

# Control Neuronal por Modelo de Referencia para un Sistema de Estructura Variable

## *Model Reference Neural Control of a Variable Structure System*

M. Margarita Goire C.<sup>1</sup>, J. Martín Flores A.<sup>2</sup>, Moisés Bonilla<sup>1</sup>, Ieroham S. Baruch<sup>3</sup>

<sup>1</sup>Facultad de Ingeniería Eléctrica, Departamento de Informática

<sup>2</sup>Secretaría de Marina, Armada de México

<sup>3</sup>Centro de Investigación y Estudios Avanzados

Departamento de Control Automático

E-mails: mgoirec@fie.uo.edu.cu, cuenta02@prodigy.net.mx,

mbonilla@enigma.red.cinvestav.mx, baruch@ctrl.cinvestav.mx

*Artículo recibido en Junio 15, 2000 aceptado en Abril 10, 2003*

## Resumen

*El objetivo de este trabajo es presentar una propuesta de control neuronal por modelo de referencia para un sistema que cambia su estructura interna de un sistema lineal de primer orden a un sistema lineal de segundo orden, aplicando para esta tarea una red neuronal recurrente. Se presentan dos esquemas de control neuronal por modelo de referencia para el sistema antes mencionado. Una de las características de la red neuronal que se utiliza es la de tener restricciones en su: pesos, esto garantiza su estabilidad durante el entrenamiento. En el primer esquema se utiliza una red neuronal para la identificación del sistema de estructura variable; en el segundo esquema se usan dos redes neuronales con el propósito de separar la identificación de cada subsistema.*

**Palabras Clave:** Redes Neuronales, Sistemas de Estructura Variable, Control por Modelo de Referencia, Control Inteligente, Sistemas Implícitos.

## Abstract

*The objective of this paper is to propose a reference model neural control of a system, which change its internal structure from a linear system of first order to a linear system of second order, applying for this task a recurrent neural network. Two schemes of reference model neural control, for the above mentioned system, are presented. One characteristic feature of the neural network used, is that a feedback weight restriction is applied, which preserved its stability during the learning. The first control scheme uses one neural network for identification of the variable structure system; the second control scheme uses two neural networks so to separate the identification of each subsystem.*

**Keywords:** Neural Networks, Variable Structure Systems, Model Reference Control, Intelligent Control, Implicit Systems.

## 1 Introducción

Dentro de los sistemas que pueden ser representados por medio de las realizaciones implícitas ( $E, A, B, C$ ), se encuentran los sistemas de estructura variable. La variación de estructura de estos sistemas puede ser clasificada como discreta (variación entre dos o más puntos) o continua (variación continua y acotada), esto según (Bonilla y Malabre, 1991). Un ejemplo típico de variación discreta son los sistemas con variación de orden, siendo éste el caso de interés en el presente trabajo. La representación de los sistemas de estructura variable con realizaciones ( $E, A, B, C$ ) permite sintetizar leyes de control a partir de la teoría de Sistemas Lineales Implícitos (Bonilla y Malabre, 1991; M. Bonilla y otros, 1993; 2000; Goire y otros, 2000 a y b).

En este trabajo se presenta un enfoque neuronal para sintetizar la ley de control de un sistema de estructura variable usando una red neuronal dinámica en donde la tarea de control consiste en seguir un modelo de referencia. El esquema neuronal propuesto consta de dos etapas, una etapa de identificación y otra de control.

En la Sección 2 se presentan algunos antecedentes de sistemas de estructura variable y de un esquema de control implícito para el mismo.

En la Sección 3 se explica la estructura de la red neuronal recurrente utilizada, así como su ley de ajuste de los pesos.

La Sección 4 presenta dos esquemas de control por modelo de referencia para el sistema de estructura variable en estudio, con los resultados de simulación obtenidos. Finalmente, en la Sección 5 damos las conclusiones del trabajo.

