


CT-769-SS1

Don - 2014



Centro de Investigación y de Estudios Avanzados
del Instituto Politécnico Nacional
Unidad Guadalajara

Aplicación de observadores conmutados para motores de inducción

**CINVESTAV
IPN
ADQUISICION
LIBROS**

Tesis que presenta:
Luis Alberto Esparza García

para obtener el grado de:
Maestro en Ciencias

en la especialidad de:
Ingeniería Eléctrica

Director de Tesis
Dr. Bernardino Castillo Toledo

CLASIF..	CT 00 6 73
ADQUIS..	CT-769-SS1
FECHA:	23-06-2014
PROCED..	Don.- 2014
\$	

xx (213855.1)

Aplicación de observadores conmutados para motores de inducción

**Tesis de Maestría en Ciencias
Ingeniería Eléctrica**

Por:

Luis Alberto Esparza García
Ingeniero en Mecánica

Universidad Autónoma de Nayarit 1997-2002

Director de Tesis

Dr. Bernardino Castillo Toledo

CINVESTAV del IPN Unidad Guadalajara, Septiembre de 2013.

Agradecimientos

A mi esposa, **Lydia Larissa Castro Rangel**, por su apoyo y amor incondicional.

A mi madre, **Alejandrina García Calderón**, por sus consejos.

A mi asesor de tesis, **Dr. Bernardino Castillo Toledo**, porque a pesar de su saturada agenda me brindó su conocimiento, apoyo y paciencia durante el desarrollo de la tesis.

A mis sinodales, **Dr. Antonio Ramírez Treviño** y **Dr. Enrique Javier Aguayo Lara**, por sus revisiones y exégesis contribuyeron a enriquecer este trabajo.

A mis compañeros, **Cesar Alberto Gómez Guzmán**, **Riemann Ruiz Cruz**, por haberme ofrecido su amistad y apoyo durante mi estancia en CINVESTAV.

Al CINVESTAV por darme la oportunidad de realizar mis estudios de maestría y de manera muy especial a la **UNIVERSIDAD AUTONOMA DE NAYARIT** por el apoyo económico.

Resumen

Los motores lineales son un tipo particular de motor eléctrico utilizado en trenes de alta velocidad, ascensores, puertas deslizantes, aplicaciones militares, en parques de diversiones y aplicaciones específicas como catapultar aviones desde plataformas.

Actualmente ha habido un gran interés en la utilización de redes neuronales para identificación y control de sistemas no lineales. Una de las muchas razones por las cuales se ha implementado el uso de las redes neuronales es que modelan sistemas no lineales a pesar de que existan variaciones de parámetros y perturbaciones externas, con esta aplicación se logra obtener un modelo matemático que emula al sistema real.

Esta tesis muestra el uso de Redes Neuronales Recurrentes de Alto Orden Discretas (DRHONN por sus siglas en inglés), para identificar un Motor de Inducción Lineal (MIL) y un control por retroalimentación de estados para el seguimiento de velocidad para el MIL. El algoritmo de entrenamiento para Red Neuronal Recurrente de Alto Orden Discreta (DRHONN) está basado en el filtro de Kalman Extendido.

Abstract

Linear motors are a particular type of electric motor used in high-speed trains, elevators, sliding doors, military, amusement parks and currently the Navy is considering to catapult planes from platforms.

Currently there has been great interest in using neural networks for identification and control of nonlinear systems. One of the many reasons why we have implemented the use of neural networks is that modeling nonlinear systems although there are variations in parameters and external disturbances, this application is able to obtain a mathematical model which emulates the real system.

This thesis demonstrates the use of Recurrent Neural Networks High Order Discrete (DRHONN) for its acronym in English, to identify a Linear Induction Motor (MIL) and a state feedback control for tracking speed for the MIL. The training algorithm for neural network Recurrent High Order Discrete (DRHONN) is based on the Extended Kalman filter.

Índice General

1. Introducción	1
1.1 Motivación	1
1.2 Objetivo	1
1.3 Justificación	2
1.4 Revisión de Literatura	2
1.5 Estado del Arte	4
1.6 Propuesta del Trabajo	5
2. Motor de Inducción	6
2.1 Motor de Inducción de Desplazamiento Lineal	6
2.2 Construcción y Clasificación	6
2.3 Modelos Matemáticos del Motor de Inducción Lineal	9
2.4 Simulación	10
3. Redes Neuronales	23
3.1 Redes Neuronales	23
3.2 Redes Neuronales Recurrentes de Alto Orden	23
3.3 Algoritmo de entrenamiento	24
4. Identificación Neuronal	28
4.1 Identificador Neuronal Recurrente de Alto Orden	28
4.2 Simulación	32
5. Control Neuronal	38
5.1 Control Neuronal Recurrente de Alto Orden por retroalimentación de Estados	38
5.2 Ley de control	40
5.3 Simulación	41
6. Conclusiones	44

6.1 Trabajo Futuro

45

Bibliografía

46

Lista de figuras

Figura 1. Conversión del motor rotatorio a motor lineal	7
Figura 2. Clasificación de los motores lineales.	8
Figura 3. Simulación de la corriente (primer modelo).	12
Figura 4. Simulación de la posición (primer modelo).	12
Figura 5. Simulación de la velocidad (primer modelo).	13
Figura 6. Simulación de la aceleración (primer modelo).	13
Figura 7. Simulación de la corriente (segundo modelo).	15
Figura 8. Simulación de la posición (segundo modelo).	16
Figura 9. Simulación de la velocidad (segundo modelo).	16
Figura 10. Simulación de la aceleración (segundo modelo).	17
Figura 11. Simulación de la corriente i_{qs} (tercer modelo).	19
Figura 12. Simulación de corriente i_{ds} (tercer modelo).	20
Figura 13. Simulación del flujo del secundario λ_{qr} (tercer modelo).	20
Figura 14. Simulación del flujo del secundario λ_{dr} (tercer modelo).	21
Figura 15. Simulación de la posición (tercer modelo).	21
Figura 16. Simulación de la velocidad (tercer modelo).	22
Figura 17. Simulación de la aceleración (tercer modelo).	22
Figura 18. Red neuronal recurrente de alto orden discreta.	31
Figura 19. Esquema de identificación.	32
Figura 20. Identificación de la Posición del LIM, (posición color magenta e identificador color amarillo).	33
Figura 21. Error de identificación de la posición.	33
Figura 22. Identificación de la Velocidad del LIM (velocidad color magenta e identificador color amarillo).	34
Figura 23. Error de identificación de la velocidad.	34
Figura 24. Validación de la Identificación de la Posición del LIM (posición color magenta e identificador color amarillo).	35
Figura 25. Error en la validación de identificación de la posición.	35
Figura 26. Validación de la Identificación de la Velocidad del LIM (velocidad color	36

magenta e identificador color amarillo).

Figura 27. Error en la validación de identificación de la velocidad.	36
Figura 28. Esquema de control del LIM basado en un identificador.	40
Figura 29. Error de control de la velocidad.	41
Figura 30. Seguimiento de la velocidad.	42
Figura 31. Error de control de la velocidad cambiando los parámetros de la planta.	42
Figura 32. Seguimiento de la velocidad cambiando los parámetros de la planta.	43

CAPÍTULO 1

Introducción

En este capítulo se brinda una explicación sobre las razones por las cuales fue seleccionado el tema de tesis y la importancia que tiene su desarrollo.

1.1 Motivación

Las redes neuronales se han establecido como una metodología adecuada para la aproximación de funciones no lineales; debido a esto son muy empleadas; por esta razón son implementadas en la identificación de sistemas no lineales para obtener modelos con dinámica muy cercana a la del sistema real [14].

Los requerimientos para una red neuronal son menores en comparación con los procedimientos clásicos de identificación. Comparando ambos procedimientos desde el punto de vista de entrada y estructura, observamos que el usuario debe especificar los datos para el proceso de entrada-salida idénticamente en ambos tipos de procedimientos. En cuanto a la estructura, en los procedimientos clásicos el usuario debe especificar la característica de la estructura de la relación entre las entradas y las salidas, a veces muy complejas, mientras que para la identificación usando las redes neuronales solo se debe especificar la topología de la red. La red neuronal no intenta asumir ninguna estructura de la relación entrada-salida, la red crea la relación de las entradas a las salidas basándose en los ejemplos proporcionados durante el entrenamiento. Lo que se le pide a la red en este caso, es que internamente identifique un modelo capaz de reproducir valores numéricos que se asemejen a los valores de algún sistema físico [21].

La mayor motivación de este trabajo es desarrollar una identificación del MIL a partir del proceso de entrada-salida de los datos utilizando una DRHONN.

1.2 Objetivo

1. Desarrollar un identificador neuronal recurrente de alto orden discreto para el MIL.
2. Desarrollar un control neuronal recurrente de alto orden discreto por retroalimentación de estados para el MIL.

1.3 Justificación

El motor de inducción lineal no cuenta con un modelo que represente su dinámica y una manera de obtenerlo es a través de la identificación.

