

CONTROL PREDICTIVO GENERALIZADO PARA SISTEMAS NO LINEALES UTILIZANDO UNA NEURONA DIFUSA RECURRENTE

EDMARY ALTAMIRANDA*
1 ELIEZER COLINA

**Facultad de Ingenierías y Arquitectura, Universidad de Pamplona,*
EDMARYA@UNIPAMPLONA.EDU.CO,
PAMPLONA – COLOMBIA

*** Facultad de Ingeniería, Departamento de Sistemas de Control,*
Universidad de Los Andes
ecolina@ula.ve
Mérida – Venezuela

1. ABSTRACT:

Se propone el diseño de un controlador predictivo generalizado, basado en un modelo en línea, construido por medio de una neurona difusa recurrente, que provee de una aproximación lineal del proceso a ser controlado. La efectividad del esquema de control es ilustrada por medio de simulaciones computacionales.

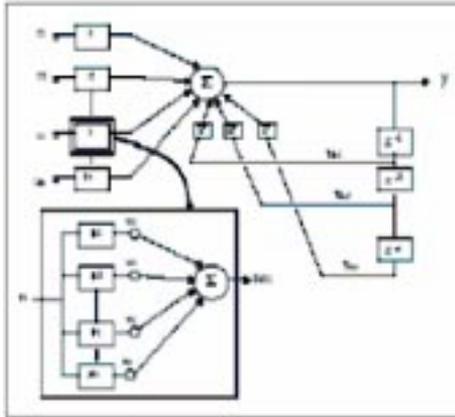
KEYWORDS:

Sistemas Difusos, Dinámicas Neuronales, Control de Sistemas No Lineales

El control predictivo constituye un amplio campo de métodos de control que está relacionado con varias disciplinas como el control óptimo, el control estocástico, el control de procesos con tiempo muerto, el control multivariable y el control con restricciones (Prett, et. al, 1989; Camacho, 1993; Charos, 1990; Cutler y Finlayson, 1988; Kraus y Rake, 1995). El Control Predictivo

Generalizado (CPG) es uno de los métodos de control que posee un largo rango de predicción en el cual, dada una señal futura de referencia, se genera un conjunto de predicciones de la salida del sistema, que es ajustado basado en las entradas futuras de control (Mohtadi, et. al, 1987). El enfoque de CPG proporciona controladores robustos que pueden ser utilizados para controlar sistemas de fase no mínima, sistemas (Clarke, 1988; Lim y Ling, 1989) Algunas veces, la aplicación del enfoque de CPG para sistemas no lineales resulta restringida debido a la dificultad para encontrar modelos lineales apropiados para el proceso.

Este trabajo propone el diseño de controladores predictivos generalizados para sistemas no lineales, usando modelos basados en una estructura llamada la neurona difusa recurrente (Altamiranda y Colina, 2002); a partir de la cual se obtiene, en línea una aproximación lineal del sistema.



$$y(k) = \sum_{i=1}^m f_i(u_i(k)) + \sum_{r=1}^P \tilde{f}_r(e(k-r))$$

$$E(k) = \frac{1}{2P} \sum_{r=1}^P e_q^2(k) \dots\dots\dots(2)$$

$$\Delta w_{r,j}(k) = -\alpha \sum_{q=1}^P e_q(k) \mu_{r,j}(w_{r,j}(k)) \quad (3)$$

de salida de la neurona difusa en el tiempo “k-r”. El valor de “P” deber ser a lo sumo igual al orden dinámico estimado del sistema.

Las potencialidades de este esquema de control, son demostradas a través de resultados de simulación.

2. ESTRUCTURA DE LA NEURONA DIFUSA RECURRENTE

La Neurona Difusa Recurrente (NDR) es una estructura que incorpora conexiones recurrentes al modelo propuesto originalmente por Yamakawa (Yamakawa, 1994). Éstas conexiones recurrentes proveen a la neurona difusa de características dinámicas; que la hacen ser una excelente candidata para el modelado en línea de sistemas no lineales tipo MISO y SISO. La estructura de la neurona difusa recurrente se ilustra en la figura 1, (Altamiranda y colina, 2002). Tanto las conexiones de alimentación directa “if”, como las de retroalimentación “rf~” poseen pesos sinápticos determinados por reglas difusas del tipo Si-Entonces

donde “(k) ui”, i = 1,2, ...,m corresponde a la iésima entrada directa en el tiempo “k”, mientras que “e(k-r)”, r = 1,2,.....,l, es un término de retroalimentación relativo al error

$$\Delta \tilde{w}_{r,j}(k) = \Delta_1 \tilde{w}_{r,j} + \Delta_2 \tilde{w}_{r,j}$$

$$\Delta_1 \tilde{w}_{r,j}(k) = -\alpha \sum_{q=1}^P e_q(k) \hat{\mu}_{r,j}(e_q(k-r)) \quad (4)$$

$$\Delta_2 \tilde{w}_{r,j}(k) = -\alpha \sum_{q=1}^P e_q(k) \left[\frac{\partial y_q(k)}{\partial e_q(k-r)} \right] z_q^r(k)$$

