

APROXIMACIÓN NEURO-FUZZY PARA IDENTIFICACIÓN DE SEÑALES VIALES MEDIANTE TECNOLOGÍA INFRARROJA

G.N. Marichal, E. J. González, L. Acosta, J. Toledo

*Dpto. de Ingeniería de Sistemas y Automática y Arquitectura
y Tecnología de Computadores,
Universidad de La Laguna, La Laguna 38271. Tenerife.
Tel: +34 922 318329/Fax: +34 922 318288
Email: nico@isaatc.ull.es*

Resumen: En este artículo se presenta un sistema basado en tecnología infrarroja para la clasificación de marcas viales empleando un sistema Neuro-Fuzzy como herramienta de clasificación. El sistema se ha testado a partir de los datos suministrados cuando se ha instalado un prototipo en un robot móvil. Los resultados obtenidos son explicados en este artículo, haciendo hincapié en el diseño de nuevas reglas y la mejoría lograda mediante los métodos propuestos. *Copyright © 2007 CEA-IFAC*

Palabras Clave. Control Inteligente, Robótica, Navegación de robots, Sistemas Neuro-Fuzzy,

1. INTRODUCCIÓN

Varios grupos de investigación han venido mostrando durante los últimos años gran interés sobre el campo del transporte inteligente en general (Franke *et al.*, 2001) y en la detección y clasificación de señales mediante métodos automáticos en particular (Gupte *et al.*, 2002). El objetivo del diseño de tales métodos es doble. Por un lado, el apoyo a la conducción, con el consiguiente aumento de la seguridad y disminución de víctimas y pérdidas económicas (daños en vehículos, tiempo en colas, etc.). Por otro lado, facilitar la navegación de vehículos autónomos en entornos como calles, aparcamientos, etc. Una particularidad a tener presente en esta tarea, es que se ha de realizar en tiempo real, lo que implica una restricción en los algoritmos empleados, dado que han de ser lo suficientemente rápidos como para que el resultado obtenido sea útil de cara a la toma de decisiones.

La inmensa mayoría de implementaciones de sistemas de detección de señales se sitúan en el marco de la visión por computador (Franke *et al.*, 2001). No obstante, nuestro interés se centra en la tecnología infrarroja aplicada a la detección y

clasificación de marcas viales, diseñando un prototipo, así como los algoritmos más adecuados para tal fin. Teniendo en cuenta las limitaciones de tiempo, dichos algoritmos estarán basados en un conjunto reducido de reglas Fuzzy. Es importante remarcar que las técnicas de extracción de reglas y su interpretación han generado recientemente gran interés (Guillaume, 2001).

2. BREVE DESCRIPCIÓN DEL PROTOTIPO BASADO EN TECNOLOGÍA INFRARROJA

El sistema de captura de información consiste en un conjunto de sensores infrarrojos que nos permite obtener información de las señales viales horizontales, tras el procesamiento de los datos recogidos (Marichal *et al.*, 2006). Esta información resulta de gran interés en el campo de la Robótica, sobre todo cuando el robot móvil se encuentra navegando dentro de un entorno con presencia de marcas viales en el suelo, como puede ser el caso de un aparcamiento. La mayoría de aparcamientos presenta marcas viales horizontales sujetas a rígidas normas en su colocación. Si somos capaces de detectar e identificar estas señales, esto permite tener

más información sobre el entorno de navegación, que utilizada convenientemente, ayudaría considerablemente en la difícil tarea de movernos por un entorno sin férrea estructuración a priori.

El dispositivo global, consiste en un conjunto de 5 pares de emisores-receptores infrarrojos junto con la electrónica auxiliar necesaria, que barren de manera continua la zona de carretera sobre la que discurre el vehículo, identificando si la zona que cubre está pintada o no. Es importante destacar que los receptores de infrarrojo empleados, pueden ser únicamente excitados por señales de 36 kHz, lo que evita interferencias, procedentes de otras fuentes emisoras de infrarrojos.

