

# Identificación Neurodifusa en Tiempo Real: Aplicación a un Motor de Corriente Directa

Juan Carlos González Gómez, José Antonio Ruz Hernández, Ramón García Hernández.

Universidad Autónoma del Carmen, Av. 56 # 4 X Av. Concordia, Col. Benito Juárez, C.P. 24180, Cd. del Carmen, Campeche, México. Teléfono (01)-938-11018

{jcgonzalez, jruz, rghernandez}@pampano.unacar.mx

**Resumen**— Este trabajo presenta la identificación neurodifusa de un motor de corriente directa conectado en excitación separada. El procedimiento de identificación incluye el experimento para realizar la colecta de datos, el entrenamiento de un sistema de inferencia difusa basado en una red adaptable ANFIS por sus siglas en inglés y su validación con datos frescos. También se realiza una prueba de validación en tiempo real donde se comparan los datos proporcionados por el modelo con las mediciones que provienen del motor. Los resultados obtenidos son exitosos y se pretenden utilizar a corto plazo en el diseño de controladores basados en modelos neurodifusos para controlar la velocidad del motor en tiempo real y realizar el seguimiento de trayectorias de diversos tipos de señales de entrada.

**Palabras clave:** Identificación neurodifusa, ANFIS, tiempo real, motor de cd.

## I. INTRODUCCIÓN

Los equipos didácticos para experimentar el control de sistemas dinámicos, son de gran importancia en el campo de la ingeniería de control, ya que la mayoría de estos equipos se diseñan con base en el funcionamiento de las plantas industriales reales. No todos los fabricantes de equipos didácticos proporcionan su modelo matemático, es por esto que estamos usando la identificación neurodifusa a partir de datos experimentales para diseñar esquemas de control basados en el modelo.

A este respecto, la experiencia adquirida en el manejo de un equipo didáctico, es de gran ayuda cuando se requiera aplicarla en un proceso industrial semejante. Los motores de corriente directa se utilizan ampliamente en aplicaciones industriales. No obstante que sus propiedades de operación son accesibles, son bien conocidos los efectos no lineales presentes en la máquina y que se reflejan durante el control de los mismos, los efectos de la fricción son los más significativos, además de otras no linealidades típicas como son: histéresis, zona muerta y saturación (Chiasson J. and M. Bodson 1993). Uno de los problemas para la implementación de sistemas de control automático es obtener un modelo que describa la dinámica del sistema a ser controlado (Tsang K. M. and G. Li 2001). El motor que se considera en este trabajo es el DL10200A1 de la marca

DE LORENZO<sup>1</sup> y el fabricante no proporciona su modelo matemático. Sin embargo, dado que es un equipo para el aprendizaje guiado basado en la experimentación, es posible obtener datos con excitación persistente en su región de operación nominal que permita la obtención de modelos confiables del motor. Se pensó en un modelo neurodifuso, en el cual se utiliza una combinación de la teoría de conjuntos difusos y de las redes neuronales, aprovechando ambas ventajas. Un modelo de este tipo se obtiene a partir del entrenamiento de una red ANFIS con datos reales de operación. Esta red permite modelar sistemas con alto grado de no linealidad y/o invariantes en el tiempo (Babuska R. 1999), (Pacheco J. G. et al.2003), (Ruz Hernandez J. A. et al. 2003), (Allaoua B. et al. 2009).

El objetivo de este trabajo es realizar la identificación neurodifusa del motor para obtener un modelo confiable que permita emplear a corto plazo algoritmos de control basados en modelos neurodifusos. Para ello se obtienen datos experimentales útiles para la identificación mediante el entrenamiento con sistemas tipo ANFIS y para la validación del modelo obtenido con datos frescos. Así mismo, se realiza la validación en tiempo real con resultados exitosos.

## II. DESCRIPCIÓN DEL EQUIPO EXPERIMENTAL

*Datos del Motor:*

El problema en el motor de corriente directa consiste en controlar la velocidad de giro aplicando un voltaje al devanado de armadura del mismo. En la Figura 1 se aprecia el equipo a utilizar y los datos de placa.




