


xx(178570.1)



Centro de Investigación y de Estudios Avanzados del I.P.N.
Unidad Guadalajara

Control Neuronal Discreto del Motor de Inducción de Desplazamiento Lineal



CENTRO DE INVESTIGACIÓN Y
DE ESTUDIOS AVANZADOS DEL
INSTITUTO POLITÉCNICO
NACIONAL

COORDINACIÓN GENERAL DE
SERVICIOS BIBLIOGRÁFICOS

Tesis que presenta:

Miguel Hernández González

para obtener el grado de:

Maestro en Ciencias

en la especialidad de:

Ingeniería Eléctrica

Directores de Tesis

Dr. Edgar Nelson Sánchez Camperos
Dr. Alexander Georgievich Loukianov

CINVESTAV
IPN
ADQUISICION
DE LIBROS

Guadalajara, Jalisco, Agosto de 2008.

CLASIF.: TR 165.48 H49 2008
ADQUIS.: S91-521
FECHA: 23- III- 2009
PROCED.: Don. 2009
\$ _____

U : 158249-1001

Control Neuronal Discreto del Motor de Inducción de Desplazamiento Lineal

**Tesis de Maestría en Ciencias
Ingeniería Eléctrica**

Por:

Miguel Hernández González

**Ingeniero en Electrónica y Sistemas de Comunicación Digital
Universidad Autónoma de Aguascalientes 2001-2006**

Becario de conacyt, expediente no. 203126

Directores de Tesis

Dr. Edgar Nelson Sánchez Camperos

Dr. Alexander Georgievich Loukianov

CINVESTAV del IPN Unidad Guadalajara, Agosto de 2008.

Agradecimientos

A mis padres, *Ma. Cristina González de Jesús y Máximo Hernández González*, por su cariño y apoyo que siempre me han brindado, tanto en mis estudios como en mi vida personal y a mis hermanos *Álfredo, Daniel, Eduardo, Javier y Sergio A.*

A mis asesores de tesis, al *Dr. Edgar N. Sánchez* y *Dr. Alexander G. Loukianov* por sus conocimientos compartidos, el apoyo brindado, así como por la paciencia que me tuvieron durante la elaboración de esta tesis.

A mis sinodales *José M. Cañedo, Arturo S. Carmona* por sus comentarios que ayudaron a enriquecer este trabajo.

A mis *compañeros de generación*; *Alvaro O. Valenzuela, Esteban A. H. Vargas, Antonio F. Quintero, Fernando O. Tellez, Sergio A. Hernández, David G. Gutierrez, Victor M. B. Zamora, Graciela C. Sandoval, Javier Magallon, José A. Canche, José M. Córdoba, Diana A. Urrego* y amigos *Guillermo R. Prado, Aracely C. Michel, Onofre M. Garduño, Ruben M. Cadena, Carlos Castañeda* por haberme brindado su amistad y apoyo durante mi estancia en cinvestav.

Al *CINVESTAV* por permitirme realizar mis estudios de maestría y muy especialmente al *CONACYT* por el apoyo económico.

Resumen

Las máquinas eléctricas son muy importantes en nuestra vida diaria. Ellas pueden ser encontradas en aplicaciones, como en el transporte, en la industria y en el hogar, entre otros. Entre estos tipos de máquinas se encuentra el Motor de Inducción Lineal (MIL), el cual es presentado en esta tesis.

Existen algoritmos de control, uno de los más utilizados es el de modos deslizantes. Ésta es una herramienta efectiva de control de sistemas no lineales; sin embargo, por su alta frecuencia de conmutación presenta los fenómenos conocidos como cascabeleo y discretización del cascabeleo. El modo deslizante en tiempo discreto no tiene estos problemas.

Ha habido un gran interés en el uso de redes neuronales para aproximar funciones no lineales. Por este motivo se han usado para identificación y control de sistemas no lineales.

Esta tesis presenta el uso de redes neuronales discretas para identificar un MIL y un control por modos deslizantes en tiempo discreto para el seguimiento de velocidad y magnitud del flujo para dicho motor. El algoritmo de entrenamiento para la red neuronal está basado en el filtro de Kalman extendido.

Abstract

Electrical machines are very important in our life. They can be found in several applications, such as transportation, in the industry and home, among others. One of this kind of machine is the Linear Induction Motor (LIM), which is presented in this thesis.

There exist a variety of control algorithms, one of the most important is the sliding modes. This is an effective control tool for nonlinear systems; even though, because its high frequency conmutation, it presents the well-known phenomena as chattering and chattering discretization. The discrete-time sliding mode does not present these problems.

Recently, there is a great motivation to use neural networks for nonlinear systems approximation. Therefore, they has been employed for nonlinear systems identification and control design.

This thesis, presents the use of discrete-time neural networks to identify a MIL and discrete-time sliding mode control for trajectory tracking. The training algorithm is based in extended Kalman filtering.

Indice General

1	Introducción	1
1.1	Motor de Inducción Lineal	1
1.2	Redes Neuronales y Control	2
1.3	Antecedentes	2
1.4	Objetivos	2
1.5	Organización de la Tesis	3
2	Motor de Inducción Lineal	4
2.1	Motor de Inducción de Desplazamiento Lineal	4
2.2	Geometría y Clasificación	5
2.3	Devanados del MIL	8
2.4	Circuitos Magnéticos	9
2.5	Efectos Electromagnéticos	9
2.5.1	Relaciones fundamentales	9
2.6	Efectos de Bordos Longitudinales	9

INDICE GENERAL

2.7	Modelo Matemático del MIL	11
2.8	Discretización	13
3	Redes Neuronales	14
3.1	Redes Neuronales	14
3.1.1	Tipos de funciones de activación	15
3.2	Redes Neuronales de Alto Orden	15
3.2.1	Identificación Neuronal	16
3.3	Algoritmo de Entrenamiento	19
3.3.1	Filtro de Kalman	19
3.3.2	Filtro de Kalman Extendido	21
4	Ley de Control	24
4.1	Modos Deslizantes en Tiempo Discreto	24
4.2	Control Neuronal por Bloques	27
4.2.1	Forma controlable por bloques	28
4.2.2	Linealización por transformación	30
4.2.3	Modos Deslizantes en Tiempo Discreto	32
5	Control del MIL	38
5.1	Desarrollo de la Ley de Control	38
5.1.1	Identificación Neuronal	38
5.1.2	Forma Controlable por Bloques	39

INDICE GENERAL

5.1.3	Ley de Control	41
5.1.4	Observador de Flujo	44
5.2	Simulación	46
6	Observador Neuronal	55
6.1	Observador Neuronal en Tiempo Discreto	55
6.2	Simulación	58
7	Conclusiones	65
7.1	Trabajo futuro	65
	Bibliografía	69

Lista de figuras

2.1	Transformación del motor rotatorio a lineal	5
2.2	Motor de inducción lineal de dos lados	6
2.3	Corte de un motor de inducción lineal	6
2.4	Envolvente B_{mz}	10
2.5	Distribución de las corrientes de Eddy para el deslizamiento	10
3.1	Red neuronal discreta .	16
3.2	Proceso dinámico lineal variante en el tiempo	20
3.3	Esquema de identificación	23
4.1	Identificación y control	37
5.1	Error de velocidad	47
5.2	Error del flujo α	47
5.3	Error del flujo β	48
5.4	Error de la corriente α	48
5.5	Error de la corriente β	49

LISTA DE FIGURAS

5.6	Seguimiento de la velocidad	49
5.7	Seguimiento de la magnitud del flujo	50
5.8	Perturbación en la carga	50
5.9	Perturbación en la resistencia del rotor	51
5.10	Error de identificación de $Im(k)$	51
5.11	Evolución de $Im(k)$	52
5.12	Flujo en la fase α	52
5.13	Flujo en la fase β	53
5.14	Control u_α	53
5.15	Control u_β	54
6.1	Observador neuronal	60
6.2	Posición del secundario	61
6.3	Velocidad lineal	61
6.4	Flujo en la fase α	62
6.5	Flujo en la fase β	62
6.6	Corriente en la fase α	63
6.7	Corriente en la fase β	63
6.8	Perturbación en la carga	64
6.9	Perturbación en la resistencia del rotor	64

Lista de tablas

5.1 Parámetros del Motor

46

Capítulo 1

Introducción

En este capítulo se dá una breve explicación del motor de inducción lineal, la estrategia de control empleada, y sobre la identificación de sistemas no lineales por medio de redes neuronales de alto orden. Además, se incluyen los objetivos de la tesis, así como la organización de la misma.

1.1 Motor de Inducción Lineal

El Motor de Inducción Lineal (MIL) es una máquina en el cual la energía eléctrica es convertida directamente en energía mecánica de movimiento translacional. El interés en este tipo de máquinas surgió a comienzos de 1970 [13]. Después de 1980 los MIL fueron aplicados en el transporte, en la industria, es decir, en los procesos de manufactura, en el hogar, entre otros. Los principios de operación de los MIL son similares a las de los motores de inducción rotatorios, pero con condiciones para su control más complicadas [13].

1.2 Redes Neuronales y Control

Las redes neuronales se han establecido como una metodología adecuada para la aproximación de funciones no lineales; debido a esto son muy empleadas en la identificación de sistemas no lineales [19] para obtener modelos cuya dinámica se comporte como la del sistema real [9].

Por otro lado, el control por modos deslizantes es una buena herramienta para el control de sistemas no lineales, ya que permite el seguimiento de trayectorias a pesar de perturbaciones tanto externas como internas [23].

En un control con modos deslizantes en tiempo continuo, cuando se alcanza a la superficie de conmutación, la frecuencia de la señal de control se vuelve infinita, por lo que excita dinámicas no modeladas de la planta y se presenta el fenómeno conocido como cascabeleo [23]. Por otro lado, la mayoría de los controladores son implementados por medio de computadoras digitales, por lo que la frecuencia de la ley de control está limitada por el período de muestreo y se presenta lo que se conoce como discretización del cascabeleo [23]. Por lo anterior en esta tesis se utilizarán modos deslizantes en tiempo discreto el cual no presenta las desventajas antes mencionadas [23].

1.3 Antecedentes

Para el control de este tipo de motor ya existen trabajos previos como [22], dónde se hace un control por modos deslizantes; sin embargo el control empleado es discontinuo, lo que nos lleva a las desventajas arriba mencionadas.

1.4 Objetivos

Los objetivos de esta tesis son:

1. Desarrollar un identificador en la forma no lineal controlable por bloques, basado

en redes neuronales de alto orden para el MIL.

2. Desarrollar una ley de control para el MIL, basado en el identificador neuronal con la técnica de control por modos deslizantes en tiempo discreto.
3. Hacer un observador neuronal basado en redes neuronales de alto orden.

1.5 Organización de la Tesis

La tesis se encuentra organizada de la siguiente forma

En el **Capítulo 2**, se presenta el motor de inducción lineal, su analogía con el motor de inducción rotatorio, los distintos tipos de MIL, sus características electromagnéticas, así como el modelo matemático del motor.

En el **Capítulo 3**, se aborda el tema de identificación no lineal mediante redes neuronales recurrentes discretas. Para el entrenamiento de éstas se utiliza un filtro de kalman extendido.

En el **Capítulo 4** se discute sobre el tipo de control usado, que es por modos deslizantes en tiempo discreto.

En el **Capítulo 5**, se describen las simulaciones realizadas usando la técnica de control por bloques y modos deslizantes con el identificador neuronal, para el seguimiento de velocidad y magnitud de flujo. Esta es la primer aportación de esta tesis.

En el **Capítulo 6** se desarrolla un observador neuronal recurrente que usa un filtro de Kalman como algoritmo de entrenamiento para adaptar los pesos en línea. También se incluyen las simulaciones aplicadas al motor de inducción lineal. Esta es la segunda aportación de esta tesis.

En el **Capítulo 7** se dan las conclusiones y trabajo futuro.

Capítulo 2

Motor de Inducción Lineal

En este capítulo se presenta este tipo de máquinas, sus características, los fenómenos que presentan, así como el modelo matemático empleado en el desarrollo de la tesis.

2.1 Motor de Inducción de Desplazamiento Lineal

En los motores eléctricos lineales el movimiento es de traslación; es decir, el elemento móvil se desplaza de manera lineal con respecto a un elemento estacionario [10], [13].

Los motores eléctricos de desplazamiento lineal pertenecen al grupo de máquinas eléctricas que convierten energía eléctrica en energía mecánica de movimiento translacional. Estos pueden ser clasificados como [13]:

- motores de corriente directa,
- motores de inducción,
- motores síncronos,
- motores híbridos.

De los anteriores, el más popular es el Motor de Inducción Lineal (MIL). Los motores eléctricos lineales, al igual que los rotatorios también pueden ser usados como generadores [13].

2.2 Geometría y Clasificación

Un MIL puede ser obtenido cortando un Motor de Inducción Rotatorio (MIR) a lo largo de su radio desde su eje a la superficie externa del estator y extendiéndolo. Se obtiene así una topología planar como se ilustra en la Fig. 2.1. Al elemento fijo se le denomina *sector primario* y al elemento móvil se le denomina *sector secundario* [13], [11]. El MIL puede ser de primario o secundario corto, dependiendo si el primario o el secundario es más corto; en cualquier caso el primario o el secundario es movable con respecto a un elemento estacionario [10]. Reenrollando al MIL en la dirección del campo magnético viajero, es decir, paralelo en la dirección de empuje, se obtiene un motor tubular [13], [12].

Teóricamente, los de un solo lado puede ser combinados para obtener un MIL de dos lados, el cual tendrá el doble de fuerza que el de un solo lado [10], como se puede ver en la Fig. 2.2. De igual forma, si el estator y rotor de un motor rotatorio son cortados y aplanados se obtiene un motor lineal de dos lados [11], como se ilustra en la Fig. 2.3.




Fig. 2.1: Transformación del motor rotatorio a lineal




Fig. 2.2: Motor de inducción lineal de dos lados




Fig. 2.3: Corte de un motor de inducción lineal

El secundario de un MIL puede ser simplificado usando un núcleo de acero sólido y reemplazando la jaula de ardilla, para el caso del motor de jaula de ardilla, con un plato no ferromagnético de alta conductividad (aluminio o cobre). El plato no ferromagnético es un circuito eléctrico secundario con parámetros distribuidos y el núcleo ferromagnético es un conductor tanto para el flujo magnético como para la corriente eléctrica [13].

Dentro de los MIL se encuentran los motores con *flujo magnético longitudinal*; es decir, las líneas del flujo magnético yacen en el plano paralelo a la dirección del campo magnético viajero, y los motores con *flujo magnético transversal*, en los cuales las líneas del flujo magnético son perpendiculares a la dirección del campo viajero [13].

La principal ventaja de un MIL con flujo magnético transversal en comparación con uno de flujo magnético longitudinal es la baja corriente magnetizante necesaria, debido a los cortos caminos del flujo magnético; la desventaja es su bajo empuje. Un MIL planar con flujo magnético transversal tiene un devanado primario de bobinas concentradas localizadas en polos salientes; además también produce *suspensión electrodinámica* [13].

De manera similar un MIL planar con polos salientes y flujo magnético longitudinal puede ser diseñado para obtener suspensión electrodinámica, propulsión y estabilización.

De acuerdo a su geometría los MIL se pueden clasificar en los siguientes grupos:

- Con primario o secundario móvil,
- De un lado sencillo o doble,
- Planar y tubular,
- Primario o secundario corto,
- Con flujo magnético transversal o longitudinal.

2.3 Devanados del MIL

Los *devanados del primario* de un MIL son conductores de cobre con sección cruzada redonda o rectangular. Los conductores de aluminio no son utilizados ya que incrementan las pérdidas en los devanados del primario y consecuentemente la temperatura del devanado. Los devanados pueden ser localizados en ranuras; es decir, devanados con *parámetros distribuidos* o en la forma de bobinas localizadas en polos salientes; es decir, devanados con *parámetros concentrados*. Los MIL de baja potencia tienen devanados aleatorios de alambre redondo (ranuras semi-abiertas), mientras que los de media y alta potencia tienen devanados hechos de bobinas preformadas de barras de cobre rectangular (ranuras abiertas) [13].

Los devanados del primario son devanados de tres fases de con el número de ranuras por polo y por fase dada por:

$$q_1 = \frac{z_1}{2pm_1} > 1$$

donde z_1 es el número de ranuras del primario totalmente ocupados con conductores, m_1 es el número de fases del primario y $2p$ es el número de polos del primario. El entre-hierro de los MIL de un solo lado es de pocos a varios milímetros y el entre-hierro no ferromagnético de los MIL de doble lado es más grande [13].

Los *devanados del secundario* en general tienen parámetros distribuidos. En los MIL de un solo, lado los devanados del secundario consisten de un núcleo de acero sólido cuya superficie adyacente al entre-hierro es cubierta con capas de aluminio o cobre. El espesor de la capa de aluminio es de 2 a 6 mm, mientras que la capa de cobre es de 1 a 4 mm. El núcleo del secundario es un conductor tanto para el flujo magnético como para la corriente eléctrica [13].

El secundario de un MIL de dos lados, usualmente no tiene un núcleo ferromagnético. En los MIL de doble lado planares el secundario es un plato de aluminio o cobre, como se ve en la Fig. 2.2 (b). El espesor del secundario es de pocos a varios milímetros.

2.4 Circuitos Magnéticos

Los circuitos magnéticos de los MIL son hechos de los mismos materiales magnéticos que la de los MIR.

2.5 Efectos Electromagnéticos

2.5.1 Relaciones fundamentales

La velocidad lineal del armónico fundamental de la fuerza magnetomotriz (MMF) de la onda viajera producida por el devanado del primario es llamado *velocidad síncrona* y está dada por:

$$v_s = \frac{2\tau}{T} = 2f\tau = \frac{\omega}{\pi}\tau \quad (2.1)$$

donde τ es la distancia entre polos, $f = 1/T$ es la frecuencia de entrada, $\omega = 2\pi f$ es la velocidad angular. La velocidad síncrona de un MIL depende de la frecuencia de la corriente de entrada y de la distancia entre polos, pero no de número de polos. [13]. El secundario del MIL se mueve a una velocidad $v < v_s$, a lo largo del eje x . El deslizamiento s es definido como:

$$s = \frac{v_s - v}{v_s} \quad (2.2)$$

2.6 Efectos de Bordos Longitudinales

La principal diferencia entre un MIR y un MIL es la longitud finita de los circuitos eléctricos y magnéticos del MIL en la dirección del campo viajero. Los circuitos magnéticos abiertos causan un efecto llamado "*efecto de bordes longitudinales*". Esos efectos son parásitos. Se supone en esta trabajo que el primario es fijo mientras que el secundario está en movimiento con una velocidad v a lo largo del eje x .

Despreciando las ranuras, la distribución de la componente normal en la dirección del eje x a velocidad $v = 0$ puede ser vista como una función rectangular. A velocidades



Fig. 2.4: Envolvente B_{mz} 

Fig. 2.5: Distribución de las corrientes de Eddy para el deslizamiento

altas hay una fuerte influencia de los efectos de bordes longitudinales. A velocidad $v \neq 0$ la distribución de la componente normal de la densidad del flujo magnético es aproximadamente una función trapezoidal. La distribución de la corrientes de Eddy en el secundario a velocidad $v = 0$, y con deslizamiento $s = 1$ se ilustra en la Fig. 2.5 (a) y para $v \neq 0$ y con deslizamiento $s = 0.12$ se ilustra en la Fig. 2.5 (b) [13].

Hay una fuerte influencia de los efectos de bordes longitudinales en el desempeño del MIL a altas velocidades, pero a bajas velocidades estos efectos no afectan [13].

Los efectos de bordes longitudinales aparecen en forma de:

- Distribución de la densidad del flujo magnético no uniforme dependiente de la velocidad en el entre-hierro (Fig. 2.4) y una no uniformidad en la distribución en las corrientes de Eddy (Fig. 2.5),
- Corrientes de fase desbalanceadas,
- Fuerzas de frenado parásitas.

Los efectos de bordes longitudinales son debidos al corte de la onda viajera en cada extremo del MIL. La física de esos efectos es complicada; son causados por la interferencia de las ondas de la densidad del flujo magnético y el cambio de paso en las reluctancias para el flujo magnético en cada extremo del circuito magnético [13].

En la Fig. 2.4 se ilustra que la distribución de la componente normal de la densidad del flujo magnético a lo largo de la distancia entre polos τ a velocidad $v \neq 0$ es no uniforme, es decir, es débil al inicio y amplificada en el extremo del circuito magnético.

2.7 Modelo Matemático del MIL

Las ecuaciones dinámicas correspondientes a los circuitos eléctricos de una máquina de corriente alterna con m_1 devanados de fase primaria, m_2 devanados de fase secundaria se describen por la siguiente ecuación matricial [13]

$$V(t) = Ri(t) + \frac{d}{dt}(D_e(q_m)i(t)) \quad (2.3)$$

donde $V(t) \in \mathfrak{R}^{m_1+m_2}$ es el vector de voltajes, $i(t) \in \mathfrak{R}^{m_1+m_2}$ es el vector de corrientes, $R \in \mathfrak{R}^{(m_1+m_2) \times (m_1+m_2)}$ es la matriz diagonal de resistencias y $D_e^{(m_1+m_2) \times (m_1+m_2)}$ es la matriz de inductancias. El secundario es dividido en m_2 circuitos con una distribución de la densidad de corriente uniforme. Para tener un modelo completo, se incluye la siguiente ecuación mecánica

$$D_m \frac{d^2}{dt^2} q_m + R_m \frac{d}{dt} q_m = \tau(t) \quad (2.4)$$

donde q_m es la posición del secundario (metros), $\tau(t)$ es la fuerza electromagnética o empuje mecánico (Newton), D_m es la masa del sector secundario (Kilogramo), R_m

es la constante de amortiguamiento viscoso mecánico (Kilogramo/s). Las ecuaciones (2.3) y (2.4) se relacionan por medio de la fuerza electromagnética o empuje desarrollado por el motor como resultado de la conversión de de energía eléctrica en energía mecánica, es decir,

$$\tau(t) = \frac{1}{2} i^T(t) \frac{\partial D_e(q_m)}{\partial q_m} i(t) \quad (2.5)$$

El modelo del MIL fue obtenido en [22], bajo la siguientes suposiciones con el secundario desplazándose a una velocidad v :

1. Las corrientes del sector secundario y la velocidad son las variables medibles,
2. Los parámetros del motor son desconocidos,
3. Las entradas de control son los voltajes aplicados al sector secundario,
4. Los dos neutros de los circuitos del primario y secundario son aislados,
5. Las terminales del secundario se encuentran en corto circuito internamente,
6. Se desprecian los efectos de bordes longitudinales,
7. De un solo lado con secundario móvil y flujo magnético longitudinal.

