

Control con Modelo Interno Neuro-difuso en tiempo real: Aplicación a un Motor de Corriente Directa

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

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

{jgonzalez, jruez, rghernandez, jrullan}@pampano.unacar.mx

Resumen— Este artículo describe el desarrollo y aplicación en tiempo real de un esquema de control con modelo interno neurodifuso. Se aplican técnicas de identificación neurodifusa para implementar el esquema. El procedimiento de identificación incluye: el experimento para la colecta de datos, el entrenamiento del sistema tipo ANFIS (Adaptive Network-based on a Fuzzy Inference System, por sus siglas en inglés) y la validación con datos frescos en tiempo real. El esquema de control neurodifuso basado en un modelo interno es un diagrama en lazo cerrado que sirve para corregir los errores generados por el modelo y aquellos que causan perturbaciones presentadas en la salida del sistema. Así mismo, el modelo inverso neurodifuso funciona como controlador. Los resultados obtenidos son exitosos.

Palabras clave: ANFIS, tiempo real, modelo inverso, modelo interno, motor de corriente directa.

I. INTRODUCCIÓN

Varios fabricantes de equipos didácticos no proporcionan información acerca de los modelos dinámicos. El usuario tiene que operar este equipo para determinar algunos parámetros por medio de guías presentes en los manuales. Sin embargo, el manual no proporciona modelos matemáticos basados en leyes físicas.

Los motores de corriente directa son ampliamente usados en aplicaciones industriales debido a sus propiedades de su operación. Los motores de corriente directa se usan como actuadores en sistemas de control, robótica industrial, control numérico por computadora (CNC), máquinas y sistemas de radar. Los efectos no lineales existentes en los motores afectan el desempeño de los motores cuando se aplica una estrategia de control lineal. Los efectos debido a la fricción son más significativos. Para implementar el sistema de control automático es de suma importancia tener accesible un modelo

que describa la dinámica del sistema que se va a controlar (Babuska R. 1999). Un modelo estimado puede obtenerse a través de las herramientas de identificación. En este caso es posible obtener un modelo matemático derivado de datos experimentales las cuales se generan usando una señal de excitación persistente en la entrada. Los modelos que usan sistemas neuro-difusos son útiles para estimar a partir de datos experimentales donde las no linealidades están incluidas. El ANFIS permite modelar sistemas con alto grado de no linealidad e invariante en el tiempo el cual combina los conceptos de las redes neuronales y la lógica difusa para formar un sistema inteligente que resalta la habilidad de adaptación y aprendizaje automático.

Los resultados de simulación obtenidos en (Pacheco J. G., et al 2003), muestran que el modelo neuro-difuso y el control de posición de la “bola y la viga” son satisfactorios. Las estrategias de control neuro-difuso que se consideraron en este trabajo son el control inverso neuro-difuso y el control con modelo interno neuro-difuso que mejoran los resultados cuando se usan controladores convencionales.

En (Ruz-Hernandez J. A., et al. 2003) se describe un modelo neuro-difuso para la puesta en marcha de los generadores de vapor se obtiene a partir de datos experimentales. El modelo neuro-difuso se combina con un algoritmo de control predictivo para producir una estrategia de control para la fase de calentamiento del generador de vapor. Las pruebas de simulación demostraron la factibilidad y resultados benéficos que pueden obtenerse de la aplicación de cualquiera de las tres variantes de control predictivo propuesto por los autores.

En (Allaoua et al 2009) se describe una aplicación del ANFIS para optimizar el control de velocidad de un motor de corriente directa junto con la inteligencia colectiva. En primer lugar, los controladores están diseñados con las reglas difusas. En segundo lugar un controlador neuro-difuso para la

velocidad del motor de corriente directa es diseñado y simulado. Finalmente, el ANFIS es optimizado por inteligencia colectiva. Los resultados de simulación digital demuestran que el ANFIS con el control de velocidad demuestra buena dinámica de desempeño en motores de corriente directa.

En éste artículo se utilizan técnicas de identificación neuro-difusa para obtener el modelo de un motor de corriente directa. Así mismo, se obtiene el modelo inverso del motor. Ambos modelos se emplea para implementar un esquema de control con modelo interno neuro-difuso que permite el seguimiento de trayectoria de velocidad en tiempo real. Los resultados obtenidos son alentadores.

