

CONTROL DE SERVO SISTEMAS NO LINEALES USANDO REDES NEURONALES

Luis A. Ponce Dioses, Arturo Rojas Moreno, Luis G. Herrera Bendezú

Universidad Nacional de Ingeniería
Facultad de Ingeniería Eléctrica y Electrónica

RESUMEN

En este trabajo se plantea el problema de identificación y seguimiento de trayectoria de sistemas no lineales empleando redes neuronales. Los resultados teóricos se verifican mediante un estudio experimental en el cual el sistema no lineal está conformado por un servomotor DC de imán permanente con reducción que además tiene una varilla acoplada al eje del motor, a manera de un Brazo Robótico de un Grado de Libertad (BRIL), en donde la varilla es capaz de moverse en un plano perpendicular al eje del motor y es controlada por la tensión de armadura aplicada al servomotor.

ABSTRACT

This work deals with the identification and tracking problems in nonlinear systems employing neural networks. Theoretical results are validated via an experimental study that employs a nonlinear system consisting in a DC servomotor with permanent magnet and gear reduction mechanism. One end of a metal rod was attached to the shaft of the motor in order to build up a Robotic Arm with One Degree of Freedom (RA1F). In such a configuration, the metal rod is able to rotate in a perpendicular plane to the motor shaft and its angular position can be controlled by means of a voltage applied to the armature of the servomotor.

KEYWORDS

Redes Neuronales, Identificación, PID, Control Inteligente, Realimentación.

INTRODUCCIÓN

En este artículo se plantea el problema de identificación y seguimiento de trayectoria de sistemas no lineales empleando redes neuronales. La solución al problema propuesto se ha dividido en dos etapas. La primera etapa consiste en la identificación de los elementos no lineales del BRIL que son la fricción estática y la fricción de Coulomb, y la componente sinusoidal debido a la presencia de la varilla, que además es función de la posición angular del eje del servomotor. Estas dos no linealidades son identificadas por dos redes neuronales multicapa de alimentación directa, entrenadas mediante el algoritmo de retropropagación (backpropagation). El objetivo

de la identificación es linealizar el sistema BRIL utilizando una compensación por realimentación con la red neuronal. El sistema utilizado puede ser considerado como un sistema de primer orden si se desprecia el efecto de la inductancia de la armadura. Esta consideración se utiliza con el fin de tener acceso a los elementos no lineales del sistema BRIL, mediante una simple traslación de los mismos hacia la tensión de entrada del servomotor, pudiendo éstos eliminarse mediante una realimentación de compensación.

La segunda etapa consiste en la realización del control. Una vez linealizado el sistema, podemos diseñar cualquier tipo de control clásico. El controlador utilizado en este trabajo fue un PID.

El sistema experimental BRIL esta constituido, además del servomotor, por un sensor óptico de posición, un decodificador de cuadratura diseñado en un PLD (Dispositivo Lógico Programable), que también integra contadores y la interfaz a la PC para medir la posición absoluta del BRIL. El sistema es controlado mediante un driver de potencia PWM (Pulse Width Modulation) con configuración tipo H.

Para sintetizar al sistema se utilizó una PC con un procesador Pentium de 100 Mhz y una tarjeta de adquisición de datos. El Software se desarrolló en lenguaje C y consistió de los siguientes módulos: (1) identificación y control utilizando redes neuronales; (2) algoritmo de entrenamiento de la red neuronal (retropropagación); (3) visualización en tiempo real de los parámetros identificados.

En la sección II de este artículo se describen las redes neuronales utilizadas. La sección III describe el sistema a controlar. En la sección IV se deduce el algoritmo de identificación de los parámetros lineales y no lineales del sistema, y en la sección V se muestran los resultados.

REDES NEURONALES

Para la identificación de los elementos no lineales del motor se puede usar una red multicapa, con una capa de entrada, una de salida y dos capas ocultas, tal como se muestra en la Fig. 1. En la salida de cada elemento de una capa se empleó la función no lineal sigmoideal $\gamma = \frac{1 - e^{-x}}{1 + e^{-x}}$.

En la practica, esta red se usa para la identificación de sistemas estáticos. Los pesos de la red son ajustados con el algoritmo de retropropagación [1] [2] [3], el cual consiste en minimizar una adecuada función de error e entre la salida y de la red y una salida deseada y_d .

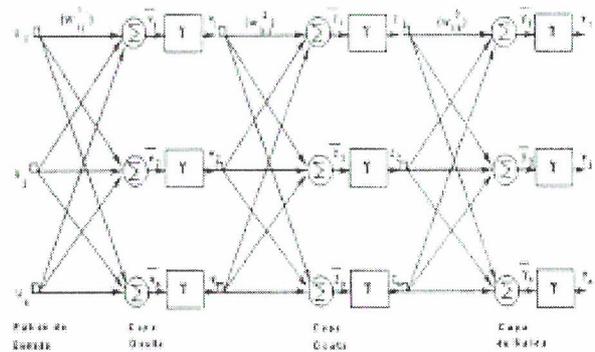


Figura 1: Una red neuronal de tres capas

Las rutinas de entrenamiento de la red fueron programado en "C". Las operaciones con matrices fueron implementadas en base a rutinas optimizadas Blas [4].

