

**ESTIMACIÓN DE LA VELOCIDAD DEL MOTOR DE INDUCCIÓN EN EL
RANGO DE BAJA VELOCIDAD UTILIZANDO INTELIGENCIA ARTIFICIAL
PARA EL CONTROL VECTORIAL “SENSORLESS”**



MARTIN GALLO NIEVES

**UNIVERSIDAD DE PAMPLONA
FACULTAD DE INGENIERIAS Y ARQUITECTURA
MAESTRIA EN CONTROLES INDUSTRIALES
PAMPLONA, COLOMBIA**

2018

**ESTIMACIÓN DE LA VELOCIDAD DEL MOTOR DE INDUCCIÓN EN EL
RANGO DE BAJA VELOCIDAD UTILIZANDO INTELIGENCIA ARTIFICIAL
PARA EL CONTROL VECTORIAL “SENSORLESS”**

MARTIN GALLO NIEVES

Trabajo de investigación presentado como requisito parcial para optar al título de:
Magister En Controles Industriales

Director

Ph.D JAIME ANTONIO GONZALEZ CASTELLANOS

Codirector:

Ms.C. JORGE LUIS DIAZ

Línea de Investigación:

Control de máquinas eléctricas, electrónica de potencia

Grupo de Investigación:

Grupo de Investigación en Sistemas Energéticos

UNIVERSIDAD DE PAMPLONA

FACULTAD DE INGENIERIAS Y ARQUITECTURA

MAESTRIA EN CONTROLES INDUSTRIALES

PAMPLONA, 2018

DEDICATORIA

A Dios.

*Por iluminar el camino que debo seguir
y por haberme permitido llegar hasta
este punto, además de su infinita
bondad y amor.*

A mi esposa María Nathaly.

*Que ha sido una gran ayuda
incondicional, quien me apoyo en todo
momento que siempre me alentó a
seguir adelante.*

A mi hijo Andrés Santiago.

*Eres mi alegría, mi motivación la razón
que me levante cada día esforzarme
por un mejor mañana.*

*Y a todas las personas que creyeron
que podía salir adelante con este
proyecto.*

AGRADECIMIENTOS.

Agradezco a Dios por sus promesas “Te estarás preparando en lo intelectual” y hoy veo tu palabra cumplida, a mi director Jaime Antonio Gonzales por sus asesorías siempre dispuestas, su apoyo incondicional en todo momento y a mi codirector Jorge Luis por la orientación y ayuda que me brindó en la realización de la tesis.

TABLA DE CONTENIDO

INDICES DE FIGURAS	8
INDICES DE TABLAS	11
Lista de Símbolos y abreviaturas	12
CAPITULO I	16
1. INTRODUCCION	16
1.1 OBJETIVOS	16
1.1.1 Objetivo General	16
1.1.2 Objetivos Específicos	16
1.2 ESTADO DEL ARTE	17
CAPITULO 2	20
MODELADO DEL MOTOR DE INDUCCIÓN	20
2.1 Concepto de Motores de Inducción (MI).....	20
2.2 Componentes	20
2.3 Funcionamiento del motor de inducción.....	21
2.4 Velocidad del motor de inducción.....	22
2.5 Análisis del motor de inducción.....	22
2.5.1 Modelo del Voltaje para el motor de inducción.....	23
2.5.2 Modelo matemático del Motor de Inducción	24
2.5.3 Transformaciones de Clarke y de Park	27
2.5.3.1 Transformación de Clarke inversa $3 \rightarrow 2$	28
2.5.3.2 Transformación de Clarke $2 \rightarrow 3$	29
2.5.3.3 Transformación de Park inverso $\alpha\beta \rightarrow dq$	29
2.5.3.4 Transformación de Park $dq \rightarrow \alpha\beta$	30
2.5.4 Modelo del motor para simulación SIMULINK.....	30
2.5.5 Resultados de la simulación del motor de inducción.....	31
CAPITULO 3	35
CONTROL VECTORIAL DEL MOTOR DE INDUCCIÓN	35
3.1 Características del Control Vectorial (CV).....	35
3.2 Modelo del motor de inducción en campo orientado.....	36

3.3	Método de Control Vectorial Indirecto	40
3.3.1	Simulación del CV aplicado al motor de inducción.....	41
3.4	Inversor PWM con fuente de voltaje.....	42
CAPITULO 4		46
REDES NEURONALES ARTIFICIALES		46
4.1	Funcionamiento RNA	46
4.2.	Procesos de aprendizaje	49
4.2.1.	Aprendizaje supervisado	50
4.2.2.	Tareas de aprendizaje.....	51
4.2.2.1.	Asociación de patrones	51
4.2.2.2.	Reconocimiento de patrones.....	51
4.2.2.3.	Aproximación de funciones	52
4.2.2.4.	Control.....	53
4.2.2.5.	Filtrado	54
4.2.3.	Estimación de parámetros utilizando redes neuronales	54
4.2.3.1.	Estimación de los parámetros eléctricos.	56
4.2.3.2.	Modelo mecánico basado en RNA	56
4.2.4.	Estimación de velocidad.....	59
CAPITULO 5		60
IMPLEMENTACION DEL ESTIMADOR NEURONAL		60
5.1	Configuración de la Red Neuronal.	61
5.2	Entrenamiento del estimador neuronal.....	64
5.2.1	Entrenamiento con los datos del modelo del motor.....	64
5.2.2	Entrenamiento con los datos del banco de pruebas.....	67
5.3	Análisis de la simulación del estimador neuronal.....	72
5.4	Implementación de la estrategia de estimación para el CV.....	74
5.4.1	Tarjeta Raspberry Pi	74
5.4.2	Sensores de Corriente y Voltaje.....	76
5.4.3	Arduino Uno.	77
5.4.4	Motor de Inducción	77
5.4.5	Sensor de velocidad.....	78

5.4.6 Banco de pruebas.	80
CAPITULO VI.....	82
VALIDACIÓN DEL SISTEMA.....	82
CONCLUSIONES.....	88
BIBLIOGRAFIA	90

INDICES DE FIGURAS

Figura 1. Motor de Inducción, (Aller, 2006).	21
Figura 2. Representación esquemática de un MI (Barbi, s. f.).....	23
Figura 3. Modelo del motor de inducción. {Fuente: Propia}.....	27
Figura 4. Sistemas representativos abc y $\alpha\beta 0$	28
Figura 5. Diagrama de bloques de la transformación de Clarke INVERSA $3 \rightarrow 2$. 29	
Figura 6. Diagrama de bloques transformación de Clarke $2 \rightarrow 3$	29
Figura 7. Diagrama de bloques de la transformada inversa de PARK.	30
Figura 8. Diagrama de bloques de la transformada de PARK.....	30
Figura 9. Modelo del motor de inducción.	31
Figura 10. Señal de la velocidad del motor en vacío.	32
Figura 11. Torque del motor en condición de vacío.	33
Figura 12. Torque vs Velocidad del rotor en vacío.	33
Figura 13. Corrientes del estator con el eje de referencia d-q en el estator.	33
Figura 14. Corrientes del estator con el eje de referencia d-q girando a la velocidad sincrónica.	34
Figura 15. Diagrama vectorial de los ejes dq.	36
Figura 16. Modelo de corriente del MI en campo orientado. (Martínez, 2012).	39
Figura 17. Modelo del MI en campo orientado.	40
Figura 18. Esquema del CV indirecto.	41
Figura 19. Control de Velocidad del Motor por CV.	42
Figura 20. Respuesta del motor al control CV.....	42
Figura 21. Circuito excitador por fase. (Caicedo P., 2014).	43
Figura 22. Voltaje entre fase y tierra del puente inversor a 100 rpm	44
Figura 23. Voltaje entre dos fases del puente inversor a 100 rpm.	45
Figura 24. Voltaje entre dos fases del puente inversor a 500 rpm.	45
Figura 25. Estructura de una neurona.	47
Figura 26. Modelo de neurona artificial propuesto por McCulloch y Pitts. {Fuente: http://www.cs.us.es/~fsancho/?e=72 }.....	48
Figura 27. Esquema de aprendizaje supervisado.	50
Figura 28. Diagrama de bloques de la clonación de un sistema.	52
Figura 29. Diagrama de bloques de un proceso con un controlador RNA.	53
Figura 30. Modelo del motor de inducción en Simulink. Fuente: (Chan & Shi, 2011)	55
Figura 31. Esquema de entrenamiento para obtener ids y iqs. Fuente: (Chan & Shi, 2011)	56
Figura 32. Esquema propuesto para el entrenamiento de un modelo, basado en RNA, para la estimación de la velocidad del motor. (Chan & Shi, 2011).....	57

Figura 33. Arriba el esquema para realizar la comparación entre la data obtenida. Abajo, la velocidad de rotor del modelo (a) y la velocidad de rotor estimada (b). Fuente: (Chan & Shi, 2011).....	58
Figura 34. Esquema propuesto para la estimación de la velocidad del rotor. Fuente(Chan & Shi, 2011).....	59
Figura 35. Diagrama de bloques básico del estimador propuesto.....	60
Figura 36. Entradas a la red neuronal.....	61
Figura 37. Corrientes del modelo del motor.	62
Figura 38. Voltajes del modelo del motor.	62
Figura 39. Voltajes del motor con el banco de pruebas.	63
Figura 40. Corrientes del motor con el banco de pruebas.....	63
Figura 41. Modelo en Simulink del CV.	65
Figura 42. Entrenamiento de la RNA.....	66
Figura 43. Resultados del entrenamiento de la RNA.	67
Figura 44. Modelo en Simulink del CV para el banco de pruebas.....	68
Figura 45. Lectura de los datos de los sensores.....	69
Figura 46. Progreso del entrenamiento de la RNA.....	70
Figura 47. Resultados del entrenamiento.....	71
Figura 48. CV con el estimador neuronal.	72
Figura 49. Respuesta del estimador neuronal del modelo.	72
Figura 50. Respuesta del estimador neuronal con carga.	73
Figura 52. Diagrama en bloques del banco de pruebas.....	74
Figura 53. Raspberry Pi 3B (Cruceira Aragón & Gonzalez Sanchez, s.f.).....	75
Figura 54. Sensor de Corriente.	76
Figura 55. Sensor de voltaje.....	76
Figura 56. Motor trifásico Siemens.....	78
Figura 57. Sensor de velocidad.....	79
Figura 58. Disco ranurado.	79
Figura 59. Diagrama de bloques del modelo para el cálculo de la velocidad.....	79
Figura 60. Etapa de Control y Potencia.....	80
Figura 61. Banco de pruebas.	81
Figura 62. Diagrama de bloques usado para el estimador neuronal.....	82
Figura 63. Respuesta del estimador neuronal para 100 200, 300 y 600 rpm.....	83
Figura 64. Respuesta del estimador neuronal para 150, 300 y 400 rpm.....	84
Figura 65. Comportamiento del estimador neuronal en condición de carga para 150 rpm.....	85
Figura 66. Comportamiento del estimador neuronal en condición de carga para 200 rpm.....	86
Figura 67. Comportamiento del estimador neuronal en condición de carga para 200 rpm.....	86

Figura 68. Comportamiento del estimador neuronal en condición de carga para 300 rpm.	87
Figura 69. Comportamiento del estimador neuronal en condición de carga para 300 rpm.	87

INDICES DE TABLAS

Tabla 1. Datos del motor de inducción.....	32
Tabla 2. Funciones de activación comunes.....	49

Lista de Símbolos y abreviaturas

Símbolo	Término
V_S	Tensiones en los terminales del estator. [V]
V_R	Tensión en terminales del rotor[V]
R_S y R_R	Representación matricial de las resistencias del estator y del rotor. [Ohm]
X_m	Reactancia magnetizante. [Ohm]
X_{ls}	Reactancia de dispersión en el estator. [Ohm]
X'_{lr}	Reactancia de dispersión en el rotor referida al estator. [Ohm]
L_S	Inductancia en el estator. [H]
L_R	Inductancia en el rotor. [H]
v_{qs} y v_{ds}	Tensiones del estator en el eje de cuadratura. [V]
λ	Enlaces de flujo. [Wb]
i_{qs} y i_{ds}	Corrientes del estator en el eje de cuadratura. [A]
i_m	Corriente de magnetización. [A]
ρ	Ángulo de desacoplamiento.
T_e	Torque electromotriz. [N-m]
w	Velocidad angular. [Rad/s]
w_e	Velocidad angular sincrónica. [Rad/s]
w_r	Velocidad mecánica del rotor. [Rad/s]
ω_{sl}	Velocidad de deslizamiento. [Rad/s]

Abreviaturas

abreviaturas	Término
MI	Motor de Inducción.
CV	Control Vectorial.
PWM	Modulación por ancho de pulso.
RNA	Redes Neuronales Artificiales.

Resumen

En el presente trabajo se aborda el estudio, diseño e implementación de una técnica de estimación de velocidad, utilizando una Red Neuronal Artificial (RNA), para un motor de inducción trifásico tipo Jaula de Ardilla. El objetivo principal de dicha técnica es estimar la velocidad del motor a partir de las condiciones propias del mismo en baja velocidad, con la finalidad de aplicar control vectorial sin la utilización de un sensor de velocidad tradicional que realimente al lazo de control la velocidad de giro del motor. Al reemplazar el sensor tradicional por una RNA se obtiene un lazo de control tipo "Sensorless".

Como primera medida, se inicia con la obtención del modelo matemático del motor de inducción a utilizar. Una vez obtenido dicho modelo se procede a realizar la simulación del sistema de control sometido a diversas condiciones de trabajo. En una segunda instancia, se aplica la técnica de control vectorial, obteniendo el conjunto de ecuaciones pertinentes para el control de la velocidad del motor. El tercer paso consiste en modificar el lazo de control para sustituir el sensor de velocidad por la RNA, previamente entrenada.

El entrenamiento de la RNA a utilizar, se realiza recolectando data en diferentes rangos de velocidad del motor, tanto en vacío como con carga. La simulación del sistema se lleva a cabo en la plataforma Simulink, del paquete de software Matlab.

Como paso siguiente a la simulación del sistema, se implementa la estrategia de control utilizando la tarjeta Raspberry Pi 3B.

Abstract

In the present work the study, design and implementation of a speed estimation technique, using an Artificial Neural Network (ANN), for a three-phase induction motor type Squirrel Cage is approached. The main objective of this technique is to estimate the speed of the engine from its own conditions at low speed, in order to apply vector control without the use of a traditional speed sensor that feeds back to the control loop the speed of rotation the motor. When replacing the traditional sensor with an RNA, a "Sensorless" type control loop is obtained.

