

# Aplicación de Inteligencia Artificial en Sistemas Automatizados de Producción

J.R. Llata, E.G. Sarabia, D. Fernández, J. Arce y J.P. Oria

Grupo de Ingeniería de Control. Departamento TEISA  
E.T.S.I. Industriales y Telecomunicación, Universidad de Cantabria  
e-mail: [llata,esther,damaso,arce,oria]@teisa.unican.es

“Soy un gigante tan gigante que puedo grabar una rosa en la uña de un niño recién nacido”. Para solucionar el problema el personaje de García Lorca puede emplear diferentes métodos o múltiples paradigmas, como haría un sistema de inteligencia artificial. La inteligencia artificial es “simplemente” la transferencia de la inteligencia a las máquinas, es decir que el computador haga cosas inteligentes. Sin embargo la inteligencia humana es una función tan compleja que los científicos están solo empezando a comprender. Como los sistemas de inteligencia artificial, el personaje seguramente posee un conocimiento concreto de hechos y factores que afectan al problema y un conocimiento abstracto de reglas e ideas para solucionarlo, y su éxito depende de la habilidad de aplicar este conocimiento a cualquier situación, y de aprender continuamente de nuevas experiencias.

Las reglas que relacionan todos los hechos conocidos están expresadas por relaciones condicionales y de la misma manera que el ser humano, puede procesar un gran número de impresiones sensoriales que le llegan al mismo tiempo y que son irrelevantes al problema. Mediante un sofisticado proceso de selección debe eliminar los caminos de razonamiento que no son vitales para resolver el problema concreto. El objetivo final se alcanza cumpliendo una serie de metas intermedias, ya que sin objetivos que lograr no existe razón para pensar, es decir, “no hacemos cosas porque pensamos sino que pensamos porque hay cosas que tenemos que hacer”.

Las técnicas de inteligencia artificial son capaces tanto de sustituir elementos tradicionales de control como de realizar tareas que hasta el momento era imposible abordar sin la presencia del operador humano. Se presentan a continuación una serie de aplicaciones en las que el Grupo de Ingeniería de Control de la Universidad de Cantabria ha empleado herramientas de inteligencia artificial para aplicaciones de automatización y control de sistemas complejos.

## Modelado de sistemas dinámicos

Cuando se pretende realizar la regulación de un proceso complejo, en el que se requiere un exigente comportamiento estático y dinámico y en el que la tolerancia a la variación de las principales variables es muy reducida, es aconsejable disponer de un modelo que permita seleccionar el controlador más adecuado a esta aplicación. Este modelo permitirá efectuar numerosas pruebas y simulaciones sin poner en peligro el sistema real. Si el sistema es complejo, los cálculos analíticos suelen ser muy costosos, tanto en esfuerzo como en tiempo. En este

caso suele optarse por la obtención de un modelo experimental, basado en las respuestas del sistema ante un conjunto de entradas. Las técnicas de control inteligente como Redes Neuronales y Lógica Fuzzy, permiten calcular un modelo aproximado del sistema en base a datos experimentales y mediante un proceso de autoajuste recursivo de los parámetros configurables de la estructura seleccionada. Entre las ventajas están que este ajuste automático de parámetros libera al ingeniero de control de los cálculos de selección y ajuste de coeficientes, no requiere un conocimiento del proceso a identificar tan profundo como en otras técnicas, permiten

modelar con cierta facilidad la dinámica de sistemas en las que existe un gran número de variables interrelacionadas y en las que pueden aparecer no linealidades. Por contrapartida, presentan inconvenientes entre los que se encuentran como más importantes el que el modelo obtenido no presenta ninguna de las formas de representación más comunes en control, esto es, no permiten obtener ni una representación externa ni representación interna, y el que sigue siendo necesario disponer de un cierto nivel de conocimiento del funcionamiento de la planta y de las interrelaciones entre variables para seleccionar una configuración apropiada.

Se presenta una aplicación real en la que se realiza el modelado de una cuba de filtrado, en régimen de operación, mediante la utilización de redes neuronales. En la figura 1 se puede ver una representación esquemática de una cuba de filtrado o Lauter Tun, en la que se observan las principales variables del proceso, así como los elementos que lo constituyen. Entre estos elementos, los que presentan una mayor relevancia en la dinámica del proceso son el depósito, el falso fondo, el material filtrante, el agua de regado y las cuchillas. El producto que le llega al lauter tun está formado por una mezcla de malta molida con agua caliente, aunque puede llevar otros componentes tales como lúpulo, maíz, arroz, etc, y el objetivo principal es la separación de los elementos sólidos que se añadieron previamente y que se encuentran en suspensión en la mezcla. Además existen otros objetivos, como obtener una alta eficiencia en la extracción, conseguir ciclos de filtrado repetibles para homogeneizar la calidad, que el mosto presente un bajo contenido en oxígeno disuelto, etc. Una vez que

se ha conseguido una matriz filtrante adecuada, comienza la extracción mediante el bombeo del mosto al exterior. Durante este proceso se produce una compactación de la matriz sólida de filtrado, de tal forma que la porosidad disminuye y se va reduciendo el caudal de mosto filtrado. Para conseguir que el material filtrante no llegue a una compactación que impida la circulación del mosto, se dispone de un conjunto de cuchillas controlables en altura mediante las cuales se reduce la compactación. La acción de estas cuchillas debe vigilarse en extremo ya que si remueven la matriz sólida de filtrado se produce un gran aumento de la turbidez, perdiendo calidad en el producto final.

El modelado de este sistema es complejo ya que presenta un comportamiento no lineal, las variables están fuertemente acopladas, existe un conjunto de variables que tienen una gran influencia en el comportamiento del sistema y presentan un carácter aleatorio (el tamaño de grano en la matriz filtración) y, por último, el sistema es tiempo variante (temperatura del agua, densidad, pH, etc). Esto hace que sea un candidato perfecto para sustituir el modelado analítico y estocástico por las técnicas de inteligencia artificial.