Las redes neuronales utilizadas poseen un elemento en la capa de entrada, 20 elementos en la primera capa oculta, 10 elementos en la segunda capa oculta y 1 elemento en la capa de salida.

DESCRIPCIÓN DEL SISTEMA A CONTROLAR

En esta sección se presenta una descripción del sistema implementado, el cual se muestra en la figura 2. También se realiza el modelamiento matemático de la planta. Para el control del BRIL se empleó un actuador que consiste de un servomotor DC de campo magnético permanente con escobillas conmutadas.

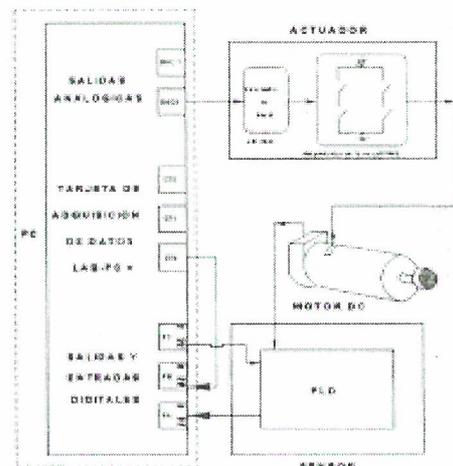


Figura 2: Esquema general del sistema implementado

Para accionar al actuador se construyó un driver PWM, cuya etapa de potencia consiste de 4 conmu-

tadores en configuración H. El esquema general del sistema de disparo y los conmutadores se muestran en la figura 3. Cuando el sistema de disparo cierra el conmutador A y abre el B, el sentido de la corriente sigue la línea de puntos, induciendo de esta forma una tensión $+V_{cc}$ en el motor. Si el sistema de disparo abre el conmutador A y cierra el B, el sentido de la corriente sigue la línea segmentada, induciendo así una tensión $-V_{cc}$ en el motor. Por consiguiente, el motor ve en sus bornes una onda de voltaje cuadrada, variando entre $\pm V_{cc}$, y la corriente que pueda absorber dependerá de los conmutadores.

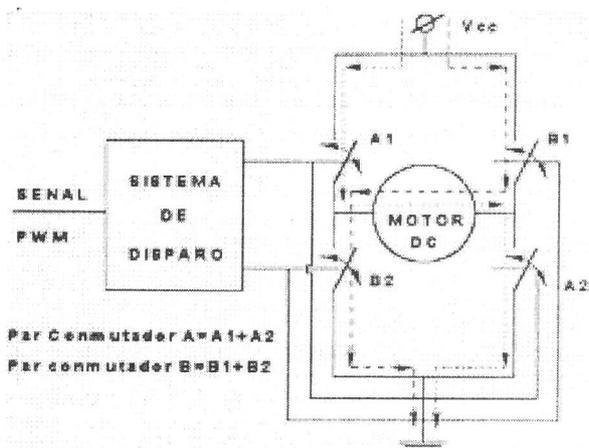


Figura 3: Esquema general del driver implementado.

Para realizar el sensado de posición y sentido de giro del motor se usó un codificador óptico montado en el motor. La información sensada se envía, a través de dos salidas seriales de tren de pulsos desfasados 90 grados, a un PLD EPM7128E de la familia MAX 7000, el cual tiene integrado un circuito sensor de posición que consiste de un LS7083 y 4 contadores de la serie 74193. Una tarjeta LAB-PC+ se usó para la adquisición de datos y manipuleo de la señal de control.

En la figura 4 se muestra un esquema general del BRIL. En este sistema se observan dos partes importantes: (1) un sistema mecánico y (2) un sistema eléctrico, donde

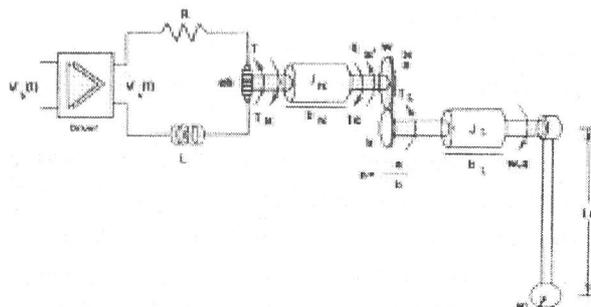


Figura 4: Esquema de la planta a controlar

J_M, J_L	Momento de inercia del motor y de la carga.
b_M, b_L	Coefficiente de fricción viscosa del motor y la carga
K_{AC}	Ganancia del actuador
m, L_0	Masa y longitud de la varilla.
$f(\cdot)$	Modelo el efecto de la fricción estática y de Coulomb.
V_a	Tensión de entrada en los bornes del motor
R, L	Resistencia e inductancia de armadura
e_b	Fuerza contra- electromotriz
K	Constante del par motriz
q	Posición de la varilla.
w	Velocidad angular de la varilla
$n = a/b$	Relación de engranajes o velocidades.