La barra en la que se disponen los emisores-receptores permite su fácil instalación debajo de un vehículo, tal como se indica en la Figura 1. A medida que el vehículo circula, se obtiene una imagen línea a línea de la carretera y por tanto de la señal horizontal en particular. Cada una de estas líneas se compone de 5 datos, ya que hemos posicionado 5 sensores sobre la barra.

Características de sumo interés del prototipo basado en infrarrojos son su bajo precio y el poco espacio que dicho prototipo ocupa tal como se puede observar en la Figura 1. Estas características son muy apreciadas en Robótica donde espacio y coste son criterios fundamentales en cualquier diseño.

3. SISTEMA DE DETECCIÓN Y CLASIFICACIÓN

A partir de este punto se ha de fijar una estrategia de cara a encontrar el método más adecuado para procesar la información. En un primer estado del trabajo, se optó por la utilización de una estrategia de lógica Fuzzy (Zadeh, 1965) (Driankov, 1998), lo que supone la ventaja de obtención de un conjunto de reglas que permiten su integración en cualquier estrategia de control de más alto nivel (Brooks, 1986). Sin embargo, un inconveniente de esta estrategia es la búsqueda de las reglas, que resulta un proceso realmente tedioso. Como alternativa, hemos optado por el uso de una estrategia Neuro-Fuzzy, que nos permite aunar las propiedades de aprendizaje de las redes neuronales y la capacidad de estructuración del conocimiento en reglas por parte de la lógica Fuzzy.

3.1 Pre-procesamiento de los datos

En el caso que nos ocupa, el proceso de segmentación se reduce a escoger aquel conjunto de datos agrupados en líneas donde los valores indican presencia de reflexión. Esta es una característica de notable interés, en tanto en cuanto el tiempo invertido en el proceso es mínimo, frente a los algoritmos aplicados en visión. Sin embargo, una vez se ha

completado este proceso, todavía para una señal vial típica se puede obtener una matriz de 150 x 5 datos. De cara a utilizar una estrategia Neuro-Fuzzy, este número de datos debería de ser reducido en pro de facilitar el proceso de obtención de reglas. En este trabajo, se ha optado por dividir la imagen binaria en 5x5 ventanas, asociando a cada ventana un número que indica la proporción de detecciones obtenidas. Con este método, finalmente obtendremos 25 entradas para nuestro sistema Neuro-Fuzzy, lo que redundará en un sistema Neuro-Fuzzy más simple y consecuentemente una mayor eficacia en los algoritmos de aprendizaje.



Figura 1. Sistema infrarrojo sobre el vehículo utilizado.

En cuanto a las salidas del sistema Neuro-Fuzzy, se tomará una única salida, de tal forma que su valor este ligado a la señal que se quiere identificar. En la Tabla 1 se muestran los números de referencia, escogidos para cada señal. Esta opción ha sido elegida, frente a la más común de una salida por señal, dado que nuestro último objetivo es obtener un conjunto de reglas para cada señal, siendo de esta forma más fácil el análisis del sistema Neuro-Fuzzy, una vez entrenado.

Tabla 1. Valores de referencia de las salidas para un conjunto de señales típicas

Señales de Tráfico	Salida de Referencia
Flecha	1
Flecha a derecha	3
Ceda el paso	5
Flecha doble de frente-derecha	7

3.2 Estructura del sistema Neuro-Fuzzy

El sistema Neuro-Fuzzy empleado en este trabajo esta basado en la aproximación de Sugeno (Takagi y Sugeno, 1985; Matía et al., 2002). Como es bien conocido la aproximación de Sugeno es más conveniente en términos de carga computacional, que la de Mamdani (Mamdani y Assilian, 1975). Esta

característica es muy apropiada para la aplicación en consideración.

