

CONTROL IMC NO LINEAL TOLERANTE A FALLOS

Sergio Saludes Rodil * M. J. Fuente **,*

* *Fundación Cartif, Parque Tecnológico de Boecillo P205,
47151 Boecillo (Valladolid), España*
sersal@cartif.es

** *Departamento de Ingeniería de Sistemas y Automática,
Facultad de Ciencias, Universidad de Valladolid*
C/ Prado de la Magdalena s/n, 47011 Valladolid, España
maria@autom.uva.es

Resumen: Este artículo trata sobre el control IMC no lineal y un método para hacerlo tolerante a los fallos en la planta. El control IMC no lineal se consigue por medio de modelos no lineales de la planta y de la inversa de la dinámica de la misma. Ambos se hacen mediante redes neuro-difusas del tipo ANFIS. La tolerancia a los fallos abruptos e incipientes en la planta se consigue mediante la adición de una señal de control compensadora. Ésta se calcula mediante una red neuronal que se entrena en línea a partir de la minimización del error de control. Se muestran resultados en simulación para una planta de control de pH. *Copyright* ©2007 CEA-IFAC

Palabras clave: IMC, redes neuronales, control no lineal, control tolerante a fallos.

1. INTRODUCCIÓN

El control por modelo interno (*Internal Model Control*) o IMC (Morari and Zafrou, 1989) ha ganado gran aceptación debido a su capacidad para rechazar perturbaciones y sus propiedades de robustez. Además de esto, el diseño del controlador es sencillo y su sintonización es simple. El diseño de controladores IMC está bien fundamentado desde un punto de vista teórico para sistemas lineales. En la práctica, sin embargo, la mayoría de los sistemas presentan algún tipo de no linealidad, especialmente si funcionan en un amplio rango de operación. De aquí surge la necesidad de extender el IMC a sistemas no lineales (Economou *et al.*, 1986).

Algunas técnicas ampliamente utilizadas para obtener representaciones de sistemas no lineales son las redes neuronales y los sistemas difusos y el concepto del IMC puede ser combinado con este tipo de modelos (Hunt *et al.*, 1992). En este artículo se presenta un controlador IMC no lineal en el cual la planta y su inversa son modeladas mediante una red neuro-difusa del tipo ANFIS (Jang, 1993).

Otro aspecto relacionado con el control y que cada vez suscita mayor interés es la tolerancia a los fallos. Los métodos para conseguir el control tolerante a fallos pueden dividirse en dos grandes familias: métodos pasivos y métodos activos.

Los métodos pasivos utilizan técnicas de control robusto para diseñar sistemas en lazo cerrado inalterables ante ciertos fallos. Un método de diseño es el propuesto por (Chen *et al.*, 1999), en el cual el controlador se diseña mediante el método de la

* Este trabajo ha sido financiado por la Comisión Interministerial de Ciencia y Tecnología (CICYT) a través del proyecto DPI2006-15716-C02-02

desigualdad de matrices lineales, introduciéndose los fallos como restricciones. La desventaja del método es que no puede aplicarse a sistemas no lineales al ser necesaria una descripción precisa del mismo en el espacio de estados. Además de esto, al considerar los métodos pasivos la tolerancia a los fallos únicamente durante la etapa de diseño del controlador sin tomar en consideración estrategias de adaptación, la amplitud de los fallos que pueden ser tolerados suele ser demasiado pequeña como para resultar de utilidad práctica.

Los métodos activos, al contrario que los pasivos, utilizan la información proporcionada por un sistema de detección e identificación de fallos para reconfigurar el controlador. De esta manera se intenta mantener la estabilidad y rendimiento del sistema después de la ocurrencia de un fallo. Son métodos activos la linealización por retroalimentación (Ochi, 1993), las leyes de control reprogramadas (Kaminer *et al.*, 1995) y el control por seguimiento de un modelo (Morse and Osman, 1990). La reconfiguración del controlador ante fallos en componentes de la planta ha sido estudiado mediante la realimentación de estados (Looze *et al.*, 1985), el método de la pseudoinversa (Gao and Antsaklis, 1991) y el método de la asignación de vectores propios (Jiang, 1994). El inconveniente de estos métodos es que han sido desarrollados a partir de modelos lineales y su aplicación a sistemas no lineales puede quedar comprometida.

Más recientemente, las redes neuronales se han utilizado para conseguir el control tolerante a fallos en sistemas no lineales. En (Noriega and Wang, 1998a) se utilizan para crear una lazo de realimentación adicional que compensa la degradación del sistema causada por un fallo.

En este artículo la tolerancia a los fallos en la planta se consigue mediante una señal de control compensadora. Ésta es sumada a la señal de control calculada por el controlador. La señal de control compensadora es calculada por una red neuronal del tipo perceptrón multicapa entrenada en línea. El entrenamiento de esta red es supervisado y el algoritmo de entrenamiento minimiza el error de control.

La organización del artículo es como sigue. En la sección 2 se describe en control IMC no lineal. En la sección 3 se describe el método para lograr la tolerancia a los fallos en la planta mediante la adición de una señal de control compensadora. En la sección 4 se presentan los resultados obtenidos en la planta de experimentación, tanto resultados de control como de tolerancia a los fallos. Finalmente, la sección 5 recoge las conclusiones.




Figura 1. Esquema del controlador IMC

2. EL CONTROL IMC NO LINEAL

Las propiedades del control IMC han sido estudiadas detalladamente (Morari and Zafrou, 1989) y se ha demostrado que subyace bajo muchas estructuras de control que aparentemente no tienen relación entre sí (García and Morari, 1982).

En la figura 1 se muestra la estructura de un controlador IMC. Los operadores P , M y C representan, respectivamente, a la planta, al modelo de la misma y al controlador. Los operadores F_i representan filtros cuya misión será discutida posteriormente.

Las propiedades más importantes del controlador IMC son:

Propiedad 1. Si el controlador y la planta son estables y el modelo de la planta es una representación perfecta de la misma, entonces el sistema en lazo cerrado es estable.

Es decir, si se supone que el modelo es una representación perfecta de la planta entonces la señal realimentada es igual a la influencia de las perturbaciones y no está afectada por la acción de las variables manipuladas. Por esta razón puede afirmarse que el sistema está en lazo abierto y, por lo tanto, no aparece ninguna de las cuestiones de estabilidad asociadas a la realimentación.

