

Arquitectura para el aprendizaje de clasificadores en un sistema de visión basado en conocimiento

JOSÉ JAVIER LORENZO NAVARRO

RESUMEN

En este trabajo se expone la arquitectura funcional para el aprendizaje de clasificadores en el contexto de un Sistema de Visión Basado en Conocimiento. La arquitectura se orienta a la Inducción de los Clasificadores a partir de muestras seleccionadas por el diseñador en un contexto, en general, borroso. La adquisición y monitorización de muestras se realiza con una herramienta de interacción. La arquitectura se orienta a la selección de atributos o características relevantes, así como a la selección activa de muestras. Todo ello en evaluación global a partir de la calidad del clasificador. El clasificador inducido se basa en el paradigma de las Redes Neuronales y el resultado es interpretable. Se incluyen diversas reflexiones, consideraciones y conjeturas de diseño.

ABSTRACT

A Functional Architecture for Teaching Classifiers in a Knowledge Based Vision System

In this paper, we present a functional architecture for teaching of classifiers in a Knowledge Based Vision System. The architecture is aimed at induction of Classifiers from a series of samples chosen by the designer generally from within a fuzzy context. The control and choice of samples is carried out via an interactive tool. The architecture is designed towards facilitating the choice of relevant characteristics and attributes whilst also allowing for active choice of the samples. This is effected by working on the level of global assessment based on the quality of the classifier. The induced classifier is based on the model of neuron networks with an interpretable result. Various other considerations and models of design are discussed.

INTRODUCCIÓN

La Visión por Computador es el área dedicada al estudio de teorías y desarrollo de métodos y algoritmos cuyo objetivo final es la obtención de sistemas de percepción visual artificial, es decir, sistemas no biológicos con capacidad de obtener información a partir de imágenes o secuencia de ellas. Este área ha sufrido una evolución en lo que a metodologías de diseño y desarrollo de dichos sistemas se refiere. Por un lado esta evolución ha aparecido en la consideración de que un Sistema de Visión no es un elemento aislado que se relaciona de forma pasiva con su entorno, sino que es un elemento más, que forma parte del mismo y, por tanto, es necesario considerar el sistema interactuando con el entorno en un bucle percepto-efector [ALOI-88].

Aparte de la anterior consideración conceptual de los Sistemas de Visión, ha existido también un nuevo planteamiento en las metodologías empleadas, conducentes a resolver el compromiso entre flexibilidad y eficacia de los sistemas desarrollados, con relación a modificaciones del entorno. Así se constata que sistemas muy eficientes, que son válidos en ciertos entornos, degradan su características de comportamiento frente a ligeras variaciones del entorno de trabajo. En este sentido, eficacia y flexibilidad son dos objetivos que muchas veces se contraponen. Es decir, sistemas muy eficaces suelen ser muy específicos y, por lo tanto, costosos de desarrollar. Al mismo tiempo, y en general, su po-

sibilidad de reutilizarlos en otros entornos es baja.

Una forma de resolver este compromiso, se asienta en la segunda tendencia metodológica que ha aparecido en el desarrollo de Sistemas de Visión. Ésta se basa en la adopción de técnicas provenientes de la Inteligencia Artificial, concretamente de los Sistemas Basados en Conocimiento [MEND-94].

En la aproximación basada en el conocimiento se asume que cualquier situación o evento a ser reconocido o detectado puede ser explicitado mediante algún mecanismo de representación de conocimiento [VERN-91]. Así se considera que todos los procesos del sistema de visión desde los que se involucran a los sensores hasta los niveles más alto de interpretación de imágenes, involucran tanto de forma intensiva como extensiva el uso del conocimiento. Aunque desde un punto de vista teórico, el uso de estas técnicas no es un requisito estricto sino más bien de utilidad, ya que es un hecho que la representación explícita del conocimiento facilita el proceso de introducción de conocimiento específico en el proceso de desarrollo del mismo. También se facilitan las tareas de verificación del sistema, así como de su reutilización e inclusión de ciertas heurísticas para la resolución del problema.

De todo lo anterior surge un paradigma en el diseño de Sistemas de Visión, que es el de los Sistemas de Visión Basados en Conocimiento (SVBC). En este enfoque surge un importantísimo cuello de botella que es el relacionado con la adquisición del conocimiento, es decir, la correlación del conocimiento del

diseñador con los datos manejados por el sistema [NIEM-90]. Por lo tanto uno de los puntos fuertes de esta aproximación también se convierte en uno de los principales escollos a salvar.

Desde el punto de vista de un sistema artificial, que interactúa con un cierto entorno, podemos entender el aprendizaje como el conjunto de mecanismos que permite acoplar o sintonizar el funcionamiento del sistema con su entorno, de forma que el desenvolvimiento se realice de la forma más eficaz posible, siempre dentro de los objetivos planteados en el diseño. Las aproximaciones existentes al problema del aprendizaje pueden ser muy diversas y las problemáticas a resolver en los casos de los Sistemas de Visión muy variadas [BOWY-94]. A continuación se enmarcará el contexto de SVBC sobre el que vamos a trabajar, así como la tipología concreta del problema de aprendizaje objeto de este trabajo.

SVEX: UN SISTEMA DE VISIÓN BASADO EN CONOCIMIENTO

El trabajo que aquí se presenta se enmarca dentro del SVBC denominado SVEX. Este sistema está concebido como un sistema percepto-efector estructurado en tres niveles. Cada uno de estos niveles viene definido por la naturaleza del grano de información que se maneja [MEND-94] [CABR-94] [HERN-95]. Así, en el nivel de información la unidad de información que se maneja es el pixel, en el nivel intermedio la unidad de in-

formación es el segmento y, por último, en el nivel superior la unidad es el objeto (Figura 1).

Cada uno de los niveles que compone SVEX, se considera como una máquina virtual en la cual las estructuras de datos y los operadores están orientados a manipular el grano de información correspondiente al nivel. De lo anterior se establece la existencia de un procesador de pixels (Figura 2), un procesador de segmentos y un procesador de objetos.

La arquitectura de cada uno de estos procesadores está concebida para que la manipulación del conocimiento resulte claramente explícita, tanto en lo que se refiere a aspectos visuales como a aspectos de control e inferencia. La interconexión de cada uno de estos niveles con los restantes está planteada de forma que cada uno de ellos reciba datos del nivel inferior y suministre al nivel superior respuestas a peticiones relacionadas con el grano de información de cada nivel. Para la elaboración de las respuestas se dispone tanto de mecanismos de computo como de lanzamiento, verificación y contrastación de hipótesis.

