



UNIVERSIDAD DE QUINTANA ROO
DIVISIÓN DE CIENCIAS E INGENIERÍA

**Control de velocidad en tiempo real de un motor
de CD mediante un controlador neuronal**

TESIS

Para obtener el grado de
Ingeniero en Sistemas de Energía

PRESENTA

Luis Alberto Canul Pantoja


DIRECTOR DE TESIS

Dr. Víctor Manuel Sánchez Huerta

ASESORES

Dr. Freddy I. Chan Puc

M.C. Emmanuel Torres Montalvo





UNIVERSIDAD DE QUINTANA ROO
DIVISIÓN DE CIENCIAS E INGENIERÍA

Trabajo de Tesis elaborado bajo supervisión del Comité de asesoría y aprobada como requisito parcial para obtener el grado de:

INGENIERO EN SISTEMAS DE ENERGÍA

Comité de Trabajo de Tesis

Director:



_____ **Dr. Víctor Manuel Sánchez Huerta**

Asesor:


_____ **M.C. Emmanúel Torres Montalvo**

Asesor:


_____ **Dr. Freddy I. Chan Puc**



Chetumal, Quintana Roo, México, Diciembre de 2013.



UNIVERSIDAD DE QUINTANA ROO

División de Ciencias e Ingeniería

Agradecimientos

Le doy Gracias a Dios por permitirme estar vivo y poder realizar una parte importante de mis sueños.

A mis padres, a mi madre Silvia Encarnación Pantoja y a mi padre José Luis Canul Ruiz les doy las gracias por todo y cada uno de sus valiosos esfuerzos por permitirme concluir mi formación profesional. A mis hermanas y sin olvidar a mi pequeña sobrina Zarela. A todos ellos por estar conmigo en las buenas y en las malas.

A Claudia Durán por darme fuerzas y ánimos en los momentos más difíciles. Pero sobre todo por estar aquí conmigo y apoyarme a todo momento.

A mis queridos y tan apreciados profesores quienes apoyaron con paciencia mi formación académica que sin duda llevo la satisfacción de decir ustedes fueron mis maestros y gracias por todos sus esfuerzos y las malas noches que nos hicieron pasar.

A mis compañeros que pasamos momentos inolvidables en las aulas pero sobre todos a mis amigos Miguel Ángel López Hernández (alias limón) y Miguel Hernán González (alias el pollo), a los cuales les agradezco por compartir momentos de éxito y de fracaso pero sobre todo por contribuir en puntos importantes durante la carrera.

Sin olvidar a mi director de tesis el Dr. Víctor Manuel Sánchez Huerta por confiar en mí y dar la oportunidad de trabajar en su gabinete aunque pensé que se acabaría el mundo con muchas presiones y sin olvidar la famosa frase “¿Qué pasó?, ¿avanzaste? , nada más ten en cuenta que era para ayer”. ¡Gracias profe!



UNIVERSIDAD DE QUINTANA ROO

División de Ciencias e Ingeniería

Dr. Víctor Manuel Sánchez Huerta Profesor Investigador de la Universidad de Quintana Roo. Por permitirme participar en proyecto “Emulador en tiempo real de un sistema de celda de combustible tipo PEM mediante la técnica de hardware-in-loop”.

A la Universidad de Quintana Roo por todas las facilidades que tiene las instalaciones, pero sobre todo a la División de Ciencias e Ingeniería.

A todos ustedes, Gracias.



UNIVERSIDAD DE QUINTANA ROO

División de Ciencias e Ingeniería

Dedicatoria

A mis padres por ayudarme en todo momento por darme el apoyo y su confianza incondicional. Les agradezco por cada uno de sus esfuerzos.



UNIVERSIDAD DE QUINTANA ROO

División de Ciencias e Ingeniería

Tabla de Contenido

Agradecimientos.....	3
Dedicatoria.....	5
Lista de figuras	9
Lista de tablas	11
Resumen	12
CAPÍTULO 1. Control de Velocidad en Motores de CD.....	13
1.1 Introducción.....	13
1.2 Justificación	14
1.3 Objetivo General.....	15
1.4 Objetivos Particulares.....	15
CAPÍTULO 2. Motores de CD.....	16
2.1 Modelo del motor de CD.....	16
2.1.1 Elementos del motor de CD	17
2.1.2 Ecuaciones del motor de CD	19
REFERENCIAS	24
CAPÍTULO 3. Redes Neuronales Artificiales	25
3.1 Introducción.....	25
3.2 Redes Neuronales Biológicas	26
3.3 Redes Neuronales Artificiales	27
3.3.1 Modelo general de una neurona artificial.....	29



UNIVERSIDAD DE QUINTANA ROO

División de Ciencias e Ingeniería

3.4 El aprendizaje en Redes Neuronales Artificiales	30
3.5 Clasificación de Redes Neuronales Artificiales	32
3.5.1 Perceptrón.....	32
3.5.2 RNA Adeline.....	33
3.5.3 RNA Backpropagation	33
3.5.4 RNA B-Spline.	35
REFERENCIAS	36
CAPÍTULO 4. Neuro-controlador B-Spline	37
4.1 Introducción.....	37
4.2 Estructura de la RNA B-spline.....	37
4.3 Funciones Base.....	38
4.3.1 Funciones base monovariable.....	40
4.3.2 Funciones base multivariable	41
4.4 Regla de aprendizaje.....	42
4.4.1 Regla de Corrección del Error	43
4.5 Diseño del neuro-controlador B-spline.....	45
4.5.1 Selección del orden de las funciones base.....	46
4.5.2 Selección del número de funciones base de orden 2 y la razón de aprendizaje.	48
4.5.3 Desempeño del neuro-controlador B-Spline.	52
REFERENCIAS	56
CAPÍTULO 5. RESULTADOS EXPERIMENTALES	57



UNIVERSIDAD DE QUINTANA ROO

División de Ciencias e Ingeniería

5.1 Introducción.....	57
5.2 Configuración del entorno HIL.	58
5.3 Desempeño del neuro-controlador B-Spline en entorno HIL.....	59
5.4 Desempeño del neuro-controlador B-Spline ante una perturbación.....	63
5.5 Desempeño del neuro-controlador B-Spline ante cambio de parámetros del motor de CD. 66	
5.6 Pruebas experimentales con módulo entrenador del motor de CD.	68
CONCLUSIONES.....	71



UNIVERSIDAD DE QUINTANA ROO

División de Ciencias e Ingeniería

Lista de figuras

Fig.2.1. Motor de CD.	18
Fig.2.2. Diagrama de bloque del modelo del motor de CD.....	18
Fig.2.3. Diagrama de bloques del modelo del motor de CD.....	22
Fig.2.4. Diagrama simplificado del motor de CD	23
Fig.3.1. Estructura típica de una neurona biológica.....	26
Fig.3.2. Modelo genérico de una neurona artificial.....	29
Fig.3.3 Modelo estándar de una neurona estándar.....	30
Fig.3.4. Perceptrón	32
Fig.3.5. Estructura de una red Adaline.....	33
Fig.3.6. Red Sencilla de 3 capas Backpropagation	34
Fig.4.1. Estructura de una RNA B-spline.....	38
Fig.4.2. Vector de puntos de control para un espacio de entrada unidimensional.....	39
Fig.4.3. Funciones spline de orden 1, 2, 3,4.....	41
Fig.4.4. Función spline multivariable.....	42
Fig.4.5 Esquema de prueba dos RNAB-S con funciones base de diferente orden.....	46
Fig.4.6. Desempeño de los neuro-controladores. (a) Seguimiento del valor de referencia de velocidad. b) Detalle del seguimiento de velocidad.....	47
Fig.4.7. Esquema de pruebas de dos neuro-controladores y un controlador PI.....	49
Fig.4.8. Resultados del esquema de pruebas de dos neuro-controladores con diferente razón de aprendizaje y el control PI.....	49
Fig.4.9. Voltaje de los neuro-controladores y el controlador PI:	50
Fig.4.10. Resultados del esquema de pruebas de dos neuro-controladores con 4 funciones base de orden 2 y el control PI.....	51
Fig.4.11. Voltaje de las RNAB-S y del PI	52
Fig.4.12. Esquema de prueba para la comparación de los controladores neuronal y PI.....	53



UNIVERSIDAD DE QUINTANA ROO

División de Ciencias e Ingeniería

Fig.4.13. Resultados de la comparación del neuro-controlador y el control PI.	53
Fig.4.14. Voltaje aplicado al motor de CD por los controladores bajo prueba.	54
Fig.5.1. Configuración del entorno de simulación HIL.	58
Fig.5.2. Esquema de prueba del Neuro-controlador y PI en tiempo real.	59
Fig.5.3. Respuesta de los controladores a un cambio de velocidad de 5 rad/s a 70 rad/s.	60
Fig.5.4. Voltajes generados por los controladores para controlar la velocidad de 5 rad/s a 70 rad/s.	61
Fig.5.5. Respuesta de los controladores a un cambio de velocidad de 65 rad/s a 130 rad/s.	62
Fig.5.6. Voltajes generados por los controladores para controlar la velocidad de 65 rad/s a 130 rad/s.	63
Fig.5.7. Esquema de prueba del neuro-controlador B-Spline aplicando una perturbación.	64
Fig.5.8. Desempeño de los controladores ante un disturbio.	64
Fig.5.9. Voltaje de los controladores para compensar la perturbación.	65
Fig.5.10. Resultados de velocidad de la BRNA y el PI con un motor distinto.	67
Fig.5.11. Voltajes de los controladores ante cambio de parámetros del motor.	67
Fig.5.12. Configuración del esquema de prueba con motor real.	68
Fig.5.13. Desempeño del controlador PI con el motor real.	69
Fig.5.14. Desempeño del controlador PI con el motor real.	69



UNIVERSIDAD DE QUINTANA ROO

División de Ciencias e Ingeniería

Lista de tablas

Tabla 2. 1 Nomenclatura de sistema de lazo abierto	19
Tabla 2. 2 Valores de los parámetros del motor de CD.....	23



UNIVERSIDAD DE QUINTANA ROO

División de Ciencias e Ingeniería

Resumen

Se presenta el desarrollo de un controlador de velocidad para un motor de CD basado en la red neuronal B-spline debido a sus características de ser un algoritmo simple que hacen que sea una opción confiable. Las redes neuronales son más que otra forma de presentar ciertas características propias de los humanos, como la capacidad de memorizar y de asociar hechos. Debido que el diseño del neuro-controlador está basado en redes neuronales B-Spline, se tomará su respuesta dinámica con el motor de CD y todos los requerimientos necesarios para la operación. Convencionalmente en el control de velocidad para motores se utiliza el controlador proporcional- integral (PI), sin embargo es un controlador lineal que depende de una forma importante en su diseño del modelo matemático del sistema a controlar. De esta forma, en esta tesis se compara el neuro-controlador B-Spline con el controlador (PI) para el problema del control de velocidad de un motor de CD. Los resultados obtenidos demuestran que el neuro-controlador diseñado presenta un mejor desempeño con respecto al control PI.

CAPÍTULO 1. Control de Velocidad en Motores de CD

1.1 Introducción

El control de velocidad de motores es uno de los objetivos de control más frecuentemente utilizado en aplicaciones industriales así como en electrodomésticos como lavadoras, refrigeradores y aires acondicionados.

Convencionalmente en el control de velocidad de motores se utiliza el controlador clásico Proporcional-Integral (conocido usualmente como controlador PI) debido a la sencillez de su algoritmo que redundo en una facilidad para ser implementado mediante circuitos analógicos o en dispositivos digitales como microcontroladores o microprocesadores. Sin embargo, el controlador PI es un controlador lineal, que depende de forma importante en su análisis del modelo matemático del sistema a controlar y que además es diseñado para operar en un punto de operación fijo. Estas condiciones en el diseño del controlador PI ocasiona que su rendimiento para realizar la tarea de control disminuya por alguna de las siguientes causas:

- Cambio del punto de operación del sistema a controlar.
- Comportamiento no lineal importante del sistema controlado.
- Presencia de perturbaciones no modeladas
- Inducción de ruido en sensores que pueden modificar el valor de la variable controlada.

Para solucionar esta problemática existen técnicas de control no lineal (modos deslizantes, control robusto, control óptimo) o de control inteligente (lógica difusa, sistemas expertos, redes neuronales) que pueden dar solución a una o varias de las desventajas del controlador

PI. Sin embargo, la principal desventaja de estas opciones de control radica generalmente en el requerimiento de cálculo computacional requerido por estas técnicas de control.

En este trabajo de tesis se propone y diseña un controlador neuronal para el control de velocidad del motor de CD. El controlador neuronal propuesto está basado en una red neuronal B-spline. Las redes neuronales B-Spline tienen como ventaja ante otras topologías de redes neuronales la sencillez de su algoritmo que le permite poder aprender en línea, es decir, la tarea de control la aprende y ejecuta estando conectada al sistema a controlar, a diferencia de otras redes neuronales que deben tener una etapa de aprendizaje previa.