Considerando como positivo el movimiento de la varilla en sentido antihorario y despreciando la inductancia del motor ($L=0$), la ecuación diferencial que modela este sistema es la siguiente:

$$\left[J_{eff} + \frac{mL_0^2}{3n} \right] \dot{w} = \frac{V_b K K_{act}}{R} - \left[b_{eff} + \frac{nEK}{R} \right] w - \frac{gL_0 m}{2n} \sin(q) - f(nw) \quad (1)$$

donde :

$$J_{eff} = nJ_M + \frac{J_L}{n} \quad \text{y} \quad b_{eff} = nb_M + \frac{b_L}{n}$$

IV. IDENTIFICACIÓN DE PARÁMETROS

En esta sección se realiza la deducción matemática del algoritmo de identificación de los parámetros lineales y no lineales de motor. Primero consideraremos el caso de un motor sin carga usado para iden-

tificar la fricción estática y la de Coulomb usando una red neuronal NNT. Esta red identificada servirá como dato para la identificación de los parámetros de un motor con carga.

El problema de identificación consiste en encontrar un conveniente modelo de identificación para ajustar los parámetros del modelo vía la optimización de una función de costo basado en el error entre la planta y la salida del modelo de identificación. En [3] se muestran dos modelos de identificación: el paralelo y el serie-paralelo. El modelo serie-paralelo se ilustra en la figura 5 y se diferencia de la configuración en paralelo en que la salida de la planta es realimentada al modelo de identificación. Para la figura 5, el modelo de identificación tiene la forma:

$$\hat{y}_p(k+1) = \hat{\alpha}_0 y_p(k) + \hat{\alpha}_1 y_p(k-1) + NN[u(k)] \quad (2)$$

El modelo serie - paralelo tiene varias ventajas sobre el modelo paralelo. Desde que la planta se asume que es estable y con salida y entrada acotada, entonces todas las señales usadas en el procedimiento de identificación (por ejemplo, entradas a la red neuronal) serán acotadas. Además, desde que no existe un lazo de realimentación en el modelo, puede usarse el algoritmo de entrenamiento retropropagación estática para ajustar los parámetros de la red, reduciendo así substancialmente los cálculos computacionales. Sin embargo, si se asume que el valor de salida tiende asintóticamente a pequeños valores, el modelo serie - paralelo puede ser reemplazado por el paralelo.

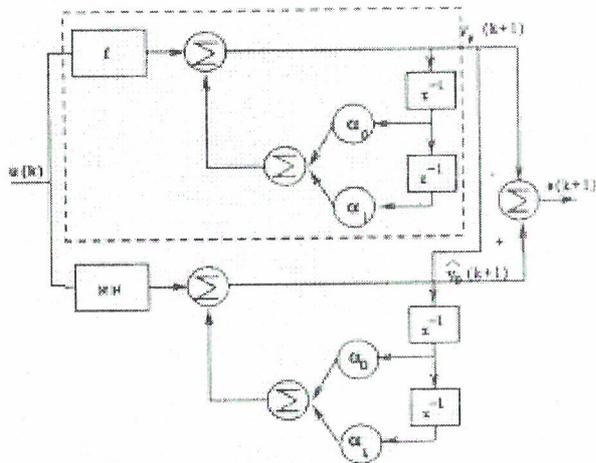


Figura 5: Modelo de identificación serie-paralelo

A. Identificación de los parámetros lineales y no lineales del motor sin carga

Asumiendo despreciable la inductancia del motor y considerando la masa de la varilla igual a cero para el motor sin carga, la ecuación diferencial de este sistema es la siguiente:

$$J_{eff} \dot{\omega} = \frac{V_b KK_{act}}{R} - \left(b_{eff} + \frac{nEK}{R} \right) \omega - f(n\omega) \quad (3)$$

Discretizando (3) se obtiene la ecuación:

$$\omega_{k+1} = \left[1 - \frac{TS}{J_{eff}} \left(b_{eff} + \frac{nEK}{R} \right) \right] \omega_k + \frac{KK_{act} TS}{RJ_{eff}} \left[V_{bk} - \frac{Rf(n\omega_k)}{KK_{act}} \right] \quad (4)$$

donde $f(n\omega_k)$ se modela como $C \text{Sgn}(n\omega_k)$ para las simulaciones. La ecuación (4) se puede escribir en una versión simplificada, tal como se muestra en la ecuación (5).

$$\omega_{k+1} = G_1 \omega_k + G_2 \{ y_{bk} + G_3 \text{Sgn}(n\omega_k) \} \quad (5)$$