Propiedad 2. Supóngase que existe la inversa del operador que describe a la planta, que dicha inversa se utiliza como controlador y que el sistema en lazo cerrado es estable con dicho controlador. Entonces el control será perfecto.

Propiedad 3. Supóngase que existe la inversa del operador que describe el modelo estacionario de la planta, que el controlador para el estado estacionario es igual a esa inversa y que con este controlador el sistema en lazo cerrado es estable. Bajo estas condiciones se obtiene un control sin error estacionario siempre y cuando las entradas sean asintóticamente constantes.

De acuerdo con las propiedades anteriores, siempre que se consiga un modelo perfecto de la planta será posible obtener un seguimiento exacto de la referencia aún a pesar de la existencia de perturbaciones no medibles.

Si el modelo no representa exactamente el comportamiento dinámico del controlador, entonces la señal realimentada representa a la vez la influencia de las perturbaciones, tanto medibles como no medibles, y el efecto del error de modelado. El error de modelado puede hacer crecer la señal de realimentación y originar problemas de estabilidad. Por esta razón se introduce el filtro F_2 . Mediante un diseño adecuado, el filtro se puede elegir de manera que se reduzca la ganancia del sistema realimentado, lo que resulta en un alejamiento del controlador perfecto. El efecto de esta acción es introducir robustez en la estructura del IMC. El filtro F_1 se aplica por motivos análogos, pero aplicado a la referencia. Un estudio completo de la robustez y diseño de los filtros F_i puede encontrarse en (Morari and Zafrou, 1989). Una segunda misión del filtro es proyectar la señal de error en el espacio de entrada apropiado para el controlador.

La importancia del IMC está en que sus propiedades de estabilidad y robustez pueden ser analizadas y manipuladas de una manera clara, incluso para sistemas no lineales. Por lo tanto, el IMC facilita un marco general para el control de sistema no lineales.

El IMC puede plantearse como un controlador no lineal (Hunt and Sbarbaro, 1991), (Hunt *et al.*, 1992) y (Economou *et al.*, 1986). La diferencia fundamental respecto a uno lineal es que los operadores M y C son no lineales. Hay varias formas de realizar estos operadores no lineales, como se discute a continuación.

2.1 El operador M

El operador M es un modelo de la dinámica de la planta. Este modelo puede hacerse con redes neuronales, como se puede ver en (Hunt and Sbarbaro, 1991), (Hunt *et al.*, 1992) y (Saludes and Fuente, 2005); o con métodos de inferencia difusa, véase (Boukezzoula *et al.*, 2003), (Fink *et al.*, 2002), (Edgar and Postlethwaite, 1999), (Sánchez *et al.*, 1998) y (Saludes and Fuente, 2003).

2.2 El operador C

El operador C es un modelo de la inversa de la dinámica de la planta. Su misión es hacer de controlador.

Antes de calcular la inversa de la dinámica de la planta hay que tener en cuenta que no siempre es posible encontrarla. Esto puede ser debido tanto a que la inversa no exista como a que no sea posible implementarla en caso de existir. La causas que pueden originar esta imposibilidad son: modelo de la planta de fase no mínima, modelo con retardo o necesidad de emplear lazos con ganancia muy grande al utilizar la inversa de la planta.

Si el modelo de la planta M es lineal y tiene inversa, entonces el cálculo de esta inversa de manera analítica es inmediato. Incluso si el modelo fuera no lineal existen métodos analíticos para calcular su inversa, como el método de Hirschorn (Hirschorn, 1979) que al ser sensible a los errores numéricos y al ruido puede resultar inadecuado.

Cuando el modelo de la planta está definido por un conjunto de modelos lineales locales, como ocurre en (Fink *et al.*, 2002), los controladores se diseñan fuera de línea para cada uno de los modelos. Durante el funcionamiento en línea los resultados de todos los controladores se suman de manera que se de más peso a unos controladores que a otros en función del punto de operación.

Conocido el modelo M de la planta es posible invertir dicho modelo en cada periodo de muestreo mediante algún método de optimización. En (Edgar and Postlethwaite, 1999) se presenta un método para invertir modelos relacionales difusos.

Hunt y Sbarbaro (Hunt *et al.*, 1992) proponen entrenar una red neuronal para representar la inversa de la planta. Para entrenar esta red se ha de minimizar la diferencia entre su salida y la salida de la red que modela la planta, M , entrenada con anterioridad. Esta manera de entrenar la red hace que la función de transferencia entre estas dos señales tienda a la unidad, es decir, se fuerza a la red que es entrenada en este paso a representar la inversa de la dinámica de la planta.

Si el modelo de la planta M puede expresarse como una ley de control afín, la inversión de dicho modelo es inmediata puesto que el control u puede despejarse directamente. Esto es lo que se hace en (Boukezzoula *et al.*, 2003), donde el operador M toma la forma de un sistema difuso de la clase Takagi–Sugeno que puede expresarse como $y_m = \Psi_1 + \Psi_2 u$, donde las funciones Ψ_1 y Ψ_2 representan las distintas reglas.

Sin embargo, en muchas situaciones prácticas, la inversión del modelo M , se haya obtenido éste de una u otra manera, no es factible o sencilla. En estos casos se puede utilizar una red neuronal o neuro-difusa para aprender la dinámica inversa. El entrenamiento se hace utilizando como entradas de la red neuronal las salidas de la planta y como salidas de dicha red las entradas de la

planta. Esta estrategia se adopta en (Sánchez *et al.*, 1998) y (Saludes and Fuente, 2003), donde se utiliza una red neuro-difusa de la clase FasBack y un ANFIS, respectivamente.

2.2.1. Inversión de redes neuronales feedforward

La inversa de una red neuronal es otra red neuronal cuyas entradas y salidas son, nominalmente, las salidas y entradas de la red neuronal inicial. Las dos redes colocadas en serie se han de comportar como la identidad.

La inversa de una red neuronal ha de representar la transformación del espacio de salida en el de entrada. Cuando se trata de redes neuronales diferentes entradas pueden originar la misma salida. Esto conduce a que puede haber más de una transformada que lleve del espacio de salida al de entrada, es decir, la inversa no tiene por qué ser única.

