

SUSTRACCIÓN ESPECTRAL DE RUIDO EN SEPARACIÓN CIEGA DE FUENTES DE RUIDO DE TRÁFICO

Fernando J. Mato Méndez ¹, Manuel Sobreira Seoane ²

Sonitum Ingeniería Acústica
E.T.S.I. Telecomunicación, Universidad de Vigo. C./ Maxwell S/N, 36310 Vigo (Spain)
fmato@tsc.uvigo.es ¹ msobre@gts.tsc.uvigo.es ²

Resumen

La técnica de sustracción espectral de ruido ha sido extensamente usada en ambientes ruidosos, durante los últimos años, para el realce de señales de voz, música o telefonía. En presencia de otras señales, no relacionadas con las señales de interés, el uso de esta técnica permite obtener resultados generalmente más robustos al ser aplicada a la clasificación de señales.

En este artículo se presentan los resultados obtenidos en separación de fuentes de ruido de tráfico interurbano tras la aplicación de sustracción espectral de ruido. Se pone de manifiesto de este modo, la obtención de una mayor separación en la zona inferior del espectro de las mezclas de entrada a algoritmos BSS (*Blind Source Separation*). Este hecho se traduce en una mejora en las hipótesis de independencia iniciales, más aún en el caso de separación intraclase de fuentes.

Palabras-clave: ruido de tráfico, separación de fuentes, BSS, análisis de componentes independientes.

Abstract

The noise spectral subtraction technique has been extensively used in noisy environments, during the last years, for the embossment of voice, music or telephony signals. In presence of other signals, not related to the signals of interest, the use of this technique allows to obtain generally more robust results applied to signals classification.

In this work the authors present the results obtained in inter-city traffic noise source separation after the application of noise spectral subtraction. It is revealed thus, the obtaining of a major separation in the low zone of the spectrum of the mixtures for to be used as entry to BSS (*Blind Source Separation*) algorithms. This fact is translated into an improvement in the initial hypotheses of independence, even more in the case of source intraclass separation.

Keywords: traffic noise, source separation, BSS, independent components analysis, spectral noise subtraction.

1 Introducción

El presente artículo viene motivado por un trabajo previo de los autores [14][15]. En dicho trabajo se aborda el problema de la separación de fuentes de ruido de tráfico en vías interurbanas, mediante la aplicación de técnicas ICA (*Independent Component Analysis*). De los resultados obtenidos se extrae un buen comportamiento para la separación interclase, pero no así para la separación intraclase debido a una menor independencia en los valores de la mezcla. Esta independencia mejora de forma importante al enfatizar las componentes armónicas distribuidas espectralmente, sobre todo en baja frecuencia y cuyo efecto es más acusado en el caso de tráfico pesado. Este hecho motivó el uso de sustracción espectral de ruido, como aplicación previa al proceso de separación, dando lugar al trabajo aquí presentado.

Para ello, se comienza identificando las fuentes de ruido que contribuyen al ruido de tráfico resultante en las señales adquiridas, como punto de partida para la comprensión del estudio llevado a cabo. Tras una breve exposición del problema planteado por los autores en un trabajo anterior [15], se lleva a cabo una continuación de éste en cuanto a la aplicación de sustracción espectral de ruido en el problema de separación intraclase, pasando a un análisis de los nuevos resultados.

2 Caracterización del ruido de tráfico

El ruido de tráfico puede ser considerado como una señal de ruido compuesto [2][7][12][13], generada por la combinación de contribuciones individuales generadas a su vez por fuentes de ruido ligadas a cada uno de los vehículos. La base de datos utilizada a lo largo de este trabajo de investigación[15] hace uso de una definición de clases según tres categorías de vehículos: motocicletas, turismos y camiones. En un trabajo previo, estas clases han sido caracterizadas mediante un análisis en los dominios temporal y espectral de las señales que las componen. La complejidad de la señal de ruido analizada es fruto de la combinación de las contribuciones de ruido correspondientes a las diferentes fuentes localizadas en cada uno de los vehículos, descritas a continuación.