## 2 Sistemas de Estructura Variable

Por medio de las realizaciones implícitas rectangulares ( $E, A, B, C$ ) representadas por:

$$\begin{aligned} E\dot{x}(t) &= Ax(t) + Bu(t) \\ y(t) &= Cx(t), \end{aligned} \quad (1)$$

en donde las variables:  $x(t) \in X, u(t) \in U, y(t) \in Y$  y las aplicaciones:  $E: X \rightarrow X, A: X \rightarrow X, B: U \rightarrow X$  y  $C: X \rightarrow Y$  son operadores lineales de dimensiones apropiadas, en donde los subespacios son tales que:  $\text{Dim}\{X\} \leq \text{Dim}\{X\}$ , y es posible representar el comportamiento y controlar sistemas de estructura variable. En (Bonilla y Malabre, 1991) se mostró que gracias al grado de libertad existente por la diferencia en las dimensiones del espacio de estados: ( $\text{Dim}\{X\} \leq \text{Dim}\{X\}$ ), hace posible tomar en cuenta la variación de estructura en una forma implícita. En (M. Bonilla y otros, 1994) se obtuvieron las condiciones geométricas con las cuales es posible diseñar una estrategia de control "robusto" en el sentido de que aun si la estructura interna está sujeta a variaciones, la salida del sistema controlado tiene un comportamiento único, (consultar: F. L. Lewis, 1992 y 1991 para mayores detalles sobre descripciones implícitas).

Considere el sistema de estructura variable descrito mediante la realización o descripción implícita siguiente:

$$\begin{aligned} \begin{bmatrix} 1 & 0 & 0 \\ 0 & 0 & 1 \end{bmatrix} \dot{x}(t) &= \begin{bmatrix} -1 & -1 & 1 \\ 0 & -1 & 0 \end{bmatrix} x(t) + \begin{bmatrix} 0 \\ 1 \end{bmatrix} u(t) \\ y(t) &= [1 \quad 1 \quad 0] x(t), \quad \forall t \geq 0 \end{aligned} \quad (2)$$

Con las dos restricciones algebraicas:

$$[0 \quad -1 \quad 1]x(t) = 0 \quad (3)$$

$$[0 \quad 1 \quad 0]x(t) = 0 \quad (4)$$

Si la restricción (3) está activada, el sistema se comporta como un sistema de primer orden:

$$\dot{y}(t) + y(t) = u(t) \quad (5)$$

Si la restricción (4) está activada, el sistema se comporta como un sistema de segundo orden:

$$\dot{y}(t) + \ddot{y}(t) = u(t) \quad (6)$$

En (M. Bonilla y otros, 1993) se aplica la metodología dada en (M. Bonilla y otros, 1994), para sintetizar un controlador lineal para tal descripción implícita, obteniéndose la ley de control siguiente:

$$u(t) = \begin{bmatrix} -1 & 0 & \left(1 - \frac{1}{\tau_0}\right) \end{bmatrix} \zeta(t) + \dots \quad (7)$$

$$+ [0 \quad 1 \quad -1] \dot{\zeta}(t) + \frac{1}{\tau_0} r(t)$$

$$\zeta_1 = x_1; \zeta_2 = x_2; \zeta_3 = x_1 + x_2 \quad (8)$$

Con esta ley de control la descripción (2) es:

$$\begin{aligned} \begin{bmatrix} 1 & 0 & 0 \\ 0 & 0 & 1 \end{bmatrix} \dot{\zeta}(t) &= \dots \\ &= \begin{bmatrix} -1 & -1 & -\frac{1}{\tau_0} \\ 0 & -1 & -\frac{1}{\tau_0} \end{bmatrix} \zeta(t) + \dots \\ &+ \begin{bmatrix} 0 \\ 1 \\ \frac{1}{\tau_0} \end{bmatrix} r(t) \\ y(t) &= [0 \quad 0 \quad 1] \zeta(t) \quad \forall t \geq 0 \end{aligned} \quad (9)$$

así, el grado de libertad se hace no observable, es decir, la variación de estructura ya no es visible a la salida del sistema.

El comportamiento del sistema en lazo cerrado aplicando la ley de control mencionada, queda descrito por la siguiente ecuación:

$$\tau_0 \dot{y}(t) + y(t) = r(t) \quad (10)$$

Donde  $\tau_0$  es la constante de tiempo del modelo de referencia. Independiente de si la restricción (3), o la restricción (4), es activada.

Dado que la estrategia de control (7, 8) está basada en acciones derivativas ideales, en (M. Bonilla y otros, 1993) se propone un controlador propio, que aproxima al no propio.