Esto no quiere decir que el problema de calcular la inversa de una red neuronal *feedforward* no tenga solución y, de hecho, ha habido una gran variedad de desarrollos para resolver este problema.

Uno de los primeros métodos para calcular la inversa de un RNA *feedforward* fue planteado por (Linden and Kinndermann, 1989). Ambos grupos propusieron un algoritmo iterativo de inversión basado en un problema de optimización sin restricciones y resuelto por gradiente descendiente.

Posteriormente (Jordan and Rumelhart, 1992) propusieron un método muy diferente compuesto de dos etapas. La primera etapa consiste en el entrenamiento de la red que ha de ser invertida, con lo que se obtiene una aproximación de la transformada del espacio de entrada en el de salida. Una vez entrenada esta RNA es conectada en serie con otra RNA, con lo que se consigue una nueva RNA que es entrenada manteniendo fijos los pesos de las conexiones aportadas por la RNA inicial y que se entrena para ser la identidad.

2.3 El operador F_2

En la práctica el operador M que representa la planta nunca es perfecto, lo que origina una señal de error no nula. El control IMC se caracteriza, como se ha dicho más arriba, por la ausencia de error estacionario si el controlador C es igual a la inversa del modelo de la planta M . Sin embargo, si el error entre la planta y el operador M es grande puede deteriorarse el rendimiento del controlador o, incluso, hacerse inestable. Como este error es más grande en frecuencias altas parece adecuado añadir un filtro pasabajos para dotar al IMC de robustez, (Morari and Zafirou, 1989).

Habitualmente el operador F_2 es un filtro de primer orden con ganancia unidad y la respuesta en frecuencia ajustada para eliminar el ruido de alta frecuencia que introducen los dispositivos de medición.

Algunos autores (Boukezzoula *et al.*, 2003) colocan este filtro en el lazo de realimentación, mientras que otros (Hunt *et al.*, 1992) lo sitúan inmediatamente antes del operador C .

El filtro F_1 no se toma en consideración en este artículo.

3. IMC TOLERANTE A FALLOS EN LA PLANTA

Cuando en la planta se produce un fallo la señal de control que se introduce en ella, u , deja de ser útil para cumplir los objetivos de control. La manera de acomodar el fallo que se describe a continuación se basa en añadir a la señal de control calculada por el controlador, u_n , una señal de control compensadora, u_c , tal que la suma de estas dos últimas permita alcanzar los objetivos de control. De esta manera, la señal de control que se introduce en la planta toma la forma de la ecuación (1).

$$u(k) = u_n(k) + u_c(k) \quad (1)$$

Al calcular la señal de control compensadora se han de tener en cuenta varios aspectos. En primer lugar hay que considerar la naturaleza no lineal de problema, lo que implica que un mismo fallo que se dé en distintos puntos de operación producirá efectos diferentes en cada uno de ellos. En segundo lugar hay que tener en cuenta que durante la fase de diseño del compensador, al menos en el ámbito en el que se plantea este artículo, no se dispone de ningún conocimiento sobre los tipos de fallos que pueden darse, ni sobre su localización ni influencia en la dinámica de la planta. Por estas razones se hace necesario adoptar una estrategia que permita la adaptación a las condiciones de fallo utilizando sólo la información disponible una vez detectado el fallo. Esto se puede lograr mediante una red neuronal entrenada en línea.

Las redes neuronales permiten modelar dinámicas no lineales, como han puesto de manifiesto incontables autores, entre los se puede citar a (Haykin, 1999) como simple exponente. El entrenamiento en línea permite ahorrar el diseño y realización de experimentos para recolectar datos de entrenamiento. También se consigue soslayar el problema de que no todos los posibles fallos que pueden afectar a una planta pueden ser conocidos.

El entrenamiento de la red neuronal compensadora tiene una peculiaridad. Cuando una red neuronal se entrena de manera supervisada se mini-

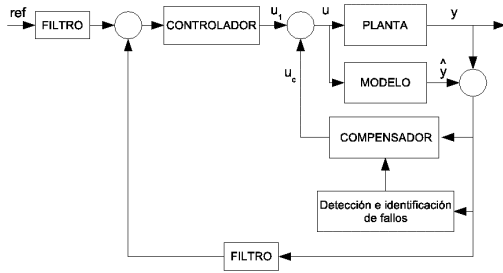


Figura 2. Esquema del controlador IMC con señal de control compensadora

miza el error entre las salidas calculadas por la red y las salidas deseadas. En el caso de la red neuronal compensadora no es posible hacer el entrenamiento de esta manera, pues sería necesario conocer la señal de control deseada, es decir, la señal de control compensadora que ha de calcular la red neuronal que se está entrenando. El camino que se seguirá aquí consiste en minimizar el error de control $\epsilon(k) = r(k) - y(k)$, donde $r(k)$ es la referencia y $y(k)$ es la salida de la planta, ambas en el instante k . Esta forma de entrenar una red neuronal ha sido empleada para hacer controladores adaptativos no lineales, como en (Cui and Shin, 1993; Noriega and Wang, 1998b), o para entrenar en línea una red neuronal que calcule la ganancia de un controlador, (Fuente *et al.*, 2005).

En la figura 2 se representa la estructura del controlador IMC tolerante a fallos mediante la adición de una señal compensadora.

Se trata de una variación del IMC habitual en el que se ha incluido un bloque para la detección de fallos y otro que realiza la compensación. Este bloque está formado por una red neuronal y el algoritmo para entrenarla en línea.

El método que se describe aquí es similar al desarrollado por (Wang and Wang, 1999), aunque hay dos importantes diferencias. En (Wang and Wang, 1999) se emplea una red neuronal pseudo-lineal (Wang *et al.*, 1994) y aquí una perceptrón multicapa. La segunda diferencia es que (Wang and Wang, 1999) desarrollan un tipo de controlador específico, mientras que aquí se utiliza un controlador IMC, que es una estructura de control mucho más general.

3.1 Descripción de la red neuronal compensadora

La red neuronal compensadora es del tipo perceptrón multicapa. La red neuronal tiene n entradas y una capa oculta con h neuronas no lineales. La capa de salida tiene una sola neurona porque sólo se toma en consideración el caso de sistemas SISO.