De esta forma en el capítulo 2 se presenta el desarrollo del modelo del motor de CD; mientras que en el capítulo 3 se describe el principio de operación de las redes neuronales artificiales. El diseño del neuro-controlador B-spline se presenta en el capítulo 4. Los resultados experimentales se presentan en el capítulo 5. Finalmente se presentan las conclusiones de este proyecto.

1.2 Justificación

En este trabajo de tesis se propone diseñar e implementar un controlador neuronal para el control de velocidad de un motor de CD en tiempo real. El neuro-controlador estará basado en una red neuronal B-spline y diseñado para su operación en tiempo real. En el diseño del neuro-controlador B-Spline se tomará en cuenta la respuesta dinámica del motor de CD y los requerimientos de tensión requeridos para su operación. El desempeño del neuro-controlador desarrollado será validado con respecto a un controlador PI clásico, el cual es el controlador más utilizado en este tipo de aplicaciones. El neuro-controlador deberá aprender en línea las no-linealidades del motor y compensar el efecto de perturbaciones que se presenten en el sistema a controlar.

1.3 Objetivo General

Diseñar e implementar un neuro-controlador, basado en una red neuronal B-Spline, para el control de velocidad de un motor de CD en tiempo real.

1.4 Objetivos Particulares

- Determinar el modelo del motor de corriente directa con la finalidad de identificar los parámetros que rigen la respuesta dinámica del sistema.
- Analizar la red neuronal B-Spline para conocer su principio de operación e implementación.
- Diseñar e implementar el neuro-controlador B-Spline en el software de simulación Simulink.
- Integrar el modelo del motor de CD y el neuro controlador B-Spline operando en tiempo real de simulación.
- Implementar el neuro-controlador en la plataforma Hardware-in-loop para el control del motor de CD en tiempo real.
- Realizar un estudio comparativo del funcionamiento del neurocontrolador B-Spline y el controlador PI (Proporcional + Integral).

CAPÍTULO 2. Motores de CD

En este capítulo se presenta el desarrollo del modelo matemático del motor de CD. El modelo matemático es requerido para ser implementado en la plataforma Hardware-in-loop y de esta forma contar con la plataforma de prueba de simulación en tiempo real para el neuro-controlador B-spline y el controlador PI. El control de velocidad que se desarrolló en esta tesis se diseñó e implementó para el motor de CD del módulo entrenador de la marca Quanser [1].

2.1 Modelo del motor de CD.

Un aspecto esencial en el control de sistemas es su modelo matemático. Un modelo matemático de un sistema dinámico se define como un juego de ecuaciones que representa la dinámica del sistema con exactitud o al menos respuestas razonables. Los sistemas se pueden representar de modos diferentes y pueden tener diferentes modelos matemáticos; ello depende de la perspectiva de la aplicación. Los elementos claves en la obtención de modelos matemáticos son [2]:

- Obtener una visión general del sistema y sus componentes.
- Comprender el sistema y cómo funciona el sistema.
- Conocer los principios del modelado de componentes.
- Verificar la validez del modelo.

El modelo matemático de un sistema puede ser tan complejo conforme se incluyan la respuesta dinámica de todos sus componentes. Por ello, en control a menudo es suficiente trabajar con modelos linealizados o modelos lineales, donde las dinámicas del sistema son representadas por funciones de transferencia. Las funciones de transferencia se pueden

obtener mediante la aplicación de las leyes físicas básicas que describen los subsistemas o por experimentos en un sistema real [2-3].

Los principios de modelado requieren un buen conocimiento de los fenómenos físicos involucrados y un buen sentido de aproximaciones razonables. El modelo matemático de un sistema también puede obtenerse a través de la excitación del sistema con una señal de entrada y analizando su respuesta dinámica. Como ejemplo de ello se tiene la respuesta del sistema a una entrada escalón o la respuesta en frecuencia del sistema. Un modelo puede ser, en principio, obtenido mediante la aplicación de cualquier tipo de entrada al sistema y el análisis de la respuesta correspondiente.

Por otra parte, la evaluación del modelo es una parte importante del modelado para el control de sistemas dinámicos, también es esencial para proporcionar alguna medida exacta del modelo. Al modelar sistemas dinámicos la precisión se expresa en términos de exactitud de los parámetros. Sin embargo, esto no es suficiente, ya que puede haber errores debido a elementos del sistema no considerados [3]. Cuando se obtiene un modelo, es una buena práctica evaluar su validez mediante la ejecución de simulaciones y comparando su respuesta con la del sistema real. La validación es un paso importante que se debe realizar con el fin de dar un nivel de confianza al modelo obtenido.

2.1.1 Elementos del motor de CD

El modelo eléctrico del motor de CD está compuesto por la parte eléctrica conformado por el devanado de armadura y el voltaje aplicado al mismo; así como también una parte mecánica conformado por el rotor y la carga inercial que tiene que mover. La Fig. 2.1 muestra el circuito eléctrico equivalente de la armadura del motor y el diagrama de cuerpo libre del rotor [2-4].




Fig.2.1. Motor de CD.

En este modelo del motor de CD se considera al voltaje de la fuente V_m como la entrada al sistema y el cual es aplicado al devanado de armadura del motor de CD. Por otra parte, la velocidad angular del rotor es considerada la variable de salida del motor. Se asume que el rotor y la flecha están unidos rígidamente[5]. La Fig. 4.2 muestra la representación en diagrama a bloques de este modelo del motor de CD.




Fig.2.2. Diagrama de bloque del modelo del motor de CD.

En el modelo de la Fig. 2.2 contempla la posible influencia de una perturbación externa al modelo la cual está representada por la variable T_d y que representa un cambio en el torque del motor.

Los parámetros físicos de los elementos del motor de CD que fueron tomados en cuenta para el modelo se muestran en la Tabla 2.1.

Tabla 2. 1. Nomenclatura de sistema de lazo abierto

Símbolos	Descripción	Unidades
ω_m	Velocidad angular del motor	rad/s
V_m	Voltaje de armadura del motor.	V
T_d	Perturbación del torque del motor	N.m
T_m	Par generado por el motor	N.m
I_m	Corriente del inducido del motor	A
K_m	Constante de Torque del motor	N.m/A
R_m	Resistencia del inducido del motor	Ω
L_m	Inductancia del inducido del motor	Mh
J_m	Momento de inercia del rotor del motor	Kg.m^2
J_l	Momento de inercia de la carga	Kg.m^2
J_{eq}	Momento de inercia total del rotor y la carga del motor	Kg.m^2
τ	Constante de tiempo de lazo abierto	s

2.1.2 Ecuaciones del motor de CD

Para la obtención del modelo del motor se considera que el campo magnético es contante, por lo que se puede considerar que el torque del motor es proporcional a la corriente de armadura por un factor constante como lo describe la ecuación 2.1 [1-2].

$$T = K_t i_m(t) \quad (2.1)$$

Por otra parte, al girar el devanado de armadura del rotor en el campo magnético del motor se genera una fuerza contra-electromotriz de polaridad inversa al voltaje aplicado al devanado de armadura. Esta fuerza contra-electromotriz es proporcional a la velocidad angular del motor y está representada por la ecuación 2.2.

$$e = K_m \cdot \omega_m(t) \quad (2.2)$$

En el Sistema Internacional de Unidades, las constantes del torque y de la fuerza contra-electromotriz son iguales, esto es:

$$K_t = K_m \quad (2.3)$$

Asumiendo las consideraciones anteriores tenemos que la ecuación que gobierna al circuito eléctrico del motor se obtiene a través de la ley de voltajes de Kirchhoff, como se representa en la ecuación (2.4).

$$V_m(t) = R_m i_m(t) + L_m \left(\frac{\partial}{\partial t} i_m(t) \right) + k_m \omega_m(t) \quad (2.4)$$

Aplicando transformada de Laplace a la ecuación anterior tenemos que:

$$R_m I_m(s) + sL_m I_m(s) = V_m(s) - K_m \Omega_m(s) \quad (2.5)$$

Si $L_m \ll R_m$ podemos despreciar el término de la inductancia, así que podemos simplificar la ecuación (2.5) como lo muestra la ecuación (2.6)

$$V_m = R_m I_m + k_m \Omega_m \quad (2.6)$$

Por otra parte, aplicando la segunda ley de Newton a la parte mecánica del motor y despreciando el coeficiente de fricción viscosa tenemos que:

$$J_{eq}\omega_m = K_m I_m(t) + T_d \quad (2.7)$$

donde:

$$J_{eq} = J_m + J_l \quad (2.8)$$

La transformada de Laplace de la ecuación (2.6) resulta en:

$$J_{eq}\Omega_m(s)s = K_m I_m(s) + T_d(s) \quad (2.9)$$

Combinando las ecuaciones (2.6) y (2.9) tenemos que:

$$J_{eq}\Omega_m(s)s + \frac{K_m^2 \Omega_m(s)}{R_m} = \frac{K_m V_m(s)}{R_m} + T_d(s) \quad (2.10)$$

A partir de la ecuación (2.10) podemos determinar la función de transferencia que modela el comportamiento dinámico de la velocidad del motor con respecto al voltaje aplicado a su armadura como lo describe:

$$G_{\omega,V}(s) = \frac{K_m}{R_m \left[J_e s + \frac{K_m^2}{R_m} \right]} \quad (2.11)$$

De esta forma, la ecuación 2.11 describe que la dinámica de la velocidad del motor es representada por una función de transferencia de primer orden. No hay que perder de vista que este modelo es aproximado ya que se han despreciado los efectos de la inductancia de

la armadura del motor así como también el coeficiente de fricción viscosa del motor. La ecuación (2.11) se puede manipular para representar la función de transferencia de la velocidad del motor como:

$$G_{\omega,V}(s) = \frac{K}{\tau s + 1} \quad (2.12)$$

La forma de la función de transferencia de la ecuación (2.12) permite visualizar fácilmente la ganancia de estado estacionario y la constante de tiempo del modelo de velocidad del motor de CD. Sustituyendo los valores de los parámetros del motor de CD y que se presentan en la Tabla 2.2 se obtiene finalmente que la función de transferencia del motor de CD es:

$$G_{\omega,V}(s) = \frac{19.9}{0.0929s + 1} \quad (2.12)$$

La Fig. 2.3 muestra el diagrama de bloques del modelo del motor de CD construido con los modelos de los elementos que lo conforman.

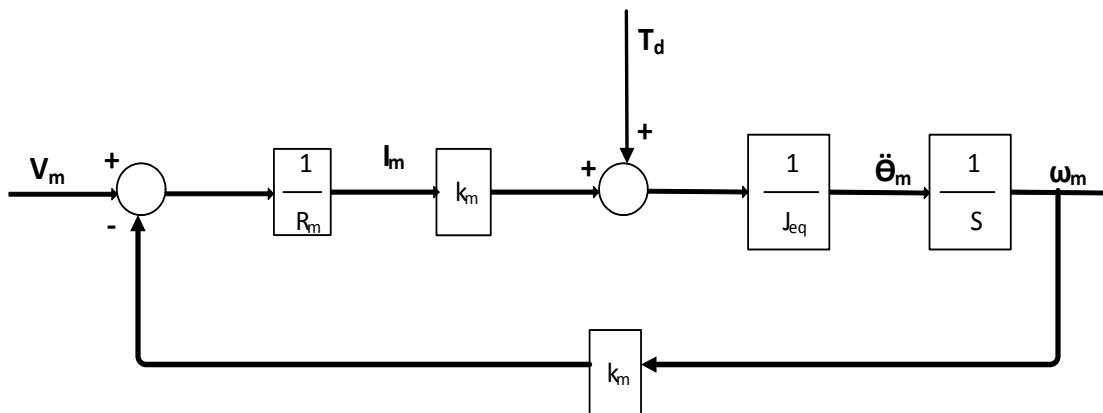


Fig.2.3. Diagrama de bloques del modelo del motor de CD.

Moviendo el punto de suma de retroalimentación detrás de los dos primeros bloques y simplificando el diagrama anterior obtenemos el diagrama equivalente que se muestra en la Fig. 2.4.

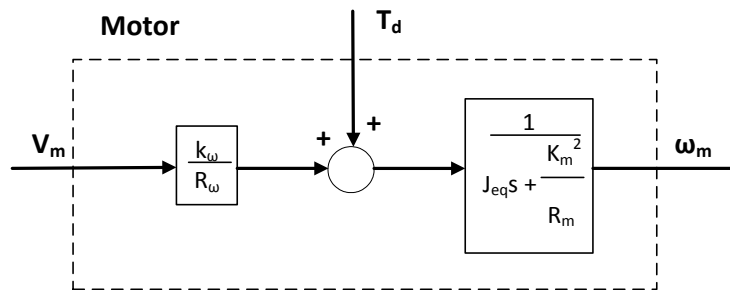


Fig.2.4. Diagrama simplificado del motor de CD

La Tabla 2.2 muestra los valores de los parámetros del motor de CD.

Tabla 2. 2. Valores de los parámetros del motor de CD.