Por ejemplo, con la siguiente aproximación propia del controlador (7) y (8), se pueden describir en la forma:

$$x^T(t) = [x^T(t) \quad x_d(t)] \quad (11)$$

$$u(t) = \dots$$

$$\begin{aligned} &\begin{bmatrix} -\frac{1}{\varepsilon} \left(1 - \frac{1}{\varepsilon}\right) & -\left(\frac{1}{\tau_0} - \frac{1}{\varepsilon}\right) & -\left(\frac{1}{\tau_0} - \frac{1}{\varepsilon}\right) \end{bmatrix} x(t) + \dots \\ &+ \frac{1}{\tau_0} r(t) \end{aligned} \quad (12)$$

$$\varepsilon \dot{x}_d(t) + x_d(t) = [I \quad I \quad -I]x(t) \quad (13)$$

Después de algunas operaciones matemáticas, se obtiene el siguiente sistema en lazo cerrado:

$$\begin{bmatrix} I & 0 & 0 & 0 \\ 0 & 0 & I & I \\ 0 & -\varepsilon & \varepsilon & \varepsilon \end{bmatrix} \dot{\zeta} = \begin{bmatrix} 0 & I & -I & 0 \\ 0 & 0 & 1/\tau_0 & 1/\tau_0 \\ 0 & 0 & 0 & -1 \end{bmatrix} \zeta + \dots$$

$$\dots + \begin{bmatrix} 0 \\ 1/\tau_0 \\ 0 \end{bmatrix} r \quad (14)$$

$$y(t) = [0 \quad 0 \quad I \quad 0]\zeta, \quad \forall t \geq 0$$

Donde se han realizado los siguientes cambios de variables:

$$\begin{aligned} \zeta_1 &= x_1; & \zeta_2 &= x_2; & \zeta_3 &= x_1 + x_2; \\ \zeta_4 &= x_1 + x_2 - x_3 + \zeta_4 \end{aligned} \quad (15)$$

$$\varepsilon \dot{\zeta}_4 + \zeta_4 = [0 \quad -1 \quad 1]\zeta \quad (16)$$

El comportamiento entrada - salida del sistema en lazo cerrado (14) tiende a (10) cuando  $\varepsilon \rightarrow 0$ . La estabilidad del sistema en lazo cerrado se estudia en (M. Bonilla y otros, 1993). La estrategia de control desarrollada en (M. Bonilla y otros, 1993, 1994) usa la variable descriptora  $x(t)$ . En (M. Goire y otros, 2000 a y b) se sintetiza un reconstructor de esta variable descriptora, utilizando un detector de estructura neuronal, que determina cual estructura interna está activada y en (Bonilla y otros, 2000) se utilizó un esquema de control adaptable.

La idea central de este trabajo es dar otra alternativa de control de un sistema de estructura variable utilizando redes neuronales, de manera que la variación de estructura no sea visible a la salida del sistema. Como la planta es continua y la red neuronal usada, es discreta, entonces las señales que se usan como entradas a la red tienen que ser discretizadas y la salida del controlador neuronal tiene que ser retenida.

### 3 Red Neuronal Recurrente

#### 3.1 Estructura de la Red

Las redes neuronales recurrentes han sido utilizadas en varios trabajos de identificación y control de sistemas (A. S. Poznyak, E. N Sánchez y otros, 2001; G. A. Rovithakis, M. A. Christodoulou, 2000; J. A. K. Suykens, L. Vandewalle y otros, 1996). En los anteriores, se ha utilizado un enfoque por medio de funciones de Lyapunov, esto hace que las redes converjan más lentamente y no se estiman los estados del sistema identificado usados para el control.

En (I. S. Baruch, J. M. Flores y otros, 2002), se propone una arquitectura de red neuronal recurrente entrenable (RNRE), se consideran algunas propiedades de esta red como controlabilidad, observabilidad y estabilidad del algoritmo Backpropagation de su aprendizaje, comprobado por un teorema y un lema, y se muestran los resultados de su aplicación para la identificación y control de un motor CD en tiempo real. En el artículo de I. S. Baruch, J. M. Flores y otros, 2001, se utilizan los estados estimados por una red neuronal para generar una retroalimentación que estabiliza el sistema. Esta red neuronal está dividida en dos capas, en la primera, se tiene una capa de retroalimentación (oculta), y la capa de salida está formada por una suma ponderada.