Los pesos de las conexiones entre la capa de entrada y la oculta se denotan por $w_{i,j}$ y los de

las sinapsis entre la capa oculta y la de salida por ν_j . Se considera que todas las neuronas de la capa oculta tienen la misma función de activación, φ , y que la función de activación de las neuronas de la capa de salida es la identidad. Todas las neuronas tienen bias. Con esta notación, una red neuronal perceptrón con una capa oculta puede expresarse como aparece en las ecuaciones (2) y (3).

$$u_c = \sum_{j=1}^{h+1} \nu_j \tilde{\varphi}(a_j) \quad (2)$$

$$a_j = \sum_{i=1}^{n+1} w_{i,j} \tilde{e}_i \quad (3)$$

donde $\tilde{e} = [e_1, e_2, \dots, e_n, 1]$, con e_i las entradas de la red neuronal, y

$$\tilde{\varphi}(a_j) = [\varphi(a_1), \varphi(a_2), \dots, \varphi(a_h), 1] \quad (4)$$

La función de activación puede ser cualquiera de las no lineales que se emplean en los perceptrones multicapa. En el caso que se estudia aquí esta función es la que aparece en la ecuación (5). La ecuación (6) es la derivada de la función de activación mostrada en la ecuación (5).

$$\varphi(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (5)$$

$$\frac{d\varphi(x)}{dx} = \dot{\varphi}(x) = \frac{4e^{-2x}}{(1 + e^{-2x})^2} \quad (6)$$

3.1.1. Entrenamiento El entrenamiento de la red neuronal se hace según la regla delta:

$$w_{i,j}(k) = w_{i,j}(k-1) - \eta \frac{\partial E(t)}{\partial w_{i,j}(k)} \quad (7)$$

$$\nu_i(k) = \nu_i(k-1) - \eta \frac{\partial E(t)}{\partial \nu_i} \quad (8)$$

donde η es el ritmo de aprendizaje. $E(t)$ es el error de seguimiento de la referencia, definido como

$$E(t) = \frac{1}{2} \sum_{k=1}^t \epsilon(k)^2 \quad (9)$$

Las derivadas que aparecen en las ecuaciones (7) y (8) pueden calcularse utilizando la regla de la cadena:

$$\frac{\partial E(t)}{\partial \nu_i} = \frac{\partial E(t)}{\partial \epsilon(k)} \frac{\partial \epsilon(k)}{\partial y(k)} \frac{\partial y(k)}{\partial u(k)} \frac{\partial u(k)}{\partial u_c(k)} \frac{\partial u_c(k)}{\partial \nu_i} \quad (10)$$

$$\frac{\partial E(t)}{\partial w_{i,j}} = \frac{\partial E(t)}{\partial \epsilon(k)} \frac{\partial \epsilon(k)}{\partial y(k)} \frac{\partial y(k)}{\partial u(k)} \frac{\partial u(k)}{\partial u_c(k)} \frac{\partial u_c(k)}{\partial w_{i,j}} \quad (11)$$

Así mismo, cada una de estas derivadas parciales puede calcularse analíticamente. De esta forma es posible obtener una expresión cuyo cálculo en línea permite el entrenamiento de la red neuronal compensadora.

El valor de las derivadas parciales es el siguiente:

$$\frac{\partial E(t)}{\partial \epsilon(k)} = \epsilon(k) \quad (12)$$

$$\frac{\partial \epsilon(k)}{\partial y(k)} = -1 \quad (13)$$

$$\frac{\partial y(k)}{\partial u(k)} = \text{sign}(K) \quad (14)$$

$$\frac{\partial u(k)}{\partial u_c(k)} = 1 \quad (15)$$

La derivada de la salida de la planta respecto de su entrada merece una atención especial. (Cui and Shin, 1993) han demostrado que para entrenar una red neuronal integrada en un lazo de control mediante la minimización del error de seguimiento de la referencia no es necesario conocer el valor exacto de $\frac{\partial y(k)}{\partial u(k)}$, sino que dicho valor puede ser substituido por el signo de la ganancia de la planta, siempre y cuando la planta tenga un comportamiento monótono. Por comportamiento monótono se entiende que la salida de la planta evoluciona de manera monótona ante entradas monótonas.

Para calcular las otras dos derivadas hay que utilizar nuevamente la regla de la cadena:

$$\frac{\partial u_c}{\partial v_i} = \begin{bmatrix} \varphi \left(\sum_{i=1}^{n+1} w_{i,1} \tilde{e}_i \right) \\ \varphi \left(\sum_{i=1}^{n+1} w_{i,2} \tilde{e}_i \right) \\ \vdots \\ \varphi \left(\sum_{i=1}^{n+1} w_{i,h} \tilde{e}_i \right) \\ 1 \end{bmatrix} \quad (16)$$

$$\frac{\partial u_c}{\partial w_{i,j}} = \begin{bmatrix} \nu_1 e_1 \dot{\varphi} \left(\sum_i w_{i,1} \tilde{e}_i \right) & \dots & \nu_h e_1 \dot{\varphi} \left(\sum_i w_{i,h} \tilde{e}_i \right) \\ \nu_1 e_2 \dot{\varphi} \left(\sum_i w_{i,1} \tilde{e}_i \right) & \dots & \nu_h e_2 \dot{\varphi} \left(\sum_i w_{i,h} \tilde{e}_i \right) \\ \vdots & \ddots & \vdots \\ \nu_1 e_n \dot{\varphi} \left(\sum_i w_{i,1} \tilde{e}_i \right) & \dots & \nu_h e_n \dot{\varphi} \left(\sum_i w_{i,h} \tilde{e}_i \right) \\ \nu_1 \dot{\varphi} \left(\sum_i w_{i,1} \tilde{e}_i \right) & \dots & \nu_h \dot{\varphi} \left(\sum_i w_{i,h} \tilde{e}_i \right) \end{bmatrix} \quad (17)$$

donde se ha suprimido la especificación del periodo de muestreo k para simplificar la notación y en todos los casos $i = \{1, \dots, n+1\}$.

Normalmente una red neuronal solamente es utilizada después de haber sido entrenada adecuadamente, es decir, cuando los pesos de la red ya no necesitan ser modificados porque se ha alcanzado el error objetivo. Sin embargo, para un sistema que cambia con el tiempo no tiene sentido hablar de una red neuronal bien entrenada porque el sistema que se modela cambia continuamente. Por eso es necesario que el algoritmo de entrenamiento se aplique continuamente. Esto es especialmente necesario en el caso de fallos en rampa.