II. DESCRIPCION DEL EQUIPO EXPERIMENTAL

La primera dificultad con los motores de corriente directa (CD) conectados en excitación separada que consiste en controlar la velocidad de giro cuando se aplica un voltaje en la armadura. La velocidad nominal del motor es de 3600 revoluciones por minuto (RPM) y el voltaje de campo es de 220 V_{cd}. Para determinar el rango de operación del motor se deben aplicar diferentes niveles de voltaje.

El módulo de alimentación DL2637, fabricado por DELORENZO se utiliza para alimentar el voltaje de armadura al motor de corriente directa. Este módulo permite un rango de voltaje entre 0 y 10 volts de voltaje externo y proporciona a la salida una relación de transformación de 0 a 240 V_{cd}. El motor a utilizar es el DL10200A. La figura 1 muestra la interconexión de los elementos usados. La descripción de cada uno de los bloques numerados está dada de la manera siguiente.

1. Es la computadora donde se encuentran instalados la tarjeta de control dSPACE DS1104 y el software Matlab-Simulink.
2. Módulo DL 2637 que 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.
3. Motor de CD de la marca DE LORENZO DL10200A1 con conexión en excitación separada.
4. Sensor de velocidad de la marca DE LORENZO DL2025DT donde se obtiene la señal de velocidad ω que nos proporciona una ganancia de $1\text{mV}/\text{mi}^{\text{n}-1}$, es decir para 3600 rpm del motor proporciona 3.6 Volts, esta señal se envía a la tarjeta de control.
5. Sensor de voltaje de la marca LEM LV 25-P., el cual envía su señal a la tarjeta de control. El valor obtenido para la ganancia del voltaje corresponde a la ganancia con

la que el sensor atenúa en su salida M el voltaje aplicado en sus terminales de alto voltaje.

6. Módulo de conexiones de la tarjeta de control DSPACE DS1104. Tiene un rango de entrada y de salida de ± 10 volts siendo ésta la señal de entrada al módulo DL 2637 para mantener un voltaje persistente en la armadura del motor.

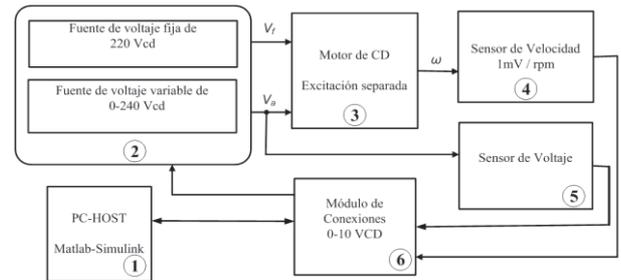


Figura 1. Esquema de interconexión.

III. CONTROL CON MODELO INTERNO NEURO-DIFUSO DEL MOTOR DE CD.

A. Esquema de control con modelo interno

Esta estructura especificada es un esquema de control en lazo cerrado en el cual involucra el modelo directo, el proceso de control ubicado en paralelo y por último el modelo inverso. Desde el punto de vista general se puede decir que el modelo directo de este proceso actúa como predictor, mientras que el modelo inverso sirve de controlador. Las interferencias externas para el proceso están representadas en la figura 2 como d_p . El filtro de retroalimentación está incluido al sistema de control para reducir la alta ganancia de frecuencias y mejora su robustez. También sirve para suavizar los abruptos inesperados y rápidos cambios en las señales mejorando la respuesta de los controladores. El control con modelo interno (IMC) ha ganado aceptación muy amplia debido a su habilidad de rechazo a interferencias y su robustez.

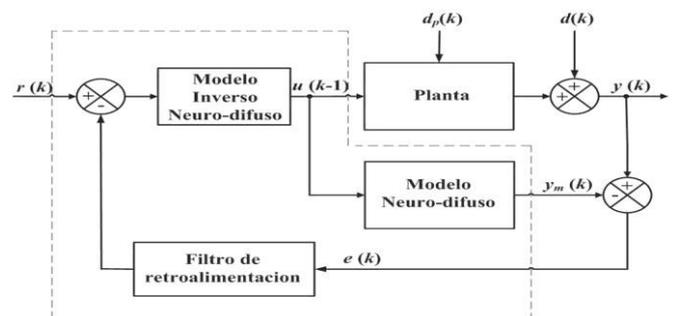


Figura 2 Control con Modelo Interno Neurodifuso.