### Modelado Mediante Redes Neuronales

Como es conocido las redes neuronales son algoritmos matemáticos que pueden identificar y modelar relaciones causa-efecto de unas determinadas variables a partir de un histórico de datos. Es decir, realizan la transformación de una serie de datos de entrada en las salidas correspondientes formando un modelo matemático. Se han utilizado redes neuronales feedforward

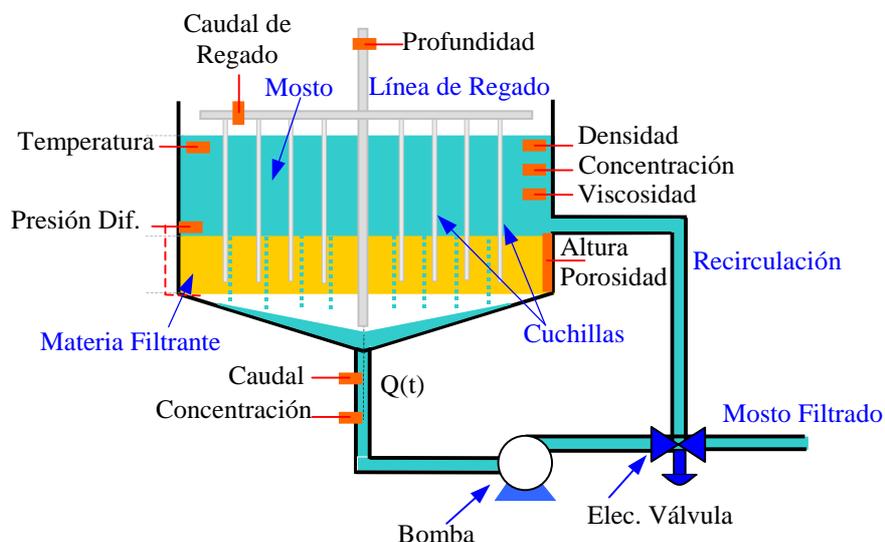
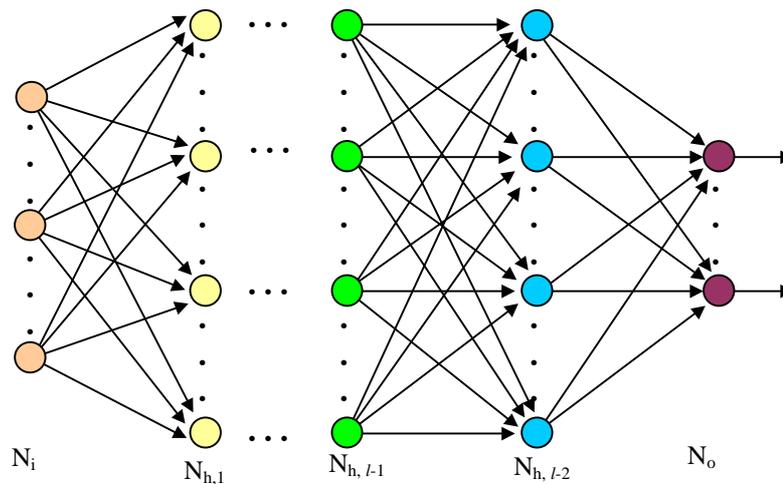


Figura 1. Representación esquemática de la estructura y funcionamiento del Lauter Tun.



multicapa, entrenadas con el algoritmo de backpropagation mediante la regla de Widrow-Hoff. Su estructura puede verse en la figura 2, en la que los datos son introducidos en la primera etapa de la red  $N_i$  donde son escalados de tal forma que todos tengan la misma capacidad de excitar al modelo. Entonces los datos se pasan a la capa oculta de la red  $N_h$  por medio de una serie de conexiones ponderadas.

A cada entrada de una neurona oculta se suman los datos que le llegan y se le aplica la función de ponderación. Las salidas de las neuronas ocultas son de nuevo ponderadas y sumadas en las neuronas de salida  $N_o$ . Las incógnitas de la red neuronal son los pesos que se utilizan para las ponderaciones. Una vez que la red converge para los datos de entrenamiento se comprueba su funcionamiento con los datos de test, si el modelo también se ajusta para estos datos entonces es probable que se haya obtenido un buen modelo.

Las redes neuronales tienen excelentes capacidades para la interpolación entre datos entrenados debido a la naturaleza no lineal de su estructura (funciones de activación). Pero la extrapolación fuera del rango en que ha sido entrenada es poco fiable. Por tanto para hacer el modelado mediante redes neuronales se necesitan grandes cantidades de datos que describan completamente el proceso a identificar en todo el rango de variación posible para cada una de las variables que forman el proceso. La medida del error se ha realizado mediante el sumatorio del cuadrado de los errores para cada dato.

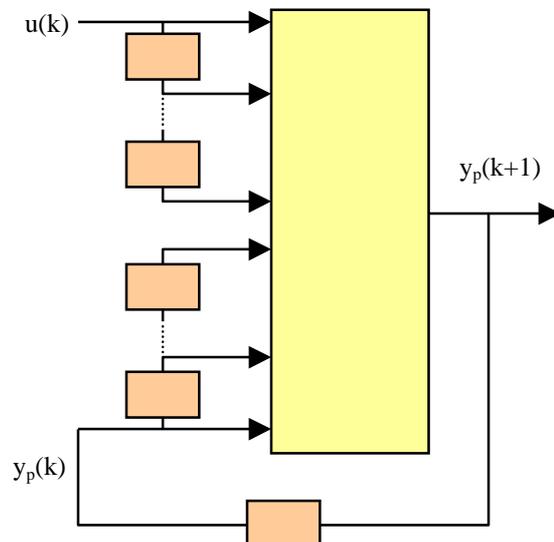
Es decir para cada vector de datos correspondiente a un determinado instante del proceso se ha obtenido la respuesta de la red. El error total se obtiene una vez que todos los datos han pasado por la red.

$$E_{\text{aprendizaje}} = \sum_{p=1}^{P_{\text{aprendizaje}}} (E^p)^2$$

$$E_{\text{prueba}} = \sum_{p=1}^{P_{\text{prueba}}} (E^p)^2$$

Los datos utilizados han sido normalizados a valores comprendidos en el intervalo  $[0,1]$ , y más exactamente entre 0.1 y 0.9 para no producir la saturación de las funciones de activación no lineales utilizadas para las neuronas. Los datos también pueden ser normalizados de forma simétrica entorno a la media.