La caracterización difusa de las entradas directas y de retroalimentación se hace considerando funciones de membresía triangulares, complementarias entre sí

$$\frac{\partial y_q(k)}{\partial e_q(k-r)} = \tilde{w}_{r,j}(k) \hat{\mu}_{r,j}(e_q(k-r)) + \tilde{w}_{r,j+1}(k) \hat{\mu}_{r,j+1}(e_q(k-r)) \quad (5)$$

$$z_q^r(k) = \frac{\partial e_q(k-r)}{\partial e_q(k-r-1)} z_q^r(k-1) + \frac{\partial e_q(k-r)}{\partial \tilde{w}_{r,j}(k)} z_q^r(k) z_q^r(k) = [\tilde{w}_{r,j}(k-1) \hat{\mu}_{r,j}(e_q(k-r-1)) + \tilde{w}_{r,j+1}(k-1) \hat{\mu}_{r,j+1}(e_q(k-r-1))] z_q^r(k-1) + \hat{\mu}_{r,j}(e_q(k-r)) \quad (6)$$

(Yamakawa, 1994). Adicionalmente, el algoritmo de entrenamiento para adaptar los

$$y^d(k) = F(y^d(k-1), \dots, y^d(k-n)) + G(u(k-1), \dots, u(k-m)) \quad (7)$$

$$y(k) = \sum_{i=1}^n \hat{f}_i(u(k-i)) + \sum_{s=1}^m \hat{f}_s(y^d(k-s)) + \sum_{r=1}^l \tilde{f}_r(e(k-r)) \quad (8)$$

pesos sinápticos está basado en el conocido método del gradiente descendente instantáneo, sobre una superficie cuadrática definida como:

Donde P es el número de patrones que se consideran por instante de tiempo y $y = (y(k) - y_d(k))$, $y_d(k)$ es el valor deseado. La aplicación del método del gradiente descendente sobre las sinapsis directas y de retroalimentación produce ecuaciones particulares para cada tipo de sinapsis. El algoritmo de Entrenamiento para los pesos de esta estructura NDR está dado por Altamiranda y Colina, 2002):

para las conexiones de alimentación adelantada y donde j_i, m y $j_r, \sim m$, corresponden a las funciones de membresía asociadas a los pesos $j_i W$, y $j_r W$, respectivamente.

En general, para un sistema no lineal SISO del tipo donde “y” y “u” corresponden a las señales de salida y entrada, respectivamente. El modelo que proporcionaría la neurona difusa recurrente sería de la forma

3. CONTROL PREDITIVO GENERALIZADO UTILIZANDO LA NDR

El CPG es un método predictivo de largo rango que permite anticipar la salida del sistema sobre un horizonte de tiempo mayor que el máximo retardo posible del sistema. La predicción producida depende tanto de valores pasados como futuros de las señales actuales de control. Ya que las señales actuantes futuras no son conocidas, el método hace consideraciones aceptables sobre sus valores [Mohtadi y Clarke, 1987; Clarke 1988]. En el esquema de CPG propuesto en este trabajo, se emplea un modelo del proceso, sintetizado con una neurona difusa recurrente, para calcular un aproximación lineal de su dinámica

$$A(q^{-1})y^l(k) = B(q^{-1})u(k-1)q^{-d} + C(q^{-1})e(k) \quad (9)$$

donde

$$A(q^{-1})y(k) = 1 + \sum_{s=1}^n a_s q^{-s}; B(q^{-1}) = \sum_{i=1}^m b_i q^{-i}; \quad (10)$$

$$C(q^{-1}) = 1 + \sum_{r=1}^l c_r q^{-r}$$

en términos del siguiente modelo CARMA. donde $y_l(k)$ es la salida del modelo lineal. Dado que la neurona difusa recurrente proporciona un modelo como el descrito en la ecuación (8) y considerando que $= y(k) + e(k)$

Así, los parámetros del modelo CARMA

$$y_i^d(k) = \sum_{s=1}^m \left(\frac{\partial f_i}{\partial u(k-i)} \right) u(k-i) + \sum_{s=1}^p \left(\frac{\partial f_i}{\partial y^d(k-s)} \right) y^d(k-s) + \sum_{r=1}^l \left(\frac{\partial f_i}{\partial x(k-r)} \right) x(k-r) \quad (11)$$