Las ecuaciones que describen a esta red neuronal son las siguientes:

$$x(k+1) = Jx(k) + Bu(k); \quad (17)$$

$$z(k) = S^h[x(k)]; \quad (18)$$

$$y(k) = S^0[Cz(k)]; \quad (19)$$

$$J = \text{block-diag}(J_{\omega}); \quad |J_{ii}| < 1 \quad (20)$$

Donde:  $u(k)$  es la entrada a la red;  $x(k)$  es el vector de estados internos;  $y(k)$  es la salida de la red;  $z(k)$  es una variable auxiliar. Las variables y parámetros que definen a la red tienen las siguientes dimensiones:

$$u(k) \in \mathfrak{R}^m; \quad x(k), z(k) \in \mathfrak{R}^n; \quad y(k) \in \mathfrak{R}^p \quad (21)$$

$$B \in \mathfrak{R}^{n \times m}; \quad J \in \mathfrak{R}^{n \times n}; \quad C \in \mathfrak{R}^{p \times n} \quad (22)$$

Considerando que es una red con  $m$  entradas,  $n$  nodos ocultos,  $p$  salidas. La matriz  $J$  es diagonal, o diagonal a bloques. Debido a esto, se dice que esta red está descrita por un modelo canónico de Jordan, con mínimo número de pesos ajustables, que permite un aprendizaje más rápido y por esto - ejecutable en tiempo real. El vector  $S^h$  con dimensión  $n$  está formado por funciones de activación del tipo tangente hiperbólico:

$$s_i^h(i) = \tanh(i) = \frac{1 - e^{-2i}}{1 + e^{-2i}} \quad (23)$$

$$S^h(i) = [s_1^h(i) \quad \dots \quad s_n^h(i)]^T \quad (24)$$

En la teoría de las redes neuronales se destaca el papel de la función de activación no lineal en su poder de representación, pero al utilizar una función de la clase tangente hiperbólico en la capa de salida de la red obliga a que se considere la escala de las señales. Para evitar este problema, en la capa de la salida se selecciona una función lineal:

$$S^0(i) = i \quad (25)$$

### 3.2 Ley de Aprendizaje

La ley de aprendizaje (ajuste) de los parámetros de esta red se basa en la conocida *regla delta*, con valores iniciales equiprobables, escogidos arbitrariamente en un rango de números pequeños, donde el peso para el instante siguiente se deriva, usando la recurrencia:

$$w_i(k+1) = w_i(k) + \eta \Delta w_i(k) \quad (26)$$

Si durante el ajuste de los pesos de la red se presentan oscilaciones, se puede agregar el término de momento, que adiciona un porcentaje de su variación del peso en el instante anterior, es decir:

$$w_i(k+1) = w_i(k) + \eta \Delta w_i(k) + \alpha \Delta w_i(k-1) \quad (27)$$

Donde los parámetros  $\eta$  y  $\alpha$  pertenecen al intervalo cerrado  $[0,1]$ . El ajuste de los parámetros de la red están definidos por las siguientes ecuaciones, (Baruch y otros, 2002):

$$\Delta e_i(k) = e(k) [1 - y^2(k)] z_i(k); \quad (28)$$

$$\Delta B_{ij}(k) = R u_j(k); \quad (29)$$

$$\Delta J_{ij}(k) = R x_i(k-1); \quad (30)$$

$$R = C(k) e(k) z_i(k); \quad (31)$$

Donde  $e(k)$  es el error de la salida. Los índices anteriores dependen de la estructura de la red utilizada.

#### Condición de Estabilidad para los Pesos J

La condición de estabilidad para la red neuronal recurrente se da con la ecuación (20). Para facilitar su implementación se hace la suposición que  $J$  es una matriz diagonal.

Para el caso discreto, la red neuronal será estable durante su operación, si los elementos de la matriz  $J$  cumplen que su magnitud es menor a 1, es decir:  $|J_{ii}| < 1$ , que corresponde a un círculo con centro en el origen y con radio unitario.