Figura 1. Motor DL10200A1 de la marca De Lorenzo

<sup>1</sup> DE LORENZO es una marca registrada.

En los datos de placa del motor se observa que la velocidad nominal es de 3600 rpm y el voltaje de alimentación es de 220 Volts. Para determinar el rango de operación del motor se le aplicaron diferentes niveles de voltaje.

**Módulo de Alimentación:**

Se emplea el módulo DL 2637 de la marca DE LORENZO para alimentar al devanado de armadura con un voltaje variable de corriente directa (Vcd.). Este módulo permite que con un voltaje entre 0 y 10 volts (señal de control), se varía el voltaje de armadura entre 0 y 240 Vcd. En la Figura 2 se aprecia este módulo.



Figura 2. Módulo DL 2637 de la marca DE LORENZO

**Interconexión de los elementos:**

En el diagrama a bloques que se muestra en la figura 3 se muestra la interconexión de los elementos empleados. Se observa que el módulo DL2637 DE LORENZO cuenta con una fuente de voltaje fijo que alimenta el devanado de campo y una fuente de voltaje variable la cual se conecta al devanado de armadura del motor DL10200A1, la tarjeta de adquisición de datos entrega una señal de control entre 0 y 10 volts. Esta señal de control se emplea para variar el voltaje de armadura entre 0 y 240 volts de esta forma se puede controlar la velocidad en lazo abierto del motor. Los sensores de velocidad angular y de voltaje de armadura envían sus respectivas señales a la tarjeta de adquisición de datos, de este modo se obtienen las señales que se emplean para la identificación del modelo del motor.

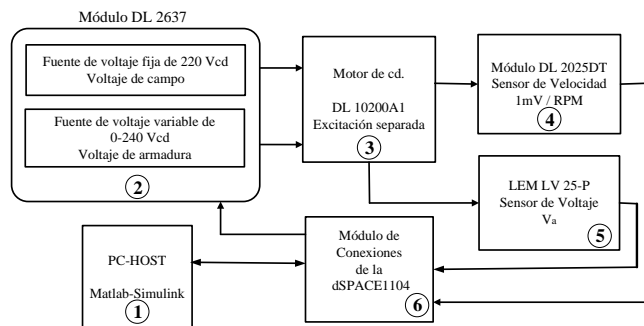


Figura 3 Diagrama de interconexión de los elementos empleados.

**Acondicionamiento de señales:**

El sensor de voltaje empleado es de la marca LEM modelo LV 25-P, este sensor se comporta como un transformador que genera una corriente del lado secundario proporcional a la del lado primario, este elemento de medida lleva asociado el circuito de conexión que se muestra en la figura 4, que consiste en dos elementos resistivos situados a la entrada y a la salida del sensor. La  $R_I$  tiene como misión transformar la tensión que se quiere en una corriente ( $i_{primario}$ ), que es lo que el sensor es capaz de medir realmente. La resistencia de medida  $R_M$ , situada a la salida del sensor, permite adaptar la corriente de salida que proporciona el sensor, a los valores de tensión de salida según los requerimientos del diseño. Este dispositivo dispone de aislamiento galvánico y es capaz de medir tensiones nominales de entre 10 y 500V. De la ecuación (1) se puede determinar la ganancia de voltaje del sensor, que para este trabajo se obtuvo una ganancia de  $\Delta_V=41$ , donde  $V_M = R_M I_s$

$$\Delta_V = \frac{V_{ent}}{V_M} \dots\dots\dots(1)$$

donde.

$V_{ent} = 205V$ , Voltaje con la que se excito el motor.  
 $R_M = 100\Omega$ , es la resistencia de medida.  
 $I_s = 50mA.$ , es la corriente en el lado secundario.

Las terminales de alto voltaje ( $\pm HT$ ) se conectan a las terminales del devanado de armadura del motor y las terminales  $\pm$  se alimentan con un voltaje de  $\pm 12 V$  cd. Este sensor se emplea con la finalidad de obtener la señal de voltaje aplicado a la armadura como señal de entrada a la planta.




Figura 4. Circuito acondicionador de señal.