Además esta estructura está bien establecida para el diseño de controladores. En la práctica, sin embargo la mayoría de los sistemas tienen una parte de no linealidad, y por lo tanto existe la necesidad para extender la IMC a sistemas no lineales. Uno de los problemas mayores en general es que la inversión de los modelos no lineales no es una tarea fácil y no se puede encontrar una solución analítica, por lo tanto las soluciones deben de calcularse numéricamente.

B. Adquisición de datos

El primer paso en la identificación de procesos es llevar a cabo un tipo de experimento del sistema estudiado, para recopilar los datos de entrada y salida que se emplean para obtener el modelo final. Para generar esos datos se muestra el equipo experimental en la figura 3.

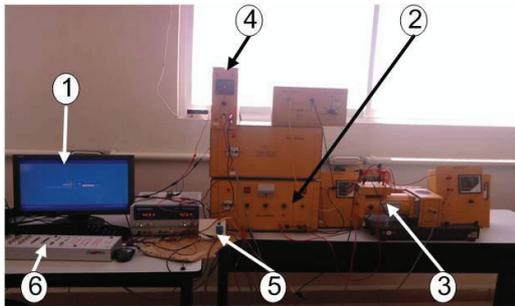


Figura 3 Prototipo experimental

El periodo de muestreo es seleccionado como $T= 0.01$ segundos. Para la adquisición de los datos se usó la secuencia binaria pseudoaleatoria (SBPA). Para la generación de la SBPA se empleó un registro de corrimiento de 8 bits con retroalimentación a la primera etapa del registro de corrimiento mediante una operación OR exclusivo en los registros 2, 3, 4, 8, para un periodo de la secuencia de 255. La SBPA con una amplitud de 2 voltios se muestra en la figura 4. La SBPA se agregó al voltaje de corriente directa, en este caso fue de 6 volts siendo éste voltaje la entrada al módulo DL 2637 para variar el voltaje de armadura $V_a(k)$ de 75-200 volts.

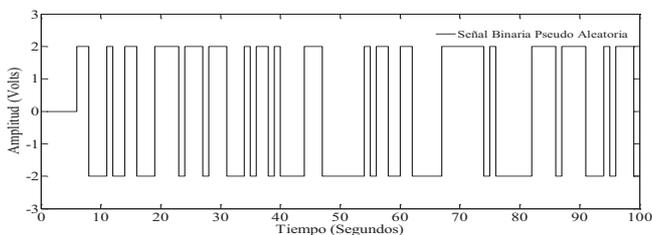
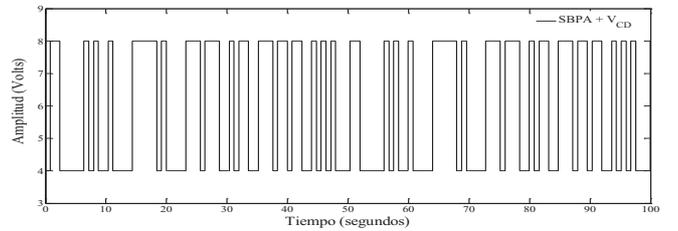
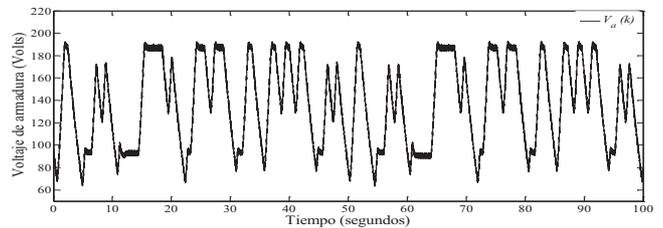


Figura 4 Secuencia Binaria Pseudoaleatoria

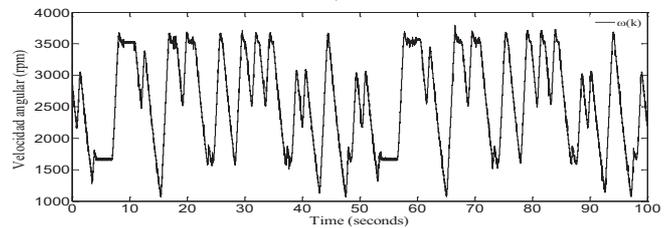
Los datos previamente obtenidos de la velocidad y del voltaje de armadura pueden usarse para el entrenamiento usando ANFIS y las herramientas de Fuzzy Logic de Matlab. En la figura 5(a) y figura 5(b) se muestra la señal de entrada y la señal de salida del módulo DL2637 respectivamente. La Figura 5(c) ilustra la velocidad angular $\omega(k)$.



a)



b)



c)

Figura 5. Datos experimentales de entrada y salida: a) SBPA + V_{CD} , b) Voltaje de armadura $V_a(k)$ y c) Velocidad $\omega(k)$.

