

An experimental study of controllers based on neuronal networks

Javier Bastidas y Carlos Vinante

*Universidad del Zulia, Apartado 10523. Maracaibo, Venezuela.
Fax 58-61-520717. E-mail: cvinante@luz.ve, jbastida@luz.ve*

Abstract

In this paper a predictive controller is presented, the output of which is obtained at each sampling time by numerically minimizing the merit function real error between the desired value and the output produced by the neural network that models the process dynamics. The on-line solution to this non-linear problem at each sampling moment corresponds to the output obtained using the direct method and the dynamic of the realizable inverse process. In comparison with the topology of the classic Internal Model Controller (IMC), this controller uses only the direct neural network and does not have the error problems of a stationary state due to the inexactness of the direct and inverse neuronal models. In order to demonstrate an experimental application of this controller, the proposed algorithm is applied to control the flow in experimental equipment used to calibrate valves. This is an interesting process because it includes non-linear considerations and dead time. The experimental results indicate that, for processes with non-linear gains and time delay, this algorithm performs better than the controllers based on linear process models.

Key words: Neuronal networks, nonlinear control, closed loop identification.

Estudio experimental de controladores basados en redes neuronales

Resumen

En este trabajo se presenta un controlador predictivo cuya salida se obtiene en cada tiempo de muestreo minimizando numéricamente una función de mérito del error actual entre el valor deseado y la salida de la red neuronal que modela la dinámica del proceso. La solución en línea de este problema no lineal en cada tiempo de muestreo se corresponde con la salida que se obtendría usando directamente la dinámica de la inversa realizable del proceso. A diferencia de la topología del Controlador de Modelo Interno (IMC) clásico, el esquema propuesto sólo utiliza un modelo neuronal y no presenta los problemas de errores en estado estacionario debidos a la inexactitud de los modelos neuronales directo e inverso. Para mostrar una aplicación experimental de este controlador se implementó para el control de caudal en un banco de calibración de válvulas. Este proceso es interesante pues presenta considerables no linealidades y tiempo muerto. Los resultados experimentales obtenidos indican que, para procesos con ganancias no lineales y tiempo muerto, el comportamiento de este tipo de controlador es superior a los lineales.

Palabras clave: Redes neuronales, control no lineal, identificación en lazo cerrado.

Introducción

Aun cuando en la práctica la mayoría de los procesos presentan características no lineales, en la actualidad las técnicas más usadas para el

diseño de controladores están basadas en modelos linealizados alrededor de los puntos de operación de la planta. Esto se debe a que para el caso lineal existen métodos bien establecidos para desarrollar modelos a partir de datos experimenta-

les de entrada-salida, y técnicas para estudiar la estabilidad, robustez, etc. de los lazos de control obtenidos. Sin embargo, cuando las no linealidades del proceso son considerables o se presentan grandes desviaciones de las variables del punto de operación para el cual se obtuvo el modelo linealizado, el comportamiento de los controladores lineales no es del todo satisfactorio.

Para estos casos es ahora posible, debido a los considerables avances en hardware y software, desarrollar e implantar algoritmos de control basados en modelos no lineales que describen mejor al proceso en todo el rango de operación [1-3].

En principio, estos modelos no lineales se pueden obtener a partir de ecuaciones basadas en relaciones físico-químicas que describen la dinámica del proceso. En general, esto es muy difícil de realizar debido al conocimiento incompleto de las ecuaciones que rigen la dinámica o por la complejidad de las relaciones en sistemas medianamente grandes. Para superar estas dificultades muchos autores [2-4], han propuesto recientemente el uso de redes neuronales para el modelado de la dinámica de procesos no lineales.

Existen varias opciones para incorporar redes neuronales en estructuras de control basadas en modelos. Una de las formas más estudiadas consiste en reemplazar los modelos lineales directo e inverso del proceso por sus correspondientes redes neuronales y utilizar la configuración clásica del IMC lineal (Control Predictivo de un solo paso) [5]. Para el Control Predictivo de múltiples pasos se reemplaza el modelo lineal de convolución por una red neuronal, y se resuelve numéricamente en cada tiempo de muestreo un problema de optimización de cuadrados mínimos no lineal [1-3].

En este trabajo se presenta un algoritmo simplificado para el Control Predictivo de un solo paso basado en la solución en línea de un problema de minimización no lineal. La acción de control obtenida corresponde aproximadamente a la salida de la red neuronal que modela la inversa del proceso. Este controlador se puede considerar como una generalización para el caso no lineal del propuesto por Dahlin [6-7], o un caso particular del método de linealización realimentada (feedback linearization), que consiste en de-

terminar una ley de control estática para que el sistema en lazo cerrado tenga un comportamiento lineal entre la entrada y la salida. La ventaja de este controlador es que en la minimización utiliza sólo la red neuronal directa, y ésta es en general más fácil de entrenar que la inversa.

Desarrollo del Controlador propuesto

Consideraciones generales

La idea central en el desarrollo de este algoritmo, es especificar una relación funcional deseada entre el valor de referencia y la variable controlada, y luego utilizando el modelo del proceso se obtiene la estructura del controlador necesaria para que el lazo de control cumpla la relación.

Con una relación funcional adecuada, se logra que las variaciones de las entradas al controlador no provoquen su saturación, llevando a la variable controlada asintóticamente a su valor deseado, siendo además el controlador robusto en presencia de errores y discrepancias por la aproximación de los modelos.

En el siguiente desarrollo se supondrá que el proceso a controlar está modelado por una relación funcional determinada (lineal o no lineal) invertible más un retraso de N tiempos de muestreo, es decir:

$$y(kT) = G_M(u(k - N)T) \quad (1)$$

donde y es la salida del proceso, u es la acción de control y G_M es la relación funcional.