2.1 Identificación de fuentes

El análisis del ruido generado por un vehículo a motor, en buenas condiciones de uso, revela que éste viene determinado principalmente por la contribución de cuatro tipos diferentes de ruido: Ruido de motor, ruido aerodinámico, ruido de expulsión y ruido de rodadura.

Ruido de motor: Las fuentes involucradas en la generación de este tipo de ruido son de origen muy diferente (motor, suspensión, frenos,...). Para su caracterización es necesario llevar a cabo un estudio mediante un análisis de su comportamiento vibratorio.

Ruido aerodinámico: Debido a las turbulencias ocasionadas por la penetración del vehículo en el medio aéreo. Dichas turbulencias dependen principalmente de la geometría del chasis, incrementándose a medida que se eleva la velocidad del vehículo.

Ruido de expulsión: El sistema de expulsión de gases que incorpora un vehículo a motor es responsable de un alto porcentaje del ruido global generado por el mismo. En el estudio de este tipo de sistemas, es particularmente importante conocer la combinación del tipo de silenciadores incorporado (reactivo, absorbente,...) con objeto de poder reducir el nivel de ruido inducido.

Ruido de rodadura: La generación de este tipo de ruido viene determinada por la propagación de ruido estructural debido al contacto de los neumáticos con la superficie del pavimento. Sobre 50 Km/h (motocicletas y coches) y 70 Km/h (camiones), el ruido generado por un vehículo a motor queda principalmente caracterizado mediante el ruido a rodadura [7].

Finalmente, el ruido generado debido a la combinación de las fuentes descritas, se verá afectado [7] por las condiciones de propagación hacia el receptor, por el patrón de directividad del vehículo, por la distancia a la que se encuentra de la fuente este receptor y por el efecto Doppler. El ruido resultante caracteriza cada tipo de vehículo, permitiendo su clasificación mediante un análisis temporal y espectral de su comportamiento.

Por último, es necesario precisar que el presente trabajo se enmarca dentro de la separación de fuentes de tráfico en entornos interurbanos. Aunque en general existirá cierta energía reverberante en cierto tipo de vías interurbanas, el contexto en el que ha sido elaborada la base de datos sobre la que se aplica el estudio de separación de fuentes ruido de tráfico, permite hacer consideraciones de campo libre simplificando en parte la complejidad del problema. Para el resto de vías interurbanas, y para el caso general de vías urbanas, se hace necesario llevar a cabo el estudio en condiciones de campo reverberante.

3 Separación de fuentes de ruido de tráfico mediante BSS-ICA

El problema planteado en la separación de fuentes de ruido de tráfico se caracteriza por la ausencia de información en cuanto al número de fuentes que conforman la mezcla, sobre su caracterización y al modo en que éstas han sido mezcladas. El problema planteado, por tanto, puede ser abordado desde la Separación Ciega de Fuentes (*Blind Source Separation*) o BSS [8][9][11]. Para que exista solución, es necesario que las señales a mezclar sean estadísticamente independientes.

La formulación del problema, planteado en [15], hace uso de la técnica ICA (*Independent Components Analysis*). Esta técnica busca estimar la matriz de mezcla minimizando la dependencia estadística entre componentes de las señales mezcladas [5][6]. Las condiciones de aplicación son las siguientes:

- El número de mezclas no puede ser inferior al número de fuentes.
- Las fuentes a mezclar no pueden presentar más de una distribución gaussiana.

Bajo estas hipótesis, existe solución al problema planteado y es única desde un enfoque estadístico. La formulación matemática del problema no convolutivo, queda como sigue:

$$\begin{aligned}
 x_1(t) &= a_{11} \cdot s_1(t) + \dots + a_{1n} \cdot s_n(t) \\
 x_2(t) &= a_{21} \cdot s_1(t) + \dots + a_{2n} \cdot s_n(t) \\
 &\vdots \\
 x_m(t) &= a_{m1} \cdot s_1(t) + \dots + a_{mn} \cdot s_n(t)
 \end{aligned}
 \tag{1}$$

siendo A la matriz de mezcla y $s(t)$ y $x(t)$ los vectores de fuentes y observaciones respectivamente.

