

APLICACIÓN DE TÉCNICAS DE INTELIGENCIA ARTIFICIAL Y TRATAMIENTO DE SEÑALES EN FUSIÓN

Farias, G.¹, Santos, M.²

¹ *Dpto. de Informática y Automática
E.T.S.I. Informática – UNED
28040 Madrid, Spain*

² *Dpto. de Arquitectura de Computadores y Automática
Facultad de Informática, Universidad Complutense
28040 Madrid, Spain*

Resumen: En el presente trabajo se exponen los principales desarrollos y resultados que se están obteniendo de la aplicación, en el ámbito de la fusión por confinamiento magnético, de técnicas de inteligencia artificial y de tratamiento avanzado de señales. Se mostrarán las distintas estrategias aplicadas y su uso en la determinación de patrones y la clasificación de este tipo de señales. *Copyright © 2005 CEA-IFAC*

Palabras Clave: Procesamiento de señales, Inteligencia Artificial, Wavelets, Redes Neuronales, SVM.

1. INTRODUCCIÓN

El CIEMAT, y específicamente la Asociación EURATOM/CIEMAT para fusión, obtienen a través de la generación de experimentos de fusión por confinamiento magnético un enorme número de señales en el dispositivo de fusión nuclear TJ-II. Los experimentos actuales realizados con plasma producen cientos de señales dinámicas en cada descarga de datos. Estas señales provienen de muy diversos sensores y han sido obtenidas en distintas condiciones, por lo que habitualmente no presentan, con un análisis inmediato, una forma común (Vega, 2004).

El grupo de trabajo compuesto por personal del CIEMAT, del Departamento de Arquitectura y de Computadores y Automática de la UCM, y del Departamento de Informática y Automática de la UNED, se ha enfrentado a la problemática de tratar estas señales, estableciendo objetivos como los que se describen a continuación:

- Procesar señales sin consideraciones físicas
- Determinar patrones en las señales
- Lograr clasificación automática
- Eliminar medidas redundantes
- Encontrar relaciones entre los distintos tipos de señales
- Revelar características de interés
- Extraer conocimiento

El problema no se había tratado con anterioridad desde un punto de vista puramente computacional. El estudio de las señales se hacía por parte de especialistas que tenían conocimiento sobre el significado físico de los diversos elementos de cada

señal. Dado el elevado número de señales de cada experimento, este tratamiento era inviable. De ahí la necesidad de automatizarlo.

En la sección 2 se describe las principales características de las señales de trabajo. En la sección 3, 4 y 5 se presentarán las técnicas. En la sección 6 se mostrarán resultados de combinar las técnicas descritas, finalmente en la sección 7 las conclusiones y trabajos futuros.

2. SEÑALES DE TRABAJO

Existen dos tipos de señales que han sido objeto de nuestro interés hasta el momento. Por una parte se han estudiado las señales denominadas *Descargas*, que tienen como principal característica la variación de su magnitud respecto del tiempo; por otro lado se han analizado señales bidimensionales o imágenes cuya magnitud y configuración proviene del Diagnóstico *Scattering Thomson*.

2.1 Descargas de Plasma

Las *Descargas* son señales unidimensionales representativas del comportamiento del plasma. Para una *Descarga* en particular existen diferentes señales asociadas al tipo de sensor analizado (clases), algunas de ellas se presentan en la tabla 1.

Las regiones de interés de las *Descargas* tienen una extensión que oscila entre los 150 y 250 [ms], y dependiendo de la frecuencia de muestreo, el número de muestras esta comprendido entre 4000 y 16000 por descarga.

Tabla 1 Tipos de Señales

Tipo	Descripción
HALFAC3	H α
DENSIDAD2_	Línea media de densidad electron.
BOL5	Señal bolométrica
ECE7	Emisión ciclotrónica

La figura 1 muestra las clases de la tabla 1 para una Descarga particular.