La obtención del modelo $\alpha - \beta$ en forma detallada puede verse en [22]. Dicho modelo propósitos de esta tesis fue discretizado por Euler [16] y está dado por

$$\begin{aligned} q_m(k+1) &= q_m(k) + v(k)T \\ v(k+1) &= (1 - k_2T)v(k) - k_1T\lambda_{r\alpha}(k)\rho_1i_{s\alpha}(k) - k_1T\lambda_{r\beta}(k)\rho_2i_{s\alpha}(k) \\ &\quad + k_1T\lambda_{r\alpha}(k)\rho_2i_{s\beta}(k) - k_1T\lambda_{r\beta}(k)\rho_1i_{s\beta}(k) - k_3TF_L \\ \lambda_{r\alpha}(k+1) &= (1 - k_6T)\lambda_{r\alpha}(k) + k_4Tv(k)\rho_1i_{s\alpha}(k) - k_4T\rho_1i_{s\alpha}(k) + k_5T\rho_2i_{s\alpha}(k) \\ &\quad + k_4T\rho_2i_{s\beta}(k) - k_4Tv(k)\rho_2i_{s\beta}(k) + k_5T\rho_1i_{s\beta}(k) \\ \lambda_{r\beta}(k+1) &= (1 - k_6T)\lambda_{r\beta}(k) + k_4Tv(k)\rho_2i_{s\alpha}(k) - k_4T\rho_2i_{s\alpha}(k) - k_5T\rho_1i_{s\alpha}(k) \\ &\quad - k_4T\rho_1i_{s\beta}(k) + k_4Tv(k)\rho_1i_{s\beta}(k) + k_5T\rho_2i_{s\beta}(k) \\ i_{s\alpha}(k+1) &= (1 + k_9T)i_{s\alpha}(k) - k_7T\lambda_{r\alpha}(k)\rho_2 - k_8T\lambda_{r\alpha}(k)v(k)\rho_1 + k_7T\lambda_{r\beta}(k)\rho_1 \\ &\quad - k_8T\lambda_{r\beta}(k)v(k)\rho_2 - k_{10}Tu_{\alpha}(k) \end{aligned} \quad (2.6)$$

$$i_{s\beta}(k+1) = (1 + k_9 T) i_{s\beta}(k) + k_8 T \lambda_{r\alpha}(k) v(k) \rho_2 - k_7 T \lambda_{r\alpha}(k) \rho_1 - k_7 T \lambda_{r\beta}(k) \rho_2 - k_8 T \lambda_{r\beta}(k) v(k) \rho_1 - k_{10} T u_\beta(k)$$

$$\rho_1 = \sin(n_p q_m(k)) \quad \rho_2 = \cos(n_p q_m(k))$$

$$k_1 = \frac{n_p L_{sr}}{D_m L_r} \quad k_2 = \frac{R_m}{D_m} \quad k_3 = \frac{1}{D_m} \quad k_4 = n_p L_{sr} \quad k_5 = \frac{R_r L_{sr}}{L_r}$$

$$k_6 = \frac{R_r}{L_r} \quad k_7 = \frac{L_{sr} R_r}{L_r (L_{sr}^2 - L_s L_r)} \quad k_8 = \frac{L_{sr} n_p}{L_{sr}^2 - L_s L_r} \quad k_9 = \frac{L_r^2 R_s + L_{sr}^2 R_r}{L_r (L_{sr}^2 - L_s L_r)}$$

$$k_{10} = \frac{L_r}{L_{sr}^2 - L_s L_r}$$

donde $q_m(k)$ (metro) es la posición del sector secundario, $v(k)$ (metro/s) es la velocidad lineal, $\lambda_{r\alpha}(k)$ y $\lambda_{r\beta}(k)$ (Weber) son los flujos en los ejes α y β , respectivamente, $i_{s\alpha}(k)$ y $i_{s\beta}(k)$ (Ampere) son las corrientes en el primario en los ejes α and β respectivamente $u_{s\alpha}(k)$ y $u_{s\beta}(k)$ (Volt) son los voltajes α y β en el primario, R_s (Ω (Ohm)) es la resistencia en el devanado por fase, R_r (Ω) es la resistencia en el devanado por fase, L_{sr} (H (Henry)) es la inductancia magnetizante por fase, L_s (H) es la inductancia en el primario por fase, L_r (H) es la inductancia en el secundario por fase, F_L (Newton) es la perturbación en la carga, R_m (Kilogramo/s) es el coeficiente de fricción viscosa y pérdidas del hierro, D_m (Kilogramo) es la masa del sector secundario y n_p es el número de pares de polos, T (s) es el periodo de muestreo.

2.8 Discretización

Considere un sistema no lineal de la siguiente forma

$$\dot{x} = f(x) + g(x)u \quad (2.7)$$

donde $x \in \mathfrak{R}^n$, $f(x) : \mathfrak{R}^n \rightarrow \mathfrak{R}^n$ y $g(x) : \mathfrak{R}^{n \times m} \rightarrow \mathfrak{R}^n$ funciones no lineales y $u \in \mathfrak{R}^m$, la discretización por Euler se presenta como sigue:

$$x(k+1) = x(k) + T(f(x(k)) + g(x(k))u(k))$$

donde $k \in Z^+$ denota el tiempo discreto.

Capítulo 3

Redes Neuronales

Este capítulo presenta la identificación de sistemas no lineales utilizando Redes Neuronales Recurrentes y el algoritmo empleado para su entrenamiento.

3.1 Redes Neuronales

Las redes neuronales son sistemas no lineales altamente interconectados que tienen propiedades importantes, como por ejemplo: la aproximación de funciones [5]. Existen algoritmos para entrenar los pesos de la red neuronal como por ejemplo el de retropropagación [8] o el filtro de Kalman [20], [2]; cuando el entrenamiento termina la red aproxima al sistema real [9].

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 un gran número de neuronas para representar la respuesta dinámica en el dominio del tiempo [24].

Otro tipo de redes neuronales son las redes neuronales recurrentes, las cuales se distinguen de las estáticas en que tienen al menos un lazo de retroalimentación [1]. Estas son apropiadas para identificación y control de sistemas dinámicos no lineales

[1].

3.1.1 Tipos de funciones de activación

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 de activación comúnmente usadas son:

- Función escalón o umbral,
- Función sigmoide,
- Función tangente hiperbólica,
- Funciones de base radial.

3.2 Redes Neuronales 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 tipo Hopfield, el estado de cada neurona se puede determinar por una ecuación diferencial de la siguiente forma:

$$\dot{x} = -a_i x_i + b_i \sum_j w_{ij} y_j \quad (3.1)$$

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 entrada a la i -ésima neurona y y_i puede ser una entrada o el estado de una neurona pasado a través de una función sigmoide, es decir, $y_i = S(x_j)$ donde $S(\cdot)$ representa una función sigmoide.

En una red neuronal de segundo orden, la entrada total a una neurona no sólo 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.

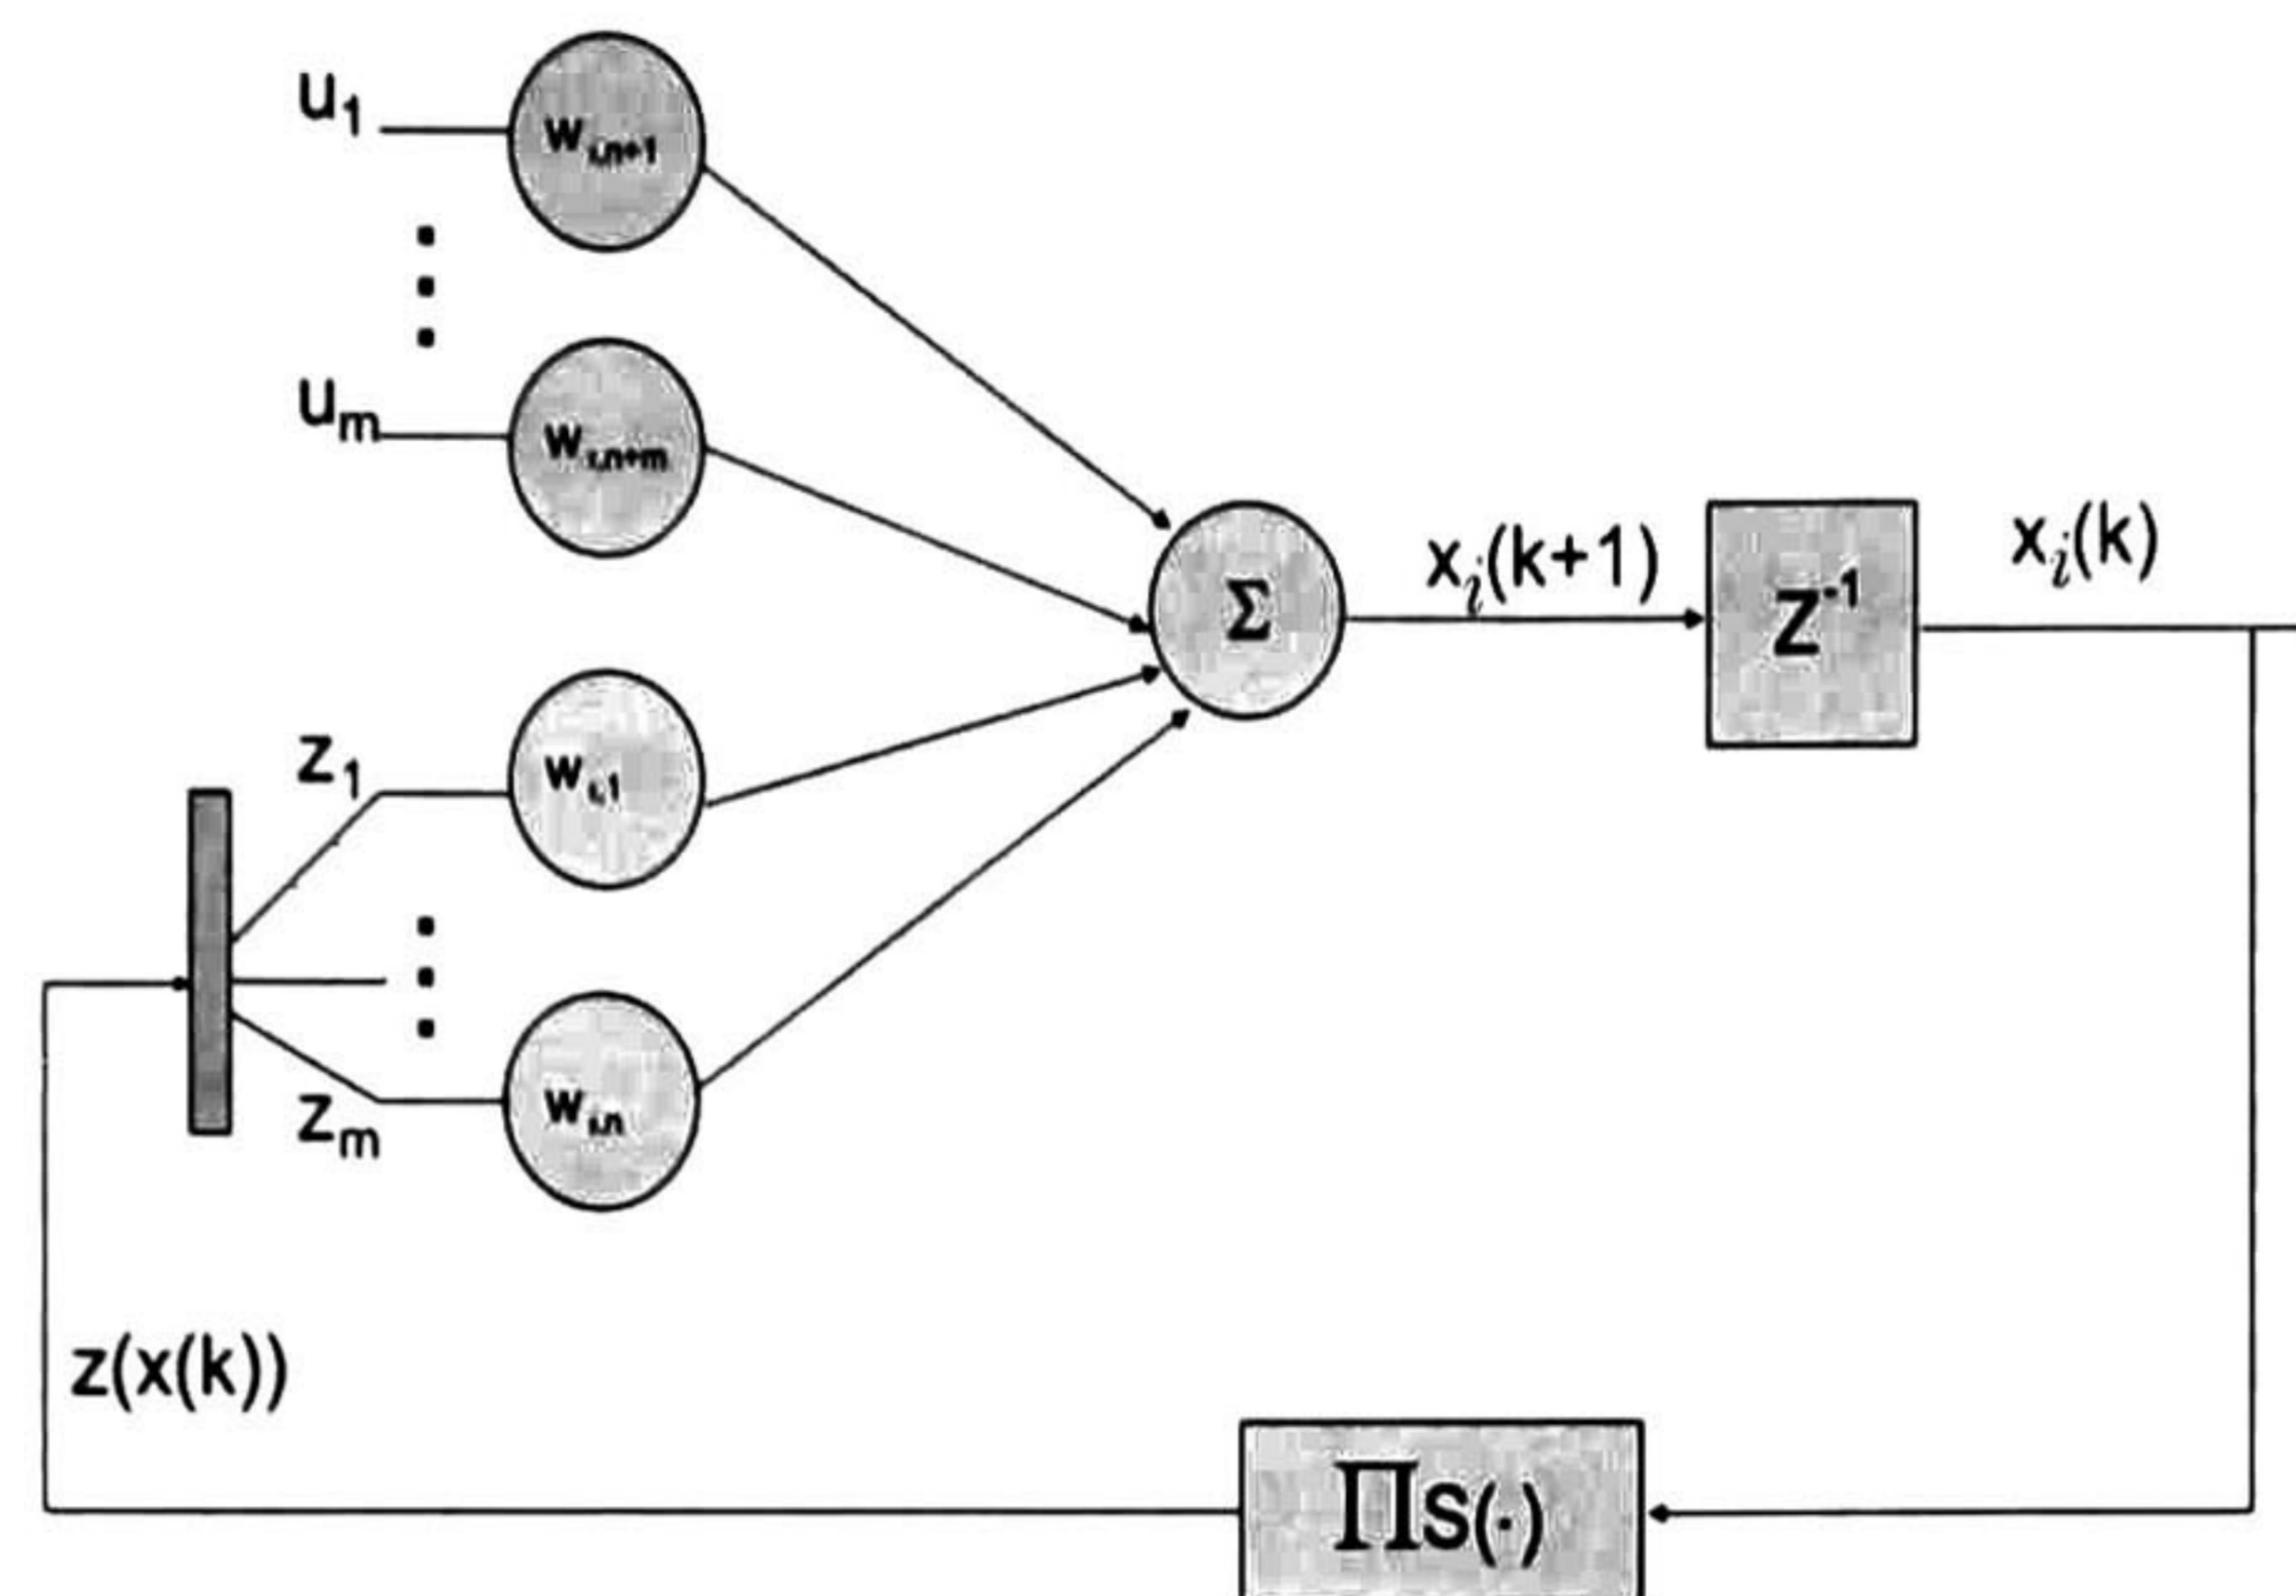


Fig. 3.1: Red neuronal discreta

Esta clase de red forma una red neuronal recurrente de alto orden (RHONN, por sus siglas en inglés “*Recurrent High Order Neural Networks*”).

La ROHNN tiene las siguientes características [14]:

- 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 de alto orden discretas presentan las mismas características que las continuas y son ideales para su uso en modelado [2], [7], [21], identificación y control de sistemas dinámicos discretos complejos debido a su facilidad de implementación y a su estructura de relativa sencillez [6].

3.2.1 Identificación Neuronal

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 de 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 [9]. Debido a que el modelo del sistema a analizar es un prerequisite para el análisis y el desarrollo de una ley de control, la identificación del sistema es importante no solo para comprender y predecir su comportamiento sino para obtener una ley de control efectiva.

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.

$$\chi_i(k+1) = w_i^T z_i(x(k), u(k)), \quad i = 1, \dots, n \quad (3.2)$$

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

$$\chi_i(k+1) = w_i^T z_i(\chi(k), u(k)), \quad i = 1, \dots, n \quad (3.3)$$

donde $x(k)$ son los estados de la planta, $\chi(k)$ son los estados 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:

$$x(k+1) = F(x(k), u(k)) + d(w(k)) \quad (3.4)$$

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

Considere el problema de aproximar al sistema (3.4) por la siguiente red neuronal de alto orden [9]:

$$\chi_i(k+1) = w_i^{*T} z_i(x(k), u(k)) + \epsilon_{z_i} \quad i = 1, \dots, n \quad (3.5)$$

donde $\chi_i (i = 1, \dots, n)$ 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 ajustables [5]. Suponga que existe un vector de pesos ideal w_i^* tal que $\|\epsilon_{z_i}\|$ puede ser minimizado sobre un conjunto compacto $\Omega_{z_i} \subset \mathbb{R}^{L_i}$. El vector de pesos ideal w_i^* es una cantidad artificial requerida para propósitos de análisis [9]. Se supone que este vector existe y es constante pero desconocido.

Para identificar al sistema (3.4) en esta tesis, se utiliza la siguiente red neuronal de alto orden discreta

$$\chi_i(k+1) = w_i^T z_i(x(k), u(k)), \quad i = 1, \dots, n \quad (3.6)$$

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

$$z_i(x(k), u(k)) = \begin{bmatrix} z_{i_1} \\ z_{i_2} \\ \vdots \\ z_{i_{L_i}} \end{bmatrix} = \begin{bmatrix} \prod_{j \in I_1} \psi_{i_j}^{d_{i_j}(1)} \\ \prod_{j \in I_2} \psi_{i_j}^{d_{i_j}(2)} \\ \vdots \\ \prod_{j \in I_{L_i}} \psi_{i_j}^{d_{i_j}(L_i)} \end{bmatrix} \quad (3.7)$$

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

$$\psi_i = \begin{bmatrix} \psi_{i_1} \\ \vdots \\ \psi_{i_n} \\ \psi_{i_{n+1}} \\ \vdots \\ \psi_{i_{n+m}} \end{bmatrix} = \begin{bmatrix} S(x_1(k)) \\ \vdots \\ S(x_n(k)) \\ u_1(k) \\ \vdots \\ u_m(k) \end{bmatrix} \quad (3.8)$$

En (3.8) $u(k) = [u_1(k) \ u_2(k) \ \dots \ u_m(k)]^T$ es el vector de entrada a la red neuronal,

y $S(\cdot)$ está dado por

$$S(\chi(k)) = \frac{\alpha}{1 + e^{-\beta x(k)}} + \gamma, \quad \beta > 0 \quad (3.9)$$

con

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

3.3 Algoritmo de Entrenamiento

3.3.1 Filtro de Kalman

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 tanto estacionarios como 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 pasados [20].

Considere el sistema dinámico lineal, en tiempo discreto, mostrado en la Fig. 3.2. Este diagrama involucra el siguiente par de ecuaciones:

1. Ecuación del proceso

$$w(k+1) = F_{k+1,k}w(k) + \mu(k)$$

en donde $F_{k+1,k} \in \mathfrak{R}^{n \times n}$ es la matriz de transición de estados del tiempo k al $k+1$, $w(k) \in \mathfrak{R}^n$ es el vector de estados al tiempo k , $\mu(k) \in \mathfrak{R}^n$ representa el vector de ruido del proceso (gaussiano con media cero) [20].