La estructura del sistema Neuro-Fuzzy usado, se podría ver como una red de 3 capas (Hush y Horne, 1993; Miller *et al.*, 1990), es decir, el sistema Neuro-Fuzzy se puede ver como una red neuronal de base radial, donde se ha insertado una capa intermedia entre una capa constituida por neuronas de base radial y una capa de salida conformada por neuronas lineales (Marichal *et al.*, 2001). Las neuronas de esta capa adicional calculan los grados de pertenencia correspondientes a las diferentes reglas, es decir, aplican el operador Fuzzy AND (operador min), siendo el número total de neuronas en esta capa igual al número total de reglas Fuzzy del Sistema Neuro-Fuzzy. Una vez, estos cálculos se han realizado, se aplica el proceso de defuzzyficación para obtener los valores numéricos de las salidas del sistema. Este proceso se realiza en la capa de neuronas lineales. Es importante resaltar que esta estructura permite la identificación de las reglas, frente a una aproximación únicamente basada en redes neuronales.

En el sistema Neuro-Fuzzy, hay algunos parámetros que determinan la relación entre las entradas y salida. En este caso, el comportamiento del sistema depende de los siguientes parámetros: Los centros de las funciones de pertenencia, las anchuras de las funciones de pertenencia y los valores de salida estimados. Para determinar todos estos parámetros se ha utilizado el algoritmo de aprendizaje que se muestra a continuación.

3.3 Algoritmo de aprendizaje

El algoritmo de aprendizaje se puede dividir en tres fases (Marichal *et al.*, 2001). La primera fase consiste en obtener unos valores iniciales para los centros de las funciones de pertenencia y los valores de salida estimados adecuados a esta aplicación. Se ha usado un algoritmo auto-organizativo de Kohonen (T. Kohonen, 2001). Con este algoritmo se buscan los valores iniciales, usando como patrones de entrenamiento los vectores formados por la unión de los valores asociados a las 5x5 ventanas en que se dividió la imagen binaria infrarroja y el número de referencia asociado a la señal vial correspondiente.

Es importante resaltar que la utilización de una red auto-organizativa de Kohonen nos permite aglutinar reglas según la señal a clasificar, sobre la base de que los valores de salida estimada parecidos darán lugar a reglas en nodos consecutivos. La segunda fase se focaliza en optimizar el número de nodos en la capa intermedia, es decir, el número de reglas Fuzzy. Mientras que la última fase se centra en ajustar los parámetros del sistema Neuro-Fuzzy, mejorando los obtenidos en las fases previas. Teniendo en cuenta las similitudes entre la red de base radial típica y el sistema Neuro-Fuzzy, se ha utilizado el algoritmo de

los mínimos cuadrados, tal como es habitual en este tipo de redes neuronales (Hush y Horne, 1993).

4. EXTRACCIÓN, SEPARACIÓN E INTERPRETACIÓN DE REGLAS.

Una vez determinado el sistema sensorial y el algoritmo Neuro-Fuzzy a utilizar, se hicieron pruebas sobre el vehículo que se muestra en la Figura 1. En Concreto se trata de un vehículo de propulsión eléctrica, modelo TXT-2 de la marca EZ-GO.

Con objeto de comprobar los métodos propuestos se han recogido un cierto número de imágenes infrarrojas sobre un conjunto de señales viales típicas. Aproximadamente este conjunto está constituido por unas 50 imágenes, tomadas en presencia de buenas condiciones climatológicas, sin dar instrucciones específicas al conductor, buscando las condiciones más habituales en la conducción. Este conjunto se ha dividido en dos subconjuntos, uno correspondiente al conjunto de entrenamiento y el otro correspondiente al conjunto de test. El primero, se ha utilizado en la aplicación del algoritmo de aprendizaje ya descrito, mientras el segundo nos ha servido para comprobar la capacidad de generalización del sistema Fuzzy resultante. Los valores de salida del sistema Neuro-Fuzzy han sido elegidos como se indica en la Tabla 1.

Hemos realizado varios entrenamientos off-line, obteniendo valores de error cuadrático medio del orden de 3.5×10^{-4} , después de 1000 iteraciones.

Una vez se ha realizado el entrenamiento, un modo de determinar el grado de generalización del sistema resultante es someterlo al conjunto de test. En la tabla 2, se puede observar el resultado de esta prueba, en donde, se ponen de manifiesto las buenas propiedades de generalización del sistema, dado que los valores del sistema se sitúan en torno a los valores de referencia para cada señal en particular.