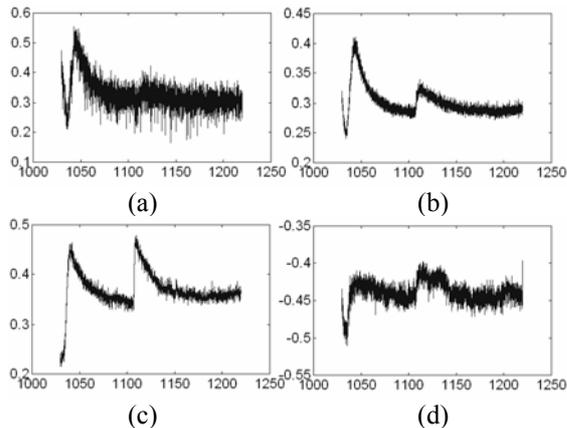


Fig. 1. Clases de señales para una Descarga:
(a) HalfaC3 (b) Densidad2_ (c) Bol5 (d) ECE7

Además, cada uno de esos tipos de señales admite perfiles con ciertas variaciones que van a dificultar su clasificación. De hecho, uno de los objetivos del proyecto es establecer las subclases que subyacen dentro de cada grupo de señales. Por ejemplo, en la Figura 2 se muestra las señales de tipo BOL5, y se observa que tienen formas distintas.

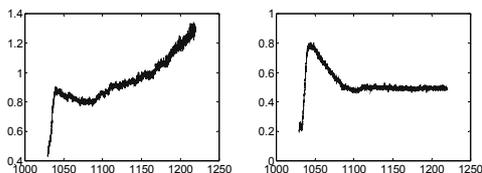


Fig. 2. Dos señales de la clase Bol5

Entre los principales inconvenientes de este tipo de señales se pueden mencionar:

- Presencia de ruido e interferencia
- Diferente número de muestras por registro
- Amplitud dependiente de la experiencia
- Evolución temporal rápida
- Elevado número de muestras

Debido a la situación anterior, se analizaron diversas técnicas de procesamiento y normalización de señales, entre las cuales se destacará la Transformada Wavelet en la sección 3.

2.1 Imágenes Scattering Thomson

El diagnóstico de dispersión Scattering Thomson (DST) es un análisis no perturbativo de tipo óptico, y que consiste en la reemisión de la radiación incidente en el plasma por parte de los electrones libres. La distribución de velocidades de los electrones se traduce en un ensanchamiento espectral de la luz dispersa y que cuyo comportamiento se relaciona con la temperatura electrónica. Por otra parte la cantidad total de fotones dispersos está relacionada con la densidad electrónica del plasma.

Las señales obtenidas son bidimensionales, y el personal del Grupo de Dispersión Thomson del TJ-II ha definido cinco tipos de patrones o clases de imágenes descritas en la tabla 2.

Tabla 2 Clases de Imágenes

Patrón	Descripción
BKGND	Fondo de la cámara CCD
COFF	Plasma en corte ECRH
ECH	Plasma con calentamiento ECRH
NBI	Plasma con calentamiento NBI
STRAY	Luz parásita sin plasma

En la figura 3 se pueden observar las imágenes de cada una de las clases. Se debe notar que la dimensionalidad de estas señales es bastante alta, 576x385 pixels.

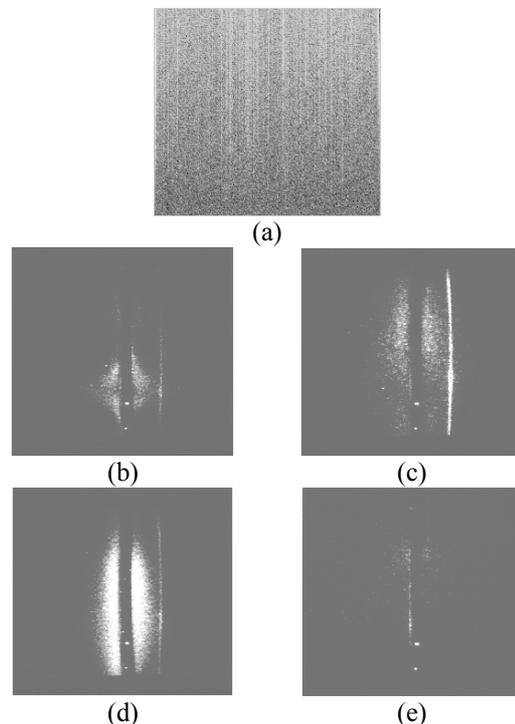


Fig. 3. Imágenes del DST para las cinco clases:
(a)BKGND (b)COFF (c)ECH (d)NBI (e)STRAY