La relación funcional especificada entre el valor deseado yd y la variable controlada, es generalmente una implementación digital de un filtro pasa-bajo lineal con un retardo de por lo menos el mismo orden que el tiempo muerto de proceso. Para el caso de un filtro lineal de primer orden se tiene:

$$\frac{y(z)}{yd(z)} = \frac{(1 - \alpha)z^{-N-1}}{(1 - \alpha z^{-1})} = F(z)z^{-N} \quad (2)$$

donde $\alpha = \exp(-T/\tau)$, T es el tiempo de muestreo y τ es la constante de tiempo del filtro.

A partir de la ecuación (2) y el modelo del proceso se obtiene el operador que representa al controlador de Dahlin para el caso general. Este consiste de la composición del operador lineal dado por:

$$E(z) = \frac{(1-\alpha)z^{-N-1}}{1-\alpha z^{-1} - (1-\alpha)z^{-N-1}} = \frac{v(z)}{e(z)} \quad (3)$$

con el operador $[G_M^{-1}]$ que representa la inversa entrenada o calculada del modelo dinámico sin considerar el tiempo muerto.

$$u(k) = [G_M^{-1}](v(k)) \quad (4)$$

En el tiempo se tiene la siguiente ecuación recursiva:

$$u(k) = G_c e(k) = [G_M^{-1}](\alpha v(k-1) + (1-\alpha)v(k-N-1) + (1-\alpha)e(k-N-1)) \quad (5)$$

Al considerar la ecuación (3) se observa la presencia de una acción integral dada por $1/(1-\alpha z^{-1} - (1-\alpha)z^{-N-1})$ que garantiza la eliminación de desviaciones en estado estacionario.

A continuación se demostrará que tanto el controlador propuesto como el IMC son casos especiales del esquema del predictor de Smith [7]. Este esquema fue desarrollado para superar las limitaciones que la presencia de tiempo muerto impone en el entonamiento de los controladores. El uso de este esquema permite entonar al controlador C, en la Figura 1, como si no hubiera tiempo muerto; es decir, sin necesidad de desensibilizar los parámetros del mismo para mantener estabilidad. En la Figura 1 se muestra la topología de este predictor para el caso lineal. El esquema para el caso no lineal es similar, debiendo sustituirse solamente las ecuaciones de transferencia en los bloques por operadores.

En este esquema, cuando se utiliza el controlador propuesto desarrollado para el modelo sin tiempo muerto, que esta dado por la ecuación (5) con $N = 0$, se obtiene el esquema correspondiente al controlador IMC mostrado en la Figura 2 [2-4], donde P representa al proceso, $G_M(u(k-N)T)$ es la relación lineal o no lineal (red neuronal por ejemplo) que modela la dinámica del proceso, G_M^{-1} es el controlador (la parte realizable de la funcional que representa la dinámica in-

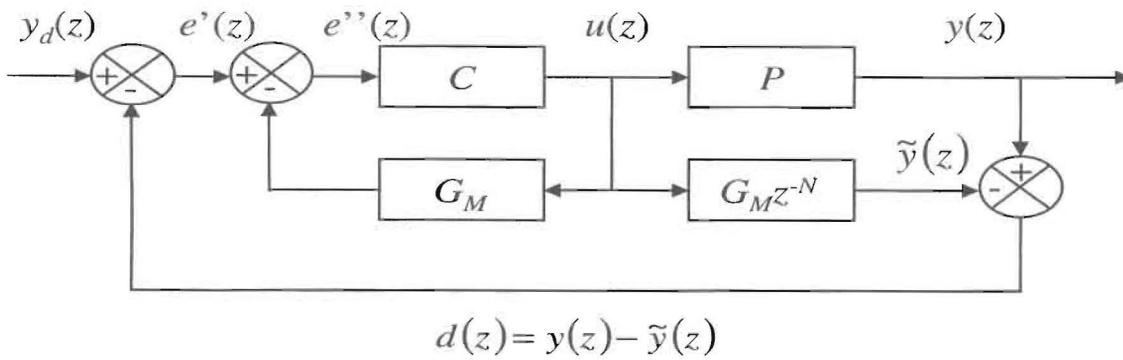


Figura 1. Predictor de Smith para el caso lineal.

P: Proceso con un tiempo muerto de N instantes de muestreo. $G_M z^{-N}$: Modelo del proceso con tiempo muerto igual a -NT. G_M : Modelo realizable del proceso (sin tiempo muerto).
C: Controlador entonado usando el modelo realizable del proceso.

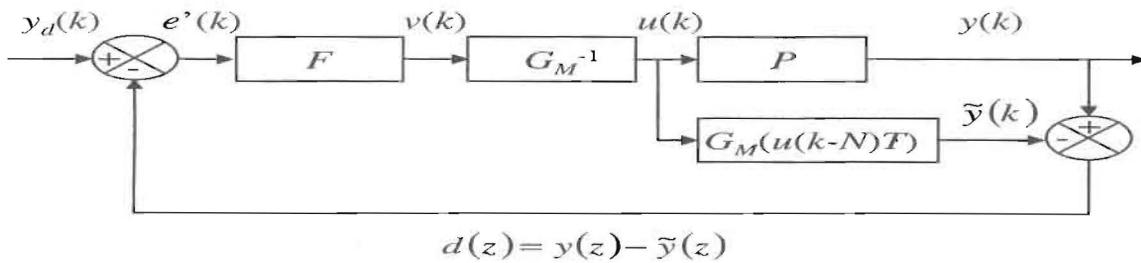


Figura 2. Lazo control con controlador IMC.

versa del proceso) y F es el filtro usado para aumentar la robustez del controlador. En general se utiliza $F = (1 - \alpha)z^{-1} / (1 - \alpha z^{-1})$.

