

Control Predictivo basado en Modelo Neuroborroso de un Autoclave Industrial

Juan Manuel Escaño (jmesca@cartuja.us.es), Carlos Bordons (bordons@cartuja.us.es)
Departamento de Ingeniería de Sistemas y Automática. Universidad de Sevilla

Míriam R. García (miriamr@iim.csic.es), Carlos Vilas (carlosvf@iim.csic.es), Antonio A. Alonso (antonio@iim.csic.es)
Grupo de Enxeñería de Procesos. IIM-CSIC

Resumen

En este artículo se presenta un modelo neuroborroso de la temperatura de un autoclave industrial, usado para estrategias basadas en Control Predictivo No-Lineal, permitiendo un bajo coste computacional, las cuales son aptas para implementarse en un autómata programable (PLC) de gama media, muy común en la industria. El modelo se ha validado con datos experimentales obtenidos en una planta real.

Palabras clave: Modelado Neuroborroso, Control Predictivo No-Lineal, IEC 1131-7

1 Introducción

En este trabajo se ha hecho un estudio y comparación de estrategias de control Predictivo basado en modelos neuroborrosos. Se intenta hacer una aportación al control predictivo basado en modelos no-lineales, pero enfocando el estudio en conseguir el menor coste computacional.

El control Predictivo se considera hoy en día una tecnología bien implantada en numerosos campos, sobre todo en procesos industriales. Ha demostrado su eficacia frente a otras estrategias durante las últimas décadas. En general, la mayoría de aplicaciones de control predictivo están basadas en modelos lineales de la planta, los cuales suelen presentar buenos resultados, sobre todo si se trabaja en el entorno de un punto de trabajo. No obstante, existen aplicaciones donde la región de trabajo es grande o se presenta un alto grado de “no-linealidad”. En esos casos el control predictivo no-lineal es una alternativa adecuada, aunque el problema de la aplicación del mismo reside en el alto coste computacional asociado.

Se presentan en este trabajo unas estrategias de control predictivo usando modelos no-lineales, las cuales, debido a su bajo coste computacional, son aptas para implementarse en un autómata programable (*Programmable Logic Controller*, PLC) de gama media, muy común en la industria. Además, teniendo en cuenta que las tecnologías borrosas están cada vez más incorporadas en este tipo de dispositivos -incluyéndose bibliotecas de

funciones específicas en ellos-, la programación y el ajuste de los controladores son fáciles de llevar a cabo.

La organización del resto del artículo es la siguiente. En la sección 2 se hace una introducción a los modelos neuroborrosos dinámicos, usados en este trabajo. En la sección 3 se describe el modelo neuroborroso obtenido para la temperatura del Autoclave. En la sección 4 se muestra el resultado de la actuación de un controlador basado en modelo lineal para la temperatura del autoclave. En la sección 5 se estudian dos estrategias de control predictivo basadas en modelos neuroborrosos y se comparan resultados con el controlador lineal. En la sección 6 se trata brevemente sobre la implementación práctica de las estrategias en autómatas programables industriales. Finalmente, las principales conclusiones de este trabajo se resumen en la sección 7.

2 Modelos Neuroborrosos Dinámicos

Las Redes de Neuronas Borrosas (*Fuzzy Neural Networks*, FNN) combinan la capacidad de manejo de incertidumbre en la información con la capacidad de aprendizaje. Cuando se usan neuronas recurrentes en una FNN tenemos los llamados RFNN (*Recurrent Fuzzy Neural Network*), los cuales han demostrado ser más adecuados para captar toda la dinámica de un sistema no-lineal. Son sistemas que poseen las mismas ventajas que las redes de neuronas recurrentes [8]. A las RFNN se les denominan también Sistemas borrosos dinámicos ó recurrentes (ver figura 1) y extiende el dominio de aplicación de las FNN a los problemas temporales. La recurrencia es debida a la realimentación de la salida para poder así captar la dinámica y el cambio. Estos sistemas presentan una dificultad: la propia estabilidad de los mismos una vez que están on-line. Los sistemas no-dinámicos no tienen este problema, debido a la respuesta instantánea y la *unidireccionalidad* de la información,[7],[9]. En el modelo borroso propuesto por Takagi-Sugeno (TS), la estructura del antecedente describe regiones borrosas en el es-