2. Ecuación de la salida

$$y(k) = H(k)w(k) + \nu(k)$$

$H(k) \in \mathfrak{R}^{p \times n}$ es la matriz de medición, $y(k) \in \mathfrak{R}^m$ es el vector de salida del proceso, $\nu(k) \in \mathfrak{R}^m$ representa el vector de ruido de medición (gaussiano con media cero).

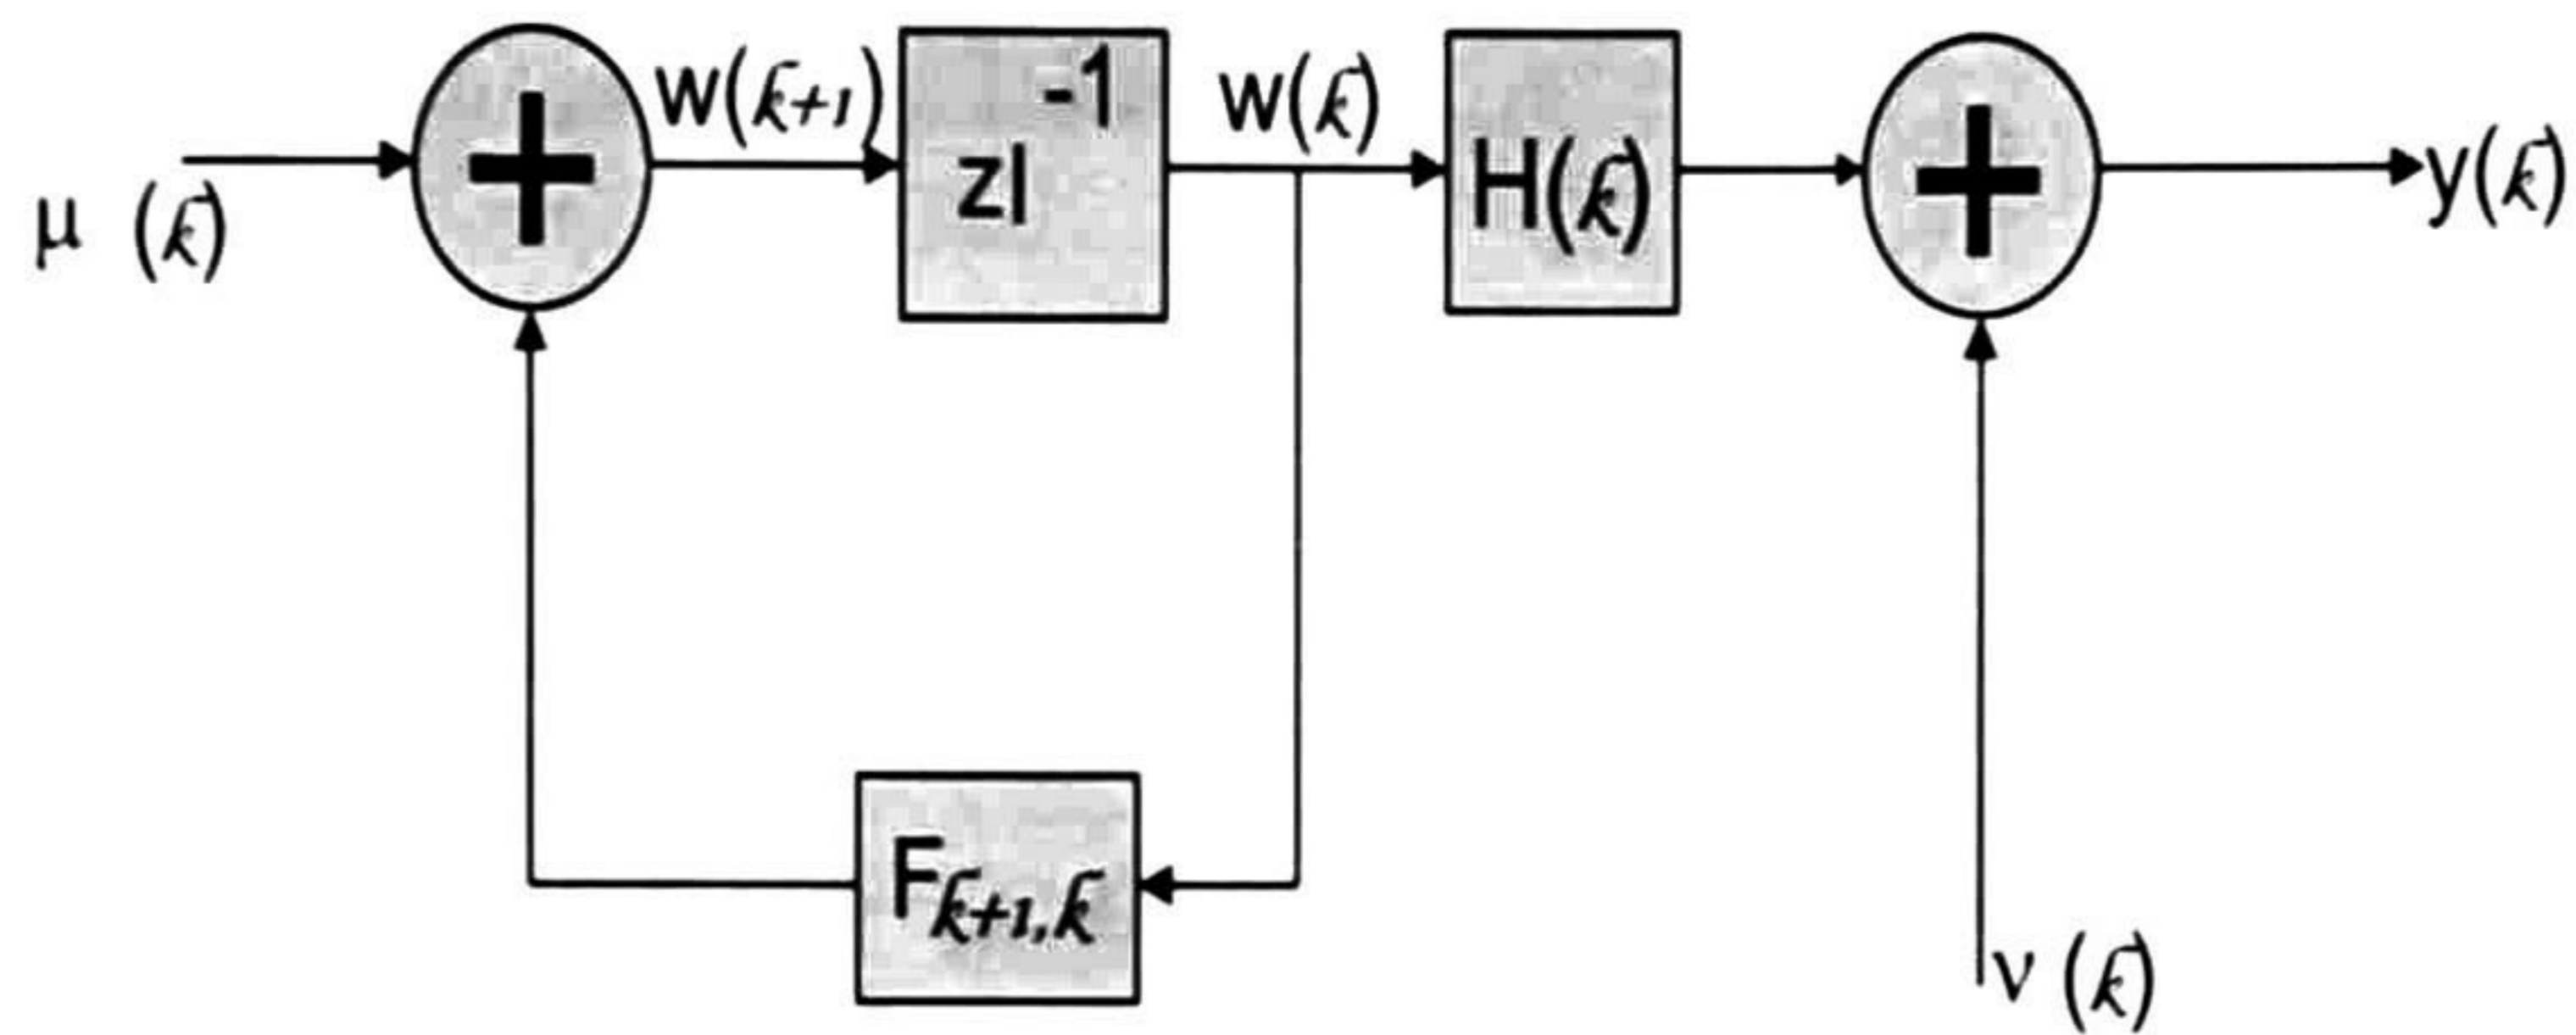


Fig. 3.2: Proceso dinámico lineal variante en el tiempo

La matriz de covarianza del ruido del proceso se define como

$$E \{ \mu(s) \mu(k)^T \} = \begin{cases} Q(k) & \text{para } s = k \\ 0 & \text{para } s \neq k \end{cases} \quad (3.10)$$

La matriz de covarianza del ruido de medición se define como:

$$E \{ \nu(s) \nu(k)^T \} = \begin{cases} R(k) & \text{para } s = k \\ 0 & \text{para } s \neq k \end{cases} \quad (3.11)$$

El ruido del proceso no está correlacionado con el ruido de medición y $E\{\cdot\}$ es la esperanza o valor medio.

Para estimar el estado $w(k)$, se tiene el siguiente procedimiento

1. Inicialización para $k = 0$:

$$\begin{aligned} \hat{w}_0 &= E\{w_0\} \\ P_0 &= E\{(w_0 - E\{w_0\})(w_0 - E\{w_0\})^T\} \end{aligned}$$

donde w_0 es el valor inicial de $w(k)$.

2. Calculo para $k = 1, 2, \dots$, calcular:

- Propagación del estado estimado

$$\hat{w}^-(k) = F_{k,k-1} \hat{w}^-(k-1)$$

- Propagación de la covarianza del error

$$P^-(k) = F_{k,k-1}P(k-1)F_{k,k-1}^T + Q(k-1)$$

- Matriz de ganancia de Kalman

$$K(k) = P^-(k)H^T(k) \left[H(k)P^-(k)H^T(k) + R(k) \right]^{-1}$$

- Actualización del estado estimado

$$\hat{w}(k) = \hat{w}^-(k) + K(k)(y(k) - H(k)\hat{w}^-(k))$$

- Actualización de la covarianza del error

$$P(k) = (I - K(k)H(k))P^-(k)$$

3.3.2 Filtro de Kalman Extendido

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) [20].

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

$$w(k+1) = f(k, w(k)) + \mu(k) \quad (3.12)$$

$$y(k) = h(k, w(k)) + \nu(k) \quad (3.13)$$

con $w(k) \in \mathfrak{R}^n$ el vector de estado de sistema, $y(k) \in \mathfrak{R}^p$ la salida medible, con $\mu(k) \in \mathfrak{R}^n$ y $\nu(k) \in \mathfrak{R}^p$ ruidos independientes, gaussianos y matrices de covarianza $R(k)$ y $Q(k)$ respectivamente, $f(k, z(k))$ denota la función matricial no lineal de transmisión y $h(k, z(k))$ denota la función matricial de medición no lineal [20].

La idea del FKE consiste en linealizar el modelo en espacio de estados de las ecuaciones (3.12) y (3.13) a cada instante de tiempo alrededor del estado estimado más reciente [20].

Las matrices $F_{k+1,k}$ y $H(k)$ son calculadas de la siguiente manera

$$F_{k+1,k} = \frac{\partial f(k, w(k))}{\partial w} \quad (3.14)$$

$$H(k) = \frac{\partial h(k, w(k))}{\partial w} \quad (3.15)$$

y una vez que las matrices $F_{k+1,k}$ y $H(k)$ son evaluadas se aplican las ecuaciones del filtro de Kalman [20].

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 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 [20], [2], [4].

El objetivo de entrenamiento es encontrar los pesos óptimos que minimicen el error de predicción. El filtro de Kalman está descrito por

$$\begin{aligned} w_i(k+1) &= w_i(k) + \eta_i K_i(k) e_i(k) \\ K_i(k) &= P_i(k) H_i(k) M_i(k) \quad i = 1, \dots, n \\ P_i(k+1) &= P_i(k) - K_i(k) H_i^T(k) P_i(k) + Q_i(k) \end{aligned} \quad (3.16)$$

con

$$\begin{aligned} M_i(k) &= [R_i(k) + H_i^T(k) P_i(k) H_i(k)]^{-1} \\ e_i(k) &= x_i(k) - \chi_i(k) \end{aligned} \quad (3.17)$$

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 -th estado de la planta, $\chi_i(k)$ es el i -th estado de la red neuronal, $K_i(k) \in \mathfrak{R}^{L_i}$ es el vector de ganancias de Kalman, $Q_i \in \mathfrak{R}^{L_i \times L_i}$ es la matriz de covarianza del ruido de estimación, $R_i \in \mathfrak{R}$ 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

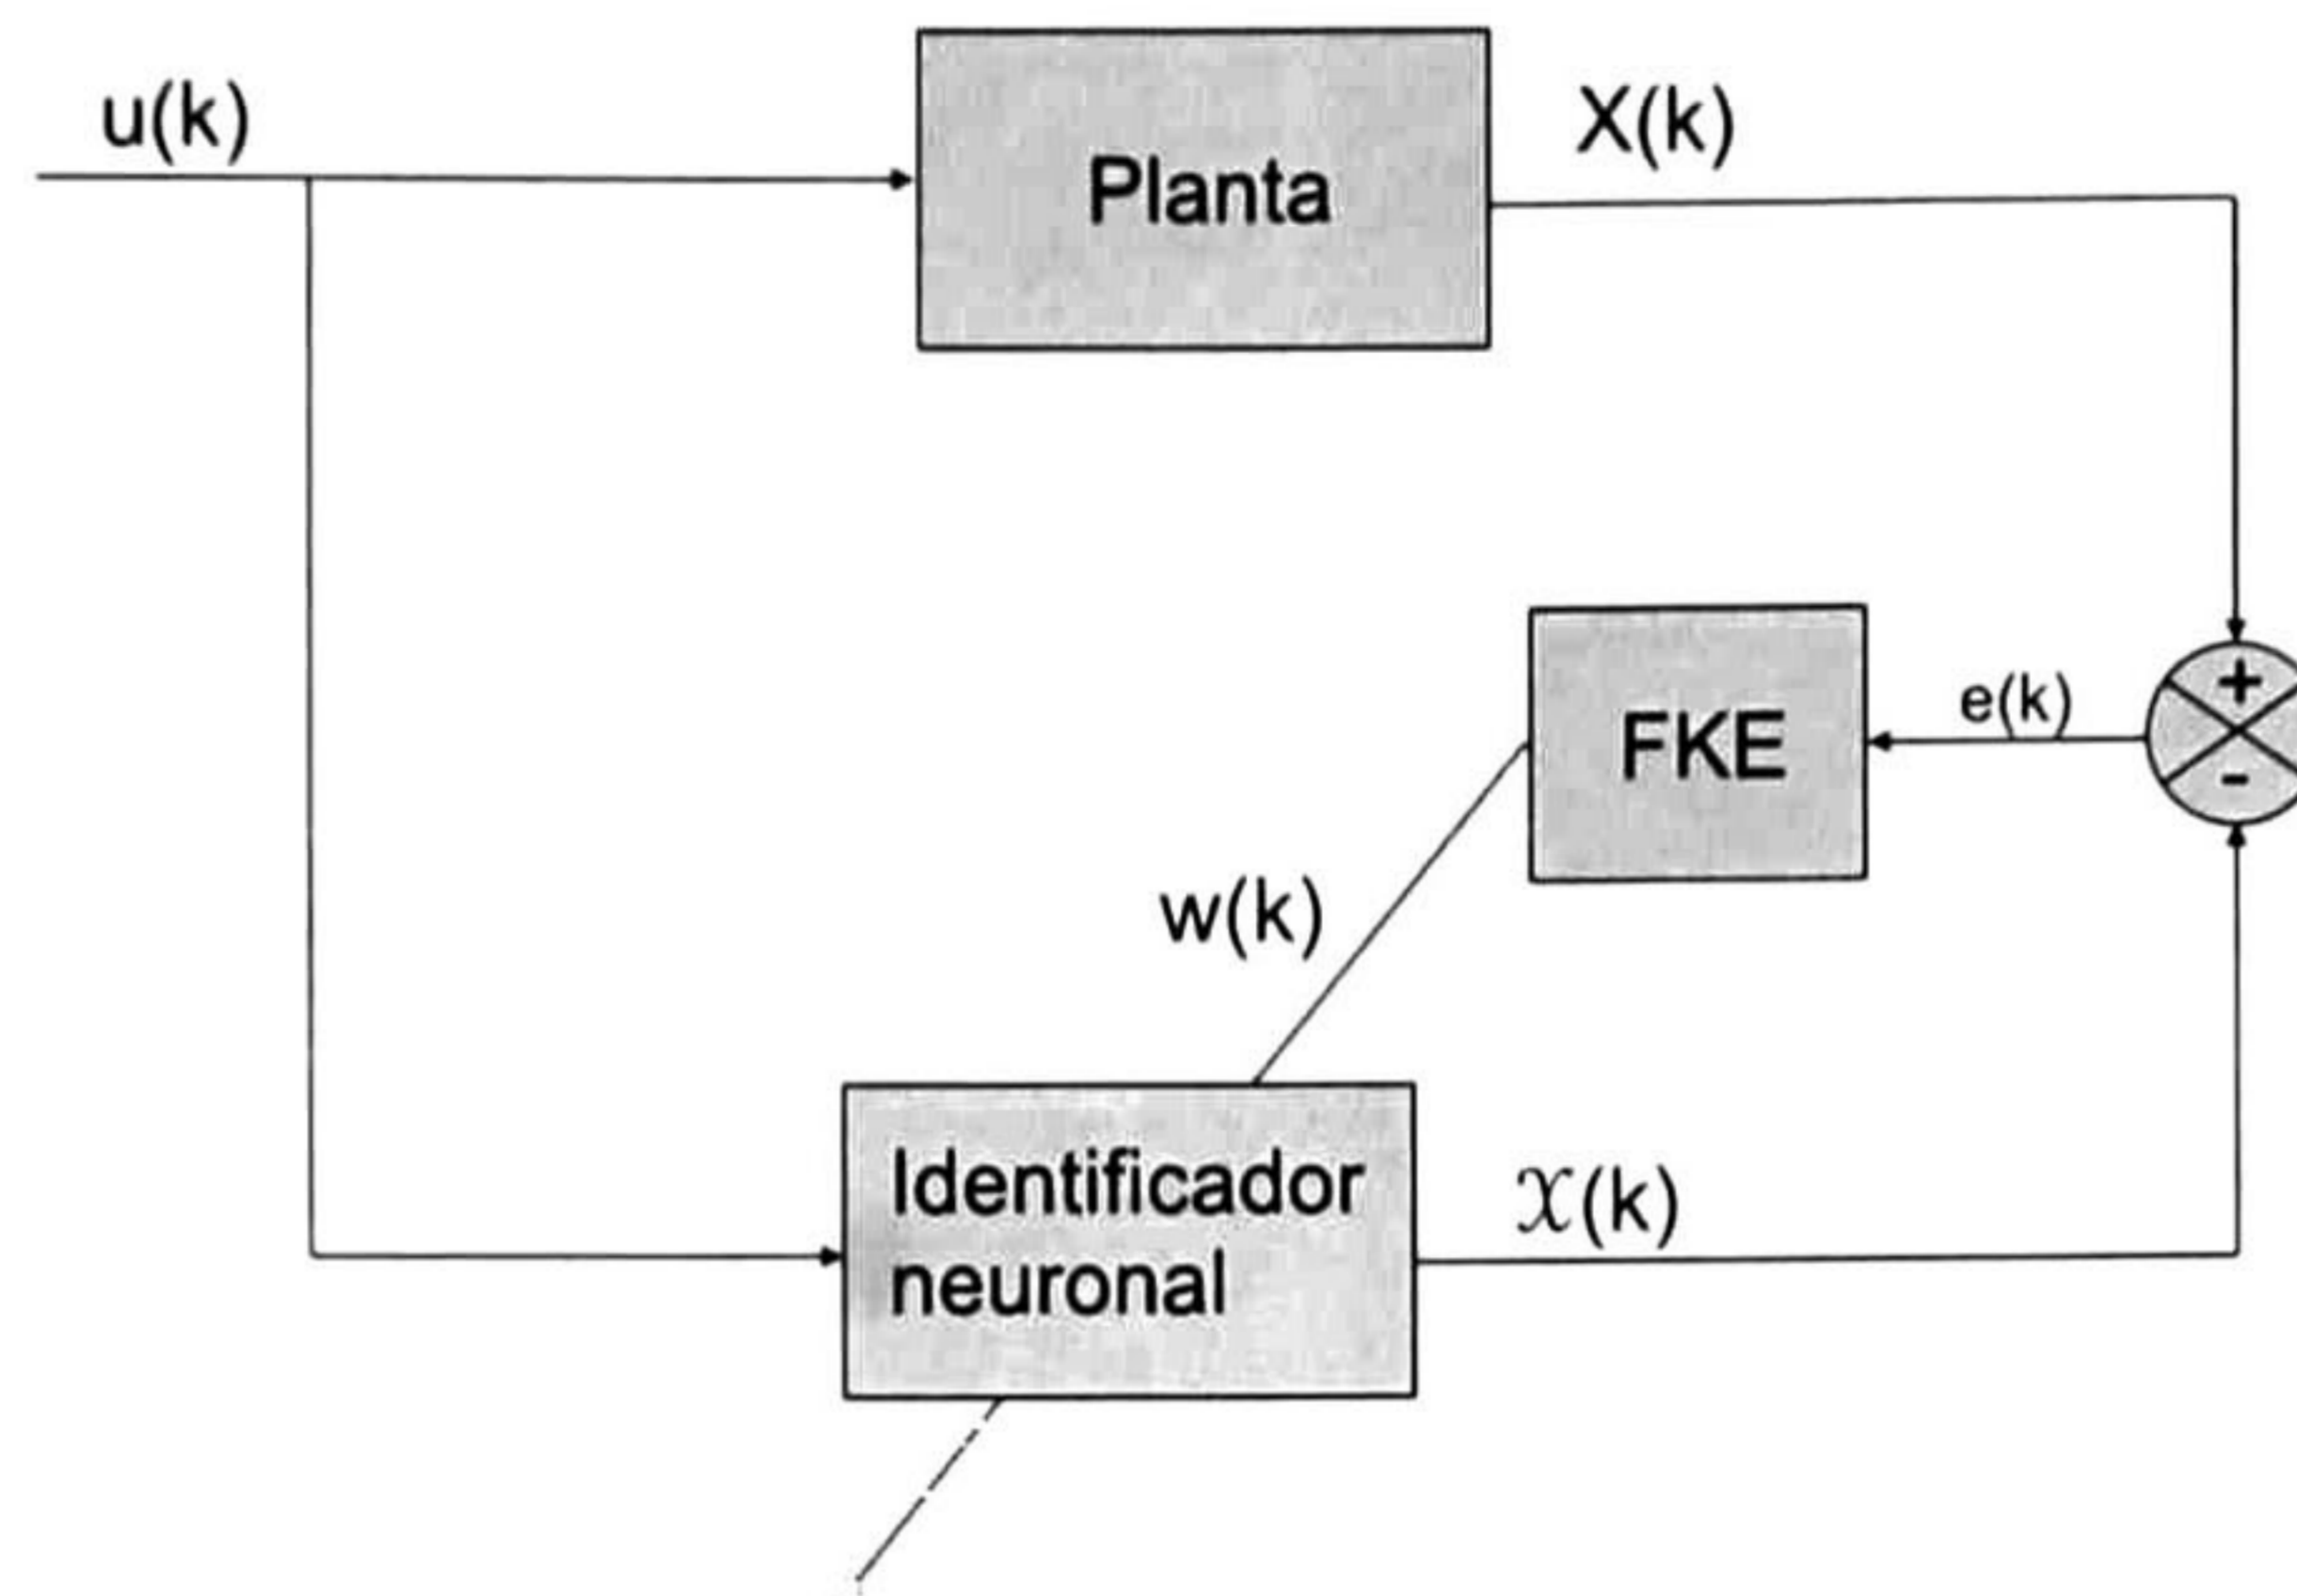


Fig. 3.3: Esquema de identificación

la red neuronal $\chi_i(k) \in \mathfrak{R}$, con respecto a los pesos de la red neuronal $w_{ij}(k)$, y está dado por:

$$H_{ij} = \left[\frac{\partial \chi_i(k)}{\partial w_{ij}(k)} \right]^T \quad (3.18)$$

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 $H_i(k)$, $K_i(k)$ y $P_i(k)$ para el FKE son acotados [18]; esto es, existen constantes $\bar{H} > 0$, $\bar{K} > 0$ y $\bar{P} > 0$ tales que:

$$\begin{aligned} \|H(k)\| &\leq \bar{H} \\ \|K(k)\| &\leq \bar{K} \\ \|P(k)\| &\leq \bar{P} \end{aligned} \quad (3.19)$$

La identificación entre la planta y la red neuronal se establece en el siguiente teorema (para detalles ver [3]).