C. Obtención del modelo neurodifuso.

El propósito del entrenamiento es obtener un modelo neuro-difuso sintonizado con la ventaja adaptativa de las redes neuronales artificiales, buscando una convergencia de error cercana a cero, ésta convergencia garantiza que al validar el modelo neuro-difuso y al ser comparado la velocidad real de salida del motor con la salida de la red ANFIS, el error entre las dos salidas sea lo más cercano a cero, por lo cual se entrenó con los primeros 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 (Takagi-Sugeno) T-S, 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 TS en la capa 4. En la figura 6 se muestra la estructura de la red ANFIS.

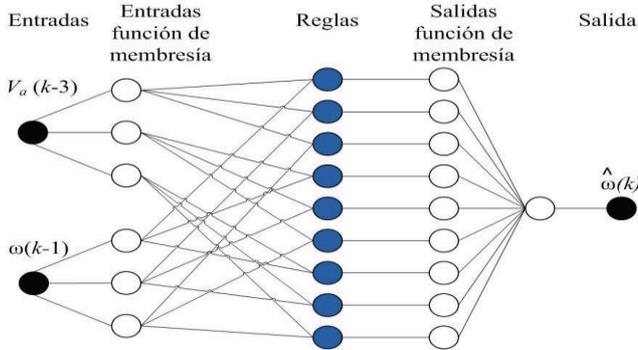


Figura 6. Estructura del ANFIS para el modelo neuro-difuso.

Después de varios ensayos con diferentes retardos históricos y con los mismos datos de entrada y salida del sistema, se entrenaron cinco modelos ANFIS neuro-difusos y se calculó el error cuadrático medio para cada uno de ellos, en la figura 7 se muestra los modelos ANFIS obtenidos. Resultado de esto, se selecciona el modelo 3 que es el que más representa las características del motor y después de tres épocas se alcanzó un error relativo de 19.8685 R.P.M. Entonces, la ecuación (1) corresponde al modelo de la velocidad angular estimada.

Comparación de los Modelos ANFIS obtenidos

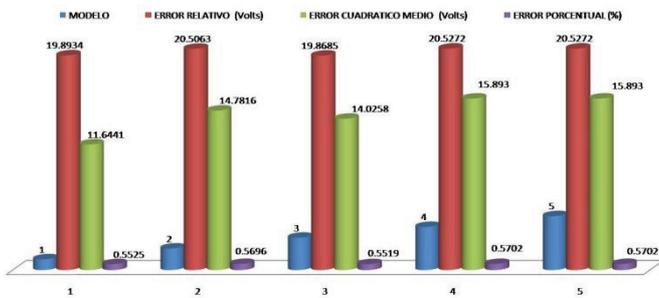


Figura 7 Modelos ANFIS.

$$\hat{\omega}(k) = f[V_a(k-3), \omega(k-1)] \quad (1)$$

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) y (The Mathworks Inc. 2001), 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 (Nauck D. 1999).

Una prueba de validación usando 40,000 datos frescos y la validación en tiempo real puede revisarse en (Gonzalez-Gomez J. C., et al 2011).

D. Obtención y validación del modelo neurodifuso inverso.

Con el fin de obtener el modelo neurodifuso inverso, hemos utilizado el ANFIS edit incluido en la caja de herramientas de Fuzzy Logic de Matlab. Además el entrenamiento ANFIS se lleva a cabo a través del algoritmo híbrido. Se entrenaron cinco modelos inversos neuro-difusos y se calculó el error cuadrático medio para cada uno de ellos. En la figura 8 se muestra los modelos ANFIS inversos obtenidos.