En cada uno de los niveles de SVEX, coexisten dos dominios, un dominio numérico y un dominio simbólico. El dominio numérico se relaciona con cálculos de características o atributos acerca del grano de información del nivel y se obtiene en general a partir de la información aferente al nivel. Así por ejemplo para el caso de los pixels estas características pueden ser el valor de alguna componente de color RGB, el valor de gradiente de la in-

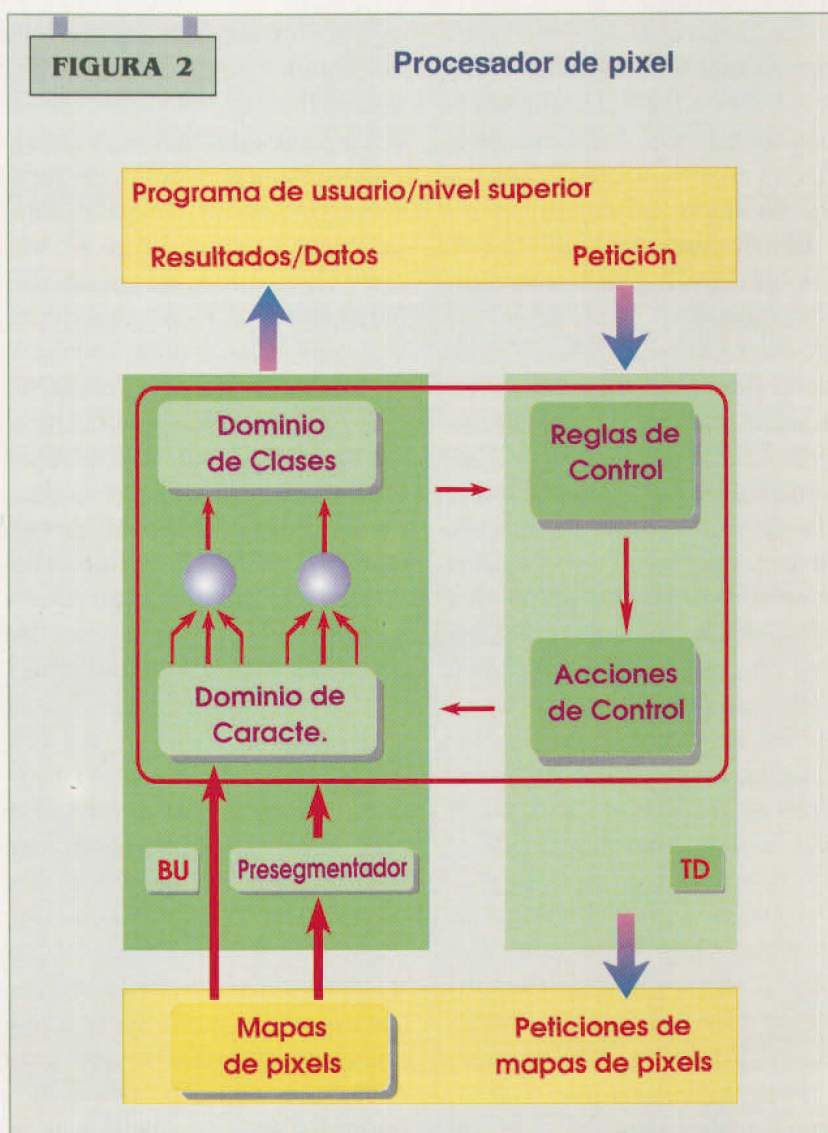
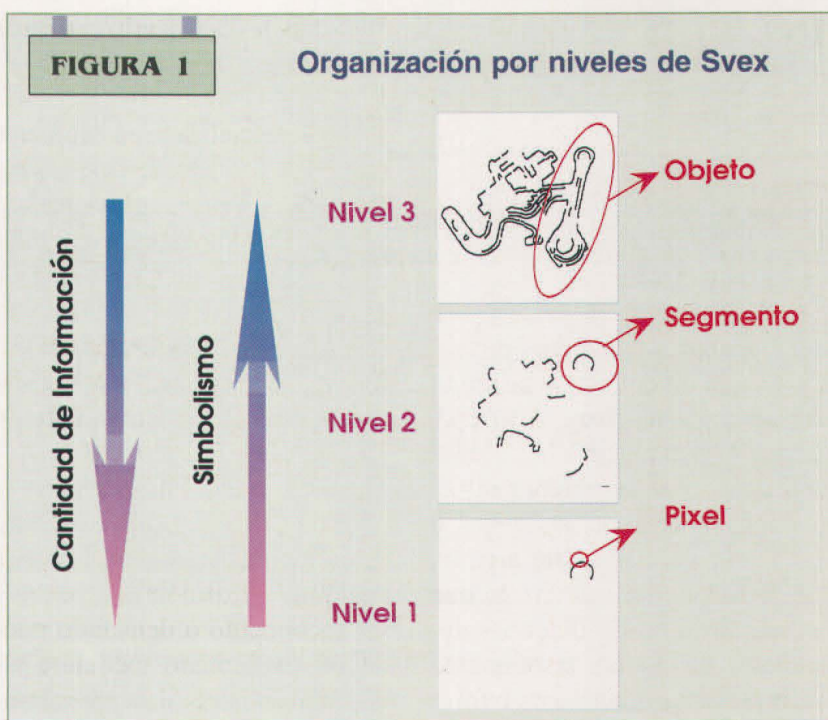
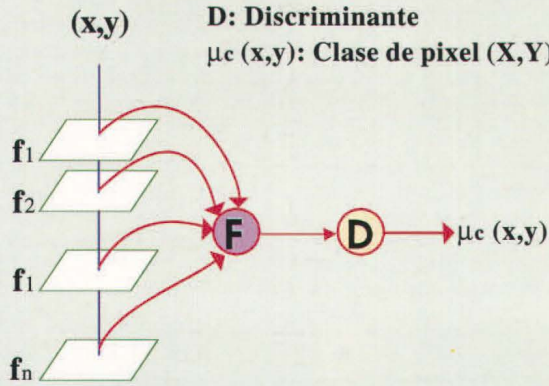


FIGURA 3

Clasificador

f_i : Característica i
F: Funcional
D: Discriminante
 $\mu_c(x,y)$: Clase de pixel (X,Y)



tensidad, etc. y en el caso de los segmentos pueden ser número de pixels de un segmento, curvatura promedio, etc. Todas estas características o atributos son elementos implícitos que aparecen en la unidad de información y que se explicitan mediante el uso de operadores o procedimientos. Por lo anterior, a este dominio se le denomina *dominio de las características*. El otro dominio es el *dominio de las clases*, que se relaciona con categorías visuales asociadas con el correspondiente grano de información, y que son parte fundamental de la explicitación del conocimiento acerca de los problemas. Como ejemplo de estas categorías visuales se pueden encontrar a nivel de pixel las clases: pixels_verdes, pixels_de_bordes, etc., y a nivel de segmentos se pueden encontrar clases: cua-drados_rojos, círculos_negros_inscritos_en_círculos_verdes, etc.

Debido a que la unidad de información (pixel, segmento u objeto) se mantiene en cada nivel, el paso del dominio numérico al dominio simbólico consiste en la abstracción, es decir, la asignación de cada ocurren-

-en muchos casos- de forma discreta. Es decir, la diferenciación entre hechos que son asignados a una categoría y los que no lo son se hace de forma gradual y con contornos no nítidos, existiendo una zonas donde la asignación es clara en cuanto a la pertenencia a la clase, y existen otras de transición donde dicha asignación no es tan clara. Estas observaciones son particularmente aplicables a los aspectos relacionados con las impresiones visuales [LAMM-94]. Un modelo matemático para formalizar este hecho es mediante la Teoría de los Conjuntos Borrosos [ZADE-71], en la cual los grados de pertenencia reflejan de forma numérica la incertidumbre o falta de nitidez mencionada anteriormente.