Bajo la suposición de que se tiene que $G_M^{-1} G_M(u(k - N)T)$ es la transformación identidad retrasada N instantes de muestreo (inversa exacta del modelo), la entrada $v(k)$ al controlador G_M^{-1} (modelo neuronal de la inversa del proceso sin tiempo muerto) debería ser igual a la salida del modelo G_M en el tiempo $k + N + 1$. Por lo tanto se tiene, para el controlador perfecto que:

$$e(z) = yd(z) - (y(z) - v(z))z^{-N-1} = \frac{1 - \alpha z^{-1}}{(1 - \alpha)z^{-1}} v(z) \quad (6)$$

recordando que para Dahlin $e(z) = yd(z) - y(z)$, y operando algebraicamente:

$$\frac{v(z)}{e(z)} = \frac{1 - \alpha z^{-1}}{1 - \alpha z^{-1} - (1 - \alpha)z^{-N-1}} \quad (7)$$

y esta expresión es la correspondiente al controlador propuesto con la relación dada por el controlador de Dahlin.

Las redes neuronales utilizadas en los controladores IMC, en general son modelos aproximados, y la combinación de las transformaciones representadas por el controlador y el modelo del proceso no es una transformación unitaria ni aun en el estado estacionario [2]. Esto hace que existan errores (*offsets*) en el estado estacionario y que sea necesario usar técnicas *ad-hoc* para eliminarlos.

Modelos del controlador

El controlador neuronal más conocido y utilizado en las aplicaciones reportadas en la literatura, usa una red neuronal entrenada fuera de línea que aproxima la dinámica de la inversa del proceso [4-5].

En el controlador propuesto en este trabajo, las acciones de control se calculan en cada instante de muestreo en forma indirecta, invirtiendo numéricamente (en línea) la red neuronal que describe la dinámica directa del proceso (funcional no afín entre la variable controlada y manipulada) [2].

Esta inversión se realiza minimizando el cuadrado de la diferencia entre el valor deseado y

la salida de la red neuronal de la dinámica directa con respecto a la acción de control a aplicar. Debido a que la red neuronal que modela la dinámica del proceso contiene implícitamente el Jacobiano del modelo y por lo tanto la derivada de la salida de la red con respecto a sus entradas, esta minimización es relativamente sencilla.

Suponiendo que el vector regresor para la construcción de un modelo tipo NARX es de la forma:

$$I = [y(k), y(k-1) \dots y(k-m+1), u(k-N), u(k-N-1), \dots, u(k-N-n+1)] \quad (8)$$

Entonces, la red neuronal que representa una transformación no lineal F^* entre el vector regresor de entrada dado por la ecuación (8) y la salida estimada en el próximo intervalo de muestreo es:

$$\tilde{y}(k+N+1) = F^* [y(k+N), y(k+N-1), \dots, y(k+N-m+1), u(k), u(k-1), \dots, u(k-n+1)] \quad (9)$$

Si en el modelo se utilizan las salidas pasadas estimadas se tiene:

$$\tilde{y}(k+N+1) = F^* [\tilde{y}(k+N), \tilde{y}(k+N-1), \dots, \tilde{y}(k+N-m+1), u(k), u(k-1), \dots, u(k-n+1)] \quad (10)$$

La inversa por la derecha del operador G_M (red neuronal de la dinámica del proceso) se obtendría despejando de (10) el valor presente de $u(k)$ en cada tiempo de muestreo. Puesto que el valor futuro $y^*(k+N+1)$ no se conoce, el controlador no lineal C , implementado en este trabajo, se diseña remplazando en (10) los valores predichos en el modelo por las salidas presente y pasadas del operador E , obteniéndose:

$$v(k) = F^* [v(k-1), v(k-2) \dots v(k-m+1), u(k), u(k-1) \dots u(k-n+1)] = F^*(u(k)) \quad (11)$$

Resolviendo (11) para determinar $u(k)$, si este es único y el modelo es perfecto, se tiene:

$$\tilde{y}(k+N+1) = v(k) \quad (12)$$

Puesto que la ecuación (11) depende de una sola variable desconocida, el problema se reduce a resolver la siguiente ecuación:

$$F^*(u(k)) - v(k) = 0 \quad (13)$$

Existen varios métodos para resolver numéricamente en línea este problema. Siendo el único requisito para su inclusión en el algoritmo del controlador, que su tiempo de ejecución sea menor que el tiempo de muestreo del lazo de control. Los algoritmos considerados en este trabajo fueron el método de minimización cuadrática reformulando el problema como un problema de optimización no lineal sin restricciones:

$$\min_{u(k)} \{F^*(u(k)) - v(k)\}^2 \quad (14)$$

y los clásicos métodos de Newton y de bisección, que se aplican directamente a la ecuación (13) generando para el método de Newton una secuencia de entradas a través de la siguiente ecuación recursiva:

$$u(k)^{n+1} = u(k)^n - \frac{(F^*(v, u(k)) - v(k))}{\partial(F^*(v, u(k)) - v(k)) / \partial u(k)^n} \quad (15)$$

donde $u(k)^n$ es el valor de la variable manipulada para la n -ésima iteración en el tiempo k .

En la ecuación (15) se usa un factor de relajación y la búsqueda se terminaba cuando, luego de iteraciones sucesivas, el cambio en la solución estaba por debajo de un umbral especificado. En cada tiempo de muestreo, para iniciar el algoritmo se toma como valor inicial de $u(k)^0$ el valor de la variable manipulada obtenida en el tiempo anterior.

La solución de estas ecuaciones no siempre es una tarea fácil debido a que la inversa de la transformación representada por la red neuronal puede no existir. Como es bien conocido, pruebas teóricas para la invertibilidad existen solamente para un número limitado de funciones no lineales, además cuando la selección del punto inicial no es adecuada o en casos patológicos tales como problemas singulares con derivadas tendiendo a cero, puede suceder que el método no converja. Afortunadamente en los modelos de procesos industriales estos problemas no ocurren frecuentemente,

ya que las no linealidades presentes en ellos son generalmente la ganancia estática con pequeñas no linealidades monotónicas y tiempo muerto, con los cuales se obtienen buenos modelos neuronales si se toman las precauciones de utilizar sólo la parte realizable de los mismos.