Un identificador es un dispositivo que tiene la función de hacer que tanto la señal de entrada como su respuesta sean o parezcan idénticas. La función de dicho identificador en el caso que se presenta, realiza la función de copiar la respuesta del MIL, el cual es sometido a una excitación exterior, tratando al sistema a copiar como una caja negra, la cual no conocemos ni su composición ni su respuesta a la excitación exterior. El mecanismo encargado de copiar el funcionamiento del MIL, es una red neuronal entrenada con un algoritmo de entrenamiento específico. Los pesos son los estados a estimar y la salida de la red es la medición requerida. Y como referencia, para que la red calcule el error que está cometiendo, se toma la diferencia entre la salida de la red y la salida del MIL.

Una vez que termine el aprendizaje, el sistema identificador, será capaz de reproducir la respuesta, si la entrada del dispositivo identificador es la señal de entrada con la cual se ha entrenado la red.

La interface con el usuario, se hará a través de una tarjeta de adquisición de datos NI-USB-6008 y el software Matlab® donde el usuario podrá seleccionar los diferentes parámetros para el entrenamiento de la red neuronal, y ver los resultados de dicho entrenamiento, para comprobar que el entrenamiento se está realizando convenientemente.

1.4 Revisión de Literatura

Para la identificación del MIL ya existen trabajos previos como [24], En este trabajo se demuestra la aplicación de las redes neuronales recurrentes para la identificación y control de un motor de inducción de desplazamiento lineal. En particular se utilizan redes neuronales recurrentes de alto orden por sus excelentes propiedades de identificación de sistemas no lineales. La identificación de la planta se realiza mediante una estructura por bloques, la cual permite linealizar el sistema y proponer una ley de control basada en modos deslizantes. Se demuestra la robustez del controlador mediante simulaciones. Este trabajo también representa una propuesta de control inteligente para ser aplicada a sistemas altamente no lineales. La estrategia no requiere conocer el modelo de la planta y resulta

Capitulo1. Introducción

atractiva para trabajar con los efectos indeseables de los motores lineales; [5], Este trabajo de investigación muestra un método de sintetizado a un motor de inducción lineal de doble lado. En tal sentido optimiza su eficiencia y el factor de potencia, muestra como estos fenómenos son modelados y que parámetros son variados para controlar estos fenómenos, discute también el modelado de varios esquemas de control; [16],Este documento presenta un esquema de control por campo orientado del motor de inducción lineal (LIM) con el fin de lograr un alto rendimiento. Se deriva del modelo dinámico del LIM teniendo en cuenta los efectos finales. También analiza la ecuación de carga mecánica modificada teniendo en cuenta el efecto de la fuerza de atracción sobre el rendimiento del motor de inducción lineal. Presenta la estrategia de control por campo orientado. Los resultados de simulación son presentados para mostrar que el sistema de control tiene una rápida respuesta de la velocidad y las características de empuje robustos, [4] En este trabajo se utilizan redes neuronales recurrentes de alto orden entrenadas con el filtro de Kalman extendido, como una alternativa de solución para el problema de seguimiento de trayectorias de sistemas no lineales tipo MIMO en presencia de perturbaciones acotadas, bajo cuatro esquemas: en el primer esquema se considera un método de control neuronal directo, usando la bien conocida técnica de “backstepping”, bajo la suposición de que el estado es medible; el segundo esquema contempla un método de control indirecto, el cual se resuelve por las técnicas de control por bloques y modos deslizantes bajo la misma suposición del estado medible. En tercer lugar se retoma la técnica de “backstepping” incluyendo un observador neuronal; y finalmente se retoma el control indirecto con un observador neuronal. Además se incluye el análisis de estabilidad respectivo bajo el enfoque de Lyapunov, para cada uno de los esquemas propuestos. Se validan los resultados teóricos, implementando en tiempo real para cada uno de los esquemas propuestos aplicados a un motor de inducción trifásico;[19],este trabajo presenta el uso de redes neuronales discretas para identificar un Motor de Inducción Lineal (MIL) y un control por modos deslizantes en tiempo discreto para el seguimiento de velocidad y la magnitud del flujo para el MIL. El algoritmo de entrenamiento para la red neuronal está basado en el filtro de Kalman extendido, [8] Este trabajo hace una aplicación del motor lineal de inducción de jaula de ardilla con el software flux 10.3, las investigaciones que se realizaron son las siguientes: conseguir un buen funcionamiento para un régimen nominal determinado; realiza un estudio estático lineal y

no lineal del modelo, analizando la respuesta del campo magnético presente en la máquina para obtener valores apropiados de inducción magnética en el entrehierro; realiza un estudio dinámico del modelo, analizando la curva de deslizamiento, para conseguir un funcionamiento como motor y que su régimen este entre los márgenes que se consideran adecuados; [6], Esta tesis se enfoca en tres puntos principales: 1. Equivalencias de los parámetros entre Motor de Inducción Rotatorio (RIM) y el Motor de Inducción Lineal (LIM) con su correspondiente análisis y validación. 2. Análisis, Modelado y Simulación de la respuesta dinámica del LIM como un sistema electromecánico. 3. Implementación de un control PI que regula la potencia original del sistema en términos de la amplitud de frecuencia y voltaje, permitiendo al LIM dificulte ciertas perturbaciones de fuerza o carga en la referencia de velocidad deseada.

1.5 Estado del Arte

Debido a que los sistemas dinámicos se encuentran a nuestro alrededor, las técnicas de identificación de sistemas han venido teniendo una gran relevancia en áreas muy diversas del conocimiento (Ingenierías, economía, biotecnología, etc.), donde se necesita de un modelo lo más parecido al sistema para fines de análisis, predicción, simulación, diseño y control.

Las técnicas de control actuales, requieren de modelos matemáticos cada vez más exactos para el análisis y el diseño. En muchos casos, tales modelos no pueden ser obtenidos en forma sencilla y económica a partir de las leyes que rigen cada proceso. Aquí es donde la identificación de sistemas dinámicos juega un papel importante, ya que es una herramienta capaz de proporcionar los métodos necesarios para obtener de manera relativamente sencilla los modelos matemáticos buscados con un alto grado de exactitud.

Al tratar de obtener un modelo dinámico del MIL se debe de considerar que estos cuentan con una construcción especial, lo que provoca una serie de efectos anómalos que afectan su rendimiento y buen funcionamiento. En un sentido, la falta de simetría del circuito magnético hace que se manifiesten efectos de borde estáticos en los extremos de la máquina, distorsionando la forma sinusoidal del campo magnético en el entrehierro. Por

otro lado, a grandes velocidades se produce un debilitamiento del campo de la parte delantera del primario, que encabeza el movimiento, y reforzamiento en la parte de la cola del primario. La presencia de estos efectos anómalos, sobre todo de los efectos dependientes de la velocidad, plantea la necesidad de tomarlos en cuenta cuando se va a modelar este tipo de motores [15].

Esto nos lleva a que el MIL es un sistema dinámico altamente no lineal es por eso que se han utilizado técnicas de identificación como: mínimos cuadrados, modelos entrada-salida, series de volterra, modelos NARMAX, redes neuronales feedforward y recurrentes. Estas últimas en específico las redes neuronales recurrentes han mostrado muy buenos resultados en la identificación.

1.6 Propuesta del Trabajo

Retomando lo anteriormente mencionado y teniendo la necesidad de obtener un modelo que represente lo más exacto posible al MIL y conociendo las propiedades de las redes neuronales recurrentes se propone diseñar una red neuronal recurrente de alto orden discreta para identificar al motor de inducción lineal, una vez obtenido esto se desarrollará una ley de control.

CAPITULO 2

Motor de Inducción

2.1 Motor de Inducción de Desplazamiento Lineal

Un motor lineal es un motor eléctrico destinado a producir la fuerza en una línea recta. En este diseño, la fuerza es producida por un campo magnético en movimiento lineal que actúa sobre los conductores en el campo. Cualquier conductor, ya sea un bucle, una bobina o simplemente una pieza de metal de la placa, que se coloca en este campo tendrá las corrientes de Foucault inducidas en él creando así un campo magnético opuesto, de conformidad con la ley de Lenz. Los dos campos opuestos se repelen entre sí, creando de este modo el movimiento como el campo magnético barre a través del metal. Muchos diseños se han propuesto para los motores lineales, separándose en dos grupos, los motores lineales de baja aceleración y alta aceleración. Los motores de baja aceleración lineal son aptos para los trenes de levitación magnética y otras aplicaciones de transporte terrestres. Los motores lineales de alta aceleración son normalmente diseñados para acelerar un objeto a una velocidad muy alta y luego soltarlo, como montañas rusas. Los motores de alta aceleración son por lo general motores de inducción lineal de CA (LIM) con una fase activa de tres bobinados en un lado del espacio de aire y una placa conductor pasiva en el otro lado. Los motores de baja aceleración, alta potencia y alta velocidad son por lo general del tipo de motor síncrono lineal (LSM), con un devanado activo en un lado del espacio de aire y un conjunto de polos de imanes alternativos en el otro lado. Estos imanes pueden ser imanes permanentes o imanes energizados. Un ejemplo de uso de estos motores es el caso del Shanghai Transrapid.