As a first step, it starts with obtaining the mathematical model of the induction motor to be used. Once this model is obtained, the simulation of the control system subjected to various working conditions is carried out. In a second instance, the technique of vectorial control is applied, obtaining the set of pertinent equations for the control of the speed of the motor. The third step is to modify the control loop to replace the speed sensor with the RNA, previously trained.

The training of the RNA to use, is done collecting data in different ranges of engine speed, both empty and loaded. The simulation of the system is carried out on the Simulink platform of the Matlab software package.

As a next step to the simulation of the system, the control strategy is implemented using the Raspberry Pi 3B card.

CAPITULO I

1. INTRODUCCION

1.1 OBJETIVOS

1.1.1 Objetivo General

Estimar la velocidad del motor de inducción en el rango de baja velocidad utilizando redes neuronales para el control vectorial “Sensorless”

1.1.2 Objetivos Específicos

- Determinar las ecuaciones matemáticas del modelo del motor de inducción para ser aplicadas en el control propuesto.
- Establecer las ecuaciones aplicadas para el Control Vectorial.
- Revisar y analizar la red neuronal artificial capaz de estimar la velocidad del Motor de Inducción.
- Implementar una estrategia de estimación de velocidad robusta ante las variaciones de condiciones propias del motor en baja velocidad.
- Validar el funcionamiento del modelo propuesto.

1.2 ESTADO DEL ARTE

En épocas relativamente recientes, en el campo de los Accionamientos de Velocidad Variable, se ha venido presentando un cambio significativo. Tradicionalmente, esta área ha sido dominada por los motores de corriente continua; sin embargo, hoy en día, cada vez más se ve como los motores de corriente alterna, tal como el motor de inducción de Jaula de Ardilla, vienen ganando terreno (Richardson & Caisse, Máquinas Eléctricas Rotativas y Transformadores, 1997), (Arnanzb, García, & Miguelc, 2016). Entre las ventajas que ofrecen estos motores frente a los de CC, se encuentran: robustez, menor peso, menor tamaño, menor costo y el requerimiento de menos mantenimiento. Por esto, se convierten en una opción muy viable a la hora de suministrar potencia mecánica en procesos industriales (Orille, Sowilam, & Valencia, 1999), Una de las dificultades que se presentan al utilizar este tipo de motores es que la velocidad depende tanto de la carga, como de la tensión de alimentación del motor. Para solventar este tipo de inconvenientes, se utilizan diversas estrategias para el control de velocidad. (Diaz & Pardo, 2006), (Markadeh & Soltani , 2006), (Arnanzb, García, & Miguelc, 2016). Dentro de las técnicas de control de velocidad del motor de inducción se pueden agrupar en las siguientes categorías:

- *Control escalar:*
 - *Control voltaje – frecuencia (v/f).*
 - *Control de la corriente del estator y de la frecuencia del deslizamiento (control del deslizamiento).*
- *Control vectorial:*
 - *Control por campo orientado (FOC) método indirecto.*
 - *método directo.*
 - *Control sin sensores. (Sensorless).*
- *Control directo del par. (DTC).*

El Control por Campo Orientado permite tener un control independiente de Flujo y Par, esto ayuda a tener un mejor rendimiento de la maquina controlando el torque, la velocidad y la posición del eje de la máquina, otra de las ventajas es generar un

Par máximo en bajas velocidades, alta eficiencia en un rango amplio de velocidades. (Alzate Gomes, Escobar Mejia, & Andres Torres, 2009).

Para implementar la técnica de control vectorial se requiere de la medición directa de la velocidad mecánica del motor de inducción. (Avendaño González & González Tamayo , 2013), (Aros & Aros, 2012). Esto ocasiona problemas de calibración en el accionamiento, efecto de carga, problemas de muestreo, entre otras. Por esto, se crea la necesidad de implementar nuevas estrategias de medición de velocidad, donde la misma se haga de forma indirecta (estimación) (Gunabalan & Subbiah, 2015), (Holtz, 2002).

Estimación de Velocidad

Desde la década de 1990, se vienen realizando trabajos enfocados en el control de la velocidad de motores de inducción tipo Jaula de Ardila, en los cuales se ve involucrada la estimación de velocidad, (Tajima & Hori, 1991), (Hirokazu & Hori, 1993), (Kanmachi & Takahashi, 1997), (Vas, Stronach, & Rashed, 1999), (Montanari, Peresada, & Tilli, 2000), (Aller & Restrepo, Junio de 2004), (Cheles, 2008). A partir de los avances hechos en el campo de la Inteligencia Artificial (IA) y su utilización en la electrónica de potencia, han surgido trabajos en los cuales se combinan las técnicas de IA y de control de motores de inducción. (Mehrotra, Quaicoe, & Venkatesan., 1996), (Yoon & Sang-Sun, 1998), (Sung-Hoe, Kyo-Beum, & Dong-Won, December 2005), (Sotelo Neyra , 2007), (Douiri & Nasser, 2010), (Hussain & Abid Bazaz, 2016), (Zolfaghari, Abbas Taher, & Vindel Munuz, Neural network-based sensorless direct power control of permanent magnet synchronous motor, 2016).

En el trabajo “aplicación de las redes neuronales en los sistemas de control vectorial de los motores de inducción” (Ali Sowilam G. , 2000), se utiliza la Inteligencia Artificial para realizar control vectorial y control directo del par de una máquina de inducción. Sin embargo, en este trabajo no se hace uso de la técnica de estimación.

En algunos de los trabajos donde se aplica la técnica de estimación de velocidad haciendo uso de RNA (González Castellanos & Pabón Vanegas, 2015),

(Barambones, 2009) la velocidad estimada presenta variaciones muy fuertes con respecto a la velocidad medida. Esto se debe, principalmente, al comportamiento de las señales de entrada, las cuales presentan un comportamiento inestable en la etapa transitoria del motor.

En el ámbito local, se han desarrollado trabajos que se enfocan en el control de velocidad de motores de inducción (Martínez Q, Díaz R, & Pardo G, 2012), donde se logran resultados aplicando la estimación de velocidad. Sin embargo, no se realiza implementación.

CAPITULO 2

MODELADO DEL MOTOR DE INDUCCIÓN

2.1 Concepto de Motores de Inducción (MI).

Los motores eléctricos trifásicos tipo jaula de ardilla son los más utilizados en los procesos industriales para el suministro de potencia mecánica. Esto es debido a sus características frente a otros tipos de motor, tales como, menor peso, bajo costo, baja robustez física (relación peso/potencia) y menor número de partes (lo cual disminuye los costos de mantenimiento). (João & Palma, 1999), (Richardson & Caisse, Máquinas Eléctricas Rotativas y Transformadores, 1997).

Chapman define el motor de inducción como: “Una máquina que sólo tiene un conjunto continuo de devanados de amortiguamiento se llama máquina de inducción.” (Chapman, 2012). Entonces, en un motor de inducción, el voltaje en el rotor (que es donde se genera el campo magnético y la corriente de rotor) no está presente físicamente en los conductores, sino que se induce en los devanados del rotor. Chapman, además, dice que “...La característica distintiva de un motor de inducción es que no se necesita de corriente de campo de cd para que la máquina funcione.”

2.2 Componentes

En la figura 1 se observan las partes típicas que componen un motor de inducción. Se compone de forma típica de las tapas laterales, el ventilador de enfriamiento, los cojinetes de bolas, la caja de terminales. Además, las dos partes principales del motor son el rotor y el estator. Wildi define estas partes como “El estator consta de un armazón de acero que soporta un núcleo cilíndrico hueco compuesto de laminaciones apiladas... El rotor también se compone de laminaciones ranuradas. Éstas están apiladas cuidadosamente para crear una serie de ranuras para el devanado del rotor. ” (Wildi, 2007).




Figura 1. Motor de Inducción, (Aller, 2006).

2.3 Funcionamiento del motor de inducción.

El funcionamiento de las máquinas asíncronas o de inducción se basa en el concepto de campo magnético giratorio (Fraile Mora, 2003), es decir, la corriente necesaria en el rotor para producir el torque se genera mediante la inducción electromagnética. El campo magnético proviene de la bobina del estator y es generado por la corriente que circula por uno de los devanados, por efecto de la FEM (Fuerza Electromotriz) aplicada. El nombre de máquinas asíncronas es debido a que “la velocidad de giro del rotor no es la de sincronismo impuesta por la frecuencia de la red eléctrica” (Fraile Mora, 2003), y, Fitzgerald, Kingsley, & Umans, definen el funcionamiento de la máquina de inducción de la siguiente forma: “...en un motor de inducción se suministra corriente alterna por inducción directamente al estator y al rotor o por acción del transformador al estator.” (Fitzgerald, Kingsley, Jr., & Umans, 2003). Los mismos autores, señalan que el rotor puede ser devanado con el mismo número de polos del estator, para ello, las terminales del rotor se conectan a los anillos colectores montados en la flecha y unas escobillas de carbón, que están

montadas en dichos anillos y expuestas en la parte externa del rotor completan el circuito del motor. Este tipo de rotor es muy inusual, debido a sus pocas aplicaciones. Otro tipo de rotor es el de inducción polifásico con un rotor de jaula de ardilla, con un devanado que son barras conductoras insertadas en ranuras y conectadas en corto circuito mediante anillos conductores. Un sistema más práctico, robusto y sencillo.

2.4 Velocidad del motor de inducción

Según Chapman (2012), si se aplica un voltaje trifásico a un motor de inducción van a fluir tres corrientes trifásicas; estas corrientes producen un campo magnético B_s que gira en sentido contrario a las manecillas del reloj. La velocidad de rotación del campo magnético está dada por la siguiente ecuación:

$$n_{sinc} = \frac{120f_e}{P} \quad (2.1)$$

Donde:

f_e es la frecuencia del sistema en Hertz.

P es el número de polos en la máquina.

2.5 Análisis del motor de inducción.

En la figura 2 se muestra un esquema de las máquinas de inducción trifásica. Este tipo de máquinas presentan estructuras magnéticas cilíndricas tanto en el rotor como en el estator; dichas estructuras son iguales en cada una de las partes del motor, con un desfase entre sí, (Barbi, s. f.). Además, dicho autor agrega; “La máquina de inducción con rotor en jaula también es simétrica, por las mismas razones expuestas. Sin embargo, el número de fases del rotor es superior a tres. De hecho, cada barra de la jaula constituye una fase”.




Figura 2. Representación esquemática de un MI (Barbi, s. f.).

2.5.1 Modelo del Voltaje para el motor de inducción.

El modelo de voltaje de un motor de inducción, está definido por la suma de la caída Óhmica más las ecuaciones de flujo; se representa a través de las siguientes ecuaciones; (Barbi, s. f.):

$$\mathbf{v}_s = \mathbf{R}_s \mathbf{i}_s + \mathbf{L}_{ss} \frac{d\mathbf{i}_s}{dt} + \mathbf{L}_{sr}(\theta) \frac{d\mathbf{i}_r}{dt} + \frac{\partial \mathbf{L}_{sr}(\theta)}{\partial \theta} \mathbf{i}_r \frac{d\theta}{dt} \quad (2.2)$$

Donde:

$$\mathbf{v}_r = \mathbf{R}_r \mathbf{i}_r + \mathbf{L}_{rr} \frac{d\mathbf{i}_r}{dt} + \mathbf{L}_{rs}(\theta) \frac{d\mathbf{i}_s}{dt} + \frac{\partial \mathbf{L}_{rs}(\theta)}{\partial \theta} \mathbf{i}_s \frac{d\theta}{dt} \quad (2.3)$$

En estas ecuaciones, v_s representa a las tensiones en los terminales del estator y v_r es la tensión en terminales del rotor que, para el caso del motor jaula de ardilla, es igual a cero. R_s y R_r son la representación matricial de las resistencias del estator y del rotor, respectivamente. Estas matrices son:

$$\mathbf{R}_S = \begin{bmatrix} R_S & 0 & 0 \\ 0 & R_S & 0 \\ 0 & 0 & R_S \end{bmatrix} \quad \mathbf{R}_R = \begin{bmatrix} R_R & 0 & 0 \\ 0 & R_R & 0 \\ 0 & 0 & R_R \end{bmatrix}$$

L_{SS} y L_{RR} , representan matricialmente las inductancias propias del estator y el rotor, respectivamente:

$$\mathbf{L}_{SS} = \begin{bmatrix} L_S & M_S & M_S \\ M_S & L_S & M_S \\ M_S & M_S & L_S \end{bmatrix}, \quad \mathbf{L}_{RR} = \begin{bmatrix} L_R & M_R & M_R \\ M_R & L_R & M_R \\ M_R & M_R & L_R \end{bmatrix}$$

$L_{SR(\theta)}$ y $L_{RS(\theta)}$, representan matricialmente las inductancias mutuas entre el estator y el rotor dependientes del ángulo θ . Pueden ser calculadas por:

$$\mathbf{L}_{SR(\theta)} = M_{SR} \begin{bmatrix} \cos \theta & \cos(\theta + \frac{2\pi}{3}) & \cos(\theta + \frac{4\pi}{3}) \\ \cos(\theta + \frac{4\pi}{3}) & \cos \theta & \cos(\theta + \frac{2\pi}{3}) \\ \cos(\theta + \frac{2\pi}{3}) & \cos(\theta + \frac{4\pi}{3}) & \cos \theta \end{bmatrix}$$

$$\mathbf{L}_{SR(\theta)} = \mathbf{L}_{RS(\theta)}^t$$

2.5.2 Modelo matemático del Motor de Inducción

Para aplicar la estrategia de control de velocidad del motor de inducción por campo orientado se hace necesario disponer de un modelo matemático que facilite el análisis del motor y la manipulación de las variables propias para el control. A continuación, se presentan las ecuaciones de tensión de la máquina trifásica asumiendo los ejes de referencias d-q. (Ali Sowilam G. , 2000), (Sánchez & Giraldo, 2008).

$$v_{qs} = p\lambda_{qs} + \lambda_{ds}\omega + r_s i_{qs} \quad (2.4)$$

$$v_{ds} = p\lambda_{ds} - \lambda_{qs}\omega + r_s i_{ds} \quad (2.5)$$

$$v'_{qr} = p\lambda_{qr} + \lambda'_{dr}(\omega - \omega_r) + r'_r i'_{qr} \quad (2.6)$$

$$v_{dr} = p\lambda'_{dr} - \lambda'_{qr} (\omega - \omega_r) + r'_{lr} i'_{dr} \quad (2.7)$$

Donde:

λ : son los enlaces de flujo.

v_{qs} y v_{ds} : tensiones del estator

v'_{qr} , v'_{dr} : tensiones del rotor que se asuman cero.