Teorema 3.3.1 *La RHONN 3.6 entrenada con el filtro de Kalman extendido para identificar al sistema no lineal 3.4 asegura que el error de identificación 3.17 es semiglobalmente uniformemente ltimamente acotado (SGUUA), además, los pesos de la RHONN permanecen acotados.*

Capítulo 4

Ley de Control

El control por modos deslizantes es una poderosa herramienta para propósitos de control, esto debido a la robustez que presenta ante el cambio de perturbaciones, tanto externas como internas, por otro lado, en muchos problemas prácticos los controladores son implementados en tiempo discreto. Por tal motivo, en este capítulo se estudia el modo deslizante en tiempo discreto como estrategia de control.

4.1 Modos Deslizantes en Tiempo Discreto

El término modo deslizante surge en el contexto de sistemas de estructura variable. Un sistema de estructura consiste de un conjunto de subsistemas continuos con una acción de conmutación. La acción de control resultante es una función discontinua de los estados del sistema, perturbaciones y las referencias [23].

Las siguientes características determinan la naturaleza del modo deslizante [23]:

- El intervalo de tiempo entre el punto inicial $t = 0$ y cuando se alcanza la variedad deslizante $\sigma = \{x : s(x) = 0\}$ en $t = t_{sm}$ es finito, a diferencia de los sistemas con ley de control continuo, los cuales exhiben convergencia asintótica a cualquier variedad consistente de trayectorias de estado.
- Una vez que el sistema se encuentra en el modo deslizante $\forall t \geq t_{sm}$ su trayec-

toría es restringida a la variedad $\sigma = \{x : s(x) = 0\}$ y el orden del sistema en lazo cerrado es menor que el orden del sistema no controlado.

- Después de que el sistema se encuentra en el modo deslizante y este se inicia en un tiempo t_{sm} la trayectoria del sistema no puede dar marcha atrás más allá de la variedad $\sigma = \{x : s(x) = 0\}$. En otras palabras, en cualquier punto $t_0 \geq t_{sm}$, no es posible determinar el tiempo t_{sm} o calcular la trayectoria para un tiempo $t_0 < t_{sm}$ basado en la información del sistema al tiempo t_0 .

Sin embargo, durante los intervalos de tiempo, antes y después de alcanzar el modo deslizante, las trayectorias de estado son funciones continuas del tiempo y la relación entre dos valores del estado en un intervalo $t = [t_0, t_0 + \Delta t]$ puede ser encontrado resolviendo

$$\dot{x} = f(x, u, t) \quad (4.1)$$

como

$$x(t_0 + \Delta t) = F(x(t_0)) \quad (4.2)$$

donde $F(x(t))$ es una función continua. Cuando se desarrolla a la ecuación (4.2) para cada punto de muestreo $t = k\Delta t$, $k = 1, 2, \dots$ se convierte en la representación en tiempo discreto del sistema en tiempo continuo (4.1), es decir,

$$x(k+1) = F(x(k)), \quad x(k) = x(k\Delta t) \quad (4.3)$$

A partir del tiempo t_{sm} , la trayectoria de estado permanece en la variedad deslizante con $s(x(t)) = 0$, para algún $k_{sm} \geq \frac{t_{sm}}{\Delta t}$,

$$s(x(k)) = 0 \quad (\forall k \geq k_{sm}) \quad (4.4)$$

A este movimiento se le llama modo deslizante en tiempo discreto [23].

Se supone que para cualquier entrada de control constante u y cualquier condición inicial $x(0)$ la solución del sistema puede ser determinada en forma cerrada [23]; es decir

$$x(t) = F(x(0), u) \quad (4.5)$$

Con la ayuda de (4.5), se tiene el siguiente procedimiento:

1. Al tiempo $t = 0$ seleccione el control constante $u(x(t = 0), \Delta t)$ para un intervalo de tiempo dado Δt tal que $s(x(t = \Delta t)) = 0$.
2. Al tiempo $t = \Delta t$ seleccione el control constante $u(x(t = \Delta t), \Delta t)$ tal que $s(x(t = 2\Delta t)) = 0$.
3. En general, para cada $k = 0, 1, 2, \dots$, al tiempo $t = k\Delta t$ seleccione el control constante $u(x(k), \Delta t)$ tal que $s(x(k + 1)) = 0$.

Es decir, en cada punto de muestreo k , seleccione $u(k)$, tal que, esta entrada de control es constante durante el siguiente instante de muestreo Δt , y alcanzará $s(x(k + 1)) = 0$ en el siguiente muestreo $k + 1$. Durante el intervalo de muestreo, el estado $x(k\Delta t < t < (k + 1)\Delta t)$ puede no pertenecer a la variedad, es decir $s(x(t)) \neq 0$ para $k\Delta t < t < (k + 1)\Delta t$. Sin embargo, el sistema en tiempo discreto

$$\begin{aligned} x(k + 1) &= F(x(k), u(k)) \\ u(k) &= u(x(k)) \end{aligned} \quad (4.6)$$

llega a la variedad deslizante en cada punto de muestreo; es decir, $s(x(k + 1)) = 0 \quad \forall k = 0, 1, \dots$, se satisface. Así la variedad es alcanzada en tiempo finito $t_{sm} = k_{sm}\Delta t$ y permanece ahí. En analogía con el caso continuo, este movimiento es llamado modo deslizante en tiempo discreto [23].

La ley de control del modo deslizante en tiempo discreto toma la siguiente forma

$$u(k) = \begin{cases} u_{eq}(k) & \text{si } \|u_{eq}(k)\| \leq u_{max} \\ u_{max} \frac{u_{eq}(k)}{\|u_{eq}(k)\|} & \text{si } \|u_{eq}(k)\| > u_{max} \end{cases} \quad (4.7)$$

4.2 Control Neuronal por Bloques

Considere un sistema no lineal perturbado MIMO (por sus siglas en inglés, *Multiple Input Multiple Output*)

$$\begin{aligned} x(k+1) &= F(x(k), u(k), k) + d(w(k)) \\ y(k) &= h(x(k)) \end{aligned} \quad (4.8)$$

donde $k \in Z$ denota el tiempo discreto, con Z el conjunto de enteros positivos, $x(k) \in \mathbb{R}^n$ es el vector de estado del sistema, $u(k) \in \mathbb{R}^m$ es el vector de entradas, $y(k) \in \mathbb{R}^p$ es el vector de salidas. $F(\cdot, \cdot, \cdot)$, $h(\cdot)$ y $d(\cdot)$ son campos vectores suaves, con $f(0, 0, 0) = 0$, $h(0) = 0$, $d(w(k))$ es un término de perturbación que representa, errores de modelado, desgaste y perturbaciones, etc.

Cada elemento del vector de estado $x(k)$ del sistema (4.8) es aproximado por la red neuronal (3.6). Se tiene el siguiente modelo neuronal

$$\begin{aligned} \hat{\chi}_1(k+1) &= \sum_{\rho=1}^{L'_1} w'_{1\rho} z'_{1\rho}(\bar{x}_1(k)) + \sum_{\gamma=L'_1+1}^{L_1} w''_{1\gamma} z''_{1\gamma}(\bar{x}_2(k)) \\ \hat{\chi}_2(k+1) &= \sum_{\rho=1}^{L'_2} w'_{2\rho} z'_{2\rho}(\bar{x}_2(k)) + \sum_{\gamma=L'_2+1}^{L_2} w''_{2\gamma} z''_{2\gamma}(\bar{x}_3(k)) \\ &\vdots \\ \hat{\chi}_i(k+1) &= \sum_{\rho=1}^{L'_i} w'_{i\rho} z'_{i\rho}(\bar{x}_i(k)) + \sum_{\gamma=L'_i+1}^{L_i} w''_{i\gamma} z''_{i\gamma}(\bar{x}_{i+1}(k)) \\ \hat{\chi}_{n-m+1}(k+1) &= \sum_{\rho=1}^{L'_{n-m+1}} w'_{n-m+1\rho} z'_{n-m+1\rho}(x(k)) + w_1 u_1(k) \\ &\vdots \\ \hat{\chi}_n(k+1) &= \sum_{\rho=1}^{L'_n} w'_{n\rho} z'_{n\rho}(x(k)) + w_m u_m(k) \\ i &= 3, \dots, n-m \\ \bar{x}_j &= [x_1 \ \dots \ x_j]^T \quad j = 1, \dots, n-m \end{aligned} \quad (4.9)$$

donde $\hat{\chi}(k) = [\hat{\chi}_1(k), \dots, \hat{\chi}_n(k)]^T$, n es el número de estados de la planta (4.8), m es el número de entradas, $u_1(k), \dots, u_m(k)$ son las entradas de control, $\chi_i(k) \in \mathfrak{R}$ ($i = 1, \dots, n$) es el i -ésimo estado de la red neuronal, $w'_{i\rho} \in \mathfrak{R}^{L'_i}$ es el vector de pesos adaptados en línea por (3.16), $z'_i(\bar{x}_i(k))$ está definido como en (3.7), $x(k)$ es el vector de estados de la planta, $w''_{i\gamma}$ y w_1, \dots, w_m son pesos considerados constantes, y $z''_i(\bar{x}_i(k))$ son funciones no necesariamente sigmoideas.

4.2.1 Forma controlable por bloques

Debido a que el control está basado en el modelo identificado, introducimos las siguientes suposiciones:

A1) El grado relativo es r ;

A2) Existe una transformación difeomórfica $\chi = \phi(\hat{\chi}(k))$ tal que el sistema (4.9) se representa en la forma controlable por bloques con una dinámica interna:

$$\begin{aligned}
 \chi^1(k+1) &= F'_1(\bar{X}^2(k), W_1(k)) + W'_1 Z'_1(X^1(k))X^2(k) \\
 \chi^2(k+1) &= F'_2(\bar{X}^3(k), W_2(k)) + W'_2 Z'_2(\bar{X}^2(k))X^3(k) \\
 &\vdots \\
 \chi^i(k+1) &= F'_i(\bar{X}^{i+1}(k), W_i(k)) + W'_i Z'_i(\bar{X}^i(k))X^{i+1}(k) \\
 \chi^r(k+1) &= F'_r(X(k), W_r(k)) + W'_r u(k) \\
 \chi^{r+1}(k+1) &= F'_{r+1}(\bar{X}^r(k), X^{r+1}(k)) \\
 &\quad (i = 3, \dots, r-1) \\
 y^1(k) &= \chi^1(k) \\
 \bar{X}^i(k) &= [X^1(k) \cdots X^i(k)]^T
 \end{aligned} \tag{4.10}$$

donde $\chi^i(k) \in \mathfrak{R}^{n_i}$ ($i = 1, \dots, r$), $\chi^{r+1}(k) \in \mathfrak{R}^{n-(r \times m)}$, $\chi = (\chi^1(k), \dots, \chi^r(k), \chi^{r+1}(k))^T$ es vector del estado de la red neuronal, $X^i(k) \in \mathfrak{R}^{n_i}$ son vectores de estados de la planta, $X^{i+1}(k)$ son cuasicontrolos para la red neuronal, $u(k) = [u_1(k) \cdots u_m(k)]^T$ es el vector de entradas de control, $W_i(k)$ son matrices de pesos adaptados en línea, W'_i son matrices de pesos constantes, $Z'_i(X^i(k))$ son

matrices de funciones no necesariamente sigmoidales, $y^1(k)$ la salida a ser controlada.

Consideremos el caso típico: $n_1 = n_2 = \dots = n_r = m$, entonces $\sum_{i=1}^n n_i = r \times m$.

A3) El punto de equilibrio de la dinámica cero

$$\chi^{r+1}(k+1) = F_{r+1}(0, \chi^{r+1}(k), k) \quad (4.11)$$

es asintóticamente estable.

Para el sistema (4.10) las siguientes suposiciones son consideradas:

B1) Las matrices $G_i(k)$ $i = 1, \dots, r-1$ y W_r' , son acotadas en norma

$$\|G_i(k)\| \leq \beta_i, \quad \|W_r'(k)\| \leq \beta_r$$

y existe la inversa $(G_i(k))^{-1}$ con

$$\|G_i^{-1}(k)\| \leq \beta_i^-, \quad \|W_r'^{-1}(k)\| \leq \beta_r^-$$

donde $G_i(k) = W_i' Z_i' (\bar{X}^i(k))$ $i = 1, \dots, r-1$ y para constantes $\beta_i, \beta_i^- > 0$.

Como otra suposición se encuentra la amplitud de la ley de control. Se requiere que el control sea capaz de asegurar el seguimiento de la referencia deseada.

B2) El valor máximo de la ley de control es tal que

$$u_{max} > \delta_r \beta_r^-$$

donde $\delta_r > 0$ se definirá mas adelante.

B3) La señal de referencia $y_{ref}(w(k))$ y la perturbación $d(w(k))$ se suponen acotadas y generadas por un sistema externo descrito por:

$$\begin{aligned} w(k+1) &= s(w(k)), & w(k) &\in \mathfrak{R}^s \\ y_{ref}(k) &= y_{ref}(w(k)) \\ d(k) &= d(w(k)). \end{aligned} \quad (4.12)$$

B4) Debido a que el error de identificación es últimamente acotado, entonces existe una función acotada $\|\eta_i(k)\| \leq \eta_i$ tal que

$$X^i(k) = \chi^i(k) + \eta_i(k). \quad (4.13)$$

4.2.2 Linealización por transformación

Se define la siguiente variable de error de seguimiento tomando en cuenta (4.13)

$$\begin{aligned} e^1(k) &= X^1(k) - y_{ref}(k) \\ &= \chi^1(k) - y_{ref}(k) + \eta_1(k) \end{aligned} \quad (4.14)$$

con $y_{ref}(k)$ la señal de referencia para la salida $y^1(k) = X^1(k)$.

Tomando un paso adelante en (4.14) tenemos

$$e^1(k+1) = F'_1(\bar{X}^2(k), W_1(k)) + W'_1 Z'_1(X^1(k))X^2(k) - x_{ref}(k+1) + \eta_1(k+1). \quad (4.15)$$

En la ecuación (4.15), $X^2(k)$ es vista como una entrada de cuasicontrol, tal que se tenga la siguiente dinámica

$$e^1(k+1) = K_1 e^1(k) + \eta_1(k+1) \quad (4.16)$$

donde la matriz K_1 en (4.16), es Schur, esto es, tiene valores propios dentro del círculo unitario para asegurar estabilidad asintótica.

Se determina la solución de $X^2(k)$ para la ecuación (4.15) tal que se satisfaga (4.16) y está dada por

$$X^2_{des}(k) = (W'_1 Z'_1(X^1(k)))^{-1} (-F'_1(\bar{X}^2(k), W_1(k)) + x_{ref}(k+1) + K_1 e^1(k))$$

el cual representa el comportamiento de la referencia para $X^2(k)$.

De la misma manera se introduce un nuevo error tomando en cuenta (4.13)

$$\begin{aligned} e^2(k) &= X^2(k) - X_{des}^2(k) \\ &= \chi^2(k) - X_{des}^2(k) + \eta_2(k) \end{aligned}$$

cuya dinámica es

$$e^2(k+1) = F_2'(\bar{X}^3(k), W_2(k)) + W_2'Z_2'(\bar{X}^2(k))X^3(k) - X_{des}^2(k+1) + \eta_2(k+1). \quad (4.17)$$

El vector $X^3(k)$ en (4.17) es vista como una entrada de cuasicontrol, se determina su solución tal que se tenga la siguiente dinámica deseada

$$e^2(k+1) = K_2 e^2(k) + \eta_2(k+1) \quad (4.18)$$

donde K_2 es una matriz Schur.

Usando (4.17) y (4.18) el valor deseado de $X^3(k)$ es calculado como

$$X_{des}^3(k) = (W_2'Z_2'(\bar{X}^2(k)))^{-1}(-F_2'(\bar{X}^3(k), W_2(k)) + X_{des}^2(k+1) + K_2 e^2(k))$$

para definir el siguiente error

$$\begin{aligned} e^3(k) &= X^3(k) - X_{des}^3(k) \\ &= \chi^3(k) - X_{des}^3(k) + \eta_3(k) \end{aligned}$$

Siguiendo este mismo procedimiento, se introduce finalmente la variable

$$\begin{aligned} e^r(k) &= X^r(k) - X_{des}^r(k) \\ &= \chi^r(k) - X_{des}^r(k) + \eta_r(k) \end{aligned} \quad (4.19)$$

con

$$\begin{aligned} X_{des}^r(k) &= -(W_{r-1}'Z_{r-1}'(\bar{X}^{r-1}(k)))^{-1}(F_{r-1}'(\bar{X}^r(k), W_{r-1}(k))) \\ &\quad + (W_{r-1}'Z_{r-1}'(\bar{X}^{r-1}(k)))^{-1}(X_{des}^{r-1}(k+1) + K_{r-1}e^{r-1}(k)). \end{aligned}$$

Tomando un paso adelante en (4.19) se tiene

$$e^r(k+1) = F'_r(X(k), W_r(k)) + W'_r u(k) - X_{des}^r(k+1) + \eta_r(k+1). \quad (4.20)$$

Del procedimiento anterior el sistema (4.10) se puede representar en las nuevas variables $e^1(k), e^2(k), \dots, e^r(k)$ como

$$\begin{aligned} e^1(k+1) &= K_1 e^1(k) + G_1(k) e^2(k) + \eta_1(k+1) \\ e^2(k+1) &= K_2 e^2(k) + G_2(k) e^3(k) + \eta_2(k+1) \\ &\vdots \\ e^{r-1}(k+1) &= K_{r-1} e^{r-1}(k) + G_{r-1}(k) e^r(k) + \eta_{r-1}(k+1) \\ e^r(k+1) &= F'_r(X(k), W_r(k)) + W'_r u(k) - X_{des}^r(k+1) + \eta_r(k+1) \\ \chi^{r+1}(k+1) &= F_{r+1}(\bar{e}^r(k), \chi^{r+1}(k), k) \end{aligned} \quad (4.21)$$

donde $\bar{e}^r(k) = [e^1(k), \dots, e^r(k)]^T$, $G_i(k) = W'_i Z'_i(\bar{X}^i(k))$ $i = 1, \dots, r-1$.

4.2.3 Modos Deslizantes en Tiempo Discreto

Se diseña un controlador con modos deslizantes para el sistema (4.21), el cual garantice seguimiento de la referencia $y_r(w(k))$ y rechazo de la perturbación $d(w(k))$, a pesar de la limitante sobre el control

$$\|u(k)\| \leq u_{max} \quad (4.22)$$

donde el valor máximo u_{max} satisface la suposición B2.

Como sucede en la técnica de control por bloques [23], el control fuerza a la evolución del sistema a una superficie, la cual garantiza que se satisfacen los objetivos de control.