Dentro del marco de los SBVC el proceso de abstracción se puede llevar a cabo mediante el uso de clasificadores, que son mecanismos computacionales cuya misión es la asignación de un grado de pertenencia a una categoría o clase a cada ocurrencia del grano de información elemental del nivel correspondiente. Para ello utilizan como entra-

cia de la unidad de información a una categoría o clase con significado. En estudios sobre el proceso de categorización humana en diferentes campos como: ciencia cognitiva, psicología, lingüística, antropología o filosofía, ha quedado demostrado que la asignación de ocurrencias a clases no puede hacerse

das las características calculadas a partir de la información aferente al nivel, que combinadas según un funcional, y haciendo uso de un discriminante, obtienen el grado de pertenencia (Figura 3).

Así este trabajo se orienta a la resolución del problema de la determinación de los clasificadores en el marco del sistema SVEX, considerado como un problema de aprendizaje en tiempo de compilación de las aplicaciones de la conversión numérica a simbólica. En los siguientes apartados se realizará una presentación y discusión de la arquitectura conceptual propuesta para el aprendizaje de los procesos de simbolización antes mencionados.

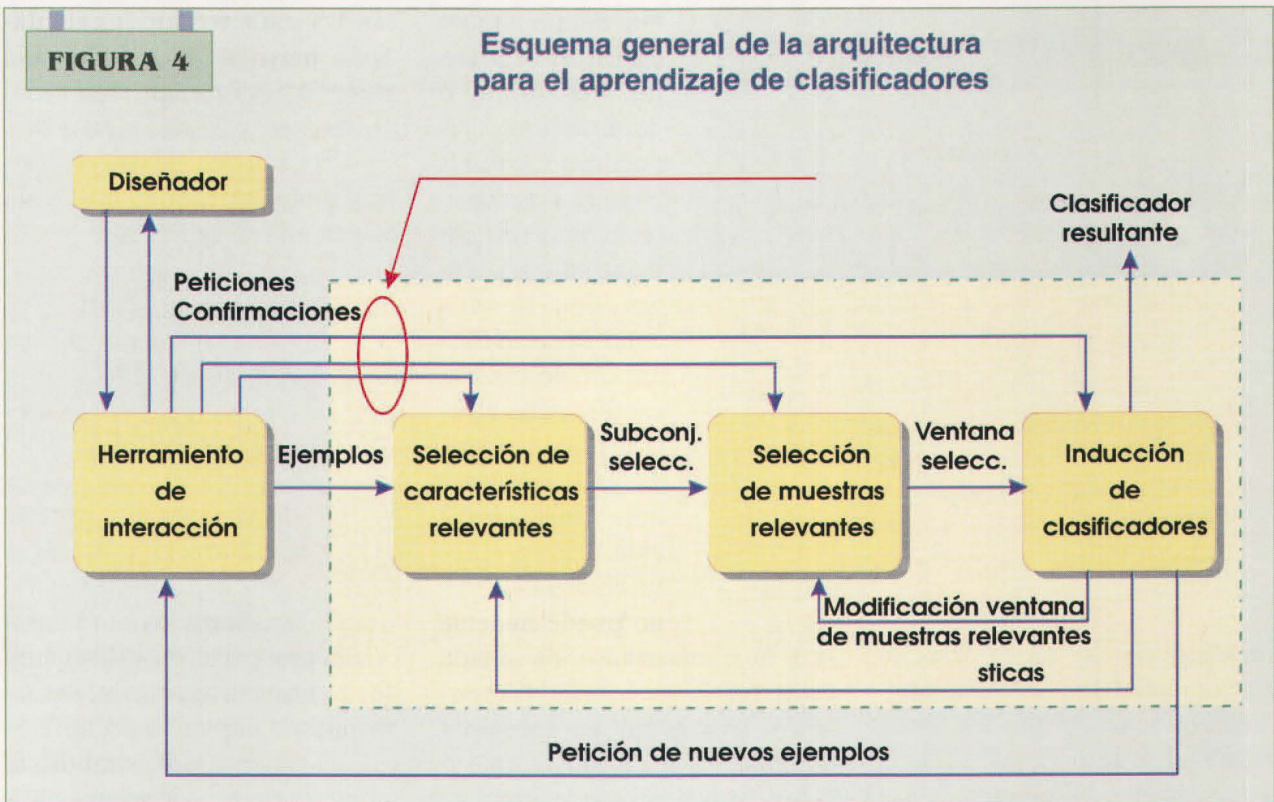
CONSIDERACIONES DE DISEÑO

El problema de la abstracción esbozado en el apartado anterior, se ve condicionado por los siguientes elementos:

a) En general no es posible definir de forma explícita qué clasificador se adapta a un problema concreto, sino el conocimiento que se tiene al respecto viene reflejado como un conjunto finito de ejemplos de los cuales se conoce, siempre según el criterio del diseñador del sistema, el grado de pertenencia a la clase. Por tanto, el conocimiento viene dado en forma de muestras consistentes de pares *atributo* (constituidos por vectores numéricos de características) - *valor* (la correspondiente clasificación, generalmente borrosa).

FIGURA 4

Esquema general de la arquitectura para el aprendizaje de clasificadores



b) Por otro lado, las características o atributos que son relevantes a efectos de la definición de una clase no se conocen de forma precisa *a priori*; como tampoco son conocidas qué muestras de todas las seleccionadas son las que aportan la información suficiente para poder inducir el clasificador a partir de las mismas.

c) El conocimiento acerca de los problemas de abstracción es escaso y las definiciones de las relaciones entre características y clases, como hemos comentado anteriormente, posee en general incertidumbre.

d) No es adecuado establecer restricciones *a priori* acerca del comportamiento estadístico de las muestras ni de la distribución de las mismas con respecto a la clase, en el espacio de las características.

Por todo lo anterior, es necesario plantear el proceso com-

pleto de aprendizaje de clasificadores atendiendo a las siguientes consideraciones:

a) Definición de un mecanismo de interacción con el usuario, tanto para la adquisición de ejemplos, como para la evaluación del estado de los procesos y modificaciones de los parámetros y condiciones de los mismos.

b) Definición de mecanismos para la selección de la información relevante. Esta información se debe extraer del conjunto de ejemplos, y hace referencia a qué características o atributos son relevantes incluyendo su grado de relevancia comparativo con el resto, así como a qué muestras o ejemplos del conjunto aportan más información para el proceso de inducción del clasificador.