Como se observa en la figura 2, todos los patrones, salvo BKGND, corresponden a imágenes con al menos cuatro características importantes: un vacío al centro, dos componentes centrales verticales, y una

línea fina a la derecha. Las diferencias entre un patrón y otro, corresponden a la intensidad de los componentes, elevado en el caso de las verticales centrales de la NBI, más tenue en el caso ECH, aunque con la línea fina muy marcada, o bien con las intensidades de las componentes centrales concentradas inferiormente, en el caso COFF, y prácticamente nulo en el caso STRAY.

Para las imágenes del Scattering Thomson contamos con una base de 46 señales, que vienen a resultar aproximadamente unas 9 por cada clase.

3. TRANSFORMADA WAVELET

La transformada wavelet (TW) es una alternativa a la Transformada de Fourier de Tiempo Corto en el análisis de señales no estacionarias. En esta transformada se usan ventanas pequeñas para las altas frecuencias y grandes para bajas frecuencias. Permite de este modo analizar la señal en distintas escalas o niveles de resolución. Permite también poner de manifiesto la existencia de discontinuidades cuando se desplaza hacia escalas menores. Entre sus aplicaciones están (Mallat, 2001; Vitterli, 2000):

- Aproximación y compresión de señales
- Reducción y eliminación de ruido
- Representación en múltiples escalas
- Representación tiempo-frecuencia
- Localización de patrones

Las wavelets son funciones matemáticas de cuadrado integrable, bien localizadas en los dominios temporal y de frecuencias con ciertas propiedades matemáticas; por ejemplo, la señal $\psi(t)$ con

$$\int_{-\infty}^{\infty} |\psi(t)|^2 < \infty$$

tal que,

$$|\psi(t)| \leq c(1+|t|)^{-1-\varepsilon}, \quad |\Psi(w)| \leq c(1+|w|)^{-1-\varepsilon}, \quad \varepsilon > 0$$

donde $\Psi(w)$ representa la transformada de Fourier de $\psi(t)$. A partir de esta señal, denominada *wavelet madre*, se forma una familia de funciones mediante las relaciones

$$\psi_{s,d}(t) = \frac{1}{\sqrt{s}} \psi\left(\frac{t-d}{s}\right), \quad s > 0, d \in R \quad (1)$$

Los parámetros s y d se denominan factor de escala y desplazamiento, respectivamente.

La Transformada Wavelet consiste en comparar la señal con versiones desplazadas y escaladas de las *wavelet madre*. Esta comparación permite obtener coeficientes de correlación entre la señal y las distintas versiones de la *wavelet madre*. A partir de los coeficientes es posible reconstruir la señal

original utilizando la Transformada Inversa (Daubechies, 1992).

Para reducir la carga computacional del cálculo de la TW, es posible utilizar factores de nivel (escala) y desplazamiento enteros, esta alternativa se denomina Transformada Wavelet Discreta (TWD).

Para señales unidimensionales la TWD presentará como resultado dos tipos de coeficientes: por un lado el coeficiente de aproximación que representa una versión suavizada y submuestreada de la señal original; y por otra parte el coeficiente de detalle que representa las componentes de alta frecuencias de la señal original.

El análisis wavelet bidimensional consiste en filtrar y submuestrear horizontalmente usando el filtro pasabaja unidimensional L y el filtro pasa alta H para cada fila en la imagen $I(x,y)$, produciendo las matrices de coeficientes $I_L(x,y)$ y $I_H(x,y)$. De esta forma el filtrado y submuestreo produce cuatro subimágenes $I_{LL}(x,y)$, $I_{LH}(x,y)$, $I_{HL}(x,y)$ y $I_{HH}(x,y)$ para cada nivel de descomposición. La subimagen $I_{LL}(x,y)$ representa la aproximación de $I(x,y)$. Las subimágenes $I_{LH}(x,y)$, $I_{HL}(x,y)$ y $I_{HH}(x,y)$ representan los detalles horizontal, vertical y diagonal de la imagen $I(x,y)$ (Santos, *et al.*, 2003).