La solución pasa, por tanto, por encontrar una estimación de la matriz B^{-1} , que siendo B la matriz del sistema:

$$y(t) = B \cdot x(t) \tag{2}$$

donde $y(t)$ será a su vez un vector de estimación de $x(t)$.

3.1 Resultados previos

Del análisis realizado en [15] se extrae un buen comportamiento para el problema interclase como se puede apreciar en el error cuadrático medio de la Tabla 1. En el caso de la separación intraclase, se aprecia como aparece una mayor dispersión en las muestras para las clases de “Turismos” y “Camiones”., haciéndose más evidente para esta última.




Figura 1 – Scattering y densidad espectral de energía (motocicletas).




Figura 2 – Scattering y densidad espectral de energía (turismos).




Figura 3 – Scattering y densidad espectral de energía (camiones).

3.2 Error cuadrático medio

Error Cuadrático Medio		Clases		
		Motocicletas	Turismos	Camiones
Señal extraída	Motocicletas	$5,4908 \cdot 10^{-6}$	$1,0698 \cdot 10^{-6}$	$3,8165 \cdot 10^{-7}$
	Turismos	$2,8623 \cdot 10^{-6}$	$4,4961 \cdot 10^{-5}$	$3,7199 \cdot 10^{-6}$
	Camiones	$1,1101 \cdot 10^{-7}$	$1,6830 \cdot 10^{-6}$	$2,9287 \cdot 10^{-4}$

Tabla 1 – Error cuadrático medio en la separación de señales para el proceso BSS-ICA aplicado.

3.3 Separabilidad de la mezcla

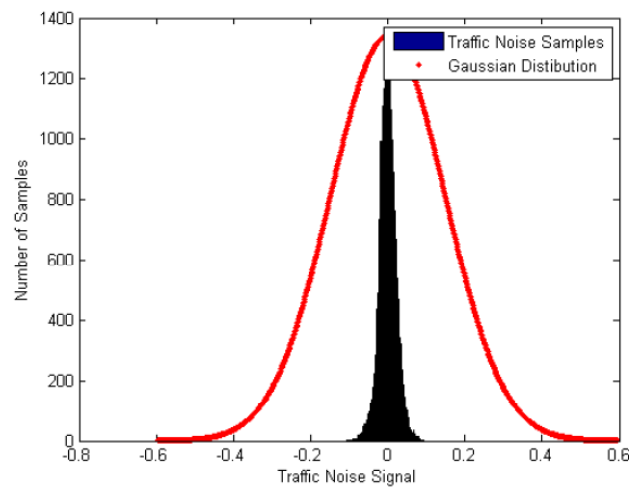


Figura 4 – Histograma de una señal correspondiente a la clase “Motocicletas”.

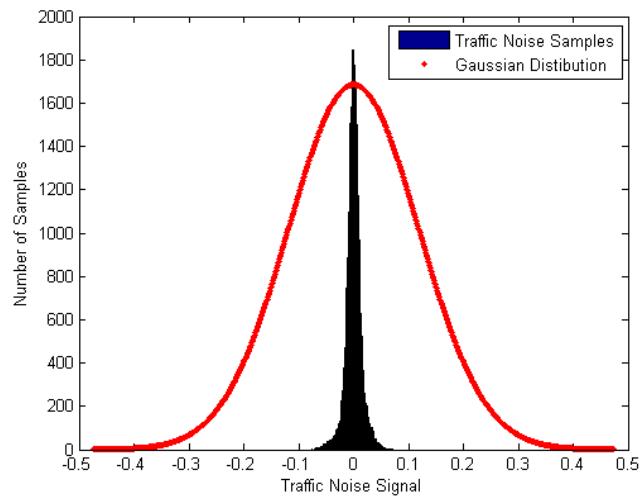


Figura 5 – Histograma de una señal correspondiente a la clase “Turismos”.