Para obtener la señal de velocidad ( $\omega$ ) se emplea el módulo DL 2025DT de la marca DE LORENZO. Este módulo proporciona una ganancia de  $1V/min^{-1}$ , es decir, que para un campo de medida o velocidad real del motor es de 3600 rpm, el sensor proporciona 3.6 volts. La ganancia se calcula por la ecuación (2), donde la velocidad nominal del motor es de 3600 rpm, entonces, la ganancia del sensor es de  $\Delta_\omega=1000$ , que es la ganancia con la que el sensor atenúa en su salida el voltaje proporcional a la velocidad.

$$\Delta_\omega = \frac{Velocidad\ nominal\ del\ motor\ (rpm)}{Tension\ de\ salida} \dots\dots(2)$$

donde:

$$Tension\ de\ salida = \frac{Campo\ de\ medida\ (rpm)}{1V / 10000\ min^{-1}} \dots\dots(3)$$

### Módulo de adquisición de datos:

Para la adquisición de las señales de velocidad y voltaje del motor se emplea la tarjeta de adquisición de datos que corresponde al modelo dSPACE 1104 que se instala en un slot de computadora. Cuenta con un módulo de entradas y salidas analógicas y digitales. Con ella, se pueden generar o adquirir señales digitales para comunicación y control. La dSPACE 1104 es una herramienta de hardware que trabaja con un software en el entorno de Matlab<sup>2</sup> y Simulink, se emplea para una rápida implementación en tiempo real de sistemas en una computadora digital.

Inicialmente, la aplicación se desarrolla en una computadora de escritorio (host), con MATLAB, Simulink, Real-Time Workshop y la herramienta Control Desk. En esta PC se crean los modelos usando bloques de Simulink y se genera el código correspondiente. Posteriormente, este código se ejecuta en tiempo real.

## III. IDENTIFICACIÓN NEURODIFUSA

### 3.1 Generación de la secuencia binaria pseudoaleatoria (SBPA)

El primer paso dentro del proceso de identificación es realizar algún tipo de experimento sobre el sistema bajo estudio para obtener los datos de entrada-salida, que servirán de base para la obtención del modelo final.

Para la generación de la secuencia binaria pseudoaleatoria se empleó un registro de corrimiento de 8 bits (Torres H. y Farfán M. 2008). La SBPA generada con el registro de corrimiento de ocho bits tiene una amplitud de  $\pm 2$  Volts como se puede ver en la figura 5.

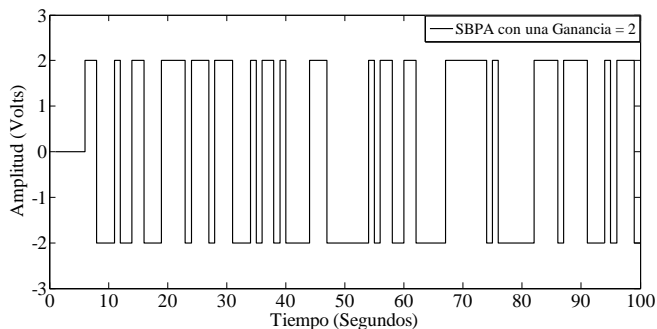


Figura 5. Secuencia binaria pseudoaleatoria generada con el registro de corrimiento de ocho bits.

La SBPA se sumó al Voltaje de corriente directa que en este caso es de 6 Volts siendo la señal de entrada al módulo DL 2637 para que controle el voltaje de armadura con la finalidad de variar el voltaje aplicado al motor. De esta forma se mantiene una excitación persistente en la entrada del motor. El voltaje de armadura puede variar después de aplicarle la SBPA entre 90-192 V después de aplicar la SBPA.

La fig. 6 muestra la forma de la señal de entrada y salida del módulo DL 2637. La SBPA no se aplica instantáneamente sino hasta después de 5 segundos y las

variaciones en el voltaje de entrada afectan directamente la velocidad en el motor.