Ahora asumiremos que no se conocen los parámetros lineales G_1 y G_2 del modelo matemático del motor. Entonces definiremos \hat{G}_{1k} , \hat{G}_{2k} y ω_k como los parámetros lineales y la velocidad angular respectivamente, estimados en el k-ésimo instante de tiempo, los cuales se encuentran relacionados por la siguiente ecuación:

$$\hat{\omega}_{k+1} = \hat{G}_{1k} \omega_k + \hat{G}_{2k} \{ V_{bk} + NNT(n\omega_k) \} \quad (6)$$

donde $NNT(n\omega_k)$ es la salida de la red neuronal para una entrada discreta $n\omega_k$. La función de NNT es identificar a $\frac{Rf(n\omega_k)}{KK_{act}}$. Si el error en el instante k se define como la diferencia entre la velocidad angular real y la estimada:

$$e_k = \hat{\omega}_k - \omega_k \quad (7)$$

entonces el objetivo de identificación se reduce a minimizar el error e_k utilizando algún método de optimización. El método seleccionado, por su simplicidad, fue el **algoritmo del gradiente**. Este algorit-

mo minimiza la función de costo $J = \frac{e_k^2}{2}$ en función de los parámetros estimados:

$$\Theta_{k+1} = \begin{bmatrix} \hat{G}_{1k+1} \\ \hat{G}_{2k+1} \end{bmatrix} \quad (8)$$

donde $\Theta_k = [\hat{G}_{1k} \ \hat{G}_{2k}]^T$ es el vector de los parámetros identificados. La ley de identificación del vector Θ_k es de forma tal que la función de costo se minimiza en cada k-ésimo instante de tiempo, de modo que

$$\begin{bmatrix} \hat{G}_{1k} \\ \hat{G}_{2k} \end{bmatrix} = \begin{bmatrix} \hat{G}_{1k-1} \\ \hat{G}_{2k-1} \end{bmatrix} - \begin{bmatrix} g_1 & 0 \\ 0 & g_2 \end{bmatrix} \frac{\partial J}{\partial \Theta_{k-1}} \quad (9)$$

donde $\begin{bmatrix} g_1 & 0 \\ 0 & g_2 \end{bmatrix}$ es la matriz de velocidad de identificación y $g_1, g_2 > 0$ son los parámetros de velocidad de identificación que permiten variar la velocidad de convergencia. Si:

$$\begin{aligned} \frac{\partial J}{\partial \Theta_{k-1}} &= \frac{\partial J}{\partial e_k} \frac{\partial e_k}{\partial \Theta_{k-1}} = e_k \frac{\partial e_k}{\partial \Theta_{k-1}} \\ &= -e_k \begin{bmatrix} \omega_{k-1} \\ V_{bk-1} + \text{NNT}(n\omega_{k-1}) \end{bmatrix} \quad (10) \end{aligned}$$

se obtiene entonces la siguiente ley de identificación discreta:

$$\begin{bmatrix} \hat{G}_{1k} \\ \hat{G}_{2k} \end{bmatrix} = \begin{bmatrix} \hat{G}_{1k-1} \\ \hat{G}_{2k-1} \end{bmatrix} + \begin{bmatrix} g_1 & 0 \\ 0 & g_2 \end{bmatrix} \begin{bmatrix} \omega_{k-1} \\ V_{bk-1} + \text{NNT}(n\omega_{k-1}) \end{bmatrix} e_k \quad (11)$$

B. Identificación de los parámetros lineales y no lineales del motor con carga

El modelo matemático de este sistema se muestra en la ecuación (1) y la discretización de este modelo se presenta en la ecuación (12):

$$\begin{aligned} \omega_{k+1} &= \left[1 - \frac{T_s \left(b_{eff} + \frac{nEK}{R} \right)}{J_{eff} + \frac{mL_0^2}{3n}} \right] \omega_k + \frac{T_s KK_{act}}{R \left[J_{eff} + \frac{mL_0^2}{3n} \right]} \\ &\quad \left[V_{bk} - \frac{RgL_0 m}{2nKK_{act}} \sin(q_k) - \frac{RC}{KK_{act}} \text{Sgn}(n\omega_k) \right] \quad (12) \end{aligned}$$

Para la identificación de los parámetros lineales se debe deducir un ley de identificación para G_1 y G_2 que es similar a la que se hizo en la sección IV-A. Reescribiendo la ecuación (12) como:

$$\omega_{k+1} = G_1 \omega_k + G_2 \{ V_{bk} + G_4 \sin(q_k) + G_3 f(n\omega_k) \} \quad (13)$$

se observa que existen dos no linealidades: $G_4 \sin(q_k)$ y $G_3 f(n\omega_k)$, de las cuales la segunda ha sido identificada en la sección anterior por la red NNT. Ahora se debe encontrar una red NNTI que identifique la primera no linealidad. La velocidad angular estimada ω_{k+1} se puede escribir como sigue:

$$\omega_{k+1} = \hat{G}_{1k} \omega_k + \hat{G}_{2k} \{ V_{bk} + \text{NNTI}(q_k) + \text{NNT}(n\omega_k) \} \quad (14)$$