ω : es la velocidad angular del sistema de referencia arbitrario.

ω_r : es la velocidad angular del rotor.

Las ecuaciones para corriente son:

$$i_{qs} = \frac{1}{X'_{ls}} (\Psi_{qs} - \Psi_{mq}) \quad (2.8)$$

$$i_{ds} = \frac{1}{X'_{ls}} (\Psi_{ds} - \Psi_{md}) \quad (2.9)$$

$$i'_{qr} = \frac{1}{X'_{lr}} (\Psi'_{qr} - \Psi_{mq}) \quad (2.10)$$

$$i'_{dr} = \frac{1}{X'_{lr}} (\Psi'_{dr} - \Psi_{md}) \quad (2.11)$$

Donde:

i_{qs} y i_{ds} : son las corrientes del estator en los respectivos eje q y el eje d.

i'_{qr} y i'_{dr} : las corrientes del rotor en los ejes q y d referidas al estator

Asumiendo un nuevo cambio de variables, se tiene: $\Psi_{qs} = \omega_e \lambda_{qs}$

Siendo:

ω_e : la velocidad angular eléctrica base correspondiente a la frecuencia nominal.

X'_{ls} y X'_{lr} : reactancias de dispersión del estator y el rotor referidas al estator.

Las ecuaciones de tensión resultantes son:

$$\Psi_{mq} = X_m (i_{qs} + i'_{qr}) \quad (2.12)$$

$$\Psi_{md} = X_m (i_{ds} + i'_{dr}) \quad (2.13)$$

Reemplazando las ecuaciones de corrientes en las ecuaciones de voltaje se tiene que los voltajes en el eje q y el eje d referidas al estator y al rotor resultantes son:

$$\Psi_{qs} = \frac{\omega_e}{p} \left[v_{qs} - \frac{\omega}{\omega_e} \Psi_{ds} + \frac{r_s}{X_{ls}} (\Psi_{mq} - \Psi_{qs}) \right] \quad (2.14)$$

$$\Psi_{ds} = \frac{\omega_e}{p} \left[v_{ds} - \frac{\omega}{\omega_e} \Psi_{qs} + \frac{r_s}{X_{ls}} (\Psi_{md} - \Psi_{ds}) \right] \quad (2.15)$$

$$\Psi'_{qr} = \frac{\omega_e}{p} \left[v'_{qr} - \left(\frac{\omega - \omega_r}{\omega_e} \right) \Psi'_{dr} + \frac{r'_r}{X'_{lr}} (\Psi_{mq} - \Psi'_{qr}) \right] \quad (2.16)$$

$$\Psi'_{dr} = \frac{\omega_e}{p} \left[v'_{dr} - \left(\frac{\omega - \omega_r}{\omega_e} \right) \Psi'_{qr} + \frac{r'_r}{X'_{lr}} (\Psi_{md} - \Psi'_{dr}) \right] \quad (2.17)$$

La ecuación de Par:

$$T_e = \frac{n}{2} \frac{P}{2} \frac{1}{\omega_e} (\Psi'_{qr} i'_{dr} - \Psi'_{dr} i'_{qr}) \quad (2.18)$$

La ecuación de velocidad es:

$$\omega_r = \frac{1}{p} \frac{(M_e - M_l)}{\left(\frac{2}{P} \right) J \omega_e} \quad (2.19)$$

En la figura 3 se muestra el modelo del motor de inducción en el software SIMULINK. Dicho modelo no es más que la representación de las ecuaciones de las tensiones, enlaces de flujo, torque y velocidad, en los ejes q y d, referidas al estator y al rotor respectivamente. Teniendo este modelo en SIMULINK es posible realizar las simulaciones necesarias para analizar el comportamiento de la máquina.

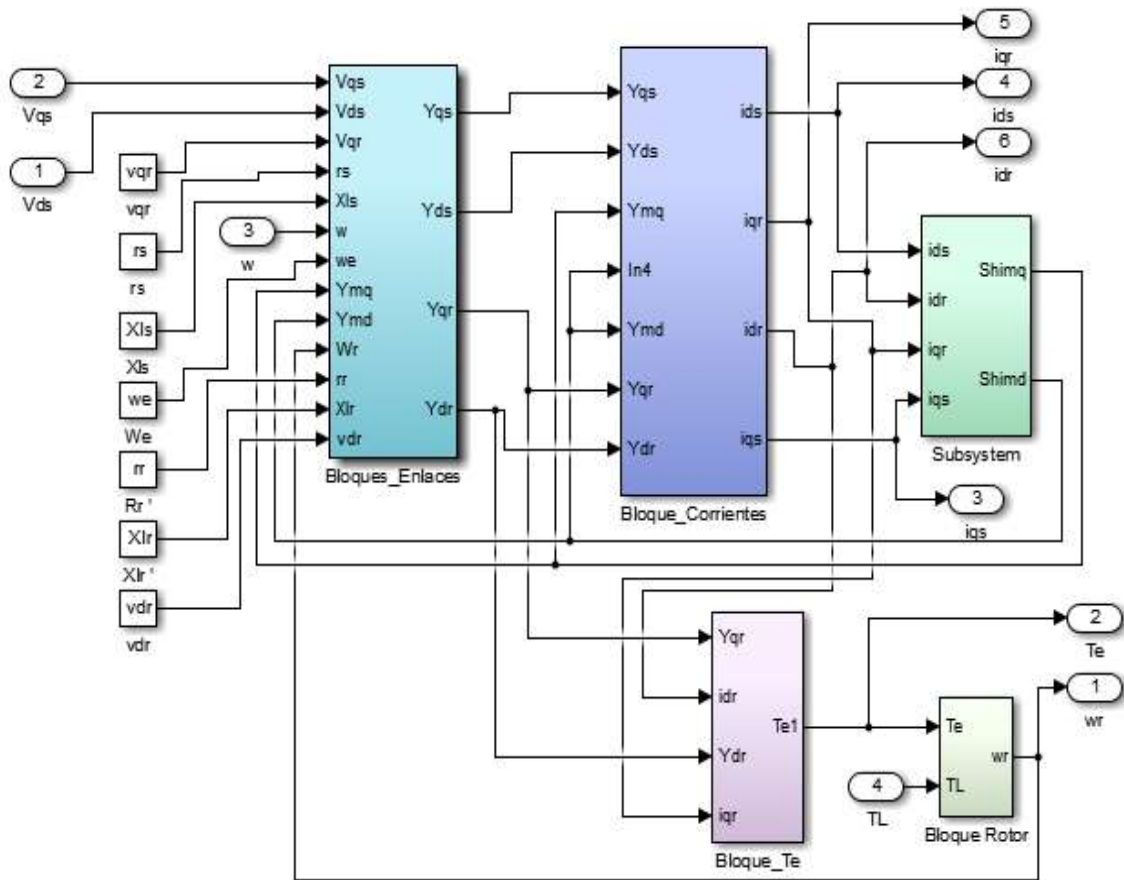


Figura 3. Modelo del motor de inducción. {Fuente: Propia}

2.5.3 Transformaciones de Clarke y de Park

Las transformadas de Clarke y de Park son metodologías utilizadas en el control de máquinas y consiste en hacer una manipulación matemática a las corrientes o tensiones de la máquina, de tal forma que se obtenga un sistema solidario al estator que represente el vector de corriente del estator y el vector de flujo del rotor, Figura 4. Sistemas representativos abc y $\alpha\beta 0$.

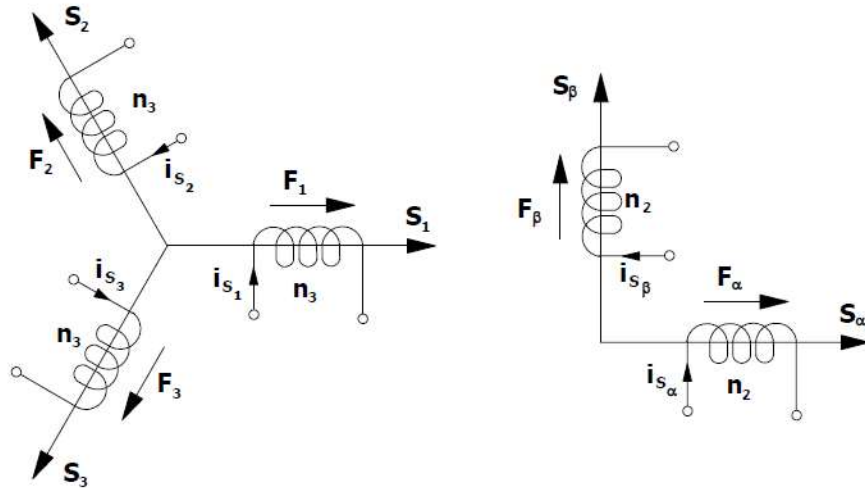


Figura 4. Sistemas representativos abc y αβ0.

2.5.3.1 Transformación de Clarke inversa 3 → 2

Según Barbi, (s. f.), la transformada inversa de Clarke, nos permite cambiar la referencia de un sistema abc a un sistema de dos ejes αβ0, que consiste en una transformación lineal que diagonaliza las matrices circulantes simétricas,

La descomposición vectorial F_1, F_2, F_3 , según los ejes S_α y S_β se llegan a las siguientes expresiones matemáticas:

$$F_{S_\alpha} = F_{S_1} + F_{S_2} \cos(2\pi/3) + F_{S_3} \cos(4\pi/3) \quad (2.20)$$

$$F_{S_\beta} = 0 + F_{S_2} \sin(2\pi/3) + F_{S_3} \sin(4\pi/3) \quad (2.21)$$

$$\begin{bmatrix} F_{S_\alpha} \\ F_{S_\beta} \end{bmatrix} = \begin{bmatrix} 1 & -1/2 & -1/2 \\ 0 & \sqrt{3}/2 & -\sqrt{3}/2 \end{bmatrix} \begin{bmatrix} F_{S_1} \\ F_{S_2} \\ F_{S_3} \end{bmatrix}$$

la transformación inversa de Clarke desarrollada en SIMULINK se presenta en la siguiente imagen:

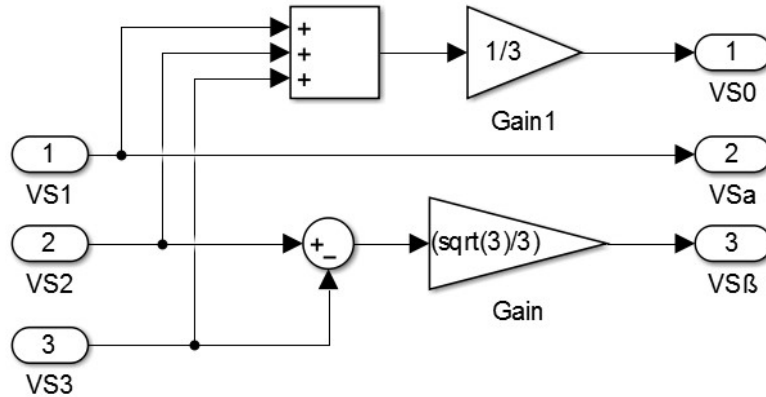


Figura 5. Diagrama de bloques de la transformación de Clarke INVERSA 3 → 2.

2.5.3.2 Transformación de Clarke 2 → 3

De forma similar la transformación de Clarke, gira nuevamente el sistema $\alpha\beta 0$, y lo lleva a las referencias iniciales abc; su representación desarrollada en SIMULINK es:

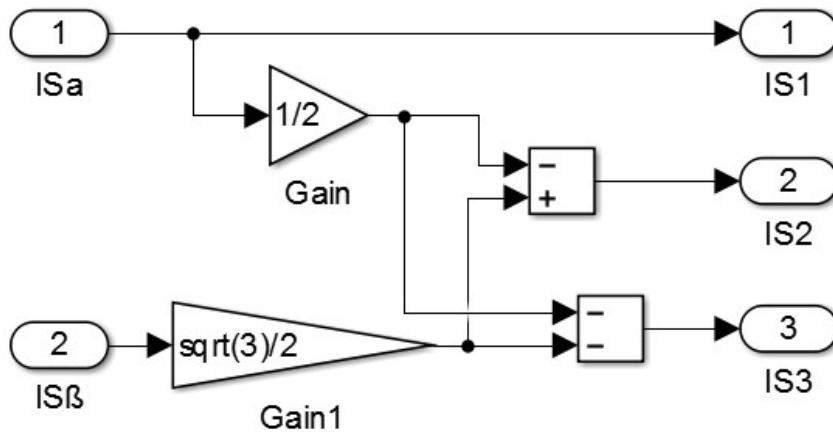


Figura 6. Diagrama de bloques transformación de Clarke 2 → 3.

2.5.3.3 Transformación de Park inverso $\alpha\beta \rightarrow dq$

Los métodos de representación modal desacoplan las ecuaciones simétricas de los sistemas de potencia. La transformación de Park Inverso, su representación desarrollada en SIMULINK es:

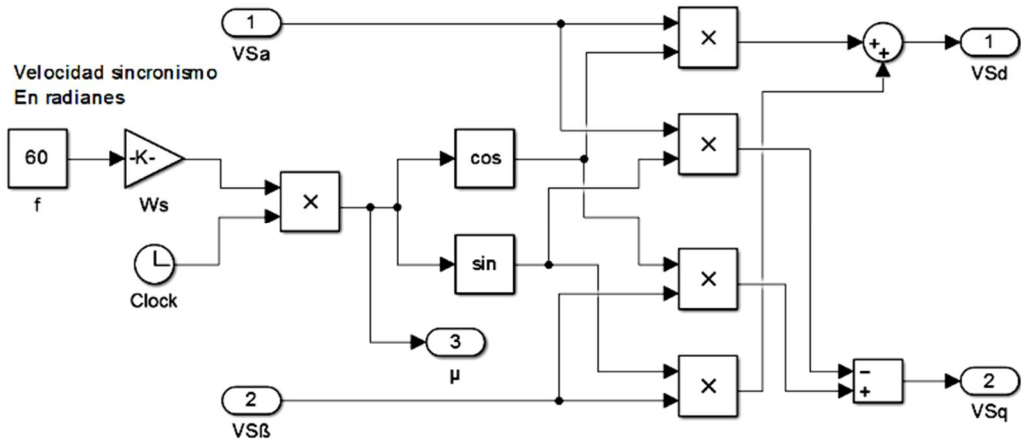


Figura 7. Diagrama de bloques de la transformada inversa de PARK.

