

# Red neuronal para la caracterización no lineal de un motor de corriente directa

Méndez Navarro Alejandro, *Member, IEEE*. Sánchez Madrigal José Eduardo, *Student Member, IEEE*, Alfaro Aguilar Gemayel Efrén, *Student Member, IEEE*

<sup>1</sup>Instituto Tecnológico de Estudios Superiores de Zamora  
 Departamento de Ingeniería Electrónica  
 Km. 7 Carretera Zamora-La Piedad, Zamora, Michoacán. MEXICO, CP. 59720  
[alex\\_mendez\\_navarro@live.com](mailto:alex_mendez_navarro@live.com)

## Resumen

Los sistemas físicos analizados en una primera instancia en control automático son los sistemas: dinámicos, lineales, invariantes en el tiempo, monovariantes de parámetros concentrados, continuos y de naturaleza determinística.

El objetivo de la teoría de control es dado un sistema físico (planta) cuyo conjunto de señales de salidas medidas  $v$ , determinar acciones de control  $u$  (controlador) para que las variables controladas y sigan de la mejor manera a las señales de referencia  $r$ ; esto a pesar de la influencia de parámetros desconocidos, cambios en el ambiente de trabajo (perturbación  $w$ ), las dinámicas no modeladas, presencia de no linealidades (saturación, zona muerta, cuantización tanto en los sensores como en los actuadores) e incertidumbres (ruido  $n$ ); llamados problemas de robustez (un problema común para muchos procesos de tecnología moderna) [1],[2] y [3].

Todo sistema físico capaz de ser modelado o caracterizado matemáticamente a partir de la(s) variable(s) de interés (valor(es) de referencia) tiene un alto grado de factibilidad de ser controlado debido a que se conocerá una aproximación precisa de la dinámica del sistema; hay que recordar que los sistemas físicos por naturaleza presentan no linealidades en su dinámica tales como varianzas en tiempo, saturaciones, fricciones, fuerza de gravedad, y demás; de allí que el modelado o caracterizado sea un desafío, debido a esto la mayor parte de los análisis de los sistemas se hacen en regiones lineales o un punto de trabajo específico<sup>1</sup>.

En este artículo se demuestra la forma de caracterizar no linealidades del motor de CD con el fin de obtener control del mismo.

**Palabras clave:** Control no lineal, motor corriente directa, red neuronal, caracterización de sistemas.

## 1. Introducción

Existen dos clases de motores eléctricos de corriente continua: rotor devanado de imán permanente y jaula de ardilla. En este artículo se presenta una red neuronal del tipo "Perceptrón Multicapas" para caracterizar la respuesta del motor de corriente continua de devanado de armadura y devanado de rotor. [Fig. 1]




Fig. 1. Red neuronal multicapa.

El motor empleado la ecuación eléctrica y mecánica es una clase particular de motores de corriente continua que permite utilizar las características que ofrecen los fabricantes. Se trata de un modelo matemático lineal exceptuando la componente no lineal del motor de corriente continua: la fricción; recordando que la fricción es una componente variante con el tiempo, es decir; no lineal.

## 2. Modelación matemática

Una red neuronal artificial (RNA) es un sistema compuesto de muchos elementos de procesamiento simples operando en paralelo cuya función es

<sup>1</sup> Series de Taylor 
$$f(t) = \sum_{n=0}^{\infty} \frac{f^{(n)}(a)}{n!} (t - a)^n$$

determinada por la estructura de la red, por las conexiones y por el desempeño del procesamiento de los elementos de cómputo o nodos [4], [5]. [Fig. 2]




Fig. 2. Diagrama a bloques de una red neuronal artificial. (RNA)

La neurona es la unidad básica de procesamiento de información de una red neuronal, donde la salida  $y_k$  puede ser escrita como se expresa en la ecuación 1. [4], [5]

$$y_k = \sigma \left( \sum_{j=1}^n \omega_{jk} x_j + b_k \right) \quad (1)$$

donde  $x_1, x_2, \dots, x_n$  son las señales de entrada,  $\omega_{k1}, \omega_{k2}, \dots, \omega_{kn}$  son los pesos sinápticos correspondientes a la neurona  $k$ ,  $b_k$  es el umbral y  $\sigma(\cdot)$  es la función de activación [4], [5].