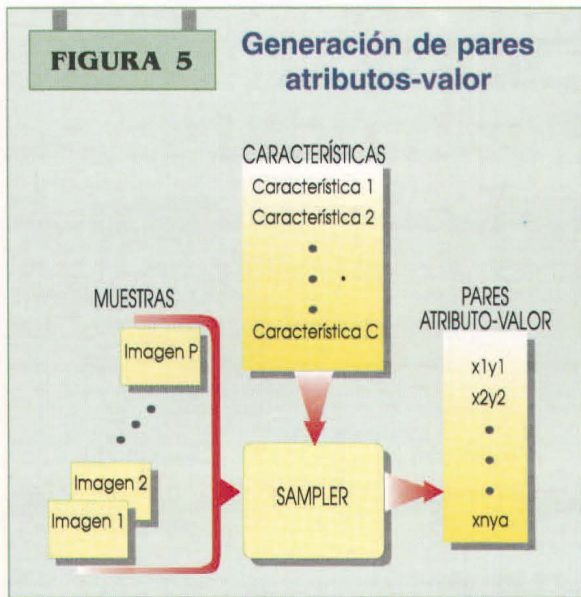
c) Definición del mecanismo que permita la inducción del clasificador, sin que presu-

ponga restricciones en cuanto a la forma de las regiones de las clases en el espacio de características.

En la Figura 4 se muestra el esquema general del proceso de aprendizaje de clasificadores, y en los siguientes apartados se pasa a describir los diferentes módulos y las interacciones que existen entre ellos, y que conforman el sistema completo.

INTERACCIÓN Y ADQUISICIÓN DE MUESTRAS

El aprendizaje de clasificadores, al ser basado en ejemplos, precisa de una herramienta que permita la adquisición de muestras etiquetadas, es decir, un conjunto de pares atributo-valor. Estos pares están consti-



tuidos por vectores de características que ha sido seleccionadas previamente por el usuario, y el grado de pertenencia asignado por éste a una clase determinada. En la Figura 5 se puede ver el esquema de funcionamiento de este proceso, donde de un conjunto de imágenes el usuario selecciona las muestras a las cuales les ha asignado un grado de pertenencia a la clase. Para estas muestras, se obtienen los vectores de características cuyos elementos han sido seleccionados previamente, y como resultado se obtiene el conjunto de pares atributo-

valor, antes mencionado. A partir de este conjunto de muestras, denominado *conjunto de aprendizaje*, el sistema debe inducir un clasificador que lleve a cabo la generalización de clasificación para otras muestras no utilizadas en el proceso de aprendizaje.

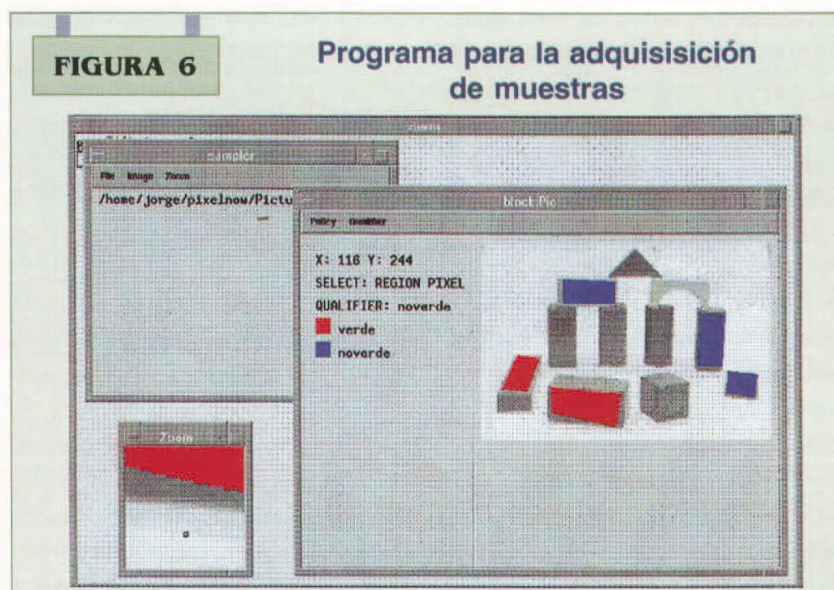
En el diseño de esta herramienta (denominada en el proyecto como Sampler) se incluye como un elemento esencial en el diseño la comodidad de utilización, ya que va a ser el medio de interacción del usuario con el sistema. La comunicación del usuario con el sistema también va a permitir que este último pueda interrogar al usuario sobre el grado de pertenencia a la clase de muestras que son seleccionadas por el propio sistema, es decir, muestras que no pertenecen en principio al conjunto de aprendizaje creado por el usuario. El hecho de habilitar

este tipo de comunicación entre el sistema y el usuario va a permitir un refinamiento en el proceso de aprendizaje en curso. Una imagen de un prototipo de esta herramienta se puede ver en la Figura 6.

SELECCIÓN DE CARACTERÍSTICAS

Para realizar el proceso de abstracción se debe partir de un conjunto de características o atributos, que combinados adecuadamente proporcione un clasificador capaz no sólo de etiquetar correctamente todas las muestras pertenecientes al conjunto de aprendizaje, sino también el resto de las ocurrencias del grano de información no usadas en el proceso de aprendizaje. Así la inducción del clasificador se puede descomponer en dos subproblemas. Por un lado, encontrar el conjunto de características adecuado para la definición de la clase y, por otro lado, buscar la regla de combinación de éstas.

En lo que respecta al primer problema, la selección de las características, es el mismo que se plantea en áreas como el Reconocimiento de Formas o el Aprendizaje Automático, no existiendo aún un modelo eficaz para resolverlo de forma óptima, sino diversas aproximaciones al mismo, que en muchos casos son bastante dependientes de la naturaleza del problema. El enfoque más común de tratar la selección de características se basa en definir un conjunto inicial de éstas, donde se presupone que un subconjunto de las mismas es



suficiente para llevar a cabo el proceso de clasificación en el caso de Reconocimiento de Formas, o para la inducción del concepto en el caso del Aprendizaje Automático.

Si se utiliza la aproximación antes mencionada, el problema de selección de características se transforma en un problema de búsqueda del subconjunto de características relevantes en el espacio de las características [LANG-94], donde cada estado de este espacio se corresponderá con una configuración de atributos o subconjunto de características del conjunto inicial.

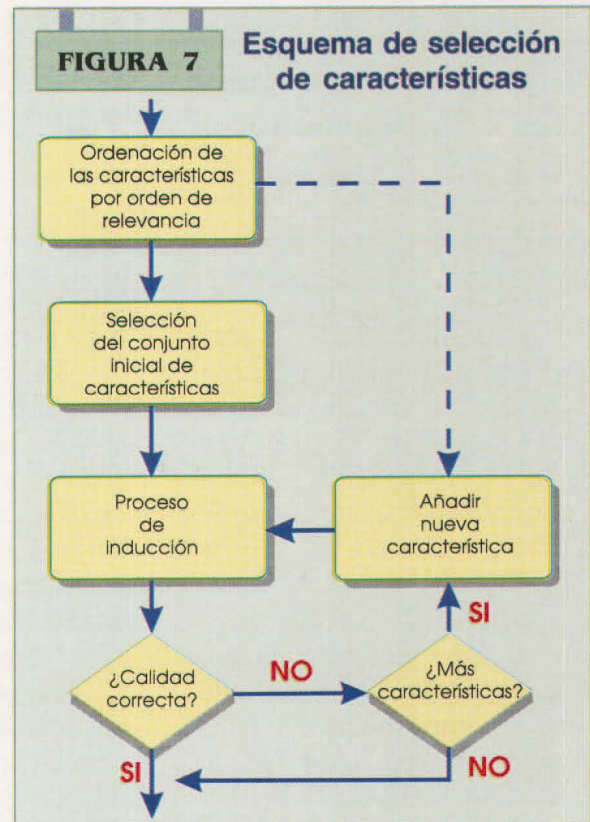
Cuando se realiza una búsqueda en un cierto espacio es necesario definir un criterio que guíe el proceso así como de una condición de parada. En algunas aproximaciones estos criterios han sido externos al proceso de aprendizaje. Debido a esta desconexión entre el proceso selector de características y el proceso de aprendizaje, aparecen una serie de inconvenientes. El primero es que en la mayoría de los casos los criterios utilizados en el proceso de selección de características (métodos estadísticos, análisis de las componentes principales, transformación de Karhunen-Loeve, etc.) son diferentes a los utilizados en el proceso de aprendizaje, dando lugar a la necesidad de una supervisión externa. Por otra parte no se evalúa al sistema de forma global, sino que por un lado se realiza la evaluación del selector de características y por otro lado la del proceso de aprendizaje. En este trabajo nuestra propuesta es la utilización de un mecanismo integrado, donde la evaluación del *tándem selector de características-pro-*