Las redes feedforward están diseñada para memorizar patrones estáticos, es decir no poseen capacidad para adaptarse a patrones dinámicos. Como el caso bajo estudio corresponde a un sistema dinámico es necesario introducir al sistema la suficiente información temporal para que pueda



reconocerlo. Es decir, es necesario modificar el entrenamiento estático de las variables de tal forma que el resultado sea un seguimiento del sistema dinámico.

La salida del sistema se puede predecir basándose en las entradas y salidas anteriores del sistema. Para un sistema MIMO este modelo se puede representar según la figura 3:

$$y_p(k) = f \{ y_p(k-1), y_p(k-2), \dots, y_p(k-n), u(k), u(k-1), u(k-2), \dots, u(k-m) \}$$

Donde :

Vector de entradas:  $u(k) = [u_1(k), u_2(k), \dots, u_q(k)]^T$ .

Vector de salidas:  $y_p(k) = [y_{p1}(k), y_{p2}(k), \dots, y_{pr}(k)]^T$

n: n° de salidas anteriores (orden del sistema).

m: n° de entradas anteriores ( $m \leq n$ ).

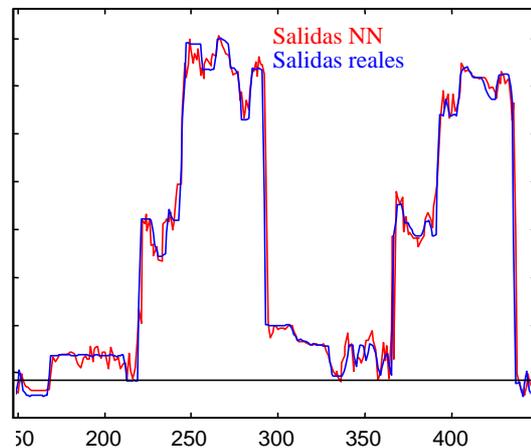
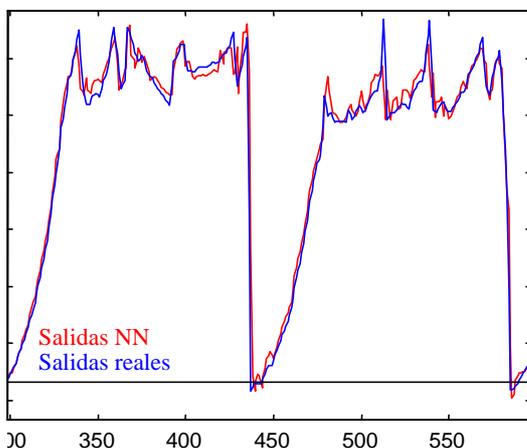
El número de entradas al sistema corresponde con el número de datos utilizados para su ajuste dinámico. Para hacer un control dinámico del sistema es necesario introducir una ventana temporal de datos de cada una de las variables analizadas. Esto es, para cada variable, en un instante dado el sistema debe tener información de cómo ha sido el comportamiento del sistema hasta ese momento. Para ello, para cada variable se introduce su valor actual y los valores en los instantes anteriores. El número de entradas depende de factores tales como el orden del sistema, ya que cuanto mayor es el orden del mismo para la variable considerada, mayor debe ser la información que en un instante dado debe conocerse. También, cuanto mayor sea el tamaño de las entradas, mayor será la complejidad de cálculo, con lo que el tiempo de entrenamiento se incrementa en exceso. Se ha utilizado una ventana temporal de las variables presión diferencial, caudal, turbidez y posición de las cuchillas. Dicha ventana está formada por el dato actual y una serie de datos que varían de 2 a 5 instantes anteriores, correspondiente con la dinámica del sistema. Otra posible opción

sería introducir una ventana temporal mayor y reducir el número de entradas consideradas para no sobrecargar la red.

Existen dos posibles métodos de entrenamiento de la red. Uno de ellos es utilizando una estructura paralela en la que el aprendizaje se realiza sobre una red que utiliza las mismas entradas que el sistema a identificar, pero que emplea como salidas anteriores las que va generando la propia red. En este caso el sistema y la red evolucionan de forma independiente. El segundo método, y del que se presentan los resultados, utiliza la estructura serie-paralela y modifica al anterior utilizando las salidas reales correspondientes a instantes anteriores del sistema como entradas a la red. De esta forma modelo y red son dos sistemas dependientes que evolucionan de la misma forma.

Empleando la información contenida en gráficas que proceden de la misma planta, los resultados obtenidos con diferentes estructuras analizadas para la identificación de la dinámica de la presión diferencial muestran que el mínimo error de prueba se obtiene para el tipo de neuronas tangente+lineal, con un número de neuronas 2+1, con 5 retardos y 200 iteraciones.

La figura 4 muestra los resultados obtenidos para la presión diferencial y el caudal. En los gráficos se puede ver la evolución real de las variables tomadas de los históricos de datos y la evolución de las mismas variables utilizando la red neuronal correspondiente. Los datos con los que han sido probadas las redes no son los datos de entrenamiento sino los valores intermedios no entrenados para ver las posibilidades de generalización de la red. El funcionamiento considerado es en lazo abierto, como predictor del instante siguiente dado uno determinado. Por tanto a partir de un entrenamiento con datos discretos nos ha permitido obtener un modelo de respuesta continua gracias a su capacidad de generalización.



## Modelado mediante lógica difusa

Cuando se pretende modelar el comportamiento dinámico de un sistema complejo el proceso es, algunas veces, muy difícil, ya que es necesario ajustar un gran número de elementos hasta llegar al comportamiento deseado. Existen técnicas que permiten seleccionar de forma automática los parámetros que definen la forma de las funciones de pertenencia, a partir de los datos experimentales. Ejemplo de este tipo de técnicas es lo que se denomina como “Sistemas Neuro-Fuzzys Adaptativos”, y en los que como componente más básico se encuentran los sistemas difusos tipo Sugeno.

Como es conocido, en los sistemas fuzzy tipo Sugeno las reglas son de la forma:

$$\text{IF } (\tilde{u}_1 = \tilde{A}_1^j) \text{ THEN } (y_q = g(x))$$

siendo  $x$  el argumento de la función  $g$ .