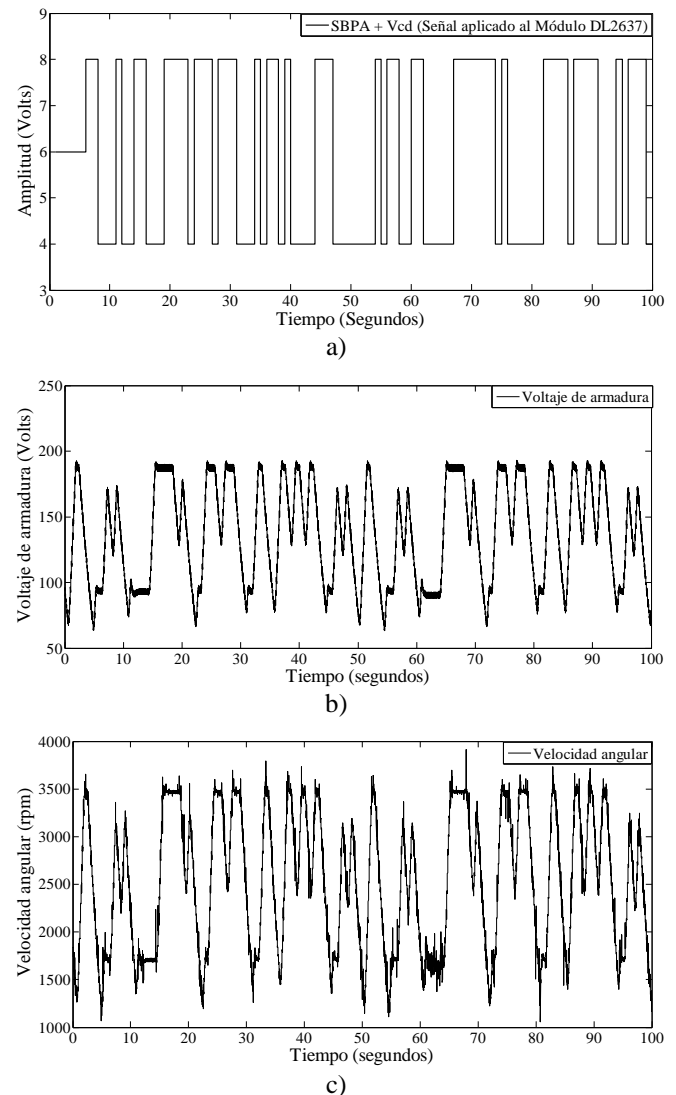


Fig. 6 Forma de la señal de entrada y salida del módulo DL 2637 cuando se le aplica la SBPA, a) SBPA aplicada al módulo DL 2637, b) voltaje aplicado a la armadura del motor y c) velocidad angular del motor.

Estos datos obtenidos previamente por medio de los sensores tanto de velocidad y de voltaje se utilizarán en el entrenamiento fuera de línea usando un ANFIS en la herramienta Fuzzy Logic de Matlab.

### 3.2 ANFIS: Sistemas de Inferencia Difusa Basados en Redes Adaptables.

Las técnicas Neurodifusas se utilizan para sintonizar automáticamente los parámetros de un sistema de inferencia difusa del tipo Takagi y Sugeno (TS) basadas en un conjunto de datos de entrenamiento. El ANFIS consiste en un sistema de inferencia difusa, implementado en el marco de las redes adaptables, que usa solamente funciones de

pertenencia diferenciables, lo que facilita la aplicación de procedimientos de aprendizaje estándares del gradiente descendente de la teoría de redes neuronales. Los parámetros de las funciones de pertenencia se ajustan usando el Algoritmo de Retropropagación o bien, el Algoritmo de Aprendizaje Híbrido. En este último se usa una combinación del primer Algoritmo con la técnica de Mínimos Cuadrados (Jang J. 1993), donde la retropropagación es usada para calcular las actualizaciones de los parámetros del antecedente, es decir los parámetros de los conjuntos difusos, y la estimación por mínimos cuadrados es usada para determinar las actualizaciones de los parámetros consecuentes, es decir los coeficientes de las combinaciones lineales en los consecuentes (Nauck D. 1999).