Símbolo	Descripción	Valor	Unidad
K _m	Constante de Torque del motor	0.0502	N.m/A
R _m	Resistencia del Inducido del Motor	10.6	Ω
L _m	Inductancia del inducido del Motor	0.82	mH
	Máxima Torsión continua del Motor	0.035	N.m
	Potencia del Motor	18	W
J _{eq}	Momento equivalente del rotor el Motor	2.21 x 10 ⁻⁵	Kg.m ²
τ _m	Constante de tiempo Mecánica del Motor	0.005	s
K	Ganancia en estado estable del lazo abierto	19.9	rad/(V.s)
τ	Constante de Tiempo de Lazo Abierto	0.0929	s
V _{max}	Tensión Máxima de salida del Amplificador Lineal	15	V

REFERENCIAS

[1]. Ogata, katsuhiko. *Ingeniería de Control Moderna. Tercera Edición* .Prentice-Hall Hispano Americano, 1933.university of Minnesota.

[2]. Karl Johan Aström and Jacob Apakarian, Hervé Lancheray (instructor workbook).DC Motor Control Trainer (DCMCT).QUANSER.INNOVATE.EDUCATE.

[3] Ramón García Hernández. “Control Neuronal Descentralizado Discreto para Manipuladores Robóticos”. Tesis para Obtener el grado en doctor en Ciencias en la especialidad de Ingeniería Eléctrica. Guadalajara, Jalisco. Noviembre 2006. CINVESTAV Centro de Investigación y de Estudios Avanzados del I.P.N. Unidad Guadalajara.

[4] Pável Zúñiga Haro. “Análisis y Control de un Compensador Serie”. Tesis para Obtener el grado en doctor en Ciencias en la especialidad de Ingeniería Eléctrica. Guadalajara, Jalisco. Mayo 2006. CINVESTAV Centro de Investigación y de Estudios Avanzados del I.P.N. Unidad Guadalajara.

[5] Oliver Clark Pérez Myers. “Un Neurocontrolador para Dispositivos de Electrónica de Potencia”. Tesis para Obtener el grado de maestro en Ciencias en la especialidad de Ingeniería Eléctrica. Guadalajara, Jalisco. Agosto 2009. CINVESTAV Centro de Investigación y de Estudios Avanzados del I.P.N. Unidad Guadalajara.

CAPÍTULO 3. Redes Neuronales Artificiales

3.1 Introducción

En la ciencia de la computación la manera de confrontar los diversos problemas es generar un modelo tomando en cuenta algunos aspectos, como son reglas matemáticas o lógicas y proponer con base a un conjunto de sentencias iterativas con mecanismos de selección o decisión una solución. Para responder a estas y a otras interrogantes a lo largo de la historia se han generado diversas formas de presentar soluciones, que en cierto modo han conformado a lo que hoy se conoce como Inteligencia Artificial[1-3].

El desarrollo de las redes neuronales artificiales (RNA) comenzó aproximadamente en los años 50's, motivado por el deseo de entender el cerebro y emular algunas de sus actividades. El cerebro humano corresponde a un sistema altamente complejo no-lineal y paralelo. Debido a sus capacidades que tiene al manejar la información, es que se han intentado crear RNA para el análisis de múltiples tipos de datos simulando el comportamiento del cerebro humano. Al igual que una red neuronal humana, las RNA deben aprender por lo que se aplican reglas de aprendizaje que ajustan las conexiones entre las neuronas artificiales para que pueda aprender a partir de ejemplos que se le muestren [2-4].

En las últimas dos décadas, se ha incrementado la atención a las RNA para modelar sistemas no lineales y diseñar controladores. La estructura de estos modelos se forma por un arreglo uniforme de unidades básicas de cálculo interconectadas entre sí. Después de seleccionar su estructura, las interconexiones se ponderan mediante un entrenamiento, para aproximar el comportamiento entrada-salida de un sistema dinámico. Los esquemas

neuronales tienen la habilidad de identificar el modelo de sistemas desconocidos mediante un conjunto de datos que relacionan la(s) entrada(s) y la(s) salida(s) [3].

3.2 Redes Neuronales Biológicas

Para entender las redes neuronales artificiales es necesario comprender como funcionan las redes neuronales biológicas. El cerebro humano es un sistema de procesamiento de información extremadamente complejo, su unidad fundamental de procesamiento es la neurona, donde el cerebro está compuesto por un elevado número de neuronas interconectadas y que funciona en paralelo. Una neurona típica posee el aspecto y las partes que se muestran en la figura 3.1 [1-2-3].

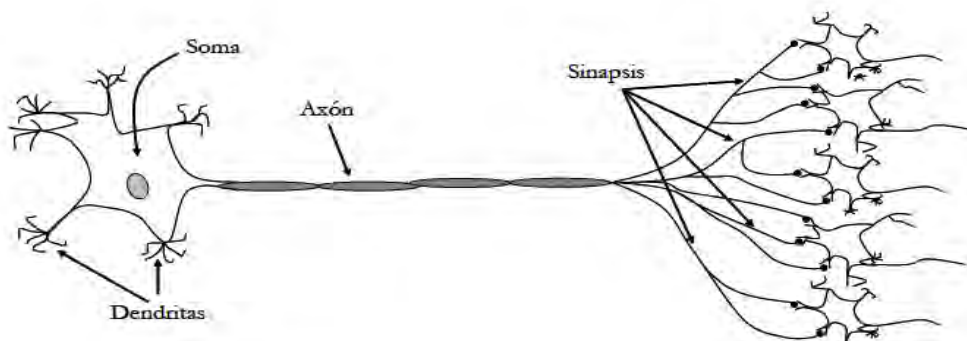


Fig.3.1. Estructura típica de una neurona biológica.

La neurona biológica está formada por tres partes principales: el soma, que es el cuerpo principal de la neurona; un solo axón, que parte del soma y se incorpora a un nervio periférico que sale de la médula espinal y las dendritas, que son numerosas prolongaciones ramificadas del soma. Las señales de entrada (aférentes) llegan a la neurona a través de las sinapsis que establecen, sobre todo, las dendritas, aunque también el cuerpo celular. El número de conexiones sinápticas que mantienen esas fibras de entrada oscila entre unos cientos y doscientos mil. Por el contrario, la señal de salida (eferente) se transmite por el

único axón de la neurona. Dicho axón tiene muchas ramas separadas destinadas a otras partes del sistema nervioso o a la periferia del cuerpo. Un rasgo especial de la mayoría de las sinapsis es que la señal se transmite de ordinario solamente en la dirección hacia delante (del axón a las dendritas). Además las neuronas se disponen en un gran número de redes nerviosas con distinta organización que determinan las funciones del sistema nervioso.

Dentro del comportamiento de las neuronas biológicas existen algunas características que pueden afectar a la RNA. Por ejemplo, el impulso que llega a una sinapsis y el que sale de ella no son iguales, Puede variar durante el proceso de aprendizaje.

En el cuerpo o soma se suman las entradas de todas las dendritas. Si estas sobrepasan un cierto umbral, entonces se transmitirá un pulso a lo largo del axón, en caso contrario no se transmitirá. Después de transmitir un impulso, la neurona no puede transmitir durante un tiempo de entre 0,5 ms a 2 ms. A este tiempo se le llama período refractario.

Las neuronas son capaces de cambiar dinámicamente junto con el medio. A esta propiedad de las neuronas se le denomina plasticidad. La plasticidad se percibe también en la capacidad de responder de forma correcta frente a un estímulo nunca antes recibido.

De esta forma una RNA, que trata de emular las características del modelo biológico, trata de reproducir la tolerancia a fallos, adquisición de conocimientos, plasticidad, adaptabilidad y la posibilidad de modelar comportamientos no lineales.

3.3 Redes Neuronales Artificiales

Una RNA se puede definir como un modelo computacional inspirado en el sistema nervioso biológico, compuesto por un gran número de elementos interconectados paralelamente denominados neuronas, las cuales están encargadas de procesar información para producir un estímulo de salida. Al igual que su símil biológico, existen diferentes tipos de RNAs.

Las características principales que distingue a una RNA son las siguientes [2-3]:

- Su patrón de conexiones entre neuronas (arquitectura)
- Su método de determinar los pesos en las conexiones (algoritmo de entrenamiento o aprendizaje)
- Su función de activación.

Las RNA están compuestas de elementos de procesamiento llamadas neuronas, unidades, células o nodos. Cada una de las neuronas se conecta a otras neuronas por medio de ligas de comunicación directas, cada una con un peso asociado. Cada neurona tiene un estado interno, llamado estado de activación o nivel de actividad, que es una función de la entrada que recibe. Una neurona envía su activación como una señal a diferentes neuronas. Un sistema neuronal está compuesto por los siguientes elementos:

- Un conjunto de procesadores elementales o neuronas artificiales.
- Un patrón de conectividad o arquitectura.
- Una dinámica de activaciones.
- Una regla aprendizaje.

La respuesta de las neuronas biológicas es del tipo no lineal, característica que se emula en las RNA ya que constituye una de sus características más interesantes para abordar este tipo de problemas.

3.3.1 Modelo general de una neurona artificial.

El modelo general de la RNA está constituido como se muestra en la Fig. 3.2 :

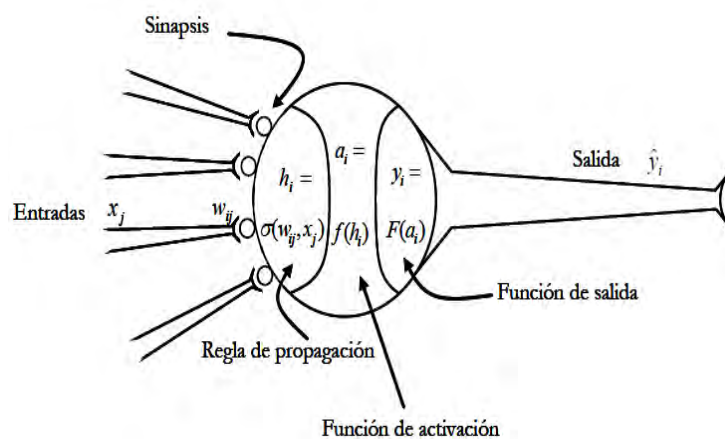


Fig.3.2. Modelo genérico de una neurona artificial.

El modelo general de la neurona artificial está constituido por los siguientes elementos.

- Conjunto de entradas, $x_j(t)$
- Pesos sinápticos de la neurona i , w_{ij} que representan la intensidad de interacción entre cada neurona presináptica j y la neurona postsináptica i .
- Regla de propagación $\sigma(w_{ij}, x_j(t))$, que proporciona el valor del potencial postsináptico $h_i(t) = \sigma(w_{ij}, x_j(t))$, de la neurona i en función de sus pesos y entradas.

- Función de activación $f_i(a_i(t - 1), h_i(t))$ que proporciona el estado de activación actual $a_i(t) = f_i(a_i(t - 1), h_i(t))$ de la neurona i $a_i(t - 1)$ y de su potencial postsináptico actual.
- Función de salida $F_i(a_i(t))$, que proporciona la salida actual $\hat{y}_i = F_i(a_i(t))$ neurona i en función de su estado de activación.

La operación matemática que realiza la i -ésima neurona puede expresarse como:

$$\hat{y}_i(t) = F_i \left(f_i \left[a_i(t - 1), \sigma_i \left(w_{ij}, x_j(t) \right) \right] \right) \quad [3.1]$$

Las variables de entrada y salida de la neurona artificial pueden ser señales binarias (digitales) o continuas (analógicas), dependiendo del modelo y aplicación. Con frecuencia se añade al conjunto de pesos de la neurona un parámetro adicional, b_i que se denomina umbral. La Fig. 3.3 muestra el diagrama estándar de una neurona artificial.




Fig.3.3. Modelo estándar de una neurona estándar.

3.4 El aprendizaje en Redes Neuronales Artificiales

Los factores principales que determinan el comportamiento de una RNA son: la función de activación y el patrón de los pesos en las conexiones sobre las cuales se envía y recibe la señal a través de la neurona [1]. El arreglo de RNA en capas y los patrones de conexión dentro y entre capas se denomina arquitectura de la red. Se distinguen tres tipos de capas: a) de entrada, b) ocultas, y c) de salida [2-3]:

- La capa de entrada o sensorial está compuesta por neuronas que reciben datos o señales procedentes del entorno.
- La capa oculta es aquella que no tiene una conexión directa con el entorno. La arquitectura de la red puede estar formada por una o más capas ocultas.
- La capa de salida es aquella cuyas neuronas proporcionan la respuesta de la red neuronal.

Las propiedades más importantes de las RNA es su capacidad de aprender a partir de conjuntos de patrones de entrenamientos. Por lo tanto el proceso de aprendizaje es aquel por el cual la RNA se adapta al estímulo modificando sus pesos y eventualmente produce un resultado esperado [5].

Al aprendizaje en la RNA se realiza al presentarle valores de entrada y salida conocidos a los cuales se les denomina patrones de entrenamiento. De esta forma, el algoritmo de aprendizaje se encarga de ajustar los pesos y umbrales de cada neurona de la RNA para que esta reproduzca la señal de salida a partir de los datos de entrada del patrón de entrenamiento. La cantidad de patrones de entrenamientos de la red debe ser una muestra representativa y un número significativo de ejemplos para que la red ajuste sus pesos de manera eficaz. Existen 2 tipos de aprendizaje: Aprendizaje Supervisado, y Aprendizaje No Supervisado.