2.5.3.4 Transformación de Park $dq \rightarrow \alpha\beta$

De forma similar la transformada de Park, su representación desarrollada en SIMULINK es:

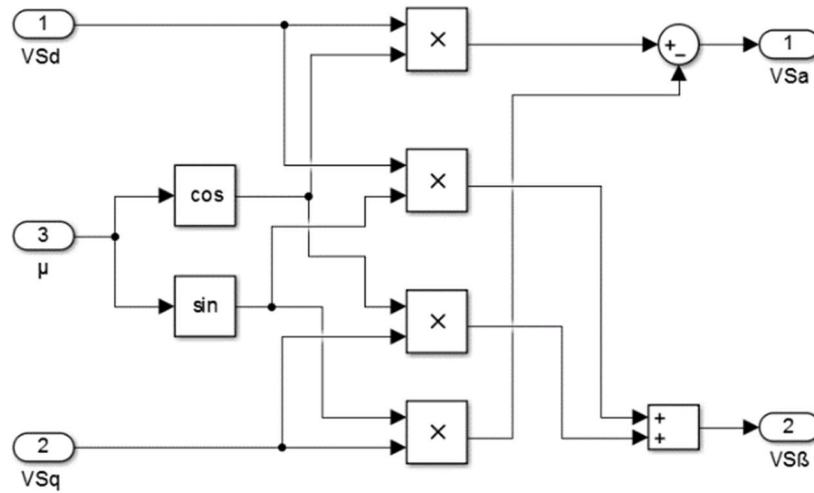


Figura 8. Diagrama de bloques de la transformada de PARK.

2.5.4 Modelo del motor para simulación SIMULINK

El modelo del motor de inducción se desarrolló matemática y matricialmente, basados en las expresiones de tensión, torque, las transformadas de CLARKE y PARK; Figura 9. Modelo del motor de inducción. Todo el modelo inicia con una fuente trifásica que proporciona las tres señales de voltaje V_{s1} , V_{s2} y V_{s3}

desfasadas mutuamente 120° , a esta señal de tensiones se le aplica la transformada inversa de CLARKE, para simplificar la simulación cambiando de un sistema polifásico de tres señales a uno de dos señales, V_α , V_β y V_0 ; el siguiente bloque es la transformada de PARK, la cual rota las dos señales de tensión V_α , V_β y las reorienta a las señales V_q y V_d , requeridas por el motor; el siguiente bloque es la representación del motor eléctrico de inducción.

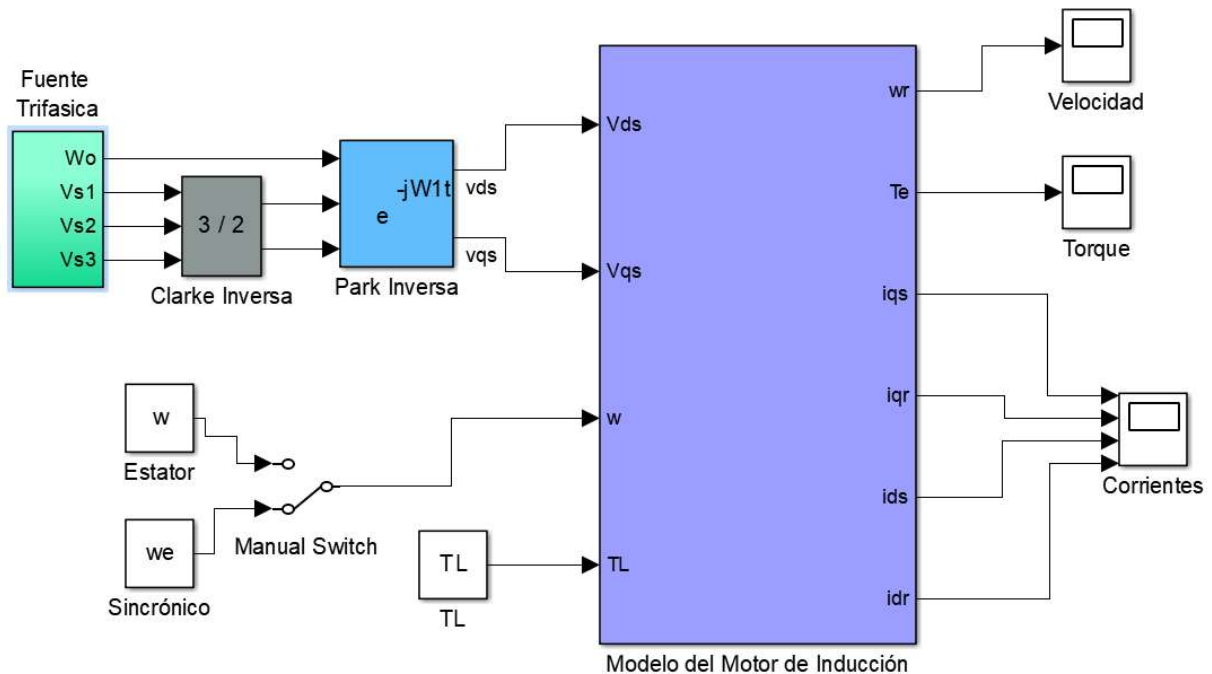


Figura 9. Modelo del motor de inducción.

2.5.5 Resultados de la simulación del motor de inducción.

Obteniendo el modelo del motor de inducción con la fuente trifásica y las transformaciones de Clark y Park, con los ejes de referencia (d-q), funcionando en vacío se procede a obtener las características de velocidad del rotor, torque y corrientes del estator con los sistemas de referencia fijado tanto en el estator $w=0$, como fijado al campo $w=w_e$, desarrolladas en Simulink. A partir del modelo mostrado en la figura 9 y utilizando los parámetros eléctricos del motor dados en la tabla 1, se obtienen los siguientes resultados.

Tabla 1. Datos del motor de inducción.

Elemento	Valor
r_s	10.43 (ohm)
r_r	84.26(ohm)
L_r	144.6(mH)
M	35.4(mH)
P	4 polos
J	0.022 Kg-m ²
L_m	136.0 (mH)

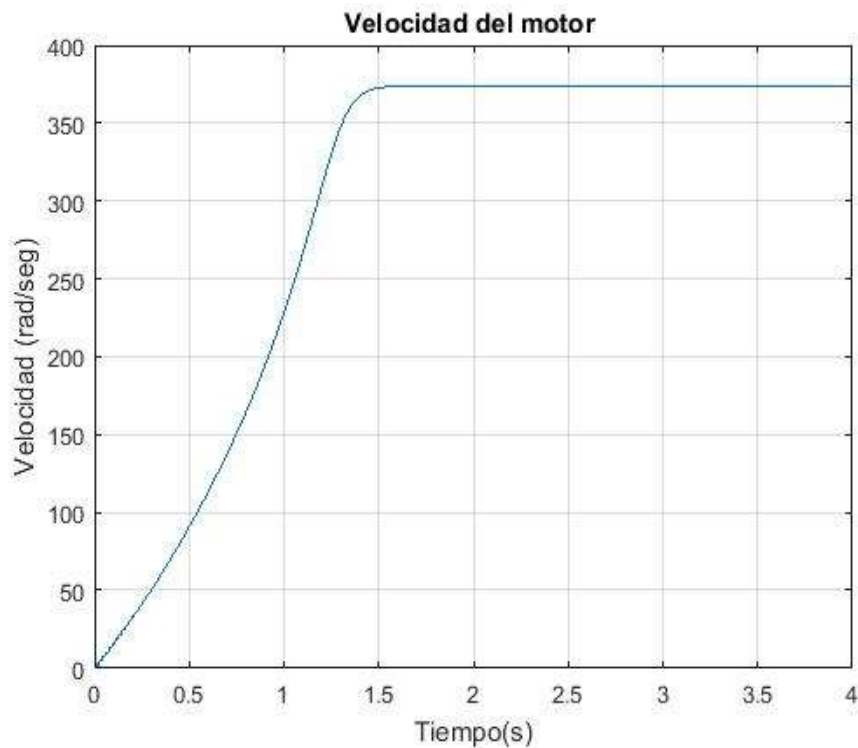


Figura 10. Señal de la velocidad del motor en vacío.

La señal de velocidad resultante del modelo del motor de inducción se observa en la figura 10, donde muestra que la velocidad del motor alcanzó los 377 rad/seg en 1.5 segundos.




Figura 11. Torque del motor en condición de vacío.




Figura 12. Torque vs Velocidad del rotor en vacío.

El torque en función del tiempo del motor de inducción en condición de vacío se observa en la figura 11 y el torque en función de la velocidad del rotor en vacío se observa en la figura 12.

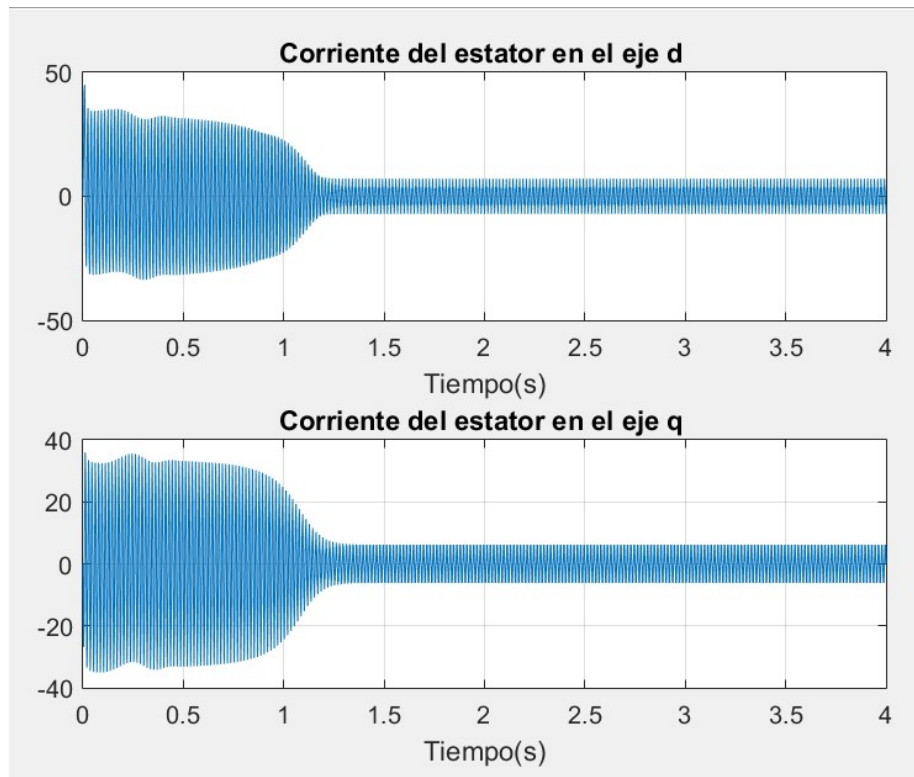


Figura 13. Corrientes del estator con el eje de referencia d-q en el estator.

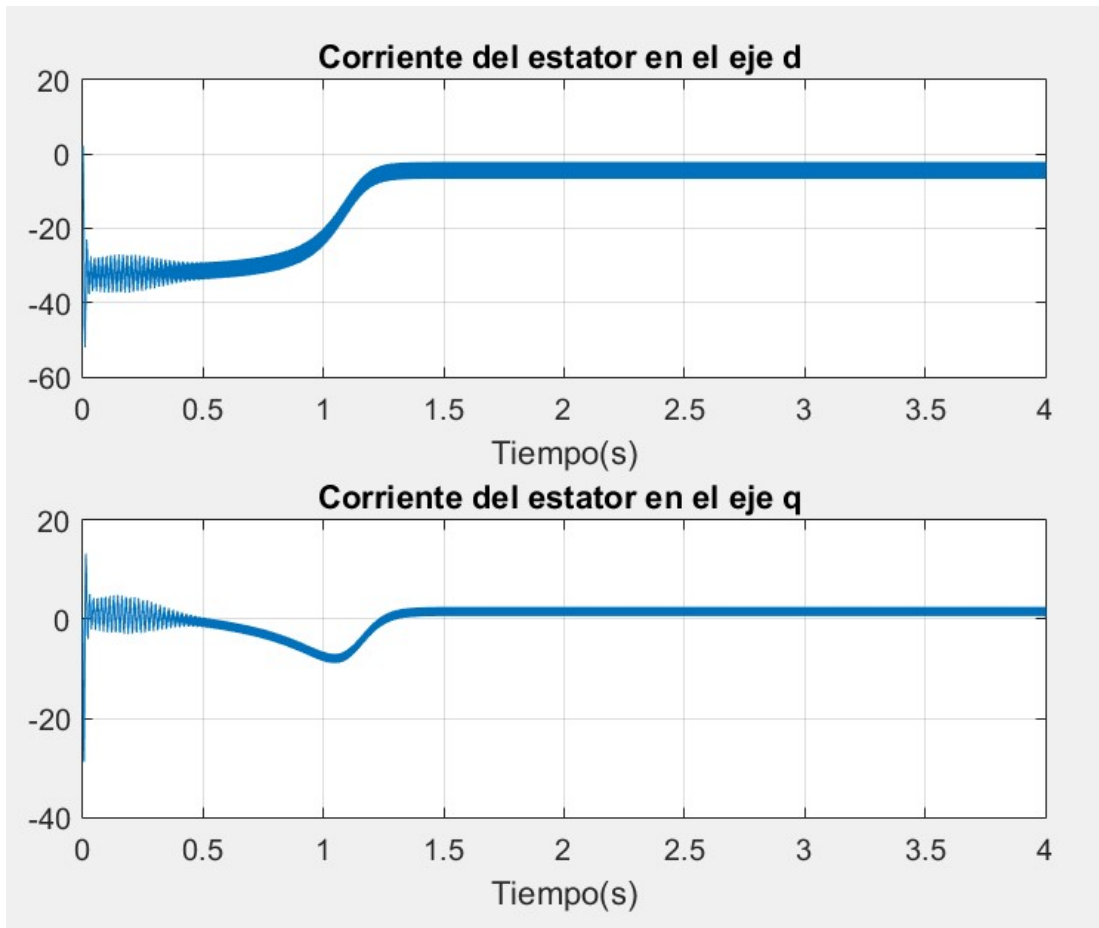


Figura 14. Corrientes del estator con el eje de referencia d-q girando a la velocidad sincrónica.