### 3.3 Modelado Neurodifuso del Motor.

Para la obtención de un modelo neurodifuso del motor, se utilizó como apoyo el software MATLAB, el Toolbox Fuzzy Logic y la herramienta ANFIS Edit (Fuzzy Logic Toolbox, 2000).

#### Esquemas de Identificación:

El esquema de identificación utilizado es el serie-paralelo, el cual puede verse en la figura 7. El error  $e(k)$  obtenido por la diferencia entre la respuesta de la planta y la del identificador, se usa como un índice de desempeño para satisfacer un conjunto de datos entrada-salida en el proceso de estimación paramétrica.

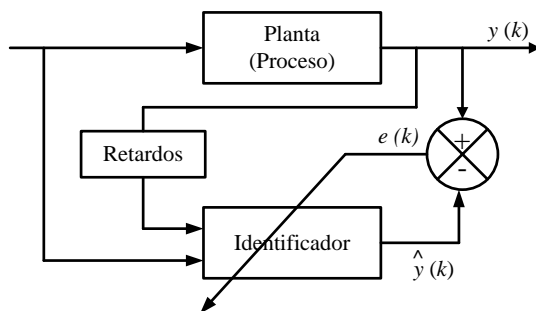


Figura 7. Esquema de Identificación en Serie-Paralelo.

#### Adquisición de los Datos para el Entrenamiento:

Las variables de voltaje y de la velocidad están disponibles en el motor como dos voltajes proporcionales a sus valores. Para obtener estos datos de voltaje se utilizó la tarjeta de adquisición de datos dSPACE 1104 y se caracterizaron los sensores de voltaje y de velocidad. Cuando se trabaja con sistemas en tiempo real, el tiempo de muestreo depende también de algunos factores como: velocidad de procesamiento de la tarjeta de adquisición de datos y del tiempo de ejecución del código del modelo. La elección del periodo de muestreo está directamente relacionada con la constante de tiempo del sistema, y tiene una influencia decisiva en el experimento de identificación. Como la constante de tiempo del sistema es de  $T=0.1752s$ , se empleará un periodo de muestreo de  $0.01s$ , que permitirá obtener 17.52 muestras en el tiempo de subida, con lo que se

determina que el tiempo de muestreo seleccionado es adecuado (Torres H. y Farfán M. 2008).

#### Datos Entrada-Salida Empleados en el Entrenamiento:

Para la adquisición de datos en tiempo real, se excitó el motor y se obtuvieron un total de 100, 000 datos, de los cuales los primeros 60, 000 se utilizaron para entrenar la red ANFIS y los otros 40,000 datos se utilizaron para una prueba de validación usando la técnica de extrapolación. (Norgaard and Ravn 2000). La herramienta utilizada para el entrenamiento fue la Fuzzy Logic Toolbox de Matlab mediante una interfaz.

#### Obtención del Modelo Neurodifuso:

La finalidad del entrenamiento es obtener un modelo neuro-difuso sintonizado con las ventajas adaptivas de las redes neuronales artificiales, buscando una convergencia de error a cero, por lo cual se entrenó con 60 000 datos para lograr dicha convergencia.

En la interfaz ANFIS Edit. se utilizó el Algoritmo de Aprendizaje Híbrido y el Sistema de Inferencia Difusa TS, 3 Funciones de Pertenencia del tipo campana gaussiana por entrada en la capa 1, el algoritmo de aprendizaje híbrido y los consecuentes de las reglas difusas del tipo Takagi-Sugeno en la capa 4, en la figura 8 se muestra la estructura de la red ANFIS. Después de varios ensayos con diferentes retardos en las entradas históricas se alcanzó después de 3 épocas un error relativo de 19.8934 R.P.M. Entonces, la ecuación (4) corresponde al modelo de la velocidad angular estimada. En la figura 9 se muestra los datos para entrenar el ANFIS.