Figura 3. Esquema del sulfitador


4. APLICACIÓN A UN PROCESO DE CONTROL DE PH

4.1 Descripción de la planta

El proceso de sulfitación se utiliza en la industria azucarera para controlar el pH de la llamada *lechada de cal*. Este pH es una variable crítica en el proceso de obtención del azúcar y por eso su control es de gran importancia.

El propósito de la sulfitación es reducir el pH de la disolución de $Ca(OH)_2$ que fluye constantemente hacia el interior del reactor o tanque de sulfitación. Este tanque tiene en su base un contenedor de agua, ver figura 3, gracias al cuál se forman burbujas de dióxido de azufre (SO_2). El gas entra en el tanque a través de una red de tubos, lo que facilita la formación de una gran cantidad de burbujas de dicho gas. Éste reacciona con la fase líquida, que desborda y abandona el reactor con un pH menor.

El caudal de SO_2 puede ser regulado mediante una válvula dispuesta para tal fin, lo que permite controlar el pH del producto de salida. El producto de la reacción entre el SO_2 y el agua es ácido sulfuroso (H_2SO_3) y al disociarse origina iones (H^+) que reducen el pH de la disolución que entra en la torre de sulfitación. Hay una tercera reacción que afecta a los iones SO_3 presentes en la lechada de cal que entra en el sulfitador. Las tres reacciones que tienen lugar en el reactor son las que se muestran en (18).



4.1.1. Modelo matemático El modelado del sulfitador se estudia en profundidad en (de Prada *et al.*, 1984). A partir del balance de masas y energías se llega al conjunto de ecuaciones (19):

Tabla 1. Parámetros del modelo del sulfitador

Constante	Valor
b	1,7 s
k	0,9
V	1000 l
F_a	11,05 l/s
Z_S	0,45344659
E_S	19010,7323 J/mol
Z_a	84415085,06
E_a	22500 J/mol

$$\begin{aligned}
 b \frac{dF_S}{dt} &= -F_S + kF_g \\
 \frac{V}{F_a} \frac{dX}{dt} &= -X + [CaOH^+]_i - \frac{\alpha}{F} F_S \\
 \frac{dC}{dt} &= \frac{F_S}{V} - \frac{F_a C}{V} \\
 [H^+] &= \frac{X}{2} \left[-1 + \text{sign}(x) \sqrt{1 + \frac{4K_w}{X^2}} \right] \\
 pH &= -\log([H^+])
 \end{aligned} \quad (19)$$

La primera de las ecuaciones describe la evolución temporal del caudal de dióxido de azufre, F_S , transferido al líquido; siendo k el coeficiente de disolución y b el tiempo característico de la solución.

La magnitud intermedia X , que aparece en la segunda de las ecuaciones, se define como $X = [OH^-] - [H^+]$. α es la constante de disociación. La cantidad $[CaOH^+]_i$ representa la concentración inicial de estos iones. Las magnitudes V y F_a son el volumen y el caudal de agua, respectivamente.

La variable C se define de la forma $C = [SO_3H_2] + [SO_3H^-]$. La cantidad K_w es el coeficiente de disociación del agua.

Finalmente, la expresión de la constante de disociación α viene dada por:

$$\alpha = \frac{-K_{eq} + \sqrt{K_{eq}^2 + 4K_{eq}C}}{2C}$$

donde K_{eq} es el coeficiente de equilibrio de la reacción. Este coeficiente, a su vez se expresa de la forma:

$$K_{eq} = Z_S \exp\left(\frac{-E_S}{RT_{abs}}\right)$$

En esta ecuación E_S es la energía de activación. También el coeficiente de disociación del agua tiene una expresión análoga:

$$K_w = Z_a \exp\left(\frac{-E_a}{RT_{abs}}\right)$$

Para las constantes E_a y Z_a se puede decir lo mismo que para la ecuación del coeficiente de equilibrio.

Los valores de las constantes que caracterizan al sulfitador aparecen en la tabla 1.




Figura 4. Superposición de las salidas de entrenamiento

4.2 Aplicación del IMC no lineal

4.2.1. Modelado de la planta Para entrenar un ANFIS que describa el comportamiento del sulfitador se ha buscado una entrada que excite todos los modos de funcionamiento de interés. La entrada elegida ha sido un tren de pulsos de diferentes amplitudes y frecuencias.

Al no tener el ANFIS una estructura recursiva ni ninguna otra característica que lo dote de memoria, se utilizan valores pasados de las entradas y de las salidas para que el ANFIS capte la dinámica de la planta. La ecuación (20) se refleja el vector de entradas. La salida es $pH(t)$.

$$\mathcal{E}_M(t) = \{F_g(t), F_g(t-1), pH(t-1), pH(t-2)\} \quad (20)$$

Se ha elegido un ANFIS con tres funciones de pertenencia gaussianas por entrada.

Para validar el sistema se ha recurrido a los datos de entrenamiento y, sobre todo, a los de validación. La figura 4 muestra la superposición de las salidas correspondientes a las entradas de entrenamiento y validación. Puede apreciarse en dicha figura que en el caso de los datos de entrenamiento hay una total coincidencia entre las salidas del modelo y de la planta. En el caso de los datos de validación ya aparece una desviación. En la figura 4 se ha ampliado la zona entre $pH = 4$ y $pH = 8$ para que se aprecie mejor la diferencia. La diferencia depende del punto de operación y es tolerable.

4.2.2. Modelado de la inversa de la planta Para entrenar el modelo de la inversa de la dinámica del sulfitador es necesario una señal de entrada que produzca una densidad de datos alta en aquellos puntos de operación donde la no linealidad es más crítica. Las señales utilizadas para entrenar se muestran en la figura 5. Para que el ANFIS capte la dinámica del sistema inverso se ha recurrido a la utilización de valores pasados de las entradas




Figura 5. Entrada y salida de entrenamiento para el modelo de la inversa de la dinámica de la planta




Figura 6. Salidas de la planta y del ANFIS inverso y salidas, como en el caso del modelo directo. La ecuación (21) expresa las entradas del ANFIS con el que se ha modelado el controlador. La salida es $F_g(t)$.

$$\mathcal{E}_C(t) = \{pH(t), F_g(t-1), F_g(t-2)\} \quad (21)$$

El tipo de función de pertenencia escogido es el producto de dos sigmoides. El número de funciones de pertenencia por entrada es tres. Para validar el modelo se ha recurrido a los datos de validación. La figura 6 muestra la superposición de las salidas. La salida del modelo coincide con la de validación, observándose cierto retraso en el seguimiento de los cambios.