2.2 Construcción y Clasificación

La construcción de un motor lineal es similar a la de un motor giratorio estándar, pero en una forma lineal. El motor de inducción lineal es esencialmente un motor circular abierto en un plano. El campo magnético, en lugar de girar, ahora se mueve a través de la cara del motor planar. El estator consiste generalmente de un bobinado en un núcleo de hierro laminado de múltiples fases. Cuando es energizado desde una fuente de CA un campo

Capítulo 2. Motor de Inducción

magnético de onda viajera se produce. El sentido de desplazamiento puede ser revertido mediante la inversión de las fases. La placa de reacción es el equivalente del rotor. Para las aplicaciones de un solo lado esto es generalmente una lámina conductora de aluminio o cobre respaldada por el acero, y para aplicaciones de doble cara se usa sólo una hoja conductora.




Figura 1. Conversión del motor rotatorio a motor lineal

Las corrientes inducidas en la placa de reacción por el campo viajero del estator crean un campo magnético secundario. Esta reacción entre los dos campos produce el empuje lineal.

La velocidad de funcionamiento del LIM no depende de la fricción de contacto, ya que no hay contacto físico directo entre el estator y el rotor del LIM. No existen engranajes o cadenas para causar contragolpe, sin lubricación ni mantenimiento. Las transmisiones mecánicas son a menudo eliminadas dando lugar a un aumento de la fiabilidad, y un menor número de partes móviles que permiten que los sistemas sean mucho más sencillos de utilizar. La simplicidad y los requerimientos de mantenimiento reducidos de las unidades LIM hacen que los costos de operación a largo plazo a menudo se reduzcan considerablemente.

El recorrido horizontal sólo está limitado por la longitud de la placa de reacción o motor y pistas largas como cintas transportadoras o juegos mecánicos que se pueden utilizar como sistemas multi-motor. O bien el estator alimentado o la placa de reacción sin alimentación pueden moverse mientras que el otro es fijo, dando la configuración óptima del sistema basada en las necesidades del usuario. Si un disco conductor es sustituido por una placa de

Capítulo 2. Motor de Inducción

reacción se produce el movimiento giratorio. El movimiento no depende de la fricción entre las ruedas y los carriles para el LIM se pueden utilizar en condiciones extremadamente adversas. Una barrera de acero inoxidable no magnético se puede utilizar entre el estator y la placa de reacción o estatores pueden ser completamente sellados dentro de un acero inoxidable de protección. Cuando esta sin alimentación, los LIM no son magnéticos y no atraen partículas de dispersión de material ferroso, que puede ser un problema común con máquinas que utilizan imanes permanentes.

El LIM hace un accionamiento de velocidad variable ideal. No sólo se comporta como un embrague magnético sino que también brinda una acción de arranque suave, pero la velocidad puede ser controlada con un alto grado de precisión con sistemas de control adecuados.

Una clasificación de los motores lineales se presenta a continuación [18].

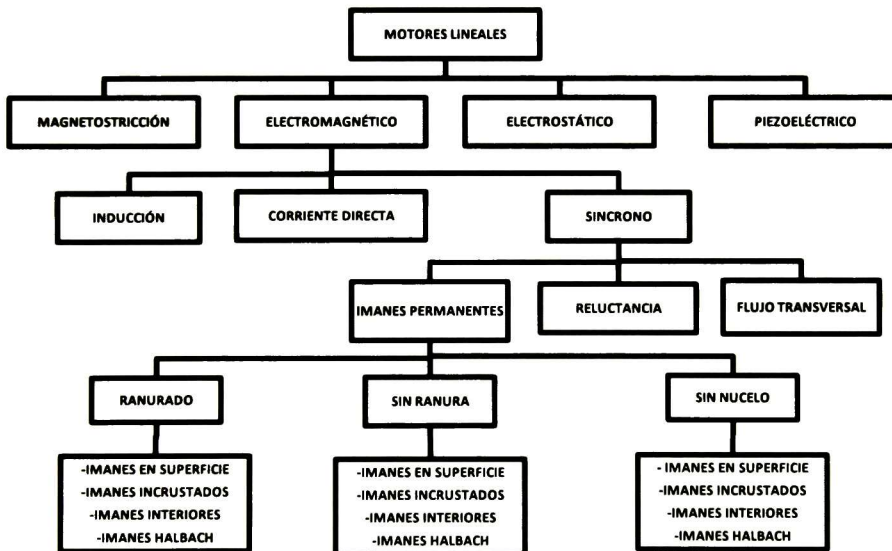


Figura 2. Clasificación de los motores lineales.

2.3 Modelos Matemáticos del Motor de Inducción Lineal

Un modelo es una representación de un sistema. Cabe destacar que para efectuar un análisis de un proceso es necesario conocerlo. En general, se desea llegar a conocer factores (internos y externos) que condicionan el comportamiento del mismo, tales como interrelaciones entre variables, el efecto de las perturbaciones, rangos de estabilidad, el efecto de la variación de parámetros, etc. El mayor conocimiento del proceso se obtiene mediante la experimentación, la cual generalmente no se puede desarrollar con profundidad en plantas industriales, debido a esta situación se debe recurrir a medios alternativos tales como la simulación de los experimentos en modelos del proceso completo o en modelos parciales de los fenómenos de interés [7].

En el estudio de los sistemas de control el primer paso siempre debe ser la obtención de un modelo matemático que describa la dinámica del sistema. Se define el modelo matemático de un sistema dinámico como un conjunto de ecuaciones que representan la dinámica del sistema incluyendo las principales características. Al obtener un modelo matemático existe un compromiso entre la simplicidad del mismo y la precisión de los resultados, esto se debe principalmente a que utilizando un modelo simplificado estamos ignorando ciertas propiedades físicas inherentes al sistema. Pero en una primera aproximación es preferible utilizar un modelo simplificado para obtener de una manera más sencilla una idea general sobre la solución, y después aumentar la complejidad del sistema si fuese necesario.

Un modelo matemático no es único para un sistema determinado, razón por la cual podemos tener muchos modelos matemáticos dependiendo de cada perspectiva. Para realizar métodos de control clásico es preferible tener descrito el modelo matemático representado como función de transferencia, mientras que para el resto de métodos de control no lineal es preferible tener el modelo matemático representado en el espacio de estados.

Podemos describir la dinámica de muchos sistemas físicos en términos de ecuaciones diferenciales. Dichas ecuaciones diferenciales se obtienen a partir de las leyes físicas que gobiernan un determinado sistema, algunos ejemplos de leyes físicas aplicables serían las

Capítulo 2. Motor de Inducción

leyes de Newton para sistemas mecánicos y las leyes de Kirchhoff para sistemas eléctricos [10].

Con frecuencia, las características de diseño de un sistema de control están especificadas en términos de su respuesta transitoria a una entrada escalón unitario, sirve para proporcionar información útil de las características de la respuesta transitoria.

La respuesta transitoria de un sistema a una entrada escalón unitario que depende de las condiciones iniciales. Al comparar respuestas transitorias de varios sistemas, es frecuente utilizar la condición inicial estándar: el sistema esta inicialmente en reposo, y la salida y todas sus derivadas con respecto al tiempo son cero. Las características de respuesta pueden entonces compararse sin dificultad.

2.4 Simulación

A continuación se muestran tres modelos matemáticos del MIL en los cuales se hará un análisis de su comportamiento dinámico en el tiempo.

El primer modelo

Se refiere a un motor de inducción lineal de imanes permanentes y puede describirse de manera simplificada por el siguiente conjunto de ecuaciones [7]:

$$u(t) = K_e \dot{x} + Ri(t) + L \frac{di(t)}{dt} \quad (1)$$

$$f(t) = K_f i(t) \quad (2)$$

$$f(t) = m\ddot{x} + f_{ripple}(x) + f_{load}(t) \quad (3)$$

$$f_{load} = m\ddot{x} + b\dot{x} + kx \quad (4)$$

Donde:

$u(t)$: voltaje de entrada al motor

f_{ripple} : fuerza debida a la variación del campo magnético

f_{load} : fuerza generada por la carga

m : Masa del motor

$x(t)$: posición lineal con respecto al tiempo

Capítulo 2. Motor de Inducción

$i(t)$: corriente con respecto al tiempo

K_e : constante eléctrica

R: resistencia de las bobinas

L: inductancia de las bobinas

La primera ecuación muestra el comportamiento eléctrico del motor, la segunda ecuación representa la relación entre la ecuación eléctrica y la mecánica con la fuerza, la tercera muestra el comportamiento de la fuerza requerida con respecto a la información del motor y la fuerza generada por la carga, y la cuarta ecuación es para la carga.

Parámetros del motor para su simulación:

$$m = 1000 \text{ kg}$$

$$b = 4.412745 \text{ N/m}$$

$$k = 294.195 \text{ N}$$

$$k_f = 0.003$$

$$k_e = 1$$

$$L = 7.2 \text{ mH}$$

$$R = 11.2 \text{ ohm}$$

$$F_{\text{ripple}} = 0$$

A partir de un análisis de las ecuaciones que representan la dinámica del sistema se concluyó que este es controlable y observable.