ceso de inducción del clasificador se hace en base al objetivo de calidad en la inducción [BHAN-93] como se ve en Figura 4. El método de la envoltura propuesto en [KOHA-95] sigue esta filosofía. En este método se genera un conjunto de características candidatas que se evalúa después de realizar el proceso de aprendizaje y, en función de la calidad obtenida, se detiene el proceso o se añaden atributos del conjunto de candidatas y se vuelve a evaluar nuevamente este conjunto.

El método de determinación del conjunto de características candidatas debe utilizar alguna medida que dé la dependencia entre la clase y las características, así como de dependencia entre características que permita obtener las más relevantes. Clásicamente la relación entre características se determina utilizando mecanismos como los orientados a covarianza [FUKU-72], presentado estos métodos la limitación de detectar sólo correlaciones lineales, algo que no siempre se puede asegurar. Así la covarianza da buenos resultados sólo si cada clase es representable por un cluster (unimodal) [SHUN94], pero como se estableció en las consideraciones de diseño del sistema este comportamiento no puede ser asegurado. Una medida de dependencia más general, que está basada en la Teo-

ría de la Información, es la información mutua (IM) [FRAS-86], ya que evalúa la cantidad de información que cada característica contiene con respecto a la clase y con respecto a las otras características. La información mutua presenta la ventaja de que, frente a medidas anteriormente mencionadas, no presupone un comportamiento concreto de las muestras con la clase ni de relación entre las características.

Como en la aproximación global se parte de un conjunto de características inicial o características candidatas, al que se van añadiendo más según la calidad del proceso de inducción como puede verse en la Figura 7, es necesario definir la selección del conjunto de características candidatas. El procedimiento utilizado para obtener el conjunto de características candidatas mediante el uso de la IM se explica a continuación.



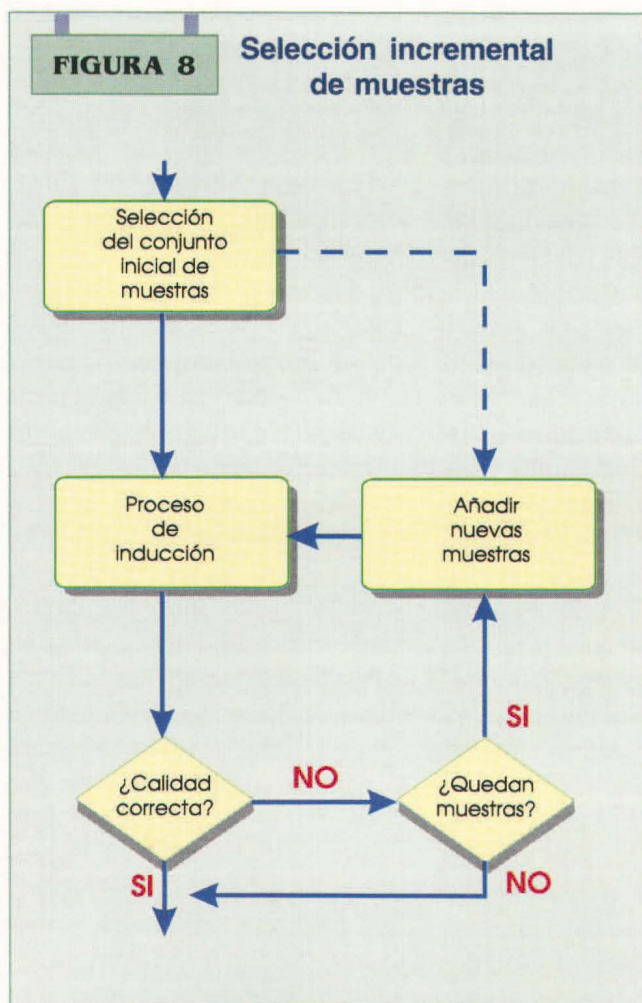
En un primer paso se calcula la información mutua de todas las características con la clase $IM(f,C)$ y de las características con el resto $IM(f,g)$. A continuación se eliminan del conjunto inicial todas aquellas características que posean un valor de $IM(f,g)$ alto, ya que eso indica que la interdependencia entre éstas es alta, con lo que la información aportada por una de ellas ya está recogida en gran parte en la otra. Luego las características restantes se ordenan por orden decreciente de $IM(f,C)$, y se define el conjunto inicial desde la que posee mayor $IM(f,C)$ hasta aquella donde se produce un mayor salto, es decir, con aquella que tenga la mayor diferencia de $IM(f,C)$ con la que le sucede en la ordenación antes mencionada.

SELECCIÓN DE MUESTRAS RELEVANTES

Uno de los mayores inconvenientes de los métodos que incluyen una evaluación global del proceso de aprendizaje es el alto coste computacional ya que para la evaluación de la calidad de cada conjunto de características candidatas es necesario llevar a cabo una ejecución completa del proceso de aprendizaje. Una forma de evitar este alto coste es introducir un esquema de aprendizaje incremental donde no todas las muestras se utilizan desde el principio en el proceso de aprendizaje. En este esquema se parte de un número reducido de muestras y el sistema va seleccionando qué muestras se van añadiendo en cada momento [ZHAN-94], en función de la relevancia de la información introducida por éstas en el procedimiento de inducción. Con ello no sólo se reduce el alto coste computacional, sino que se evita también el problema del sobreajuste ("overfitting") de los datos

por el exceso de muestras utilizadas en el proceso de inducción. Muchas de estas muestras no suministran información relevante, lo que provoca que el clasificador inducido tenga una capacidad de generalización pobre sobre otras muestras no pertenecientes al conjunto de aprendizaje [KOHA-95], es decir, clasifica muy bien la muestras del conjunto de aprendizaje pero mal las no utilizadas en este conjunto.