Una vez tratada la señal mediante este tipo de herramientas que permiten a su vez extraer las distintas características de las mismas se ha pasado a aplicar diversas técnicas de clasificación

4. MÁQUINAS DE VECTORES SOPORTE

Las Máquinas de Vectores Soporte, SVM, son una reciente alternativa de solución al problema de clasificación. Una de sus principales ventajas es la rapidez de cálculo asociada al proceso de aprendizaje y de decisión. Aborda el problema a través de un procedimiento de optimización por el que se determina la existencia de un hiperplano que separe dos clases de señales (Vapnik, 2000, 2001).

4.1 Caso Linealmente Separable

Generalmente el problema de la clasificación ha sido tratado como la búsqueda de una recta (o hiperplano dependiendo de las dimensiones del problema) que separe o delimite las áreas pertenecientes a dos clases distintas. Para dos clases linealmente separable descritas por dos atributos que indican su posición en el plano, es evidente que pueden existir infinitas rectas para delimitar ambas zonas. Sin embargo un caso interesante puede darse al tratar de encontrar la recta que divide las dos zonas con márgenes de separación máximos. La figura 4 ilustra este caso.

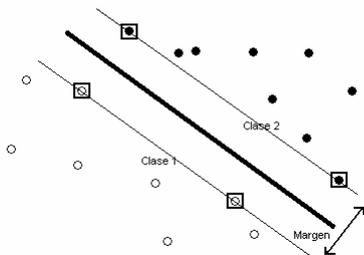


Fig. 4. Recta con máximo margen de separación

En este caso se debe resolver un problema de optimización cuadrático sujeto a restricciones lineales para obtener esa superficie de separación. Esta recta óptima queda completamente determinada por las señales marcadas en la figura, denominadas Vectores Soporte.

Finalizado el problema de optimización, y por tanto, determinados los vectores soporte, estos son utilizados para identificar la clase a la cual pertenecen nuevas señales.

4.2 Caso Linealmente No Separable

La separación a través de una recta o hiperplano de un conjunto de señales no es posible en la mayoría de los casos por las dimensiones propias del problema, por lo que es necesario recurrir a dimensiones mayores (o infinitas) para encontrar un hiperplano separador entre las clases.

Para la transformación de las dimensiones del problema a otras mayores, se utilizan funciones de transformación denominadas kernel o núcleo (Schölkopf y Smola, 2002). Estas funciones, que deben cumplir ciertos requisitos, permiten de manera sencilla enfrentar el problema de optimización de forma similar al caso de separabilidad lineal, aunque en un espacio de dimensión mayor.

5. REDES NEURONALES

Las redes neuronales (RN) se han utilizado con éxito en gran número de problemas y aplicaciones de reconocimiento de patrones. Existe diversidad de tipos de RN, cada una con estructura distinta de acuerdo a los propósitos de su aplicación. Sin embargo en todos los casos es posible encontrar sus componentes básicos: elementos de procesamiento denominados neuronas que se agrupan en capas (layers) y se conectan a través de sinapsis ponderadas con un peso (Hilera y Martínez, 1995).

En el caso que se expone se ha utilizado una RN de tipo feedforward con aprendizaje supervisado, para lo que se debe entrenar la red estableciendo en la capa de entrada los atributos de una señal determinada y los valores esperados en la capa de salida de acuerdo a la clase de la señal.

6. RESULTADOS

A continuación se presentan los principales resultados obtenidos utilizando combinaciones de las técnicas anteriormente expuestas.

6.1 Influencia del Procesamiento en la Clasificación

En Farias *et al.* (2004) se menciona la dificultad para abordar el problema de la extracción de características de un determinado tipo de señal cuando no se tiene conocimiento y experiencia en el ámbito del problema. Debido a esto es fundamental utilizar herramientas adecuadas que proporcionen la información relevante y eliminen (o atenúen) el ruido y la distorsión existente, así como la información redundante.