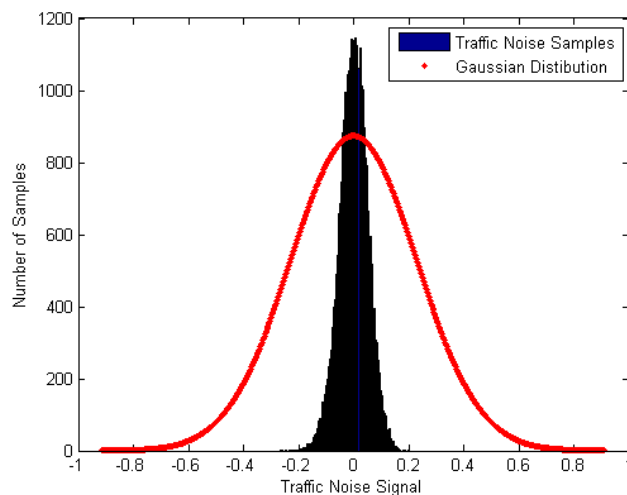


Figura 6 – Histograma de una señal correspondiente a la clase “Camiones”.

Desde un punto de vista matemático, la existencia de solución [10][3] requiere que la matriz A sea regular. Garantizada esta condición, resta verificar la hipótesis de no gaussianidad de las fuentes de entrada.

En las Fig. 1-3 se comparan los histogramas correspondientes a señales de cada una de las clases definidas con la fdp gaussiana construida a partir de la media y la varianza de las muestras. En dichas figuras queda patente la no gaussianidad de las fuentes a separar, lo que garantizará posteriormente la convergencia del método.

3.3.1 Medida de no gaussianidad

De entre los muchos algoritmos desarrollados para la aplicación de las técnicas ICA, se ha optado por el desarrollado por [10], debido a su excelente relación entre la calidad final obtenida y su coste

computacional asociado. Este algoritmo en punto fijo utiliza conjuntamente la Kurtosis y la Negentropía como medida de no gaussianidad en la estimación de componentes.

Para la optimización del valor de Kurtosis hace uso de la siguiente función de coste:

$$Kurt(\mathcal{G}^t x) = E\left(\left(\mathcal{G}^t x\right)^4\right) - 3\left(E\left(\left(\mathcal{G}^t x\right)^2\right)\right)^2 \quad (3)$$

donde los vectores solución \mathcal{G} se corresponden con las estimaciones de cada una de las componentes independientes del vector $s(t)$, buscando alejar de cero (valor de la Kurtosis para una fdp gaussiana) lo más posible su valor.

El algoritmo ICA de punto fijo utiliza la expresión de la Eq. (3), mediante la convergencia en la estimación de \mathcal{G} para cada k -ésima iteración según la siguiente expresión:

$$\mathcal{G}^{k-ésima} = \frac{1}{n} \sum_{i=1}^n \left(\mathcal{G}^t x\right)_i - 3\mathcal{G} \quad (4)$$

Otro modo de medir la no gaussianidad de las componentes extraídas es utilizar la Negentropía, definida mediante la siguiente expresión:

$$J(\mathcal{G}^t x) = H(v_{gauss}) - H(\mathcal{G}^t x) \quad (5)$$

donde v_{gauss} es una variable aleatoria gaussiana con la misma matriz de covarianza que $\mathcal{G}^t x$. Por otro lado H es la función de entropía, definida como:

$$H(\theta) = -\int f(\theta) \log(f(\theta)) d\theta \quad (6)$$

El algoritmo en punto fijo utiliza la expresión de la Eq. (8), mediante la aproximación

$$J(\mathcal{G}^t x) \propto \left(E(G(\mathcal{G}^t x)) - E(G(\gamma))\right) \quad (7)$$

siendo γ una variable aleatoria con fdp $N(0,1)$ y G una función no cuadrática. Las funciones no cuadráticas elegidas para su uso con el algoritmo son las siguientes:

$$G_1(\theta) = \frac{1}{\alpha} \log(\cosh(\alpha\theta)) \quad (8)$$

$$G_2(\theta) = -\exp\left(\frac{-\theta^2}{2}\right) \quad (9)$$

con $1 \leq \alpha \leq 2$.