Comparación de los Modelos ANFIS Inversos obtenidos

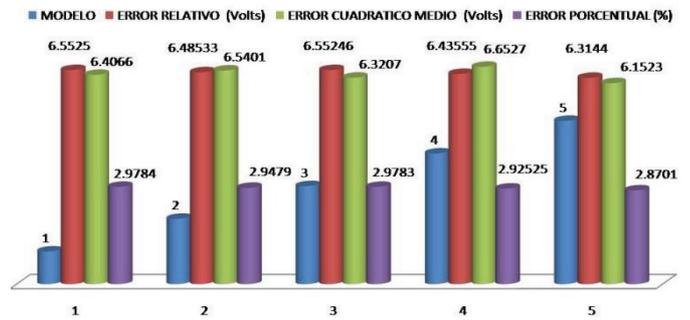


Figura 8 Modelos ANFIS.

La figura 9 muestra el esquema de entrenamiento usado para obtener el modelo ANFIS Inverso del motor de corriente directa, la ecuación correspondiente es:

$$\hat{V}_a(k-1) = f^{-1}[\omega(k), \omega(k-1)] \quad (2)$$

Donde, $\hat{V}_a(k)$ es el voltaje de armadura estimada, $\omega(k-1)$ es la velocidad angular en el instante $k-1$ y $\omega(k)$ es la velocidad angular en el instante k . El modelo inverso neurodifuso se valida usando datos frescos tanto en simulación y en tiempo real como se describe en (González-Gómez J. C., et al 2011).

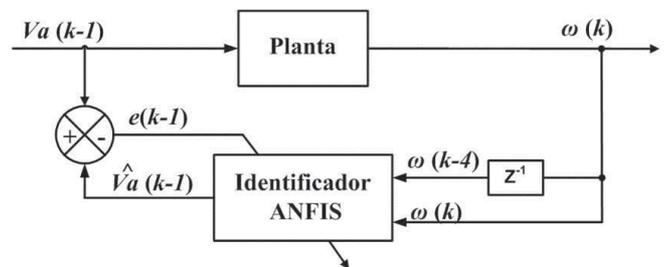


Figura 9. Esquema de entrenamiento del modelo neurodifuso inverso.

El modelo Inverso obtenido es validado en tiempo real. La inversa de una planta no lineal, no necesariamente existe. La prueba consiste en aplicarle una señal de voltaje persistente al motor de CD; en este caso, una SBPA entre 4 y 8 Volts, luego se compararon las señales de salida del modelo y la del motor. La figura 10 muestra el esquema usado en la validación.

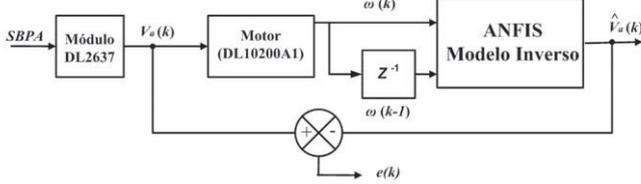


Figura 10 Esquema para validar el Modelo Inverso en tiempo real.

La figura 11 a) muestra la comparación de la señal de salida estimada por el modelo con la señal de salida del motor de CD y la figura 11 b) el error entre las dos señales anteriores.

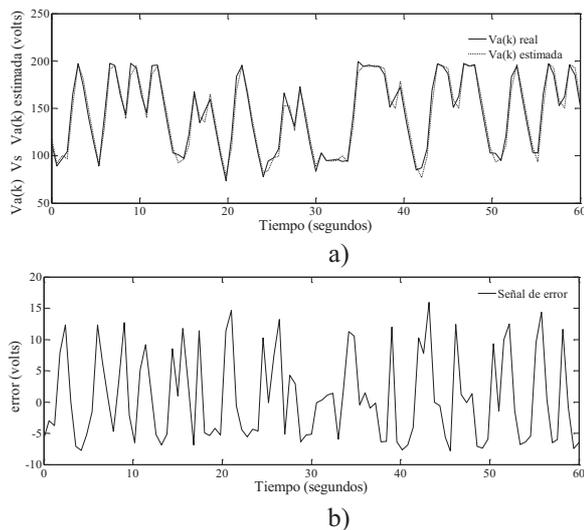


Figura 11 ANFIS Modelo Inverso: a) Comparación del $V_a(k)$ con el $\hat{V}_a(k)$, b) Error, $V_a(k) - \hat{V}_a(k)$.

IV APLICACIÓN EN TIEMPO REAL.