Del estudio numérico comparativo de estos métodos se encontró que el de bisección es el más rápido para nuestra aplicación y la exactitud es aceptable, siendo su tiempo promedio de ejecución 20 ms, para el computador personal y la topología de la red usada.

Para garantizar la estabilidad del lazo de control, es indispensable que en los controladores considerados se utilicen como entradas a la red neuronal inversa los valores presente y pasados de $v(k)$, la salida del operador E , en lugar de la variable controlada. Esto se debe a que la combinación de las transformaciones del controlador y el proceso nunca son unitarias en estado estacionario, (es decir el controlador no invierte exactamente la ganancia del proceso) y por tanto es imposible satisfacer la condición de que $v(k) = yd$ y por la presencia de la acción integradora en el sistema la acción de control crecería indefinidamente y el lazo sería inestable, $[G_M^{-1}][P] \neq 1$.

Identificación de parámetros de modelos neuronales

La identificación de los parámetros de los modelos neuronales directos e inversos, utilizando datos experimentales de entrada-salida, se realiza mediante regresión lineal o no lineal (entrenamiento). Los datos para el entrenamiento y la validación del modelo generalmente se obtienen mediante una de las siguientes formas:

En lazo cerrado, introduciendo variaciones en el valor deseado y observando la salida del proceso. Con los datos así obtenidos se identifica un modelo en lazo cerrado, luego bajo la suposición de que se conoce el modelo del controlador se obtiene un modelo para el proceso [12].

En lazo abierto, introduciendo variaciones en la entrada al proceso (variable manipulada) y observando la salida del proceso. Con datos obtenidos se identifica directamente el modelo directo. De las dos formas la última es la más ventajosa pues en la práctica es a menudo difícil tener un modelo exacto del controlador.

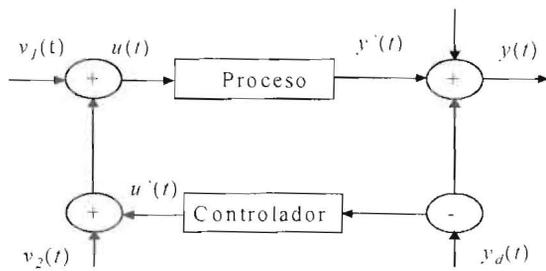


Figura 3. Típico lazo de control.

Debido a limitaciones operacionales, en las aplicaciones prácticas, los datos de entrada y salida del proceso generalmente se obtiene en condiciones de lazo cerrado. El mayor problema en usar identificación en lazo cerrado es que el modelo del proceso puede estar influenciado por el modelo del controlador, y en casos extremos puede llegar a ser simplemente la inversa negativa del mismo. Muchas discusiones existen en la literatura sobre las dificultades asociadas con la identificación en lazo cerrado [8-11]. La mayoría de estos trabajos se limitan a estudiar la identificación con modelos lineales y utilizando simulaciones digitales.

Identificación del modelo del proceso bajo condiciones de lazo cerrado

El flujo de información en un típico lazo de control se muestra en la Figura 3, donde u es la entrada al proceso, u' es la salida del controlador y' es la salida del proceso, y es la variable medida del proceso, $w(t)$ es el ruido en el camino directo, $y_d(t)$ es la señal de valor deseado al proceso, $v_2(t)$ es una entrada externa y $v_1(t)$ es el ruido en la realimentación. En este esquema las variables que están disponibles para identificar al proceso son la entrada u y la salida y medida del mismo.

En condiciones de lazo cerrado, las excitaciones que se introducen al lazo de control pueden ser, cambios en el valor deseado, o una perturbación (medida o no medida) al proceso. La entrada al proceso u no puede ser usada como excitación, como en el caso de identificación en lazo abierto, porque esta afectada por la salida del controlador y las entradas externas al lazo de control.

Al realizar identificaciones directas en lazo cerrado, se debe tener especial cuidado en garantizar que el proceso P sea identificable bajo una estructura de modelo, condiciones experimentales dadas y un método de identificación especifi-

co. La identificabilidad implica que el modelo identificado tiende a representar al proceso verdadero con probabilidad 1 a medida que la cantidad de datos experimentales tiende a infinito. Las condiciones de identificabilidad en lazo cerrado han sido estudiadas extensamente en [8-9], donde se presentan resultados para sistemas multivariados lineales. Para el caso de sistemas lineales de una entrada-una salida con una estructura del modelo de predicción como la usada en este trabajo, se pueden particularizar estos resultados obteniéndose las siguientes condiciones necesarias y suficientes para garantizar identificabilidad:

- Existencia de un tiempo muerto de por lo menos un tiempo de muestreo (en la práctica esta situación se cumple siempre por la presencia del retenedor).
- Estabilidad asintótica del lazo cerrado.
- Uso del valor deseado como variable de perturbación, persistentemente excitatriz y no correlacionado con la perturbación hacia delante $w(t)$.
- Uso de un controlador P, PI o PID.

En la práctica, una señal persistentemente excitatriz significa que la señal de excitación debe poseer una banda de frecuencias considerablemente ancha. Este tipo de señales se puede lograr en la práctica con frecuentes cambios escalón en la señal excitación.

De las condiciones de identificabilidad se puede observar que ninguna de ellas involucra la naturaleza del proceso. Esto significa que aun cuando el proceso es no lineal, los datos de entrada salida obtenidos en lazo cerrado proveen información apropiada acerca de la relación causal entre entradas y salidas del proceso no lineal. Por lo tanto si se puede encontrar un modelo predictivo no lineal que es apropiado para ajustar un proceso (por ejemplo redes neuronales), se tiene que los datos obtenidos en lazo cerrado representaran la relación causal entrada-salida para el proceso.

Para procesos no lineales, además de cumplir las condiciones de identificabilidad, es necesario considerar la región de operación, porque con un modelo empírico la extrapolación es incierta, y es de esperar que el modelo identificado sea válido sólo en el rango de operación para el cual los datos en lazo cerrado fueron obtenidos. Para

estos casos es conveniente introducir cambios en el valor deseado de forma de obtener para el modelo un rango de validez suficientemente amplio.