3.3.2 Blanqueado y Rotación

El método hace uso de una proyección ortogonal, mediante decorrelación de las mezclas de entrada, factorizando la matriz de separación como sigue:

$$B = RW \tag{10}$$

siendo W la matriz de blanqueado y R la de rotación. Eliminando la componente continua de las muestras de entrada y aplicando una factorización SVD, se consigue el blanqueado de la señal. Se consigue así hacer coincidir con la matriz identidad la matriz de covarianza C , dada por:

$$C = E[s \cdot s^t] \tag{11}$$

Si bien es cierto que el estudio de estadísticos de segundo orden, y más en concreto el análisis suministrado por la decorrelación, permiten llevar a cabo un blanqueado de las muestras, ésta es una condición necesaria pero no suficiente para garantizar su independencia debido a la indeterminación que introduce la posible rotación de las mismas. Ésta es la razón por la que, como mucho, solamente una de las fuentes originales puede presentar una fdp Gaussiana, ya que, de existir más, la fdp conjunta presenta simetría circular imposibilitando con ello la separación.

4 Resultados

A continuación, se ilustra el efecto de la aplicación de substracción espectral de ruido [16][17], previa a la separación intraclase, contexto en el que esta técnica ha mejorado los resultados de aplicación globales obtenidos en [15]. Para ello se sigue la evolución del proceso de separación de una mezcla lineal correspondiente a dos fuentes de ruido de tráfico de las que han sido seleccionados dos secuencias de 30886 muestras de longitud. El caso de estudio corresponde a la mezcla de dos señales pertenecientes a la clase de “Camiones”, como peor caso en el problema de separación intraclase.

4.1 Blanqueado de la mezcla

Matriz U		Matriz D		Matriz V	
-0.3375	-0.6985				
0.3464	-0.2271				
0.7180	-0.0952				
0.0852	-0.1936	2.8463	0	-0.9615	0.2748
-0.2711	-0.0758				
-0.1455	0.3795				
-0.1431	0.3491	0	0.3964	-0.2748	-0.9615
-0.1086	0.2248				
-0.3022	0.0358				
0.1583	0.3010				

Tabla 2 – Factorización SVD de las observaciones (sin substracción espectral).

Matriz U		Matriz D		Matriz V	
-0.0286	-0.5560				
0.0601	-0.5469				
-0.5188	-0.1314				
-0.4300	0.0994	2.5515	0	0.9595	-0.2816
-0.1210	0.2005				
0.2032	0.3560				
0.4956	0.0609	0	0.4176	-0.2816	0.9595
0.4780	-0.0901				
-0.0393	0.2780				
-0.0992	0.3295				

Tabla 3 – Factorización SVD de las observaciones (con substracción espectral).

Como se puede apreciar en las Tablas 2-3, los autovectores de la matrices U y V, procedentes de la factorización SVD, son ortogonales e incorrelados, dando lugar a una nueva mezcla ortogonal e incorrelada. Los valores mostrados corresponden a las 10 primeras muestras.

4.2 Kurtosis y Negentropía

En la Figuras 7-8 podemos observar la diferente evolución de la solución, sin y con aplicación de substracción espectral previa a la mezcla a separar. Si bien en el segundo caso la Kurtosis muestra una distribución supergaussiana, se ha producido un alejamiento del valor nulo tanto para el valor absoluto de ésta como para el valor de de la Negentropía. Ambas métricas ponen de manifiesto una mejora en las condiciones de no gaussianidad como hipótesis de entrada a ICA, que se traducen en una mejora de los resultados obtenidos, como puede comprobarse en el apartado 4.3, Tablas 4-5 y Fig.9.




Figura 7 – Evolución de la optimización en el cálculo de la Kurtosis y Negentropía (sin substracción espectral).