Tabla 2. Salidas para los patrones de test

Patrones del conjunto de test	Valor de salida
Patrón Flecha 1	0.9973
Patrón Flecha a derecha 1	2.9800
Patrón Flecha a derecha 2	2.9763
Patrón Ceda el paso 1	5.3931
Patrón Ceda el paso 2	4.7881
Patrón Flecha doble de frente-derecha 1	7.0572

Se puede concluir, por tanto, que hemos conseguido un sistema Neuro-Fuzzy con unos parámetros concretos y satisfactorias capacidades de generalización. Obsérvese que el sistema resultante podría ser considerado como un sistema Fuzzy de tipo Sugeno, como era nuestro objetivo inicial. De hecho, se ha obtenido un sistema Fuzzy tipo Sugeno

de orden cero. El orden del sistema Fuzzy es de especial relevancia, dado que en sistemas de orden superior las reglas son más difíciles de interpretar y la complejidad computacional del sistema se incrementa. Por lo tanto, esto nos lleva a considerar que la solución al problema se ha convertido en un conjunto de reglas Fuzzy, susceptibles de ser explicitadas, a diferencia del resultado proporcionado por otras aproximaciones como son las redes neuronales. Sin embargo, una de las desventajas de los sistemas Neuro-Fuzzy es el gran número de reglas que habitualmente se obtienen, lo que dificulta enormemente la extracción de las mismas. En nuestro caso, después del proceso de entrenamiento y aplicando el proceso de minimización de reglas incluido en éste, se han obtenido finalmente 25 reglas.

En un análisis más detallado, sería de notable interés responder a las siguientes cuestiones: ¿Cuáles de estas reglas son importantes de cara a la clasificación? ¿Qué reglas son importantes para la clasificación de una señal en particular?.

Por otro lado, un conocimiento más detallado de estas reglas permitiría a un experto añadir nuevas reglas ó modificar las ya existentes en un intento de acondicionarlas mejor a un entorno particular en el que podamos movernos.

La respuesta a estas preguntas las podríamos encontrar en diferentes características del algoritmo de aprendizaje empleado. En nuestro caso, hemos comenzado el análisis, teniendo en cuenta uno de los parámetros del sistema Neuro-Fuzzy, los valores estimados para la salida. Los valores estimados de la salida son los valores que asociamos a la capa de neuronas lineales, donde se realiza el proceso de defuzzyficación. De tal forma que su contribución viene dada por la siguiente expresión:

$$Y = \frac{\sum_j sv_j \gamma_j}{\sum_j \gamma_j} \quad j=1,2,\dots,N2 \quad (1)$$

Donde:

Y = Salida del sistema Neuro-Fuzzy.

sv_j= Valor estimado de la salida, proporcionado por el nodo j-ésimo de la capa intermedia.

γ_j = Salida del nodo j-ésimo de la capa intermedia.

N2 = número de nodos de la capa intermedia (número de reglas Fuzzy).

Observando la expresión (1), se puede extraer la conclusión de que cada regla viene asociada a un valor estimado de salida. Comparando estos valores estimados de salida con los valores de referencia asociados a cada señal, se puede establecer una

primera correspondencia entre las reglas Fuzzy obtenidas y a que señal clasifican, tal como se muestra en la Tabla 3. De hecho, se puede comprobar tal como se apuntaba en la exposición del algoritmo de aprendizaje del sistema Neuro-Fuzzy, que las reglas que dan como resultado valores estimados de salida dentro del mismo rango, según la tabla 1, corresponden a reglas de nodos consecutivos. Esta característica redonda en la simplificación del análisis del sistema Fuzzy resultante.

Tabla 3. Reglas para cada señal de acuerdo a los valores estimados.

