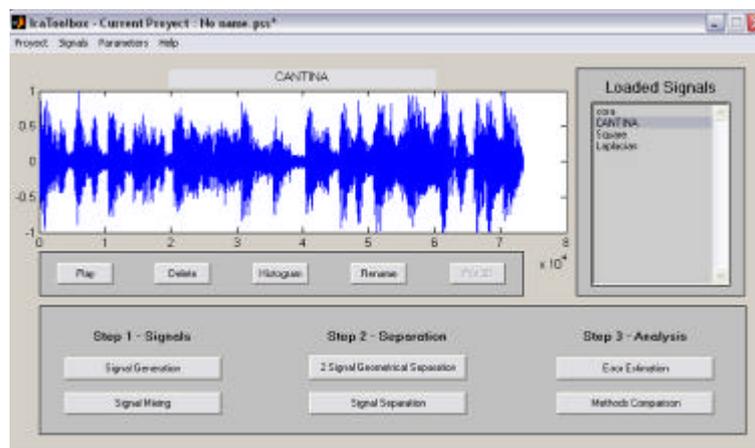


Fig.1 Ventana Principal.

4.2. Separación y Comparación de Métodos:

La nueva herramienta ICAToolBox2.0. permite, mediante el uso del botón “Signal Separation” acceder a un menú de selección de métodos entre los que puede elegir el usuario (véase Fig. 3). Los distintos métodos se agrupan en dos columnas, a la izquierda los métodos geométricos y a la derecha los estadísticos.

Una vez elegido el método de separación, se seleccionan las señales de las que se quieren extraer las componentes independientes (señales originales) y el programa redacta un informe sobre el proceso de separación en el que se incluyen datos relevantes como tiempo de ejecución, “CrossTalk” (medida de la calidad de la señal separada en decibelios), etc (Fig 4).

Una característica importante de la herramienta gráfica es la posibilidad de comparar distintos métodos (Fig. 5). La comparación pone de manifiesto, cuando usamos un conjunto de señales elevado, la necesidad del método híbrido que presentamos en este trabajo. En aplicaciones en tiempo real, por ejemplo al usar los algoritmos ICA aplicados a finanzas [8], la tasa de convergencia a la solución deseada (matriz de separación), debe ser lo más eficiente posible para que el sistema cumpla con las especificaciones temporales propias de un sistema en tiempo real. Además en aplicaciones como en biomedicina (EEG) el número de señales de entrada usadas (de 12 a 22) puede provocar que los algoritmos estándares ICA no sean lo suficientemente eficientes (debido a la maldición de la dimensionalidad), por lo que también se mejora el rendimiento de los mismos al hibridar con estrategias de AI.



Fig.2 Menú de carga de Señales.