Figura 1: Sistema neuroborroso dinámico

pacio de entrada, y la del consecuente presenta funciones no borrosas de las entradas del modelo. Si usamos funciones recurrentes con una estructura NARMAX (*Non-linear Auto Regressive Moving Average with eXogenous input*), del tipo: $\hat{y}(k+1) = f(y(k), \dots, y(k-m), u(k), \dots, u(k-n))$, donde u, y son las entradas y salidas del sistema, podemos describir el sistema de la siguiente manera, para cada regla:

R_j :
IF $x_1(k)$ is F_{1j} , ..., and $x_n(k)$ is F_{nj} , THEN

$$y_j(k) = a_j(z^{-1})y(k-1) + b_j(z^{-1})u(k-d) + \xi(k) \quad (1)$$

Donde $a_j(z^{-1}) = a_{1j} + a_{2j}z^{-1} + \dots + a_{n_y j}z^{-(n_y-1)}$ y $b_j(z^{-1}) = b_{0j} + b_{1j}z^{-1} + b_{2j}z^{-2} + \dots + b_{n_u j}z^{-n_u}$

$X(k) = [x_1(k)x_2(k)\dots x_n(k)]^T$ es el vector de las entradas del sistema neuroborroso en el tiempo k , F_{ij} es el conjunto borroso correspondiente a $x_i(k)$ en la regla j , $y_j(k)$ es la salida del modelo correspondiente a la región de operación asociada a la regla. Si $\mu_{ij}(k)$ es el grado de pertenencia de $x_j(k)$ en el conjunto borroso F_{ij} y el número de implicaciones o reglas es L , el modelo completo RFNN se puede describir por

$$y(k) = \sum_{j=1}^L w_j(k) [a_j(z^{-1})y(k-1) + b_j(z^{-1})u(k-d)] + \xi(k) \quad (2)$$

Donde

$$w_j(k) = \frac{\bar{\mu}_j(k)}{\sum_{j=1}^L \bar{\mu}_j(k)}, \quad \bar{\mu}_j(k) = \prod_{i=1}^n \mu_{ij}(k)$$

3 Modelo Neuroborroso del autoclave

En la figura 2 se representa la unidad Autoclave perteneciente al IIM-CSIC (Vigo), la cual utiliza una corriente de entrada de vapor saturado para calentar un producto determinado, una entrada de agua a temperatura ambiente para enfriar y otra entrada de aire, empleada para evitar caídas

bruscas de presión que puedan dañar el envase durante la etapa de enfriamiento. Tiene, por tanto tres entradas (vapor saturado, agua y aire) y dos salidas (purga y drenaje). La retorta (retort) contiene el producto a esterilizar, normalmente consistirá en un número de latas con las mismas características (geometría, tamaño y tipo de alimento). Una vez dentro, la carga será sometida a un perfil de temperatura previamente diseñado para asegurar una “letalidad” determinada (parámetro relativo al grado de reducción de microorganismos patógenos) mientras se preserva, tanto como sea posible, la calidad del producto. El perfil de temperatura se consigue manipulando el caudal de vapor que entra, producido por una caldera.

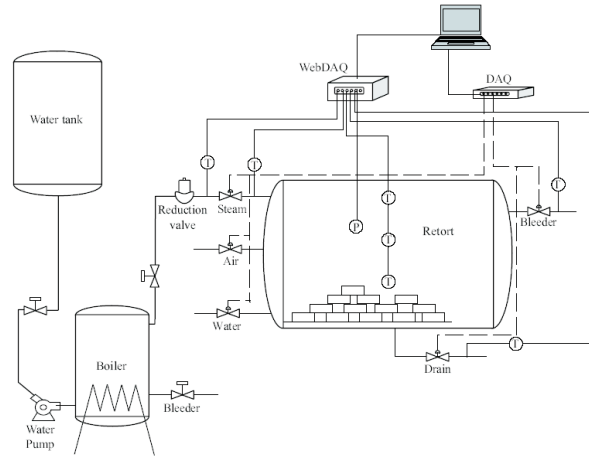


Figura 2: Esquema de prototipo de autoclave industrial [1]