A pueden se rexpresados como:

El esquema de CPG utiliza un algoritmo explícito en el cual los parámetros del proceso, luego de ser estimados, son empleados para calcular los parámetros del controlador. Dadas mediciones de la variable de salida hasta el tiempo “k” y cualquier “u(k+p)”, para p>1, el predictor óptimo de “p+d” pasos adelante,

$$A(q^{-1}) = 1 + \sum_{s=1}^m a_s q^{-s} = \sum_{s=1}^m \left(- \frac{\partial f_i}{\partial y^d(k-s)} \right) q^{-s} \quad (12)$$

$$B(q^{-1}) = \sum_{i=1}^m b_i q^{-i} = \sum_{i=1}^m \left(\frac{\partial f_i}{\partial u(k-i)} \right) q^{-i} \quad (13)$$

$$C(q^{-1}) = 1 + \sum_{r=1}^l c_r q^{-r} = 1 + \sum_{r=1}^l \left(\frac{\partial f_i}{\partial x(k-r)} \right) q^{-r} \quad (14)$$

usando la aproximación lineal, puede ser calculado en la forma siguiente:

El objetivo del controlador predictivo neralizado es el de forzar a las futuras salidas

seguir a las futuras consignas . La ley de control minimiza una función de costo cuadrática.

$$y_i^d(k+p+d/t) = G_{p+d}(q^{-1}) \Delta u(k+p-1) + F_{p+d}(q^{-1}) y_i^d(k) + D_{p+d}(q^{-1}) \Delta x(k) \quad (15)$$

donde

$$\begin{aligned} G_{p+d}(q^{-1}) &= E_{p+d}(q^{-1}) B(q^{-1}) \\ D_{p+d}(q^{-1}) &= E_{p+d}(q^{-1}) C(q^{-1}) \end{aligned} \quad (16)$$

$$E_{p+d}(q^{-1}) A \Delta + q^{-d} F_{p+d}(q^{-1}) = 1 \dots \quad (17)$$

$$\text{con } \Delta = 1 - q^{-1}$$

El conjunto de señales de control en tiempo presente y futuro que minimiza a $J(N)$ está dada por la ecuación matricial y la matriz G es triangular inferior de dimensión $M \times N$:

El primer elemento del vector de control u es $\Delta u(K)$, así que la señal de control actual $u(k)$ está dada por:

$$J(N) = E \left[\sum_{p=1}^N \left[y_i^d(k+p+d/t) - r(t+p+d) \right]^2 + \lambda \sum_{p=1}^N \left[\Delta u(t+p-1) \right]^2 \right] \quad (18)$$

4. EJEMPLO ILUSTRATIVO

Considere el siguiente sistema no lineal: La NDR utilizada para modelar este sistema SISO fue la siguiente:

La tasa de aprendizaje utilizada, $a=0.145$

$$\tilde{u} = (G^T G + \lambda I)^{-1} G^T (r - f) \dots\dots\dots (19)$$

$$\begin{aligned} \tilde{y} &= [y_r^d(k+d+1), \dots, y_r^d(k+d+N)]^T \\ \tilde{u} &= [\Delta u(k), \Delta u(k+1), \dots, \Delta u(k+N-1)]^T \\ f &= [F_{P,D} y_r^d(k) + R_{P,D} \Delta u(k-1) + T_{P,D} \Delta e(k)]^T \\ \tilde{r} &= [r(k+d+1), r(k+d+2), \dots, r(k+d+N)]^T \end{aligned} \quad (20)$$

fue

$$\begin{bmatrix} g_0 & 0 & \dots & 0 \\ g_1 & g_0 & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots \\ g_{N-1} & g_{N-2} & \dots & g_0 \end{bmatrix} \quad (21)$$

obtenida empíricamente. El número de patrones utilizados para cada instante de tiempo $P=1$. Las funciones de membresía

$$u(k) = u(k-1) + \tilde{g}^T (\tilde{r} - f) \quad (22)$$

utilizadas para las entradas y términos recurrentes se ilustran en la figuras 2 y 3
Los parámetros de diseño para el onrolador fueron $l=0.32$, $N=8$ para una señal de referencia Las Figuras 4 y 5 ilustran la eficiencia del esqua de control propuesto.