Para incorporar la condición de estabilidad en las expresiones de actualización de los pesos  $J_{ii}$  se propone la siguiente modificación a la regla delta:

$$J_{ii}(k+1) = \bar{J}_{ii}(k) - \eta \frac{\partial E(k)}{\partial J_{ii}} + \alpha \Delta J_{ii}(k-1); \quad (32)$$

$$\bar{J}_{ii}(k) = \text{Sat}[J_{ii}(k)],$$

Donde la función  $\text{Sat}(x)$  que se usa es:

$$\text{Sat}(x) = \begin{cases} 1 - \varepsilon; & x \geq 1 \\ x; & x < 1 \\ \varepsilon - 1; & x \leq -1 \end{cases}$$

Aquí la constante  $\varepsilon$  es un número pequeño y positivo. De esta forma en la red neuronal se propone sustituir el peso  $J_{ii}$  por su valor saturado y asegurar así que este peso satisface las condiciones de estabilidad. Así, manteniendo los valores propios de la matriz  $J$  ( $J_{ii}$ ), que son polos de la red neuronal recurrente, en el rango estable se asegura la estabilidad de toda la red y su algoritmo de aprendizaje.

## 4 Control Neuronal por Modelo de Referencia

El control de sistemas por modelo de referencia consiste en diseñar un sistema que modifique el comportamiento natural de la planta con el objetivo que se aproxime a la respuesta que tiene un modelo de referencia establecido. En este esquema de control se supone que el diseñador tiene el suficiente conocimiento del sistema como para definir el comportamiento deseado por medio de un modelo. Uno de los primeros trabajos de la aplicación de las redes neuronales para el control por modelo de referencia de sistemas puede consultarse en (K. S. Narendra, K. Parthasarathy, 1990). A continuación se presentan un par de esquemas de control por modelo de referencia para sistemas de estructura variable en tiempo real, en donde la etapa de identificación se realiza por medio de redes neuronales.

### 4.1 Esquema con Una Red

El esquema general del control por modelo de referencia para el sistema de estructura variable, (2-4), se muestra en la Figura 1. El esquema de control se divide en tres secciones: una de control, formada por un lazo de retroalimentación de la salida y una red neuronal recurrente; una etapa de identificación, que utiliza otra red neuronal recurrente; y la tercer etapa formada por el modelo de referencia.

El último suaviza la señal de referencia y define el comportamiento del sistema en lazo cerrado, porque los pesos del controlador neuronal se ajustan con el error de control, que es  $e_c = y_{ref} - y_p$ .




Fig.1: Esquema de control neuronal por modelo de referencia de un sistema de estructura variable.

Durante la operación del sistema de estructura variable su comportamiento dinámico se alterna entre los siguientes subsistemas:

$$\dot{x}(t) = \begin{bmatrix} -I & 1 \\ 0 & 0 \end{bmatrix} x + \begin{bmatrix} I \\ \theta \end{bmatrix} u; y = \begin{bmatrix} 1 & 0 \end{bmatrix} \quad (33)$$

$$\dot{x}(t) = \begin{bmatrix} -I & 0 \\ 0 & -1 \end{bmatrix} x + \begin{bmatrix} I \\ \theta \end{bmatrix} u; y = \begin{bmatrix} 1 & 1 \end{bmatrix} \quad (34)$$

Desde la representación entrada-salida, el subsistema (3) (subsistema-1) tiene una dinámica de segundo orden con polos en  $p_{1,2} = \{0, -1\}$ ; dos ceros al infinito,  $z_{1,2} = \infty$ . El subsistema (33) (subsistema-2) tiene un par de polos en  $p_{1,2} = -I$  y ceros en  $z_{1,2} = \infty, -I$ . El polo y cero localizados en  $-I$  se cancelan, en consecuencia, la dinámica mostrada por este sistema, desde el punto de vista entrada salida, es de un sistema de primer orden.

Con el fin de estabilizar el subsistema (33), se agregó el lazo de retroalimentación de la salida. El lazo de retroalimentación no altera la localización de los ceros de los subsistemas, pero si la posición de sus polos, para estudiar el efecto de este lazo vea las Figuras 2 y 3.