Escogiendo $S(k) = e^r(k) = 0$ como la superficie deslizante, el r -ésimo bloque de (4.21), puede ser reescrito como

$$S(k+1) = F'_r(X(k), W_r(k)) + W'_r u(k) - X_{des}^r(k+1) + \eta_r(k+1). \quad (4.23)$$

El siguiente paso es elegir una ley de control que nos lleve a dicha superficie; tal control es:

$$u(k) = \begin{cases} u_{eq}(k) & \text{si } \|u_{eq}(k)\| \leq u_{max} \\ u_{max} \frac{u_{eq}(k)}{\|u_{eq}(k)\|} & \text{si } \|u_{eq}(k)\| > u_{max} \end{cases} \quad (4.24)$$

donde el control equivalente $u_{eq}(k)$ es calculado como una solución de la ecuación $S(k+1) = 0$ en (4.23) sin el término de perturbación $\eta_r(k+1)$, esto es

$$u_{eq}(k) = W_r'^{-1} (-F_r'(X(k), W_r(k)) + X_{des}^r(k+1)). \quad (4.25)$$

Para análisis de estabilidad del sistema en lazo cerrado, se reescriben las ecuaciones (4.23) y (4.25) como [23]:

$$\begin{aligned} S(k+1) &= S(k) + \bar{f}_s + W_r' u(k) \\ u_{eq}(k) &= -W_r'^{-1} (S(k) + \bar{f}_s) \end{aligned} \quad (4.26)$$

donde

$$\bar{f}_s = F_r'(X(k), W_r(k)) - X_{des}^r(k+1) - e^r(k). \quad (4.27)$$

De (4.26) y B1 se sigue que

$$\|u_{eq}\| \leq \beta_r^- \|S(k) + \bar{f}_s\| \quad (4.28)$$

donde \bar{f}_s está acotado para

$$\|\bar{f}_s\| \leq \delta_r, \quad \delta_r > 0. \quad (4.29)$$

Ahora, considere los casos en (4.24). Cuando $\|u_{eq}(k)\| \leq u_{max}$, el control $u_{eq}(k)$ es aplicado, llevando la trayectoria del sistema a la variedad deslizante $S(k) = 0$ en un paso. Cuando $\|u_{eq}(k)\| > u_{max}$, tenemos

$$\begin{aligned} S(k+1) &= S(k) + \bar{f}_s + W_r' u_{max} \frac{u_{eq}(k)}{\|u_{eq}(k)\|} \\ &= (S(k) + \bar{f}_s) \left(1 - \frac{u_{max}}{\|u_{eq}(k)\|} \right) \end{aligned} \quad (4.30)$$

A lo largo de la solución de (4.30), el incremento de la función de Lyapunov $V(k) = \|S(k)\|$ está dado por

$$\begin{aligned}\Delta V &= \|S(k+1)\| - \|S(k)\| \\ &= \|S(k) + \bar{f}_s\| \left(1 - \frac{u_{max}}{\|u_{eq}(k)\|}\right) - \|S(k)\| \\ &\leq \left(\|S(k) + \bar{f}_s\| - \frac{u_{max}}{\|W_r'^{-1}\|}\right) - \|S(k)\|.\end{aligned}\quad (4.31)$$

De las suposiciones B1 y B2 y de la ecuación (4.29) se sigue que

$$\|S(k) + \bar{f}_s\| - \frac{u_{max}}{\|W_r'^{-1}\|} \leq \|S(k)\| + \delta_r - \frac{u_{max}}{\|W_r'^{-1}\|} < \|S(k)\| \quad (4.32)$$

entonces $\Delta V < 0$ y $\|S(k)\|$ decrece monotónicamente. También $\|u_{eq}(k)\|$ decrece monotónicamente, ya que de (4.28) y (4.29)

$$\|u_{eq}(k)\| \leq \beta_r^- (\|S(k)\| + \delta_r) \quad (4.33)$$

y habrá un instante de tiempo \bar{k} tal que $\|u_{eq}(k)\| \leq u_{max}$, para $k \geq \bar{k}$. En este tiempo el control equivalente $\|u_{eq}(k)\|$ es aplicado, llevando a la trayectoria del sistema a la variedad deslizante $S(k) = 0$ al tiempo $\bar{k} + 1$.

La dinámica de modos deslizantes es descrito por un sistema reducido de orden $(n - n_r)^{th}$:

$$\begin{aligned}e^1(k+1) &= K_1 e^1(k) + G_1(k) e^2(k) + \eta_1(k+1) \\ e^2(k+1) &= K_2 e^2(k) + G_2(k) e^3(k) + \eta_2(k+1) \\ &\vdots\end{aligned}\quad (4.34)$$

$$\begin{aligned}e^{r-1}(k+1) &= K_{r-1} e^{r-1}(k) + \eta_{r-1}(k+1) \\ \chi^{r+1}(k+1) &= F_{r+1}(\bar{e}, \chi^{r+1}, k)\end{aligned}\quad (4.35)$$

donde K_i ($i = 1, \dots, r-1$) es Schur y $e(k) = [e^1(k), \dots, e^{r-1}(k)]^T$

Expresando el sistema (4.34) de la siguiente forma

$$e(k+1) = Ke(k) + G(k)e(k) + \eta(k) \quad (4.36)$$

donde

$$\begin{aligned} K &= \text{diag}\{K_1, \dots, K_{r-1}\} \\ G(k) &= \text{diag}\{G_1(k), \dots, G_{r-1}(k), 0\} \\ \eta(k) &= [\eta_1(k+1), \dots, \eta_{r-1}(k+1)]^T \end{aligned}$$

definimos la siguiente función de Lyapunov

$$V(k) = e^T(k)Pe(k) \quad (4.37)$$

donde P es una matriz simétrica y definida positiva, y satisface la siguiente función de Lyapunov:

$$K^T P K - P = -Q, \quad Q > 0, \quad Q = Q^T \quad (4.38)$$

Entonces, usando (4.36) y (4.37), se tiene

$$\begin{aligned} \Delta V(k) &= V(k+1) - V(k) \\ &= e^T(k+1)Pe(k+1) - e^T(k)Pe(k) \\ &= (e^T(k)K^T + e^T(k)G^T(k) + \eta^T(k)) P (Ke(k) + G(k)e(k) + \eta(k)) \\ &\quad - e^T(k)Pe(k) \\ &= e^T(k)K^T P K e(k) + e^T(k)K^T P G(k)e(k) + e^T(k)K^T P \eta(k) \\ &\quad + e^T(k)G^T(k) P K e(k) + e^T(k)G^T(k) P G(k)e(k) + e^T(k)G^T(k) P \eta(k) \\ &\quad + \eta^T(k) P K e(k) + \eta^T(k) P G(k)e(k) + \eta^T(k) P \eta(k) - e^T(k)Pe(k) \end{aligned}$$

y usando (4.38) se obtiene

$$\begin{aligned} \Delta V(k) &= -e^T(k)Qe(k) + e^T(k)D_1e(k) + e^T(k)D_2\eta(k) + \eta(k)^T D_3\eta(k) \\ &\leq -\alpha_{\min}(Q)\|e(k)\|^2 + \|D_1(k)\|\|e(k)\|^2 \\ &\quad + \|D_2(k)\|\|\eta(k)\|\|e(k)\| + \|D_3\|\|\eta(k)\|^2 \end{aligned} \quad (4.39)$$

donde

$$\begin{aligned} D_1(k) &= 2K^T P G(k) + G(k)^T P G(k) \\ D_2(k) &= 2(K^T + G(k)^T) P \\ D_3 &= P. \end{aligned}$$

Se introduce la siguiente acotación:

$$\|e(k)\| > \gamma \|\eta(k)\|, \quad \gamma > 0. \quad (4.40)$$

Ahora usando (4.40) en (4.39) se tiene

$$\begin{aligned} \Delta V(k) &\leq -\alpha_{\min}(Q) \|e(k)\|^2 + (\|D_1(k)\| + \gamma \|D_2(k)\| + \gamma^2 \|D_3\|) \|e(k)\|^2 \\ &= -(\alpha_{\min}(Q) - \|D_1(k)\| - \gamma \|D_2(k)\| - \gamma^2 \|D_3\|) \|e(k)\|^2 \end{aligned}$$

Entonces si

$$\|D_1(k)\| + \gamma \|D_2(k)\| + \gamma^2 \|D_3\| < \alpha_{\min}(Q) \quad (4.41)$$

$\Delta V(k)$ es negativa afuera de la acotación (4.40). por lo tanto existe k_1 , tal que $\forall k > k_1$ con

$$\|e(k)\| \leq \delta, \quad \delta = \gamma \|\eta(k)\| \quad (4.42)$$

Los resultados anteriores se presentan en el siguiente teorema:

Teorema 4.2.1 *Supongamos que se satisfacen las suposiciones A1-A3, B1-B4 y las condiciones (4.40), (4.41), entonces una solución del sistema en lazo cerrado (4.21), (4.24), (4.25) es ultimamente acotado, por (4.41) y (4.42).*

Para asegurar que la salida de la planta sigue la trayectoria deseada, con el control basado en la red neuronal se tiene el siguiente resultado [17]

Dada una trayectoria deseada $y_r(w(k))$, un sistema dinámico con salida $y(k)$ a ser controlada, y una red neuronal con salida $y^1(k)$, entonces es posible establecer la

siguiente desigualdad

$$\|y(k) - y_r(w(k))\| \leq \|y(k) - y^1(k)\| + \|y^1(k) - y_r(w(k))\| \quad (4.43)$$

donde $y(k) - y_r(w(k))$ es el error de seguimiento entre la salida de la planta y la referencia deseada, $y(k) - y^1(k)$ es el error de identificación entre la salida de la planta y la red neuronal, $y^1(k) - y_r(w(k))$ es el error de seguimiento entre la red neuronal y la referencia.

Basados de esto es posible, es posible dividir el error de seguimiento en dos partes [17]:

1. Minimización de $y(k) - y^1(k)$, el cual se satisface con el algoritmo de identificación en línea (3.16), y el teorema 3.3.1
2. Minimización de $y^1(k) - y_r(w(k))$, el cual se satisface por medio de una ley de control basado en la red neuronal.

La Fig. 4.1 ilustra un esquema de identificación y control.

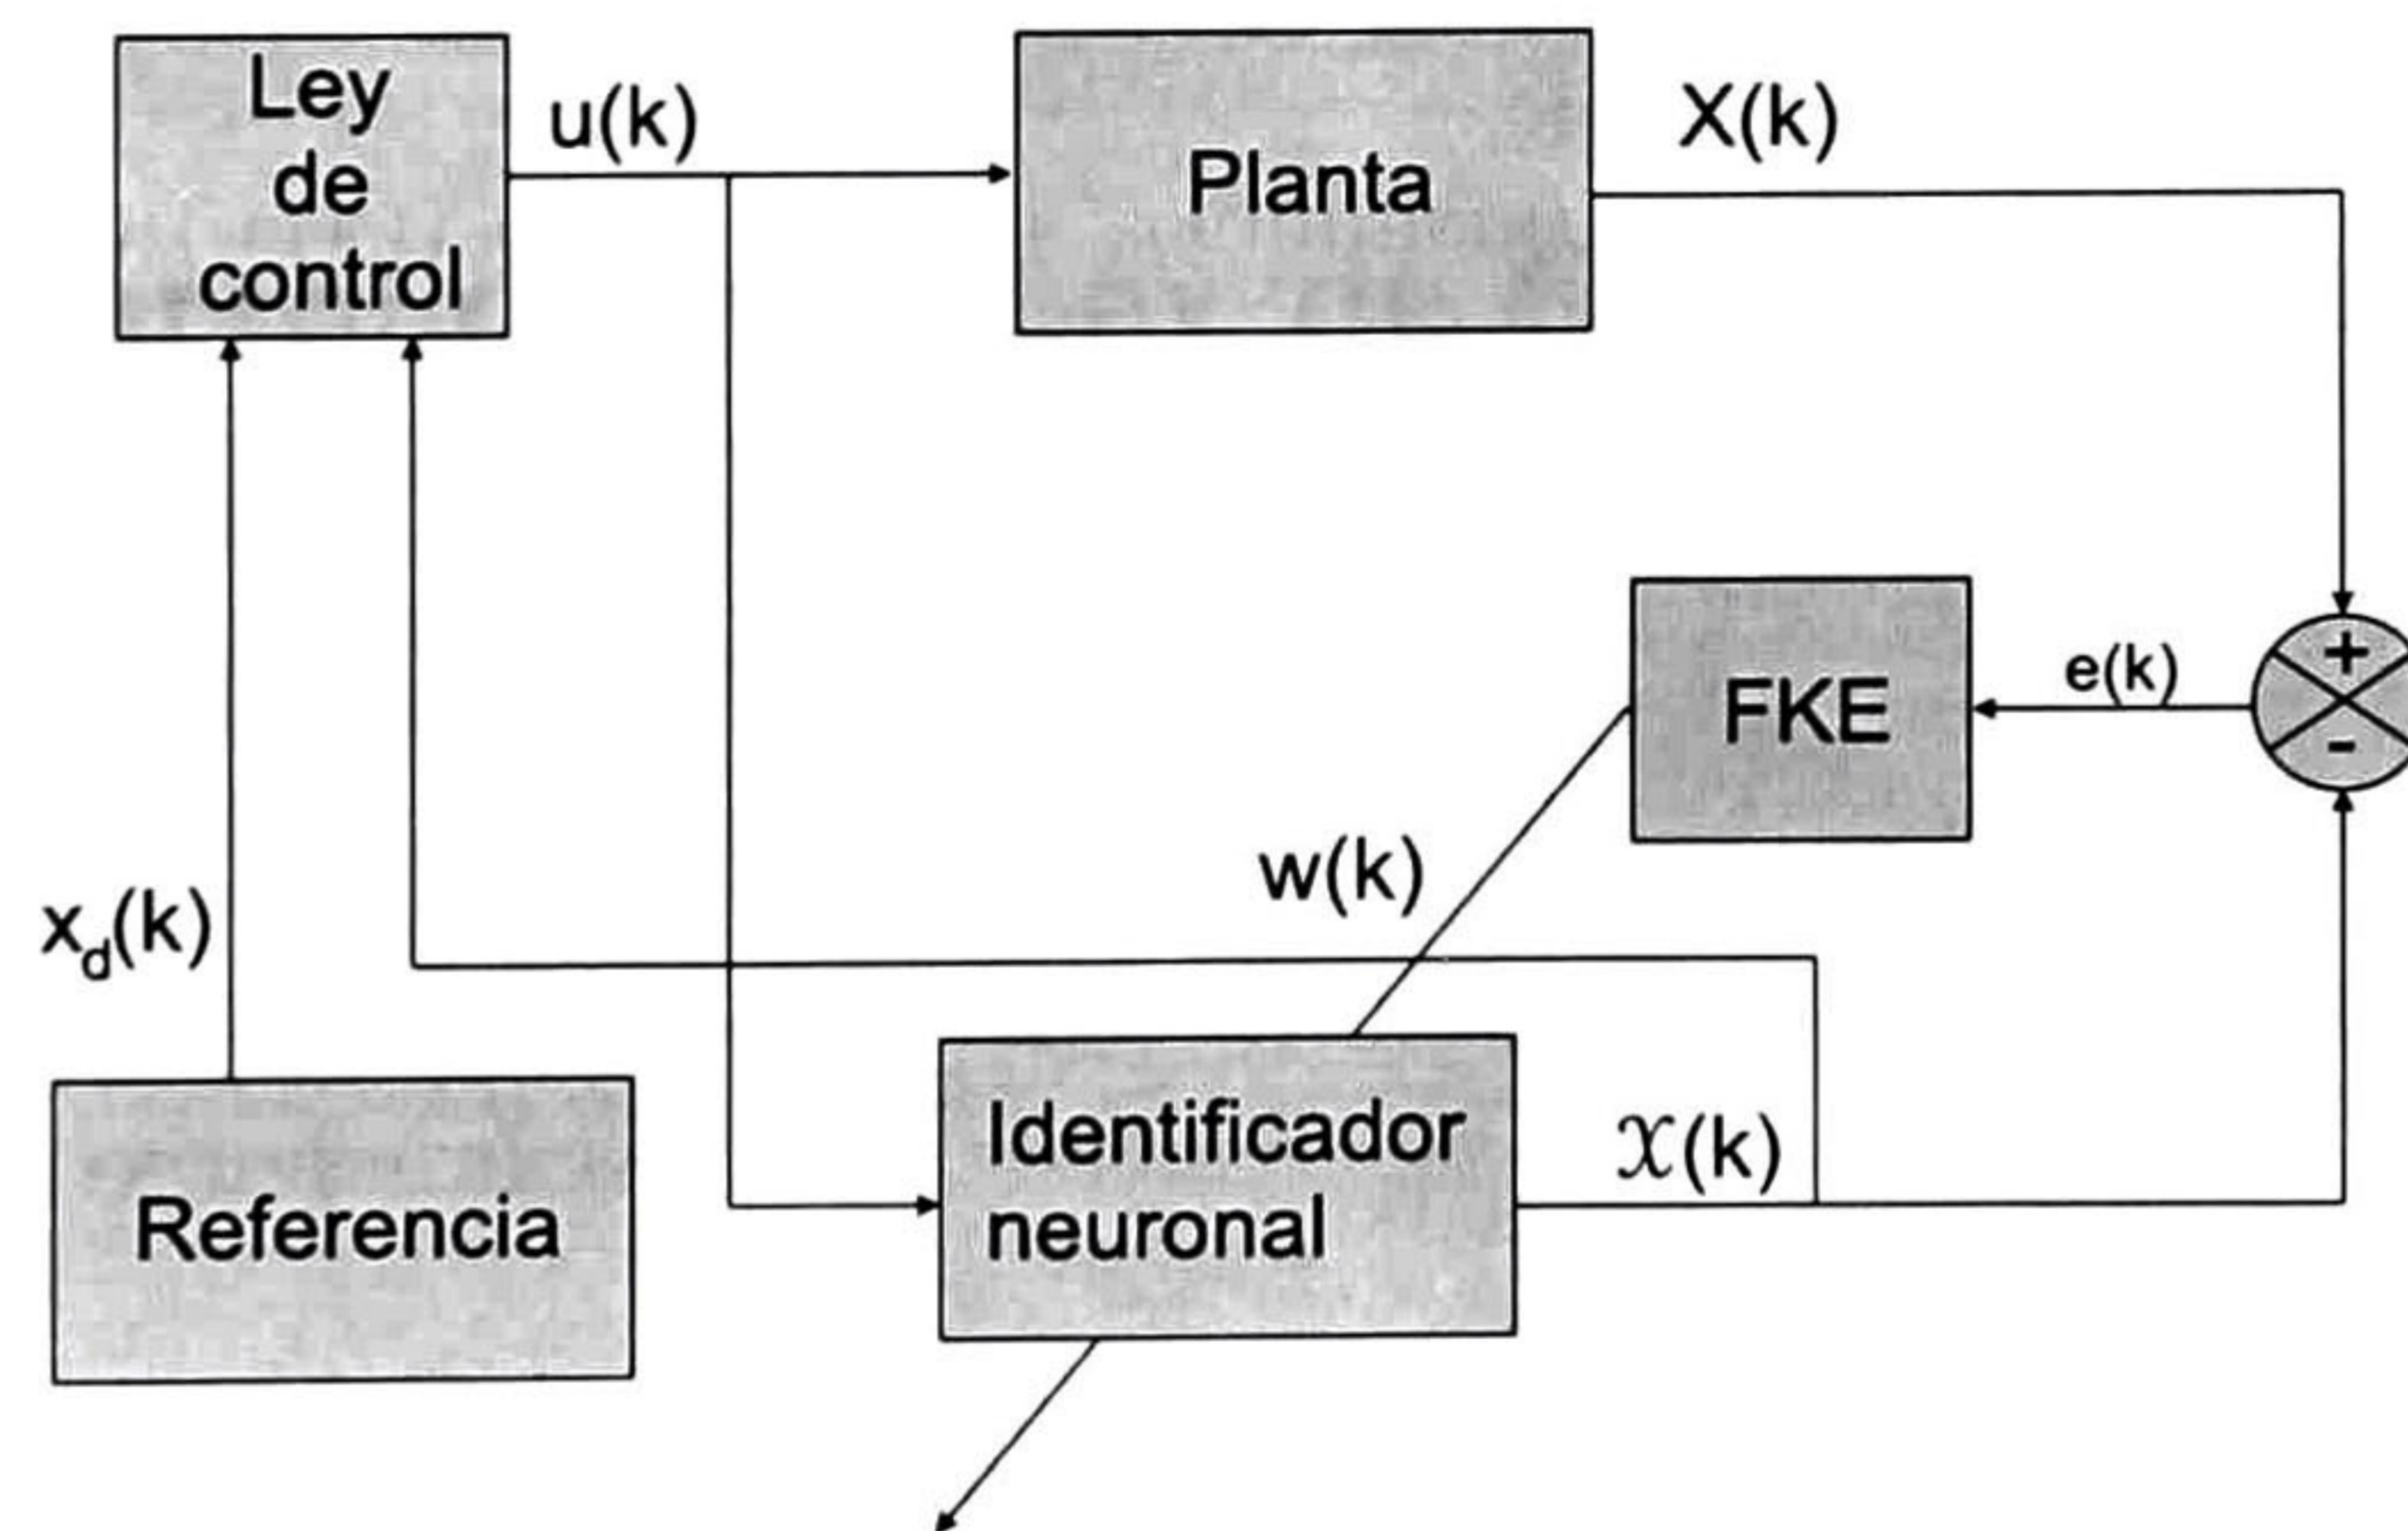


Fig. 4.1: Identificación y control

Capítulo 5

Control del MIL

Una vez que el modelo matemático del motor MIL ha sido determinado, el siguiente paso es aplicar una ley de control para lograr los objetivos de seguimiento. Con este propósito en este capítulo, se utilizan el algoritmo de identificación visto en el capítulo 3 y la técnica de control por modos deslizantes del capítulo 4, y se presenta la primera aportación importante de esta tesis: Control discreto por modos deslizantes del MIL.