- Aprendizaje Supervisado es el que aprende de sus errores.
- Aprendizaje No Supervisado debe indentificar informacion del entorno como parte del proceso entrenamiento.

3.5 Clasificación de Redes Neuronales Artificiales

Existen diferentes arquitecturas de RNA, entre las más comunes podemos encontrar [4]:

3.5.1 Perceptrón

Es la primera red neuronal conocida, fue desarrollada en 1943 por Warren McCulloch y Walter Pitts; está consiste en una suma de señales de entrada, multiplicadas por unos valores de pesos escogidos aleatoriamente. La entrada es comparada con un patrón preestablecido para determinar la salida de la red. Si en la comparación, la suma de las entradas multiplicadas por los pesos es mayor o igual que el patrón preestablecido, la salida de la red es un uno lógico (1), en caso contrario la salida es un cero lógico (0). El perceptrón es un tipo de RNA que utiliza aprendizaje supervisado, es decir necesita conocer los valores esperados para cada una de las entradas presentadas [3-4].

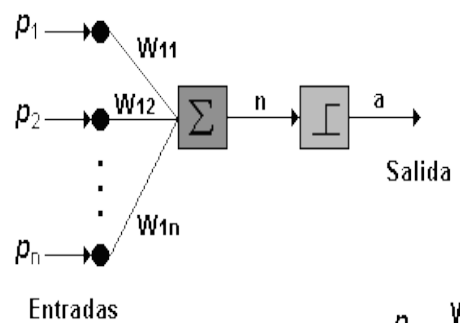


Fig.3.4. Perceptrón

La única neurona de salida del Perceptrón realiza la suma ponderada de las entradas y pasa el resultado a una función de transferencia de tipo escalón.

3.5.2 RNA Adaline

La red Adaline (Neurona Lineal Adaptiva), es similar al Perceptrón, excepto en su función de transferencia, la cual es una función de tipo lineal en lugar de una función lógica como en el caso del Perceptrón. En esta RNA, la neurona realiza la suma de los productos de los valores de entrada y de pesos, y aplica una función de salida para obtener un único valor de salida, el cual debido a su función de transferencia lineal, se encontrará en el rango de +1 si ó -1. La Fig. 3.5 muestra la arquitectura de una RNA Adaline.




Fig.3.5. Estructura de una red Adaline.

3.5.3 RNA Backpropagation

Uno de los grandes avances logrados con la RNA Backpropagation es que esta red aprovecha la naturaleza paralela de las redes neuronales para reducir el tiempo requerido por un procesador secuencial para determinar la correspondencia entre valores de entrada y salida. Es un tipo de red de aprendizaje supervisado, que emplea un ciclo propagación o

adaptación de dos fases. Una vez que se ha aplicado un patrón a la entrada de la red como estímulo, este se propaga desde la primera capa a través de las capas superiores de la red, hasta generar una salida. La señal de salida se compara con la salida deseada y se calcula una señal de error para cada una de las salidas. La importancia de este proceso consiste en que, a medida que se entrena la red, los valores de los pesos de las neuronas de las capas intermedias se modifican de tal modo que las distintas neuronas aprenden a reconocer distintas características del espacio total de entradas [4]. Existen diferentes algoritmos de aprendizaje para RNA Backpropagation entre las que podemos encontrar:

- Red Backpropagation con momentum
- Red Backpropagation con tasa de aprendizaje variable
- Método del Gradiente Conjugado
- Algoritmo de Levenberg - Marquardt

La Fig. 3.6 muestra la arquitectura de una RNA Backpropagation.




Fig.3.6. Red Sencilla de 3 capas Backpropagation

3.5.4 RNA B-Spline.

En el sub-campo matemático de análisis numérico, una función B-spline es una función spline (curva diferenciable definida en porciones mediante polinomios, son utilizados para trabajar tanto en una o en varias dimensiones) que tiene el mínimo apoyo con respecto a un determinado grado, suavidad y partición de su dominio. El término B-spline fue definido por Isaac Jacob Schoenberg y es la abreviatura de spline básica.. Las B-Splines pueden ser evaluadas de una manera numéricamente estable según el algoritmo de Boor [2-5].

Las redes neuronales B-Spline tienen un amplio potencial de aplicaciones ya que es un aproximador universal. Esto implica que se pueden entrenar para modelar funciones lineales o no-lineales con el grado de precisión que se requiera. Las principales ventajas del uso de redes neuronales B-spline en control es su implementación, debido a que permiten reducir la complejidad y costo computacional de algunos controladores no lineales y mejorar el desempeño de los controladores diseñados con técnicas convencionales [6]. En el caso de las B-spline, son un tipo particular de redes neuronales que permiten modelar y controlar sistemas en línea con una gran simplicidad en los cálculos de la señal de control.

REFERENCIAS

- [1]. *Lenin Andrés González Silva. “Redes B-Spline con aprendizaje pso para la estimación de costo”. Tesis para obtener el grado Ingeniero Civil en Informática. Abril 2013. Pontificia Universidad Católica de Valparaíso Facultad de Ingeniería Escuela de Ingeniería Informática.*
- [2]. *Ruben Tapia Olvera. “Utilización del Neurocontrolador B-spline Para Regular el StatCom”. Tesis para Obtener el grado en doctor en Ciencia en la especialidad de Ingeniería Eléctrica. Guadalajara, Jalisco. Diciembre 2006. CINVESTAV Centro de Investigación y de Estudios Avanzados del I.P.N. Unidad Guadalajara.*
- [3] *Simon Haykin. “Neuronal Networks”. Second Edition 2001. Hamilton Ontario, Canada. Pearson. Prentice hall.*
- [4] *Fernando Izurieta y Carlos Saavedra. “Redes Neuronales Artificiales”. Departamento de física, Universidad de Concepción. Concepción, Chile.*
- [5] *“Principales Tipos de Redes Neuronales”. Obtenida el día 20 de octubre del 2013, <http://proton.ucting.udg.mx/posgrado/cursos/idc/neuronales2/General2.htm>.*
- [6] *Paluszky, Prautzsch, Boehm.” Método de Bezier y B-Spline”. Springer verlag berlin heideiberg 2002. universitäts verlag karlsruhe.*

CAPÍTULO 4. Neuro-controlador B-Spline

4.1 Introducción

El diseño y desarrollo del neuro controlador B-Spline se apoya en la simulación con la ayuda del software Matlab™. La finalidad de trabajar con la RNA B-Spline se debe a la sencillez de su algoritmo, ya que le permite aprender en línea la tarea de control. El controlador neuronal de velocidad de un motor de CD fue diseñado mediante simulaciones en tiempo real para analizar la respuesta dinámica del neuro-controlador en lazo cerrado y comparar su desempeño con respecto a un controlador PI. El diseño del neuro-controlador B-Spline consiste en seleccionar las funciones de activación de la RNA llamadas funciones base. Estas funciones base son funciones spline, las cuales pueden ser de distinto orden. De igual forma se tiene que seleccionar el número de funciones base a utilizar por la RNA. Al igual que en el diseño de otros controladores neuronales esta selección se realiza de forma heurística. Una de las principales ventajas de la RNA B-spline radica en el hecho de que sólo se calculan las funciones base que activen los datos de entrada, lo cual reduce la demanda computacional para su procesamiento [1].

4.2 Estructura de la RNA B-spline

La Fig. 4.1 muestra la estructura de una RNA B-spline, la cual está estructurada en tres capas: la capa de entrada, la capa intermedia y la capa de salida.

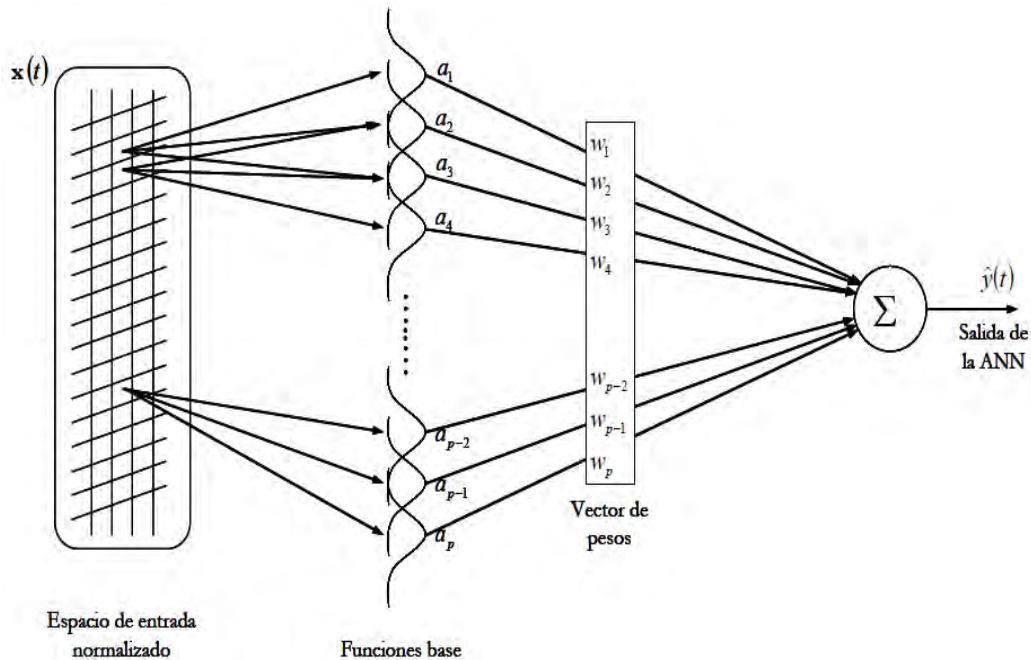


Fig.4.1. Estructura de una RNA B-spline.

Como se observa en la Fig. 4.1, la capa de entrada se encarga de normalizar y distribuir el conjunto de datos de entrada hacia la capa intermedia de la RNA. Por su parte, la capa intermedia se encarga de transformar el conjunto de entradas a la RNA utilizando funciones base, que como se ha mencionado son funciones de tipo spline. Estas funciones base tienen asociadas un conjunto de pesos (vector de pesos), los cuales son ajustados por el algoritmo de aprendizaje para que se asocie con ellos un “aprendizaje” de la RNA [2]. Finalmente la capa de salida realiza la sumatoria del vector transformado de los datos de entrada a la RNA.

4.3 Funciones Base

Las funciones base de la RNA se encargan de transformar el espacio dimensional de las variables de entrada. Estas funciones base, se definen a partir de un conjunto de vectores con puntos de control, como se muestra en la Fig.4.2. Los puntos de control son

distribuidos en función del conocimiento previo de la planta que puede incorporar el diseñador [1-4].




Fig.4.2. Vector de puntos de control para un espacio de entrada unidimensional.

Como se puede observar los puntos de control de las funciones base forman un vector de datos que se compone de puntos interiores y exteriores. Los puntos interiores, $\lambda_{i,j}$, ($j = 1, \dots, r_i$, $i = 1, \dots, l$) cumplen con la siguiente relación:

$$x_i^{\min} < \lambda_{i,1} \leq \lambda_{i,2} \leq \dots \leq \lambda_{i,r_i} < x_i^{\max} \quad (4.1)$$

Donde x_i^{\min} y x_i^{\max} definen los valores mínimos y máximos de la i -ésima entrada a la RNA. El vector de puntos de control se debe definir para cada una de las variables de entrada. De esta forma, si se tiene sólo una variable de entrada la RNA B-Spline utilizará funciones base monovariantes. Si la RNA tiene más de una variable de entrada entonces las funciones base serán multivariantes. Para este trabajo de tesis en que el problema de control se trata de minimizar el error del control de velocidad del motor de CD, sólo existe una variable de entrada a la RNA que es el error por lo que las funciones base utilizadas son funciones monovariantes.

La ventaja de las funciones spline es que están son calculadas recursivamente a partir de operaciones aritméticas, lo que disminuye la cantidad de procesamiento requerido para su cálculo [3].