A continuación se muestra la simulación del sistema en MatLab®.




Figura 3. Simulación de la corriente (primer modelo).




Figura 4. Simulación de la posición (primer modelo).




Figura 5. Simulación de la velocidad (primer modelo).




Figura 6. Simulación de la aceleración (primer modelo).

Al aplicarle una señal escalón al sistema [7] muestra un retardo en la respuesta, posteriormente responde con una respuesta oscilatoria para la posición, velocidad y aceleración, pero en el caso de la corriente logra establecerse en un valor final.

Capítulo 2. Motor de Inducción

Segundo modelo

Se refiere a un servomecanismo con un motor lineal. El modelo del motor tiene que ser establecido en la base de las siguientes ecuaciones describiendo la dependencia eléctrica y física del motor. Podemos decir que la forma es idéntica con el modelo estándar de la maquina CD [12].

Ecuación de voltaje del motor:

$$U_0 = R * i + L \left(\frac{di}{dt} \right) + U_i \quad (5)$$

Donde:

U_0 : es el voltaje de la entrada

R : es la resistencia

L : es la inductancia

U_i : es el voltaje inducido

i : es la corriente de armadura

Ecuación de movimiento:

$$F_H = F_Z + m \left(\frac{dv}{dt} \right) \quad (6)$$

Donde:

F_H : es la fuerza conducida

F_Z : es la fuerza de carga

M : es la masa total de la armadura y carga

De las ecuaciones previas el modelo del motor tiene que ser establecido:

$$F_M(s) = \frac{v(s)}{U_0(s)} = \frac{\left(\frac{1}{K_1} \right)}{\left(\left(\frac{s^2}{\Omega_0^2} \right) + \left(\frac{2\xi s}{\Omega_0} \right) + 1 \right)} \quad (7)$$

Donde:

v : es la velocidad

U_0 : es el voltaje de la entrada

K_1 : es la constante del motor

ξ : es el factor de amortiguamiento

Capítulo 2. Motor de Inducción

Ω_0 : frecuencia natural no amortiguada

Parámetros del motor lineal para su simulación:

Masa (m) = 45 g

Frecuencia = 100 Hz

Longitud = 10.5 cm

Tiempo (t) = 176 ms

Voltaje (V) = 6.2 volts

Inductancia (L) = 41 mH

Resistencia (R) = 74 ohm

Constante del motor = 10 v/ms⁻¹

Velocidad (v) = 0.6 m/s

A partir de un análisis de las ecuaciones que representan la dinámica del sistema se concluyó que éste es controlable y observable.

La simulación del modelo es la siguiente:




Figura 7. Simulación de la corriente (segundo modelo).




Figura 8. Simulación de la posición (segundo modelo).



Figura 9. Simulación de la velocidad (segundo modelo).




Figura 10. Simulación de la aceleración (segundo modelo).

Al aplicarle una señal escalón al sistema [12] muestra un retardo en la respuesta, posteriormente responde con un cambio instantáneo, para la corriente, velocidad y aceleración logran establecerse en un valor final, pero en el caso de la posición no.

El tercer modelo

Se trata de un motor de inducción lineal y está representado por el modelo d – q [20]:

El modelo del MIL en el marco d – q está gobernado por:

$$\begin{aligned}
 \frac{di_{qs}}{dt} &= - \left[\frac{R_s}{\sigma L_s} + \frac{1 - \sigma}{\sigma T_r} \right] i_{qs} - \frac{n_p L_m \pi}{\sigma L_s L_r \tau} v \lambda_{dr} + \frac{L_m}{\sigma L_s L_r T_r} \lambda_{qr} + \frac{1}{\sigma L_s} u_q \\
 \frac{di_{ds}}{dt} &= - \left[\frac{R_s}{\sigma L_s} + \frac{1 - \sigma}{\sigma T_r} \right] i_{ds} + \frac{L_m}{\sigma L_s L_r T_r} \lambda_{dr} + \frac{n_p L_m \pi}{\sigma L_s L_r \tau} v \lambda_{qr} + \frac{1}{\sigma L_s} u_d \\
 \frac{d\lambda_{qr}}{dt} &= \frac{L_m}{T_r} i_{qs} + n_p \frac{\pi}{\tau} v \lambda_{dr} - \frac{1}{T_r} \lambda_{qr} \\
 \frac{d\lambda_{dr}}{dt} &= \frac{L_m}{T_r} i_{ds} - \frac{1}{T_r} \lambda_{dr} + n_p \frac{\pi}{\tau} v \lambda_{qr} \\
 \frac{dv}{dt} &= \frac{K_f}{M} (\lambda_{dr} i_{qs} - \lambda_{qr} i_{ds}) - \frac{D}{M} v - \frac{F_L}{M}
 \end{aligned} \tag{8}$$

Donde:

v = es la velocidad del movimiento lineal.

Capítulo 2. Motor de Inducción

λ_{dr} y λ_{qr} son, respectivamente, el eje d y q del flujo del secundario.

i_{ds} e i_{qs} son, respectivamente, el eje d y q de la corriente del primario.

u_{ds} y u_{qs} son, respectivamente, el eje d y q del voltaje del primario.

$T_r = L_r/R_r$ es la constante de tiempo del secundario.

$\sigma = 1 - (L_m^2/L_s L_r)$ es el coeficiente de dispersión.

$K_f = 3/2 n_p \pi L_m / \tau L_r$ es la fuerza constante.

R_s = es la resistencia devanado por fase.

R_r = es la resistencia del secundario por fase referida al primario.

L_m = es la inductancia magnetizante por fase.

L_r = es la inductancia por fase del secundario.

L_s = es la inductancia del primario por fase.

F_L = es la perturbación de carga.

M = es la masa total del elemento en movimiento.

D = es la fricción de viscosidad y el coeficiente de pérdida en el hierro.

τ = es la distancia entre polos, y

n_p = es el número de par de polos.

Si seleccionamos las siguientes variables de estado:

$$X_1 = v, X_2 = \lambda_{dr}, X_3 = \lambda_{qr}, X_4 = i_{ds}, X_5 = i_{qs}$$

Entonces, la ec. (8) puede ser representada por

$$\begin{aligned} \dot{X}_1 &= C_0(X_2X_5 - X_3X_4) - C_1X_1 - C_2F_L \\ \dot{X}_2 &= C_3X_4 - C_4X_2 - C_5X_1X_3 \\ \dot{X}_3 &= C_3X_5 + C_5X_1X_2 - C_4X_3 \\ \dot{X}_4 &= -C_6X_4 + C_7X_2 + C_8X_1X_3 + C_9u_d \\ \dot{X}_5 &= -C_6X_5 - C_8X_1X_2 + C_7X_3 + C_9u_q \end{aligned} \quad (9)$$

Donde:

$$\begin{aligned} C_0 &= \frac{K_f}{M}, & C_1 &= \frac{D}{M}, & C_2 &= \frac{1}{M}, & C_3 &= \frac{L_m}{T_r}, & C_4 &= \frac{1}{T_r}, & C_5 &= n_p \frac{\pi}{\tau}, \\ C_6 &= \frac{R_s}{\sigma L_s} + \frac{1 - \sigma}{\sigma T_r}, & C_7 &= \frac{L_m}{\sigma L_s L_r T_r}, & C_8 &= \frac{n_p L_m \pi}{\sigma L_s L_r \tau}, & C_9 &= \frac{1}{\sigma L_s} \end{aligned}$$

Capítulo 2. Motor de Inducción

Parámetros del motor de MIL son:

Parámetros	Valor	Descripción
R_s	5.3685	Resistencia devanado por fase.
R_r	5.5315	Resistencia del secundario por fase referida al primario.
L_m	0.02846	Inductancia magnetizante por fase.
L_r	0.02846	Inductancia por fase del secundario.
L_s	0.0241	Inductancia del primario por fase.
n_p	4	Número de par de polos.
M	2.78	Masa total del elemento en movimiento.
D	36.0455	Fricción de viscosidad.
T	0.027	Distancia entre polos.
K_f	148.35	Fuerza constante.
σ	$1 - (L_m^2 / L_s L_r)$	Coefficiente de dispersión.
T_r	L_r / R_r	Constante de tiempo del secundario.

A partir de un análisis de las ecuaciones que representan la dinámica del sistema se concluyó que este es Controlable y Observable.

La simulación del modelo es la siguiente:




Figura 11. Simulación de la corriente i_{qs} (tercer modelo).




Figura 12. Simulación de corriente i_{ds} (tercer modelo).




Figura 13. Simulación del flujo del secundario λ_{qr} (tercer modelo).




Figura 14. Simulación del flujo del secundario λ_{dr} (tercer modelo).




Figura 15. Simulación de la posición (tercer modelo).




Figura 16. Simulación de la velocidad (tercer modelo).




Figura 17. Simulación de la aceleración (tercer modelo).