Figura 8 – Evolución de la optimización en el cálculo de la Kurtosis y Negentropía (con substracción espectral).

4.3 Error cuadrático medio y densidad espectral de energía

Error Cuadrático Medio		Clases		
		Motocicletas	Turismos	Camiones
Señal extraída	Motocicletas	$5,4908 \cdot 10^{-6}$	-	-
	Turismos	-	$4,4961 \cdot 10^{-5}$	-
	Camiones	-	-	$2,9287 \cdot 10^{-4}$

Tabla 4 – Error cuadrático medio en la separación intraclase de señales para el proceso BSS-ICA aplicado (sin substracción espectral).

Error Cuadrático Medio		Clases		
		Motocicletas	Turismos	Camiones
Señal extraída	Motocicletas	$4,2153 \cdot 10^{-6}$	-	-
	Turismos	-	$3,5748 \cdot 10^{-6}$	-
	Camiones	-	-	$5,6534 \cdot 10^{-6}$

Tabla 5 – Error cuadrático medio en la separación intraclase de señales para el proceso BSS-ICA aplicado (con substracción espectral).

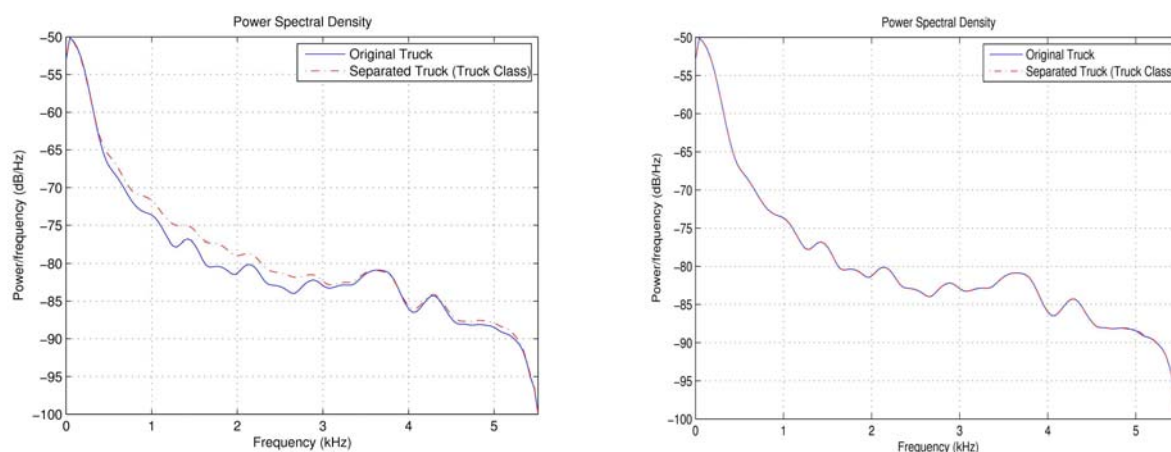


Figura 9 – Densidad espectral de energía sin sustracción espectral (Fig. Izda) y con sustracción espectral (Fig. Dcha).

5 Conclusiones

Se ha llevado a cabo un análisis en detalle de las prestaciones de la aplicación de sustracción espectral de ruido a una mezcla de fuentes de ruido de tráfico interurbano previa a la aplicación del algoritmo ICA en punto fijo. Como medida de estas prestaciones, se ha hecho uso de la información obtenida por la Kurtosis y la Negentropía, métricas estadísticas usadas como parámetros de medida de la no gaussianidad de las muestras de entrada.

Se ha demostrado que la aplicación previa de técnicas de sustracción espectral de ruido a la mezcla de entrada mejora drásticamente la calidad de la separación intracase. Este hecho viene a poner de manifiesto la existencia de cierto nivel de enmascaramiento, sobre todo en la zona de baja frecuencia, de componentes espectrales que diferencian a cada uno de los vehículos. Este enmascaramiento se hace más patente en el caso de los vehículos pesados, debido fundamentalmente a la distribución de componentes espectrales armónicas provenientes del ruido de motor.