En las figuras 13 y 14, muestran las corrientes de motor con el eje de referencia d-q, en las dos posiciones tanto en el estator como en el sincrónico en vacío.

En la figura 14 representan las mismas corrientes de la figura 13, solo que en la figura 14 el eje de referencia se ha posicionado intencionalmente girando a la velocidad sincrónica al hacer esto los efectos senoidales desaparecen, tal como se observan en dicha figura.

CAPITULO 3

CONTROL VECTORIAL DEL MOTOR DE INDUCCIÓN

Una vez obtenido el modelo matemático que representa el comportamiento dinámico del motor de inducción, se procede a establecer el conjunto de ecuaciones necesarias para aplicar la estrategia de control vectorial indirecto de la máquina de inducción. Utilizando el entorno SIMULINK, se realizan simulaciones donde se observa la respuesta del motor de inducción controlado mediante el control vectorial.

3.1 Características del Control Vectorial (CV)

El control vectorial, también llamado Control por Campo Orientado (En inglés FOC, *Field Oriented Control*), fue propuesto por Kakhim (Kakhim, Rezak, & O'Kelly) y Hasse.K (Blaschke, May 1972). Esta estrategia permite controlar de manera independiente el flujo de campo magnético y el par electromagnético; esto se logra reduciendo el modelo no lineal del motor a un modelo referido a dos ejes ortogonales d y q , lo que permite que el motor de inducción sea modelado de la misma forma que un motor de corriente continua de excitación separada, pasando así de un sistema trifásico a un sistema bifásico utilizando vectores espaciales y la transformación a un sistema de ejes dq . Al hacer esto, es posible controlar el flujo por medio de la regulación de la componente de corriente del eje directo d , mientras que el par se controla regulando la corriente asociada al eje ortogonal q .

Existen tres posibilidades en la elección del sistema de ejes que cumplan esta condición, dando lugar a los siguientes métodos de control vectorial:

- *Control en coordenadas de flujo de estator.*
- *Control en coordenadas de flujo de rotor (campo orientado).*
- *Control en coordenadas de flujo de entrehierro.*

En la figura 15 se presenta el diagrama vectorial, siendo los ejes de coordenadas α y β estacionarios, y d y q las componentes de los ejes vectoriales, los cuales están girados un ángulo ρ . Una de las condiciones del control en campo orientado es

posicionar el vector de flujo sobre el eje d para que la corriente de cuadratura sea cero ($i_q=0$); otra condición es mantener constante el flujo de manera que el par sea proporcional a la variación de la corriente en el eje q, así, el motor se controla indirectamente a través de la corriente del estator que tiene dos componentes \vec{i}_{sd} y \vec{i}_{sq} , donde la parte real (\vec{i}_{sd}), controla el flujo, y la parte imaginaria (\vec{i}_{sq}) controla el torque.

$$\vec{i}_s = \vec{i}_{sd} + j \vec{i}_{sq}$$

$\vec{i}_{sd} \propto \lambda$: Corriente del estator en la componente d proporcional al flujo.

$\vec{i}_{sq} \propto T_e$: Corriente del estator en la componente q proporcional al torque.

$\vec{i}_{mr} = \frac{\bar{\lambda}_r}{L_m}$; Corriente de magnetización. (que produce el flujo).




Figura 15. Diagrama vectorial de los ejes dq.

3.2 Modelo del motor de inducción en campo orientado.

Para aplicar la estrategia de control vectorial en campo orientado al motor de inducción, se requiere modificar el modelo del motor previamente obtenido para llevarlo a una forma en función de corrientes, con la finalidad de obtener el flujo y el torque relacionadas a las corrientes del estator. Esto se consigue reescribiendo las

ecuaciones de voltaje del motor en función de la variable manipulada (corriente de estator) y las variables controladas (flujo y torque).

$$\vec{V}_s = R_s \cdot \vec{i}_s + \frac{d\vec{\lambda}_s}{dt} + j\omega \cdot \vec{\lambda}_s \quad (3.1)$$

$$\vec{V}_r = R_r \cdot \vec{i}_r + \frac{d\vec{\lambda}_r}{dt} + j(\omega - \omega_r) \cdot \vec{\lambda}_r \quad (3.2)$$

$$\vec{\lambda}_s = L_s \cdot \vec{i}_s + L_m \cdot \vec{i}_r \quad (3.3)$$

$$\vec{\lambda}_r = L_m \cdot \vec{i}_s + L_r \cdot \vec{i}_r \quad (3.4)$$

$$\vec{i}_s = \frac{1}{\sigma L_s} \cdot \vec{\lambda}_s - \frac{L_m}{\sigma L_s L_r} \cdot \vec{\lambda}_r \quad (3.5)$$

$$\vec{i}_r = -\frac{L_m}{\sigma L_s L_r} \cdot \vec{\lambda}_s - \frac{1}{\sigma L_r} \cdot \vec{\lambda}_r \quad (3.6)$$

$$\vec{\lambda}_r = \vec{i}_{mr} \cdot L_m \quad (3.7)$$

Reescribiendo las ecuaciones de voltajes de motor de inducción tomando el flujo del estator (Ec. 3.3), la corriente del rotor (Ec. 3.6) y teniendo en cuenta la ecuación 3.7. da como resultado las ecuaciones 3.8 y 3.9 quedando en función de corrientes (la corriente del estator y la corriente de magnetización).

$$\vec{V}_s = R_s \cdot \vec{i}_s + \frac{L_m^2}{L_r} \cdot \frac{d\vec{i}_{mr}}{dt} + \sigma L_s \cdot \frac{d\vec{i}_s}{dt} + j\omega_{mr} \frac{L_m^2}{L_r} \cdot \vec{i}_{mr} + j\omega_{mr} \sigma L_s \cdot \vec{i}_s \quad (3.8)$$

$$0 = R_r \frac{L_m}{L_r} \cdot \vec{i}_s + R_r \frac{L_m}{L_r} \cdot \vec{i}_{mr} + L_m \cdot \frac{d\vec{i}_{mr}}{dt} + j(\omega_{mr} - \omega_r) L_m \cdot \vec{i}_{mr} \quad (3.9)$$

Las siguientes expresiones matemáticas son las que modelan la dinámica del motor de inducción en campo orientado en un sistema que gira a la velocidad del flujo del rotor.

$$i_{ds}(s) = i_{mr}(s) + \tau_r s \cdot i_{mr}(s) \quad (3.10)$$

$$\frac{i_{mr}(s)}{i_{ds}(s)} = \frac{1}{1 + \tau_r s} \quad (3.11)$$

$$\frac{\lambda_r(s)}{i_{ds}(s)} = \frac{L_m}{1 + \tau_r s} \quad (3.12)$$

$$w_{sl} = \frac{i_{qs}}{\tau_r \cdot i_{mr}} = \frac{L_m i_{qs}}{\tau_r \cdot \lambda_r} = w_{mr} - w_r \quad (3.13)$$

$$w_{mr} = w_r + \frac{i_{qs}}{\tau_r \cdot i_{mr}} = w_r + \frac{L_m i_{qs}}{\tau_r \cdot \lambda_r} = w_r + w_{sl} \quad (3.14)$$

$$T_e = \frac{3}{2} \frac{P}{2} \frac{L_m}{L_r} \cdot \lambda_r \cdot i_{qs} = \frac{3}{2} \frac{P}{2} \frac{L_m^2}{L_r} \cdot i_{mr} \cdot i_{qs} \quad (3.15)$$

$$J s w_r + B w_r = \frac{P}{2} (T_e - T_c) \quad (3.16)$$

$$\rho = \int w_{mr} dt \quad (3.17)$$

Siendo:

i_{ds} : la corriente del estator en el eje d,

i_{mr} : corriente de magnetización.

λ_r : flujo en el rotor.

w_{sl} : velocidad de deslizamiento.

ρ : ángulo de desacoplamiento.

T_e : par eléctrico.

En la figura 16, se presenta el diagrama en bloques del modelo de corriente del motor en campo orientado.

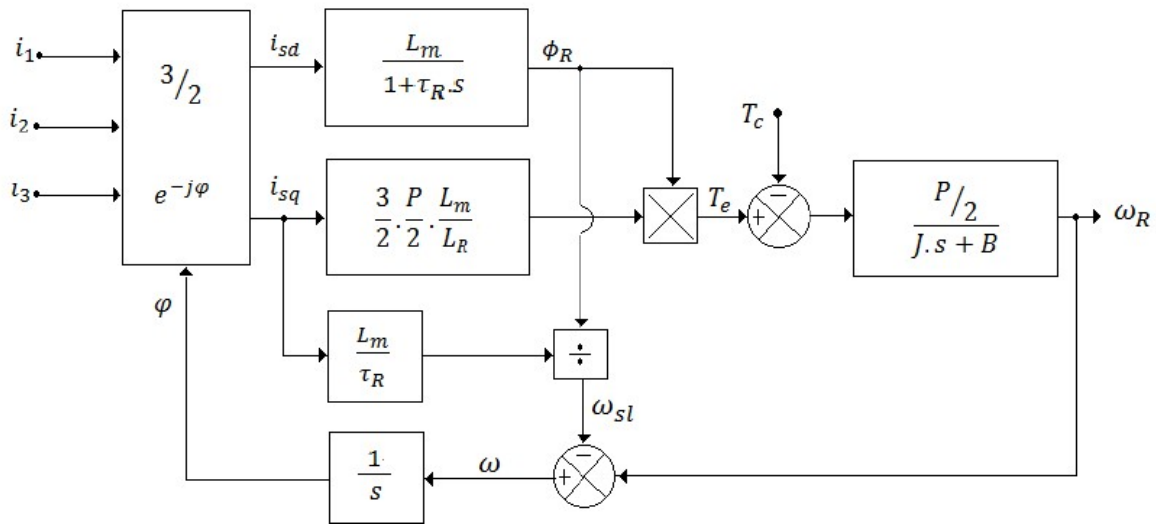


Figura 16. Modelo de corriente del MI en campo orientado. (Martínez, 2012).

A continuación, se presentan las ecuaciones de voltaje aplicadas al modelo de corriente del motor:

$$\sigma \tau_s \cdot \frac{di_{ds}}{dt} + i_{ds} = \frac{V_{ds}}{R_s} + \omega_{mr} \sigma \tau_s \cdot i_{qs} - (1 - \sigma) \tau_s \cdot \frac{di_{mr}}{dt} \quad (3.18)$$

$$\sigma \tau_s \cdot \frac{di_{qs}}{dt} + i_{qs} = \frac{V_{qs}}{R_s} - \omega_{mr} \sigma \tau_s \cdot i_{ds} - (1 - \sigma) \omega_{mr} \tau_s \cdot i_{mr} \quad (3.19)$$

Donde:

$$\sigma = 1 - \frac{L_m^2}{L_s L_r}; \text{ Coeficiente de dispersión o de Blondel.}$$

El diagrama de bloques el modelo del motor de inducción en campo orientado se muestra en la figura 17, siendo las entradas del modelo las tensiones trifásicas, desfasadas 120° y la carga del motor (es decir, el trabajo que debe realizar dicha

máquina). A la salida del modelo se tiene el flujo, el torque, las corrientes y la velocidad del motor.

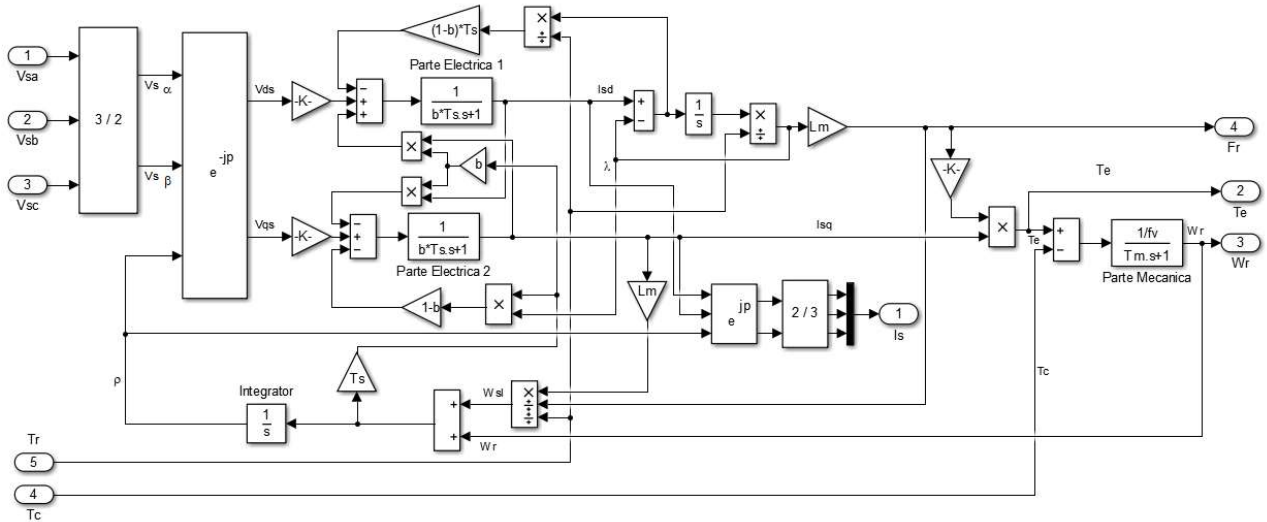


Figura 17. Modelo del MI en campo orientado.