La forma de la función  $g$  puede ser cualquiera, y depende de la aplicación a la que se dedique. Sin embargo, una de las funciones más sencillas y, por lo tanto, que permiten un cálculo más rápido es aquella en la que la función toma un valor constante, y se puede escribir de la forma:

$$g_q = a_q$$

Este tipo de sistema fuzzy disminuye el número de coeficientes a ajustar ya que, por un lado las reglas presentan una forma fija y, por otro, solo se requiere ajustar la posición de las funciones de pertenencia de salida y los parámetros de las funciones de entrada. Así, aplicando un procedimiento de backpropagation y/o mínimos cuadrados, se pueden ajustar el sistema fuzzy hasta que ajuste perfectamente las señales de entrada y salida del sistema real. En la figura 5 se muestra el conjunto de elementos que intervienen en el proceso de ajuste del modelo fuzzy. En base a esta técnica de autoajuste es posible obtener un modelo de lauter tun utilizando las gráficas obtenidas

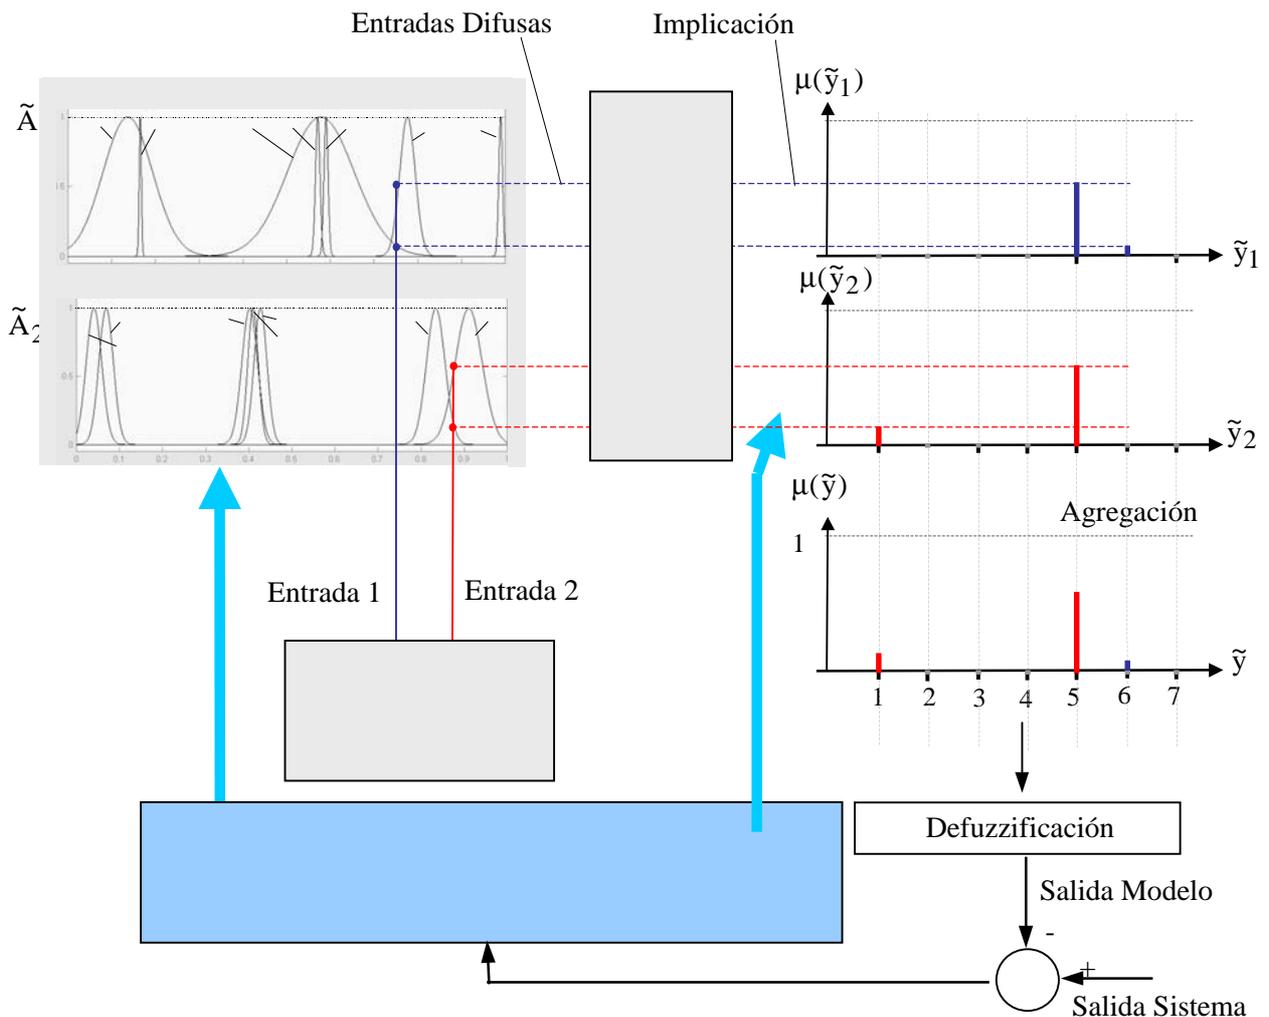
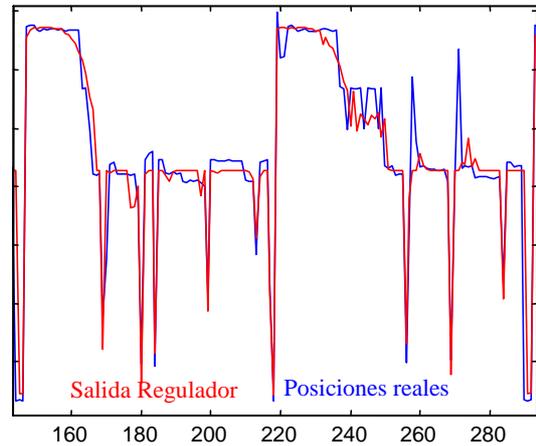
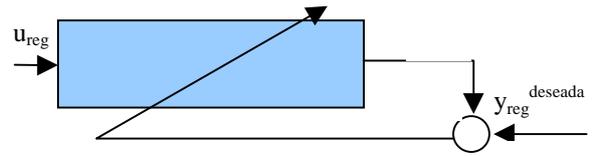


Figura 5. Proceso de Ajuste de Funciones de Pertenencia

experimentalmente, al igual que se ha realizado mediante redes neuronales. Como resultado se obtiene un sistema fuzzy con unas funciones de pertenencia de la forma indicada por el ingeniero de control, pero ajustadas en posición y configuración, un conjunto de reglas de tipo Sugeno, y unas funciones de pertenencia para la salida, de tipo Sugeno constante, cuya posición se ha seleccionado automáticamente.