El proceso de esterilización opera de manera semi-continua y su dinámica es extremadamente no lineal como se ve en [1]. Se ha realizado un modelo Neuroborroso que describe el comportamiento de la temperatura en la fase del calentamiento. Se han tomado datos reales de operación junto con datos provenientes de un modelo realizado en EcosimPro®. Como entradas se han elegido la apertura de la válvula del vapor (u_s), la temperatura del vapor (T_s), las aperturas de las válvulas de purga y drenaje (u_b, u_d) y las temperaturas del autoclave almacenadas de anteriores muestreos (T_{-2}, T_{-1}). Las funciones de pertenencia se muestran en la figura 3 y la base de reglas es:

- IF in1 IS mf1 AND in2 IS mf1 AND in3 IS mf1 AND in3 IS mf1 AND in4 IS mf1 AND in5 IS mf1 AND in6 IS mf1 THEN:
 $T = 0.385u_s - 0.141T_s + 0.0584u_b + 0.0875u_d + 0.125T_{-2} + 0.732T_{-1} + 0.116$

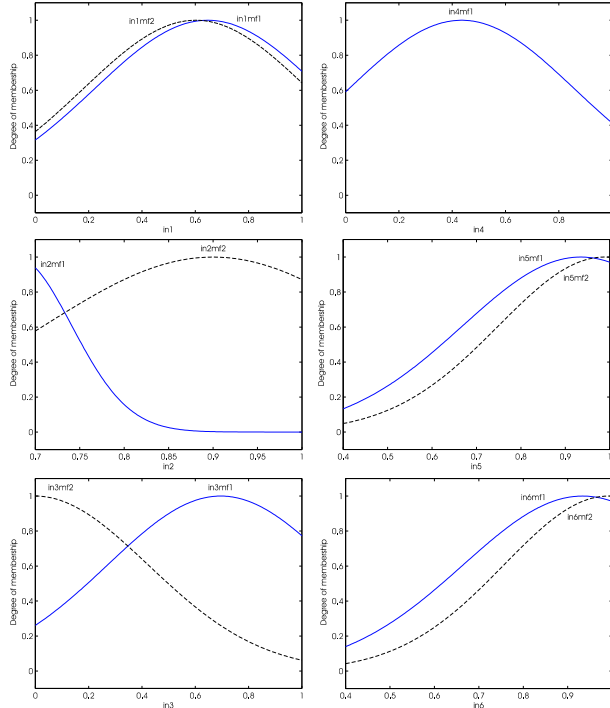


Figura 3: Funciones de Pertenencia para el modelo neuroborroso de Autoclave

- IF in1 IS mf2 AND in2 IS mf2 AND in3 IS mf2 AND in3 IS mf2 AND in4 IS mf1 AND in5 IS mf2 AND in6 IS mf2 THEN:
 $T = 0.0354u_s + 0.002T_s + 0.007u_b + 0.011u_d - 0.308T_{-2} + 1.272T_{-1} + 0.015$

En la figura 4 puede observarse la comparación entre el modelo y los datos de temperatura reales en el autoclave.