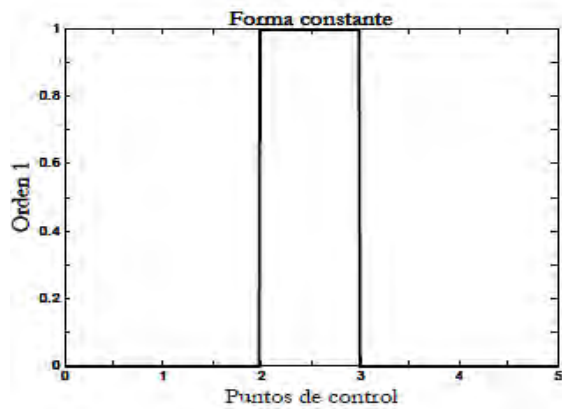
4.3.1 Funciones base monovariante

A partir de los puntos de control que se definen por el diseñador, la j -ésima función base de orden K monovariante se denota por $N_k^j(\cdot)$ y se define por las siguientes ecuaciones de recurrencia [4-5]:


$$N_1^j(x) = \begin{cases} 1 & \text{de } x \in I_j \\ 0 & \text{otro caso} \end{cases} \quad (4.2)$$

$$N_k^j(x) = \left(\frac{x - \lambda_{j-k}}{\lambda_{j-1} - \lambda_{j-k}} \right) N_{k-1}^{j-1}(x) + \left(\frac{\lambda_j - x}{\lambda_j - \lambda_{j-k+1}} \right) N_{k-1}^j(x) \quad (4.3)$$

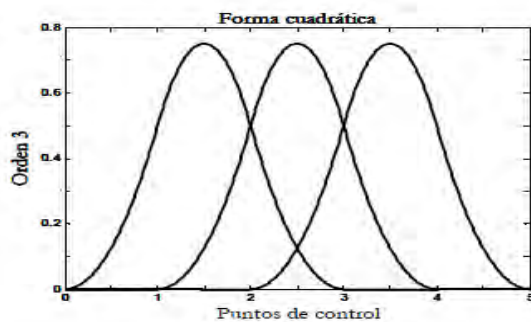
Donde λ_j es el j -ésimo punto de control e $I_j = [\lambda_{j-1}, \lambda_j)$ es el j -ésimo intervalo. Una vez definido el vector de puntos de control y empleando la ec. (4.3) se crean las funciones base monovariante. Un ejemplo de ello son las funciones de orden $K = 1, 2, 3$ y 4 , que se muestran en la Fig. 4.3; se puede ver que la función se vuelve más suave conforme se incrementa su orden.




a) Función base de orden 1



b) Función base de orden 2



c) Función base de orden 3



d) Función base de orden 4

Fig.4.3. Funciones spline de orden 1, 2, 3,4.

Las funciones base B-spline son numéricamente estables, computacionalmente eficientes, y pueden tratar con cualquier distribución estratégica de vectores de puntos de control.

4.3.2 Funciones base multivariable

Una función base multivariable se forma tomando el producto tensorial de n funciones base monovariante, donde una y solamente una función base monovariante se define en cada eje de entrada. Debido a que las funciones base multivariable se forman a partir de las funciones base monovariante, conservan de forma natural todas sus propiedades y cualidades [6]. Algunas funciones multivariable que se pueden crear combinan el orden de

las funciones base multivariable de dos dimensiones. La Fig. 4.4 muestra una función multivariable de dos dimensiones formada con 2 funciones monovariante de orden 3.




Fig.4.4. Función spline multivariable.

4.4 Regla de aprendizaje

Las redes neuronales se configuran de tal forma que al procesar un conjunto de entradas produzca el conjunto de salidas deseadas. Las RNA aprenden a calcular la salida correcta para cada entrada con base a ejemplos. En la actualidad existen un gran número de métodos para encontrar los valores óptimos de los pesos del modelo neuronal. Una manera es ajustar los pesos explícitamente, empleando conocimiento previo del sistema. Otra manera es entrenar la red neuronal proporcionándole patrones para su aprendizaje y manteniendo estos cambios en sus pesos de acuerdo a alguna regla de adaptación [4-6].

Una regla de aprendizaje típicamente minimiza una función de desempeño que se debe especificar antes de que el aprendizaje comience. Las dos formas prácticas para implementar el método de aprendizaje de las RNA consisten en: el entrenamiento por lotes (batch learning) y en línea (online learning).

El entrenamiento por lotes corresponde al método gradiente estándar, donde los pesos de la red se actualizan solo una vez en cada iteración del procedimiento de entrenamiento al presentarle a la RNA un conjunto de datos conocidos y minimizar el error entre la salida deseada y el valor calculado por la RNA.

El entrenamiento en línea es una variación del método del gradiente estándar, donde los pesos de la red se actualizan después de que se procesa cada uno de los ejemplos de aprendizaje [9]. En ingeniería computacional de las redes neuronales, el método del gradiente en línea se emplea comúnmente debido a su simplicidad y eficiencia

La relación de aprendizaje es un parámetro muy importante que establece la convergencia de la regla de entrenamiento; si no se selecciona un valor adecuado, la regla de aprendizaje puede resultar inestable, y por lo tanto no converge.

La simplicidad de la RNA B-spline permite utilizar una regla de aprendizaje en línea para la adaptación de los pesos de sus conexiones. En este trabajo de tesis se utiliza la regla de corrección del error para el neuro-controlador de velocidad del motor de CD.

4.4.1 Regla de Corrección del Error

Esta regla de aprendizaje es una regla simple por lo que es apropiada para ser implementada para el aprendizaje en línea de la RNA. Esta regla de aprendizaje ajusta los pesos de las conexiones de la red en función de la diferencia entre los valores deseados y los obtenidos a la salida de la red, es decir, en función del error cometido en la salida [4-8].

La regla de corrección del error está descrita por la ecuación:

$$e_k(t) = d_k(t) - y_k(t) \quad (4.4)$$

donde:

$e_k(t)$ Determina la señal del error.

$d_k(t)$ Determina la repuesta deseada.

$y_k(t)$ Determina la señal de salida.

La regla de corrección del error ajusta los pesos de la RNA con la finalidad de reducir el error de salida. El ajuste de los pesos es realizado bajo el principio del mínimo disturbio, lo que significa que el valor de los pesos de la RNA son actualizado con pequeños cambios con la finalidad de evitar cambios importantes en la salida de la RNA.

La regla de corrección del error emplea el cálculo del error cuadrático medio como un indicador del desempeño de la RNA. La magnitud del cambio en el valor de los pesos de la RNA es realizado proporcionalmente con base en la ecuación (4.5).

$$w_i(t-1) = \frac{\eta e_i(t)}{\|\mathbf{a}(t)\|_2^2} \mathbf{a}(t) \quad (4.5)$$

Dónde: η es la razón de aprendizaje y $e_i(t)$ es el error instantáneo descrito en la ecuación (4.4).

Finalmente, la actualización de los pesos en cada iteración de la regla de corrección del error está descrito por:

$$w_i(t) = w_i(t-1) + \frac{\eta e_i(t)}{\|\mathbf{a}(t)\|_2^2} \mathbf{a}(t) \quad (4.6)$$

La regla de corrección del error se comporta como un filtro pasa-bajas adaptivo por lo que el ruido de alta frecuencia contenido en el error de la RNA es atenuado por la regla de aprendizaje. La constante de tiempo de este filtro pasa-bajas es inversamente proporcional a la razón de aprendizaje. El valor de la red de aprendizaje debe estar en el rango de: $0 < \eta < 2$, [7]. Los pesos de la RNA convergen, si y solo si, la razón de aprendizaje satisface la condición previa. La razón de aprendizaje es ajustada por el diseñador de forma heurística.

4.5 Diseño del neuro-controlador B-spline.

La configuración del neuro-controlador para el control de velocidad del motor de CD se realizó con base en resultados de simulaciones con el fin de determinar el número de funciones base y razón de aprendizaje más adecuados para el neuro-controlador.

Las pruebas de simulación se realizaron con el programa Simulink™ de Matlab™. La elección de las funciones base se realizó heurísticamente, proponiendo el orden y el número de las mismas para posteriormente mediante simulación determinar la mejor configuración. El criterio de selección del orden y número de las funciones base, así como de la razón de aprendizaje de la RNA B-spline consistió en el seguimiento del valor de referencia de la velocidad para el motor de CD.

El esquema de prueba consiste en variar el valor de referencia para la velocidad del motor de CD, aplicando una señal cuadrada a esta entrada, simulando de esta forma un cambio en forma de escalón del valor de referencia. La evaluación del desempeño del controlador se realiza mediante la comparación del seguimiento de la velocidad del motor con respecto al valor de referencia deseado.

Cabe mencionar que las pruebas de simulación se realizaron con la configuración del método numérico Runger-Kuta en Simulink con un paso de integración fijo de 100 μ s. Esta configuración del método numérico en Simulink permite asegurar que los datos obtenidos en simulación serán cercanos a los valores que se obtendrán en la aplicación real.

4.5.1 Selección del orden de las funciones base.

Este primer conjunto de pruebas tienen como finalidad determinar el número y orden de funciones base más adecuado para que el neuro-controlador realice el control de la velocidad del motor de CD. En esta prueba de simulación, se comparan dos RNA B-spline (RNAB-S) con funciones base de diferente orden. La Fig. 4.5 muestra el esquema simulado con los modelos de las RNAB-S bajo prueba.

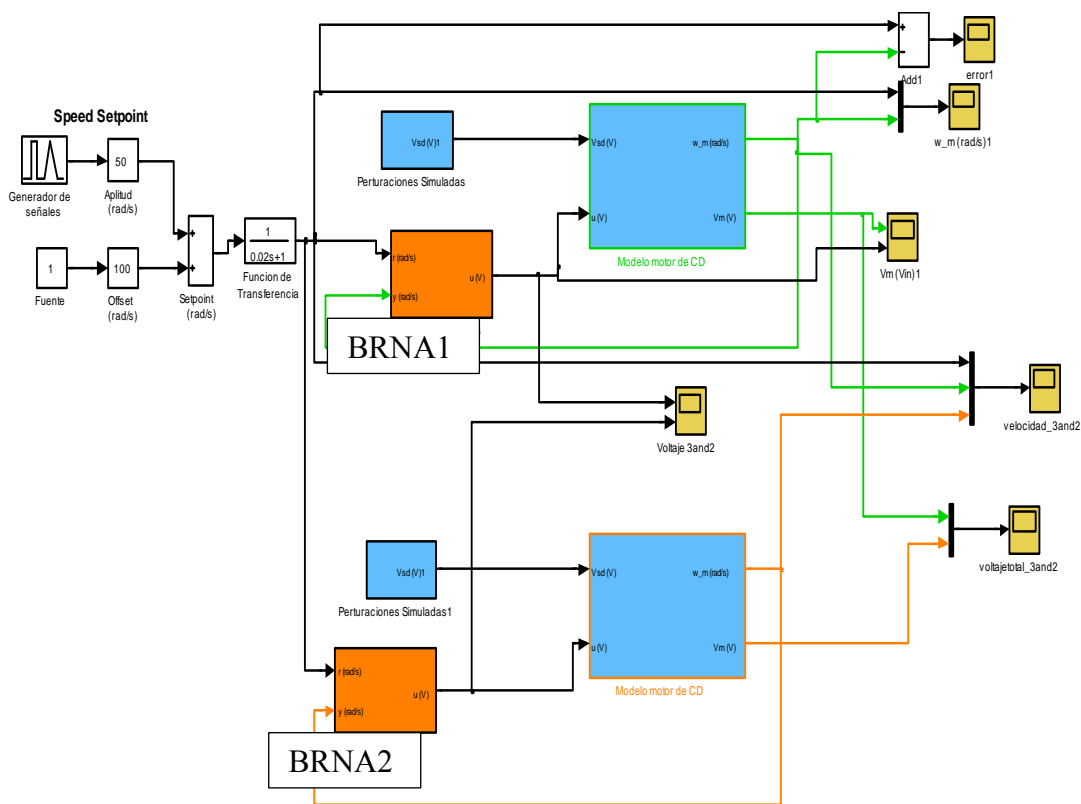


Fig.4.5. Esquema de prueba dos RNAB-S con funciones base de diferente orden.

En el esquema de la Fig. 5.1, cada bloque de color naranja contiene el programa que ejecuta el algoritmo del neuro-controlador con una red RNAB-S, la diferencia entre ellos consiste en el número y orden de funciones base. De esta forma, para el neuro-controlador denominado BRNA1 utiliza una RNAB-S con 3 funciones base de orden 2 y una razón de aprendizaje de 1.3. Por otra parte, el neuro-controlador BRNA2 contiene una RNAB-S con 3 funciones base de orden 3 y una razón de aprendizaje de 1.3.

La Fig. 4.6 presenta los resultados de simulación de los dos neuro-controladores.