En la Figura 2 se observa que al ir aumentando la ganancia de la retroalimentación negativa, los polos en lazo abierto en  $-1$  y  $0$ , se mueven sobre el eje real hasta converger en  $-0.5$  y de allí la parte imaginaria se incrementa simétricamente alejándose perpendicularmente del eje real.

Para el segundo subsistema, al aumentar la ganancia del lazo de retroalimentación, sólo uno de sus polos se altera, alejándose por la izquierda sobre el eje real. Esto era de esperarse pues el otro polo queda fijo al cero finito en  $-1$  que lo cancela.




Fig. 2: Efecto de la retroalimentación de la salida sobre el subsistema 1 (o, primer polo; x segundo polo).

De lo anterior se infiere que la retroalimentación de la salida, altera la posición de los polos no apareados, y que los ceros no se ven alterados, pero de ellos depende la dirección en la cual los polos se mueven.

Para los esquemas de control por modelo de referencia la ganancia del lazo de retroalimentación que se seleccionó es de  $-1.5$ . De las gráficas anteriores puede determinarse en donde se localizaran los polos de ambos subsistemas. Durante la simulación valores menores de  $-1.5$  en los esquemas neuronales, el desempeño en el seguimiento de la referencia se reduce.

En el primer esquema de control neuronal se utiliza una RNRE como identificador. Los pesos de esta red son

ajustados utilizando el error formado por la diferencia entre la señal de salida del sistema de estructura variable y la propia salida de la red:




Fig. 3: Efecto de la retroalimentación de la salida sobre el subsistema 2 (o, primer polo; x segundo polo).

$$e_s = y_p - y_n \quad (35)$$

El que sustituye a  $e(k)$  en las ecuaciones (28) y (31).

El modelo de referencia que define la respuesta deseada es de primer orden, descrito por:

$$Y_{ref}(s) = \frac{0.4}{s + 0.2} R(s) \quad (36)$$

La red que genera la señal de control recibe como entrada la salida del modelo de referencia,  $y_{ref}$ , el ajuste de los parámetros se determina por el nivel del error de control,  $e_c$ , definido por la diferencia entre la señal de referencia y la salida de la red de identificación,  $y_n$ :

$$e_c = y_{ref} - y_n \quad (37)$$

En la Tabla 1, se resumen los parámetros para las redes neuronales usadas en las simulaciones.

Tabla 1: Parámetros de simulación.

PARÁMETROS	VALOR
Número de Nodos, $n$	15
Ganancia de momento, $\alpha$	0.0005
Ganancia de momento, $\eta$	0.0005
Periodo de Muestreo, $T_s$	0.01 Seg

Durante la simulación, el sistema de estructura variable, (2), conmuta entre los subsistemas (5) y (6) cada 100 segundos. La señal de entrada es una onda cuadrada simétrica con un periodo de 200 segundos. El periodo de muestreo, dado en la Tabla 1, cumple con las condiciones de Shannon. En la Figura 4, se muestran las gráficas de la señal de salida del sistema de estructura variable, de la señal de salida del modelo de referencia o señal objetivo y el error que se comete entre ambas señales. Estos resultados fueron obtenidos usando como entrada al modelo de referencia una señal cuadrada. Se puede observar que el esquema de control es capaz de cumplir con el objetivo de hacer que el comportamiento del sistema de estructura

variable siga al del modelo de referencia propuesto, aunque se presenta un breve sobre impulso que coincide con el momento de la conmutación entre los subsistemas y el cambio de polaridad de la señal de entrada.

Analizando el error instantáneo, Figura. 4c, generado por el esquema propuesto, se puede ver con mayor claridad que durante la conmutación entre los subsistemas el error aumenta, aunque su valor, posterior a este evento, se reduce rápidamente.




Fig.4: (a) Salida del sistema, (b) Salida del modelo de referencia, (c) Error entre la salida del sistema y el modelo de referencia.

En la Figura 5, se presentan los componentes de la señal de control. El componente del control generado por el lazo de retroalimentación (línea continua); esta en oposición con el componente de control producido por la red neuronal.

El control aplicado al sistema de estructura variable se forma de la suma del control generado por el lazo de retroalimentación de la salida y de la salida de la RNRE, Figura 6. Como se observó en las gráficas anteriores, el esquema de control neuronal por modelo de referencia para el sistema de estructura variable tiene un buen desempeño fuera de los instantes de cambio de los subsistemas. Se presume que este efecto se debe al uso de una RNRE en la etapa de identificación, que debe reajustar sus parámetros.