El criterio utilizado para realizar el proceso de selección de muestras se basa, como en el caso de la selección de características, en el concepto de la información mutua. El uso de la información mutua en este caso se justifica en que las muestras a seleccionar son aquellas que aportan más información al proceso de inducción. Así se debe calcular la información que aporta cada una de las muestras que no están siendo utilizadas en el proceso de inducción y añadir aquellas que aporten una mayor cantidad de información. Lo anterior equivale a realizar un proceso de clasificación con el clasificador inducido hasta ese punto, y seleccionar aquellas muestras que con este clasificador se encuentran peor clasificadas [ZHAN-94], y considerar éstas como las que aportan mayor información al proceso de aprendizaje y, por tanto, añadirlas. Luego, con el nuevo conjunto de muestras, se vuelve a aprender el clasificador y a realizar la selección de nuevas muestras, siempre que no se haya alcanzado la calidad de clasificación deseada y queden más muestras para añadir al conjunto de aprendizaje. Un esquema de este proceso se puede ver en Figura 8.



INDUCCIÓN DE CLASIFICADORES

Un aspecto importante en el diseño y, por tanto, en el resultado de la inducción en un SVBC es la posibilidad de transportar el conocimiento implícito en dicho clasificador al lenguaje natural [FICH-92]. Por otra parte, debido a la naturaleza del problema donde el conocimiento no se encuentra codificado, sino que es necesario extraerlo del conjunto de muestras utilizadas para el aprendizaje, un esquema válido para la inducción de clasificadores es el aportado por las redes neuronales, aunque resolviendo el problema de la transcribibilidad de la misma y, por tanto, del clasificador inducido.

Por razones de eficiencia el enfoque a la hora de abordar la inducción de un clasificador en el marco de las redes neuronales, se ha optado por diferenciar entre clases linealmente separables o no, de forma que el esquema varía según el tipo de las clases.

Clases Linealmente Separables

En las clases linealmente separables que son aquellas que pueden separarse mediante el uso de hiperplanos, la regla de combinación de los atributos es la combinación lineal, es decir:

$$F = \sum_i w_i \cdot f_i$$

donde w_i son los pesos y f_i es el valor del atributo i -ésimo. Introduciendo el resultado de la anterior combinación lineal a una función discriminante no lineal

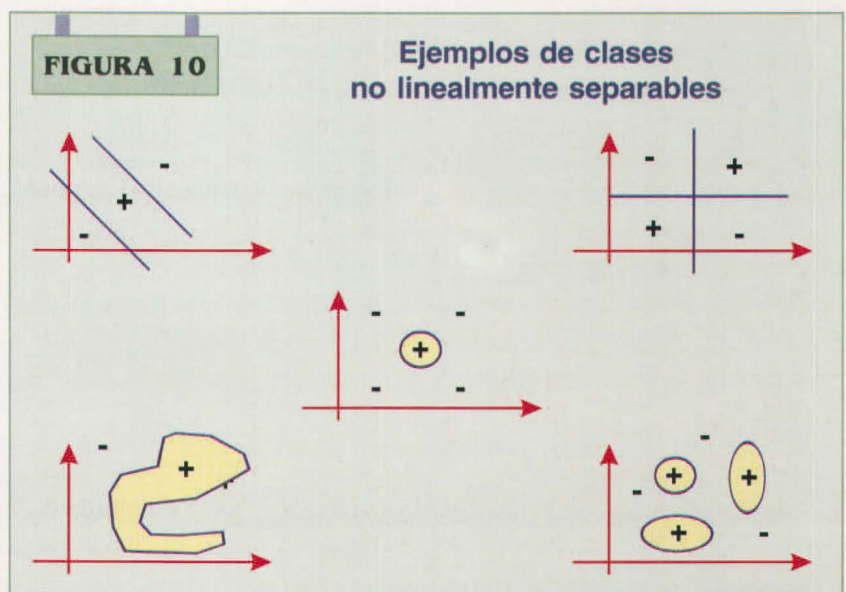
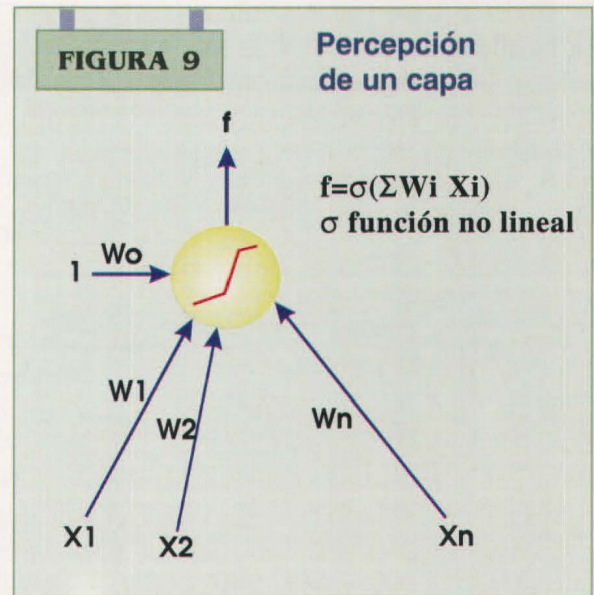
se puede obtener la clasificación correcta [DUDA-72], siendo el valor de la función no lineal el grado de pertenencia a la clase de la muestra.

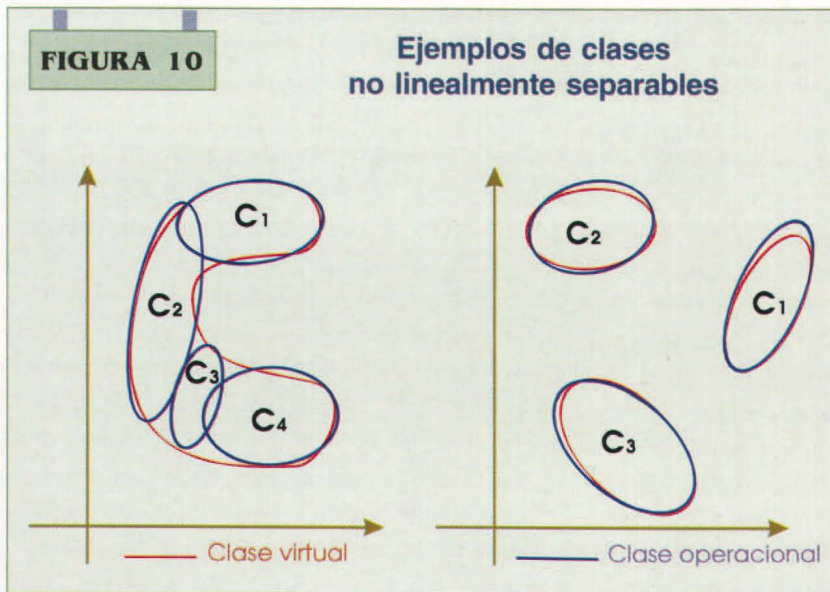
Una posibilidad dentro del marco de las redes neuronales para inducir los clasificadores en este tipo de clases es mediante el perceptrón de una sola capa [ROSE-60] [RUME-86], cuya estructura consiste en una capa de entrada y una de salida (Figura 9). La función de activación de las unidades de la capa de salida realizan la suma ponderada de la entradas, que luego es pasada a una función no lineal del tipo sigmoide. El aprendizaje en este tipo de redes se realiza mediante el método denominado propagación hacia atrás del error («backpropagation»). Este método se basa en ir modificando los pesos que unen las unidades de la capa de entrada con la de salida en función del error que hay entre la

salida esperada y la que se obtiene con la red.