	Flecha	Flecha Derecha	Ceda el paso	Flecha doble Frente - Derecha	Otras Reglas
Intervalo	[0 2)	[2 4)	[4 6)	[6 8]	[-1 0]
Valor De Ref. Reglas	1	3	5	7	
	6, 7	8,9, 10,11, 12	13,14, 15,16, 17,18	19,20,21, 22,23, 24, 25	1,2, 3,4, 5

Sin embargo, es importante destacar que aparece una columna en la tabla 3, indicando valores estimados en el intervalo [-1, 0]. Evidentemente, no se puede establecer una correspondencia directa de estas reglas con ningún valor de referencia, dado que se alejan de los mismos. En una primera reflexión este fenómeno podría estar conectado con la aparición de neuronas muertas, tal como se conoce al fenómeno de que en las redes auto-organizativas, ciertas neuronas se encuentran lejos de los valores objetivos y no contribuyen en el aprendizaje (T. Kohonen, 2001). Por otra parte, aunque todas las reglas de una misma columna pueden contribuir a la tarea de clasificación de una señal específica, no queda claro que todas las reglas contribuyan a esa señal ó al menos al mismo nivel. Con el objeto de intentar aclarar estas dudas podríamos plantearnos utilizar otros parámetros del sistema Neuro-Fuzzy que resultarían relevantes en este propósito. Uno de los valores que en nuestra opinión debería ser considerado es la salida de capa intermedia γ_j que aparece en la fórmula (1). Obsérvese que esta salida viene a ser el resultado obtenido de los nodos de la capa intermedia, de tal forma, que tendremos un valor por cada regla. Por motivos de simplicidad nos referiremos a ella, como γ en lo sucesivo. De hecho, se sitúa en el rango de [0,1] y depende del patrón de entrada que se suministre al sistema Fuzzy, es decir, la imagen binaria infrarroja pre-procesada. El que se encuentre entre el rango 0 y 1, nos permite tomarla como un índice que nos indica la influencia que sobre la clasificación de una determinada señal tiene la regla Fuzzy correspondiente. Hasta tal punto, que podríamos hablar de porcentaje de influencia de la regla sobre la clasificación de un tipo de señal concreta.




Figura 2 –Valores de los centros de las funciones de pertenencia para varias reglas. (a) regla 13 (b) regla 14 (c) regla 15. (d) regla 6

Haciendo un análisis para un conjunto amplio de señales, observamos que muchas reglas tienen influencias iguales o menores al 0.1 % sobre la clasificación de señales. De hecho, se puede comprobar que existe un conjunto de reglas que independientemente de la señal en cuestión, dan un índice de influencia inferior o igual al 0.1 %. Esta observación nos lleva a no considerar estas reglas dada su aportación tan exigua al proceso de clasificación. Este hecho representa una simplificación del sistema Fuzzy, resultando conveniente en esta aplicación. Por otra parte, podríamos considerar en una primera aproximación todas aquellas reglas que influyen al menos en un 25% a la clasificación de una señal en particular. Con lo que finalmente nos quedamos con 14 reglas. En la tabla 4 presentamos ese conjunto de reglas para cada señal en particular.

Tabla 4. Reglas más importantes de acuerdo a los parámetros γ de un conjunto amplio de imágenes de señales.

Señal	Reglas
Flecha	1 2 3 4 5 6 7 9 10 11
Flecha Derecha	7 9 10 11 13
Ceda el paso	13
Flecha doble	22 23 24
Frente- Derecha	

Si comparamos las tablas 3 y 4, podemos ver como aquellas reglas cuyos valores estimados se encontraban en el intervalo $[0, -1]$, juegan un papel importante en la clasificación de ciertas señales, a pesar de que sus valores estimados están lejos de los valores de referencia para las salidas. Este hecho contribuye a ver con otros ojos el fenómeno de las neuronas muertas. Generalmente en el contexto de los algoritmos de aprendizaje aplicados a redes auto-organizativas se suele asociar con una ineficiencia de

los algoritmos. Sin embargo, en el contexto de este trabajo parecen contribuir a introducir un mayor grado de generalización del sistema Fuzzy resultante.