Si se supone que se tiene disponible la indicación de cuando se realiza la conmutación entre los subsistemas, se podría utilizar un esquema de identificación multimodelo. En la siguiente sección se presenta esta opción.




Fig.5: Componentes de la señal de control (retroalimentación de la salida, línea continua; red neuronal, línea segmentada).




Fig.6: Control aplicado al sistema de estructura variable.

## 4.2 Esquema con Multimodelo

Se supone que se conoce de antemano el número de subsistemas en los cuales se divide el sistema de estructura variable y cuando se lleva a cabo la conmutación entre ellos. Debido a lo anteriormente expresado, en este artículo se propone un esquema en donde la identificación se realiza por medio de dos redes neuronales (ver Baruch y otros, 2000), conmutando entre ellas en correspondencia con el cambio de subsistema. En la Figura 7, se presenta el esquema que se utilizará para realizar la simulación.

El conmutador de sistema tiene la tarea de habilitar una de las RNRE de la etapa de identificación, con lo que tendrá una red neuronal para identificar a cada uno de los subsistemas.

Los parámetros de ambas redes son los mismos a los indicados en la Tabla 1. En la Figura 8a se muestra la salida del sistema de estructura variable, vuelven a presentarse el efecto transitorio del sobre impulsos cuando se conmuta entre los subsistemas. En la Figura 8b aparece la salida del modelo de referencia y en la Figura 8c está el error entre la salida del sistema y el modelo de referencia.

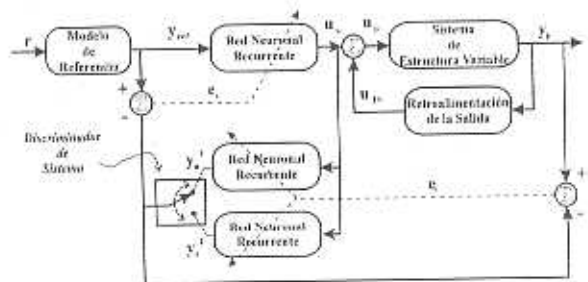


Fig.7: Esquema multimodelo de control neuronal. El control por modelo de referencia de un sistema de estructura variable (multimodelo).




Fig. 8: (a) Salida del sistema, (b) Salida del modelo de referencia, (c) Error entre ambas señales.

La utilización del multimodelo en la identificación del sistema de estructura variable no resultó en una mejora apreciable en el control. Comparando las gráficas del error, Figuras 4c y 8c, se observan ligeros cambios en algunos de los transitorios que aparecen en el esquema de identificación de una red.

En la Figura 9 se presentan los componentes de la señal de control aplicada al sistema de estructura variable. Aquí nuevamente vemos como la componente del lazo de retroalimentación (línea continua) se opone a la señal de salida de la RNRE que genera el control.

Finalmente, en la Figura 10 se presenta la señal de control aplicada al sistema de estructura variable.

Se observa que la señal de control está formada por la suma del lazo de retroalimentación de la salida y la salida de la red neuronal que realiza el control.




Fig. 9: Componentes de la Señal de Control (retroalimentación de la salida, línea continua; red neuronal, línea segmentada)




Fig. 10: Control Aplicado al Sistema de Estructura Variable.

## 5 Conclusiones

En este trabajo se presentaron dos esquemas de control neuronal por modelo de referencia para un sistema de estructura variable, donde la red neuronal recurrente utilizada fue la reportada en (I. S. Baruch, J. M. Flores y otros, 2002, 2001, 2000). Sería oportuno señalar que el lazo de retroalimentación de la salida fue necesario para garantizar la estabilidad del subsistema (33), este es un requerimiento para que pueda ser identificado por la red neuronal.

De los resultados de la simulación podemos decir que ambos esquemas de control son viables. Entre estos dos modelos de control no hubo gran diferencia en su desempeño, lo que indica que el hecho de separar la etapa de identificación no representa una mejora de importancia, al menos para el ejemplo utilizado.