Clases No Linealmente Separables

En el caso de clases no linealmente separables, puede ocurrir que una clase se corresponda con una región de forma genérica en el espacio de características, o incluso con un conjunto de regiones no conexas, como puede verse en la Figura 10. Dada la generalidad de la forma de la región correspon-





diente a la clase, es útil definir un concepto intermedio denominado "clase operacional", entendiéndose como tal a aquella región del espacio de características separable del resto mediante la utilización de un discriminante lineal o cuadrático. De esta forma una clase estaría conformada por una mezcla de una o más clases operacionales como puede verse en la Figura 11, siendo el número de éstas desconocido *a priori*. La pertenencia de una muestra a la clase vendría dada por una combinación del grado de pertenencia de esa muestra a las diferentes clases operaciona-

les que la componen, por lo tanto es tarea del procedimiento de inducción el descubrimiento del número de clases operacionales necesarias, la generación de una función de pertenencia a cada una de las clases operacionales y, por último, la combinación del grado de pertenencia a todas las clases operacionales para obtener el grado de pertenencia a la clase.

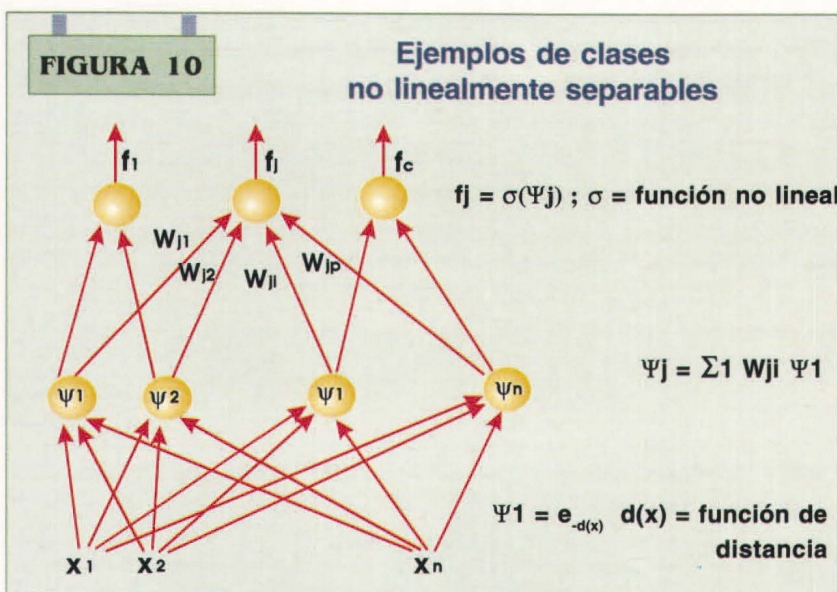
Dentro del marco de las redes neuronales, una posibilidad para realizar el aprendizaje, con las restricciones antes mencionadas, son las denominadas Re-

des Neuronales Basadas en Funciones de Base Radial (RBFN) [LEE-88][RENA-89]. La estructura de estas redes consiste en un capa de entrada, una capa oculta y una de salida (Figura 12). La capa oculta está compuesta de unidades que tienen como función de salida a una función de base radial (RBF), cuya salida es máxima en el centro y va decreciendo a medida que la distancia con el centro aumenta. Una función de base radial muy utilizada es la función gaussiana. En la capa de salida, la función de activación realiza la suma ponderada de las salidas de las unidades de la capa oculta, y puede tener una función de salida que introduzca alguna no linealidad como es el caso de una sigmoide.

Así, la utilización de este tipo de redes permite asociar a cada unidad de la capa oculta una clase operacional, lo que unido al uso de una función de distancia generalizada como la de Mahalanobis, permite que las clases operacionales asociadas puedan ser separables cuadráticamente. De la anterior consideración se tiene que la salida de cada unidad de la capa oculta se correspondería al grado de pertenencia de la muestra a la clase operacional representada por la unidad, por lo que la unidad de la capa de salida tendría como misión obtener el grado de pertenencia a la clase como una combinación de los grados de pertenencia a las diferentes clases operacionales. Esta combinación se ha planteado que sea alguna expresión de la función O-difuso [KLIR-88], como por ejemplo:

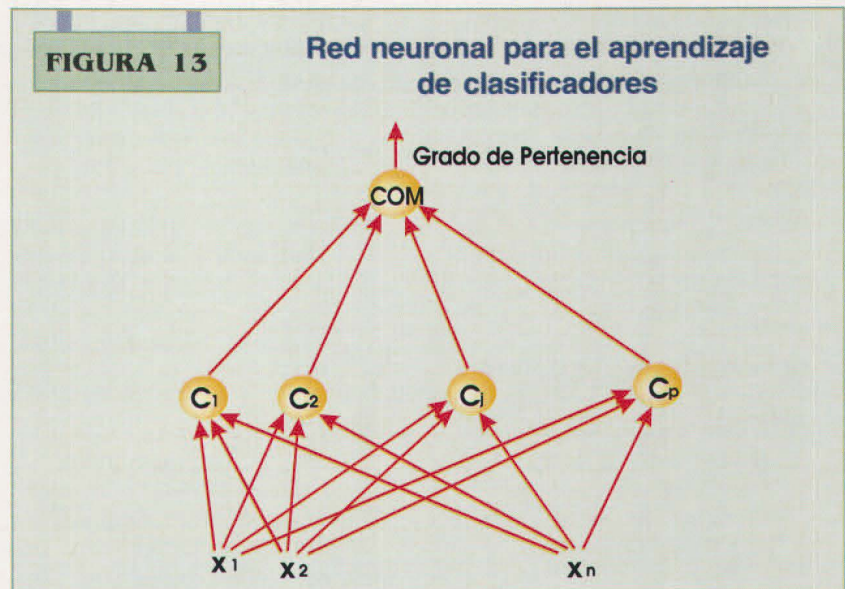
$$\mu(u, v) = u + V \cdot u \cdot v$$

donde u y v son grados de pertenencia, y λ es el grado de pertenencia conjunto. De las anterior-



res consideraciones se obtiene como estructura de la red neuronal para el aprendizaje de clasificadores para clases no linealmente separables, la mostrada en Figura 13.

El aprendizaje en este tipo de redes tiene dos partes. Por un lado, se debe obtener el número de unidades de la capa oculta, que en nuestro caso se corresponde con el número de clases operacionales y, por otro lado, los parámetros que definen función de base radial de cada unidad. Para encontrar el número de unidades existen dos aproximaciones, una consiste en realizar previamente un proceso de agrupamiento de las muestras, de tal forma que cada unidad tenga un campo receptivo correspondiente a un conjunto de muestras que conforman un agrupamiento en el espacio de características. Otra forma de obtener el número de unidades de la capa oculta es comenzar con una sola unidad e ir incrementando su número a medida que el campo receptivo de las existentes no recubra a todas las muestras del conjunto de aprendizaje. Para el aprendizaje de los parámetros que definen la función de base radial de cada unidad de la capa oculta, el método a utilizar es el mis-



mo al utilizado con el Perceptron de una capa, es decir, el aprendizaje hacia atrás.