En la identificación en lazo cerrado el entonamiento del controlador gobierna el rango de la variable manipulada, la velocidad de cambio, las características de frecuencia, etc., que a su vez afectaran los resultados de la identificación. Por ejemplo si el entonamiento da un controlador muy sensible, entonces para un error de una cierta magnitud, la señal de control mostrará una variación más grande y un cambio más rápido (alta frecuencia) que la que se obtiene con un controlador entonado en forma más conservadora. En este caso el modelo identificado representara mejor al proceso para frecuencias altas y en un rango más amplio. Algunos autores sugieren que para identificación, el controlador no deber ser ni muy sensible ni muy lento, y para lograr esto en el entonamiento, la velocidad de respuesta del lazo cerrado debe ser igual a la velocidad de respuesta en lazo abierto.

Estudio Experimental

En el estudio experimental de la identificación de un proceso no lineal y su control mediante los algoritmos propuestos se utilizó un banco de pruebas para calibración de medidores de flujo y válvulas mostrado en la Figura 4. El arreglo de tuberías y válvulas permite variar y controlar presiones y caudales en el proceso. Las válvulas VM1 y VM2 son manuales, mientras que la CV1 y

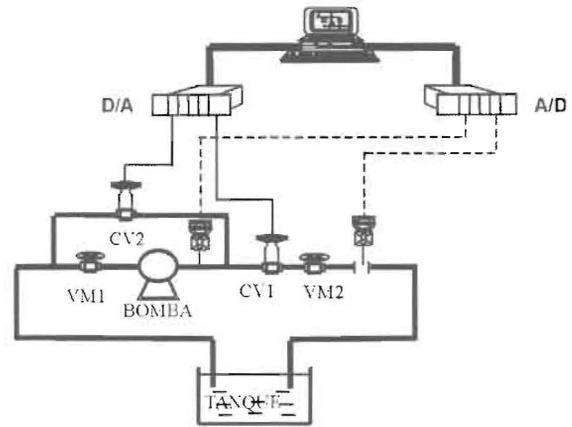


Figura 4. Esquema del banco de calibración.

CV2 son válvulas de control neumáticas. Los algoritmos propuestos se utilizaron para controlar el flujo de agua en el sistema, midiendo el caudal con una placa orificio y una celda de medición de presión diferencial y utilizando la válvula de neumática CV1 para su control.

Los algoritmos de control se implementaron digitalmente usando una computadora personal y tarjetas de entrada (A/D) OMEGA DAS-8PGA, y de salida (D/A) OMEGA DDA-06. El tiempo de muestreo utilizado en todos los experimentos fue de 0.1 segundos.

En este equipo es posible, mediante variaciones de la posición de la válvula manual VM2 variar la ganancia del proceso que relaciona la señal a la válvula de control y el caudal medido. La Figura 5a, muestra las relaciones de caudal con posición del vástago de la válvula para distintas

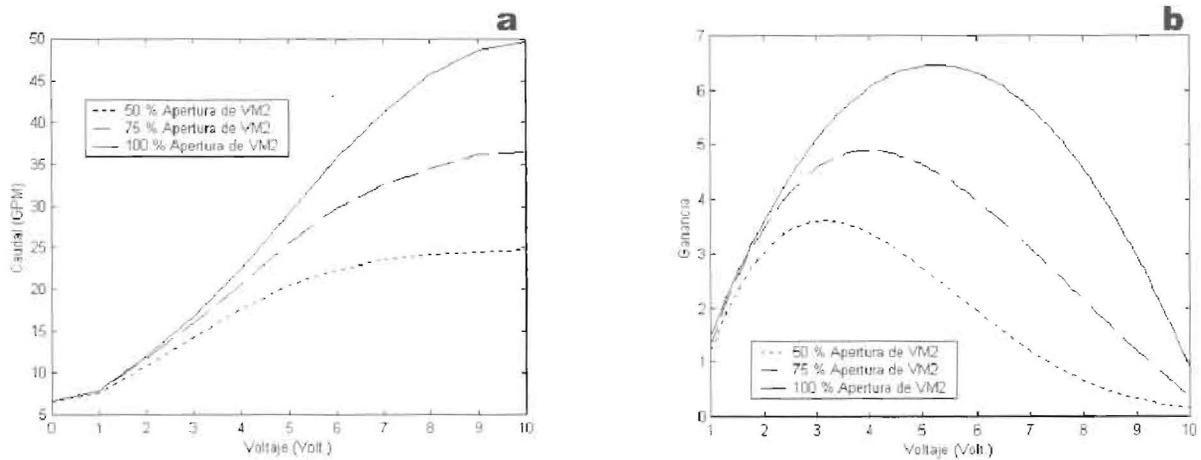


Figura 5. Características de la válvula CV1 para diferentes porcentajes de apertura de la VM2. (a) Curva instalada de la válvula CV1. (b) Variación de la ganancia estática.

aperturas de VM2. Mediante cambios en la posición de esta válvula se pueden introducir perturbaciones interesantes para estudiar el comportamiento de los controladores. La Figura 5b muestra las variaciones de la ganancia del proceso para distintos puntos de operación del equipo. Estos cambios significativos en los valores de la ganancia, como se verá más adelante desmejoran considerablemente el comportamiento de los controladores lineales.

Para realizar el estudio experimental de los controladores, se fijó un punto de operación para el equipo que permitiera introducir perturbaciones y cambios en el valor deseado en zonas de alta no linealidad sin saturar las válvulas. De las curvas obtenidas de la CV1 se observa que el máximo caudal para un 75% de apertura de la válvula VM2 es 36 GPM, tomando como valor de operación, el punto medio de éste, 18 GPM, se obtiene una zona donde la ganancia es alta, mientras que en los extremos (caudal mínimo y máximo), la ganancia es considerablemente menor.