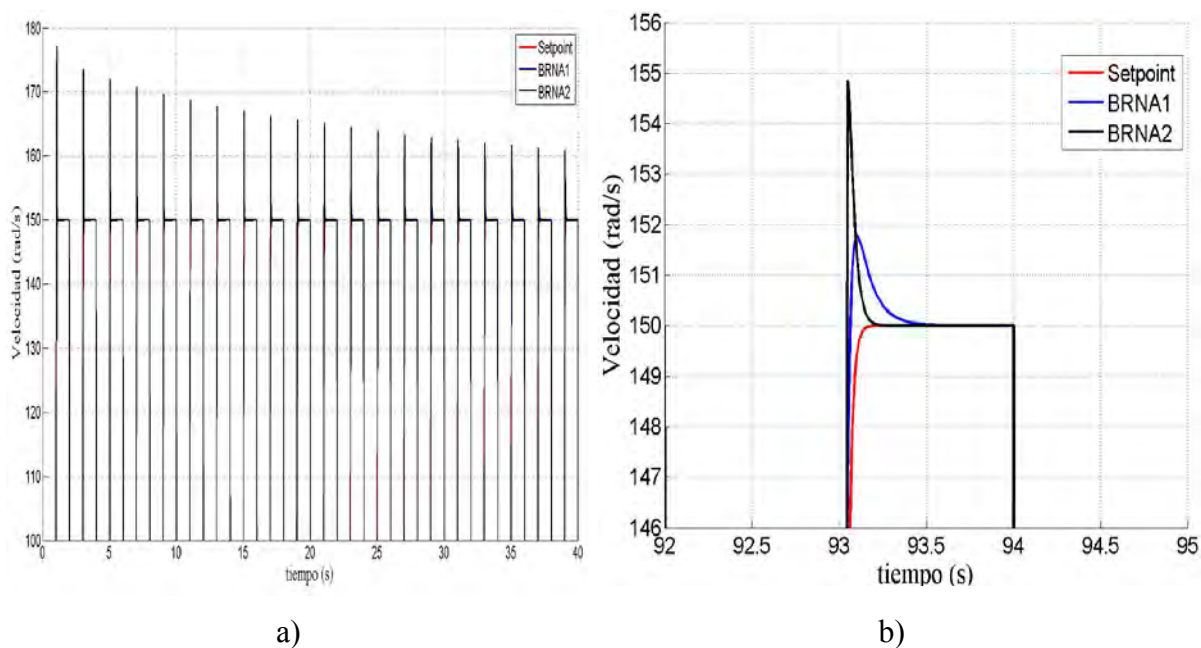


Fig.4.6. Desempeño de los neuro-controladores. (a) Seguimiento del valor de referencia de velocidad. (b) Detalle del seguimiento de velocidad.

La Fig. 4.6 (a) muestra el comportamiento de la velocidad del motor en el seguimiento del valor de referencia impuesto; en donde se puede observar como conforme transcurre el tiempo el sobre-impulso que se presenta en los primeros cambios del valor de referencia de

velocidad van disminuyendo. Estos resultados demuestran dos cosas: la primera es que los dos neuro-controladores han aprendido el comportamiento dinámico del motor y por lo tanto son capaces de controlarlo; y por otro lado ambas redes neuronales demuestran su capacidad de aprendizaje en línea. Por otra parte en la Fig. 4.6 (b) se muestra el detalle del seguimiento del valor de referencia de velocidad en la que se observa que la BRNA1 tiene un mejor seguimiento del valor de referencia con respecto a la BRNA2. El neuro-controlador con la BRNA2 es la que cuenta con 3 funciones base de orden 3 y los resultados demuestran que tiene un menor desempeño con respecto al neuro-controlador con funciones base de orden 2. Este hecho se explica si consideramos que las funciones base de orden 3 requieren de un procesamiento computacional mayor con respecto a las funciones de orden 2, por lo que este tiempo adicional se refleja negativamente en el seguimiento del valor de referencia de la velocidad impuesta al motor de CD. Con base en los resultados de esta prueba se seleccionaron funciones base de orden 2 para el neuro-controlador.

4.5.2 Selección del número de funciones base de orden 2 y la razón de aprendizaje.

En este conjunto de pruebas se comparan dos neuro-controladores con 3 funciones base de orden 2 pero se ha modificado la razón de aprendizaje (η) de las mismas. De esta forma, el neuro-controlador BRNA1 se le ha configurado una $\eta=0.28$ mientras que a la BRNA2 se le ha configurado una $\eta=0.2$. Debido a que el marco de comparación del neuro-controlador se realizará con respecto al controlador Proporcional - Integral (PI), se ha agregado éste en el conjunto de pruebas. La Fig. 4.7 muestra el esquema de simulación para este conjunto de pruebas.

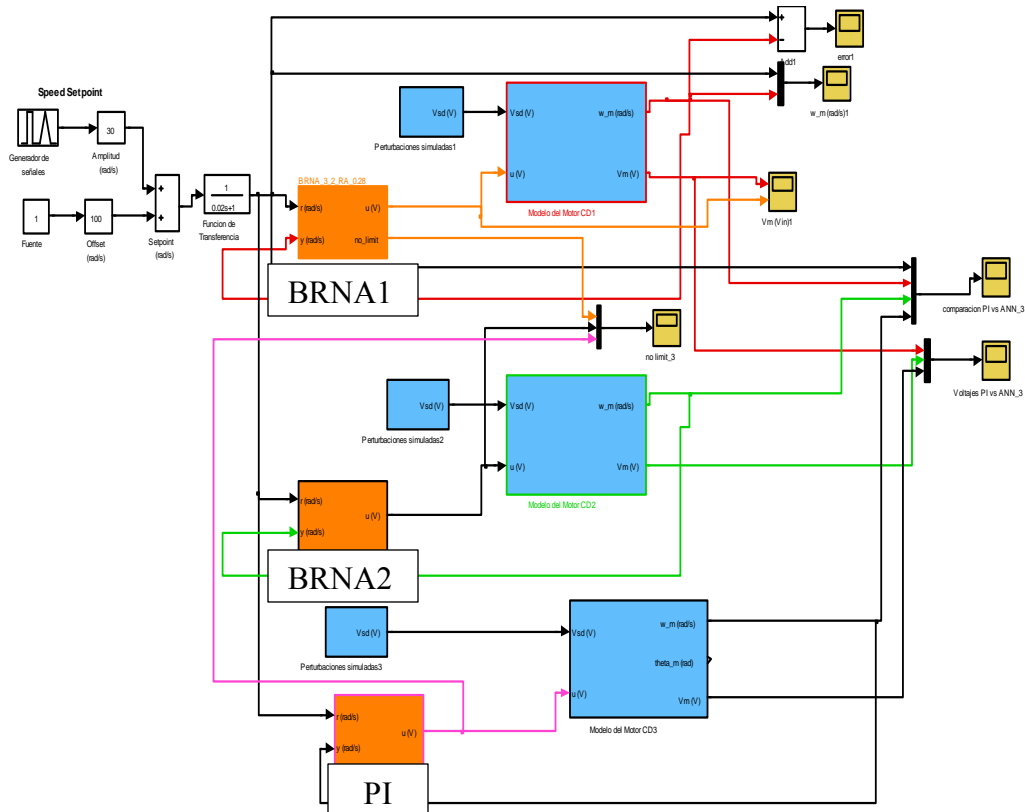


Fig.4.7. Esquema de pruebas de dos neuro-controladores y un controlador PI.

Los resultados de simulación obtenidos se muestran en la Fig.4.8




Fig.4.8. Resultados del esquema de pruebas de dos neuro-controladores con diferente razón de aprendizaje y el control PI.

Los resultados obtenidos tanto de la Fig. 4.8 (a) como la Fig. 4.8 (b) demuestran que tienen un mejor seguimiento del valor de referencia de la velocidad con respecto al controlador PI. Sin embargo, este mejor desempeño de los neuro-controladores es debido a que aplican un voltaje importante al motor de CD en cada transición de la velocidad con respecto al controlador PI como se muestra en la Fig. 4.9.




Fig.4.9. Voltaje de los neuro-controladores y el controlador PI:

Como se observa en la Fig. 4.9, los neuro-controladores aplican voltajes que crecen conforme avanza la simulación. Este hecho puede representar potencialmente que los neuro-controladores tiendan a desestabilizar el sistema. La razón por la que los neuro-controladores están generando estas picos de voltaje hacia el motor de CD se debe a que las 3 funciones base no son suficientes para generar una señal de salida suave que minimice el error del valor de referencia con respecto al valor de la velocidad del motor de CD. A partir de estos resultados se realizó un segundo conjunto de pruebas pero ahora con 4 funciones base de orden 2 para los neuro-controladores. En este mismo sentido, se han utilizado una $\eta=0.015$ para la BRNA1 mientras que a la BRNA2 se le ha configurado una $\eta=0.022$; con la finalidad de también determinar con los resultados de esta simulación el valor adecuado para la razón de aprendizaje. Los resultados obtenidos se muestran en la Fig. 4.10.

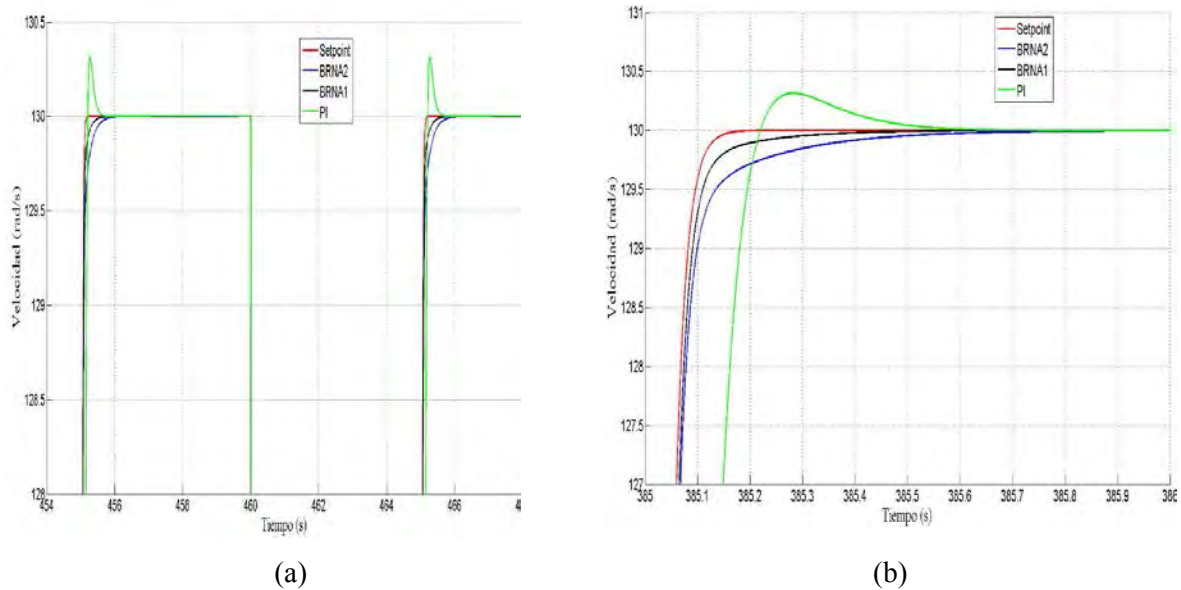


Fig.4.10. Resultados del esquema de pruebas de dos neuro-controladores con 4 funciones base de orden 2 y el control PI.

Los resultados obtenidos en la Fig. 4.10 demuestran que ambos neuro-controladores con 4 funciones base de orden 2 también son capaces de seguir los cambios en el valor de referencia de la velocidad del motor. Además, como se observa en la Fig. 4.10 (b) la BRNA1 tienen un seguimiento más cercano al valor de referencia de la velocidad en el motor; por lo tanto se utilizará una $\eta=0.015$ en la configuración del neuro-controlador final. Por otra parte, la Fig. 4.11 muestra el voltaje aplicado por los neuro-controladores al motor de CD.




Fig.4.11. Voltaje de las RNAB-S y del PI

La gráfica de la Fig. 4.11 muestra un comportamiento acotado del voltaje aplicado al motor de CD. Este hecho permite determinar que los neuro-controladores con 4 funciones splines de orden 2 tienen un mejor desempeño desde el punto de vista del voltaje que aplican al motor de CD para el seguimiento del valor de referencia. Con base en estos resultados se seleccionaron 4 funciones de orden 2 para el neuro-controlador final.

4.5.3 Desempeño del neuro-controlador B-Spline.

El conjunto de resultados de simulación que se presentan en esta sección tiene como finalidad evaluar el desempeño del neuro-controlador diseñado para el seguimiento del valor de referencia de la velocidad del motor de CD. Para ello, se compara la respuesta del neuro-controlador con respecto a la respuesta de un controlador PI para determinar si tiene un mejor desempeño. Es importante hacer notar que el neuro-controlador diseñado está constituido con 4 funciones base de orden 2 y con una $\eta=0.015$. La Fig. 4.12 muestra el esquema de prueba en simulación para la comparación del neuro-controlador y el controlador PI.

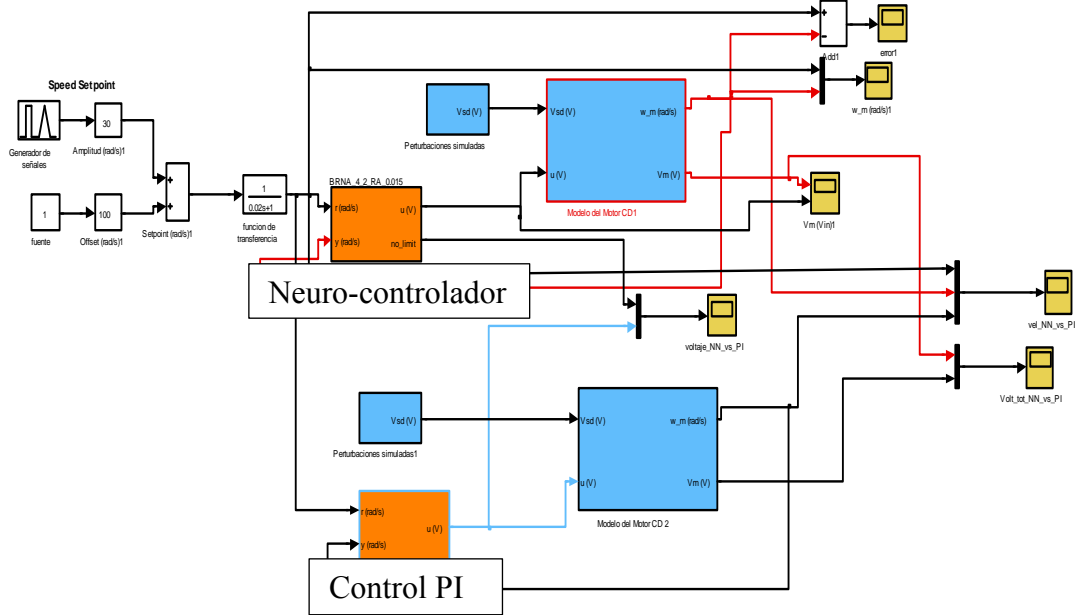


Fig.4.12. Esquema de prueba para la comparación de los controladores neuronal y PI.