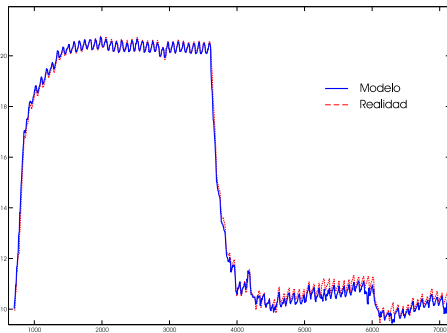


Figura 4: Validación del modelo neuroborroso del autoclave industrial

4 Control Predictivo Generalizado para el Autoclave

A partir de un modelo lineal de la planta y usando un horizonte de predicción y de control iguales:

$N_p = N_u = 4$ y el parámetro de ponderación de la acción de control $\lambda = 0.6$, se obtuvo un controlador GPC (*Generalized Predictive Controller*) con la siguiente ley:

$$u(k) = u(k-1) - 12.01y(k-1) + 21.68y(k-2) - 12.85y(k-3) + 2.30y(k-4) + 0.44w(k+1) + 0.27w(k+2) + 0.14w(k+3) + 0.04w(k+4) \quad (3)$$

Donde se ha usado una aproximación suave de la trayectoria de referencia futura con $\alpha = 0.7$:

$$w(t+k) = \alpha w(t+k-1) + (1-\alpha)r(t+k), k = 1, \dots, N_p \quad (4)$$

Se ha usado el modelo matemático realizado en EcosimPro[®] para simular resultados. El comportamiento de éste controlador se puede ver en la figura 5 Se puede apreciar que el controlador tiene un buen comportamiento en la zona donde el modelo lineal funciona bien, pero no es admisible, provocando una sobre-temperatura en otra zona. Además, puede observarse un comportamiento de




Figura 5: Resultado de la estrategia GPC

la acción de control indeseable en la zona del primer escalón. La válvula estaría oscilando para mantener el sistema en esa temperatura. Una solución para este problema sería el uso de modelos no lineales en el control predictivo. Existen diversas propuestas en este campo [2]. Una opción interesante, dentro de los modelos de *caja gris*, es el uso de modelos Neuroborrosos. En la literatura se puede encontrar diversos ejemplos usando los mismos, [5],[14],[10],[12],[17],[3],[4]. El asunto quizá más importante en el Control Predictivo basado en modelos No-Lineales, es la solución del optimizador, lo cual consiste en un problema no convexo, cuya resolución lleva consigo un gran coste computacional para resolverlo en tiempo

real. En los últimos años han aparecido diversas técnicas para evitar los problemas asociados a la solución exacta del problema de optimización no convexa [2]. Además, se debe de garantizar la estabilidad del proceso en lazo cerrado. Nos hemos centrado en la obtención de un controlador predictivo que sea de fácil implantación en entornos industriales, usando controladores bien conocidos como los PLC. En la sección siguiente se presentan dos estrategias de control predictivo basado en modelos neuroborrosos (Neuro-Fuzzy Model-based Predictive Control, NF-MPC). Las dos se basan en el control predictivo GPC, donde se usa un modelo de función de transferencia discreta del tipo CARIMA (Controlled Auto-Regressive Integrated Moving Average):

$$A(z^{-1})y(t) = z^{-d}B(z^{-1})u(t-1) + C(z^{-1})\frac{e(t)}{\Delta} \quad (5)$$

5 Estrategias NF-MPC aplicadas en el Autoclave

Usaremos dos estrategias basada en el modelo Neuroborroso obtenido para el autoclave. Observando que el modelo de TS tiene dos modelos lineales locales. Tomando los modelos lineales,

$$y_1(t) = 0.385u(t-1) - 0.385u(t-2) + 0.125y(t-3) + 0.606y(t-2) + 1.732y(t-1) \quad (6)$$

$$y_2(t) = 0.035u(t-1) - 0.035u(t-2) - 0.308y(t-3) + 1.580y(t-2) + 2.273y(t-1) \quad (7)$$

Una estrategia propuesta en [17] y [4] consiste en calcular tantos controladores GPC (u_j) como implicaciones se obtengan en el modelo Neuroborroso, de tal forma que la salida del controlador venga dada, según la ecuación (2) por

$$u(k) = \sum_{j=1}^L w_j(k)u_j(k) \quad (8)$$

La ventaja de esta técnica es la fácil y rápida implementación, pudiéndose usar un simple PLC. La principal desventaja de esta estrategia es que no siempre se obtiene un mínimo global, aunque sí se garantiza un mínimo local para cada regla o implicación. Puede verse en la figura 6, cómo mejora ostensiblemente el comportamiento, respecto al controlador GPC lineal.