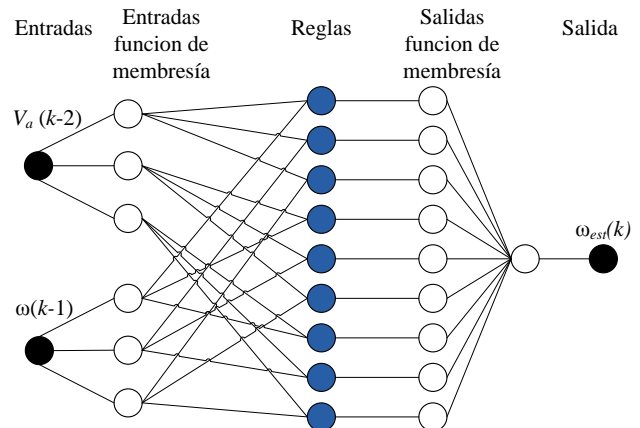


Figura 8 Estructura de la red ANFIS.

$$\omega_{est}(k) = f[V_a(k-2), \omega(k-1)] \dots \dots \dots (4)$$

El error relativo alcanzado por el método de ajuste por mínimos cuadrados está dado en revoluciones por minuto, como la velocidad nominal del motor es de 3600 R.P.M., entonces el error porcentual es 0.5525%.




Figura 9 Datos usados en el entrenamiento del ANFIS. a) Voltaje de armadura del motor, b) Velocidad angular del motor.

#### IV VALIDACION EN TIEMPO REAL DEL MODELO ANFIS.

El modelo ANFIS obtenido, se valida usando la técnica de extrapolación (The MathWorks Inc. (2001), (Pacheco R. y Ruz H., 2004). En esta técnica, se aplican las variables  $V_a(k)$ ,  $\omega(k)$  con datos diferentes a los utilizados en el entrenamiento (datos frescos) en las entradas de este modelo que tiene por salida la velocidad estimada  $\omega_{est}(k+1)$ , la figura 10, muestra esta técnica de validación.

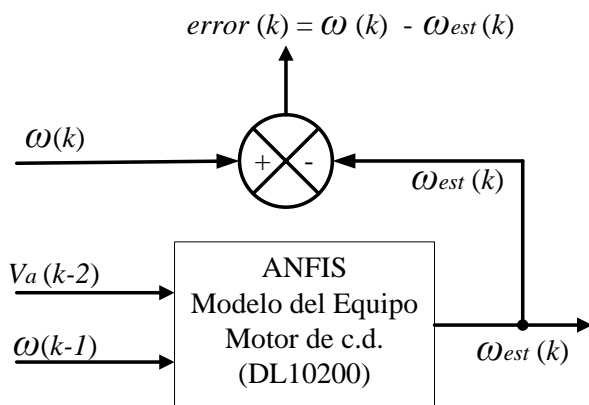


Figura 10 Esquema para Validar el ANFIS por extrapolación.

En la figura 11, se muestran las gráficas de los datos frescos de  $V_a(k)$ ,  $\omega(k)$  empleados para la validación del

modelo y en la figura 12 se compara su respuesta con la salida real del equipo  $\omega_{est}(k+1)$ .




Figura 11. Datos frescos usados en la validación del ANFIS. a) Voltaje de armadura  $V_a(k)$  y b) Velocidad angular  $\omega(k)$ .




Figura 12 Gráficas para Validar el ANFIS por extrapolación. a) Compara la velocidad real de salida del motor en el instante  $(k)$  (-) con la red ANFIS  $\omega_{est}(k)$  en el instante  $(k)$ , b) Error entre las dos salidas anteriores.

En la figura 12(a), se puede observar que la gráfica de la salida del ANFIS está prácticamente superpuesta a la gráfica

## V CONCLUSIONES

de la salida real del equipo, de hecho la figura 12(b), muestra que el error durante todo el trayecto siempre se mantiene cercano a cero. También, se sometió el modelo identificado a una prueba de validación en tiempo real. La prueba consistió en aplicar una señal escalonada en el rango de 4 a 8 V a la fuente de voltaje variable del módulo 2637 para generar un voltaje de armadura entre 96 y 192 V (ver figura 13). Posteriormente, se compararon las señales de velocidad del motor y la del modelo y se obtuvo la señal de error entre ambas. Ambos resultados se muestran en la figura 14. Se puede determinar el error cuadrático medio por medio de la ecuación 5, este error de la señal muestreada con respecto al modelo identificado es de 35.6063 rpm que corresponde a un error del 0.98%.

$$\varepsilon = \sqrt{\frac{1}{n} \sum_{i=1}^n [f(x_1, \alpha_1, \alpha_2, \dots, \alpha_m) - y_i]^2} \dots \dots \dots (5)$$






Figura 13 Señal de voltaje aplicada a la fuente variable del módulo DL2637.