Una adecuada definición de clases, suficientemente separadas entre sí, hace que para el caso de la separación intercase, no se aprecien mejoras significativas mediante la utilización de sustracción espectral de ruido. En el caso de la base de datos utilizada, sí se ha observado sin embargo una mejora para la clase de “turismos”, debido a la existencia de un solapamiento en la distribución de componentes armónicas con las clases colindantes.

Agradecimientos

Este trabajo ha sido parcialmente financiado por el MEC, ref. TEC2006-13883-C04-02, bajo el proyecto AnClaS3 "Sound source separation for acoustic measurements".

Referencias

- [1] Manolakis and Proakis. Digital Signal Processing: Principles. Algorithms and Applications. 3rd edition, Prentice-Hall.
- [2] Wu, H.; Siegel, M.; Khosla, P. Vehicle Sound Signature Recognition by Frequency Vector Principal Component Analysis. Submitted to *IEEE Instrumentation and Measurement*, 1998.
- [3] Prasad, R.; Saruwatari, H; Lee, A.; Shikano, K. A Fixed-Point ICA Algorithm for Convolved Speech Signal Separation. *ICA2003 4th Int. Symp.* Nara, Japan, April 2003, pp. 579-584.
- [4] Vincent, E.; Gribonval, R; Févotte, C. Performance Measurement in Blind Audio Source Separation. *IEEE Trans. on Speech and Audio Procc*, vol. 14 (4), 2006, pp. 1462-1469.
- [5] Févotte, C.; Gribonval, R.; Vincent, E. BSS_EVAL Toolbox User Guide. *IRISA Technical Report 1706.*, Rennes, France, April 2005.
- [6] Carlos, G. Procedimientos y Aplicaciones en Separación de Señales (BSS-ICA). *URSI 2003*. Departamento de Arquitectura y Tecnología de los Computadores, Universidad de Granada.
- [7] Miyara, F. Modelización del Ruido del Tránsito Automotor. Universidad Nacional de Rosario, Argentina.
- [8] Comon, P. Independent Component Analysis, a new concept ?. *Signal Processing*, vol. 36 (3), 1994, pp. 287-314.
- [9] Cardoso, J.F. Blind Signal Separation: Statistical Principles. Submitted to *IEEE* vol. 86 (10), 1998, pp. 2009-2025.
- [10] Cao, X.R.; Liu, R.W. General Approach to Blind Source Separation. Submitted to *IEEE Transactions on Signal Processing*, vol. 44 (13), 1996, pp. 562-571.
- [11] Oja, E. ; Hyvärinen, A. Independent Component Analysis: Algorithms and Applications. *Neural Networks* vol. 13 (4-5), pp. 411-430, 2000.
- [12] Cevher V.; Chellapp R.; McClellan J.H. Vehicle Speed Estimation using Acoustic Wave Patterns. Submitted to *IEEE Transactions on Signal Processing*.
- [13] Amman, S.A; Das M. An efficient technique for modelling and synthesis of automotive engine sounds. *IEEE Transactions on Industrial Electronics*, vol.48, February 2001, pp. 225-234.
- [14] Mato-Méndez, F.J. Automatic Segmentation of Traffic Noise. *International Congress on Acoustics - Acoustics'08*. París, July 2008.
- [15] Mato-Méndez, F.J.; Sobreira-Seoane, M. Aplicación de Técnicas de Análisis de Componentes Independientes en Separación de Fuentes de Ruido de Tráfico. *Tecniacústica 2008*, Coimbra, Octubre 2008.
- [16] Wu K.; Chen P. Efficient Speech Enhancement Using Spectral Subtraction for Car Hands-free Application. *International Conference on Consumer Electronics*, vol. 2, pp. 220-221, 2001.
- [17] Berouti M.; Schwartz R.; Makhoul J. Enhancement of Speech Corrupted by Acoustic Noise. *Proc.IEEE Int. Conf. Acoust., Speech, Signal Process.*, pp.208-211, Apr. 1979.