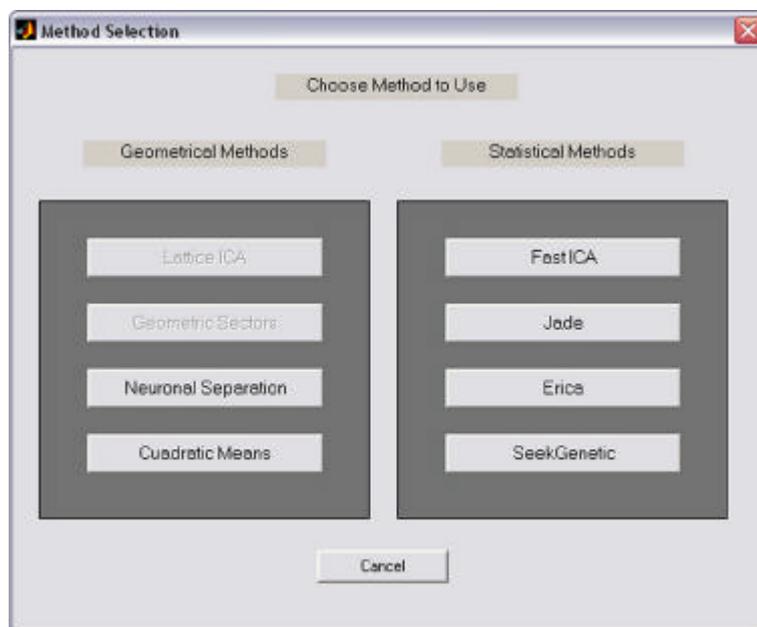


Fig 3. Selección de Métodos

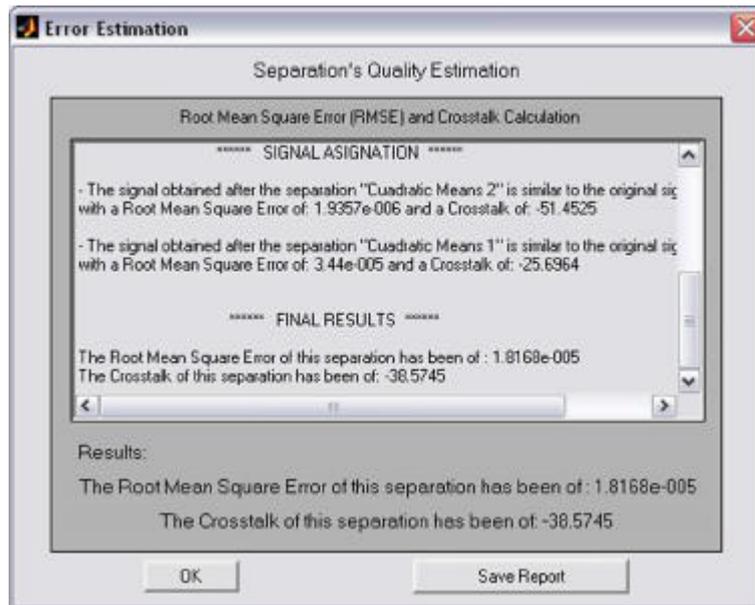


Fig 4. Informe sobre la separación.

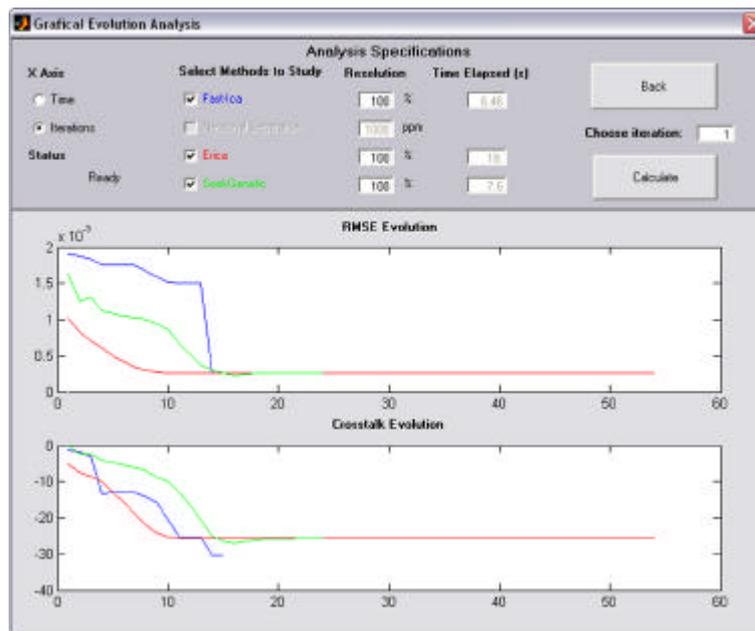


Fig 5. Comparación de métodos (n = 2).

5. RESULTADOS

Para concluir con este trabajo vamos a plantear un ejemplo clásico (y el más sencillo por motivos pedagógicos) en el problema de BSS. Trataremos de resolver el problema del efecto "Cocktail" cuando en un recinto se mezclan linealmente distintas señales provenientes de distintas fuentes (igual al número de sensores), por ejemplo en una sala donde toca una orquesta. Con ayuda de dos sensores captamos dos señales que contienen información de dos fuentes independientes (en nuestro ejemplo una trompeta y un acordeón). Evidentemente en cada sensor se recoge la señal mezclada de distinta manera por su posición en la sala y/o cercanía a cada fuente. Estas señales las

capturamos con nuestra herramienta ICAToolBox2.0. y apreciamos que, al representar una frente a otra, existe una cierta correlación entre ellas debido a la mezcla lineal que queda representada por los ejes azules de la Fig.6.

Para concluir con este trabajo vamos a plantear un ejemplo clásico (y el más sencillo por motivos pedagógicos) en el problema de BSS. Trataremos de resolver el problema del efecto “Cocktail” cuando en un recinto se mezclan linealmente distintas señales provenientes de distintas fuentes (igual al número de sensores), por ejemplo en una sala donde toca una orquesta. Con ayuda de dos sensores captamos dos señales que contienen información de dos fuentes independientes (en nuestro ejemplo una trompeta y un acordeón). Evidentemente en cada sensor se recoge la señal mezclada de distinta manera por su posición en la sala y/o cercanía a cada fuente. Estas señales las capturamos con nuestra herramienta ICAToolBox2.0. y apreciamos que, al representar una frente a otra, existe una cierta correlación entre ellas debido a la mezcla lineal que queda representada por los ejes azules de la Fig.6.