Otra estrategia no-lineal basada en modelos neuroborrosos, viene propuesta en [5], podríamos reescribir un modelo neuroborroso recurrente




Figura 6: Comparación de las estrategias de control Predictivo Lineal y no-lineal

como un sistema lineal variante en el tiempo (*Linear Time Variant, LTV*):

$$\bar{a}(z^{-1})y(k) = \bar{b}(z^{-1})u(k-d) + \xi(k) \quad (9)$$

Donde d es el retardo puro, $\xi(k)$ es una secuencia de ruido blanco con media cero y

$$\begin{aligned} \bar{a}(z^{-1}) &= 1 - \bar{a}_1 z^{-1} - \bar{a}_2 z^{-2} - \dots - \bar{a}_{n_y} z^{-n_y} \\ \bar{b}(z^{-1}) &= \bar{b}_1 z^{-1} + \bar{b}_2 z^{-2} + \dots + \bar{b}_{n_u} z^{-n_u} \\ \bar{a}_i &= \sum_{j=1}^L w_j(k) a_{ij} z^{-i} \\ \bar{b}_i &= \sum_{j=1}^L w_j(k) b_{ij} z^{-i} \end{aligned}$$

Si tomamos como función objetivo la siguiente

$$J(k) = \sum_{p=d}^{N_p} (\hat{y}(k+p|k) - \varphi_i r(k+p))^2 + \sum_{p=d}^{d+N_u-1} q(z^{-1})\Delta u(k+p-d|k))^2 \quad (10)$$

Donde $r(k)$ es la referencia, φ_i una ganancia, $\Delta = 1 - z^{-1}$, $q(z^{-1}) = q_0 + q_1 z^{-1} + \dots + q_{N_p+n_u-1} z^{N_p+n_u-1}$ un polinomio de pesos. N_p, N_u son los horizontes de predicción y control. Para obtener la secuencia de control que minimiza esta función objetivo, podemos usar el modelo descrito en (9). Dado un polinomio $e_p(z^{-1})$, los polinomios $f_p(z^{-1})$ y $g_p(z^{-1})$ se pueden definir por

$$1 = \Delta e_p(z^{-1})\bar{a}(z^{-1}) + z^{-p}f_p(z^{-1}), \quad (11)$$

$$g_p(z^{-1}) = \Delta e_p(z^{-1})\bar{b}(z^{-1}) \quad (12)$$

Multiplicando (9) por $\Delta z^p e_p(z^{-1})$, se tiene que

$$\Delta z^p e_p(z^{-1})\bar{a}(z^{-1})y(k) = \Delta z^p e_p(z^{-1})\bar{b}(z^{-1})u(k-d) + \bar{\xi}(k) \quad (13)$$

Donde $\bar{\xi}(k) = \Delta z^p e_p(z^{-1})\xi(k)$

Usando, junto a ésta, las ecuaciones (11) y (12), la salida predicha se obtiene por

$$\hat{y}(k+p|k) = f_p(z^{-1})y(k) + g_p(z^{-1})\Delta u(k+p-d) \quad (14)$$

Para reducir el costo computacional, vamos a reducir el horizonte de control a $N_u = 1$, así pues, la función de coste definida en (10) se puede expresar como:

$$J(k) = (Fy(k) + G\Delta u(k) + \Lambda - \Phi R)^T (Fy(k) + G\Delta u(k) + \Lambda - \Phi R) + (q(z^{-1})\Delta u(k))^2 \quad (15)$$