5.1 Desarrollo de la Ley de Control

5.1.1 Identificación Neuronal

Para identificación del motor MIL (2.6), se utiliza la siguiente red neuronal en su representación serie-paralelo

$$\begin{aligned}\chi_1(k+1) &= w_{11}(k)S(v(k)) + w_{12}(k)S(\psi_{r\alpha}(k)) + w_{13}(k)S(\psi_{r\beta}(k)) \\ &\quad - w_{14}(k)S(\psi_{r\alpha}(k))\rho_1 i_{s\alpha}(k) - w_{14}(k)S(\psi_{r\beta}(k))\rho_2 i_{s\alpha}(k) \\ &\quad + w_{15}(k)S(\psi_{r\alpha}(k))\rho_2 i_{s\beta}(k) - w_{15}(k)S(\psi_{r\beta}(k))\rho_1 i_{s\beta}(k) \\ \chi_2(k+1) &= w_{21}(k)S(v(k)) + w_{22}(k)S(\psi_{r\alpha}(k)) \\ &\quad + w_{23}(k)S(\psi_{r\beta}(k)) + w_{24}(k)\rho_2 i_{s\alpha}(k) + w_{25}(k)\rho_1 i_{s\beta}(k)\end{aligned}\quad (5.1)$$

$$\begin{aligned}
\chi_3(k+1) &= w_{31}(k)S(v(k)) + w_{32}(k)S(\psi_{r\alpha}(k)) \\
&\quad + w_{33}(k)S(\psi_{r\beta}(k)) - w_{34}(k)\rho_1 i_{s\alpha}(k) + w_{35}(k)\rho_2 i_{s\beta}(k) \\
\chi_4(k+1) &= w_{41}(k)S(v(k)) + w_{42}(k)S(\psi_{r\alpha}(k)) + w_{43}(k)S(\psi_{r\beta}(k)) \\
&\quad + w_{44}(k)S(i_{s\alpha}(k)) + w_{45}(k)u_\alpha(k) \\
\chi_5(k+1) &= w_{51}(k)S(v(k)) + w_{52}(k)S(\psi_{r\alpha}(k)) + w_{53}(k)S(\psi_{r\beta}(k)) \\
&\quad + w_{54}(k)S(i_{s\beta}(k)) + w_{55}(k)u_\beta(k) \\
S(\chi) &= \alpha \tanh(\beta\chi) + \gamma
\end{aligned}$$

donde $\chi_1(k)$ identifica la velocidad, $\chi_2(k)$ identifica al flujo en la fase alfa, $\chi_3(k)$ identifica al flujo en la fase beta, $\chi_4(k)$ identifica a la corriente en la fase alfa, $\chi_5(k)$ identifica a la corriente en la fase beta y

Los pesos $w_{ij}(k)$ son actualizados por (3.16), con la excepción de $w_{14}(k)$, $w_{15}(k)$, $w_{24}(k)$, $w_{25}(k)$, $w_{34}(k)$, $w_{35}(k)$, $w_{45}(k)$ y $w_{55}(k)$ que permanecen fijos durante la identificación. Además $w_{24}(k) = w_{25}(k) = w_{34}(k) = w_{35}(k) = w_f$, donde w_f es una constante, α , β y γ son parámetros de diseño.

Los valores de los pesos fijos son: $w_{14} = 0.001$, $w_{15} = 0.001$, $w_f = 0.001$, $w_{45} = 0.02178$ y $w_{55} = 0.02178$.

5.1.2 Forma Controlable por Bloques

Definiendo $\psi(k) = \chi_2^2(k) + \chi_3^2(k)$, que representa la magnitud de los flujos del rotor, se tiene

$$\begin{aligned}
\psi(k+1) &= \chi_2^2(k+1) + \chi_3^2(k+1) \\
&= w_{23}^2(k)S^2(\psi_{r\beta}(k)) + 2w_{31}(k)w_{33}(k)S(v(k))S(\psi_{r\beta}(k)) \\
&\quad + 2w_{32}(k)w_{33}(k)S(\psi_{r\alpha}(k))S(\psi_{r\beta}(k)) + w_{32}^2(k)S^2(\psi_{r\alpha}(k)) \\
&\quad + 2w_{22}(k)w_{23}(k)S(\psi_{r\alpha}(k))S(\psi_{r\beta}(k)) + w_{33}^2(k)S^2(\psi_{r\beta}(k)) \\
&\quad + 2w_{21}(k)w_{23}(k)S(v(k))S(\psi_{r\beta}(k)) + w_{21}^2(k)S^2(v(k)) \\
&\quad + 2w_{21}w_{22}S(v(k))S(\psi_{r\alpha}(k)) + w_{22}^2(k)S^2(\psi_{r\alpha}(k)) \\
&\quad + 2w_{31}(k)w_{32}(k)S(v(k))S(\psi_{r\alpha}(k)) + w_{31}^2(k)S^2(v(k))
\end{aligned} \tag{5.2}$$

$$\begin{aligned}
& -2w_{32}(k)w_f S(\psi_{r\alpha})\rho_1 i_{s\alpha}(k) - 2w_f(w_{31}(k)S(v(k))) \\
& + 2w_f(w_{21}(k)S(v(k))) + w_{22}(k)S(\psi_{r\alpha}(k))\rho_2 i_{s\alpha}(k) \\
& + 2w_{23}(k)w_f S(\psi_{r\beta}(k))\rho_2 i_{s\alpha}(k) + w_f^2(i_{s\alpha}^2(k) + i_{s\beta}^2(k)) \\
& + 2w_{23}(k)w_f S(\psi_{r\beta}(k))\rho_1 i_{s\beta}(k) + 2w_f(w_{22}(k)S(\psi_{r\alpha}(k))\rho_1 i_{s\beta}(k) \\
& + 2w_f w_{21}(k)S(v(k)))\rho_1 i_{s\beta}(k) + 2w_f(w_{32}(k)S(\psi_{r\alpha}(k))\rho_2 i_{s\beta}(k) \\
& + 2w_f w_{33}(k)S(\psi_{r\beta}(k)))\rho_2 i_{s\beta}(k) + 2w_{31}(k)w_f S(v(k))\rho_2 i_{s\beta}(k) \\
& + w_{33}(k)S(\psi_{r\beta}(k))\rho_1 i_{s\alpha}(k)
\end{aligned}$$

Basándose en (5.2) se representa al sistema (5.1) en la forma no lineal controlable por bloques

$$\begin{aligned}
\chi^1(k) &= F_1(\bar{X}^2(k), W_1(k)) + G_1(k)X^2(k) \\
\chi^2(k) &= F_2(\bar{X}^2(k), W_2(k)) + W_2'(k)u(k)
\end{aligned} \tag{5.3}$$

$$y^1(k) = \chi^1(k) \tag{5.4}$$

con $y^1(k)$ la salida a ser controlada, \bar{X}^i como en (4.10), $W_1(k)$ y $W_2(k)$ los pesos adaptados en línea, W_2' es una matriz de pesos que permanecen fijos durante la identificación y control, y

$$\begin{aligned}
\chi^1(k) &= \begin{bmatrix} \chi_1(k) \\ \psi(k) \end{bmatrix}, & \chi^2(k) &= \begin{bmatrix} \chi_4(k) \\ \chi_5(k) \end{bmatrix} \\
F_1(\bar{X}^2, W_1(k)) &= \begin{bmatrix} f_{11}(k) \\ f_{12}(k) \end{bmatrix}, & F_2(\bar{X}^2, W_1(k)) &= \begin{bmatrix} f_{21}(k) \\ f_{22}(k) \end{bmatrix}, \\
G_1(k) &= \begin{bmatrix} g_{11}(k) & g_{12}(k) \\ g_{21}(k) & g_{22}(k) \end{bmatrix}, & W_2'(k) &= \begin{bmatrix} w_{55}(k) & 0 \\ 0 & w_{65}(k) \end{bmatrix} \\
X^2(k) &= \begin{bmatrix} i_\alpha \\ i_\beta \end{bmatrix}, & u(k) &= \begin{bmatrix} u_\alpha(k) \\ u_\beta(k) \end{bmatrix}
\end{aligned} \tag{5.5}$$

con

$$\begin{aligned}
f_{11}(k) &= w_{11}(k)S(v(k)) + w_{12}S(\psi_{r\alpha}(k)) + w_{13}S(\psi_{r\beta}(k)), \\
f_{12}(k) &= w_{23}^2(k)S^2(\psi_{r\beta}(k)) + w_f^2 I_m^2(k) + 2w_{31}(k)w_{33}(k)S(v(k))S(\psi_{r\beta}(k)) \\
& + 2w_{32}(k)w_{33}(k)S(\psi_{r\alpha}(k))S(\psi_{r\beta}) + 2w_{22}(k)w_{23}(k)S(\psi_{r\alpha}(k))S(\psi_{r\beta})
\end{aligned}$$

$$\begin{aligned}
& +2w_{21}(k)w_{23}(k)S(v(k))S(\psi_{r\beta}) + w_{21}^2(k)S^2(v(k)) + w_{32}^2S^2(\psi_{r\alpha}) \\
& +2w_{21}(k)w_{22}(k)S(v(k))S(\psi_{r\alpha}) + w_{22}^2(k)S^2(\psi_{r\alpha}(k)) + w_{33}^2S^2(\psi_{r\beta}) \\
& +2w_{31}(k)w_{32}(k)S(v(k))S(\psi_{r\alpha}) + w_{31}^2(k)S(v(k)), \\
f_{21}(k) & = w_{41}(k)S(v(k)) + w_{42}(k)S(\psi_{r\alpha}(k)) + w_{43}(k)S(\psi_{r\beta}(k)) \\
& +w_{44}(k)S(i_{s\alpha}(k)) \\
f_{22}(k) & = w_{51}(k)S(v(k)) + w_{52}(k)S(\psi_{r\alpha}(k)) + w_{53}(k)S(\psi_{r\beta}(k)) \\
& +w_{54}(k)S(i_{s\beta}(k)) \\
g_{11}(k) & = -w_{14}(k)S(\psi_{r\alpha})\rho_1 - w_{14}(k)S(\psi_{r\beta})\rho_2, \\
g_{12}(k) & = w_{15}(k)S(\psi_{r\alpha})\rho_2 - w_{15}(k)S(\psi_{r\beta})\rho_1, \\
g_{21}(k) & = 2w_f w_{23}(k)S(\psi_{r\beta}(k))\rho_2 - 2w_f w_{32}(k)S(\psi_{r\alpha}(k))\rho_1 - 2w_f(w_{31}(k)S(v(k)) \\
& +w_{33}(k)S(\psi_{r\beta}))\rho_1 + 2w_f(w_{21}(k)S(v(k)) + w_{22}(k)S(\psi_{r\alpha}))\rho_2, \\
g_{22}(k) & = 2w_f w_{23}(k)S(\psi_{r\beta}(k))\rho_1 + 2w_f w_{31}(k)S(v(k))\rho_2 + 2w_f(w_{22}(k)S(\psi_{r\alpha}(k)) \\
& +w_{31}(k)S(v(k)))\rho_1 + 2w_f(w_{32}(k)S(\psi_{r\alpha}(k)) + w_{33}(k)S(\psi_{r\beta}))\rho_2
\end{aligned}$$

con

$$I_m(k) = \sqrt{i_{s\alpha}^2(k) + i_{s\beta}^2(k)}. \quad (5.6)$$

Las matrices en (5.5) son invertibles porque los pesos $w_{14}(k)$, $w_{15}(k)$, $w_{24}(k)$, $w_{25}(k)$, $w_{34}(k)$, $w_{35}(k)$, $w_{45}(k)$, $w_{55}(k)$ son fijos.

5.1.3 Ley de Control

Para alcanzar los objetivos de control de velocidad y magnitud del flujo, se definen el error de seguimiento como:

$$e^1(k) = y^1(k) - y_{ref}(w(k)) \quad (5.7)$$

con $y_{ref}(w(k))$ como

$$y_{ref}(w(k)) = \begin{bmatrix} v_{ref}(k) \\ \psi_{ref}(k) \end{bmatrix}$$

donde $e^1(k)$ es el error entre la salida de la red neuronal y la referencia deseada, $v_{ref}(k)$ y $\psi_{ref}(k)$ son las señales de referencia.

Usando (5.7), y tomando un paso adelante, se tiene

$$e^1(k+1) = F_1(\bar{X}^2(k), W_1(k)) + G_1(k)X^2(k) - y_{ref}(w(k+1)) \quad (5.8)$$

y escogiendo $X_{des}^2(k)$ como

$$X_{des}^2(k) = G_1^{-1}(k)(-F_1(\bar{X}^2(k), W_1(k)) + y_{ref}(w(k+1)) + Ke^1(k)) \quad (5.9)$$

se obtiene la siguiente dinámica para $e^1(k)$

$$e^1(k+1) = Ke^1(k)$$

donde K es una matriz Schur.

Definiendo un nuevo vector de error como $e^2(k) = X^2(k) - X_{des}^2(k)$, se llega al siguiente conjunto de ecuaciones

$$\begin{aligned} e^1(k+1) &= Ke^1(k) + G_1(k)e^2(k) \\ e^2(k+1) &= F_2(\bar{X}^2(k), W_2(k)) - X_{des}^2(k+1) + W_2'u(k). \end{aligned} \quad (5.10)$$

Se define la variedad deslizante como $S(k) = e^2(k) = 0$. Por lo que (5.10) toma la forma:

$$\begin{aligned} e^1(k+1) &= Ke^1(k) + G_1(k)S(k) \\ S(k+1) &= F_2(\bar{X}^2(k), W_2(k)) - X_{des}^2(k+1) + W_2'u(k). \end{aligned} \quad (5.11)$$

Para diseñar la ley de control, un modo deslizante en tiempo discreto es utilizado como en [15]

$$u(k) = \begin{cases} u_{eq}(k) & \text{if } \|u_{eq}(k)\| \leq u_{max} \\ u_{max} \frac{u_{eq}(k)}{\|u_{eq}(k)\|} & \text{if } \|u_{eq}(k)\| > u_{max} \end{cases} \quad (5.12)$$

donde $u_{eq}(k) = W_2'^{-1}(-F_2(\bar{X}^2(k), W_2(k)) + X_{des}^2(k+1))$ es calculada de (5.11) tomado

$S(k+1) = 0$, y u_{max} es la cota para el control.

En esta ley de control el término $X_{des}^2(k+1)$ requiere usar $i_{s\alpha}(k+1)^2$ e $i_{s\beta}(k+1)^2$, por lo que la ley de control depende de la entrada de control. Para resolver este problema en [15] el siguiente observador es propuesto para $I_m(k)$:

$$\begin{aligned}\hat{I}_m(k+1) &= \hat{I}_m(k) + ge(k) \\ e(k) &= I_m(k) - \hat{I}_m(k)\end{aligned}\tag{5.13}$$

Para saber que valores toma g , se hace el siguiente analisis:

$$\begin{aligned}e(k+1) &= I_m(k+1) - \tilde{I}_m(k+1) \\ &= I_m(k) - \tilde{I}_m(k) - ge(k) \\ &= e(k) - ge(k) \\ &= (1-g)e(k)\end{aligned}$$

y se propone la siguiente función de Lyapunov para probar estabilidad

$$V(k) = e^T(k)e(k)\tag{5.14}$$

con

$$\Delta V = V(k+1) - V(k)\tag{5.15}$$

$$\begin{aligned}&= e^T(k+1)e(k+1) - e^T(k)e(k) \\ &= (1-g)^2 e^T(k)e(k) - e^T(k)e(k) \\ &= [(1-g)^2 - 1]e^T(k)e(k)\end{aligned}\tag{5.16}$$

Para que $V(k) < 0$ se debe de cumplir que

$$(1-g)^2 - 1 < 0$$

por lo que

$$(1-g)^2 - 1 < 0$$

$$\begin{aligned}
(1 - g)^2 &< 1 \\
|1 - g| &< 1 \\
-1 &< 1 - g < 1 \\
0 &< g < 2
\end{aligned} \tag{5.17}$$

Por lo tanto, si $0 < g < 2$, entonces $V(k) < 0$ y $e(k)$ será asintóticamente estable, donde $I_m(k)$ es definido como en (5.6).

También es posible hacer un identificador para $I_m(k)$ en la forma serie-paralelo y evitar la dependencia de la entrada $u(k)$ y queda de la siguiente forma

$$\hat{I}_m(k+1) = w_{11}S(I_m(k)) + w_{12}S^2(I_m(k)) \tag{5.18}$$

donde los pesos w_{11} y w_{12} son actualizados en línea.

En esta simulación se utilizó la ecuación (5.18) para aproximar (5.6), aunque (5.13) mostró buen desempeño también.

Una vez que el modo deslizante es alcanzado, $S(k+1) = 0$, $S(k) = 0$ queda la ecuación del modo deslizante

$$e^1(k+1) = Ke^1(k) \tag{5.19}$$

donde K es una matriz Schur.

El esquema de identificación y control es mostrado en la figura 4.1.

5.1.4 Observador de Flujo

Debido a que los flujos no son medibles, se hace uso de un observador de orden reducido. La dinámica de los flujos en (2.6) puede ser reescrita como:

$$\Psi(k+1) = \Psi(k) - k_6 T \Psi(k) - k_4 T \Theta^T J I_s(k)$$

$$+k_4T\Theta^T JI_s(k)v(k) + k_4T\Theta^T I_s(k) \quad (5.20)$$

con

$$\Theta(k) = \begin{bmatrix} \cos(n_p q_m) & -\sin(n_p q_m) \\ \sin(n_p q_m) & \cos(n_p q_m) \end{bmatrix}, \quad J = \begin{bmatrix} 0 & -1 \\ 1 & 0 \end{bmatrix},$$

$$\Psi(k) = \begin{bmatrix} \psi_{r\alpha}(k) \\ \psi_{r\beta}(k) \end{bmatrix}, \quad I_s(k) = \begin{bmatrix} i_{s\alpha}(k) \\ i_{s\beta}(k) \end{bmatrix}$$

Se propone el siguiente observador

$$\begin{aligned} \tilde{\Psi}(k+1) &= \tilde{\Psi}(k) - k_6T\tilde{\Psi}(k) - k_4T\Theta^T JI_s(k) \\ &\quad + k_4T\Theta^T JI_s(k)v(k) + k_4T\Theta^T I_s(k) \end{aligned}$$

y se define el siguiente error

$$e(k) = \Psi(k) - \tilde{\Psi}(k) \quad (5.21)$$

con

$$\begin{aligned} e(k+1) &= \Psi(k) - k_6T\Psi(k) - k_4T\Theta^T JI_s(k) + k_4T\Theta^T JI_s(k)v(k) \quad (5.22) \\ &\quad + k_4T\Theta^T I_s(k) - \tilde{\Psi}(k) + k_6T\tilde{\Psi}(k) + k_4T\Theta^T JI_s(k) \\ &\quad - k_4T\Theta^T JI_s(k)v(k) - k_4T\Theta^T I_s(k) \\ &= e(k) - k_6Te(k) \\ &= (1 - k_6T)e(k) \end{aligned}$$

Para probar estabilidad de $e(k)$, se propone la siguiente función de Lyapunov

$$V(k) = e^T(k)e(k) \quad (5.23)$$

con

$$\begin{aligned} \Delta V &= V(k+1) - V(k) \\ &= e^T(k+1)e(k+1) - e^T(k)e(k) \\ &= (1 - k_6T)^2 e^T(k)e(k) - e^T(k)e(k) \end{aligned}$$

Tabla 5.1: Parámetros del Motor

Parámetro	Valor	Descripción
R_s	5.3685 Ω	Resistencia del devanado
R_r	3.5315 Ω	Resistencia en el secundario
L_s	28.46 mH	Inductancia en el primario
L_r	28.46 mH	Inductancia en el secundario
L_m	24.1 mH	Inductancia magnetizante
n_p	4	Número de pares de polos
R_m	36.0455 Kg/s	Fricción viscosa
D_m	2.78 Kg	Masa del secundario
τ	0.027 m	Distancia entre polos
K_f	148.38 N/A	Fuerza constante
T	0.0001 s	Período de muestreo

$$= [((1 - k_6 T)^2) - 1]e^T(k)e(k) \quad (5.24)$$

Dado que el término $(1 - k_6 T)^2 < 1$, entonces $\Delta V < 0$, por lo que $e(k)$ tiende asintóticamente a 0.

5.2 Simulación

Para realizar las simulación, se utilizaron los parámetros listados en la tabla 5.1. La simulación se realizó de la siguiente manera: con el sistema en lazo abierto, se identifica a la planta (2.6) hasta un tiempo de 0.5 s. Después de este tiempo, se aplica la ley de control (5.12) tanto a la planta como al identificador. Las referencias son $v_{ref}(k) = 0.3 \sin(\pi k T)$ m/s para la velocidad y $\psi_{ref}(k) = 0.2$ Wb² para la magnitud del flujo.

Los resultados de simulación son presentados de la siguiente forma: las Fig. 5.1-5.5 muestran los errores de identificación entre la red neuronal (5.1) y el sistema (2.6) y las Fig. 5.6 y 5.7 muestran el seguimiento de velocidad y magnitud de flujo aplicando la ley de control (5.12).




Fig. 5.1: Error de velocidad




Fig. 5.2: Error del flujo α




Fig. 5.3: Error del flujo β




Fig. 5.4: Error de la corriente α




Fig. 5.5: Error de la corriente β




Fig. 5.6: Seguimiento de la velocidad

Para ilustrar la robustez de la identificación y control usados, las Fig. 5.8 and 5.9 muestran las perturbaciones aplicadas en $t=1$ s. La resistencia del rotor es incrementada 1Ω por segundo y la carga toma diferentes valores.

La Fig. 5.10 ilustra el error de identificación entre $Im(k)$ de la planta y del




Fig. 5.7: Seguimiento de la magnitud del flujo




Fig. 5.8: Perturbación en la carga

identificador (5.18). La Fig. 5.11 muestra, como comparación, la evolución de $I_m(k)$ de la planta, $\tilde{I}_m(k)$ del observador e $\hat{I}_m(k)$ del identificador.

Las Fig. 5.12 y 5.13 muestran la evolución de los flujos tanto de la planta como del observador.