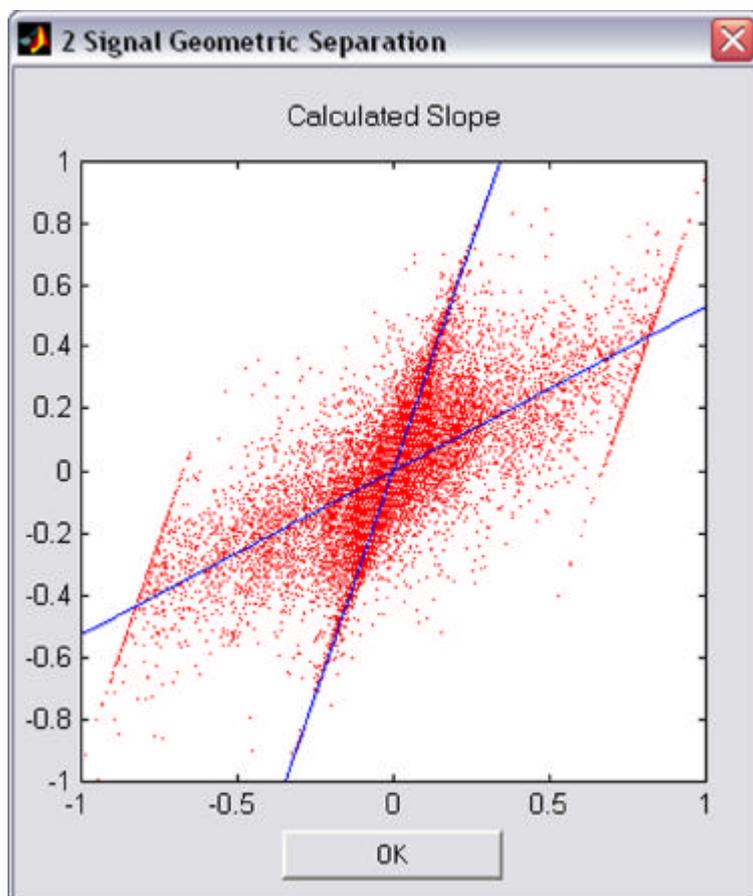


Fig 6. Representación de BSS para dos señales.

Tras seleccionar algunos de los métodos de separación obtenemos las señales reconstruidas con el informe que se presenta en la siguiente Tabla 1. Las señales reconstruidas pueden verse en la Fig. 7 así como las captadas en los sensores Mix1 y Mix2.