Modelado del proceso

Inicialmente se observaron las respuestas del sistema a cambios en escalón de la válvula CV1 en distintas zonas de operación. Esto permitió determinar la presencia de un tiempo muerto aproximadamente constante en todo el rango de trabajo, mientras que la ganancia estática y el comportamiento dinámico variaban considerablemente evidenciando un alto grado de no linealidad.

Para obtener los datos de entrenamiento y validación de los modelos del proceso, se generó

una secuencia de pulsos en el valor deseado con amplitudes aleatorias en el intervalo entre 10 a 33 GPM. La duración de los cambios del valor deseado, se seleccionó de tal manera que permitiera que el proceso se estabilizara luego de aplicado el pulso. Los datos generados tiene un total de 1836 puntos, con un tiempo de muestreo de 0.1 segundos

En este trabajo y para propósitos de comparación se identificó el proceso (dinámica inversa y directa) usando primero un modelo paramétrico lineal ARX, y luego redes neuronales.

Para el caso del modelo lineal ARX se identificó primero la dinámica directa y con un simple despeje matemático se obtuvo la ecuación que rige la dinámica inversa del proceso. Para el caso de los modelos no lineales, se entrenaron las redes que modelan la dinámica inversa y directa del proceso, eliminando primero el tiempo muerto de los datos de entrenamiento mediante un corrimiento de la señal de salida tantos tiempos de muestreo como retrasos presentes en el sistema.

Modelo neuronal de la dinámica del proceso

Luego de varias pruebas con diferentes arquitecturas de redes, variando el número de neuronas en la capa de entrada y la capa oculta, se determinó que la red neuronal con tres entradas, el caudal presente y el obtenido en el tiempo de muestreo anterior y una señal de control, y tres neuronas ocultas modelaba satisfactoriamente al proceso. Como se muestra en las Figuras 6 a y b el ajuste del modelo a los datos experimentales

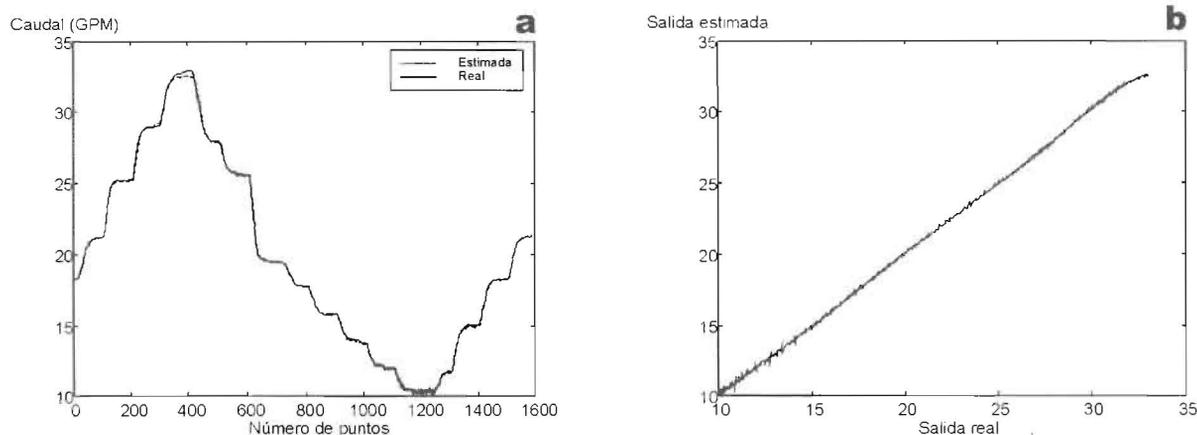


Figura 6. Validación del modelo neuronal directo.

de validación es satisfactorio en todo rango de operación.

Modelo neuronal de la inversa realizable del proceso

De igual manera se procedió para la obtención del modelo neuronal de la dinámica inversa del proceso, obteniéndose que la arquitectura con menor número de neuronas que aproxima mejor es de 3 entradas (todas de caudal), 3 ocultas y una salida. Los resultados se observan en la Figura. 7 Como puede observarse de las figuras, el ajuste del modelo a los datos experimentales de validación es razonablemente bueno. La salida del modelo sigue a las tendencias de los datos de validación con bastante precisión. El ruido su-

perpuesto no afectará mayormente el comportamiento del lazo de control debido a la acción de filtrado que sobre la señal de salida del computador ejercerán la válvula de control y el convertidor de voltaje a presión usado.

Modelo ARMA inverso

Para comparar el comportamiento de los controladores lineales y no lineales se obtuvo el modelo ARMA inverso invirtiendo algebraicamente el modelo directo y eliminando el tiempo muerto para hacer al modelo realizable.

Los resultados de la validación de modelo se muestran en la Figura 8. El modelo sigue la tendencia de los datos experimentales pero con grandes fluctuaciones.

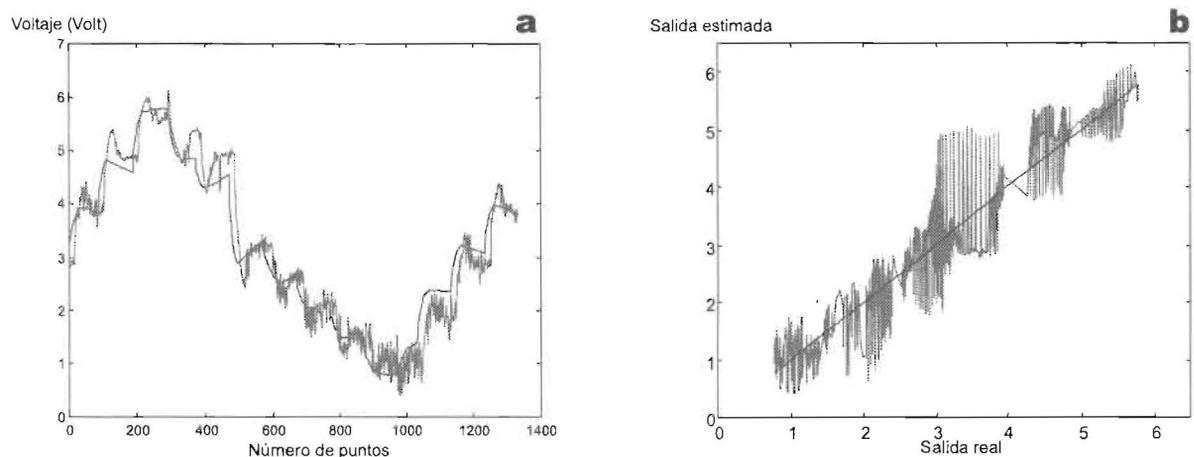


Figura 7. Validación del modelo neuronal inverso.