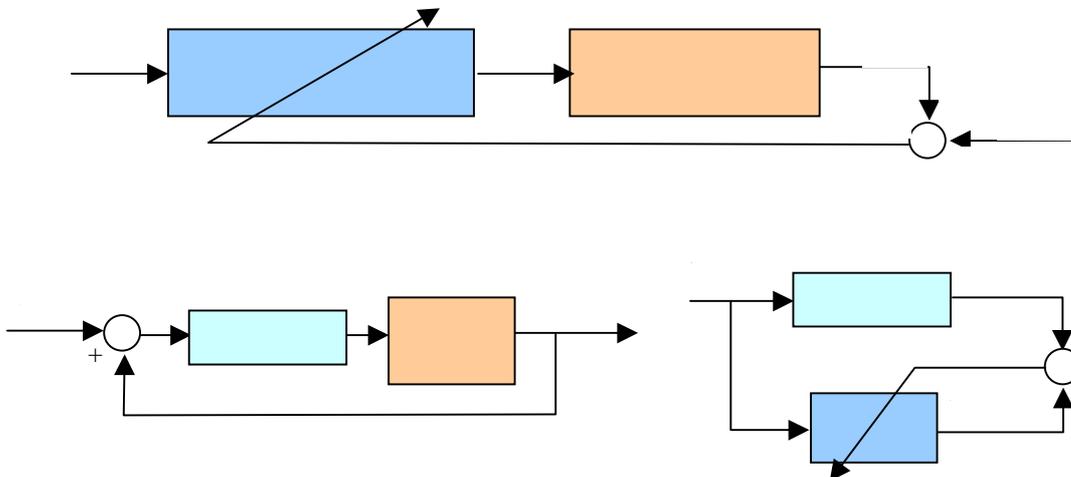
### Control Mediante Redes Neuronales

Una forma de realizar el ajuste del controlador es a partir de los datos de funcionamiento cuando un experto está controlando la planta. Por tanto se guarda en cada instante los valores de las variables utilizadas del sistema como datos de entrada, y las actuaciones realizadas por el experto como objetivos. Una vez obtenida suficiente información de todos los posibles modos de funcionamiento, se utiliza esta para entrenar el modelo del controlador. Para el control de las cuchillas, se ha realizado el entrenamiento de una serie de redes con la misma forma que para la identificación del sistema, esto es redes feedforward con backpropagation. Estas redes reciben como entradas los patrones de los distintos puntos de funcionamiento (con sus ventanas temporales correspondientes), y que tiene como targets las posiciones que deben ir tomando las cuchillas para obtener un correcto funcionamiento del sistema. Esta es la técnica denominada ajuste directo (figura 6). El número de capas y neuronas ha sido ajustado para llegar a un error máximo aceptable, de tal forma que la red no pierda su capacidad de generalización. Con un número moderado de neuronas no llega a adaptarse totalmente a la forma de variación del regulador, ver figura 7, pero existe un compromiso ya que si se utiliza un número elevado de neuronas se pierde la capacidad de generalización.



Si se posee información sobre la correcta evolución que deben seguir las variables se puede realizar el entrenamiento del controlador para que la respuesta del sistema completo se ajuste a esos datos. En este caso a la hora de entrenar el regulador es necesario utilizar el modelo neuronal que identifica el sistema. El esquema de entrenamiento seguido, o ajuste indirecto se muestra en la figura 8. Se coloca en serie un regulador y el modelo identificado de la planta. El regulador, que parte con unos pesos calculados arbitrariamente, calcula la posición de las cuchillas y las aplica al modelo. Utilizando el error existente entre la salida deseada y la salida real del sistema se modifican los pesos del regulador hasta ajustar su correcto funcionamiento.

Otra alternativa consiste en realizar el ajuste de un





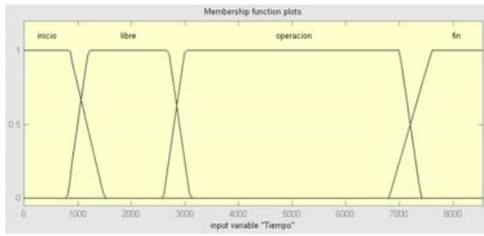


Figura 12. F. de pert. para la medición de tiempo

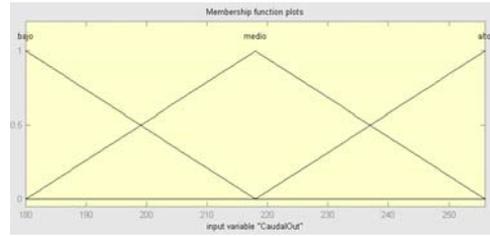


Figura 13. F. para el caudal de salida

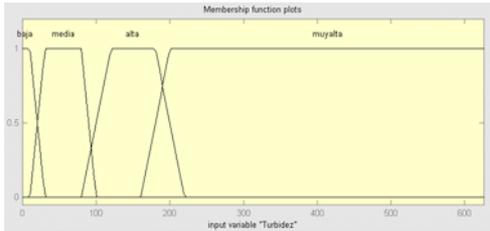


Figura 14. F. de pertenencia para la turbidez

de una planta en construcción o, incluso, sobre una planta que estando actualmente en operación se disponga de un breve tiempo para la actualización del software y su posterior ajuste, ya en operación. Como muestra de las capacidades de aprendizaje que puede presentar el controlador implementado con lógica difusa, en la figura 16 se puede observar la señal de actuación que presenta el sistema real ante el conjunto de señales de entrada formado por la presión diferencial, el tiempo, el caudal de salida y la turbidez, y la ley de control proporcionada por el sistema fuzzy una vez entrenado con las mismas señales.