Si comparamos las ecuaciones (13) y (14) con (5) y (6) respectivamente, se deduce fácilmente la siguiente ley de identificación:

$$\begin{aligned} \begin{bmatrix} \hat{G}_{1k} \\ \hat{G}_{2k} \end{bmatrix} &= \begin{bmatrix} \hat{G}_{1k-1} \\ \hat{G}_{2k-1} \end{bmatrix} + \begin{bmatrix} g_1 & 0 \\ 0 & g_2 \end{bmatrix} \\ &\quad \begin{bmatrix} \omega_{k-1} \\ V_{bk-1} + \text{NNTI}(q_{k-1}) + \text{NNT}(n\omega_{k-1}) \end{bmatrix} e_k \quad (15) \end{aligned}$$

V. RESULTADOS EXPERIMENTALES

En esta sección se presentan los resultados experimentales obtenidos, los cuales son comparados con modelos matemáticos deducidos.

Para entrenar a la red neuronal hay que excitar el sistema con una señal que realice un mapeo total. Es decir, se debe elegir un conjunto de entrada \mathbf{I} que produzca un conjunto de salidas \mathbf{S} , de tal forma que \mathbf{I} y \mathbf{S} se distribuyan uniformemente en el conjunto de entradas y salidas del sistema, respectivamente. Para nuestro sistema, la tensión de entrada se encuentra

entre [-1.53, 1.37] Volt. Se realizaron experiencias con tres tipos de señales: (1) escalones con amplitudes variando dentro del rango de entrada y tiempo de duración variable para cada escalón; (2) escalones con amplitudes variando dentro del rango de entrada y tiempo de duración fijo; (3) sinusoides con amplitudes variables y periodo fijo. Para el entrenamiento se eligió el segundo tipo de señal; el criterio de elección fue la velocidad de aprendizaje de la red y el periodo de las señales de entrenamiento se eligió por el método de prueba y error, teniendo como valor inicial la frecuencia de resonancia del BR1L, linealizado alrededor de $q=0$.

Se eligió 30 valores fijos de tensiones uniformemente distribuidos para el conjunto **I**, los cuales produjeron un conjunto de velocidades $S \in [-37, 37] \text{Rad s}^{-1}$ que es el rango de salida. Por consiguiente, la señal de excitación resulta un tren de escalones cuyas amplitudes se encuentran aleatoriamente distribuidas en cada conjunto **I**. Para la identificación de $G_y f(n\omega_k)$, cada escalón tienen una duración de 0.5 seg. y para $G_4 \sin(q_k)$ los escalones tiene una duración de 2 seg., produciendo una velocidad que incluye un estado transitorio y uno estacionario, tal como se muestra en la figura 6.

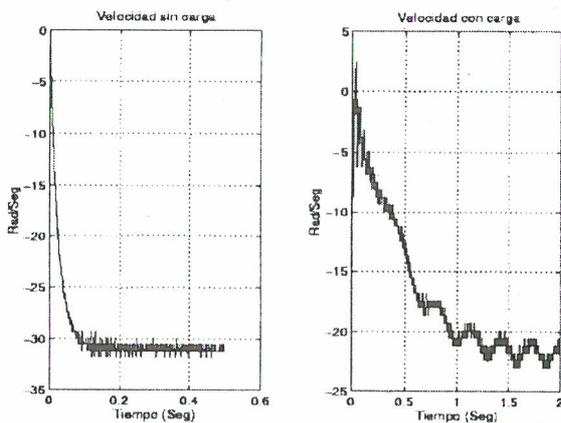


Figura 6: La primera figura muestra la velocidad de salida sin carga en el motor y la segunda con carga.

Para comprobar el aprendizaje de la red, se excitó al sistema, sin actualizar los pesos de la red, con un tren de escalones con amplitudes distribuidas en un conjunto de entrada **I** (distinto al de entrenamiento). Podemos definir un error cuadrático promedio por fase como:

$$E_f = \frac{\sum_{k=1}^N e_k^2}{N} \quad (16)$$

donde N es el número de muestras por fase y e_k es el error por muestra.

A. Identificación de la fricción Estática y de Coulomb

Utilizando la ley de identificación de la ecuación (11) se obtuvieron los resultados que a continuación se detallan.

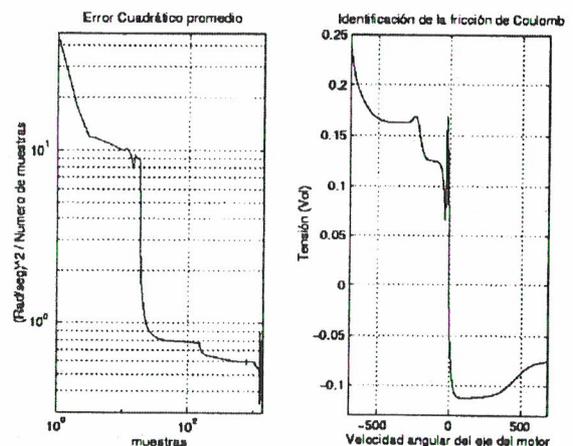


Figura 7: La primera figura muestra el error cuadrático promedio durante el entrenamiento y la segunda la fricción de Coulomb identificada.