Al aplicarle una señal escalón al sistema [20] se observa una respuesta oscilatoria que logra establecerse en un valor final para las corrientes i_{ds} e i_{qs} , flujo del secundario λ_{qr} y λ_{dr} , la velocidad y la aceleración, mientras que para la posición no logra establecerse en ningún valor.

CAPITULO 3

Redes Neuronales

3.1 Redes Neuronales

Las Redes Neuronales son sistemas no lineales altamente interconectados que tienen propiedades importantes como la aproximación de funciones [9]. Existen algoritmos para entrenar los pesos de la red neuronal, como por ejemplo el de retropropagación [13] o el filtro de Kalman [22], [2]; cuando el entrenamiento termina la red aproxima al sistema real [14].

Es sabido que las redes neuronales estáticas son capaces de aproximar cualquier función no lineal continua [1]. Una red neuronal estática, puede usar información anterior por medio de retardos para incluir entradas y salidas pasadas [1] con el propósito de realizar transformaciones dinámicas, pero se requiere de un gran número de neuronas para representar la respuesta dinámica en el dominio del tiempo [25]. Otro tipo de redes son las redes neuronales recurrentes, las cuales se distinguen de las estáticas en que tienen al menos un lazo de retroalimentación [1]. Éstas son apropiadas para identificación y control de sistemas dinámicos no lineales [1].

Las funciones de activación, denotadas por $S(x)$, definen la salida de la neurona en función del potencial de activación x . Algunas de las funciones comúnmente usadas son: función escalón o umbral, función sigmoide, función tangente hiperbólica y funciones de base radial [19].

3.2 Redes Neuronales Recurrentes de Alto Orden

Las redes neuronales de alto orden son una generalización de las redes de Hopfield de primer orden. En el caso de una red neuronal recurrente de tipo Hopfield, el estado de cada neurona se puede determinar por una ecuación diferencial de la siguiente forma:

$$\dot{x} = -a_i x_i + b_i \sum_j w_{ij} y_j \quad (10)$$

Donde x_i es el estado de la i -ésima neurona, a_i , b_i son constantes, w_{ij} es el peso sináptico que conecta la j -ésima neurona y y_i puede ser una entrada o el estado de una neurona que pasa a través de una función sigmoideal, es decir, $y_i = S(x_j)$ donde $S(\cdot)$ representa una función sigmoideal.

En una red neuronal de segundo orden, la entrada total a una neurona no solo es la combinación lineal de los componentes y_j sino que también se incluyen sus productos $y_j y_k$. Siguiendo este procedimiento es posible obtener interacciones de alto orden. Esta clase de red forma una red neuronal recurrente de alto orden (RHONN).

La RHONN tiene las siguientes características [17]:

- Permiten el modelado eficiente de sistemas dinámicos complejos,
- Son buenos candidatos para identificación y control,
- Son de fácil implementación,
- Su estructura es relativamente sencilla,
- Son capaces de ajustar sus parámetros en línea.

Las redes neuronales recurrentes de alto orden discretas presentan las mismas características que las continuas y son ideales para su uso en modelado [2], [11], [23], identificación y control de sistemas dinámicos discretos complejos debido a su facilidad de implementación y a su estructura de relativa sencillez [10].

3.3 Algoritmo de entrenamiento

El filtro de Kalman formulado como un sistema lineal en el espacio de estados, provee una solución al problema lineal de filtrado óptimo. Se aplica a ambientes estacionarios y no estacionarios. La solución es recursiva, de tal forma que cada actualización del estado estimado es calculado a partir del estimado anterior y del nuevo dato de entrada. Esto significa que no es necesario almacenar todos los datos anteriores de tiempo [22].

Capítulo 3. Redes Neuronales

El filtro de Kalman, suponiendo un sistema dinámico lineal, estima el estado con ruido aditivo blanco, tanto en el estado como en la salida. Sin embargo, en muchas ocasiones el modelo es no lineal, por lo que se extiende el filtro de Kalman a través de un proceso de linealización. El filtro resultante es conocido como filtro de Kalman extendido (FKE) [22].

Considérese un sistema dinámico no lineal descrito por el siguiente modelo en espacio de estado

$$w(k+1) = f(k, w(k)) + \mu(k) \quad (11)$$

$$y(k) = h(k, w(k)) + v(k) \quad (12)$$

Con $w(k) \in \mathbb{R}^n$ el vector de estado del sistema, $y(k) \in \mathbb{R}^p$ la salida medible, con $\mu(k) \in \mathbb{R}^n$ y $v(k) \in \mathbb{R}^p$ ruidos independientes, gaussianos y matrices de covarianza $Q(k)$ y $R(k)$ respectivamente, $f(k, z(k))$ denota la función matricial no lineal de transición y $h(k, z(k))$ denota la función matricial de medición no lineal [22].

La idea del FKE consiste en linealizar el modelo en espacio de estados de la ecuación (11) y (12) a cada instante de tiempo alrededor del estado estimado más reciente [22].

Los cálculos de las matrices $F_{k+1,k}$ y $H(k)$ se realizan como sigue:

$$F_{k+1,k} = \frac{\partial f(k, w(k))}{\partial w} \quad (13)$$

$$H(k) = \frac{\partial h(k, w(k))}{\partial w} \quad (14)$$

Cuando han sido evaluadas las matrices $F_{k+1,k}$ y $H(k)$ se aplican las ecuaciones del FKE [22].

Para el entrenamiento de redes neuronales basadas en el filtro de Kalman, los pesos son los estados a estimar y la salida de la red es la medición requerida. El error entre la red

Capítulo 3. Redes Neuronales

neuronal y la salida de la planta es considerada como ruido aditivo blanco. Debido a que la red neuronal es no lineal se requiere un FKE [22], [2.], [3].

El objetivo del entrenamiento del Filtro de Kalman Extendido es encontrar los pesos óptimos que minimicen el error de predicción. El FKE se describe por

$$\begin{aligned}w_i(k+1) &= w_i(k) + \eta_i K_i(k) e_i(k) \\K_i(k) &= P_i(k) H_i(k) M_i(k) \quad i = 1, \dots, n \\P_i(k+1) &= P_i(k) - K_i(k) H_i^T(k) P_i(k) + Q_i(k)\end{aligned}\tag{15}$$

con

$$\begin{aligned}M_i(k) &= [R_i(k) + H_i^T(k) P_i(k) H_i(k)]^{-1} \\e_i(k) &= x_i(k) - X_i(k)\end{aligned}\tag{16}$$

donde $e_i(k) \in \mathfrak{R}$ es el respectivo error de identificación, $P_i(k) \in \mathfrak{R}^{L_i \times L_i}$ es la matriz de covarianza del error de estimación al paso k , $w_i(k) \in \mathfrak{R}^{L_i}$ es el vector de pesos (estado) adaptados en línea, $x_i(k)$ es el i -ésimo estado de la planta, $X_i(k)$ es el i -ésimo estado de la red neuronal, $K_i(k) \in \mathfrak{R}^{L_i}$ es el vector de ganancias de Kalman, $Q_i(k) \in \mathfrak{R}^{L_i \times L_i}$ es la matriz de covarianza del ruido de estimación, $R_i(k) \in \mathfrak{R}$ es la covarianza del ruido de medición y $H_i(k) \in \mathfrak{R}^{L_i}$ es un vector, y se obtiene como la derivada del estado de la red neuronal $X_i(k) \in \mathfrak{R}$ con respecto a los pesos de la red neuronal $w_{ij}(k)$, y está dado por:

$$H_{ij} = \left[\frac{\partial X_i(k)}{\partial w_{ij}(k)} \right]^T\tag{17}$$

donde $i = 1, \dots, n$ y $j = 1, \dots, L_i$. Usualmente P_i y Q_i son inicializados como matrices diagonales, con entradas $P_i(0)$ y $Q_i(0)$, respectivamente. Es importante notar que

$$\begin{aligned} \| H(k) \| &\leq \bar{H} \\ \| K(k) \| &\leq \bar{K} \\ \| P(k) \| &\leq \bar{P} \end{aligned} \tag{18}$$

La identificación entre la planta y la red neuronal se establece en el siguiente Teorema (para detalles ver [4]).

Teorema. *La RHONN (23) entrenada con el filtro de Kalman extendido para identificar el sistema no lineal (21) asegura que el error de identificación (16) es semiglobalmente uniformemente últimamente acotado (SGUUA), y los pesos de la RHONN permanecen acotados.*

CAPITULO 4

Identificación Neuronal

4.1 Identificador Neuronal Recurrente de Alto Orden

Debido a la capacidad de las redes neuronales para aproximar funciones no lineales, éstas se pueden utilizar para la identificación de sistemas no lineales. La identificación neuronal consiste en seleccionar un modelo apropiado a la red y ajustar sus pesos de acuerdo a alguna ley de adaptación, tal que la red a una señal de entrada aproxime la respuesta del sistema real a la misma entrada [14]. Debido a que el modelo del sistema a analizar y el desarrollo de una ley de control, la identificación del sistema no solo es importante para entender e identificar su dinámica sino que también para obtener una ley de control.