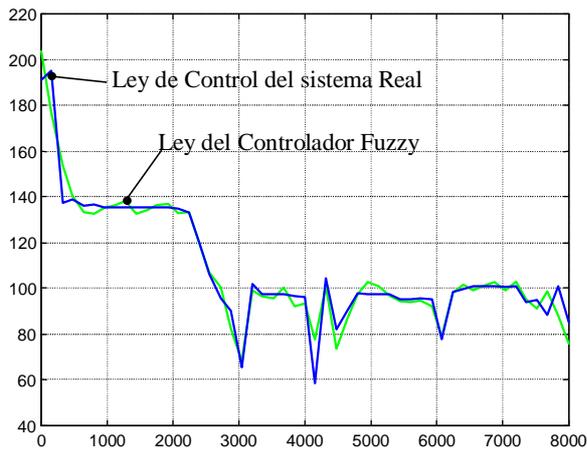


Figura 16. Resp. real vs controlador fuzzy

## Reconocimiento de objetos

El reconocimiento de objetos presenta, hoy en día, una gran importancia para los sistemas automatizados de producción, ya que esto permitiría reconocer un determinado objeto entre un conjunto

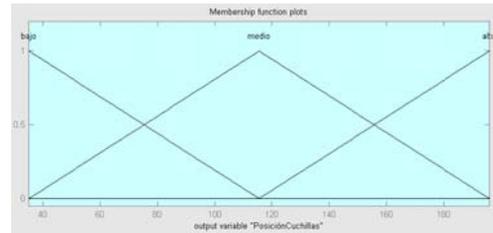


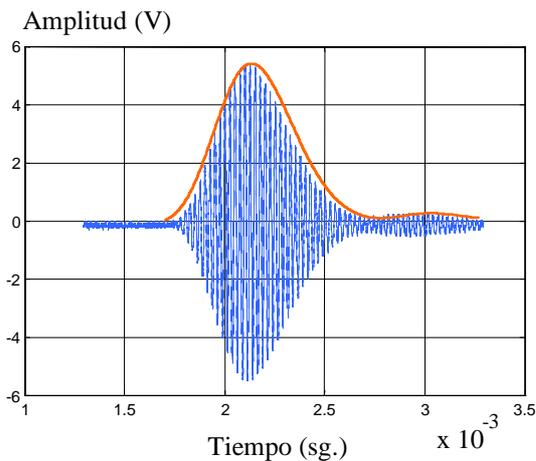
Figura 15. F. de la posición de las cuchillas

preestablecido, y tomar una determinada acción en función del tipo al que pertenezca. De esta forma, se puede dotar a un manipulador, o a una etapa del proceso de fabricación, de un cierto nivel de decisión y autonomía. En función del entorno en que se desarrolle la aplicación, se puede elegir entre diferentes tipos de sensores, como cámaras de visión artificial, sensores ópticos, sensores ultrasónicos, etc. Cada uno de ellos presenta una casuística particular y, por tanto, un diferente nivel de incertidumbre en la medida. Cuanto mayor sea la incertidumbre en la medición mayor deberá ser la capacidad de discriminación de la técnica utilizada, y más interesante se hace la aplicación de técnicas de inteligencia artificial.

El nivel de incertidumbre se hace especialmente alto en el caso de aplicar técnicas basadas en ultrasonidos, cuando las condiciones ambientales lo requieren. Esto es así porque, durante en proceso de transmisión de la onda ultrasónica, aparecen numerosos factores que afectan la misma. Entre estos pueden señalarse la variación de temperatura y de humedad, turbulencias de aire, etc. Todo esto hace que la identificación de objetos mediante ultrasonidos sea un candidato perfecto para la aplicación de técnicas de inteligencia artificial, y en especial para el uso de sistemas expertos. El primer



Figura 17. Estimación de Orientación



**Figura 18. Típica señal ultrasónica recibida.**

paso para la aplicación de cualquier técnica de inteligencia artificial en reconocimiento consiste en la recopilación de información. Esta información se puede obtener por un experto humano y/o mediante datos experimentales. En este caso la información se extrae mediante información ultrasónica, figura 17. Se han calculado un conjunto de parámetros de la envolvente del eco recibido, figura 18, que permiten extraer información acerca del tipo de objeto sobre el que se ha producido la reflexión del eco. Si el proceso de transmisión de la señal ultrasónica fuese totalmente determinista, sólo sería necesario obtener una señal de eco de cada una de las piezas y/o posiciones bajo estudio, sin embargo, debido a que existe una componente aleatoria muy fuerte en la propagación ultrasónica, se hace necesario repetir las medidas sobre el mismo elemento un gran número de veces. De esta forma, es posible obtener una aproximación a las distribuciones de probabilidad de cada una de las características calculadas. En la figura 19 se muestran las funciones de densidad de probabilidad obtenidas para una de las

características extraídas de la envolvente, en una aplicación para distinguir la orientación de una pieza. Las características no presentan un valor único para cada una de las posiciones, si no que tiene un rango de valores en los que aparece con mayor frecuencia, para la pieza bajo análisis.

Además, es importante observar que se producen solapamientos entre los valores de una misma característica, para diferentes objetos insonificados. Por lo tanto, la técnica deberá ser capaz de extraer información relevante incluso con estos solapamientos, y trabajar con los elevados niveles de incertidumbre que presenta este tipo de sensores. Una vez que se dispone de las características es necesario eliminar aquellas que aporten menos información o las que presenten información redundante. Para ello existen diferentes métodos:

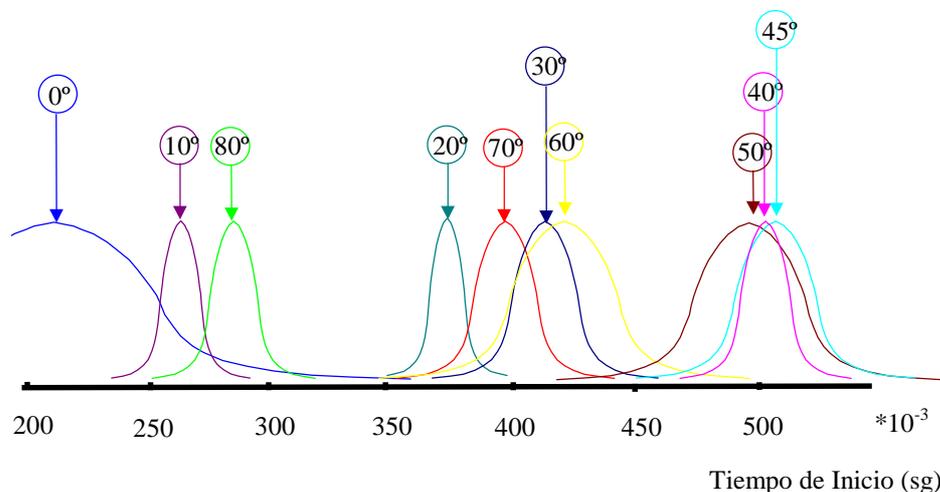
El método de clasificación mediante la regla de la probabilidad de error de Bayes, consiste en ordenar las características en función de la probabilidad de error de clasificación que produzcan. Suponiendo que el costo de clasificación correcta es cero y que el costo de todas las clasificaciones incorrectas es 1, esta regla de decisión asigna un objeto a aquella clase para la cual la probabilidad a posteriori es máxima. En este caso, el riesgo asociado con una característica se reduce a la probabilidad de error de clasificación:

$$P_e(s) = E[1 - \max(\hat{p}_1(s), \hat{p}_2(s), \dots, \hat{p}_n(s))] ]$$

Donde:  $\hat{p}_i(s) \Rightarrow$  Probabilidad a posteriori de Bayes de la clase  $i$ , condicionada a la característica  $s$ :

$$\hat{p}_i(s) = P(x_i/s) = \frac{P(s/x_i) * P(x_i)}{\sum_{1 \leq i \leq n} P(s/x_i) * P(x_i)}$$

Mediante el cálculo de la Entropía de Shannon, una característica  $S_1$  es preferible a una característica  $S_2$  si la incertidumbre posterior esperada es menor para la  $S_1$  que para la  $S_2$ . Su expresión es:



**Figura 19. Funciones de densidad de probabilidad estimadas para el Tiempo de Inicio. ( Normalizadas)**

$$H(S_1) = E \left[ - \sum \hat{p}_i(S_1) \cdot \log(\hat{p}_i(S_1)) \right]$$

Otro método utilizado es el de la entropía cuadrática, en la cual, una característica  $S_1$  es preferible a una característica  $S_2$  si la incertidumbre posterior esperada es menor para la  $S_1$  que para la  $S_2$ . Su expresión es:

$$Q(S_1) = E \left[ \sum \hat{p}_i(S_1) \cdot [1 - \hat{p}_i(S_1)] \right]$$

## Sistemas Expertos Basados en Reglas

Este tipo de sistemas expertos requiere plasmar la base de conocimiento en un conjunto de reglas que deben extraerse como consecuencia de los resultados experimentales del apartado anterior. Sobre estas reglas se puede establecer ordenes de preferencia, ponderaciones, etc. Sin embargo, es trabajo del ingeniero de control buscar el conjunto de características que, evitando los solapamientos, permitan discriminar los objetos. Se puede comprobar (figura 19), que ésta es una tarea que requiere un gran esfuerzo por parte del ingeniero de control, especialmente cuando el número de objetos a discriminar es elevado. Además como ocurre con los ultrasonidos las funciones de densidad de probabilidad experimentan desviaciones en su posición a medida que varían las condiciones de temperatura, humedad, etc. A título de resumen, este tipo de sistemas expertos presentan como principales ventajas el que son sencillos de programar una vez se conoce el conjunto de reglas, y que sus respuestas son extremadamente rápidas. En cuanto a las desventajas, está que exige un elevado esfuerzo humano para su puesta en marcha, y que una variación de las funciones de densidad y la inclusión de nuevos elementos precisa de un nuevo estudio y replanteamiento de las reglas.

## S. Expertos Basados en Probabilidad

Otra posibilidad interesante para reconocimiento es la utilización de sistemas expertos basados en probabilidad. En ellos el motor de inferencia viene dado por la aplicación de las expresiones de la teoría de probabilidad, y la base de conocimiento está formada por las propias funciones de densidad de probabilidad obtenidas experimentalmente. Una de las principales ventajas que presenta esta técnica es que necesita una intervención, por parte del ingeniero de control, muy reducida, tanto en la etapa de la generación de la base de conocimiento inicial, como en la introducción de nuevos elementos. Además, presenta una gran capacidad de adaptación a las variaciones experimentadas en las características. En aplicaciones prácticas de reconocimiento, realizadas con esta técnica, se han obtenido muy buenos resultados, pero para ello se

hace necesario transformar cada una de las características en síntomas binarios, es decir, en síntomas que estén presentes o no. Esto se ha realizado como muestra la figura 20.

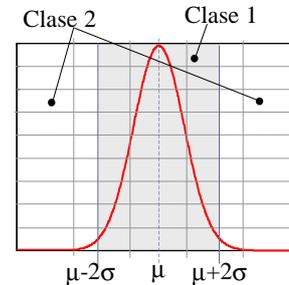


Figura 20. División por Característica

Una vez establecidos los síntomas binarios, es necesario establecer el modelo probabilístico que inferirá las conclusiones, en función de los datos recibidos. Los posibles modelos son:

- Modelo con hipótesis de independencia. Una representación gráfica del modelo probabilístico que se ha analizado puede verse en la figura 21. Para este modelo la expresión que controla la probabilidad es:

$$p(x_i / s_1, \dots, s_n) = \frac{p(x_i) \cdot \prod_{j=1}^n p(s_j / x_i)}{p(s_1, s_2, \dots, s_n)}$$

En este caso se utiliza un modelo de probabilidad simplificado en el que se considera la independencia entre síntomas, es decir, que la existencia de uno de ellos no condiciona la aparición de ningún otro

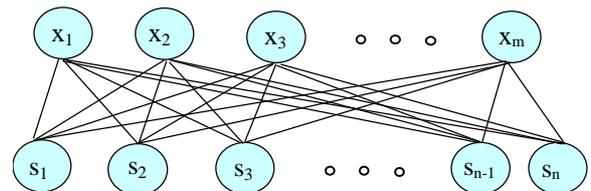


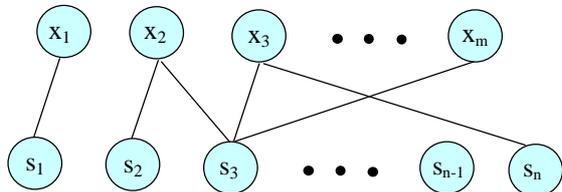
Figura 21. Modelo de Independencia

- Modelo con Hipótesis de Independencia con Síntomas Binarios Relevantes. En la figura 22 se puede ver una representación gráfica del modelo probabilístico que se ha analizado. Y la expresión que controla la probabilidad de este modelo es la siguiente.