Para el caso de una red neuronal multicapa con conexiones hacia adelante la salida  $y_k$  puede ser escrita como en la ecuación 2:

$$y_k = \sigma \left( \sum_{j=1}^{N_2} \omega_{jk} \sigma \left( \sum_{i=1}^{N_1} v_{ji} x_i + v_{j0} \right) \right) \omega_{k0} \quad (2)$$

En la figura 1 se muestra el diagrama a bloques de una red neuronal multicapa. La aplicación de las redes neuronales ha tenido gran éxito en aplicaciones tales como la clasificación, reconocimiento de patrones, en el procesamiento digital de señales. Desde el punto de vista de la teoría de control, la habilidad de las redes neuronales es tratar con sistemas no lineales (la componente fricción de un motor de CD visto de manera no lineal) y la propiedad de aproximación de funciones son quizás las más importantes. [Fig. 3],




Fig. 3. RNA aplicada a la teoría de control.

Una de las metodologías para modelar el motor de CD es mediante dos ecuaciones diferenciales: eléctrica y mecánica [Fig. 4].




Fig. 4. Esquemático de un motor de C.D.

$$e_a(t) = L_a \frac{di(t)}{dt} + R_a i(t) + v_b(t) \quad (3)$$

$$\tau_m(t) = J \frac{d^2 \theta_m(t)}{dt^2} + \tau_l(t) + \tau_f(t) \quad (4)$$

Las variables y parámetros que describen al sistema son:

$e_a(t)$	voltaje aplicado al motor	[V]
$i(t)$	corriente eléctrica	[A]
$\theta_m$	posición angular del eje del motor	[rad]
$v_b(t)$	fuerza contraelectromotriz <sup>2</sup>	[fcm]
$\tau_m(t)$	par del motor <sup>3</sup>	[Nm]
$\tau_l(t)$	par de carga visto desde el eje del motor	
$\tau_f(t)$	par de fricción	
$L_a, R_a, J$	inductancia, resistencia y momento de inercia	[H, $\Omega$ , kgm <sup>2</sup> ]

Los motores a considerar satisfacen además las ecuaciones de acoplo electromecánico siguiente:

$$\tau_m(t) = k_m i(t) \quad (5)$$

$$e_b(t) = k_b \dot{\theta}_m(t) \quad (6)$$

donde

$k_m$	constante del par	[Nm/A]
	constante de la fuerza	[Vseg/rad]
$k_b$	contraelectromotriz	

En este trabajo presentamos una red neuronal del tipo perceptrón para caracterizar la respuesta del motor de CD, donde dicha red

<sup>2</sup> La energía eléctrica transformada en energía mecánica por cada unidad de carga que circula

<sup>3</sup> Es el momento de fuerza que ejerce un motor sobre el eje de transmisión de potencia.

neural es entrenada para aproximar todo el intervalo de operación del motor empleado. [Fig. 5]

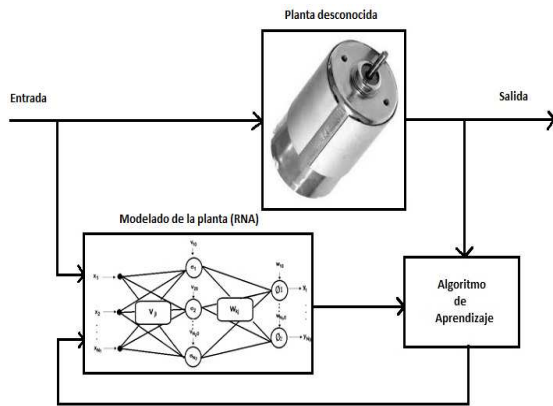


Fig. 5. Caracterización de un motor de C.D por RNA.

Cuando se utilizan polinomios, para cubrir un intervalo se utilizarían tres polinomios distintos  $f_1$ ,  $f_2$  y  $f_3$ , como se ve en la figura 6.


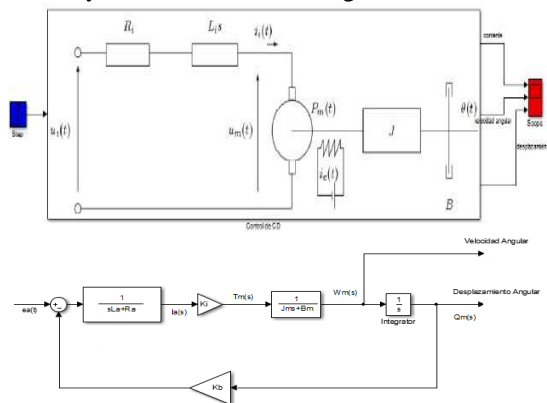


Fig. 6. Caracterización del motor CD.