En nuestro diseño el modelo del sistema está en paralelo con el sistema real. La diferencia entre la salida del sistema y el modelo se utiliza con el propósito de retroalimentación. El error entre la salida del modelo (modelo neurodifuso) y la respuesta del motor de corriente directa, se utiliza como señal de retroalimentación, que es la alimentación del controlador (control inverso neurodifuso). La figura 12 muestra la programación en Simulink del CMIBMN. Los valores del ANFIS usa valores reales, mientras que el módulo de

alimentación trabaja entre 0-10 V_{cd} . Debido a que el modelo ANFIS inverso provee un voltaje de armadura de 0-220 V_{cd} y el módulo solamente trabaja de 0-10 V_{cd} entonces se usa una ganancia de $1/220 V_{cd}$, y es multiplicado por 10 cuando sale del DAC, siendo este el voltaje de control al sistema.

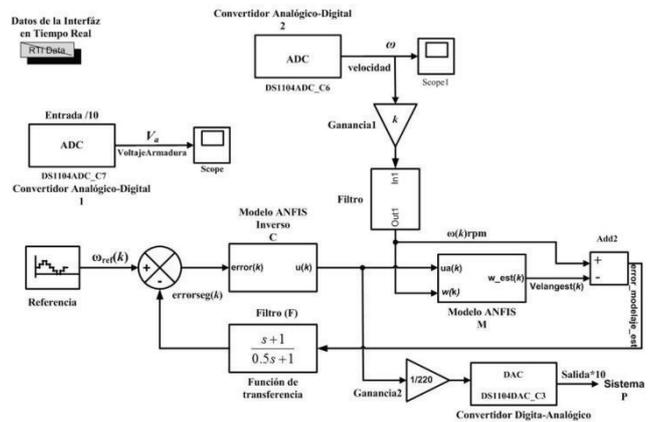


Figura 12 Programación en Simulink: esquema del CMIBMN.

donde:

- Filtro F: la función de transferencia es el filtro en la retroalimentación y es el único parámetro de diseño la cual existen dificultades para imponer restricciones en la señal de control y tiene la función de filtrar el ruido en la salida y estabilizar el lazo reduciendo la ganancia, por lo que la retroalimentación no es directamente la salida del sistema, sino que se retroalimenta el error entre la salida del sistema y la salida del modelo directo.
- ADC 1 y 2: son los convertidores analógicos digitales instalados en el módulo de conexiones de la tarjeta de control dSPACE DS1104 y recibe la señal de los sensores de voltaje de armadura y velocidad angular para su procesamiento.
- DAC: es el convertidor digital analógico el cual proporciona la señal de control a la planta y al modelo ANFIS neurodifuso.
- Sistema P: la señal de control que proviene del Modelo ANFIS Inverso. Ésta señal se le aplica una ganancia proporcional al módulo DL2637 que cuenta con una fuente de voltaje fijo que alimenta al devanado de campo y una fuente de voltaje variable la cual se conecta al devanado de armadura del sistema.
- ω_{ref} : señal de referencia aplicada al ANFIS Modelo Inverso. Los parámetros de ésta señal se indica en la ecuación 3.

$$\omega_{ref}(k) = A \sin[(f * T + \phi)] + \delta \quad (3)$$

donde A es la amplitud de la señal de velocidad angular $A=500$ RPM, f es la frecuencia de la señal ($f=0.2$ rad/s), T es el tiempo de muestreo ($T=0.01$ s), ϕ es el desfase de la señal ($\phi = \pi$ rad) y δ es el bias ($\delta = 3000$ RPM.).

La figura 13 muestra las gráficas de los resultados en tiempo real para el seguimiento de trayectoria, la señal de control se muestra en la figura 14 y el error de seguimiento en la figura 15 respectivamente.

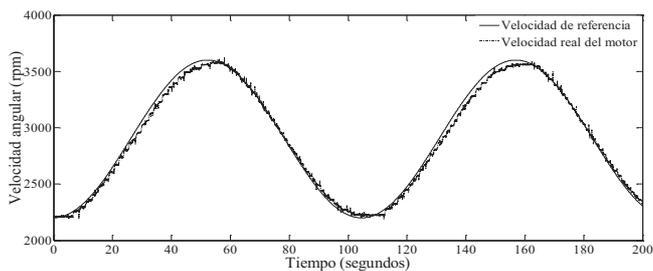


Figura 13. Seguimiento de trayectoria

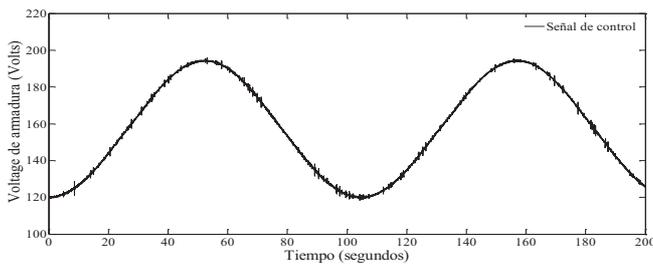


Figura 14. Señal de control.