La Fig. 4.13 muestra los resultados obtenidos del desempeño del neuro-controlador con respecto al control PI.




Fig.4.13. Resultados de la comparación del neuro-controlador y el control PI.

La Fig. 4.13 (a) muestra que el control PI presenta un sobre-impulso al momento de controlar el valor de la velocidad de referencia. Por su parte, el neurocontrolador tiene un seguimiento suave del valor de referencia, sin sobre-impulsos, lo cual es uno de los aspectos que se busca para el problema de seguimiento del valor de referencia. Esta afirmación queda corroborada con el acercamiento que se muestra en la Fig. 4.13 (b), con lo cual podemos afirmar de forma preliminar que el neuro-controlador tiene un mejor desempeño en el seguimiento de la velocidad de referencia con respecto al controlador PI.

Por otra parte, la Fig. 4.14 muestra los voltajes aplicados por los controladores al motor de CD para regular su velocidad.




Fig.4.14. Voltaje aplicado al motor de CD por los controladores bajo prueba.

En la gráfica de la Fig. 4.14 se observa que el neuro-controlador si bien aplica impulsos de voltaje al motor de CD, este se mantiene acotado. Este hecho permite asegurar que el neuro-controlador mantendrá una operación estable en el seguimiento de cambio de referencia. Por su parte el controlador PI no genera estos pulsos de voltaje, pero que más

sin embargo se requieren para que la velocidad del motor siga el valor de referencia como lo demuestran las gráficas de la Fig.4.13.

REFERENCIAS

- [1]. *Ruben Tapia Olvera. "Utilización del Neurocontrolador B-spline Para Regular el StatCom". Tesis para Obtener el grado en doctor en Ciencia en la especialidad de Ingeniería Eléctrica. Guadalajara, Jalisco. diciembre 2006. CINVESTAV Centro de Investigación y de Estudios Avanzados del I.P.N. Unidad Guadalajara.*
- [2]. *Damián Jorge Matich. "Redes Neuronales: Conceptos Básicos y Aplicaciones". Marzo 2001. Universidad Tecnológica Nacional – Facultad Regional Rosario Departamento de Ingeniería Química Grupo de Investigación Aplicada a la Ingeniería Química (GIAIQ).*
- [3]. *"Redes Neuronales Artificiales". Obtenida el día 26 de octubre del 2013. <http://www.slideshare.net/camilorene/inteligencia-artificial-clase-3>*
- [4]. *Simon Haykin. "Neuronal Networks". Second Edition 2001. Hamilton Ontario, Canada. Pearson. Prentice hall.*
- [5]. *Laurene Fausett, "Fundamentals of Neural Networks Architectures, Algorithms, and Applications," Prentice-Hall, Inc., 1994.*
- [6] *James A. Momoh, Mohamed E. El-Hawary. "Electric Systems, Dynamics, and Stability with Artificial Intelligence Applications," Marcel Dekker, Inc., 2000.*
- [7] *Cox M.G., "The numerical evaluation of B-splines", J. Inst. Math. Appl., vol. 10. Institute of Technology, 1995.*
- [8] *Zebirate, S., Chaker, A., Feliachi, A., "Neural network control of the unified power flow controller," IEEE Power Engineering Society General Meeting.*
- [9] *C. M. Lim and Q. Li, "An enhanced adaptive neural network control scheme for power systems," IEEE Trans. on Energy Conversion.*

CAPÍTULO 5. RESULTADOS EXPERIMENTALES

5.1 Introducción

En este capítulo se presentan los resultados experimentales del desempeño del neuro-controlador en el control de la velocidad del motor de CD. Las características del neuro-controlador B-spline consisten en que es un controlador adaptivo por lo que tiene la capacidad de controlar sistemas que son no-lineales así como también tiene la capacidad de aprender en línea la dinámica no-lineal de la planta. Estas características le permiten al neuro-controlador compensar variaciones de los parámetros de la planta a controlar, compensar perturbaciones, ruidos de medición o controlar dinámicas no modeladas.

Los resultados experimentales comprenden simulación hardware-in-loop (HIL) en tiempo real así como también resultados controlando un motor de CD real.

La simulación hardware-in-loop es una técnica de rápido desarrollo de prototipos para evaluar rápidamente el desempeño de un sistema antes de ser implementado con la planta real. Esta evaluación permite de manera preliminar identificar funcionamientos anómalos o variables que excedan un valor límite preestablecido. De esta forma, en este trabajo de tesis se usa la técnica HIL para validar la operación del neuro-controlador en el control de velocidad del motor de CD. La simulación HIL fue implementada en la plataforma dSPACE© ds1104, la cual es programada a partir del modelo desarrollado en Simulink desde donde se compila tal modelo.

Por otra parte, se utilizó el motor de CD del módulo entrenador de la marca Quanser para obtener los resultados del desempeño del neuro-controlador operando con la planta real. En estas pruebas, el neuro-controlador fue programado en la plataforma dSPACE para de esta forma generar la señal de control adecuada y controlar la velocidad del motor de CD.

Finalmente y a manera de comparación se utiliza un controlador PI para tener un marco de referencia en la evaluación del desempeño del neuro-controlador diseñado.

5.2 Configuración del entorno HIL.

En el esquema de simulación HIL, el valor de referencia de velocidad para el motor de CD es obtenido a partir de un generador de funciones. El generador de funciones es configurado para generar una señal cuadrada de voltaje la cual es introducida a la plataforma dSPACE como se muestra en la Fig. 5.1.




Fig.5.1. Configuración del entorno de simulación HIL.

Por otra parte se ha conectado un osciloscopio conectado a la salida de la plataforma dSPACE para observar las señales de voltaje que generar y que son proporcionales al voltaje que aplicarían los controladores al motor de CD para regular su velocidad, así como también disponer de una señal de voltaje proporcional a la velocidad del motor de CD.

Los resultados de la simulación HIL son desplegados visualmente en la aplicación Control Desk que se encuentra ejecutando en la PC, como se observa en la Fig. 5.1. De igual forma, la aplicación Control Desk permite el registro de los datos de simulación y los almacena en formato de texto. En este trabajo se utilizó esta característica de la aplicación para luego graficar los datos en Matlab en los puntos que nos interesaba resaltar.

5.3 Desempeño del neuro-controlador B-Spline en entorno HIL

Los resultados mostrados en esta sección corresponden a los datos obtenidos de la plataforma dSPACE operando en tiempo real. Estas simulaciones incluyen tanto al neuro-controlador como al controlador PI, tal como se muestra en la Fig. 5.2.

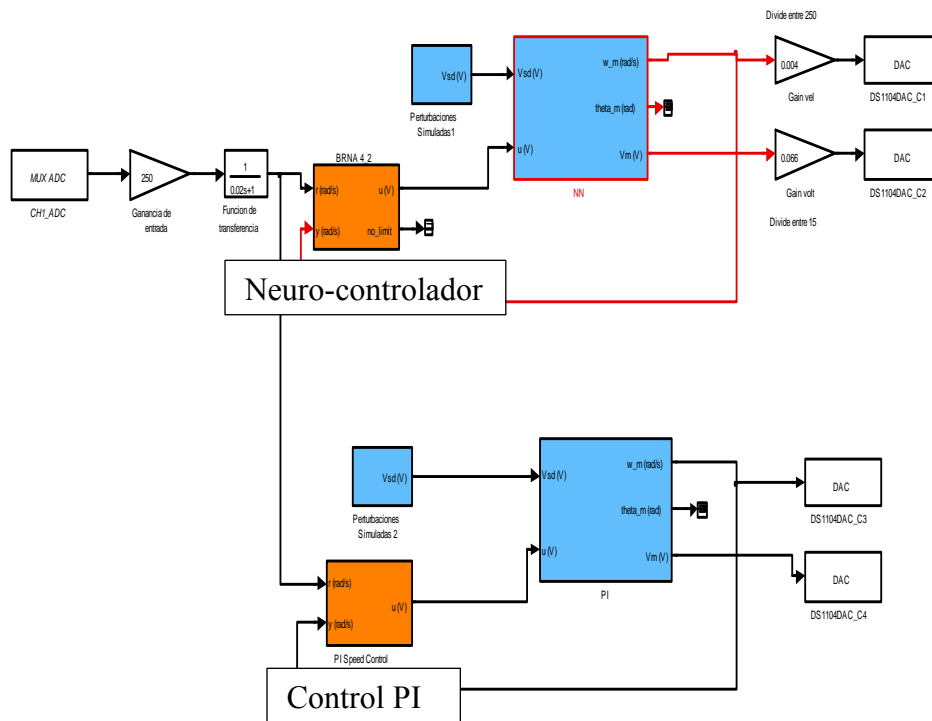


Fig.5.2. Esquema de prueba del Neuro-controlador y PI en tiempo real.

Se observa en la Fig. 5.2 que el esquema a simular en la plataforma HIL es similar al esquema de control utilizado en la sección, con la diferencia que el valor de referencia de entrada proviene del generador de funciones y por lo tanto se ha colocado un bloque de ganancia a la entrada CH1_ADC para hacer compatible la señal de voltaje de entrada con respecto a la velocidad deseada. De igual forma a la salida de los controladores (DAC), se han colocado bloques de ganancia con la misma finalidad.

Es importante mencionar que la plataforma dSPACE cuando trabaja con señales analógicas, éstas deben ser acotadas en el rango de ± 10 V. Debido a ello las señales de entrada o salida de la plataforma dSPACE son acondicionadas mediante bloques que atenúan o amplifican la señal de interés, tal como se observa en la Fig. 5.2.

La Fig. 5.3 muestra los resultados experimentales obtenidos con la plataforma HIL. El neuro-controlador está constituido con 4 funciones base de orden 2 y con una $\eta=0.015$. Se analiza un cambio del valor de referencia de la velocidad de 5 rad/s a 70 rad/s.




Fig.5.3. Respuesta de los controladores a un cambio de velocidad de 5 rad/s a 70 rad/s.

En la Fig. 5.3 (a) se observa que en el inicio de la etapa de prueba, el neuro-controlador presenta un sobre-impulso en el control de la velocidad. Sin embargo, conforme el tiempo transcurre este sobre-impulso va disminuyendo. Este hecho significa que el neuro-controlador va aprendiendo la respuesta dinámica del motor y su desempeño mejora conforme este aprendizaje se refuerza. En la Fig. 5.3 (b) se observa el detalle de control de velocidad del motor en el cual se observa como el neuro-controlador realiza un seguimiento más cercano del valor de referencia con respecto al controlador PI. Además, el neuro-controlador ya no presenta el sobre-impulso, signo de que para $t=27.2$ s ya aprendió la respuesta dinámica del motor.

En la Fig. 5.4 se muestran los voltajes generados por los controladores para controlar la velocidad del motor de CD. Se observa que el neuro-controlador si bien genera voltaje con picos de tensión estos están acotados en magnitud, lo que es un indicador de que tiene un comportamiento estable.




Fig.5.4. Voltajes generados por los controladores para controlar la velocidad de 5 rad/s a 70 rad/s.

En la Fig. 5.5 se muestra un cambio en la región de operación del motor de CD. Ahora el valor de referencia cambia de 65 rad/s a 130 rad/s.




Fig.5.5. Respuesta de los controladores a un cambio de velocidad de 65 rad/s a 130 rad/s.

La Fig. 5.5 (a) muestra nuevamente que al inicio el neuro-controlador presenta un sobreimpulso el cual va disminuyendo conforme transcurre el tiempo, signo de que el neuro-controlador está aprendiendo. La Fig. 5.5 (b) muestra el detalle en el seguimiento del valor de referencia en donde se observa que el neuro-controlador ya no presenta el sobreimpulso.

En la Fig.5.6 se presenta los voltajes que generan el neuro-controlador BRNA y el PI. Se observa que los voltajes son acotados en magnitud lo que significa que ambos controladores tienen un comportamiento estable.