3.3 Método de Control Vectorial Indirecto

El ángulo ρ para el método de control indirecto, se obtiene a través del cálculo de deslizamiento, aplicando la ecuación 3.22. La figura 18 muestra el esquema general indirecto de control vectorial, siendo las entradas de dicho sistema las corrientes i_{ds} (valores de referencia de flujo) y i_{qs} (valores de referencia del par).

$$\lambda_r(s) = \frac{L_m}{1 + \tau_r s} i_{ds}(s) \quad (3.20)$$

$$w_{sl} = \frac{L_m i_{qs}}{\tau_r \cdot \lambda_r} \quad (3.21)$$

$$w_{sl} = \frac{L_m i_{qs}}{\tau_r \cdot \lambda_r} = \frac{1}{\tau_r} \frac{i_{qs}}{i_{ds}} (\tau_r s + 1) \quad (3.22)$$

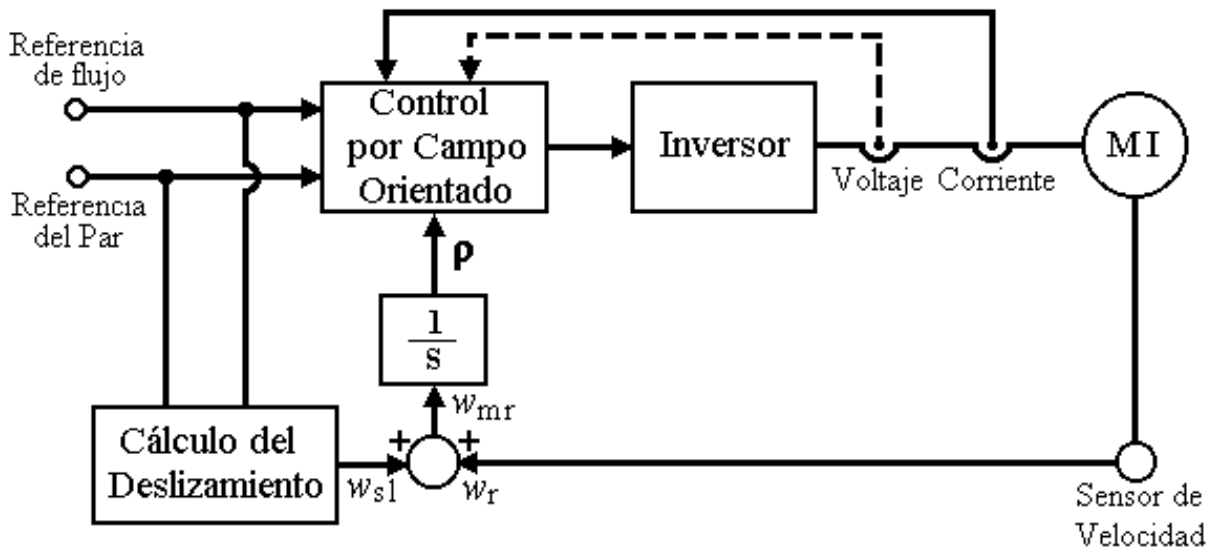


Figura 18. Esquema del CV indirecto.

3.3.1 Simulación del CV aplicado al motor de inducción

El bloque del motor de inducción en campo orientado, junto con el bloque de control vectorial, se ilustran en la figura 19. El bloque “Vref” es la velocidad de referencia y el bloque “Torque de la carga” representa el trabajo que realiza el motor. Los bloques “flujo”, “torque” y “velocidad”, muestran el comportamiento de dichas variables.

Los resultados obtenidos a partir del uso de la estrategia de control vectorial, aplicado al motor de inducción, se muestran en la figura 20. Las condiciones son las siguientes: En un primer momento, la velocidad de referencia fue de 40 rad/s. Se observa que el motor alcanza dicha velocidad aproximadamente en 5 segundos. Permanece estable en dicha velocidad hasta los 50 segundos, donde se introduce un cambio en el valor de referencia, que pasa a ser 10 rad/s; el sistema de control lleva al motor a esta velocidad. El motor permanece en este valor hasta los 100 segundos, donde se introduce un nuevo cambio de set point, que ahora es 30 rad/s. Cuando el motor se establece en dicha velocidad, se ingresa al sistema una carga,

y se observa que la estrategia de control, nuevamente, lleva a la máquina al valor de velocidad requerido y lo mantiene allí.

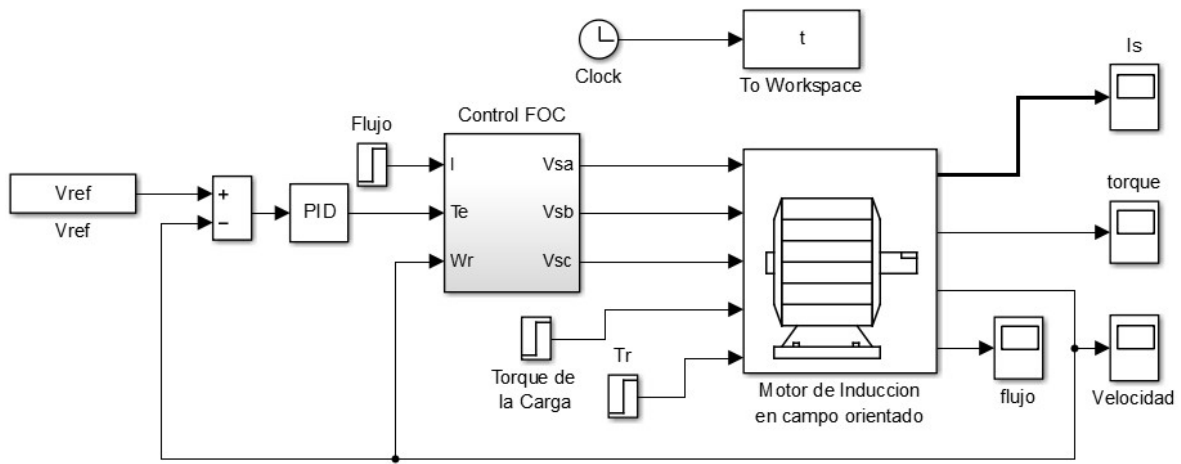


Figura 19. Control de Velocidad del Motor por CV.

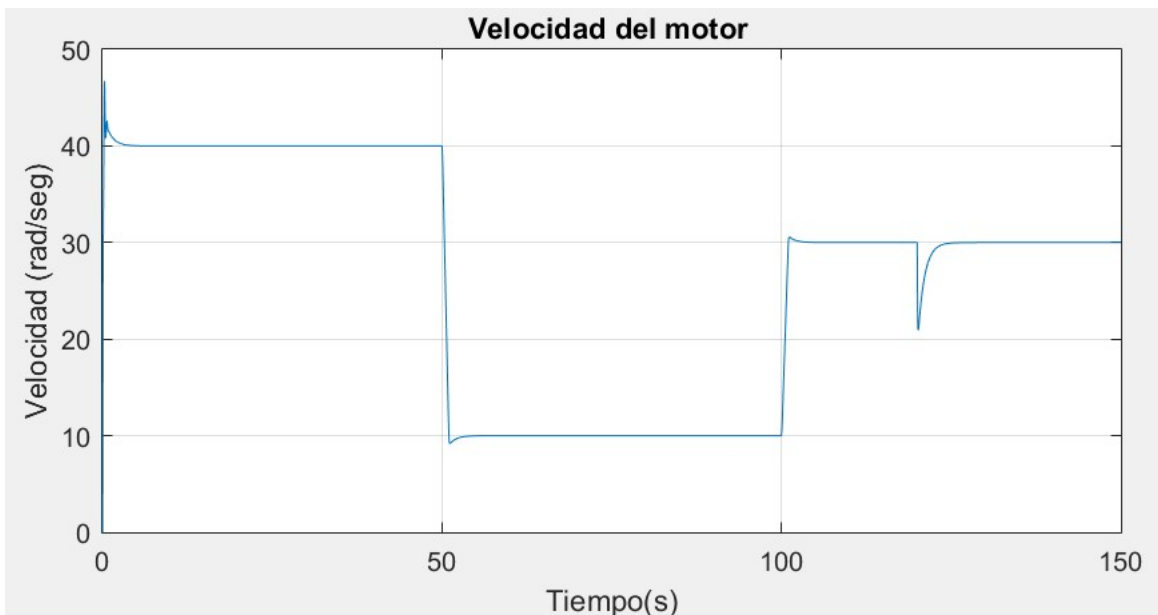


Figura 20. Respuesta del motor al control CV.

3.4 Inversor PWM con fuente de voltaje.

El esquema de control por FOC contempla la utilización de un *inversor*. En el diagrama de bloques mostrado en la figura 18, se ve cómo la señal de control que

sale del bloque controlador llega al mencionado bloque inversor. La función de este componente es “cambiar un voltaje de entrada CD a un voltaje simétrico de salida en CA, con la magnitud y frecuencia deseada” (Rashid, 1995). Los inversores pueden ser de tipo VSI (Inversores de Fuente de Voltaje, en inglés Voltage Source Inverter), cuando el voltaje de entrada se mantiene constante, o de tipo CSI (Inversores de fuente de corriente, en inglés Current Source Inverter), si es la corriente de entrada quien se conserva constante.

Existen dos tipos de inversores según el número de fases: Inversores monofásicos e inversores trifásicos. Su funcionamiento se basa en la conmutación sincronizadas de interruptores unidireccionales que pueden ser transistores BJT, MOSFET, IGBT o tiristores de conmutación forzada (Rashid, 1995).

En el presente trabajo se utiliza un inversor de tipo VSI trifásico, tipo puente de seis ramas que emplea MOSFET's como elemento interruptor. En la figura 21 se ilustra el circuito empleado para cada una de las fases (El inversor completo se compone de tres circuitos iguales, uno para cada fase). El circuito está conformado por las siguientes etapas: aislamiento, driver y potencia.

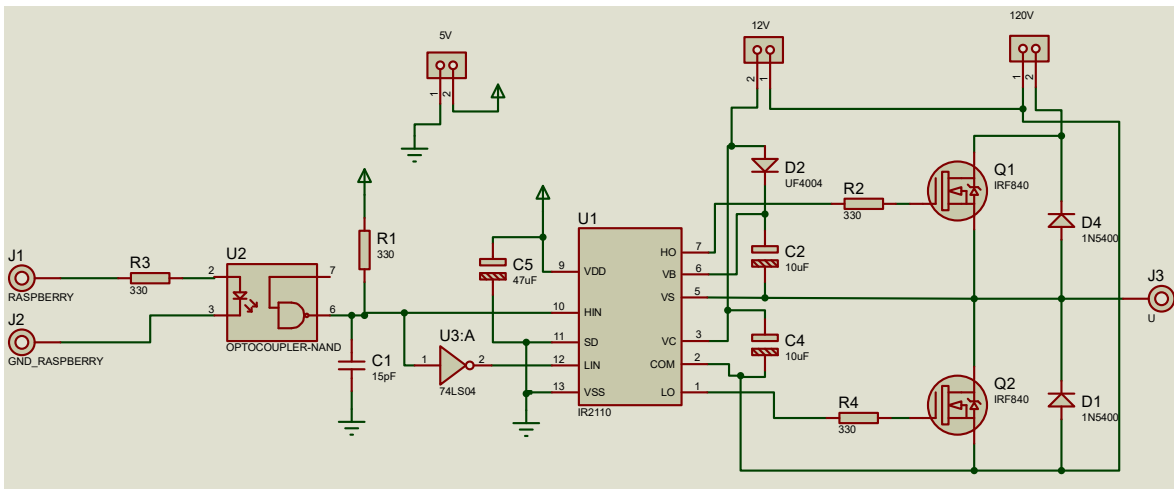


Figura 21. Circuito excitador por fase. (Caicedo P., 2014).

Cómo elemento de aislamiento entre la etapa de control y la etapa de potencia se utiliza el optoacoplador 6N137. El control se realiza por medio de una tarjeta de

desarrollo Raspberry Pi, la cual suministra una onda PWM. Esta onda se genera por medio del software Simulink, utilizando para ello el bloque PWM generator – 2 level, para la activación de los transistores generada mediante una comparación de una onda portadora triangular (Diaz R, Cote U, & Pardo G, 2013) y las señales moduladoras sinusoidales provenientes del control Vectorial.

En la etapa de driver se utiliza el circuito integrado IR2110. Este componente tiene como función la activación de dos MOSFET's (por fase). El CI recibe dos señales de control, la señal principal y le señal negada.

La etapa de potencia, por su parte, consiste en un circuito tipo puente, conformado por dos MOSFET's IRF840, que pueden manejar voltajes de hasta 500 V y corrientes de hasta 8 A.

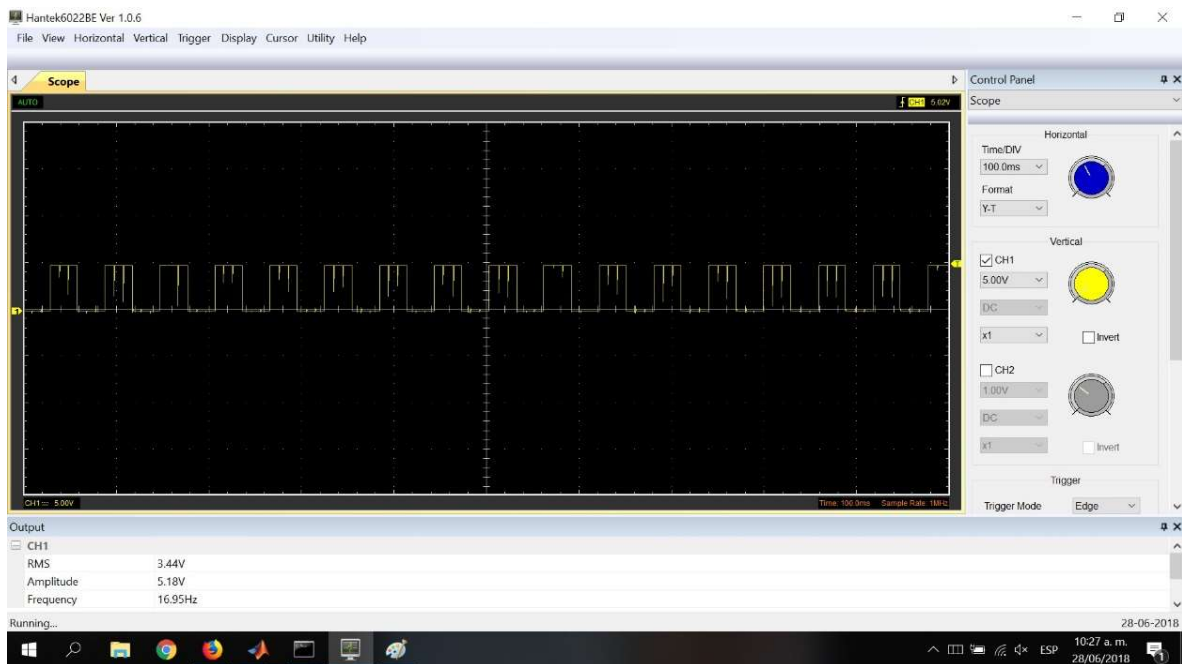


Figura 22. Voltaje entre fase y tierra del puente inversor a 100 rpm

En la figura 22 se muestra el voltaje aplicado a una de las fases del motor, para una velocidad de 100 RPM. En la figura 23, por su parte, se muestra el voltaje entre dos de las fases del motor, también para una velocidad de 100 RPM y en la figura 24 se

muestra el voltaje entre dos fases a 500 RPM. Se observa, a partir de las gráficas antes mencionadas, que el comportamiento del circuito inversor es el esperado.