Estableciendo una comparación entre los esquemas usados tradicionalmente para este tipo de sistema y el esquema neuronal propuesto, se destaca el hecho de que en este último, no se necesitan los estados del sistema para realizar el control. Además, se hace uso de redes neuronales dinámicas que son entrenadas en línea. Destacar que en el primer modelo no se requiere una detección explícita de los subsistemas.

Como línea de trabajo futura será interesante realizar experimentos con esquemas donde el controlador esté compuesto por más de una red neuronal. Otra línea de trabajo podría ser investigar que otros elementos mejoran el comportamiento del esquema de control neuronal y aplicar los resultados a sistemas más complejos.

## Referencias

I. S. Baruch, J.M. Flores, F. Nava, I.R. Ramirez, and B. Nenikova, "An Advanced Neural Network Topology and Learning, Applied for Identification and Control of a D.C. Motor", in *Proc. of the First Int. IEEE Symposium on Intelligent Systems, Varna, Bulgaria, Sept., 2002*, pp. 289-295.

I. S. Baruch, J. M. Flores, R. Garrido, and E. Gortcheva, "Identificación de sistemas no lineales complejos usando un multimodelo neuronal difuso", in *Científica, ESIME, No.19, Ene-Feb., 2000*, pp.29-40.

I. Baruch, J.M. Flores, F. Thomas, and R. Garrido, Adaptive Neural control of Nonlinear Systems, in *Proc. of the Artificial Neural Networks Conf. -ICANN 2001, Lecture Notes in Computer Science, vol. 2130, G. Dorfner, H. Bischof, and K. Hornik, Eds. Berlin, Heidelberg, New York: Springer-Verlag, 2001*, pp. 930-936.

M. Bonilla, and M. Malabre, "Variable Structure Systems via implicit Descriptions", in *Proceedings of the 1st European Control Conference, Grenoble, France, Vol. 1, pp. 757-761, 2-5 July, 1991*.

M. Bonilla, G. Lebret, and M. Malabre, "Output Dynamics Assignment for Implicit Descriptions", in *Circuits, Systems and Signal Processing, Special Issue on Implicit Robust Systems, Vol. 13 No. 2-3, 1994*, pp. 349-359.

M. Bonilla, M. Fonseca M, and M. Malabre, "On the Implementation of some Variable Structure Systems Control Laws (the case of two points varying systems)", in *Proceedings of the 32-nd IEEE CDC, San Antonio, Texas, USA, 1993*, pp. 895-896.

M. Bonilla E., M. M. Goire, and S. Mondié, "Adaptive Structure Detector", in *Proc. of the American Control Conference ACC'2000, Chicago, USA, June, 2000*.

M. Goire, M. Bonilla, S. Mondié, "Neural Network Reconstructor for Implicit Systems", in *Proc. American Control Conference ACC'2000, Chicago, USA, June 2000*.

M. M. Goire, M. Bonilla, and S. Mondié, "Sur l'apprentissage des réseaux de neurones pour la reconstruction de la structure de systèmes implicites", in *Proc. Conférence Internationale Francophone d'Automatique CIFA'2000, Lille, France, Juillet, 2000*.

F.L. Lewis, "A Tutorial on the Geometric Analysis of Linear Time-invariant Implicit Systems", in *Automatica, Vol.28, No. 1, 1992*, pp. 119-137.

F. L. Lewis, "A Survey of Linear Singular Systems", in *Circuits, Systems and Signal Proc., No. 9, September, 1991*, pp. 3-36.

K. Narendra, and K. Parthasarathy, "Identification and Control of Dynamical Systems Using Neural Networks", in *IEEE Transactions on Neural Networks, Vol. 1, No. 1, March, 1990*, pp. 4-27.

A. S. Poznyak, E. N Sánchez, and W. Yu, *Differential Neural Networks for Robust Nonlinear Control*, World Scientific, Singapore, 2001.

G. A. Rovithakis, and M. A. Christodoulou, *Adaptive Control with Recurrent High-Order Neural Networks*, Springer Verlag, New York, USA, 2000.

J. A. K. Suykens, L. Vandewalle, and R. de Moor, *Artificial Neural Networks for Modelling and Control of Nonlinear Systems*, Kluwer Academic Publishers, Boston, USA, 1996.