Dentro de la identificación neuronal de sistemas no lineales se pueden distinguir las siguientes configuraciones:

- **Serie-paralelo.** En esta configuración la red neuronal es alimentada por los estados de la planta.

$$X_i(k + 1) = w_i^T z_i(x(k), u(k)), \quad i = 1 \dots, n \quad (19)$$

- **Paralelo.** En esta configuración la red neuronal es retroalimentada por sus propios estados.

$$X_i(k + 1) = w_i^T z_i(X(k), u(k)), \quad i = 1 \dots, n \quad (20)$$

donde $x(k)$ es el estado de la planta, $X(k)$ es el estado de la red neuronal, w_i son los pesos adaptables en línea, $u(k)$ es la entrada de control.

Considere el siguiente sistema no lineal discreto:

Capítulo 4. Identificación Neuronal

$$x(k + 1) = F(x(k), u(k)) + D(w(k)) \quad (21)$$

donde $x(k) \in \mathfrak{R}^n$ es el vector de estados de la planta, $u(k) \in \mathfrak{R}^m$ es la entrada de control y $F \in \mathfrak{R}^n \times \mathfrak{R}^m \rightarrow \mathfrak{R}^n$ es una función no lineal, $D(w(k)) \in \mathfrak{R}^n$ son las perturbaciones del sistema.

Considere el problema de aproximar al sistema anterior por la siguiente red neuronal de alto orden [14]:

$$X_i(k + 1) = w_i^{*T} z_i(x(k), u(k)) + \epsilon_{z_i} \quad i = 1 \dots, n \quad (22)$$

donde $X_i(i = 1, \dots, n)$ es el i -ésimo estado de la red neuronal, $x(k)$ es el vector de estado de la planta, ϵ_{z_i} es el error de aproximación acotado el cual puede ser reducido incrementando el número de pesos ajustable [9]. Suponga que existe un vector de pesos ideal w_i^* tal que $\|\epsilon_{z_i}\|$ puede ser minimizado sobre un conjunto compacto $\Omega_{z_i} \subset \mathfrak{R}^{L_i}$. El vector de pesos ideal w_i^* es una cantidad artificial requerida para propósitos de análisis [14]. Se supone que este vector existe y es constante pero desconocido.

Para identificar el sistema en esta tesis, se utilizará la siguiente red neuronal de alto orden discreta, cuya estructura se muestra en la figura 18.

$$X_i(k + 1) = w_i^T z_i(x(k), u(k)), \quad i = 1 \dots, n \quad (23)$$

donde $X_i(i = 1, 2 \dots, n)$ es el estado de la i -ésima neurona, $x(k)$ es el vector de estados de la planta, w_i es el vector de pesos adaptados en línea, y es un estimado para $w_i^* z_i(x(k), u(k))$ está definido como

$$z_i(x(k), u(k)) = \begin{bmatrix} z_{i_1} \\ z_{i_2} \\ \vdots \\ z_{i_{L_i}} \end{bmatrix} = \begin{bmatrix} \prod_{j \in I_1} \psi_{ij}^{d_{ij}(1)} \\ \prod_{j \in I_2} \psi_{ij}^{d_{ij}(2)} \\ \vdots \\ \prod_{j \in I_{L_i}} \psi_{ij}^{d_{ij}(L_i)} \end{bmatrix} \quad (24)$$

con L_i se refiere al número de conexiones de alto orden, $\{I_1, I_2, \dots, I_{L_i}\}$ una colección de subconjuntos no ordenados de dimensión $\{1, 2, \dots, n+m\}$, $d_{ij}(k)$ enteros no negativos y ψ_i definido como

$$\psi_i = \begin{bmatrix} \psi_{i_1} \\ \vdots \\ \psi_{i_n} \\ \psi_{i_{n+1}} \\ \vdots \\ \psi_{i_{n+m}} \end{bmatrix} = \begin{bmatrix} S(x_1(k)) \\ \vdots \\ S(x_n(k)) \\ u_1(k) \\ \vdots \\ u_m(k) \end{bmatrix} \quad (25)$$

En (25) $u(k) = [u_1(k) \ u_2(k) \ \dots \ u_m(k)]^T$ es el vector de entrada a la red neuronal, y $S(\cdot)$ está dado por

$$S(x(k)) = \frac{\alpha}{1 + e^{-\beta x(k)}} + \gamma, \quad \beta > 0 \quad (26)$$

con

$$S(x(k)) \in [\gamma, \alpha + \gamma]$$

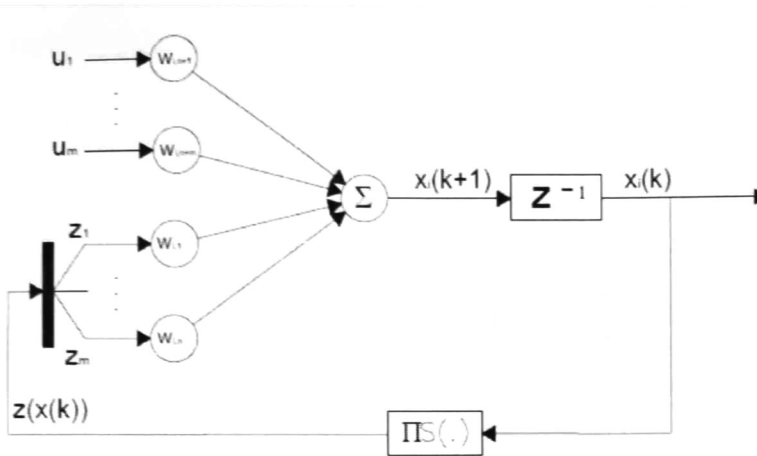


Figura 18. Red neuronal recurrente de alto orden discreta.

Un identificador con una red neuronal es aplicado a los datos adquiridos de LIM; se supone que todas las variables de estado son medibles. Para la identificación del LIM se utiliza una red neuronal recurrente de alto orden discreta (DRHONN por su nombre en inglés) en su representación serie- paralelo (ver figura. 19) como:

$$\widehat{p}_0(k+1) = w_1 S(p_0(k)) + w_2 S(v_0(k)) + w_3 u(k) \quad (27)$$

$$\widehat{v}_0(k+1) = w_4 S(p_0(k)) + w_5 S(v_0(k)) + w_6 u(k) \quad (28)$$

donde $\widehat{p}_0(k)$ identifica la posición, $\widehat{v}_0(k)$ identifica la velocidad lineal y los pesos $w_{ij}(k)$ son actualizados por (15).

El entrenamiento es realizado con el filtro de Kalman extendido, para la identificación se usa una configuración serie-paralelo como se muestra en la figura 19.

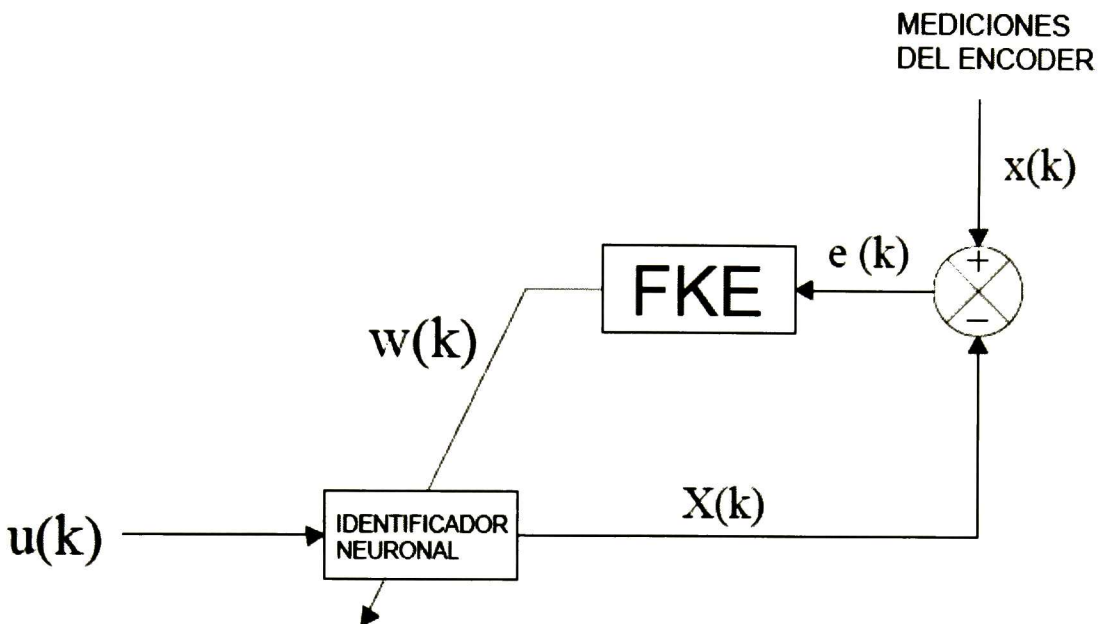


Figura 19. Esquema de identificación.