4.2.3. Filtro En el IMC se utiliza un filtro, que es aplicado a la señal que se realimenta, ecuación (22). El valor del filtro se ha calculado por el método de prueba y error.

$$F = \frac{10^{-6}}{z + 10^{-6}} \quad (22)$$

En el IMC la señal realimentada es nula mientras no haya perturbaciones, ruido de medida o cambios en la referencia. Pero en la práctica siempre tendremos ruido de medida y ruido debido a los

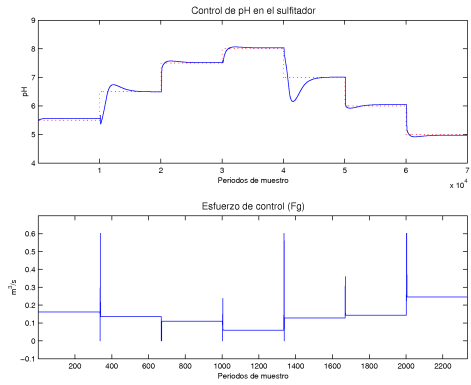


Figura 7. Control del sulfitador con el IMC

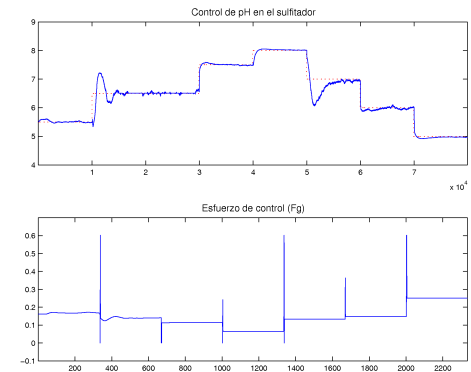


Figura 8. Rechazo de la perturbación en pH_a

errores de modelado. La finalidad del filtro de realimentación es eliminar o suavizar estos ruidos. De esta manera se evitan los problemas de estabilidad que podrían derivarse de la realimentación de los mismos.

4.2.4. Resultados del control IMC no lineal Se han realizado experimentos de control de pH en simulación. La figura 7 muestra el resultado cuando la referencia se mueve por todo el rango de operación. Se aprecia como el rendimiento del controlador cambia con el punto de operación. La figura 8 muestra el rechazo de la perturbación en el pH de la lechada de cal, pH_a . Esta perturbación es la que más afecta al control, siendo el efecto de las otras perturbaciones, por separado o conjuntamente, despreciable. En la señal de control se observan picos en los instantes en los que se produce un cambio en la referencia. La causa de estos picos es un modelado imperfecto de la dinámica de la inversa de la planta.

4.3 Tolerancia a fallos en la planta

El método descrito en la sección 3 se ha aplicado al sistema formado por el sulfitador y el IMC no lineal descritos anteriormente. No se han conside-

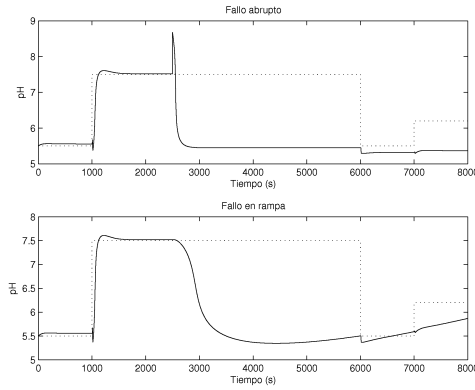


Figura 9. Salida del sulfitador en presencia de un fallo abrupto y un fallo en rampa, ambos sin acción compensadora.

rado fallos ni en los actuadores ni en los sensores, solamente fallos en la planta. Estos fallos consisten en la disminución de la temperatura interna del sulfitador monótonamente o abruptamente hasta la mitad de su valor normal.

En la figura 9 se muestra la salida de la planta cuando se produce un fallo en escalón o en rampa en $t = 2500$ s y no se lleva a cabo ninguna acción de reconfiguración del controlador. Puede verse como el fallo hace que la salida de la planta se aleje abruptamente de la referencia, de manera más acusada en el caso del fallo en escalón, al ser el controlador nominal incapaz de generar acciones de control válidas para la nueva situación de la planta. A pesar de ello, se observan ciertos cambios en la salida de la planta en los instantes en los que se producen cambios en la referencia.

Para generar la señal de control compensadora, u_c , que será sumada a la señal de control nominal, u_n , y formar la señal de control que se introduce en la planta, tal como se muestra en la ecuación (1), se ha utilizado una red neuronal perceptrón multicapa con dos entradas y cinco neuronas en la capa oculta y una en la capa de salida. La función de activación de la neurona de la capa de salida es la identidad y la de las neuronas de la capa oculta es la que se muestra en la ecuación (5).

Las entradas de la red neuronal compensadora deben reflejar el estado real y deseado de la planta controlada, por lo que el conjunto de entradas puede incluir a la salida de la planta, la referencia o el error de seguimiento de la misma. Para el caso que aquí se describe se utiliza el error de seguimiento:

$$e(k) = \{\epsilon(k), \epsilon(k-1)\} \quad (23)$$

Las entradas de la red neuronal pueden ser normalizadas tomando como límites los valores máximos y mínimos de la salida de la planta, la referencia o el error de seguimiento. De la misma manera, la salida de la red neuronal compensadora puede

Tabla 2. Ritmo de aprendizaje

Punto de operación	η
$pH = 5,0, 5,5$	0,005
$pH = 6,0, \dots, 9,0$	0,001

ser desnormalizada usando como límites el rango de variación de la señal de control, pues esta salida se sumará a la señal de control nominal. En el caso del sulfitador no se han normalizado las entradas de la red neuronal compensadora ni desnormalizado sus salidas. Al estar el conjunto de entradas formado por los errores de seguimiento y ser éste el que minimiza el algoritmo de entrenamiento, no se hace necesario normalizar las entradas porque son del mismo orden que el error que se minimiza.