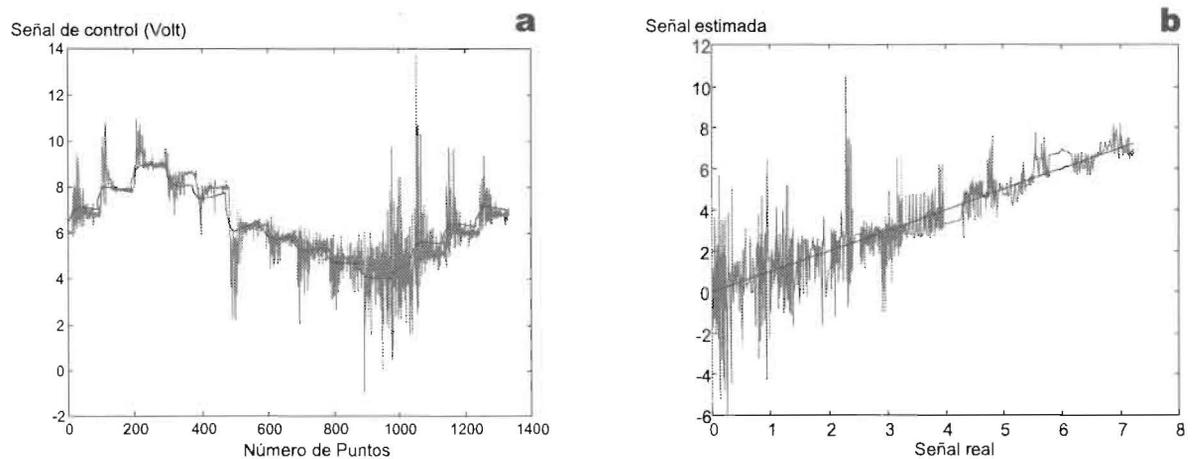


Figura 8. Validación del modelo lineal ARMA inverso.

Comportamiento de los Controladores

Para estudiar y comparar el desempeño de los controladores obtenidos se realizó con cada uno de ellos dos tipos de pruebas; variaciones en el valor deseado para conocer la velocidad de respuesta y el error obtenido, y aplicación de perturbaciones al proceso. La perturbación consistió en abrir rápidamente la válvula CV2 (Figura 5), con lo que se disminuye temporalmente el caudal en el proceso controlado, luego de esperar a que el lazo de control se estabilice, se cierra la CV2 para introducir una nueva perturbación en el sistema.

La Figura 9 muestra los resultados obtenidos, utilizando los controladores basados en la red neuronal inversa calculada y entrenada. Se

puede observar que el método basado en la inversa calculada en línea responde con menos oscilaciones, con mayor precisión y más rápido que el método directo, en especial en la zona de baja ganancia del proceso, valor deseado de 35 GPM.

Para tener una referencia del desempeño de los controladores basados en modelos neuronales, se compara ahora las respuestas obtenidas usando el controlador con la inversa calculada, el controlador lineal ARX y un controlador PI, entonado con el método relay [12]. La Figura 10 muestra las respuestas obtenidas. Se puede apreciar que los controladores basados en modelos, tanto el neuronal como el lineal, presentan un mejor desempeño que el controlador PI, en tanto que el controlador basado en las redes es más rápido, alcanzando el valor deseado en un tiempo menor que el controlador basado en modelos ARX.

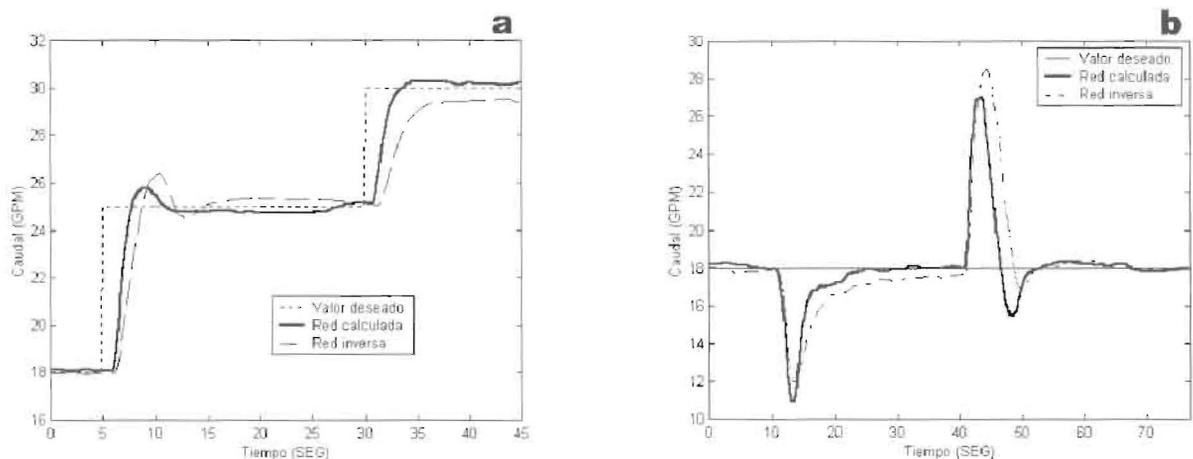


Figura 9. Respuesta del controlador con modelos neuronales inverso entrenado y calculado: (a) cambios en el valor deseado y (b) perturbaciones.