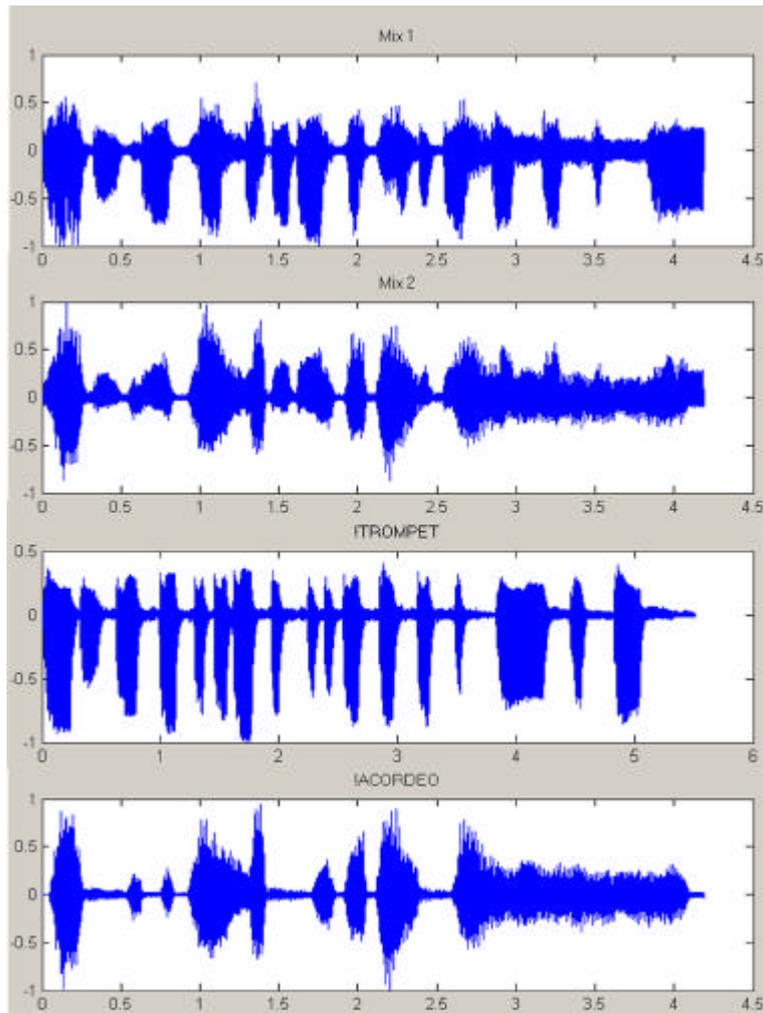


Fig. 7. Señales captadas y reconstruidas

Informe ICAToolBox2.0.	Fast-ICA	Geométrico N	Cumulantes	SeekGenetic
Tiempo empleado en segundos	0.731	13.399	5.047	16.424
Error cuadrático medio por señal	7.7366e-006	6.7439e-005	1.8016e-005	1.8016e-005
Error CrossTalk medio por señal	-39.7438	-24.8041	-33.6735	-33.6735

6. DISCUSIÓN Y CONCLUSIONES

La herramienta gráfica desarrollada permite al usuario la posibilidad de captar señales en distintos formatos y obtener las componentes independientes de dichas señales. Además pone a su disposición una amplia gama de métodos de separación basados en el Análisis de Componentes

Independientes basados en el caso lineal de mezcla que por lo general suele ser el más usado en las distintas aplicaciones donde ICA se ha implantado. El lenguaje de programación MatLab nos permite trabajar de manera flexible y necesidad de compilación dado que es un lenguaje de programación interpretado muy optimizado.

Como observamos en la Tabla 1 para el caso más sencillo (dos señales) la aplicación de técnicas de AI no es aconsejable, haciéndose indispensable cuando crece la dimensionalidad del problema tal y como se muestra en [7] y [8]. El nivel de calidad en la separación depende exclusivamente de las condiciones de convergencia que se imponga para la selección de la matriz de separación candidata, en el ejemplo una matriz de dos filas y dos columnas.

En resumen, presentamos un analizador de componentes independientes de gran utilidad para la resolución del problema de BSS. Las ventajas principales de este analizador como herramienta virtual son la portabilidad, la flexibilidad y escalabilidad, el bajo coste, la posibilidad de acceso a programación tanto gráfica como analítica, su posible uso en PCs compatibles con múltiples plataformas, su versatilidad en el proceso de Ingeniería y su posible adaptación a sistemas embebidos, entre otras. La única desventaja de usar este tipo de herramientas es su modera rapidez en ciertas aplicaciones que puede ser suplida usando un PC de altas prestaciones..

7. BIBLIOGRAFÍA

- [1] P. Comon, "Separation de mélanges de signaux", Proceedings of the 12th. GRETSI Conference, Juan les Pins (Francia), Septiembre, 1989
- [2] C. Jutten, J. Héroult, P. Comon, E. Sorouchyari, "Blind separation of sources, Part I, II y III", Signal Processing 24, 1991 [1] Hewlett Packard. "Fundamentals of the Electronic Counters". Application Note 200. Electronic Counter Series. 2000.
- [3] J. Héroult, C. Jutten, B. Ans, "Detection de grandeurs primitives dans un message composite par une architecture de calcul neuromimétique en apprentissage non supervisé". Proceedings of the 10th. GRETSI Conference, Juan-les-Pins (Francia), Septiembre, 1985
- [4] C. Jutten, "Calcul Neuromimétique et Traitement du Signal. Analyse en Composante Indépendentes", Thèse d'Etat, INPG-USMG. Grenoble (Francia), 1987
- [4] C.G. Puntonet, "Nuevos Algoritmos de Separación de fuentes en medios lineales", Tesis doctoral. Universidad de Granada, Spain. (1994)
- [5] J.F. Cardoso, "Infomax and maximum likelihood for source separation" IEEE letters on signal processing, 4, p. 112-114, 1997.
- [6] A. Hyvärinen, E. Oja. "Independent component analysis: algorithms and applications", Neural Networks, p. 411-430, 2000.
- [7] J.M. Górriz, C.G. Puntonet, M. Salmerón and F.Rojas. "Hybridizing Genetic Algorithms with ICA in higher dimension". In Press ICA 2004 Lecture Notes in Computer Science.
- [8] J.M. Górriz. "Algoritmos Híbridos para la Modelización de Series Temporales con Técnicas AR-ICA". Tesis Doctoral Universidad de Cádiz (2003).