Lo cual genera un polinomio de grado 9 [Fig. 7]; para controlar dicho sistema se tendría que aplicar un control de switcheo. Lo que generaría un control robusto y por consiguiente el problema del

controlabilidad y observabilidad resultarían complicados.

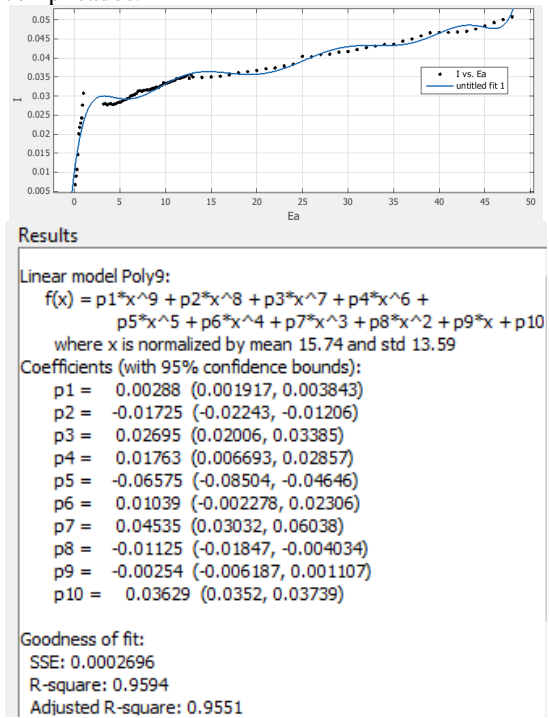


Fig. 7 “Curve Fitting Tool” para un motor de CD.

Para evitar lo anterior se propone un modelo por medio de redes neuronales que permita el reconocimiento de ciertos patrones con el fin de caracterizar plantas físicas no lineales de una manera muy sencilla; como se analizara en la siguiente sección.

### 3. Resultados obtenidos

Se utilizó una red neuronal construida en la plataforma MATLAB/Simulink de tipo Perceptrón Multicapas con Backpropagation. [Fig. 8].




Fig. 8. Perceptrón Multicapas con Backpropagation

Esta consta de dos capas una de 5 neuronas tipo “tansig” y la otra consta de una neurona tipo “purelin” [Fig. 9]. Que son las que efectúan el cálculo de la corriente de acuerdo al voltaje registrado.

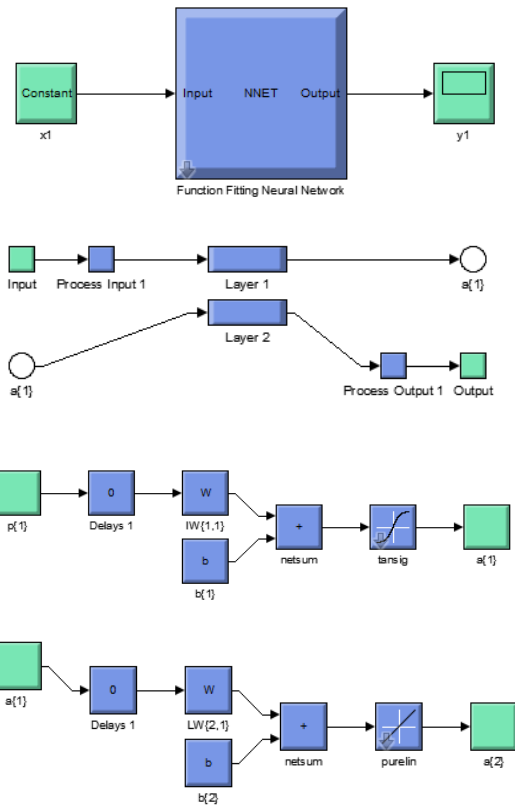


Fig. 9. RNA de dos capas en SIMULINK.

Para entrenar la red neuronal se reunieron los datos del voltaje aplicado al motor  $E_a$  y la corriente  $I$ . Las características de fábrica del motor de CD, son las siguientes [ver Tabla 1]:

Tabla 1. Características mecánicas eléctricas de motor de CD.