Otro aspecto que resulta de la comparación de tablas es que la tabla 4, representa un conjunto razonable de reglas a escoger para nuestro sistema, en la idea de simplificar al máximo el sistema Fuzzy resultante. Sin embargo, esta simplificación corre el riesgo de convertirse en excesiva, es decir, la tabla 4 podría tener un número demasiado pequeño de reglas para realizar la clasificación de forma adecuada. También, hay que indicar que sería interesante tener una visión más detallada de la estructura de las reglas obtenidas. De esta forma, un experto podría modificarlas de acuerdo a un conocimiento más específico del entorno ó podría diseñar nuevas reglas más apropiadas para la aplicación concreta. Para explorar estas cuestiones, en este trabajo nos hemos centrado en el caso más sencillo: La clasificación de una señal Ceda el Paso. Adicionalmente, hemos de considerar la importancia que esta señal en particular tiene de cara a evitar accidentes. Si observamos la tabla 4, la única regla que aparece en este caso es la regla 13. Por lo tanto, concluimos que el resto de reglas contribuyen a la clasificación del Ceda el paso por debajo del 25%. Si consideramos únicamente esta regla y la sometemos a las señales Ceda el paso utilizadas en el entrenamiento, la salida se encuentra en el intervalo de 4 a 6, como debería de ser según la tabla 1. Por lo tanto, se deduce que esta única regla es capaz de realizar el proceso de clasificación. Sin embargo, sería clarificador tener en cuenta las otras reglas de cara a ver su influencia. En este estudio consideraremos las señales utilizadas en el conjunto de entrenamiento, como en el de test indistintamente. Considerando una de las señales Ceda el paso utilizadas en el entrenamiento y considerando únicamente la regla 13 se obtuvo el resultado de 5.8049. Si considerásemos todas las 25 reglas el resultado sería 4.9972. Por lo tanto, estas reglas adicionales contribuyen a mejorar el proceso de clasificación.

Ahora, considerando un patrón Ceda el Paso del conjunto de test, el resultado considerando todas las reglas de la tabla 3 para la señal Ceda el Paso es de 5.4286. Sin embargo, si volvemos a considerar todas las 25 reglas obtenemos un resultado de 5.3931. Estos resultados nos llevan a indicar que el conjunto de reglas presentes en la tabla 3 representa un buen conjunto de reglas. De hecho si fuera necesario disminuir aun más el número de reglas, se podría optar por escoger aquellas reglas que tengan un nivel de influencia superior al 0.1 %, intentando no traspasar el límite del 25 % indicado por las reglas presentes en la tabla 4, dado que nos podría llevar a una clasificación inadecuada de las señales.

Por otro lado, estas reglas podrían ser estudiadas en mayor profundidad, intentando indagar en la estructura de las mismas. En la Figura 2 mostramos las imágenes construidas con los centros de las

funciones de pertenencia para varias reglas Fuzzy. Las imágenes están constituidas por ventanas que conforman una malla de 5 filas por 5 columnas, correspondientes a los valores de los centros de las funciones de pertenencia y asociando un color proporcional al valor, según una escala de grises. En la Figura 2 (a) podemos observar que la imagen corresponde a un Ceda el Paso invertido, siendo la regla estudiada la regla 13. Obsérvese que esta regla es la más importante en la clasificación de esta señal. En la Figura 2 (b) y Figura 2 (c), se han representado las imágenes en forma de mallas de 5 filas por 5 columnas, de las reglas 14 y 15. Estas reglas son menos significativas que la regla 13 en la clasificación de la señal Ceda El Paso, tal como se indicó en los párrafos anteriores. Como se puede observar estas reglas presentan imágenes con pequeñas diferencias respecto a la correspondiente a la regla 13. Podríamos concluir que estas reglas atienden a clasificar patrones ligeramente diferentes al patrón de un Ceda el Paso ideal, es decir, imágenes resultado de defectos en el proceso de medición. Estas imágenes podrían ser un buen punto de partida en el rediseño de las reglas de forma manual, adaptándolas a escenarios más concretos.

En el caso de otras señales de tráfico, un procedimiento similar podría ser aplicado. Como el caso de la regla 6, mostrada en la Figura 2 (d). Obsérvese que la tabla 3 y 4 relacionan esta regla con la señal correspondiente a una flecha.