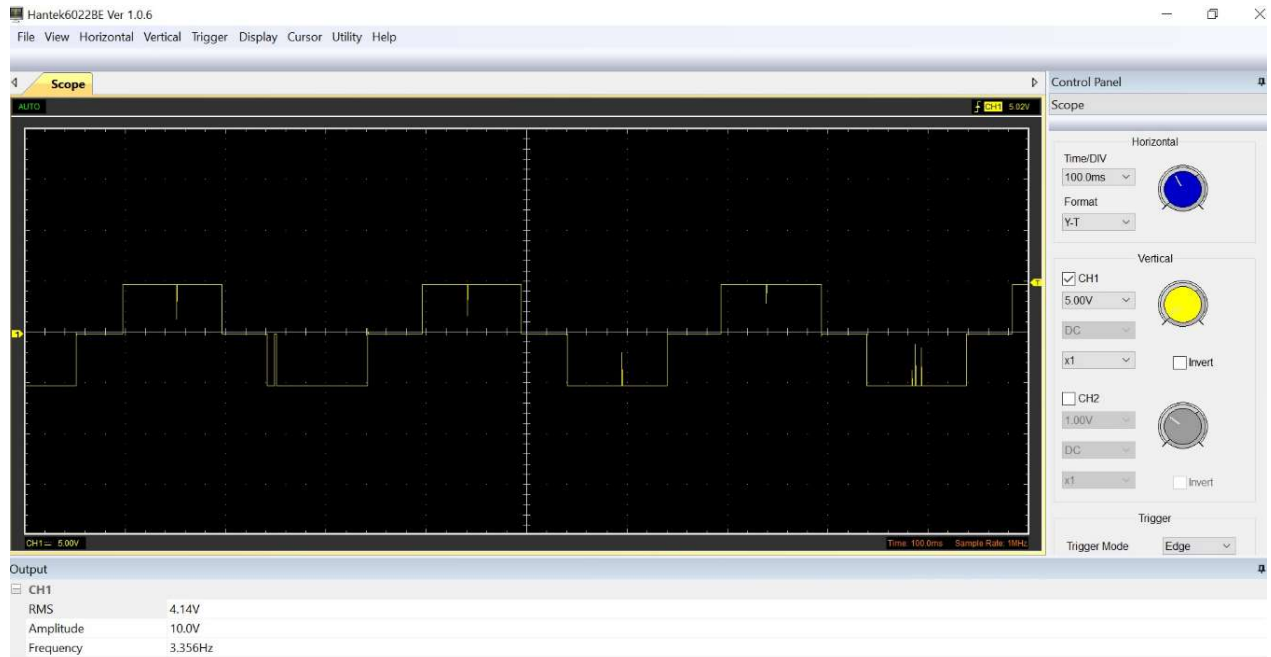


Figura 23. Voltaje entre dos fases del puente inversor a 100 rpm.

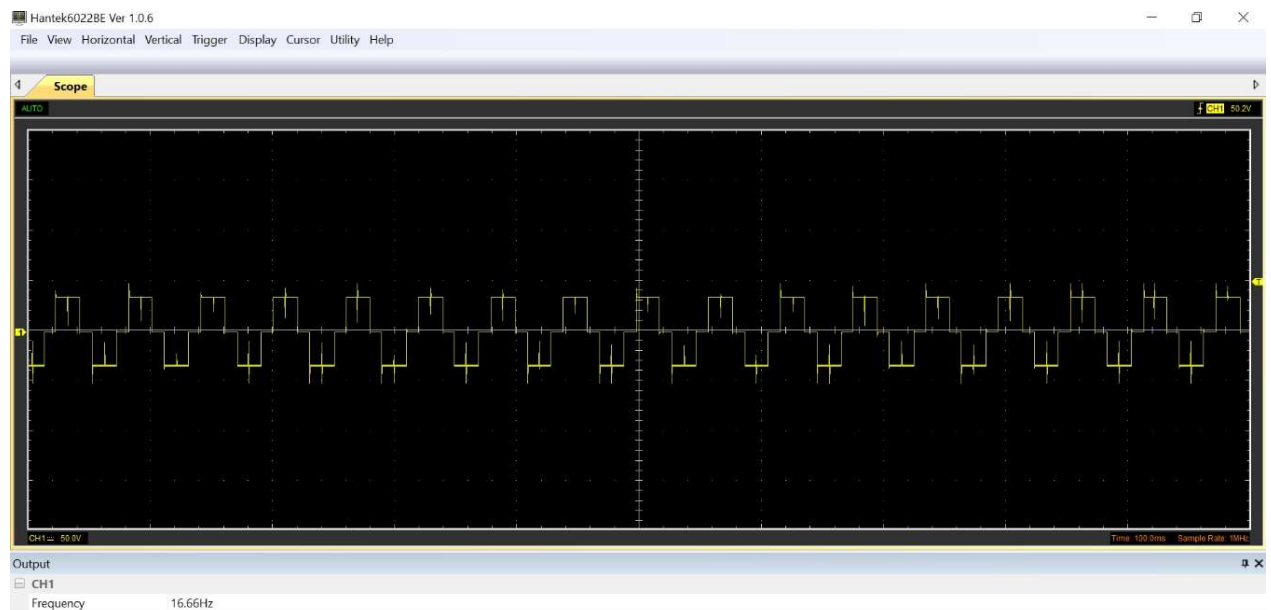


Figura 24. Voltaje entre dos fases del puente inversor a 500 rpm.

CAPITULO 4

REDES NEURONALES ARTIFICIALES

La técnica de inteligencia artificial a utilizar para realizar la estimación de la velocidad del motor son las Redes Neuronales Artificiales (RNA). Esta elección obedece a los buenos resultados obtenidos utilizando esta técnica en sistemas con dinámica no lineal (Pyne, Chatterjee, & Dasgupta, Speed estimation of three phase induction motor using artificial neural network., 2014). El tipo de red neuronal escogida es “feed forward” con aprendizaje *backpropagation* automático y supervisado (Ponce Cruz P. , 2010). En el presente capítulo se realizará una revisión teórica de las RNA y, posteriormente, se presentará el diagrama de bloques de control de velocidad del motor de inducción incluyendo el estimador por RNA.

4.1 Funcionamiento RNA

Según Ponce Cruz, las RNA son aproximaciones no lineales a la forma en que funciona el cerebro. Sin embargo, no deben compararse directamente con el cerebro, dado que las redes neuronales biológicas generan procesos neurobiológicos muy complejos, que no pueden imitarse con redes artificiales monocapa o multicapa. Entonces, las RNA deben estudiarse como aproximadores universales desde el punto de vista matemático.

Las RNA basan su funcionamiento en el cerebro humano, más específicamente en el reconocimiento de patrones. Esto es porque, a pesar de que las computadoras son mucho más rápidas para efectuar cálculos matemáticos, no lo son en tareas como, por ejemplo, reconocer un rostro familiar en medio de una multitud con un esfuerzo aparentemente pequeño.

En la siguiente figura, entonces, podemos observar una representación general de lo que es una neurona biológica, la cual tiene cuatro elementos bien definidos.

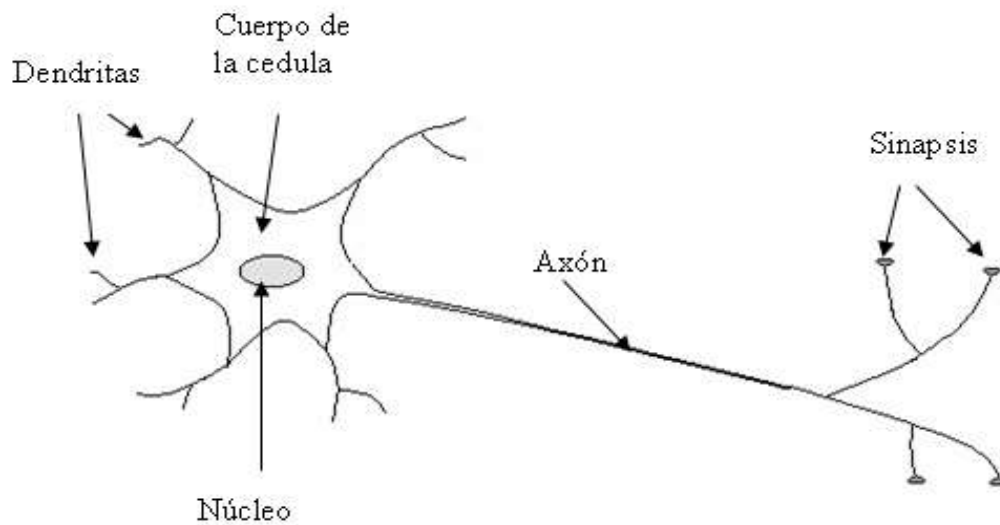


Figura 25. Estructura de una neurona.

Las partes más importantes de la neurona biológica son:

El cuerpo o soma, que contiene el núcleo.

El axón, que es una prolongación del soma.

Las dendritas, que son ramificaciones que sirven para que las neuronas establezcan relaciones entre sí. Además, en estas dendritas se originan impulsos nerviosos, que viajan de una neurona a otra.

La sinapsis, que es la unión entre neuronas.

Nuestro aprendizaje y las reacciones que tenemos ante los estímulos externos dependen de las conexiones sinápticas entre neuronas. Las RNA, entonces, son un intento de emular este modelo general de neurona biológica y las conexiones entre ellas.

En la figura 26 se muestra un modelo de Neurona Artificial, propuesto por Warren McCulloch y Walter Pitts en 1943. En dicha figura se hace un paralelismo entre las partes de una neurona biológica y de una neurona artificial.

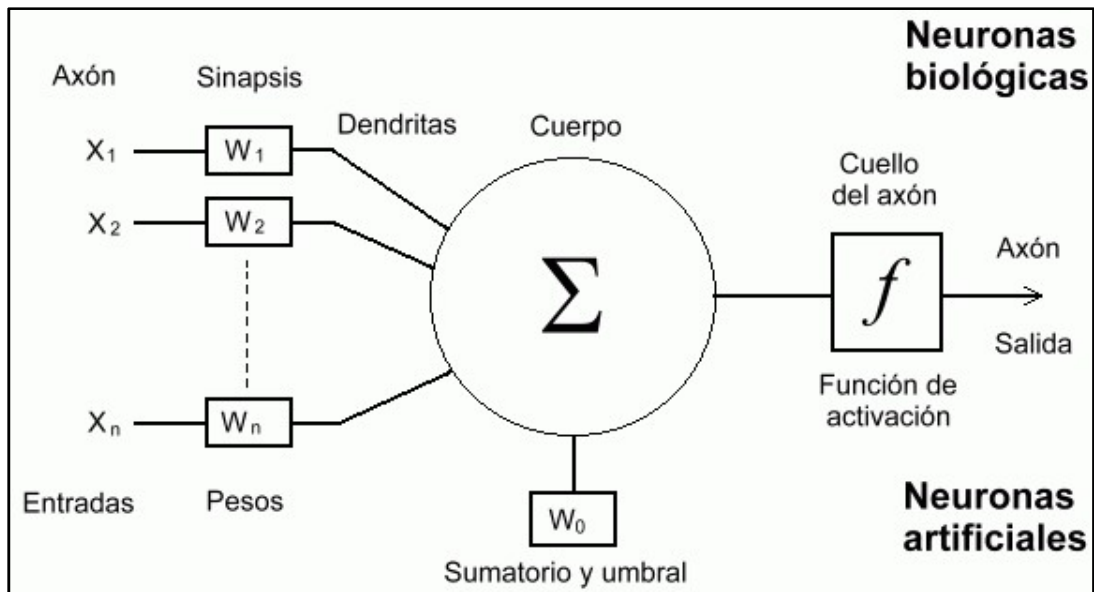


Figura 26. Modelo de neurona artificial propuesto por McCulloch y Pitts. {Fuente: <http://www.cs.us.es/~fsancho/?e=72>}

Las entradas de la neurona artificial son los estímulos externos que llegan a la neurona. Por otro lado, la salida, es la respuesta de la neurona ante dichos estímulos. La característica principal de las neuronas artificiales es que pueden adaptarse al medio que la rodea y ajustar sus pesos sinápticos generando un aprendizaje, por esto, estos parámetros son conocidos como parámetros libres.

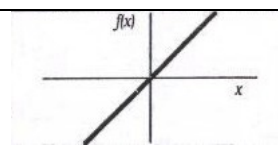
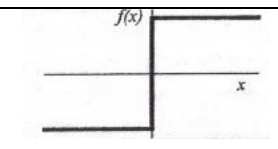
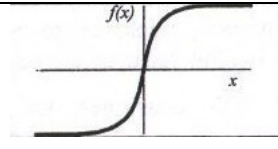
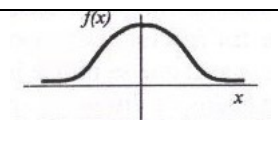
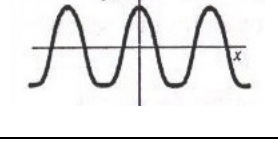
En el modelo anteriormente mencionado, la salida neuronal está dada por la ecuación 4.1.

$$Y = f\left(\sum_{i=1}^n \omega_i x_i\right) \quad (4.1)$$

Donde f es la función de activación, ω los pesos sinápticos, x las entradas y Y la salida.

La función de activación se elige dependiendo de la tarea que debe realizar la neurona. En la tabla 2 se muestran algunas de las funciones más comunes.

Tabla 2. Funciones de activación comunes.

	Función	Rango	Gráfica
Identidad	$y = x$	$[-\infty, +\infty]$	
Escalón	$y = \text{sign}(x)$ $y = H(x)$	$\{-1, +1\}$ $\{0, +1\}$	
Sigmoidea	$y = \frac{1}{1 + e^{-x}}$ $y = \text{tgh}(x)$	$[0, +1]$ $[-1, +1]$	
Gaussiana	$y = Ae^{-Bx^2}$	$[0, +1]$	
Sinusoidal	$y = A\text{sen}(\omega x + \varphi)$	$[-1, +1]$	

4.2. Procesos de aprendizaje

Según Haykin (Haykin, 1999), la razón de ser de una red neuronal es tener la habilidad de aprender a partir de su entorno, y mejorar su rendimiento a partir de dicho aprendizaje.