Donde

$$\begin{aligned} F &= [f_d(z^{-1}) \quad f_{d+1}(z^{-1}) \quad \dots \quad f_{N_p}(z^{-1})]^T, \\ G &= [g_{d,0} \quad g_{d+1,0} \quad \dots \quad g_{N_p,0}]^T, \\ \Lambda &= \begin{bmatrix} \sum_{\rho=1}^{d+n_u-1} g_{d,\rho}\Delta u(k-\rho) \\ \sum_{\rho=1}^{d+n_u} g_{d+1,\rho}\Delta u(k-\rho) \quad \dots \\ \dots \quad \sum_{\rho=1}^{N_p+n_u-1} g_{N_p,\rho}\Delta u(k-\rho) \end{bmatrix}^T \\ \Phi &= \text{diag}\{\varphi_d \quad \varphi_{d+1} \quad \dots \quad \varphi_{N_p}\} \\ R &= [r(k+d) \quad r(k+d+1) \quad \dots \quad r(k+N_p)]^T \end{aligned}$$

Como la función de coste es cuadrática, el óptimo se puede obtener fácilmente derivando:

$$\left. \frac{\partial J(k)}{\partial (\Delta u(k))} \right|_{\Delta u(k)=\Delta u^*(k)} = 0 \quad (16)$$

Con lo cual, se llega a

$$G^T (Fy(k) + \Lambda - \Phi R) + (G^T G + q(z^{-1})q_0)\Delta u^*(k) = 0 \quad (17)$$

Desarrollando la ecuación anterior,
 $G^T (Fy(k) - \Phi R) + G^T \Lambda + (G^T G + q_0^2)\Delta u^*(k) + q_0(q_1 z^{-1} + \dots + q_{N_p} z^{N_p})\Delta u^*(k) = 0$,
 $G^T (Fy(k) - \Phi R) + (G^T G + q_0^2)\Delta u^*(k) + G^T \Lambda + q_0 \sum_{i=1}^{N_p} q_i \Delta u^*(k-i) = 0$,
 $G^T (Fy(k) - \Phi R) + (G^T G + q_0^2)\Delta u^*(k) + \Theta(k) = 0$

Para poder simplificar la ley de control, elegimos $q_0^2 = \lambda > 0$ y ajustamos los valores q_1, q_2, \dots, q_{N_p} tal que satisfagan que $\Theta(k) = 0$. Así obtenemos, de manera simplificada:

$$\Delta u^*(k) = \frac{G^T (\Phi R - Fy(k))}{G^T G + \lambda} \quad (18)$$

Se han simulado bajo las mismas condiciones las tres estrategias de control, comprobándose el mejor comportamiento de ésta última, tal y como se observa en la figura 7.




Figura 7: Comparación general de las estrategias de control Predictivo

6 Implementación en PLC

Es común encontrar en los PLC industriales conjuntos de objetos de programación para implementar control borroso. Tal es la frecuencia y el éxito de esta forma de control que ha requerido de un apartado especial dentro de la norma internacional IEC 1131 (*International Electrotechnical Commission*), la cual se ocupa de la estandarización de los autómatas programables industriales. Muchos grupos han estado envueltos en esta normalización, dando como fruto en 1997 la IEC 1131-7 [6] cuyo draft puede descargarse de <http://www.fuzzytech.com/binaries/ieccd1.pdf>. La norma IEC 1131-7 establece un conjunto de funciones para programar aplicaciones de control borroso. Este conjunto de funciones forma el denominado “Lenguaje de Control Borroso” ó FCL (*Fuzzy Control Language*). Los bloques de funciones definidos en el FCL se pueden usar en los lenguajes que establece la IEC 1131-3.

Las funciones del lenguaje FCL se definen con los siguientes nombres: *Fuzzification*, *Defuzzification* y *Ruleblock*. estableciéndose además un conjunto de parámetros opcionales para ellas. En algunos PLC, la función Ruleblock se sustituye por la interconexión de los bloques de Fuzzification y Defuzzification.