$$y^d = \frac{0.85y^d(k-1)y^d(k-2)+0.16u(k-4)+0.24u(k-5)}{1+y^d(k-1)} \quad (23)$$

$$\begin{aligned} y(k) &= \sum_{i=1}^5 f_i(u(k-i)) + \sum_{s=1}^5 \tilde{f}_s(y^d(k-s)) + \\ &\sum_{r=1}^5 \tilde{f}_r(e(k-r)) \end{aligned} \quad (24)$$

5. CONCLUSIÓN

Se ha presentado un esquema de control predictivo generalizado para sistemas no lineales utilizando una neurona difusa recurrente. La NDR es utilizada para calcular,

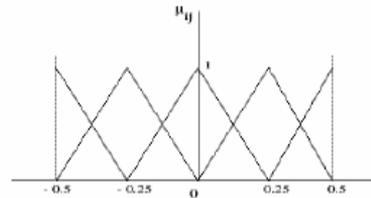


Figura 2. Funciones de Membresía para $u(k-i)$ y $d(k-s)$

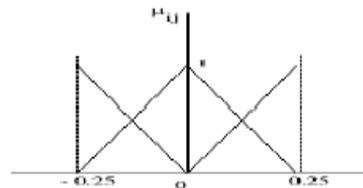


Figura 3. Funciones de membresía para $e(k-r)$

en línea, una aproximación lineal para la construcción de la ley de control. La eficiencia del esquema propuesto fue puesta en evidencia a través de resultados de simulación.

$$r(k) = 0.3 \sin\left(\frac{2\pi k}{50}\right)$$

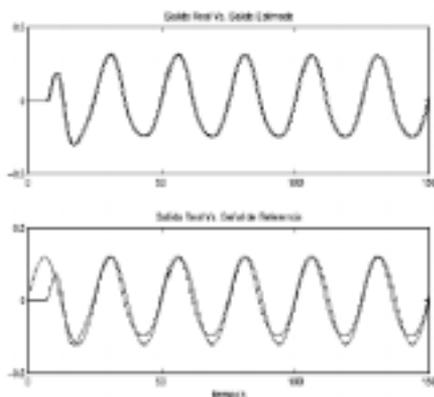


Figura 4. Salida Real, Salida Estimada y Señal de Referencia $r(k)=0.3\sin(2\pi k/50)$.

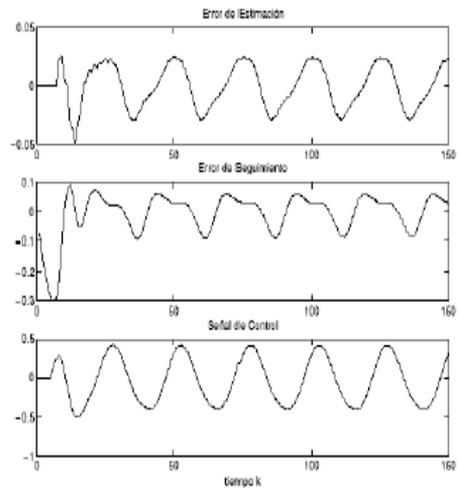


Figura 5. Error de Estimación, Error de Seguimiento y Señal de Control $u(k)$

REFERENCIAS BIBLIOGRÁFICAS

Altamiranda, E. and Colina, E. (2002). A current Fuzzy Neuron for On Line modelling of Nonlinear Systems, 15th Triennial IFAC World Congress, Barcelona, Spain, July.

Camacho, E.. (1993). Constrained generalized predictive control, IEEE Transactions on Automatic Control **38**(2), 327-332.

Charos, G. (1990). Model predictive constrained control: Development implementation and decentralization, Ph.D thesis, Georgia Institute of Technology.

Clarke, D. (1988). Applications of generalized predictive control in the industrial processes, IEEE Control Systems Magazine (1988), 49-55

Cutler, C. and Finlayson, G. (1988). Design considerations for a hydrocracker preflash column multivariable constraint controller,

Kraus, P. and Rake, H. (1995). Design for a multivariable predictive controller in state space, 3rd European Control Conference, Rome, September, pp.3579-3584.

Lim, K. and Ling, K. (1989). Generalized predictive control of a heat exchanger, IEEE Control Systems Magazine, 49-55.

Mohtadi, C., Clarke D., and Tuffs, P. (1987). Generalized predictive control part i. the basic algorithm, *Automática* **23**(2), 137-148

Prett, D., Gacía and Morari, M. (1989). Model Predictive control: theory and practice. A survey, *Automática* **25**(3), 335-348.

Yamakawa, T. (1994). A neo fuzzy neuron and its application to systems identification and prediction of chaotic behaviour, *Introduction to Artificial Neural Systems*, IEEE Press J.M.

Zurada, R.J. Marks and C.J. Robinson editors,
New York.