En la Fig. 7 se observa que el error cuadrático por muestra se reduce hasta un valor de 0.3, en donde se ha tomado en cuenta un ruido de cuantificación cuando se calculó la velocidad a partir de la posición (ver Fig. 6). El modelo de identificación tiene como salida el promedio de la velocidad a identificar. En la Fig. 7 se muestra también la identificación de la fricción de Coulomb; es claro observar que el torque de fricción tiene distintos valores para cada velocidad. También se muestra que la red es capaz de identificar el offset de la señal de entrada, obser-

* Números de entrenamientos

vando la asimetría en la señal identificada.

B. Identificación de la componente sinusoidal, efecto de la varilla

Utilizando la ley de identificación de la ecuación (15) y la red neuronal NNT de la sección anterior, se realizó la identificación de los componentes lineales de la ecuación (14) y de la red neuronal (NNT1) que identificará a la componente sinusoidal, debido al efecto de la dinámica de la varilla. Se probaron 3 posibles señales de entrada para entrenar a la red NNT1. Primero, una señal escalón de periodo 2 seg., cuyas amplitudes se encuentran distribuidas en dos conjuntos de entrada **I** mencionados en la sección V. Segundo, una señal sinusoidal, cuyas frecuencias, se encuentran distribuidas en un ancho de banda alrededor de la frecuencia de resonancia del sistema linealizado alrededor de $\theta=0$. Se tomó el criterio de -3dB para el cálculo de las frecuencias iniciales y finales de este ancho de banda. Las amplitudes se encuentran distribuidas en el primer conjunto. Tercero, se combinaron las señales anteriores, para generar una nueva señal de entrada. Esto se realizó intercalando el primer conjunto con el segundo. Con el primer conjunto de entrenamiento se obtuvo mejores resultados con respecto a la velocidad de convergencia en la identificación de los parámetros lineales y no lineales.

Otro punto importante que hay que tomar en cuenta es la señal de entrada a NNT1. El método de actualización de pesos empleado (retropropagación) sirve sólo para sistemas estáticos. En nuestro caso, a partir del modelo matemático del sistema se deduce fácilmente que la no linealidad a identificar

$\left(\frac{R_g L_0 m}{2n K K_{act}} \sin(q_k) \right)$ es una función estática en el rango de $[0, 2\pi]$. En forma práctica, la posición es derivada a partir de la velocidad del eje de la carga. Por tanto, se puede aprovechar la periodicidad de la función sinusoidal para acotar la posición del eje de la carga en el rango de $[0, 2\pi]$; es decir, limitarla. En la figura 8 se muestra la señal identificada por la red neuronal NNT1; la señal de entrada a esta red es la posición del eje de la carga limitada entre $[0, 2\pi]$. Esta red identificó la no linealidad producida por la varilla en el eje de la carga. En este gráfico se observa el efecto de NNT (red que identificó la fricción de Coulomb) sobre la identificación de NNT1. Aquí se observa qué tan sensible es la identificación de NNT1 ante disturbios externos*.

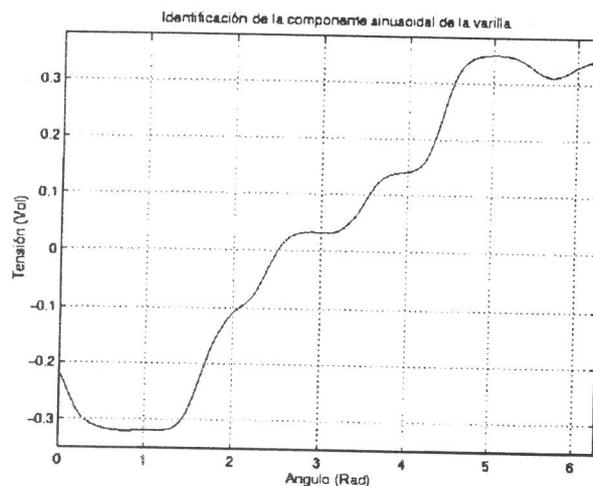


Figura 8: Señal identificada por la red neuronal NNT1.

En el primer gráfico de la figura 9 se muestra el error por muestra al final del entrenamiento, que se realizó sin actualizar los pesos de la red. Aquí se observan unos picos de error de hasta 10 rad/seg; esto se debe

* Cabe hacer la observación que NNT identificó a la fricción de Coulomb con un error que es el que esta produciendo la distorsión. Simulaciones sin considerar a NNT, produjeron una señal senoidal identificada sin distorsiones.

a que la red ha promediado un ruido transitorio debido al cambio de posición de la varilla de una posición a otra. Este ruido transitorio se puede observar en los primeros segundos del segundo gráfico de la figura 6. En el segundo gráfico de la figura 9 se observa el error cuadrático promedio que se calcula después de cada fase de entrenamiento, sin actualizar los pesos de la red, utilizando la ecuación (16).