Todos los estados de la red neuronal son inicializados en cero. Las matrices de covarianza son inicializadas diagonales, como $P(0)=1100$, $R(0)=900$, $Q(0)=100$ para el desplazamiento, $P(0)=10$, $R(0)=1$, $Q(0)=0.1$ para la velocidad del LIM. Como se puede notar se cumple la condición del filtro de Kalman requiere que $P > R > Q$.

4.2 Simulación

Las simulaciones de la identificación del LIM se realizaron en Simulink®, utilizando los datos de entrada-salida de éste. El modelo propuesto que se utilizó para la identificación es el de (27) y (28). La estructura utilizada es la propuesta en la figura 19. La señal que se utilizó es una combinación de los comandos pulso generador y repetidor de secuencia, estas dos señales se suman antes de aplicarlo a LIM. Los parámetros de las señales son: amplitud=1, periodo=2, ancho de pulso=50, retraso de fase=0; valores del vector de salida = [1 0.8 0.9 0.6 0.7 0.5 0.8], tiempo de muestreo = -1, respectivamente.

Los resultados de la simulación son los siguientes:




Figura 20. Identificación de la Posición del LIM, (posición línea continua e identificador línea punteada).




Figura 21. Error de identificación de la posición.




Figura 22. Identificación de la Velocidad del LIM (velocidad línea continua e identificador línea punteada).




Figura 23. Error de identificación de la velocidad.

Para la validación de la identificación neuronal, al LIM se le aplica una entrada escalón con los siguientes parámetros: tiempo de paso =5, valor inicial=0, valor final =1 y tiempo de

muestreo=0.01. Se obtienen nuevos datos los cuales son aplicados al identificador dando los siguientes resultados:




Figura 24. Validación de la identificación de la Posición del LIM (posición línea de círculos e identificador línea continua).




Figura 25. Error en la validación de identificación de la posición.




Figura 26. Validación de la Identificación de la Velocidad del LIM (velocidad línea de círculos e identificador línea continua).




Figura 27. Error en la validación de identificación de la velocidad.

Los resultados de la simulación son presentados como sigue: las figuras 21, 23, 25 y 27 muestran el error de identificación entre la red neuronal (27) y (28) y los datos de entrada-

Capítulo 4. Identificación Neuronal

salida del LIM y las figuras 20, 22, 24 y 26 muestran los buenos resultados obtenidos de la identificación de la red neuronal a partir de los datos de entrada-salida del LIM.

CAPITULO 5

Control Neuronal

5.1 Control Neuronal Recurrente de Alto Orden por retroalimentación de Estados

El incremento de las demandas tecnológicas en nuestros tiempos, ha generado sistemas muy complejos que requieren controladores altamente sofisticados para asegurar alto desempeño dentro de condiciones adversas. Estas y otras condiciones de control no se pueden cumplir con controladores convencionales, debido principalmente a la falta de conocimiento preciso acerca del proceso que se desea controlar. La adquisición de conocimiento adecuado del sistema en ocasiones es problemática o impráctica debido a la complejidad del sistema y al hecho de que la estructura y los parámetros en muchos sistemas cambian de manera significativa e impredecible con el tiempo. Es bajo estas condiciones en donde se utilizan las técnicas del control por retroalimentación de estados utilizando redes neuronales.

Se han propuesto diversos esquemas de control para un MIL, como en [19] se propone un control por modos deslizantes en tiempo discreto, en [16] se propone un control por campo orientado y en [24] se propone un control neuronal a bloques.

Existen dos objetivos comunes de control, *la regulación* que se trata de llevar la salida de un sistema a un punto de operación deseado y *el seguimiento de trayectoria* que es manipular el sistema con el fin de tener el mínimo error posible entre una salida del sistema y la trayectoria deseada.

En este trabajo radica esencialmente en mostrar el buen funcionamiento del método de control por retroalimentación de estados basado en un identificador, aplicado al modelo que se muestra en [12].

Capítulo 5. Control Neuronal

La propuesta para la problemática mencionada se integra de lo siguiente:

Un esquema de control que tiene el objetivo de seguir una trayectoria impuesta, la cual consta de las siguientes partes:

La primera parte es un identificador basado en una red neuronal artificial tipo (DiscretRecurrent High Order Neural Network DRHONN por sus siglas en inglés), partiendo de la suposición de que el modelo matemático del sistema no se conoce y los parámetros de este son desconocidos. Este identificador funcionara como un modelo paralelo al sistema, lo que ayudara a proporcionar un modelo matemático alternativo y poder aplicar una ley de control basada en el modelo.

Las RNA tipo DRHONN son redes donde su principal característica es que la salida de la red está relacionada directamente con alguna capa intermedia o con la entrada de dicha red. Una RNA en general para lograr su objetivo se modifican los pesos sinápticos de esta, a lo cual se le llama entrenamiento de la red. El entrenamiento que es utilizado es el Filtro de Kalman Extendido (FKE), el cual es una herramienta recursiva y tiene como objetivo obtener los pesos ideales en línea.

La segunda parte del esquema es la técnica de control llamado Control por Retroalimentación de estados, este método permite ejercer una acción de control mediante la estimación de cada uno de los estados; llevando la variable controlada a un valor deseado a través de la incorporación de una referencia en el sistema, ver figura 28.

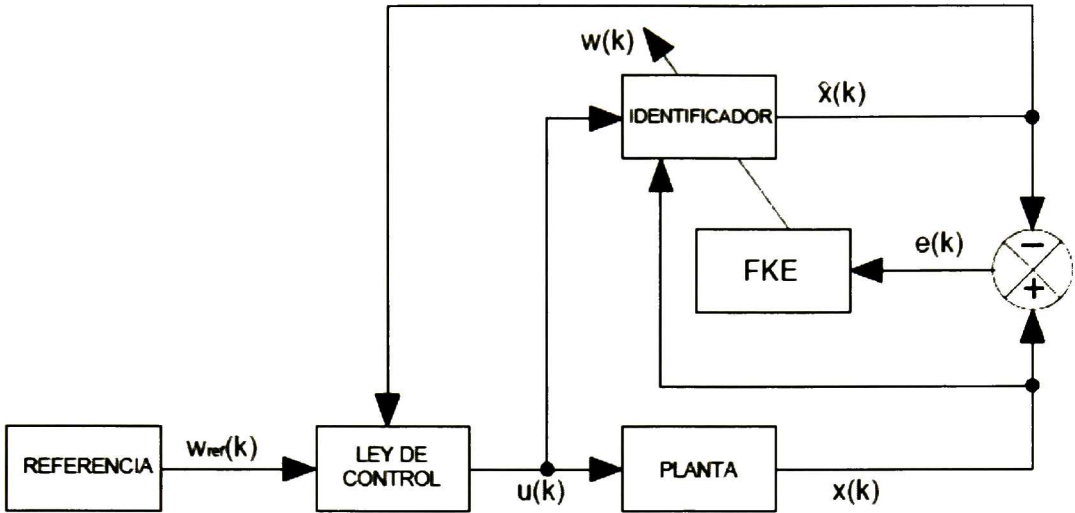


Figura 28. Esquema de control del LIM basado en un identificador.

Para la identificación del MIL, se utilizó la siguiente red neuronal en su representación serie-paralelo

$$\widehat{p}_0(k+1) = w_1 S(p_0(k)) + w_2 S(v_0(k)) + w_3 u(k)$$

$$\widehat{v}_0(k+1) = w_4 S(p_0(k)) + w_5 S(v_0(k)) + w_6 u(k)$$

donde $\widehat{p}_0(k)$ identifica la posición, $\widehat{v}_0(k)$ identifica la velocidad lineal y los pesos $w_{ij}(k)$ son actualizados por (15).

5.2 Ley de control

Para alcanzar los objetivos de control de velocidad, se define el vector de error de seguimiento:

$$e(k) = \hat{X}(k) - W_{ref}(k) \quad (29)$$

donde $e(k)$ es el error entre la salida de la red neuronal y la referencia deseada, respectivamente.

Evaluando un paso adelante

$$e(k + 1) = \widehat{v}_0(k + 1) - W_{ref}(k) \quad (30)$$

$$e(k + 1) = w_4S(p_0(k)) + w_5S(v_0(k)) + w_6u(k) - W_{ref}(k) = ke(k)$$

De aquí se obtiene la ley de control

$$u = w_6^{-1}(ke(k) - w_4S(p_0(k)) + w_5S(v_0(k)) + w_6u(k) - W_{ref}(k)) \quad (31)$$

donde $0.9 < k < 1$.

5.3 Simulación

En [12] se desarrolló un control de sintonización de lazo usando el módulo de criterio óptimo, este se basa en un regulador constante el cual es determinado usando el Método de Modulo Optimo de constantes ya conocidas del modelo del motor lineal.

En este trabajo se aplicó a [12] el control neuronal por retroalimentación de estados obteniéndose buenos resultados de control.

Las simulaciones se realizaron en Simulink®. Mostrando los siguientes resultados.




Figura 29. Error de control de la velocidad.




Figura 30. Seguimiento de la velocidad.

A continuación se variaron los parámetros de [12] para comprobar el buen funcionamiento del controlador neuronal por retroalimentación de estados.