Modelo:	EM-529 RS445PA14233R
Voltaje:	12-42V
Corriente:	60mA - 1.47A
Potencia:	7.78W
Torque:	81.8 mNm
6500 rpm	
Diámetro del eje:	3.17mm
Diámetro del motor:	30mm
Longitud del motor:	67mm

Para crear esta red neuronal se requiere una datos para el entrenamiento, (entradas  $E_a$ ), y resultados objetivos, como (target  $I$ ); se utiliza el comando *nftool* de la plataforma *MATLAB*. [Fig. 10]

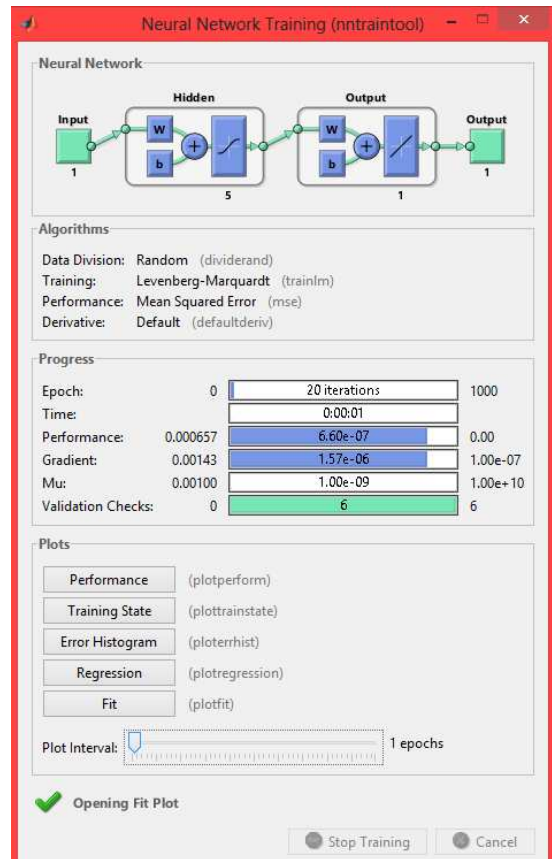


Fig. 10. RNA de dos capas en SIMULINK.

Se entrenó la red neuronal artificial con lo cual da resultados con un error muy pequeño como se muestra a continuación:

a) Si damos click en “Performance” se grafican los errores entrenados, un test de errores y la validación de los errores, se observa que en la época 14 donde es la mejor validación.




Fig. 11. Performance de la RNA.




Fig. 12. Training State de la RNA.

Con la opción “Training State” es otra manera de comprobar si los valores determinan si los datos es mala, o si esos puntos de datos son diferentes que el resto de la conjunto de datos. Si los valores atípicos son puntos de datos válidos, pero son a diferencia del resto de lade datos, entonces la red es siempre disponible para la extrapolación de puntos. Para esto de reconocen los datos que se parecen que se parece a los puntos atípicos y por lo siguiente reciclar a la red. [Fig. 12].

Otra manera de estudiar el comportamiento de la eficiencia del entrenamiento de la red neuronal es mediante el histograma de errores, el cual se muestra en la Fig. 13, en ella se observa que son pocos los datos que tienen errores significativos, correspondientes a  $\{-0.00044, -0.000023, 0.0000397\}$  cuales seguramente necesitaban adiconar otros tipos de datos de entrada.




Fig. 13. Error histogram de la RNA.

Las regresión lineal muestran que el sigue las salidas de la red con respecto los objetivos de formación, validación y equipos de prueba. Para un ajuste perfecto, los datos. En caso de caída a lo

largo de una línea de 45 grados, donde las salidas de la red son iguales a los objetivos. Si hace click en “Regression” se puede realizar una regresión lineal entre las salidas de la red y de los objetivos correspondientes, [Fig. 14].

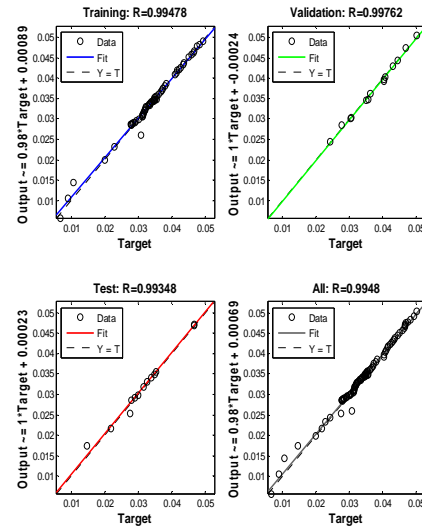
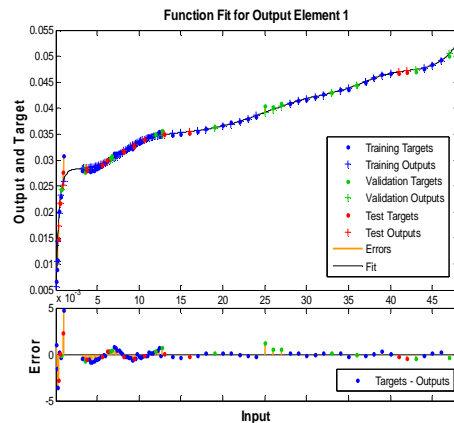


Fig. 14. Regression de la RNA.