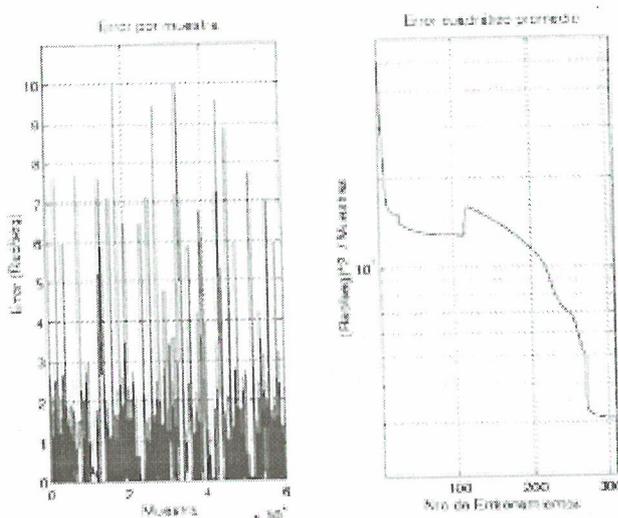


Figura 9: En la primera figura se muestra el error por muestra al final del entrenamiento. En la segunda figura, se observa el error cuadrático promedio durante el entrenamiento.

C. Control PID

Es claro observar en las ecuaciones (5) y (13) que los torques no lineales $G_4 \sin(q_k)$ y $G_3 f(n\omega_k)$ han sido trasladados hacia la tensión de entrada del sistema para tener acceso a ellos. Entonces, la eliminación de estas no linealidades puede ser realizada por una realimentación de compensación. Es decir, generando una tensión de igual magnitud que $G_3 f(n\omega_k)$ y $G_4 \sin(q_k)$ pero de signo contrario, de tal manera que al adicionarlas a la tensión de entrada, elimine los torques de fricción no lineal. Las redes neuronales NNT y NNT1 se utilizaron para realizar esta realimentación de compensación.

1. Compensación neuronal

El primer gráfico de la figura 10 muestra la velocidad del motor sin carga para una entrada

$0.5 \sin\left(\frac{2\pi t}{3}\right)$ sin utilizar compensación; el segundo gráfico compensa esta no linealidad. Se observa que la velocidad aumenta y desaparece la zona muerta del motor. En el tercer gráfico de la figura 10 se muestra la velocidad del motor con carga para una entrada $\sin(\pi)$ sin compensar; en el cuarto gráfico se muestra el efecto de la compensación del sistema.

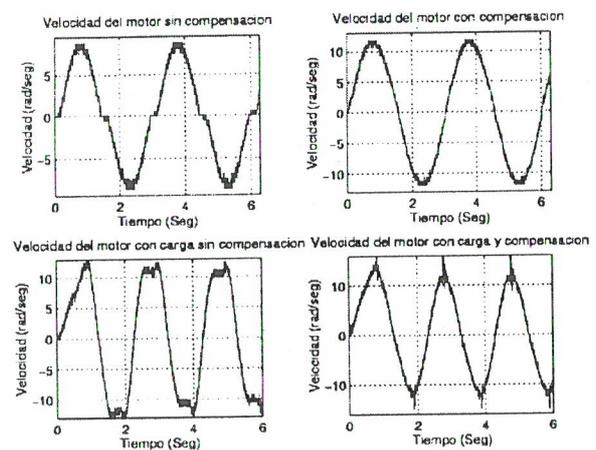


Figura 10: Compensación neuronal del motor con y sin carga.

2. Control PID del motor sin carga

En el gráfico de la figura 11 se muestra la respuesta del motor sin carga. En el primer gráfico se observa el efecto de la zona muerta del motor y en el segundo se muestra su compensación. La trayectoria a seguir es $r = 0.8t - 3\sin(3t)$ para el tiempo $0 \leq t \leq 5$. Los parámetros lineales convergieron a los valores $G_1 = 0.9604$ y $G_2 = 0.9546$

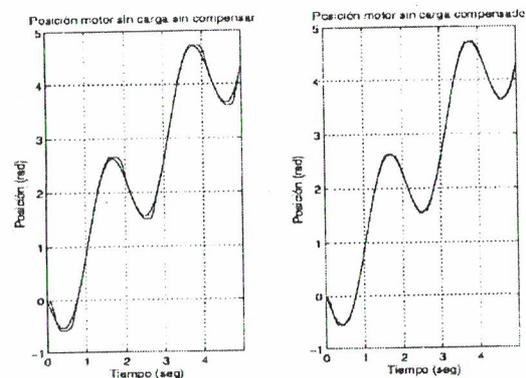


Figura 11: Control PID de un motor sin carga.