Obteniéndose los siguientes resultados:




Figura 31. Error de control de la velocidad cambiando los parámetros de la planta.




Figura 32. Seguimiento de la velocidad cambiando los parámetros de la planta.

Como podemos apreciar a pesar del cambio de los parámetros de la planta el controlador continúa realizando un buen funcionamiento en el control de la velocidad.

Capítulo 6. Conclusiones

En el presente trabajo se muestran los resultados cuando se aplican redes neuronales recurrentes de alto orden para la identificación del MIL. Dichos resultados fueron favorables, esto se puede notar en las simulaciones.

Por medio de la identificación neuronal recurrente de alto orden en tiempo discreto se demostró que es posible aproximar modelos donde sus dinámicas sean parecidas a las de la planta.

El control neuronal recurrente de alto orden discreto permite realizar el seguimiento de trayectoria.

El enfoque que se da con este control neuronal por retroalimentación de estados es adecuado para los MIL ya que brinda muy buenos resultados siendo estos comprobados en las simulaciones.

Las ventajas que presenta el control por retroalimentación de estados que es de implementación simple, solo se debe conocer la estructura del modelo. Una de las ventajas que presenta el controlador. Una desventaja es que está restringido a la estructura del modelo.

Unas desventajas al utilizar Redes Neuronales es que al inicializar los parámetros de una red neuronal no podemos saber cuáles vana ser los más adecuados para que el sistema minimice el error de la forma más rápida posible, por eso se inicializan estos parámetros de forma aleatoria. Es posible por tanto, que los parámetros elegidos aleatoriamente converjan muy lentamente. Durante el intervalo en el que aprende se está controlando muy mal el sistema y por tanto la salida es mala. Otra desventaja es que la velocidad de convergencia de la red depende de la RNA utilizada y en los casos en los que se utilizan RNA estándares pueden surgir velocidades de convergencia lentas, lo que hace que sea un problema en la práctica.

6.1 Trabajo Futuro

Como trabajo futuro se propone:

La implementación en tiempo real del algoritmo de identificación y control.

Bibliografía


- [1] A. S. Poznyak, E. N. Sánchez and W. Yu. *Differential Neural Networks for Robust Nonlinear Control*. WorldScientific Publishing Co., Singapore, 2001.
- [2] A. Y. Alanís. *Entrenamiento de redes neuronales con el filtro de kalman*. Tesis de Maestría, Centro de Investigación y Estudios Avanzados del IPN, Guadalajara, México, 2004.
- [3] A. Y. Alanís, E. N. Sánchez and A. G. Loukianov. "Discrete-time recurrent neural induction motor using Kalman learning". *Proceedings of the International Joint Conference on Neural Network*, July 2006.
- [4] A. Y. Alanís. *Discrete-time Neural Control: Application to Induction Motors*. Tesis de Doctorado, Centro de Investigación y Estudios Avanzados del IPN, Guadalajara, México, 2007.
- [5] Andrew P. Johnson. *High Speed Linear Induction Motor Efficiency Optimization*. Tesis de Maestría, Massachusetts Institute of technology, 2005.
- [6] Armando José Sinisterra. *Modeling of Linear Induction Machines for Analysis and Control*. Tesis de Maestría, The College of Engineering and Computing Science, Florida Atlantic University, Boca Raton, Florida, 2011.
- [7] Bernardino Castillo Toledo; "Motores de Inducción Lineales para uso en un Sistema de Transporte Rápido". Pag. 23.
- [8] Carlos P. Rodríguez. *Caracterización de un motor lineal de inducción*. Tesis de fin de carrera, departamento de Ingeniería Eléctrica, Universidad Carlos tercero de Madrid, España, 2011.
- [9] E. B. Kosmatopoulos, M. M. Polycarpou and M. A. Christodolou and P. A. Inoannou. "High-order neural network structures for identification of dynamical systems" Vol. 6, No. 2, pp. 422-431, *IEEE Trans. on Neural Networks*, 1995.

Bibliografía

- [10] Edgar Nelson Sánchez Camperos y Alma Yolanda Alanís García. “REDES NEURONALES, Conceptos Fundamentales y Aplicaciones a Control Automático”, Pearson Education, Madrid, España, 2006.
- [11] E. N. Sánchez, A. Y. Alanís and G. Chen. “Recurrent Neural Networks Trained with Kalman Filtering for discrete chaos reconstruction” Vol. 13, pp. 1-18, Dynamics of Continuous, Discrete and Impulsive Systems Series B DCIS_B, 2006
- [12] Eliska Tejklová. “Realization of Servomechanism with Linear Motor in Matlab–Simulink Environment”; Department of applied Cybernetics, Faculty of Mechanical Engineering, Technical University of Liberec, Studenská 2, 461 17 Liberec, Czech Republic. June 9 – 12, 2009. P 155 157.
- [13] F. L. Lewis, S. Jagannathan, and A. Yesildirek. Neural Network Control of Robot Manipulators and Nonlinear Systems. Taylor & Francis, Philadelphia, U. S. A., 1999.
- [14] G. A. Rovithakis and M. A. Chistodoulou. Adaptive Control with Recurrent High-Order Neural Networks. Springer Verlag, Berlin, Germany, 2000.
- [15] J. Flórez, A. García Rico, G. Martínez, M. Martínez-Iturralde, “ESTRATEGIAS DE CONTROL PARA ACCIONAMIENTOS ELÉCTRICOS LINEALES”, ISA, Sección Española Conferencias Anuales 2003, TECNUN (Escuela Superior de Ingenieros), Universidad de Navarra.
- [16] J. Liu, F. Lin, Z. Yang, and T. Q. Zhen. “Field oriented control of linear induction motor considering attraction force & end-effects” Vol. 1 pp. 1-5, IPEMC, Aug. 2006.
- [17] J. L. Ricalde. Inverse Optimal Adaptive Recurrent Neural Control with Constrained Inputs. Tesis de Doctorado, Centro de Investigación y Estudios Avanzados del IPN, Guadalajara, México, 2005.
- [18] Juan Morejón Vevia. SIMULACIÓN Y ANÁLISIS DE UN PROTOTIPO DE TRANSPORTE MASIVO CON MOTOR LINEAL SÍNCRONO DE IMANES PERMANENTES. APLICACIÓN EN MEF/MES. Proyecto de fin de carrera, Departamento de Mecánica, Universidad Carlos Tercero de Madrid, Escuela Politécnica Superior. 2009.

Bibliografía

- [19] M. H. González. Control Neuronal Discreto del Motor de Inducción de Desplazamiento Lineal. Tesis de Maestría, Centro de Investigación y Estudios Avanzados del IPN, Guadalajara, México, 2008.
- [20] M. Hernández González, E. N. Sánchez, A. G. Loukianov. “Discrete-time Neural Network Control for a Linear Induction Motor”, IEEE Multi-conference on System and Control, San Antonio, Texas, September 2008.
- [21] Pedro Arafet Padilla, Francisco Chang Mumañ, Miguel Torres Alberto, Hugo Domínguez Abreu; “MÉTODOS DE IDENTIFICACIÓN DINÁMICA”, Facultad de Ingeniería Eléctrica. Universidad de Oriente; Junio 2008.
- [22] S. Haykin. Kalman Filtering and Neural Networks. John Wiley and Sons, N.Y., U.S.A., 2001.
- [23] S. S. Ge, J. Zhang, and T. H. Lee. “Adaptive neural network control for a class of MIMO nonlinear systems with disturbances in discrete-time” Vol. 34, No. 4, pp. 1630-1645, *IEEE transactions on systems, Man and cybernetics*, 2004.
- [24] V. H. Benítez. Control neuronal a bloques: Aplicación a un motor de inducción de desplazamiento lineal. Tesis de Maestría, Centro de Investigación y Estudios Avanzados del IPN, Guadalajara, México, 2002.
- [25] Y. M. Park, M. S. Choi, and K. Y. Lee. “An optimal Tracking neuro-controller for nonlinear dynamic systems”. Vol. 7, pp. 1099-1110, *IEEE Trans. Neural Networks*, 1996.



CENTRO DE INVESTIGACIÓN Y DE ESTUDIOS AVANZADOS DEL I.P.N. UNIDAD GUADALAJARA

El Jurado designado por la Unidad Guadalajara del Centro de Investigación y de Estudios Avanzados del Instituto Politécnico Nacional aprobó la tesis

Aplicación de observadores conmutados para motores de inducción

del (la) C.

Luis Alberto ESPARZA GARCÍA

el día 27 de Septiembre de 2013.

Dr. Bernardino Castillo Toledo
investigador CINVESTAV 3C
CINVESTAV Unidad Guadalajara

Dr. Antonio Ramirez Treviño
investigador CINVESTAV 3A
CINVESTAV Unidad Guadalajara

Dr. Enrique Javier Aguayo Lara
PROFESOR TIEMPO COMPLETO.
INSTITUTO TECNOLÓGICO Y DE ESTUDIOS
SUPERIORES DE MONTERREY, Campus
Guadalajara.



CINVESTAV - IPN
Biblioteca Central



SSIT0011906