Fig. 5.9: Perturbación en la resistencia del rotor




Fig. 5.10: Error de identificación de $I_m(k)$




Fig. 5.11: Evolución de $Im(k)$



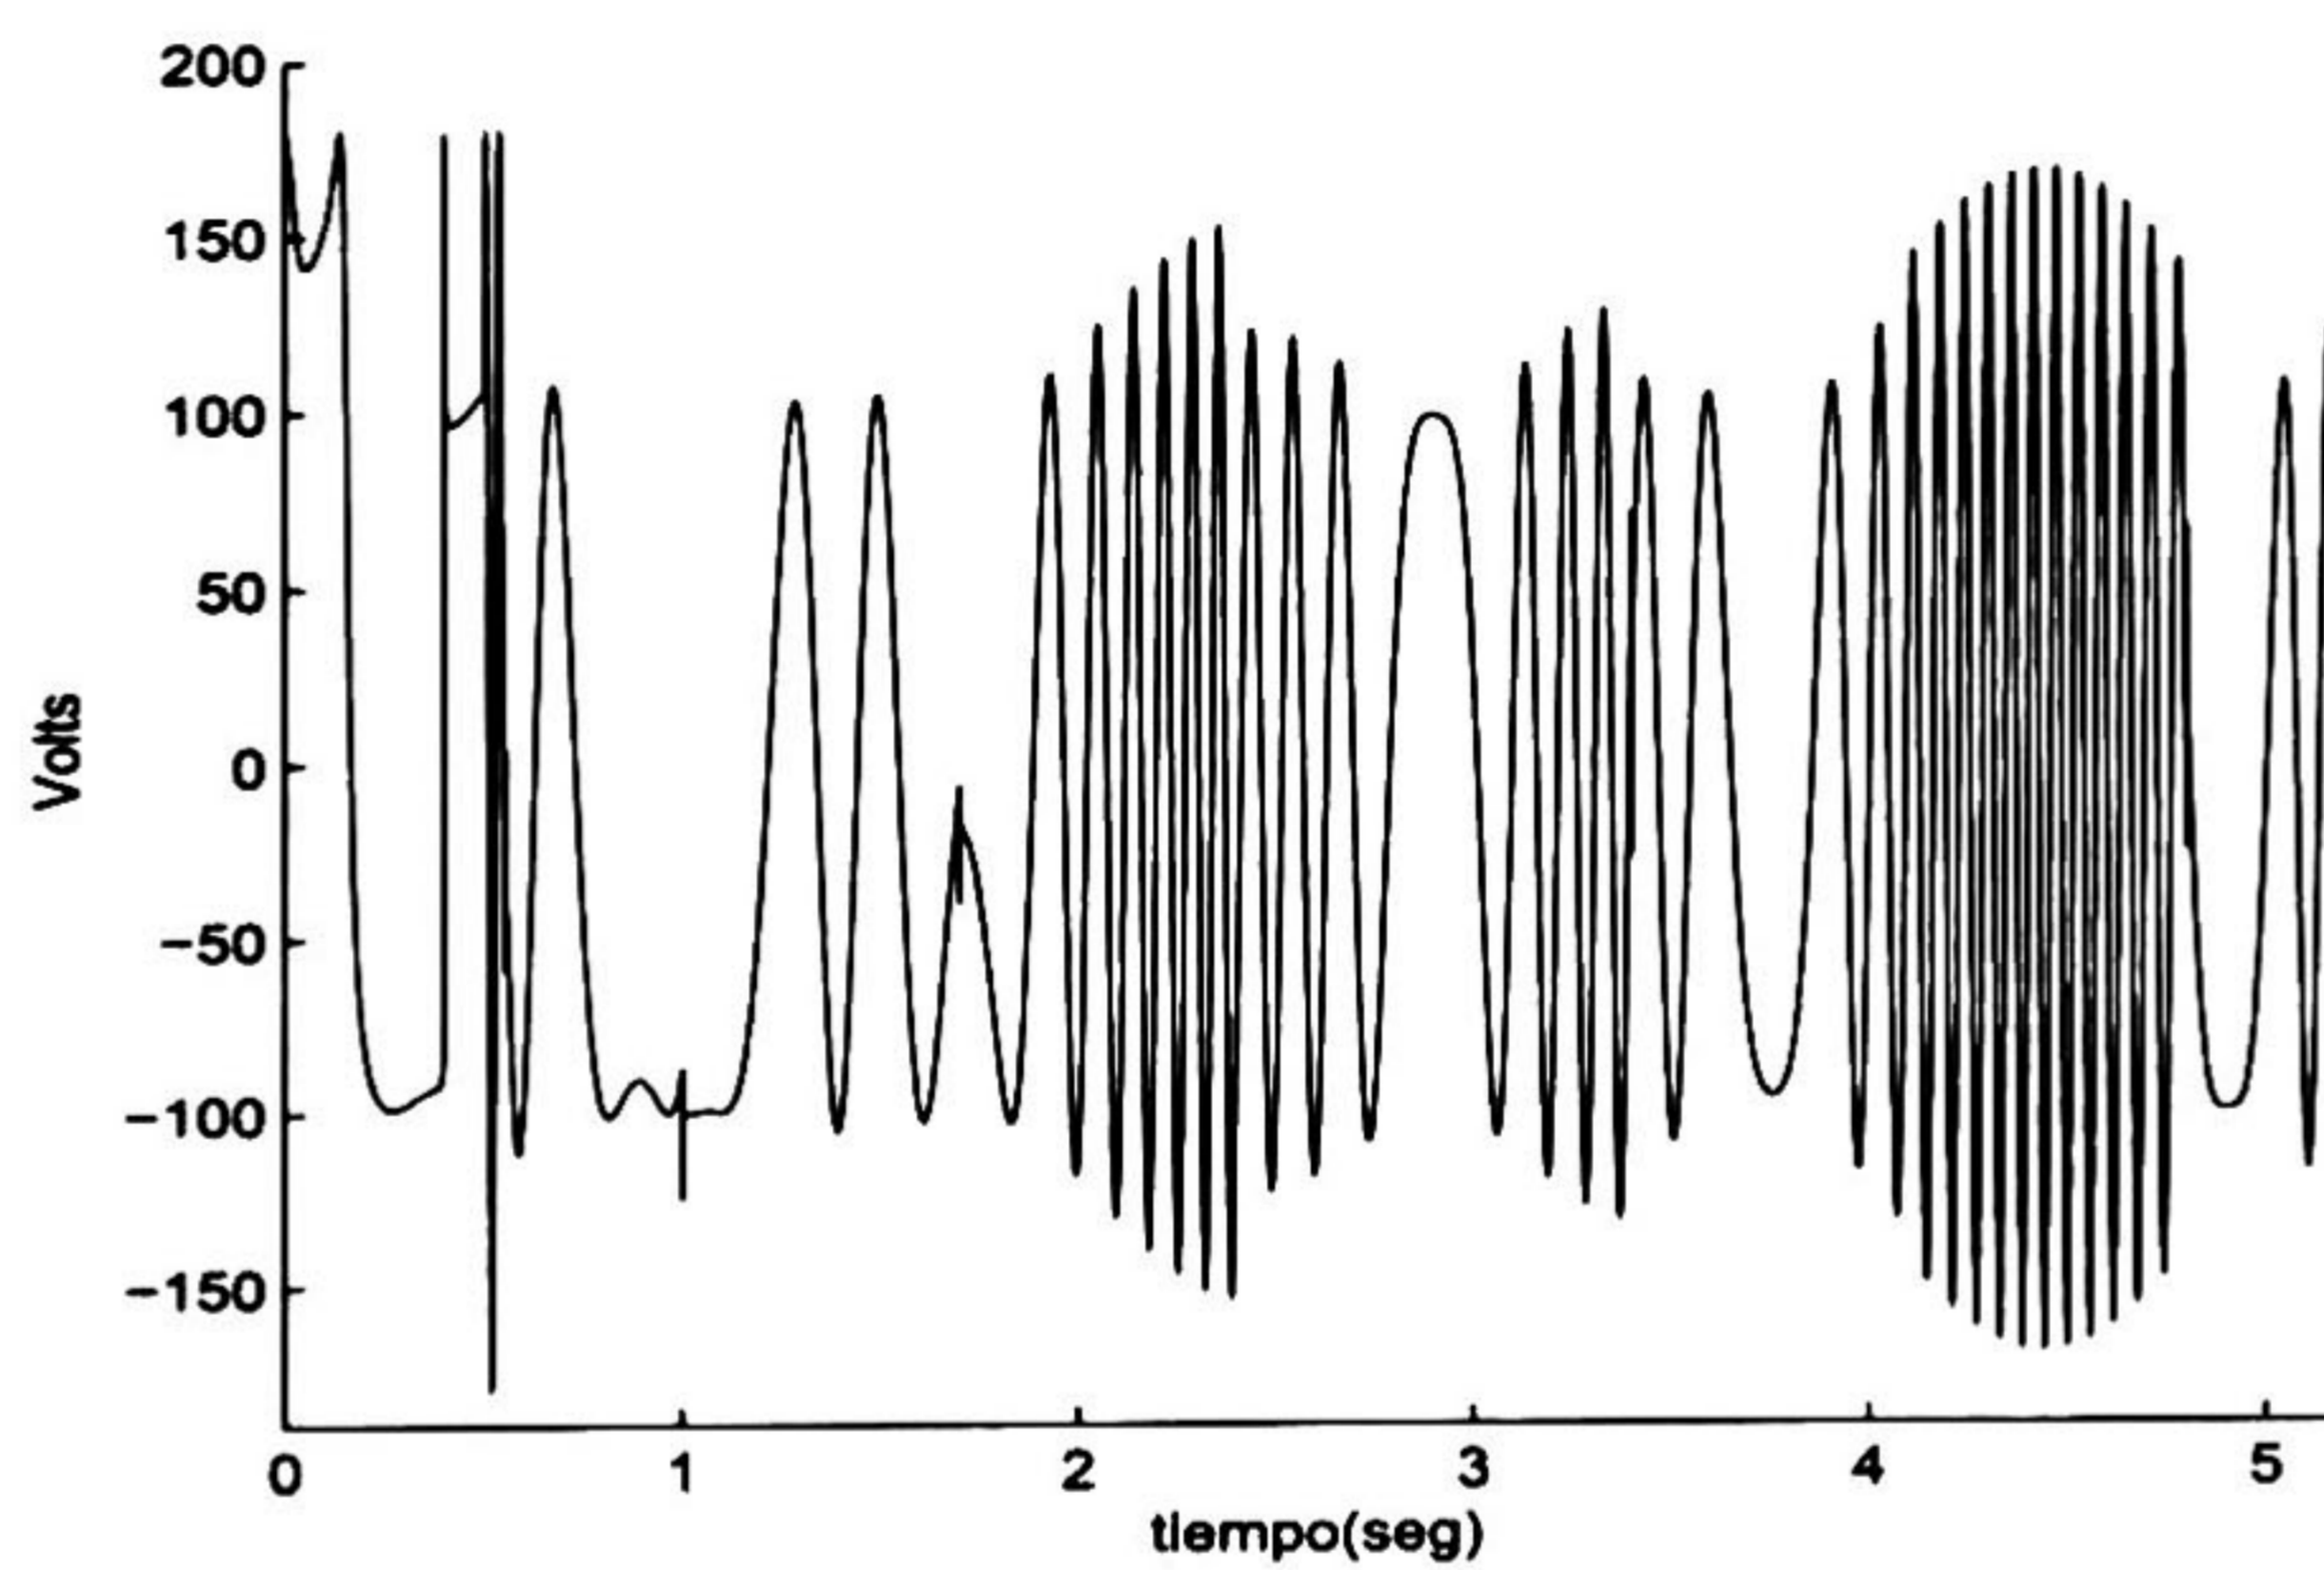



Fig. 5.12: Flujo en la fase α

Fig. 5.13: Flujo en la fase β

Las Fig. 5.14 y 5.15 muestran las leyes de control aplicadas a la planta, observese que después de aplicada la ley de control las señales u_α y u_β son continuas.

Fig. 5.14: Control u_α

Fig. 5.15: Control u_β

Capítulo 6

Observador Neuronal

Usualmente es necesario conocer todos los estados para poder ser utilizados en la ley de control. Sin embargo, muchas veces esto no siempre es posible. Como segunda aportación de esta tesis, en este capítulo se presenta un observador neuronal para estimar los estados no medibles del MIL.

6.1 Observador Neuronal en Tiempo Discreto

Considere el problema de estimar el sistema no lineal en tiempo discreto, dado por

$$\begin{aligned}x(k+1) &= F(x(k), u(k)) + d(k) \\ y(k) &= Cx(k)\end{aligned}\tag{6.1}$$

donde $x(k) \in \mathbb{R}^n$, es el vector de estado del sistema, $u(k) \in \mathbb{R}^m$ es el vector de entradas $y(k) \in \mathbb{R}^p$ es el vector de salida, $C \in \mathbb{R}^{p \times n}$ es la matriz de salida conocida, $d(k) \in \mathbb{R}^n$ es un vector de perturbaciones, $F(\cdot, \cdot)$ es un vector suave.

El sistema (6.1) puede ser escrito como [3]:

$$x(k) = [x_1(k) \cdots x_i(k) \cdots x_n(k)]^T$$

$$\begin{aligned}
d(k) &= [d_1(k) \cdots d_i(k) \cdots d_n(k)]^T \\
x_i(k+1) &= F_i(x(k), u(k)) + d_i(k), \quad i = 1, \dots, n \\
y(k) &= Cx(k)
\end{aligned} \tag{6.2}$$

Para el sistema (6.2) en [3] se propone el siguiente observador neuronal recurrente tipo Luenberger

$$\begin{aligned}
\hat{x}(k) &= [\hat{x}_1(k) \cdots \hat{x}_i(k) \cdots \hat{x}_n(k)]^T \\
\hat{x}_i(k+1) &= w_i^T z_i(\hat{x}(k), u(k)) + L_i e(k) \\
y(k) &= C\hat{x}(k), \quad i = 1, \dots, n
\end{aligned} \tag{6.3}$$

con $L_i \in \mathbb{R}^p$, $z_i(\hat{x}(k), u(k))$ es definido como:

$$z_i(\hat{x}(k), u(k)) = \begin{bmatrix} z_{i_1} \\ z_{i_2} \\ \vdots \\ z_{i_{\lambda_i}} \end{bmatrix} = \begin{bmatrix} \prod_{j \in I_1} \psi_{i_j}^{d_{i_j}(1)} \\ \prod_{j \in I_2} \psi_{i_j}^{d_{i_j}(2)} \\ \vdots \\ \prod_{j \in I_{\lambda_i}} \psi_{i_j}^{d_{i_j}(\lambda_i)} \end{bmatrix} \tag{6.4}$$

donde λ_i es el respectivo número de conexiones de alto orden, $\{I_1, I_2, \dots, I_{\lambda_i}\}$ es una colección de subconjuntos no ordenados de $\{1, 2, \dots, n+m\}$, con $d_{i_j}(k)$ enteros no negativos y ψ_i está definido como

$$\psi_i = \begin{bmatrix} \psi_{i_1} \\ \vdots \\ \psi_{i_n} \\ \psi_{i_{n+1}} \\ \vdots \\ \psi_{i_{n+m}} \end{bmatrix} = \begin{bmatrix} S(\hat{x}_1(k)) \\ \vdots \\ S(\hat{x}_n(k)) \\ u_1(k) \\ \vdots \\ u_m(k) \end{bmatrix} \tag{6.5}$$

El vector de pesos $w_i(k)$ es actualizado en línea por medio del FKE, cuyas ecua-

ciones están dadas por [20], [3]:

$$\begin{aligned}
 w_i(k+1) &= w_i(k) + \eta_i K_i(k) e(k) \\
 K_i(k) &= P_i(k) H_i(k) M_i(k) \quad i = 1, \dots, n \\
 P_i(k+1) &= P_i(k) - K_i(k) H_i^T(k) P_i(k) + Q_i(k)
 \end{aligned} \tag{6.6}$$

con

$$\begin{aligned}
 M_i(k) &= [R_i(k) + H_i^T(k) P_i(k) H_i(k)]^{-1} \\
 e(k) &= y(k) - \hat{y}(k) \\
 &= Cx(k) - C\hat{x}(k) \\
 &= C\tilde{x}(k)
 \end{aligned}$$

donde $e(k) \in \mathbb{R}^p$ es el vector de error entre la salida de la planta y la red neuronal, $P_i(k) \in \mathbb{R}^{\lambda_i \times \lambda_i}$ es la matriz de covarianza del error de estimación al paso k , $w_i \in \mathbb{R}^{\lambda_i}$ es el vector de pesos (estado), $x(k)$ es el vector de estado de la planta, $\hat{x}(k)$ es el vector de estado de la red neuronal, $\tilde{x}(k)$ es el vector de error entre los estados de la planta y la red neuronal, $K_i(k) \in \mathbb{R}^{\lambda_i}$ es el vector de ganancias de Kalman, $Q_i \in \mathbb{R}^{\lambda_i \times \lambda_i}$ es la matriz de covarianza del ruido de estimación, $R_i \in \mathbb{R}^p$, y $H_i(k) \in \mathbb{R}^{p \times \lambda_i}$ es una matriz, en el cual cada vector de entrada $H_j(k)$ es la derivada del estado de la red neuronal $\hat{x}_i(k)$, con respecto a los pesos de la red neuronal de los estados medibles, $H_j(k)$ está dado por:

$$H_{ij}(k) = \left[\frac{\partial y}{\partial w_i(k)} \right]^T \tag{6.7}$$

donde $i = 1, \dots, m$. Usualmente $P_i(k)$ y $Q_i(k)$ son inicializados como matrices diagonales, con entradas $P_i(0)$ y $Q_i(0)$, respectivamente. Es importante notar que $H_i(k)$, $K_i(k)$ y $P_i(k)$ para el FKE son acotados [18], esto es, existen constantes $\bar{H} > 0$, $\bar{K} > 0$ y $\bar{P} > 0$ tales que:

$$\begin{aligned}
 \|H(k)\| &\leq \bar{H} \\
 \|K(k)\| &\leq \bar{K} \\
 \|P(k)\| &\leq \bar{P}
 \end{aligned} \tag{6.8}$$

La Fig. 6.1 muestra el diagrama de observador neuronal.

6.2 Simulación

En esta sección se presenta la segunda contribución de esta tesis. Se presenta el observador neuronal explicado en este capítulo a la planta (2.6). El observador neuronal propuesto para el motor MIL tiene la siguiente forma

$$\begin{aligned}
\hat{x}_1(k+1) &= w_{11}S(\hat{x}_1(k)) + w_{12}\hat{x}_2(k) + L_1e(k) \\
\hat{x}_2(k+1) &= w_{21}S(\hat{x}_2(k)) + w_{22}S(\hat{x}_3(k)) + w_{23}S(\hat{x}_4(k)) + w_{24}S(\hat{x}_2(k))S(\hat{x}_4(k)) + \\
&\quad w_{25}S(\hat{x}_3(k))S(\hat{x}_4(k)) + w_{26}S(\hat{x}_2(k))S(\hat{x}_3(k)) - \\
&\quad w_v(S(\hat{x}_3(k))\sin(n_p\hat{x}_1(k)) + S(\hat{x}_4(k))\cos(n_p\hat{x}_1(k)))\hat{x}_5(k) + \\
&\quad w_v(S(\hat{x}_3(k))\cos(n_p\hat{x}_1(k)) - S(\hat{x}_4(k))\sin(n_p\hat{x}_1(k)))\hat{x}_6(k) + L_2e(k) \\
\hat{x}_3(k+1) &= w_{31}S(\hat{x}_2(k)) + w_{32}S(\hat{x}_3(k)) + w_{33}S(\hat{x}_2(k))S(\hat{x}_3(k)) + \\
&\quad w_{34}S(\hat{x}_1(k))S(\hat{x}_2(k)) + w_{35}S(\hat{x}_1(k))S(\hat{x}_3(k)) + \\
&\quad w_{fa}\cos(n_p\hat{x}_1(k))\hat{x}_5(k) + w_{fa}\sin(n_p\hat{x}_1(k))\hat{x}_6(k) + L_3e(k) \\
\hat{x}_4(k+1) &= w_{41}S(\hat{x}_2(k)) + w_{42}S(\hat{x}_4(k)) + w_{43}S(\hat{x}_2(k))S(\hat{x}_4(k)) + \\
&\quad w_{44}S(\hat{x}_1(k))S(\hat{x}_2(k)) + w_{45}S(\hat{x}_1(k))S(\hat{x}_4(k)) - \\
&\quad w_{fa}\sin(n_p\hat{x}_1(k))\hat{x}_5(k) + w_{fa}\cos(n_p\hat{x}_1(k))\hat{x}_6(k) + L_4e(k) \\
\hat{x}_5(k+1) &= w_{51}S(\hat{x}_2(k)) + w_{52}S(\hat{x}_3(k)) + w_{53}S(\hat{x}_4(k)) + \\
&\quad w_{54}S(\hat{x}_5(k)) + w_{55}S(\hat{x}_2(k))S(\hat{x}_3(k)) + w_{56}S(\hat{x}_2(k))S(\hat{x}_4(k)) + \\
&\quad w_{57}S(\hat{x}_3(k))S(\hat{x}_4(k)) + w_{58}u_\alpha(k) + L_5e(k) \\
\hat{x}_6(k+1) &= w_{61}S(\hat{x}_2(k)) + w_{62}S(\hat{x}_3(k)) + w_{63}S(\hat{x}_4(k)) + \\
&\quad w_{64}S(\hat{x}_6(k)) + w_{65}S(\hat{x}_2(k))S(\hat{x}_3(k)) + w_{66}S(\hat{x}_2(k))S(\hat{x}_4(k)) + \\
&\quad w_{67}S(\hat{x}_3(k))S(\hat{x}_4(k)) + w_{68}u_\beta(k) + L_6e(k)
\end{aligned}$$

donde

$$S(x(k)) = \alpha \tanh(\beta x) + \gamma$$

$$\hat{x}_1(k) \text{ que estima } q_m(k)$$

$\hat{x}_2(k)$ que estima $v(k)$

$\hat{x}_3(k)$ que estima $\psi_\alpha(k)$

$\hat{x}_4(k)$ que estima $\psi_\beta(k)$

$\hat{x}_5(k)$ que estima $i_\alpha(k)$

$\hat{x}_6(k)$ que estima $i_\beta(k)$

con

$$C = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (6.9)$$

Se presenta el $H(k)$ para un estado. Para los demás el procedimiento es el mismo.