3. Control PID del motor con carga

En el gráfico de la figura 12 se muestra la respuesta del control del motor con carga. En el primer gráfico se muestra la respuesta sin compensación y en el segundo gráfico se muestra su compensación. La trayectoria a seguir es $r = 0.8t - 2.5\sin(3t)$ para el tiempo $0 \leq t \leq 5$. Para el control se sintonizaron los parámetros del controlador en ambas experiencias. Los parámetros lineales convergieron en valores $G_1 = 0.9973$ y $G_2 = 0.0416$.

Motor	Error cuadrático medio
Sin compensación	0.0071
Con compensación	0.0036

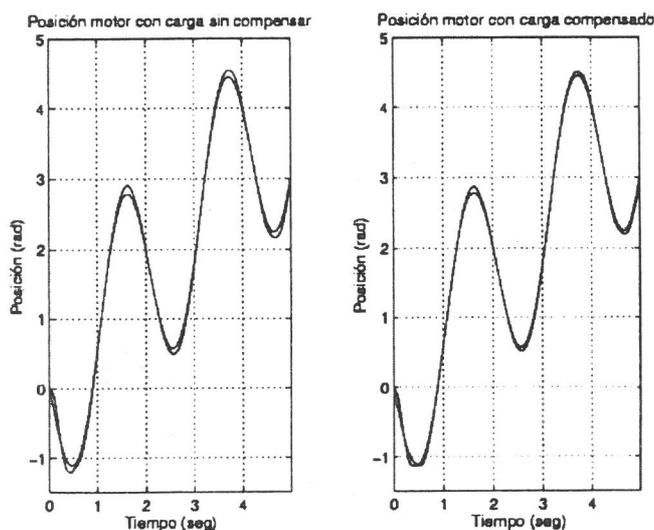


Figura 12: Control PID de un motor con carga.

La compensación disminuyó el error cuadrático medio (ecuación (16)) de seguimiento de la trayectoria en la mitad, tal como se observa en la tabla 1. En la figura 13 se muestran estos errores.

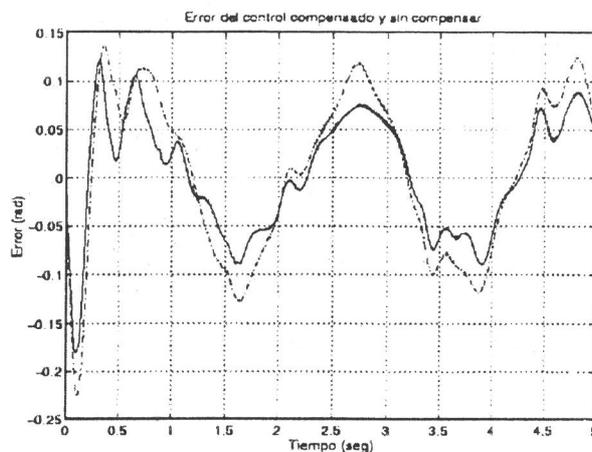


Figura 13: Error en el seguimiento de la trayectoria para un motor con carga. La línea continua muestra el error utilizando compensación y la punteada sin compensación.

CONCLUSIONES

En este trabajo se ha demostrado que las redes neuronales son capaces de identificar elementos no lineales tales como la fricción de Coulomb y la componente sinusoidal debido a la varilla. Se demostró también que la velocidad puede ser hallada a partir de la posición, a pesar del error de cuantificación (resolución) del sensor. Como hemos visto, la red neuronal promedia este error cuando se realiza la identificación. De los parámetros identificados, se verificó que la dinámica introducida por la inductancia de la armadura del motor se pudo despreciar en el diseño, lo cual redujo en uno el orden del modelo.

AGRADECIMIENTOS

A CONCYTEC por su apoyo mediante el programa nacional de electrónica (PRONACEM).

REFERENCIAS

1. **James A. Freeman / David M. Skapura**, Redes Neuronales. Algoritmos, aplicaciones y técnicas de programación. Addison Wesley Iberoamericana, S. A. 1993.

2. **Simon Haykin**, **Neural Networks**, Macmillan College Publishing Company, Inc 1994.
3. **Kumpati S. Narendra and Kannan Parthasarathy**, Identification and Control of Dynamical Systems Using Neural Networks, IEEE Transactions on Neural Networks. Vol. I. No. 1, March 1990.
4. **Octave**, Software para cálculos matemáticos. University of Wisconsin-Madison, <ftp://ftp.che.wisc.edu/pub/octave>.
5. **Astrom, K.J. and Wittenmark B.**, Computer Controlled Systems: Theory and Desing. Prentice Hall, 2da edición, 1990.
6. **Priyadarshee D. Mathur**, Servo Desing for High-Speed Low-Tension Tape Transport. Carnegie Mellon University, Pittsburgh, Pennsylvania, December 1994.