El entrenamiento de la red neuronal se lleva a cabo según se ha descrito en la sección 3.1.1 y se ejecuta una sola vez en cada periodo de muestreo, es decir, sólo se ejecuta una época de entrenamiento en cada periodo de muestreo.

El ritmo de aprendizaje η determina la velocidad con la que se acomoda el fallo, esto es, el tiempo que se requiere para que la salida de la planta alcance de nuevo a su referencia. Valores pequeños de η producen convergencias lentas de la salida hacia su referencia. Los valores grandes, aparte de producir una acomodación más rápida, pueden originar una respuesta oscilatoria sin convergencia.

Los valores del ritmo de aprendizaje que se han utilizado para el sulfitador se muestran en la tabla 2.

Se han hecho varios experimentos para comprobar la validez del método presentado, cada uno en un punto de operación diferente. En primer lugar se han hecho experimentos de fallo en escalón, como en el ejemplo mostrado en la figura 9, manteniendo constante el tamaño y el instante en el que se produce el fallo. En la figura 10 se muestra el experimento hecho en el valor de la referencia $pH = 7,0$ y en la figura 11 el resultado del experimento hecho en el valor de la referencia $pH = 8,0$. En ambas figuras u_1 es la señal de control calculada por el controlador, u_c es la señal de control calculada por la red neuronal y u es la suma de ambas. Ésta es la señal de control que se introduce en la planta.

En la tabla 3 se muestran los resultados de todos los experimentos de fallo en escalón. Para cada uno de ellos se ha calculado el sobrepico (M_p) que aparece como consecuencia de la adición de la señal compensadora, el tiempo de pico o instante en el que se produce el sobrepico (t_p) y el tiempo de asentamiento (t_s) calculado según el criterio del 1%. Todos estos parámetros se han calculado según se definen en (Ogata, 1993). En todos los experimentos, independientemente del valor de la




Figura 10. Acomodación de un fallo en el sulfita-dor en la referencia $pH = 7$ por el método de la red neuronal compensadora




Figura 11. Acomodación de un fallo en el sulfita-dor en la referencia $pH = 8$ por el método de la red neuronal compensadora

referencia en el momento del fallo, se consigue acomodar el fallo.

También se han hecho experimentos de fallos en rampa, como el que se muestra en la parte inferior de la figura 9. En todos los casos el fallo empieza en $t = 2500$ s y la pendiente de la rampa es siempre la misma. En la tabla 4 se muestran los resultados resumidos de la misma manera que en el caso de los fallos en escalón. En todos los casos la salida de la planta vuelve a alcanzar su valor de referencia, a pesar de la presencia del fallo.

En el experimento realizado en $pH = 9$ el tiempo de establecimiento es nulo porque la salida de la

Tabla 3. Resumen de los resultados obtenidos en el sulfita-dor con el método de la señal de control compensadora para un fallo abrupto

Referencia	t_p	M_p	t_s
5,0000	220,9000	0,1046	648,6000
5,5000	161,8000	-0,0990	337,5000
6,0000	194,8000	-0,5045	898,0000
6,5000	153,6000	-0,9087	730,4000
7,0000	140,7000	-1,4041	914,2000
7,2500	138,9000	-1,5997	876,7000
7,5000	149,7000	-1,7223	733,4000
8,0000	3,9000	1,1672	630,6000
8,5000	0	1,0479	460,0000
9,0000	3,9000	1,1413	373,5000

Tabla 4. Resumen de los resultados obtenidos en el sulfita-dor con el método de la señal de control compensadora para un fallo en rampa

Referencia	t_p	M_p	t_s
5,0000	-0,0000	-0,0130	658,0000
5,5000	-0,0000	0,1535	156,3000
6,0000	0,7000	0,1581	841,8000
6,5000	2,1000	0,1026	768,1000
7,0000	7,0000	0,1169	615,6000
7,2500	31,5000	0,0904	668,1000
7,5000	53,4000	0,1399	502,0000
8,0000	-0,0000	0,0992	60,5000
8,5000	-0,0000	-0,1101	26,8000
9,0000	-0,0000	-0,0355	0,0




Figura 12. Acomodación de un fallo en rampa en $pH = 7$ mediante la red neuronal compensadora

planta no sale de la banda de $\pm 1\%$ en ningún momento.

En la figura 12 se muestra un ejemplo de acomodación de un fallo en rampa producido en el punto de operación $pH = 7,0$ y en la figura 13 otro ejemplo de la acomodación de un fallo en rampa, esta vez en el punto de operación $pH = 8,0$.




Figura 13. Acomodación de un fallo en rampa en $pH = 8$ por el método de la red neuronal compensadora

5. CONCLUSIONES

En este artículo se ha presentado un controlador IMC para sistemas no lineales. El controlador está basado en modelos neuro-difusos ANFIS que se utilizan tanto para modelar la planta como para hacer un modelo de la inversa de la misma. De entre todos los métodos posibles para calcular un modelo de la inversa de la dinámica de una planta, aquí se ha empleado el que conceptualmente resulta más sencillo, que no consiste más que en utilizar las salidas de la planta como entradas para el modelo y las entradas de la misma como salidas del modelo. Los resultados obtenidos en simulación en un sulfitador como los empleados en la industria azucarera han mostrado que el IMC no lineal realizado de esta manera es útil para controlar este proceso no lineal en un amplio rango de operación.

Los fallos que se producen en el sulfitador no pueden ser compensados por el controlador IMC por sí sólo. Al producirse un fallo tanto el modelo de la planta como el de la inversa de la dinámica de la misma dejan de tener validez. Por esta razón la señal de control calculada por el IMC no conseguirá que las salidas de la planta alcancen sus referencias. Una manera de remediar este problema consiste en sumar a la señal de control generada por el IMC otra señal de control que compense el efecto del error de modelado que introduce la presencia de un fallo en la planta.

Esta señal de control se puede calcular en línea sin necesidad de tener ningún conocimiento previo de la dinámica de la planta cuando está sometida a la acción de un fallo. Para lograrlo se puede recurrir a una red neuronal cuya salida es la

señal de control compensadora. La red neuronal es entrenada en línea y de manera supervisada. El entrenamiento posibilita que la red neuronal aprenda situaciones no conocidas previamente, aspecto en el que se basa la propiedad de no necesitar conocimiento previo de la dinámica de la planta bajo fallo. El entrenamiento puede hacerse en línea porque el algoritmo de aprendizaje busca la minimización del error de control.