La TWD se ha utilizado en este caso para analizar las señales bidimensionales del diagnóstico Scattering Thomson (figura 5). El objetivo del trabajo fue determinar los parámetros de la TWD, esto es, los coeficientes de aproximación y detalles, la *wavelet madre*, el nivel de resolución, etc., que proporcionen los mejores resultados en un proceso de clasificación de las imágenes.

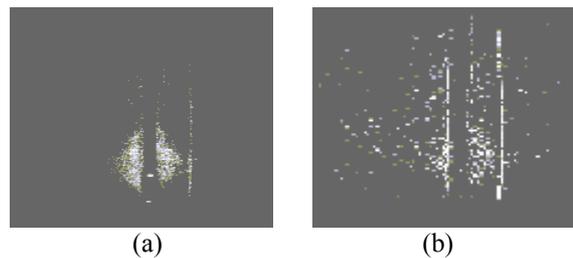


Fig. 5. Imagen Scattering Thomson y su TWD (a)Imagen COFF (b)Coeficiente Detalle Vertical

Para la clasificación de las señales, una vez aplicada la TWD, se utilizó la técnica SVM. Evidentemente para deducir conclusiones respecto a la modificación de los parámetros de la TWD, la estrategia de clasificación se mantuvo sin variaciones durante las pruebas y evaluaciones realizadas.

De todos los análisis realizados se pudo concluir que el nivel de descomposición presenta un óptimo, como se observa en la figura 6, donde se muestra el rendimiento del clasificador (potencia) versus el nivel de resolución.

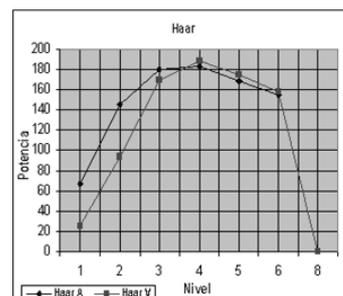


Fig. 6. Potencia del Clasificador versus Nivel

Otras conclusiones y resultados obtenidos fueron que para estas imágenes, la Transformada de Wavelet apropiada es la que tiene la *wavelet madre* de tipo Haar, a un nivel 4 de resolución, y con el coeficiente de Detalle Vertical. Es importante destacar que al aplicar la TWD mencionada las imágenes se reducen de 221.760 (576x385) atributos a 900 (36x25), es decir, los atributos obtenidos mediante la TWD representan el 0.4% del total de la señal original.

Cabe mencionar que la tasa de éxito promedio de clasificación fue 89.17%, lo cual es bastante satisfactorio considerando que el número de clases es alto (5) y la cantidad de señales es baja (46).

6.2 Clasificación de Imágenes del Diagnóstico Scattering Thomson

En Farias *et al.* (2005) se ha propuesto un clasificador para las imágenes del diagnóstico Scattering Thomson mediante la TWD y las RNs.

Los resultados presentados anteriormente se utilizaron para la parametrización de la TWD. En el caso de la Red Neuronal se diseñó la estructura feedforward multicapa. La entrada tiene 900 atributos provenientes de la etapa de procesamiento con TWD; se utilizó una capa oculta con 90 neuronas con funciones de activación *tansig*, y la capa de salida tenía 5 neuronas con funciones de activación *logsig*. Cuando se realiza el entrenamiento de esta RN se asocia cada señal a su clase mediante la activación de la neurona de salida correspondiente y la asignación a cero de las restantes.

Para implementar las ideas expuestas en el presente trabajo, se diseñó en Matlab una aplicación denominada **Scattering Thomson Classifier**. Esta aplicación permite manipular un conjunto de señales etiquetadas, y su función principal es la de evaluar la capacidad de distintos clasificadores que se pueden obtener al modificar parámetros como la *wavelet madre*, el nivel de resolución, el número de capas de la RN, sus funciones de activación, etc. La figura 7 presenta el interfaz de la aplicación.

Los resultados obtenidos para la configuración presentada se pueden observar en la figura 8.