Para el estado \hat{x}_6 se tiene

$$\begin{aligned} H_6(k) &= \frac{\partial \hat{y}(k)}{\partial w_6} \\ \frac{\partial \hat{x}_1(k+1)}{\partial w_6(k)} &= \frac{\partial \hat{x}_1(k+1)}{\partial x_6(k)} \frac{\partial \hat{x}_6}{\partial w_6(k)} \\ \frac{\partial \hat{x}_2(k+1)}{\partial w_6(k)} &= \frac{\partial \hat{x}_2(k+1)}{\partial x_6(k)} \frac{\partial \hat{x}_6}{\partial w_6(k)} \\ \frac{\partial \hat{x}_5(k+1)}{\partial w_6(k)} &= \frac{\partial \hat{x}_5(k+1)}{\partial x_6(k)} \frac{\partial \hat{x}_6}{\partial w_6(k)} \\ \frac{\partial \hat{x}_6(k+1)}{\partial w_6(k)} &= \frac{\partial \hat{x}_1(k+1)}{\partial x_6(k)} \frac{\partial \hat{x}_6}{\partial w_6(k)} + Z^6 \end{aligned}$$

con Z^6 como

$$Z^6(k) = \begin{bmatrix} S(\hat{x}_2(k)) \\ S(\hat{x}_3(k)) \\ S(\hat{x}_4(k)) \\ S(\hat{x}_6(k)) \\ S(\hat{x}_2(k))S(\hat{x}_3(k)) \\ S(\hat{x}_2(k))S(\hat{x}_4(k)) \\ S(\hat{x}_3(k))S(\hat{x}_4(k)) \end{bmatrix} \quad (6.10)$$

La matriz $H(k)$ queda de la siguiente forma

$$H(k) = \begin{bmatrix} \frac{\partial \hat{x}_1(k)}{\partial w_6(k)} & \frac{\partial \hat{x}_2(k)}{\partial w_6(k)} & \frac{\partial \hat{x}_5(k)}{\partial w_6(k)} & \frac{\partial \hat{x}_6(k)}{\partial w_6(k)} \end{bmatrix} \quad (6.11)$$

Las Fig. 6.2-6.7 muestran los estados de la planta y del observador neuronal; y las Fig. 6.8 y 6.9 son las perturbaciones aplicadas al motor.

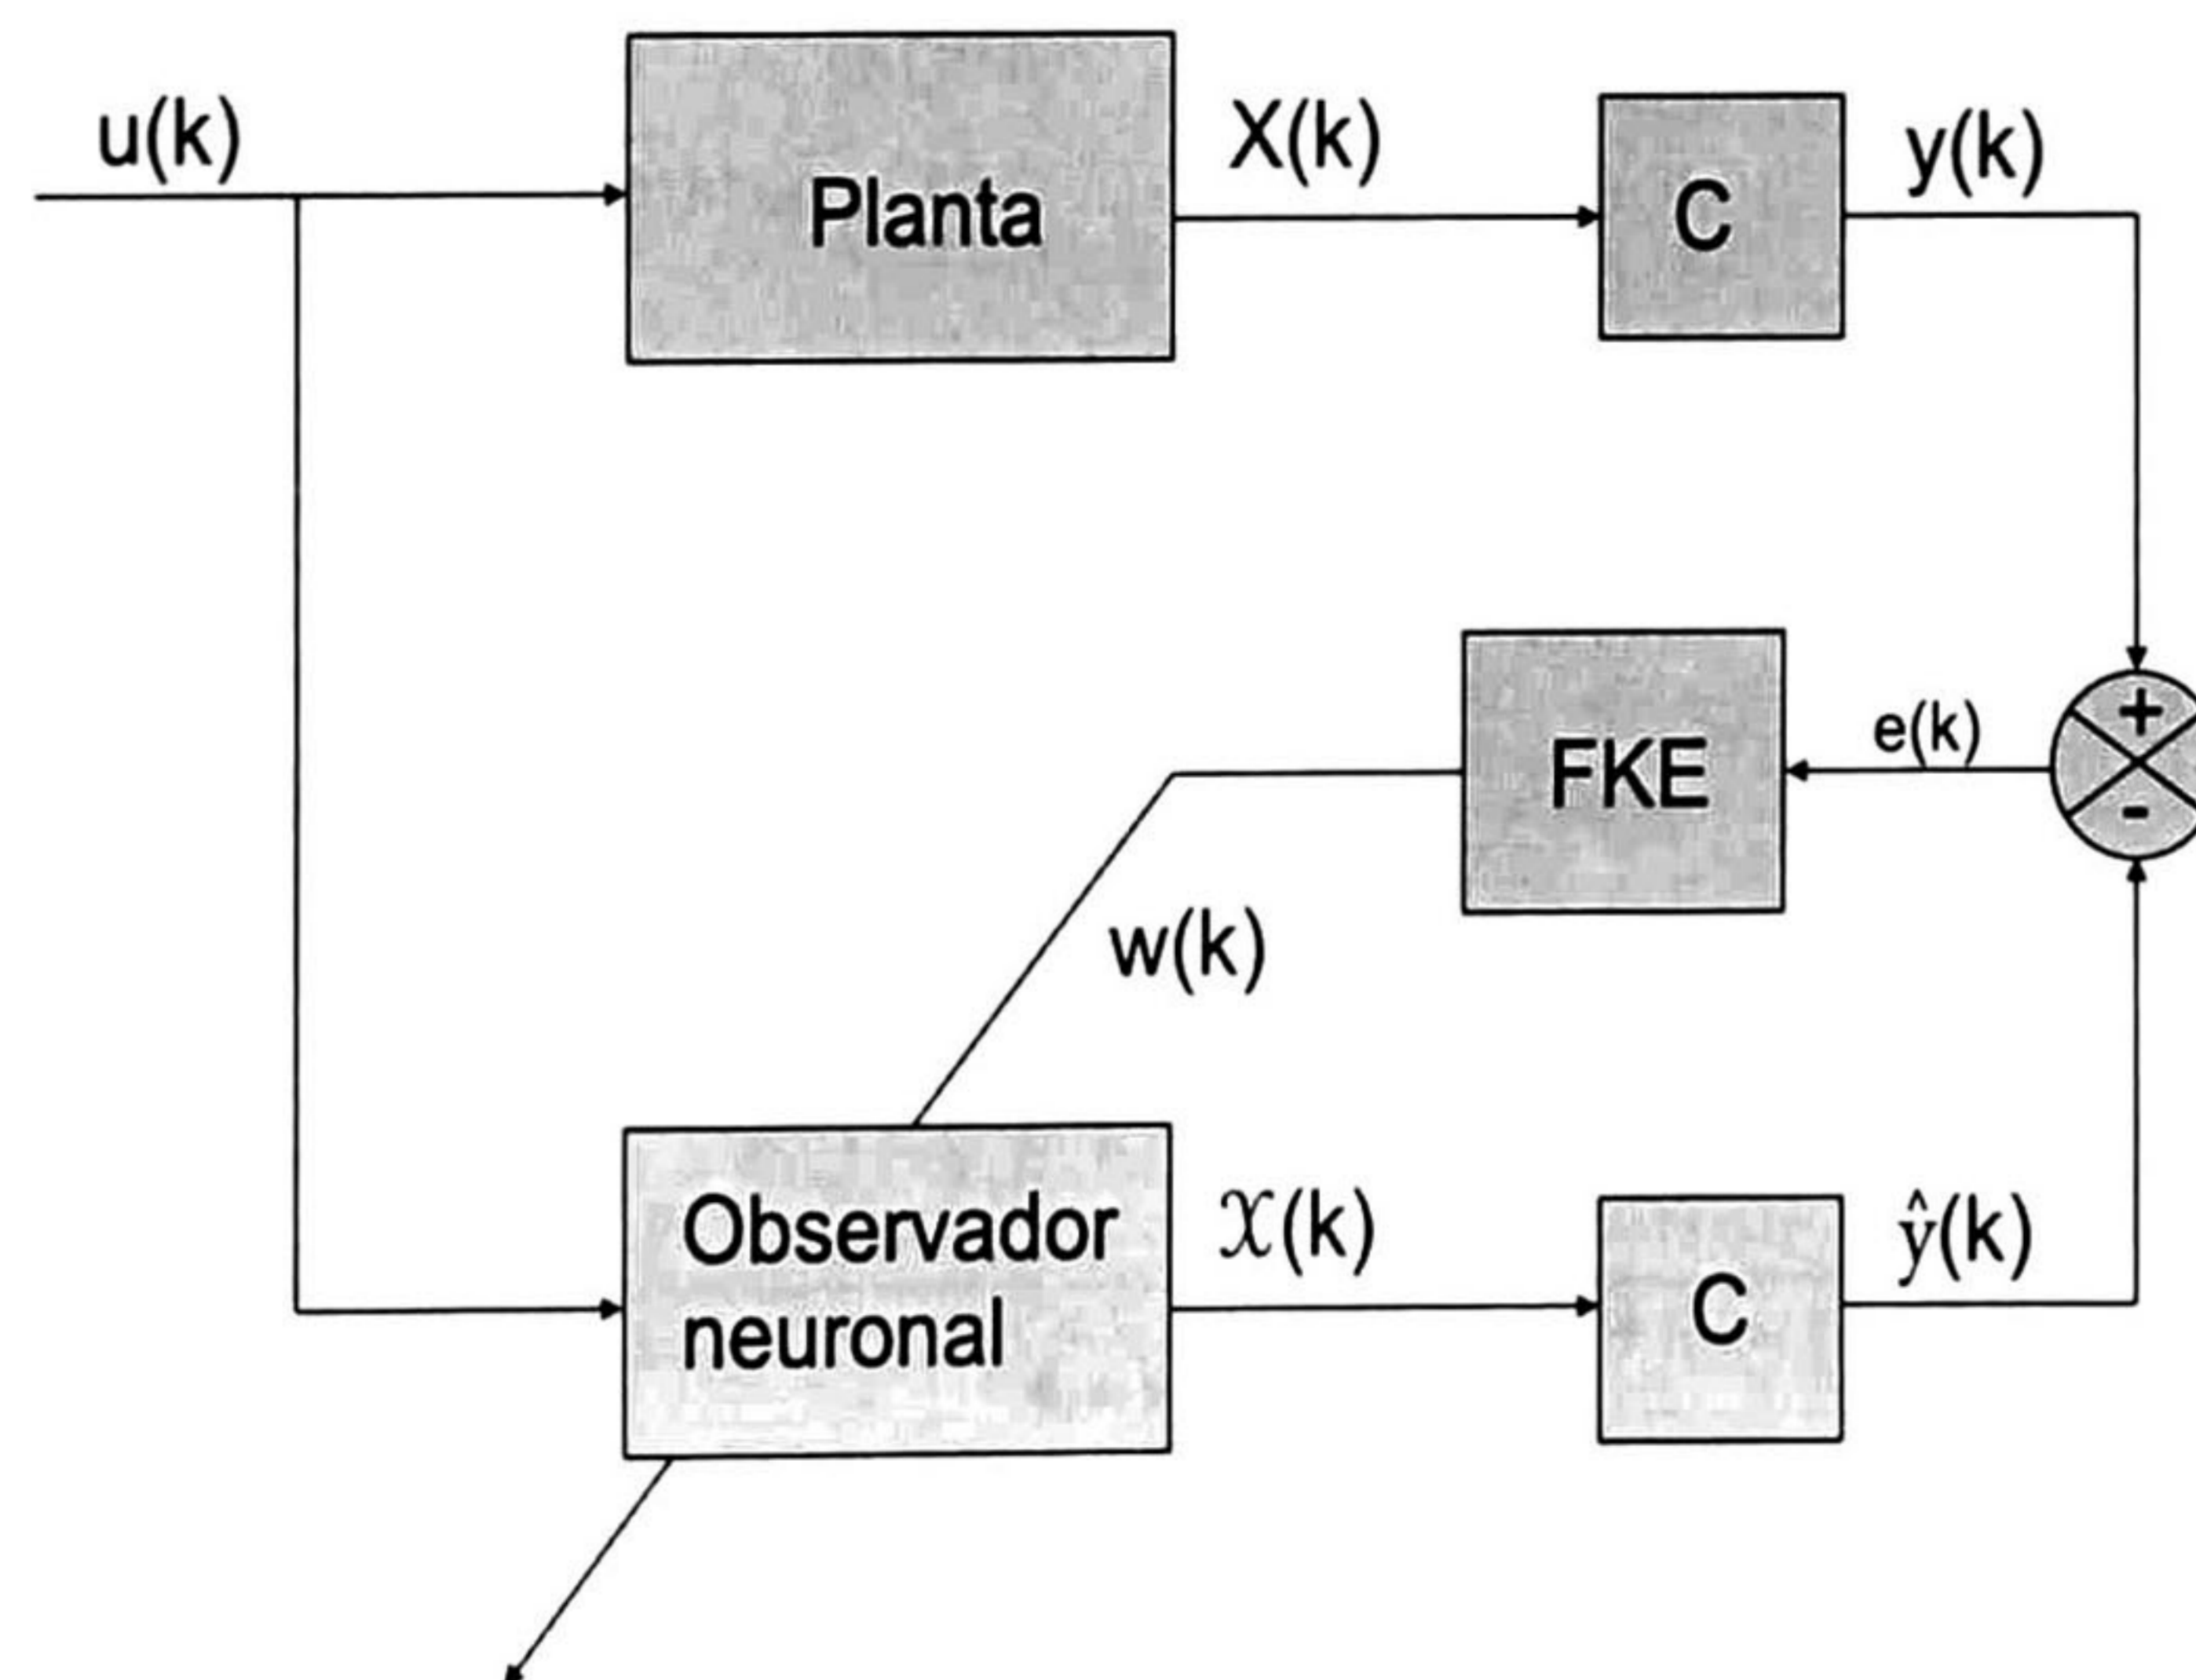


Fig. 6.1: Observador neuronal




Fig. 6.2: Posición del secundario








Fig. 6.3: Velocidad lineal

Fig. 6.4: Flujo en la fase α Fig. 6.5: Flujo en la fase β

Fig. 6.6: Corriente en la fase α Fig. 6.7: Corriente en la fase β




Fig. 6.8: Perturbación en la carga




Fig. 6.9: Perturbación en la resistencia del rotor

Capítulo 7

Conclusiones

- En este trabajo se presentan los resultados obtenidos al usar redes neuronales de alto orden para identificar un MIL, y control por modos deslizantes para el seguimiento de referencias. Los resultados fueron muy satisfactorios como se muestra en las simulaciones, aun ante la presencia de perturbaciones.
- El control en tiempo discreto no presenta el fenómeno conocido como cascabeleo, que ocurre en el control discontinuo por modos deslizantes.
- Por medio de la identificación neuronal se pueden obtener modelos cuyas dinámicas se comporten como la planta que se quiera aproximar.
- Se diseñó un observador neuronal de alto orden para estimar los flujos del MIL que no pueden ser medidos. El algoritmo de entrenamiento está basado en el filtro de Kalman extendido.

7.1 Trabajo futuro

Como trabajo futuro se propone:

- La implementación en tiempo real del algoritmo de identificación y control.
- Hacer un control basado en el observador neuronal desarrollado en esta tesis.

- Incluir el efecto de bordes longitudinales.

Bibliografía

- [1] A. S. Poznyak, E. N. Sanchez, and W. Yu. *Differential Neural Networks for Robust Nonlinear Control*. World Scientific Publishing Co., Singapore, 2001.
- [2] A. Y. Alanis. 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. Alanis. *Discrete-time Neural Control: Application to Induction Motors*. PhD Thesis, Centro de Investigación y Estudios Avanzados del IPN, Guadalajara, México, 2007.
- [4] A. Y. Alanis, E. N. Sanchez, and A. G. Loukianov. “Discrete-time recurrent neural induction motor using Kalman learning” *Proceedings of the International Joint Conference on Neural Network*, July 2006.
- [5] 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.
- [6] E. N. Sanchez and A. Y. Alanis. *Redes Neuronales: Conceptos Fundamentales y Aplicaciones a Control Automático*. Pearson Education, Madrid, España, 2006.
- [7] E. N. Sanchez, A. Y. Alanis, 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(DCDIS_B)*.
- [8] F. L. Lewis, S. Jagannathan, and A. Yesildirek. *Neural Network Control of Robot Manipulators and Nonlinear Systems*. Taylor & Francis, Philadelphia, U. S. A. 1999.

-
- [9] G. A. Rovithakis and M. A. Chistodoulou. *Adaptive Control with Recurrent High-Order Neural Networks*. Springer Verlag, Berlin, Germany, 2000.
- [10] H. A. Toliyat and G. B. Kliman. *Hanbook of Electric Motors*. Marcel Dekker Inc., U. S. A, 2004.
- [11] I. Boldea and S. A. Nasar. *Linear Electric Actuators and Generators*. Cambridge University Press, Cambridge, England, 1997.
- [12] I. Takahashi and Y. Ide. “Decoupling control of thrust and attractive force of a LIM using a space vector control inverter”, Vol. 29, pp. 161-167, *IEEE Trans. and Applicat.*, Jan 1993.
- [13] J. F. Gieras. *Linear Induction Drives*. Oxford University Press, Oxford, England, 1994.
- [14] J. L. Ricalde. *Inverse Optimal Adaptive Recurrent Neural Control with Constrained Inputs*. PhD Thesis, Centro de Investigación y Estudios Avanzados del IPN, Guadalajara, México, 2005.
- [15] J. Rivera. *Discrete-time Sliding Mode Control of an Induction Motor*. Tesis de Maestría, Centro de Investigación y Estudios Avanzados del IPN, Guadalajara, México, 2001.
- [16] N. Kazantsis and C. Kravaris. “Time-discretization of nonlinear control systems via Taylor methods”, Vol. 23, pp. 763-784, *Computer and Chemical Engineering*, 1999.
- [17] R. A. Felix, E. N. Sanchez, and A. G. Loukianov. “Avoiding controller singularities in adaptive recurrent neural network” *Proceedings IFAC’05*, July, 1996.
- [18] R. Grover and P. Y. C. Hwang. *Introduction to Random Signals and Applied Kalman Filtering*. John Wiley and Sons, N.Y., U.S.A., 1992.
- [19] S. Haykin. *Neural Network*. Prentice Hall, Deli, India, 1999.
- [20] S. Haykin. *Kalman Filtering and Neural Netorks*. John Wiley & Sons, New York, U.S.A., 2001.

-
- [21] 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.
- [22] V. H. Benitez. *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.
- [23] V. Utkin, J. Guldner, and J. Shi. *Sliding Mode Control in Electromechanical Systems*. Taylor & Francis, New Fetter Lane, London, 1999.
- [24] 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.

Anexo

Artículo generado de esta tesis.

Artículo en congreso aceptado

- M. Hernandez Gonzalez, E. N. Sanchez, A. G. loukianov. "Discrete-time Neural Network Control for a linear Induction Motor, *IEEE Multi-Conference on Systems and Control*, San Antonio, Texas, September 2008.

General Chair
Oscar González
 Old Dominion University,
 USA

Program Chair (CCA)
Gary Balas
 University of Minnesota,
 USA

Program Chair (CACSD)
Marco Lovera
 Politecnico di Milano, Italy

Program Chair (ISIC)
Kevin Moore
 Colorado School of Mines,
 USA

Invited Session Chair (CCA)
Luigi Glielmo
 Università del Sannio, Italy

Invited Session Chair
 (CACSD)
Nikos Karampetakis
 Aristotle University of
 Thessaloniki, Greece

Invited Session Chair (ISIC)
Warren Dixon
 University of Florida, USA

Workshops Chair
Suresh Joshi
 NASA Langley Research
 Center, USA

Best Student Paper Award
 Chair
Lalit K. Mestha
 Xerox Research Center,
 USA

IEEE CSS Conference
 Editorial Board Chair
Thomas Parisini
 University of Trieste, Italy

Publication Chair
Raúl Ordoñez
 University of Dayton, USA

Registration Chair
Simon Hecker
 German Aerospace Center,
 Germany

Finance Chair
Dimitrie Popescu
 Old Dominion University,
 USA

Exhibits Chair
Michael R. Moan
 Raytheon, USA

Publicity Chair
Fabio Previdi
 Università di Bergamo, Italy

Local Arrangements Co-
 Chairs
Chujiang "CJ" Qian
 The University of Texas at
 San Antonio, USA
Michael T. Frye
 University of the Incarnate
 Word, USA

May 27, 2008

Miguel Hernandez-Gonzalez
 Centro de investigacion y estudios avanzados
 Av. Cientifica 1145, Col. El Bajio, Zapopan, Jalisco
 45010 Guadalajara
 Mexico

Dear Miguel Hernandez-Gonzalez,

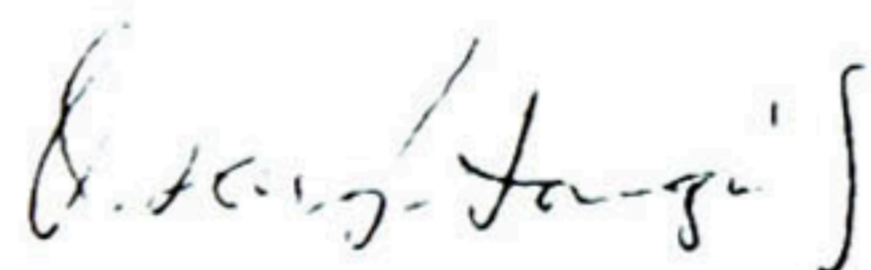
On behalf of the Organizing and the Program Committees, it gives me great pleasure to invite you to participate in the 2008 IEEE Multi-conference on Systems and Control (MSC 08), which will be held at the Hilton Palacio del Rio, San Antonio, Texas from September 2-5, 2008. The meeting is open to all those interested in the field of Control Systems. We are please to learn that you will be attending to present your accepted paper at the meeting.

The MSC is sponsored by the Control Systems Society of the Institute of Electrical and Electronics Engineers (IEEE). The 2008 MSC is the joint gathering of the International Conference on Control Applications (CCA), the International Symposium on Computer-Aided Control Systems Design (CACSD) and the International Symposium on Intelligent Control (ISIC).

Acceptance of your paper for presentation does not, in any way, financially oblige either the MSC 08 or the IEEE for the expenses incurred by you to travel and attend the conference.

Thank you in advance for your participation. I look forward to seeing you in San Antonio.

Sincerely,



Oscar R. Gonzalez
 General Chair, MSC 2008
 ogonzale@odu.edu

Accepted paper details.

Miguel Hernandez-Gonzalez, Edgar N. Sanchez, Alexander G. Loukianov, "Discrete-Time Neural Network Control for Linear Induction Motors." Scheduled for presentation on Friday September 5, 2008, 15:50-16:10 hrs.



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

**Control Neuronal Discreto del Motor de Inducción de
Desplazamiento Lineal**

del (la) C.

Miguel HERNÁNDEZ GONZÁLEZ

el día 22 de Agosto de 2008.

Dr. Edgar Nelson Sánchez Camperos
Investigador CINVESTAV 3D
CINVESTAV Unidad Guadalajara

Dr. Alexander Georgievich Loukianov
Investigador CINVESTAV 3C
CINVESTAV Unidad Guadalajara

**Dr. Arturo del Sagrado Corazón
Sánchez Carmona**
Investigador CINVESTAV 3B
CINVESTAV Unidad Guadalajara

Dr. José Manuel Cañedo Castañeda
Investigador CINVESTAV 3A
CINVESTAV Unidad Guadalajara



CINVESTAV
BIBLIOTECA CENTRAL



SSIT000006882