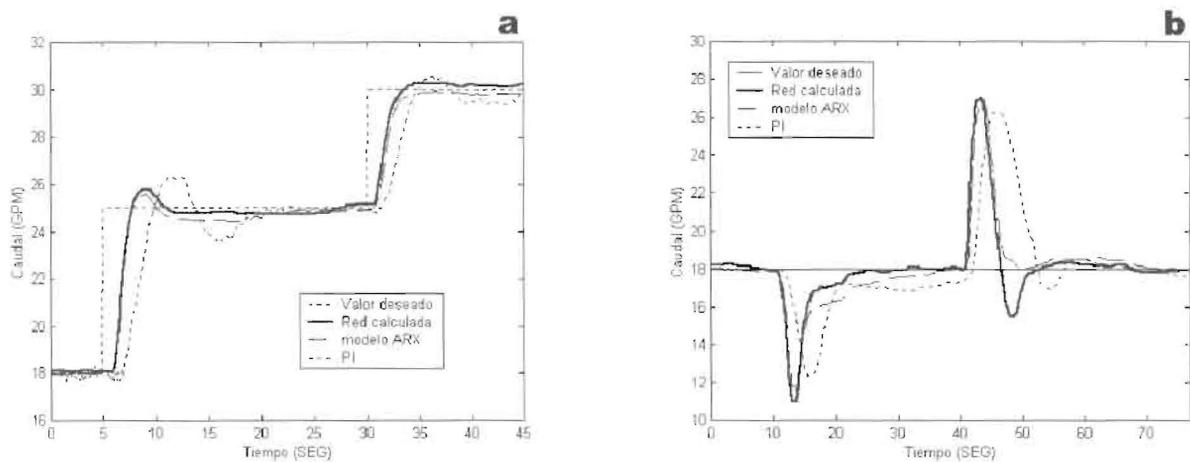


Figura 10. (a) Respuesta ante cambios en el valor deseado y (b) su señal de control.

Conclusiones

Los resultados experimentales obtenidos demostraron que el controlador propuesto opera adecuadamente en el control de un proceso no-lineal con tiempo muerto, tanto para cambios en el valor deseado como ante la presencia de perturbaciones. Este estudio experimental permitió además comprobar las ventajas y desventajas de usar red neuronal inversa entrenada fuera de línea o calculada en línea. La ventaja principal de la primera es que se puede calcular la acción de control rápidamente. Sin embargo el entrenamiento de la red inversa no es una tarea fácil. Muy frecuentemente se presentan problemas que resultan en un aprendizaje incorrecto de la red, en especial cuando el operador directo (red neuronal que modela al proceso directo o el proceso real) no es invertible. Además como el entrenamiento de la red inversa se realiza generalmente con datos obtenidos para el entrenamiento de la red directa, esta no presenta la información adecuada para modelar la dinámica inversa. Otra desventaja que presenta el método directo es que en él no se pueden incorporar restricciones. El control indirecto, por otro lado, si tiene la flexibilidad de poder incorporar las restricciones de una manera natural, mejorando de esta manera su comportamiento.

La única desventaja relativa de los controladores indirectos es la necesidad de realizar los cálculos de las acciones de control en línea. En este trabajo se ha comprobado que con una subrutina optimizada para resolver la ecuación no lineal que representa la salida de control, el tiempo de cálculo es una fracción pequeña del tiempo de muestreo, y por lo tanto la desventaja no es severa.

En general los resultados experimentales obtenidos en este trabajo demuestran que el control indirecto supera al control directo en su comportamiento dinámico, aun cuando ambos controladores eliminan el error, y sus comportamientos son superiores a los obtenidos utilizando modelos lineales.

Referencias Bibliográficas

1. Nahas E. "Nonlinear Internal Model Control strategy for Neuronal Network Models" Computers Chem. Eng. Vol. 16 N° 12 pp 1039-1057, 1992.
2. Ungar L. "Direct and Indirect Model based Control using Artificial Neuronal Networks" Ind. Ng. Cchem. Res. 30, 2564-2573, 1991.
3. Abi Assali W. "Estrategias de Control basadas en redes neuronales". MSc Thesis. Dpt. Automatica. Zulia University. Venezuela.
4. Hunt K., Sbarbo D. "Neuronal Networks for Control Systems-A survey" Automatica, Vol 28, N° 6, pp 1083,1112 (1992).
5. Morari M. "Internal Model Control 1". Ind. Eng. Chem. Process Des. Dev. 21, pp 308-323. 1982.
6. Smith C. "Digital Computer Process Control". Intext Educational Publisers. Chemical Engineering Series. 1972.
7. Bahill T. "A simple adaptive Smith-Predictor for controlling time-delay systems". Control Syst. Mag. Vol 4, N° 5, pp 16-22 (1983).
8. Gustavsson I, Ljung L., Soderstrom T. "Identification of processes in closed loop. Identifiability and accuracy aspects" Automatica 13, 59-67. (1997).
9. Ljung L. "System identification- theory for the user" Prentice Hall. Englewood Cliffs, NJ(1987).
10. Bridges, B. *et al* "Least-square identification of fixed multivariable processes operating in closed loop". Proceeding of International Conference on Control 88. pp 122-127. Oxford, UK.
11. Low T., Lee.H., Lim K. "A methodology for neural network training and control of drives with nonlinearities" IEEE Trans. Ind. Electron.Vol.40, N° 2, pp243-249,1993.
12. Cheng Y., Karjala T. Himmelblau D. "Resolving problems in closed loop nolinear process identification using IRN" Computers chem. Engng. Vol. 20, N° 10,1159-1176. (1996).
13. Astrom K. J.; Hagglund, T. "Automatic Tuning of Simple Regulators with Specifications on Phase and Amplitud margins" Automática 1984, 20, 645-651.

Recibido el 7 de Junio de 1999

En forma revisada el 15 de Enero de 2001