(a)



(b)

Figura 14 Señales obtenidas de la validación del modelo (a) Señales de salida del motor y del modelo, (b) Error entre las dos señales anteriores.

Se comprobó que las técnicas neurodifusas, son adecuadas para modelar sistemas no lineales. Los aspectos más importantes a considerar y que son determinantes para obtener un buen modelo neurodifuso son: la selección de entradas del modelo, la señal utilizada como referencia para la adquisición de los datos experimentales y el periodo de muestreo. El modelo neurodifuso obtenido se validó usando la técnica de extrapolación y en tiempo real, obteniéndose resultados satisfactorios.

## VI. AGRADECIMIENTOS

El primer autor agradece a la Facultad de Ingeniería de la UNACAR por su apoyo para la utilización de los equipos del Laboratorio de Ingeniería de Control y la beca para la realización de sus estudios de Maestría.

## REFERENCIAS

Chiasson J. and M. Bodson (1993). Technical Notes and Correspondence Nonlinear Control of a Shunt DC. IEEE Transactions on Automatic Control, 38, 11, 935-942.

Tsang K. M. and G. Li (2001). Robust Nonlinear Nominal-Model Following Control to Overcome.

Babuska R.(1999). An overview of fuzzy modeling and model-based fuzzy control. World Scientific Series in Robotics and Intelligent Systems, 3-32.

Pacheco J. G., Ruz-Hernández J. A. and Shelomov E. (2003). "Técnicas Neurodifusas Aplicadas al Control del Equipo de la Bola y la viga" In proc. of Seminario Anual de Automática, Electrónica Industrial e Instrumentación, SAAEI 2003, Vigo Spain, pp. 1-6.

Ruz-Hernandez J. A., D. A. Suarez-Cerda, E. Shelomov and A. Villavicencio-Ramírez (2003). "Predictive Control based on an Auto- Regressive Neuro-Fuzzy Model Applied to the Steam Generator Startup Process at a Fossil Electric Power Plant", Computación y Sistemas, Vol. 6, Num. 3, pp. 204-212.

Allaoua B., A. Laoufi, B. Gasbaoui and A. Abderrahmani (2009). "Neuro-Fuzzy DC Motor Speed Control Using Particle Swarm Optimization", Leonardo Electronic Journal of Practices and Technologies, Issue 15, pp. 1-18.

Torres H. y Farfán M. (2008) Identificación y Control Adaptable Aplicados a un Motor de Corriente Directa. VIII Congreso Nacional de Ingeniería Eléctrica y Electrónica del Mayab. CONIEEM.

Jang J. (1993), ANFIS: Adaptive-Neuro-Based Fuzzy Inference System, IEEE Transactions on Systems, Man and Cybernetics, 665-671.

Nauck D. (1999). Neuro-Fuzzy Methods, World Scientific Series in Robotics and Intelligent, 70-71.

Fuzzy Logic Toolbox (2000) User's Guide for Use with MatLab. The Math Works Inc, 2-116, 2-77, 3-10, 3-13, 3-35, 3-37.

Norgaard M. and, Ravn O., N. K. Poulsen and L. K. Hansen (2000), Neural Networks for Modelling and Control of Dynamic Systems. A Practitioner's Handbook, Springer-Verlag London Limited.

The MathWorks Inc. (2001) Fuzzy Logic Toolbox for Use with MATLAB, User's Guide Version 2. U.S.A.

(Pacheco R. y Ruz H., 2004). Técnicas Neurodifusas Aplicadas al Control del Equipo de la Bola y la Viga. Memorias SAAEI 2004.