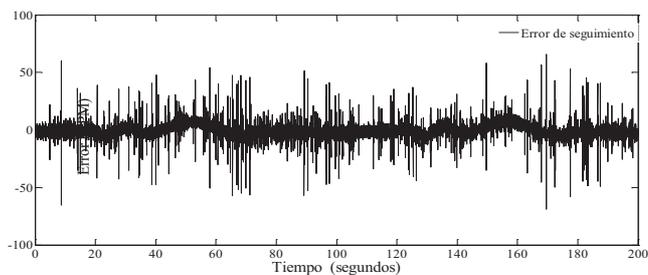


Figura 15. Error de seguimiento.

V CONCLUSIONES

La tarjeta de control dSPACE DS1104 es la encargada de aplicar la señal de control al módulo DL2637. Se verificó que las técnicas neuro-difusas están adaptadas a los sistemas de los modelos no lineales. Los aspectos más importantes a considerar y que son determinantes para obtener un buen modelo neuro-difuso 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 neuro-difuso obtenido se validó usando la técnica de extrapolación y en tiempo real, obteniéndose resultados satisfactorios. La aplicación del control con modelo interno basado en un modelo neuro-difuso fue un éxito. Los autores están animados para continuar este trabajo y aplicarle perturbaciones externas al motor de corriente directa.

AGRADECIMIENTOS

Los autores agradecen a la Universidad Autónoma del Carmen (UNACAR) por apoyar ésta investigación. El primer autor agradece a la UNACAR por la beca que le otorgó para realizar sus estudios de posgrado.

REFERENCIAS

- Chiasson J. and M. Bodson (1993). Nonlinear Control of a Shunt DC motor. *IEEE Transactions on Automatic Control*, 38, 11, 935-942.
- Babuska R.(1999). An overview of fuzzy modeling and model-based fuzzy control. *World Scientific Series in Robotics and Intelligent Systems*, 3-36.
- Pacheco J. G., Ruz-Hernandez J. A. and Shelomov E. (2003). "Técnicas Neurodifusas Aplicadas al Control del Equipo de la Bola y la viga". In *Proceedings of Seminario Anual de Automática, Electrónica Industrial e Instrumentación, SAAEI 2003*, Vigo Spain, pp. 1-6.
- Ruz-Hernandez J. A., Suarez-Cerda D.A., Shelomov E., and Villavicencio-Ramírez A. (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.
- A Allaoua B., Laoufi A., Gasbaoui B. and Abderrahmani A. (2009). "Neuro-Fuzzy DC Motor Speed Control Using Particle Swarm Optimization", *Leonardo Electronic Journal of Practices and Technologies*, Issue 15, pp. 1-18.
- Jang J. (1993), ANFIS: Adaptive-Network-Based Fuzzy Inference System, *IEEE Transactions on Systems, Man and Cybernetics*, 665-671.
- The Mathworks Inc. (2001). *Fuzzy Logic Toolbox User's Guide for Use with MATLAB User's Guide Versión 2*. U.S.A.
- Nauck D. (1999). Neuro-fuzzy methods, in *fuzzy Logic Control Advances in Applications*, H.B. Verbruggen and R. Babuska, Eds. New Jersey, USA: *World Scientific Series in Robotics and Intelligent Systems*, 65-86.
- Gonzalez-Gomez J. C., Ruz-Hernandez J. A. and García-Hernandez R. (2011). Identificación neuro-difusa en tiempo real: Aplicación a un motor de corriente directa, in *Memorias del Congreso Nacional de la Asociación de México de Control Automático*.
- Gonzalez-Gomez J. C., Ruz-Hernandez J. A., García-Hernandez R. and Sánchez-Camperos E. N. (2011). Real-time neuro-fuzzy inverse control for a dc motor, in *Proceedings of the 8th International Conference on Electrical Engineering, Computing Science and Automatic Control*.