CONCLUSIONES

Como conclusiones a la arquitectura de aprendizaje que se ha presentado en este trabajo, cabe destacar el tratamiento integral que se realiza del problema del aprendizaje de clasificadores, mediante la integración de la selección de características y muestras en el proceso de inducción del clasificador. Otro

elemento a tener en cuenta en este trabajo es que no se establecen condicionantes en las distribuciones que puedan tener las muestras, debido al uso de la información mutua como medida de la dependencia de las muestras con la clase, así como de dependencia de las características entre sí. Por último destacar los diversos bucles de vuelta atrás entre los diferentes módulos que componen la arquitectura, dando de esta forma la posibilidad de realimentación entre las distintas fases que conlleva el aprendizaje de clasificadores en la arquitectura que se ha presentado.

REFERENCIAS

- **ALOI-88** Aloimonos J., Weis I. (1988): «Active Vision», *International Journal of Computer Vision*, pp. 333-356.
- **BHAN-93** Bhandaru M., B. A. Draper, V. R. Lesser (1993): «Learning Image to Symbol Conversion», en *Papers from the 1993 AAAI Fall Symposium on Machine Learning in Computer Vision: What, Why and How?*, AAAI FS-93-04 Tech. Rep., AAAI Press, pp. 6-9.
- **BOWY-94** Bowyer K. W., Hall L., Langley P., Bhanu B., Drapper B. A. (1994): «Report of the AAAI Fall Symposium on Machine Learning and Computer Vision: What, Why and How?», en *Proc. of the 1994 ARPA Image Understanding Workshop*, Morgan Kaufman, San Mateo, California.
- **CABR-94** Cabrera J. (1994): *Sistema Basado en Conocimiento para Segmentación de Imágenes*. Desarrollos y Aplicaciones, Tesis Doctoral, Dpto. de Informática y Sistemas, Univ. de Las Palmas de Gran Canaria.
- **DUDA-73** Duda R. P. Hart (1973): *Pattern Classification and Scene Analysis*, Wiley.
- **FICH-92** Fichera O., Pellegretti P., Roli F. Serpico S.B. (1992): «Automatic Acquisition of Visual Models for Image Recognition», *Proc of the 11th. Int. Conf. on Pattern Recognition*, pp. 95-98.

- **FRAS-86** Fraser A.M., Swinney H.L. (1986): "Independent Coordinates for strange attractors from Mutual Information", *Physical Review A*, vol. 33 (2), pp. 1134-1140.
- **FUKU-72** Fukunaga K. (1972): *Introduction to Statistical Pattern Recognition*, Academic Press Inc.
- **HERN-95** Hernández J.D., Cabrera J., Falcón A., Hernández M. (1995): "SVEX: A Knowledge-Based Tool for Image Segmentation", *Proc. of 1995 Int. Conf. on Acoustics, Speech, and Signal Processing*.
- **KLIR-88** Klir G. J., T. A. Folger (1988): *Fuzzy Sets, Uncertainty, and Information*, Prentice-Hall Int., Inc.
- **KOHA-95** Kohavi R., Sommerfeld D. (1995): "Feature Subset Selection Using the Wrapper Model: Overfitting and Dynamic Search Space Technology", KDD-95, Computer Science Dept., Stanford Univ.
- **LAMM-94** Lammens J. M. (1994): *A Computational Model of Color Perception and Color Naming*, Ph. D. Dissertation, Faculty of the Graduate School of State Univ. of New York at Buffalo.
- **LANG-94** Langley P. (1994): "Selection of Relevant Features in Machine Learning", *Procs. of the AAAI Fall Symposium on Relevance*, New Orleans, LA, AAAI Press.
- **LEE-88** Lee. S., Kil R. M. (1988): "Multilayer Feedforward Potential Function Network", *Proc. of 2nd. Int. Conf. on Neural Networks*, vol I, pp. 161-171.
- **MEND-94** Méndez J., A. Falcón, F. M. Hernández, J. Cabrera (1994): "Development Tool for Computer Vision Systems at Pixel Level", *Cybernetics and Systems*, Vol. 25, nº 2, pp. 289-319.
- **NIEM-90** Niemann H., Brünig H., Salzbrunn R., Schröder S. (1990): "A Knowledge-Based Vision System for Industrial Applications", *Machine Vision and Applications*, Vol. 3, pp. 201-229.
- **ROSE-60** Rosenblatt F. (1960): "On the Convergence of Reinforcement Procedures in Simple Perceptrons", Cornell Aeronautical Report VG-1196-G-4, Buffalo, NY.
- **RENA-89** Renals S. and Rohwer R. (1989): "Phoneme Classification Experiments using Radial Basis Functions", *Proc. of Int. Joint Conf. on Neural Networks I*, pp. 416-467.
- **RUME-86** Rumelhart D. E., Hinton G. E. and Williams R. J. (1986): "Learning Representations by Back-Propagating Errors", *Nature*, 323, pp. 533-536.
- **SHUN-94** Sunichi S. (1994): *Self Organizing Neural Networks Based on Gaussian Mixture Model for PDF Estimation*, Ph. D. Dissertation, Faculty of the Graduate School, Univ. of Southern California.
- **VERN-91** Vernazza G. (1991): "From Numerical to Symbolic Image Processing: Integration of Computational and Knowledge-Based Approaches", *Proc. of the Workshop: Computer Vision: Craft, Engineering, and Science*, ESPRIT Basic Research, Springer-Verlag, Berlin.
- **ZADE-71** Zadeh L. A. (1971): "Quantitative Fuzzy Semantics", *Information Sciences*, Vol. 3, pp. 159-176.
- **ZHAN-94** Zhang B. (1994): "Accelerated Learning by Active Example Selection", *International Journal of Neural Networks*, vol. 5 (1), pp. 67-75.

BIOGRAFÍA

José Javier Lorenzo Navarro

Nació en Las Palmas de Gran Canaria en 1967. Es Diplomado y Licenciado en Informática por la Universidad de Las Palmas de Gran Canaria. Desde Abril de 1992 trabaja como profesor asociado en el Dpto. de Informática y Sistemas de la ULPGC. Ha realizado una estancia en el Instituto Astrofísico de Canarias con motivo de una beca de verano. Actualmente se encuentra realizando su tesis doctoral en el Grupo de Inteligencia Artificial y Sistemas de la ULPGC, dirigida por el Dr. D. Francisco

Mario Hernández Tejera, y sus áreas de interés son Aprendizaje Automático, Redes Neuronales y Sistemas Autónomos Inteligentes.

Dirección:
Dpto. de Informática y Sistemas
Univ. de Las Palmas de G. C.
Campus Univ. de Tafira
35017 - Las Palmas
Tlf: 458747/00 - Fax: 458711
correo electrónico: jlorenzo@dis.ulpgc.es

Este trabajo ha sido patrocinado por:

AGUAS MINERALES DE FIRGAS, S.A.