$$p(x_i / s_1, \dots, s_n) = \frac{p(x_i) \cdot \prod_{j=1}^{r_i} p(s_j / x_i) \cdot \prod_{j=r_i+1}^n p(s_j)}{p(s_1, s_2, \dots, s_n)}$$

Este es un caso simplificado del anterior, en el que no se considera el conjunto total de las características para el cálculo de la probabilidad, si no que para cada una de las piezas se consideran

únicamente aquellos síntomas que realmente son relevantes. Este tipo de modelo probabilístico consigue una elevada reducción del número de parámetros.

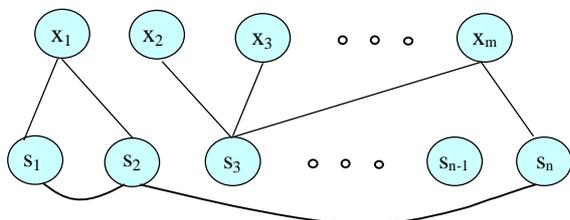


**Figura 22. Modelo de Independencia con Síntomas Relevantes**

- Modelo de dependencia para síntomas relevantes e independencia para irrelevantes. En este caso se asume dependencia solamente entre algunas características, figura 23, mientras que el resto son consideradas como independientes. La función de probabilidad viene dada por:

$$p\left(\frac{X_i}{S_1, \dots, S_n}\right) = \frac{p(X_i) \cdot p\left(\frac{S_1, \dots, S_{r_i}}{X_i}\right) \cdot \prod_{j=r_i+1}^n p\left(\frac{S_j}{X_i}\right)}{p(S_1, S_2, \dots, S_n)}$$

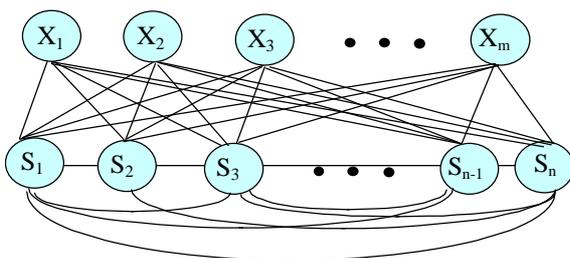
Para aplicar este modelo es necesario establecer un mapa de conexiones entre síntomas y clases, siendo necesario conocer las probabilidades condicionadas para cada una de las posibles combinaciones de síntomas, lo que hace que el número de parámetros sea muy elevado.



**Figura 23. Modelo de Dependencia para Síntomas Relevantes**

- Modelo con Hipótesis de Dependencia: En el que todas las clases dependen de todos los síntomas y en el que todos los síntomas tienen dependencia entre ellos. De esta forma es necesario utilizar la expresión de probabilidad condicionada:

$$p\left(\frac{X_i}{S_1, \dots, S_n}\right) = \frac{p(X_i, S_1, \dots, S_n)}{p(S_1, S_2, \dots, S_n)} = \frac{p(X_i) \cdot p(S_1, \dots, S_n / X_i)}{p(S_1, S_2, \dots, S_n)}$$

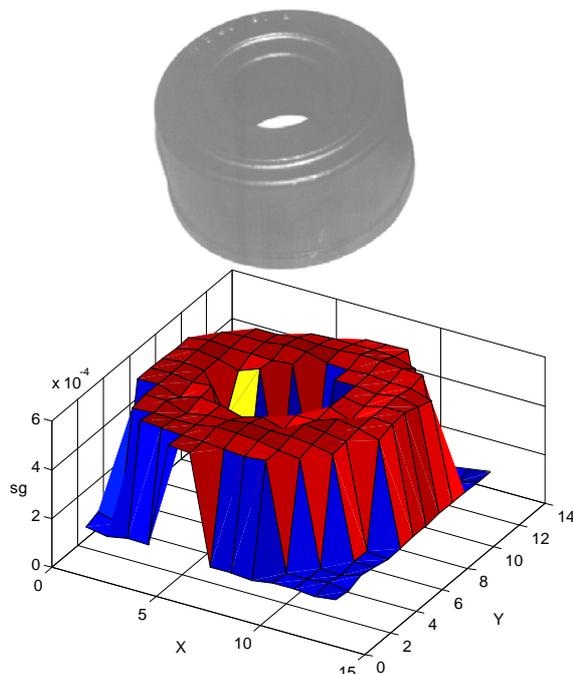


**Fig. 24. Modelo de características dependientes**

En la figura 24 se puede ver una representación gráfica de este modelo. El problema es que en este caso el número de parámetros es extremadamente grande

## Visión acústica

Mediante la aplicación de arrays de sensores ultrasónicos es posible obtener una imagen tridimensional de la superficie del cuerpo sobre el que se realiza el proceso de exploración punto a punto. Sin embargo, la información aportada por estos sensores presenta un elevado nivel de ruido y, además, en algunas configuraciones superficiales el sistema no detecta correctamente las zonas de transición. Por ello es necesario utilizar algún mecanismo que filtre las desviaciones que se producen en las mediciones y permita incorporar el conocimiento de un experto humano para ajustar de forma más precisa los bordes. La lógica fuzzy es el candidato perfecto para este tipo de tarea, ya que permite realizar un filtrado de las señales recibidas, así como establecer un sistema de reglas, obtenidas con la experiencia práctica, que permita al sistema de reconstrucción establecer un mecanismo de decisión. En la figura 25 se muestra el objeto bajo análisis y la reconstrucción superficial obtenida mediante la exploración de la cara superior con sensores ultrasónicos de 40 kHz. Como se puede comprobar, aparecen ruidos sobre la superficie del cuerpo y, además, no representa correctamente los bordes. En la actualidad se trabaja en el desarrollo de un algoritmo de que permita obtener una imagen más nítida.



**Figura 25. Reconstrucción superficial ultrasónica**