En total se realizaron 86 experiencias, en las que se generaron 2 grupos aleatorios de entrenamiento y test, en donde el primero tenía el 60% de las señales. Cabe mencionar que para las experiencias realizadas sólo se contaba con 46 imágenes. La tasa de éxito promedio fue de 90.89%

Se debe hacer notar que los resultados serán probablemente mejores si se agrega conocimiento experto al análisis. Además es de esperar que las tasas de éxito mejoren cuando se cuente con un conjunto mayor de señales.

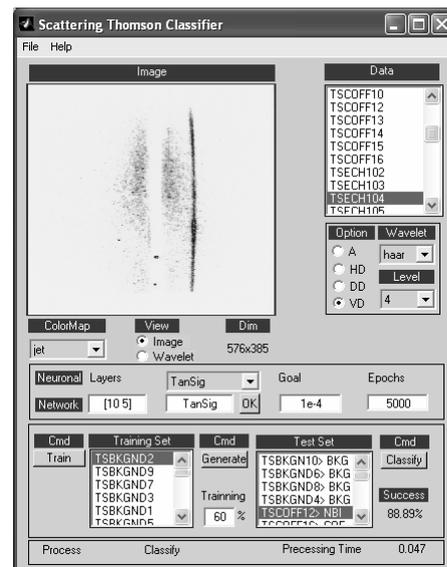


Fig. 7. Clasificador TWD + RN para imágenes Scattering Thomson.

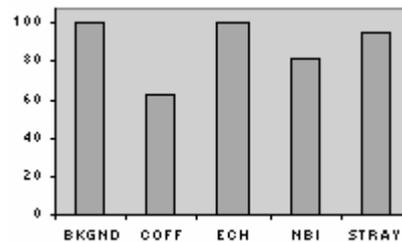


Fig. 8. Tasas de éxito por clase.

6.3 Clasificación de Descargas

Como se ha mencionado cada experimento en fusión termonuclear genera cientos de señales. Para el análisis de estas señales es importante tener mecanismos automáticos de clasificación y recuperación. En Dormido-Canto *et al.* (2004) y Dormido *et al.* (2004) se muestra como las técnicas de Transformada Wavelets y las Máquinas de Vectores Soporte son eficientes para el fin señalado. En los experimentos realizados se han utilizado señales pertenecientes a algunas de las clases que se muestran en la tabla 1.

Se calcula la TWD de las señales para reducir su dimensión. La figura 9 muestra una señal original y su Transformada Wavelet para el coeficiente de aproximación con tres niveles de resolución distintos.

Las señales se clasifican usando SVM. Se hace una clasificación en múltiples clases a partir de clasificaciones binarias de cada tipo de clase frente al resto mediante un grupo de señales de entrenamiento.

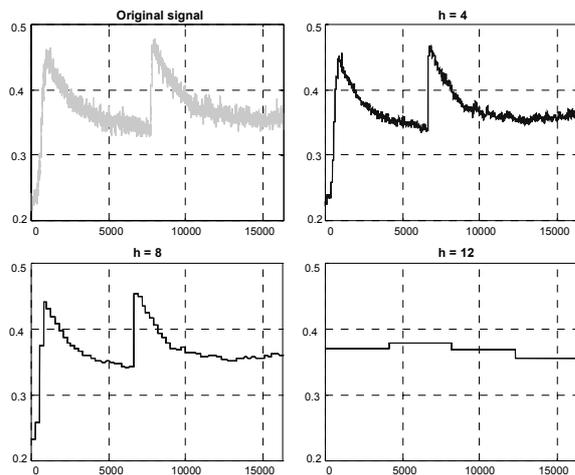


Fig. 9. Transformación wavelet de una señal con diferentes niveles de descomposición.

Los resultados para distintos kernels son presentados en la figura 11. Los porcentajes representan la tasa de éxito promedio de las cuatro clases, es decir el número de aciertos en la clasificación.

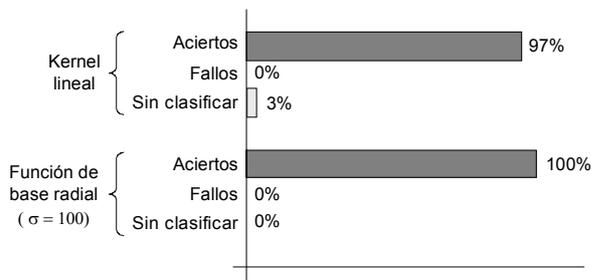


Fig. 10. Resultados para el experimento de cuatro clases de señales.