5. CONCLUSIONES

En este artículo, hemos presentado un sistema de detección y clasificación de señales horizontales basado en reglas Fuzzy utilizando tecnología infrarroja. Partiendo de una Sistema Neuro-Fuzzy y un conjunto de medidas tomadas de un vehículo desplazándose en un aparcamiento, hemos obtenido un conjunto de reglas que nos permiten realizar convenientemente las tareas de detección y clasificación de un conjunto típico de señales viales horizontales. Un análisis posterior sobre las reglas nos ha permitido minimizar su número y asociar subconjuntos de reglas a la tarea de clasificación de cada señal en particular. La minimización de reglas, así como la asociación de las mismas a cada una de las señales, son características de notable interés en Robótica. Muchos modelos de control de robots móviles, tales como, la aproximación basada en comportamientos (Brooks, 1985) se fundamentan en la definición de reglas para cada una de las circunstancias con las que se puede encontrar el robot y en base a las que ha de adoptar alguna decisión.

Por último, señalar que sería de interés en futuros trabajos, determinar hasta que punto, condiciones climatológicas adversas o características especiales en la conducción influirían en la ineficiencia de los métodos propuestos.

AGRADECIMIENTOS

Este trabajo ha sido financiado por el proyecto DPI2004-06626.

REFERENCIAS

- Brooks, R.A. (1986). A robust layered control system for a mobile robot. *IEEE Journal of Robotics and Automation*, **2**, 14-23.
- Driankov, D., H. Hellendoorn, and M. Reinfrank: 1998, *An Introduction to Fuzzy Control*. Berlin: Springer.
- Franke, U. D. M. Gavril, A. Gern, S. Görzig, R. Janssen, F. Paetzold y C. Wöhler (2001). From Door to Door - Principles and Applications of Computer Vision for Driver Assistant Systems, chapter 6 in *Intelligent Vehicle Technologies*, L. Vlacic and F. Harashima and M. Parent, Butterworth Heinemann, Oxford.
- Guillaume S. (2001). Designing Fuzzy Inference Systems from Data: An Interpretability-Oriented Review. *IEEE Trans. On Fuzzy Syst.*, **9**, 3, 426-443
- Gupte, S., O. Masoud y N.P. Papanikolopoulos (2002). Detection and classification of vehicles, *IEEE Trans. on Intelligent Transportation Systems*, **3**, 37-47
- Hush, D.R. y B.G. Horne (1993). Progress in supervised Neural Networks. *IEEE Signal Processing Magazine*, **10**, 8-34
- Kohonen T. (2001). Self-Organising Maps. Springer series in Information Sciences, Vol. 30, Springer, Berlin, Third Edition.
- Mamdani, E.H. y S. Assilian (1975). An experiment in linguistic synthesis with a fuzzy logic controller, *International Journal of Man-Machine Studies*, **7**, 1-13.
- Marichal, G.N., L. Acosta, L. Moreno, J.A. Méndez, J. J. Rodrigo y M. Sigut (2001). Obstacle avoidance for a mobile robot: A neuro-fuzzy approach. *Fuzzy Sets and Systems*, **124**, 171-179.
- Marichal G.N., E.J. González, L. Acosta, J. Toledo, M. Sigut, J. Felipe (2006), An Infrared and Neuro-Fuzzy-Based Approach for Identification and Classification of Road Markings *Advances in Natural Computation. Lecture Notes in Computer Science*, **4222**, 918-927, 2006
- Matía F., B. M. Al-Hadithi, A. Jiménez (2002), Generalization of stability criterion for Takagi-Sugeno Continuous Fuzzy model. *Fuzzy Sets and Systems*, **129**, 295-309.
- Miller W., R. Sutton y P. Werbos, eds. (1990). *Neural Networks for Control*. The Mit Press, Cambridge.
- Takagi, T. y M. Sugeno (1985). Fuzzy identification of systems and its applications to modelling and control. *IEEE Trans. On Systems, Man and Cybernetics*, **15**, 116-132
- Zadeh, L.A.:1965, Fuzzy sets. *Information and Control* **8**, 338-353.