Si no está satisfecho con el rendimiento de la red en el original o nuevos datos, puede realizar una de las que el sigue:

- Formar de nuevo.
- Aumentar el número de neuronas.
- Obtener un conjunto de datos de entrenamiento más grande.

Si el rendimiento del conjunto de entrenamiento es bueno, pero el rendimiento de prueba significativamente peor es, lo que podría indicar es un sobreajuste para eliminar esto se reduce el número de neuronas para que mejore sus resultados. Si el rendimiento del entrenamiento es pobre, entonces es posible que desee aumentar el número de neuronas.



**Fig. 15. Fit de la RNA.**

El rendimiento de la red neuronal propuesta en la figura 8 es buena como se observa en la figura 14, ya que se ha caracterizado la respuesta del motor añadiendo el parámetro no lineal de la fricción (ver ecuación 3,4) evitando así un polinomio de grado 9.

#### 4. Conclusiones

La aplicación de este tipo de red neuronal no implica ecuaciones complejas para su desarrollo. El margen de error alcanzado es de 0.01. Para obtener un menor error, se debe entrenar más la red neuronal. Con esta técnica es posible caracterizar cualquier sistema no lineal. Una red neuronal contiene funciones de activación los cuales son funciones que pueden derivarse múltiples veces. El entrenamiento de la red neuronal exige por el momento un proceso fuera de línea. Esto implica que el entrenamiento y el cómputo de los polinomios se llevarán a cabo en un sistema de cómputo diferente al cual se usará en las aplicaciones.

#### 5. Referencias

- [1] Kuo, B.C., "Sistemas de Control Automático", Séptima edición, Prentice-Hall.
- [2] Ogata, K., "Ingeniería de Control Moderna", Cuarta edición, Pearson, Prentice Hall.
- [3] Ogata, K., "Sistemas de control en tiempo discreto", Cuarta edición, Pearson, Prentice Hall.
- [4] Simon Haykin, "Neural Networks. A Comprehensive Foundation", Pearson Education, 1999.
- [4] Mark Hudson Beale, Martin T. Hagan, Howard B. Demuth. "Neural Network Toolbox™, Getting Started Guide".
- [5] G. Cybenko, "Approximation by Superpositions of a Sigmoidal Function", Mathematics.
- [6] Stoline. "Applied Nonlinear Control".
- [7] Alberto Isidori. "Nonlinear Control Systems", 1999.

- [8] Signal and Systems - General - A.V. Oppenheim A.S. Willsky - Signals and Systems Solution Manual - Prentice Hall - 2<sup>nd</sup>



#### 6. Biografía

**Alejandro Mendez** nació en Zamora, Michoacán, el 11 de Abril de 1987. Se graduó en el Instituto Tecnológico de Estudios Superiores de Zamora y fue estudiante de Maestría del CINVESTAV, México, en el departamento de Control Automático. Recibió grados honorarios en el Instituto Tecnológico de Estudios Superiores de Zamora.



**José Eduardo Sánchez Madrigal** nació en Zamora, Michoacán, el 24 de abril de 1993. Terminó sus estudios de educación preparatoria en el Colegio Nacional de Educación Profesional Técnica (CONALEP), en la carrera de Profesional Técnico Bachiller en Informática. Cuenta con conocimientos de programación en "C" y en diversas plataformas para el manejo de datos. Actualmente realiza sus estudios superiores en el Instituto Tecnológico de Estudios Superiores de Zamora, cursando el tercer año de la carrera de Ingeniería en Electrónica.



**Gemayel Efrén Alfaro Aguilar** nació en Zamora, Michoacán, el 09 de Diciembre de 1993. Estudio en el CBTIS No. 52 la carrera de electromecánica con conocimientos en mantenimiento en instalaciones y obtuvo su certificado. Actualmente es estudiante de la carrera Ing. Electrónica de 4to semestre en el Instituto Tecnológico de Estudios Superiores de Zamora y tiene un nivel básico de inglés.