7. CONCLUSIONES Y TRABAJOS FUTUROS

Se han presentado los principales resultados obtenidos hasta el momento en la aplicación de técnicas de inteligencia artificial y tratamiento avanzado de señales en el ámbito de la fusión por confinamiento magnético.

Los resultados son prometedores, y alientan la espera de mejores tasas de éxito de clasificación en la medida que el número de señales se incremente o el conocimiento sobre las mismas sea más completo.

Por otra parte se debe notar que la mayor parte de las experiencias han sido realizadas con muy poco conocimiento de las particularidades de las señales, por lo que este será sin duda uno de los aspectos a considerar en el futuro.

Por otro lado, se quieren implementar también otros tipos de estrategias de clasificación: clustering difuso, árboles de decisión, “vecino más cercano”, etc., y comparar entre sí los resultados.

Junto con esto, se van resolviendo problemas inherentes a las señales que hacen referencia a condiciones de experimentación, etc. Un paso

importante sería incorporar ese conocimiento a los clasificadores. Por otro lado, también sería muy productivo el poder extraer conocimiento de las clasificaciones realizadas por estos métodos, es decir, encontrar la interpretación cualitativa, el significado físico, de las particularidades de las señales que han llevado a esas técnicas computacionales a una clasificación.

AGRADECIMIENTOS

Los autores desean manifestar su agradecimiento al grupo de trabajo de la UCM, UNED y CIEMAT por permitirse realizar este resumen.

REFERENCIAS

- Daubechies, I. (1992). *Ten Lectures on Wavelets*, SIAM.
- Dormido, S., De la Cruz, J.M., Vega, J., Santos, M., Dormido-Canto, S., Sánchez, J., Dormido-Canto, R., Farias, G. (2004) *Análisis de formas de onda de plasmas con wavelets y support vector machines*. 3ra. Conferencia Iberoamericana en Sistemas, Cibernética e Informática CISCI.
- Dormido-Canto, S., Farias, G., Dormido, R., Vega, J., Sánchez, J., Santos, M. (2004) *TJ-II wave forms analysis with wavelets and support vector machines*, *Review of Scientific Instruments* 75, 10, 4254-4257.
- Farias, G., Santos, M., Marrón, J. L., Dormido-Canto, S.: (2004) *Determinación de Parámetros de la Transformada Wavelets para la Clasificación de Señales del Diagnóstico Scattering Thomson*. XXV Jornadas de Automática, Ciudad Real (España), ISBN: 84-688-7460-4 .
- Farias, G., Dormido, R., Santos, M., Duro, N.(2005) *Image Classifier for the TJ-II Thomson Scattering Diagnostic: Evaluation with a Feed Forward Neural Network. Lecture Notes in Computer Science*. Springer-Verlag, 3562, 604-612.
- Hilera, J.R., Martínez, V.J.(1995), *Redes Neuronales Artificiales. Fundamentos, modelos y aplicaciones*. Ed. Ra-ma.
- Mallat, S. (2001). *A Wavelet Tour of Signal Processing*. 2º Edition, Academic Press.
- Santos M., Pajares G., Portela M., de la Cruz J.M. (2003) *A new wavelets image fusion strategy. Lecture Notes in Computer Science*. Springer-Verlag, Berlin, 2652, 919-926.
- Schölkopf, B., Smola, A.J. (2002) *Learning with Kernels*, MIT Press.
- Vapnik, V. (1998) *Statistical Learning Theory*, John Wiley & Sons, INC.
- Vapnik, V. (2000) *The Nature of Statistical Learning Theory*, 2º Edition, Springer.
- Vega, J. (2004). *Estado estacionario, tiempo real y participación remota en el horizonte de los dispositivos de fusión*. CISCI.
- Vetterli, M. (2000). *Wavelets, Approximation and Compression*, IEEE Signal Processing Magazine, pp. 59-73.