Los experimentos realizados en simulación en el sulfitador permiten concluir que esta técnica sirve para acomodar fallos multiplicativos, tanto abruptos como incipientes, en esa planta no lineal.

REFERENCIAS

- Boukezzoula, Reda, Sylvie Galichet and Laurent Foulloy (2003). Nonlinear internal model control: Application of inverse model based fuzzy control. *IEEE Transactions on Fuzzy Systems* **11**(6), 814–829.
- Chen, J., Ron J. Patton and Z. chen (1999). Active fault tolerant flight control systems design using the linear matrix inequality method. *Transactions of the Institute of Measurement Control* **21**(2/3), 77–84.
- Cui, Xianzhong and Kang G. Shin (1993). Direct control and coordination using neural networks. *IEEE Transactions on Systems, Man and Cybernetics* **23**(3), 686–697.
- de Prada, César, Pastora Vega and Luis Alonso (1984). Modelling and simulation of a sulfitation tower for adaptive control. In: *11th IASTED conference Applied Modelling and Simulation*.
- Economou, C. G., Manfred Morari and B. O. Pals-son (1986). Internal model control. 5. extension to nonlinear systems. *Industrial Engineering Chemical Process Design and Development* **25**, 403–411.
- Edgar, Craig R. and Bruce E. Postlethwaite (1999). Using fuzzy relational models for control. In: *Proceedings of the European Symposium on Intelligent Techniques*. Orthodox Academy of Crete, Grecia.
- Fink, Alexander, Oliver Nelles and Rolf Isermann (2002). Nonlinear internal model control for MISO systems based on local linear neuro-fuzzy models. In: *Proceedings of the 15th IFAC World Congress*. Barcelona.
- Fuente, M. J., G. I. Sáinz, M. Alonso and A. Aguado (2005). Neuro-fuzzy control of a pH plant. In: *Proceedings of the 16th IFAC World Congress*. Praga.
- Gao, Z. and P. J. Antsaklis (1991). Stability of the pseudo-inverse method for reconfigurable control systems. *International Journal Control* **53**, 717–729.

- García, C. E. and Manfred Morari (1982). Internal model control – 1. a unifying review and some new results. *Ind. Eng. Chem. Process Des. Dev.* **21**, 308–323.
- Haykin, Simon (1999). *Neural Networks: a Comprehensive Foundation*. 2^a ed.. Prentice Hall International, Inc.
- Hirschorn, Ronald M. (1979). Invertibility of multivariable nonlinear control systems. *IEEE Transactions on Automatic Control* **24**(6), 855–865.
- Hunt, K. J. and D. Sbarbaro (1991). Neural networks for nonlinear internal model control. In: *IEE Proceedings–D* (IEE, Ed.). Vol. 138. IEE. pp. 431–438.
- Hunt, K. J., D. Sbarbaro, R. Zbikowski and P. J. Gawthrop (1992). Neural networks for control systems – a survey. *Automatica* **28**(6), 1083–1112.
- Jang, J.R. (1993). ANFIS: Adaptive-network-based fuzzy inference system. *IEEE Trans. on Systems, Man and Cybernetics* **23**, 665–685.
- Jiang, J. (1994). Design of reconfigurable control systems using eigenstructure assignments. *International Journal of Control* **59**(2), 395–410.
- Jordan, Michael I. and Davis E. Rumelhart (1992). Forward models: Supervised learning with a distal teacher. *Cognitive Science* **16**, 307–354.
- Kaminer, I., A.M. Pascoal, P.P. Khargonekar and E.E. Coleman (1995). A velocity algorithm for the implementation of gain-scheduled controllers. *Automatica* **31**(8), 1185–1192.
- Linden, A. and J. Kinndermann (1989). Inversion of multilayer nets. In: *Proceedings of the International Joint Conference on Neural Networks*. Vol. 2. pp. 425 – 430.
- Looze, D. P., J. L. Weiss, J. S. Eterno and N. M. Barret (1985). An automatic redesign approach for restructurable control systems. *IEEE Control Systems Magazine* **5**(2), 16–22.
- Morari, Manfred and Evangelos Zafirou (1989). *Robust Process Control*. Prentice–Hall.
- Morse, W.D. and K.A. Ossman (1990). Model-following reconfigurable flight control system for the AFTI/F–16. *Journal of Guidance, Control and Dynamics* **13**(6), 969–976.
- Noriega, Jose R. and H. Wang (1998a). A heuristic approach to fault tolerant control of unknown nonlinear systems using neural networks. In: *Proceedings of Fifth IFAC Workshop on Algorithms and architectures for real-time control*. Cancún, México. pp. 265–269.
- Noriega, Jose R. and Hong Wang (1998b). A direct adaptive neural-network control for unknown nonlinear systems and its application. *IEEE Transactions on Neural Networks* **9**(1), 27–34.
- Ochi, Y. (1993). Application of feedback linearisation method in a digital restructurable flight control system. *Journal of Guidance, Control and Dynamics* **16**(1), 111–117.
- Ogata, Katsuhiko (1993). *Ingeniería de Control Moderna*. 2^a ed.. Prentice Hall Hispanoamericana, S.A.
- Saludes, Sergio and M. J. Fuente (2003). Fault tolerant fuzzy IMC control in a pH process. In: *Proceedings of the European Control Conference*. Cambridge (Reino Unido).
- Saludes, Sergio and M. J. Fuente (2005). Support vector based novelty detection for fault tolerant control. In: *Proceedings of the European Control Conference*. Sevilla (España). pp. 5820–5825.
- Sánchez, E. Gómez, J. M. Cano Izquierdo, M. J. Araúzo Bravo, Y. A. Dimitriadis and J. López Coronado (1998). Adaptive IMC using fuzzy neural networks for the control on non linear systems. In: *The European Conference on Integration in Manufacturing*. Goteborg, Suecia.
- Wang, H. and Y. Wang (1999). Neural-network-based fault-tolerant control of unknown nonlinear systems. *IEE Proceedings – Control Theory and Applications* **146**(5), 389–398.
- Wang, H., M. Brown and C. J. Harris (1994). Fault detection for a class of unknown nonlinear systems via associative memory networks. *IMEchE J, I, Syst. Control Eng.* **79**, 1415–1441.