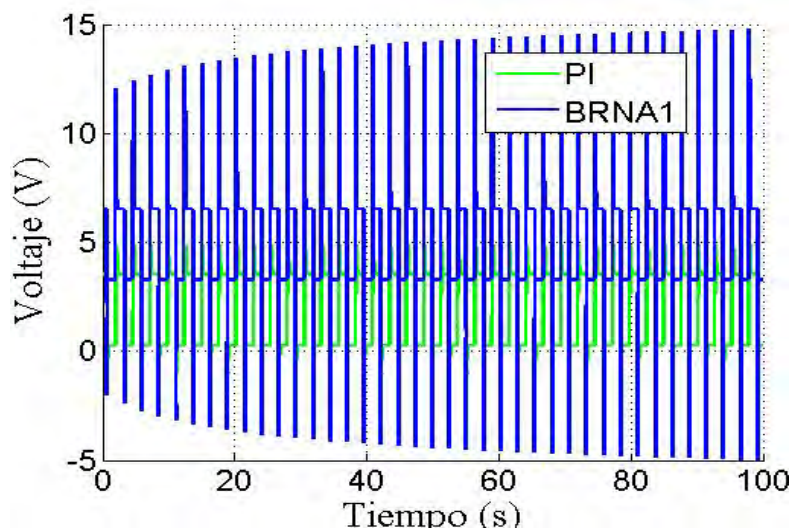


Fig.5.6. Voltajes generados por los controladores para controlar la velocidad de 65 rad/s a 130 rad/s.

5.4 Desempeño del neuro-controlador B-Spline ante una perturbación.

Para esta prueba se aplica una perturbación al sistema para observar el comportamiento que tiene el neuro-controlador. Este análisis es de importancia debido que el motor no está exento a estos tipos de fenómenos que suceden durante su operación. La perturbación puede representar variaciones de tensión, corriente o frecuencia, lo cual puede modificar el valor de regulación del controlador.

En la Fig. 5.7 se presenta el esquema de prueba para analizar la influencia de una perturbación en el control de velocidad. Para este caso el valor de referencia se mantiene constante y la perturbación es la que actúa sobre el motor de CD.

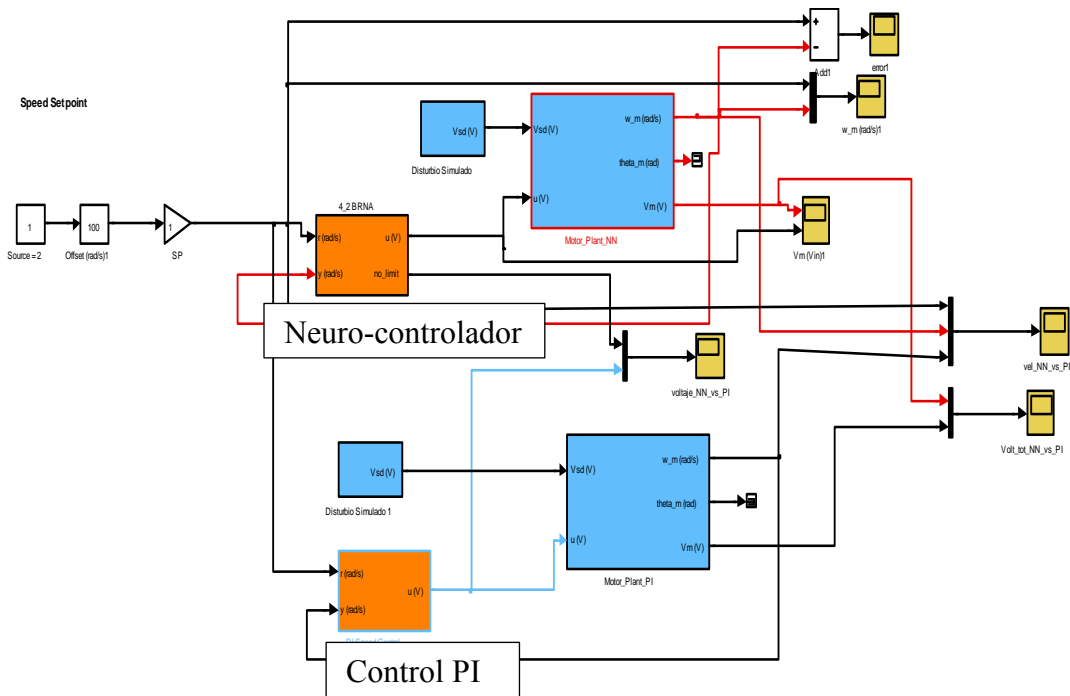


Fig.5.7. Esquema de prueba del neuro-controlador B-Spline aplicando una perturbación.

En la Fig.5.8 se presentan los resultados de los controladores ante una perturbación.




Fig.5.8. Desempeño de los controladores ante un disturbio

La Fig. 5.8 (a) muestra que el neuro-controlador presenta un mejor desempeño ante la perturbación con respecto al controlador PI. La Fig. 5.8(b) muestra que mientras la perturbación ocasiona una variación del 15% en el control de la velocidad por el neuro-controlador B-spline, en el caso del controlador PI esta variación llega a ser de 45%, esto significa una variación 3 veces mayor en el control de la velocidad del motor de CD. Estos resultados demuestran que el neuro-controlador presenta un comportamiento adaptativo ante el cambio la presencia del disturbio en el sistema.

La Fig. 5.9 muestra el voltaje generado por los controladores para compensar el disturbio. Se observa que el voltaje generado por el neuro-controlador presenta un comportamiento suave.




Fig.5.9. Voltaje de los controladores para compensar la perturbación.

5.5 Desempeño del neuro-controlador B-Spline ante cambio de parámetros del motor de CD.

Uno de los problemas que se pueden presentar durante el tiempo de operación del motor de CD es el cambio de sus parámetros de construcción. Esto se puede deber a los efectos de la temperatura, desgaste de los elementos mecánicos o envejecimiento de los materiales. Por otra parte, si consideramos el caso hipotético en que se requiera reemplazar el motor, es muy posible que el nuevo motor no tenga los mismos parámetros que el original. Ante esta problemática es deseable que el controlador tenga la capacidad de compensar esta variación de parámetros sin que afecte la regulación de velocidad del motor.

De esta forma, el conjunto de pruebas que se presenta en esta sección tienen como finalidad mostrar el comportamiento del neuro-controlador ante un posible cambio de parámetros del motor. Para ello, el modelo del motor de CD se ha modificado a la función de transferencia de la ec. (6.1).

$$F(s) = \left(\frac{0.1}{0.5s + 1} \right) \quad (6.1)$$

Por otra parte, la Fig. 5.10 muestra el desempeño de los controladores ante el cambio de parámetros del motor de CD.




Fig.5.10. Resultados de velocidad de la BRNA y el PI con un motor distinto.

En la Fig. 5.10 se puede observar como el neuro-controlador presenta un mejor desempeño con respecto al controlador PI ante la variación de parámetro del motor de CD. Este resultado muestra el comportamiento adaptivo del neuro-controlador para el control de velocidad del motor de CD.

En la Fig.5.11 se presenta los voltajes generados por los controladores para el caso de cambio de parámetro del motor de CD. El rango de voltaje es diferente con respecto a las pruebas anteriores ya que el modelo utilizado corresponde a un motor de mayor potencia.




Fig.5.11. Voltajes de los controladores ante cambio de parámetros del motor.

5.6 Pruebas experimentales con módulo entrenador del motor de CD.

En esta sección se presentan los resultados del desempeño tanto del neuro-controlador B-spline como el controlador PI con la planta real del motor de CD. La Fig. 5.12 muestra la configuración del esquema de prueba utilizado para el control de velocidad del motor, dónde nuevamente se utiliza un generador de funciones para general el valor de referencia de velocidad para el motor de CD.

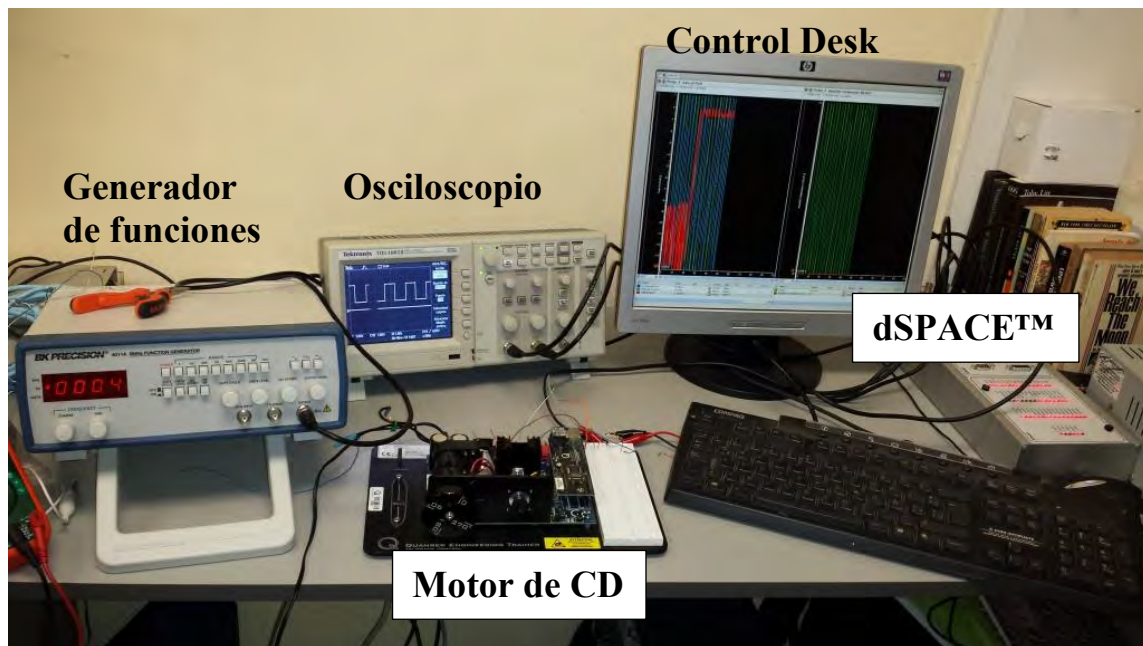


Fig.5.12. Configuración del esquema de prueba con motor real.

Es importante hacer notar que ente conjunto de pruebas, la plataforma dSPACE sólo ejecuta el algoritmo de los controladores. De esta forma en la Fig. 5.13 se muestra el desempeño del controlador PI en el seguimiento del valor de referencia de velocidad para el motor de CD.




Fig.5.13. Desempeño del controlador PI con el motor real.

Por otra parte en la Fig. 5.14 se muestra el desempeño del neuro-controlador con la planta real.




Fig. 5.14. Desempeño del controlador PI con el motor real.

Comparando el desempeño de los controladores con base en las Figs. 5.13 y 5.14 se observa que el neuro-controlador Bspline tiene un seguimiento más cercano del valor de referencia de velocidad con respecto al controlador PI. Estos resultados con la planta real demuestran el desempeño superior del neuro-controlador con respecto al controlador PI.

CONCLUSIONES

El principal objetivo de esta tesis fue diseñar el neuro-controlador aplicado a una red neuronal B-Spline para el control de velocidad de un motor de CD en tiempo real. Los resultados obtenidos, tanto de simulación como experimentales, demuestran un desempeño superior del neuro-controlador B-spline.

Las redes neuronales pueden operar de dos formas: modo de aprendizaje o entrenamiento, y el modo de ejecución y se distinguen por su modo de entrenamiento que puede ser: Supervisado y No Supervisado.

Se puede determinar qué para el diseño de una neurona artificial B-Spline los elementos principales son:

- El conjunto de procesadores elementales o neuronas artificiales.
- El patrón de conectividad o arquitectura.
- Las funciones de activación o transformación.
- La regla de aprendizaje.

Debido a que las características del diseño eran que el neuro-controlador tenía que aprender en línea las no linealidades del motor y compensar el efecto del disturbio se realizaron diferentes tipos de pruebas para poder obtener tener el neuro-controlador con mejor desempeño.

Las pruebas de simulación se realizaron en el software matemático de Simulink™ de Matlab™. en donde se llevaron a cabo diferentes simulaciones esto se debió a que teníamos que ajustarnos a las características del controlador PI y ajustar nuestro neuro- controlador B-Spline encontrando los parámetros adecuados: razón de aprendizaje, cantidad de splines y las funciones bases.

El neuro-controlador con mejor desempeño fue el de 4 Splines, con función base de orden 2, con una razón de aprendizaje de 0.015. Con base en este diseño se simuló en tiempo real con la plataforma Hardware-in-loop dSPACE.

Es importante definir que el diseño del modelo neuronal B-Spline presentado en este trabajo no es único, se pueden emplear diferentes modelos neuronales, reglas de aprendizaje, funciones base, y podríamos obtener resultados semejantes. Depende del diseño para tener información concreta y sólida, conocer las características detalladas del sistema que se desee controlar, al igual el conocimiento sobre las propiedades y características de las redes neuronales. Sin embargo, si se busca realizar un control de bajo costo computacional, eficaz y con simplicidad en los cálculos, el controlador B-spline es una de tantas opciones ideales. Finalmente, con los resultados mostrados se corroboran las expectativas de los modelos neuronales, teniendo la posibilidad de ampliar su rango de aplicación y realizar el control de sistemas de para el control de velocidad con otros dispositivos con el objetivo de una aplicación en tiempo real.