7 Conclusiones

se ha realizado dos estrategias de control predictivo generalizado no lineal basado en modelos neuroborrosos de Takagi-Sugeno, sobre una planta industrial para ensayos. Por un lado se ha probado una estrategia basada en la combinación de dos controladores GPC mediante un sistema neuroborroso. También se ha propuesto una metodología de diseño de Control Predictivo Generalizado basado en un modelo RFNN LTV, que ha mostrado el mejor comportamiento frente a dos estrategias más. Además, la principal ventaja de los mismos es la posibilidad de implantación en un autómatas programable de gama media, ahorrando un coste muy considerable. Esto último, junto a la simplicidad del modelado y el buen comportamiento del sistema, los hacen atractivo para su implementación en el mundo industrial. Otra ventaja añadida es la posibilidad de continuar el aprendizaje en tiempo real, para la mejora del modelo. Para ello se debe de garantizar la convergencia del aprendizaje [5].

Agradecimientos

Los autores desean agradecer la financiación de este trabajo al MEC (por su proyecto de investigación DPI2004-07444-C04-01)

Referencias

- [1] A.A. Alonso, J.R. Banga, R. Pérez-Martín. "A complete dynamic model for the thermal processing of bioproducts in batch units and its application to controller design". *Chemical engineering science*, vol. 52, pp. 1307-1322. 1997
- [2] E.F. Camacho, C. Bordons. "Model Predictive Control". Springer-Verlag London. 2004
- [3] J.J. Espinosa, J. Vandewalle. "Predictive Control using Fuzzy models". *Advances in Soft Computing in Engineering Design and Manufacturing*. 1998
- [4] J.J. Espinosa, M.Hadjili, V. wertz, J. Vandewalle. "Predictive Control using Fuzzy models-Comparative study". ECC. 1999
- [5] Chi-Huang L., Ching-Chih T. "Generalized predictive control using recurrent fuzzy neural networks for industrial processes". *Journal of Process Control*. 2007
- [6] International Electrotechnical Commission (IEC). "IEC 1131 Programmable Controllers. Part 7: Fuzzy Control Programming". IEC TC65/WG 7/TF8. 1997
- [7] K. Kiriakidis, "Fuzzy Model-Based Control of Complex Plants". *IEEE TRANSACTIONS ON FUZZY SYSTEMS*, vol. 6, NO. 4, Nov.1998
- [8] Lee, "Diagonal recurrent neural networks for dynamic systems control". *IEEE Trans. Neural Networks*. 1995
- [9] Ching-Hung Lee, Ching-Cheng Teng, "Identification and Control of Dynamic Systems Using Recurrent Fuzzy Neural Networks", *IEEE TRANSACTIONS ON FUZZY SYSTEMS*, vol.8, no. 4, Aug. 2000
- [10] M. Mahfouf, D.A.Linkens, M.F. Abbod. "Adaptive Fuzzy TSK Model-based Predictive Control using a CARIMA model structure". *Institution of Chemical Engineers, Trans IChemE, Vol 78, Part A*. 2000
- [11] L.F. Mendoça, J.M. Sousa, U. Kaymak, J. Sá da Costa. "Fuzzy issues in Predictive Control". *IEEE Conference on Fuzzy Systems*. 2003
- [12] H.N. Nounou, K.M. Passino. "Fuzzy model Predictive Control: Techniques, Stability Issues, and Examples. International Symposium on Intelligent Control/Intelligent Systems and Semiotics. 1999
- [13] M. Peña, H. Álvarez, S. Piñon, R. Carelli. "Fuzzy Model Predictive Control: Simultaneous and Sequential comparison". IFAC. 2000.
- [14] S. Blazic, I. Skrajanc. "Design and stability analysis of Fuzzy Model-based Predictive Control -A case study". *J Intell Robot Syst*. Springer Science. 2007
- [15] J.M. da Sousa, M. Setnes. "Fuzzy predictive filters in Model Predictive Control". *IEEE Transactions on Industrial Electronics*, Vol 46, No. 6. 1999
- [16] Shao-Yuan L., Yi-Peng Y. "On-line constrained Predictive Control algorithm using Multi-Objective Fuzzy-Optimization and case study". *Fuzzy Optimization and Decision Making*, 2, 123-142. 2003
- [17] J. Zhang, A.J. Morris. "Long Range Predictive Control of nonlinear processes based on recurrent Neuro-Fuzzy network models". *Neural Computing and Applications*. Springer-Verlag London. 2000