Una red neuronal aprende por medio de un proceso iterativo, en el cual se ajustan sus pesos sinápticos. En un caso ideal, la red neuronal adquiere más conocimiento acerca de su entorno luego de cada iteración del proceso de aprendizaje.

Una definición del proceso de aprendizaje de una red neuronal implica la siguiente secuencia de eventos:

1. La red neuronal es estimulada por un entorno.
2. La red neuronal sufre cambios en sus parámetros libres como resultado de esta estimulación.
3. La red neuronal responde de una nueva forma al entorno debido a los cambios sufridos en su estructura interna.

Un conjunto de reglas bien definidas para la solución de un problema de aprendizaje es llamado algoritmo de aprendizaje.

4.2.1. Aprendizaje supervisado

En términos conceptuales, el aprendizaje supervisado de una red neuronal es aquel donde un “profesor” enseña a la red cómo comportarse ante un conjunto determinado de estímulos procedentes del entorno. En la figura 27 se observa un esquema de este tipo de aprendizaje.

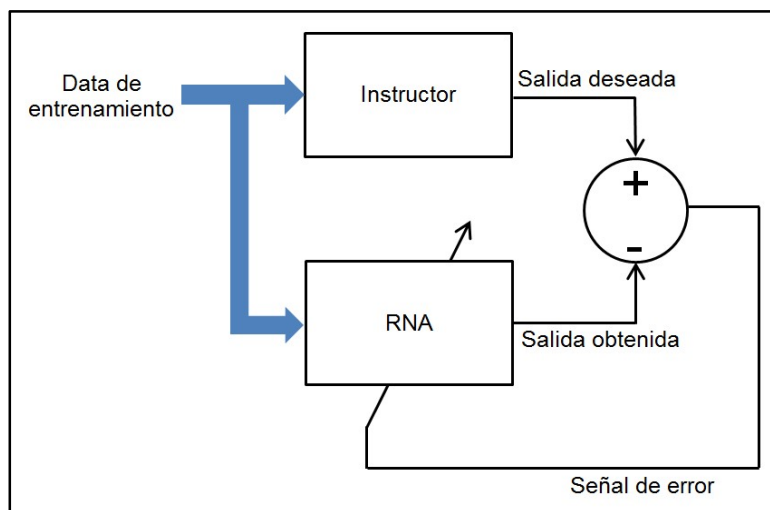


Figura 27. Esquema de aprendizaje supervisado.

En este esquema, se alimenta al instructor y la RNA con una data de entrenamiento. Por medio del instructor se obtiene la salida deseada de la RNA, a partir de la cual se genera una señal de error. Dicha señal de error ingresa a la RNA y ajusta los pesos sinápticos.

En un caso ideal, en cada una de las iteraciones del proceso de aprendizaje los pesos se ajustan para que la salida obtenida sea cada vez más parecida a la salida deseada.

4.2.2. Tareas de aprendizaje

Dependiendo de la tarea para la cual se vaya a utilizar la red neuronal, es decir, el trabajo que va a desempeñar la misma, se escoge un algoritmo de aprendizaje determinado. A continuación, se definen algunas tareas básicas de aprendizaje.

4.2.2.1. Asociación de patrones

Si se utiliza una RNA con la finalidad de reconocer patrones, se tienen dos tipos de asociación: autoasociación heteroasociación. En la autoasociación, la RNA almacena un conjunto de patrones, y luego, cuando se le presenta una versión distorsionada de algún patrón almacenado, la RNA debería ser capaz de reconocerlo. Este es un proceso de aprendizaje no supervisado.

En la heteroasociación, con cada patrón de entrenamiento, se le presenta a la red la salida deseada, con lo cual, es un tipo de aprendizaje supervisado.

4.2.2.2. Reconocimiento de patrones

Se puede definir el reconocimiento de patrones como el proceso en el cual una señal recibida es asignada a un número de clases prescritas (categorías). Para que una red neuronal sea capaz de realiza un reconocimiento de patrones debe pasar por un proceso de entrenamiento en el cual se le presenta un conjunto de patrones,

como entradas de la red, junto con la categoría a la cual pertenecen dichos patrones, como salida de la red.

Luego de este proceso, si a la red se le presenta un patrón que nunca antes ha visto, pero que pertenece a una de las clases con las cuales fue entrenada, la RNA debería ser capaz de reconocer dicho patrón.

4.2.2.3. Aproximación de funciones

Es posible utilizar la RNA para clonar el comportamiento de una función desconocida, siempre que se tenga la posibilidad de conocer la respuesta de dicha función ante una determinada entrada. Entonces, si se tiene un conjunto de entradas y sus respectivas salidas de la función, es posible entrenar a la red neuronal para que se comporte como una aproximación de la función.

Esta tarea de aprendizaje se utiliza para trabajos como por ejemplo la identificación de sistemas. En la figura 28 se muestra un diagrama de bloques correspondiente a la obtención de un modelo RNA de un proceso.

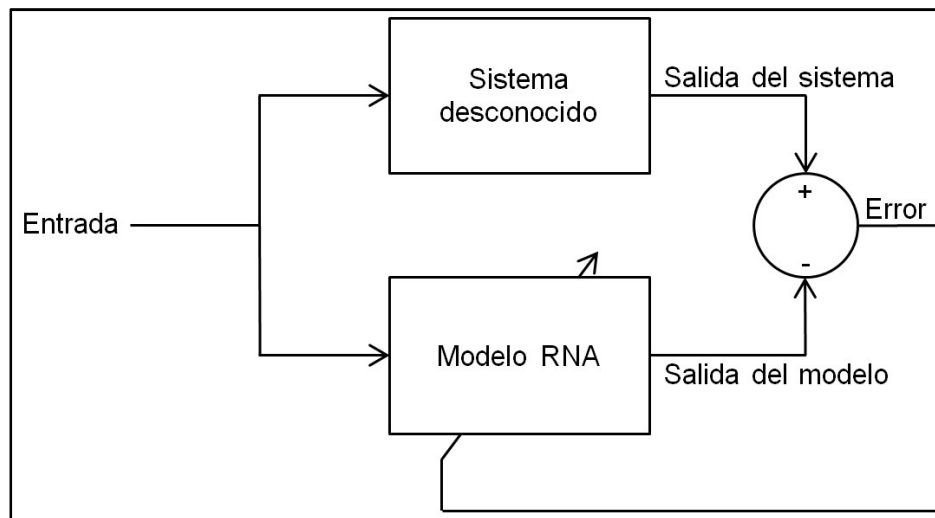


Figura 28. Diagrama de bloques de la clonación de un sistema.

En la figura anterior, se ilustra como el sistema desconocido es excitado con una señal de entrada conocida, la cual también excita a la RNA, la señal de error se

utiliza para ajustar los pesos de la RNA. Al final del proceso de entrenamiento, la RNA se comporta tal como el sistema desconocido, obteniéndose así un modelo del sistema por clonación.

4.2.2.4. Control

Controlar una planta o proceso es otra de las tareas que puede ser realizada por una red neuronal. Esto es porque, utilizando una red neuronal es posible clonar el comportamiento de un controlador ya establecido. Así, el controlador neuronal toma como entrada el valor del error y genera, como salida, una señal de control u . En la figura 29 se puede observar un diagrama en bloques de un sistema de control utilizando un controlador neuronal en lugar de un controlador clásico.

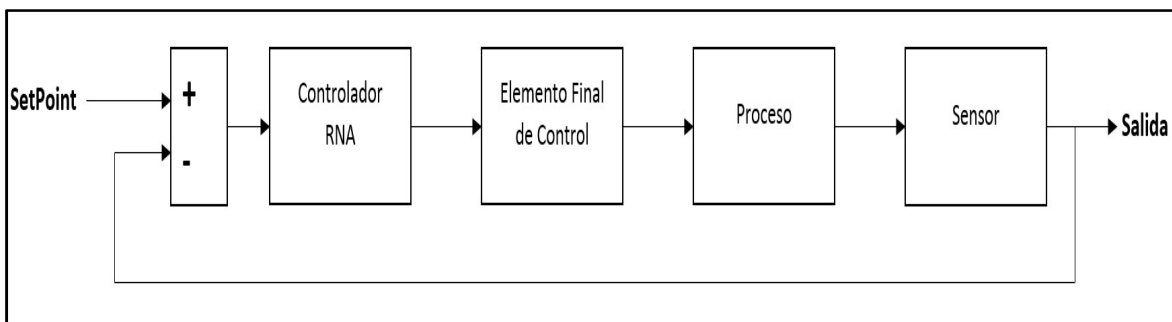


Figura 29. Diagrama de bloques de un proceso con un controlador RNA.

En este caso, se parte de que una RNA es una imitación del cerebro humano, el cual puede ejercer acciones de control. Es decir, partiendo de una información tomada del entorno, el cerebro computa y genera acciones que afectan a dicho proceso. La RNA, entonces, también puede computar acciones a partir de la información recolectada del entorno, en forma de señales provenientes de sensores, y tomar acciones en consecuencia, en forma de señal de control. Otra de las ventajas es que el control por RNA puede tomar acciones en paralelo, controlando varios actuadores, en diversos lazos de control.

4.2.2.5. Filtrado

El término filtro se refiere a un dispositivo o algoritmo usado para extraer información de interés de un grupo de datos contaminados con ruido. El ruido, por su parte, puede venir de numerosas fuentes, por ejemplo, un sensor ruidoso, una mala conexión, o simplemente un ruido provocado por un factor ambiental. Es posible subdividir el filtrado en tres tareas básicas de procesamiento:

1. Filtrado: Se refiere a la extracción de una data específica de un conjunto de data con ruido.
2. Suavizado: Difiere del filtrado en que es un filtrado con retraso, dado que mucha de la data puede inferirse de la data que llega a la RNA después del tiempo determinado para el filtrado.
3. Predicción: En este caso, se pretende estimar el comportamiento que tendrá una señal en función de la información conocida.

4.2.3. Estimación de parámetros utilizando redes neuronales.

Tze-Fun Chan y Keli Shi, en su libro *Applied Intelligent Control of Induction Motor Drives*, (Chan & Shi, 2011) introducen la estimación de parámetros del motor de inducción, tema que es de total relevancia para el presente trabajo.

En varias publicaciones (Agrebi Zorgani, Koubaa, & Boussak, 2016), (Zolfaghari, Abbas Taher, & Vindel Munuz, Neural network based sensorless direct power control of permanent magnet synchronous motor, 2016), han sido propuestos muchos métodos para estimar los parámetros de un motor de inducción, desde el uso de funciones de transferencia obtenidas a partir de data tomada en el dominio del tiempo continuo, hasta modelos de referencia adaptativos (MRAC), pasando por algoritmos genéticos y filtros de Kalman. Así mismo, han sido propuestos métodos de estimación utilizando técnicas de inteligencia artificial, tales como la lógica difusa, las RNA y los algoritmos genéticos.

Las redes neuronales artificiales han mostrado tener un mejor desempeño en la estimación de los parámetros de un motor de inducción, debido a su buen desempeño en la adquisición y procesamiento de información.

Para propósitos de control y análisis, se requiere un conocimiento preciso del modelo del motor de inducción. Para esto, cada uno de los parámetros del motor debe ser modelada utilizando una RNA de múltiples entradas y una única salida. En la figura 30 se muestra un modelo del motor de inducción utilizado para realizar la estimación paramétrica. Este diagrama en bloques se realiza en el software Simulink.

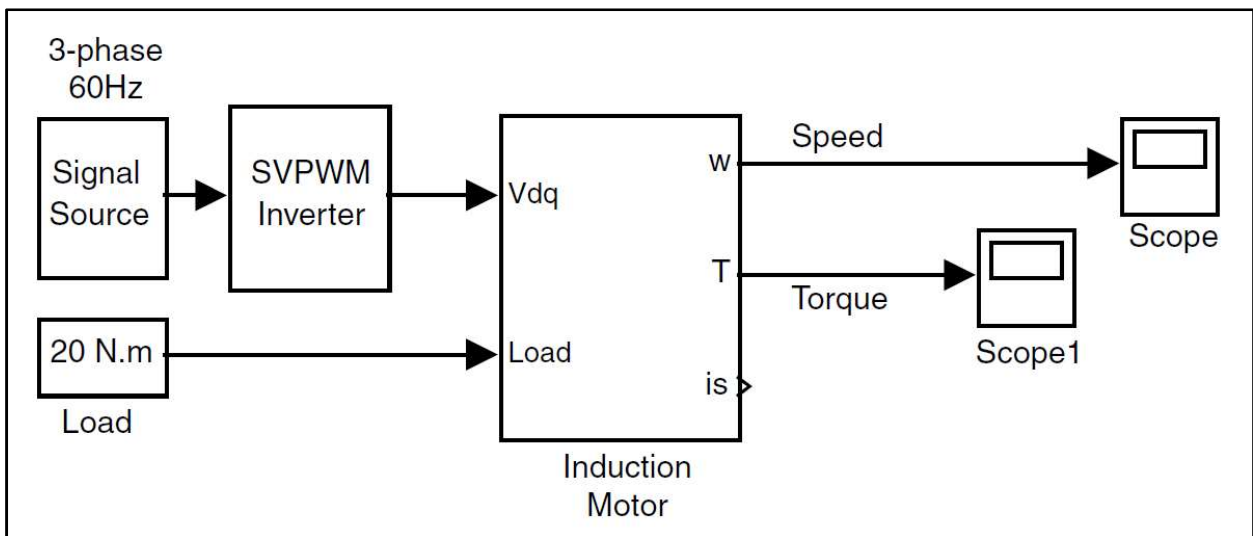


Figura 30. Modelo del motor de inducción en Simulink. Fuente: (Chan & Shi, 2011)

El Signal Source es un generador de tres señales sinusoidales de 60Hz. EL bloque Load representa una carga de 20 N.m constantes. El bloque SVPWM simula un inversor PWM, cuyas salidas son los voltajes V_{ds} y V_{qs} en los ejes dq, con una magnitud de 300 V, y manipulan el motor de inducción.

El bloque Induction Motor es un modelo con entrada de voltaje del motor de inducción. Se utiliza el circuito equivalente en T.

Las salidas del sistema son la velocidad y el torque.

4.2.3.1. Estimación de los parámetros eléctricos.

La figura 31 muestra un esquema de entrenamiento de una RNA para la estimación de los parámetros i_{ds} y i_{qs} . En dicho esquema ambos parámetros se realimentan como entradas para asegurar el aprendizaje.

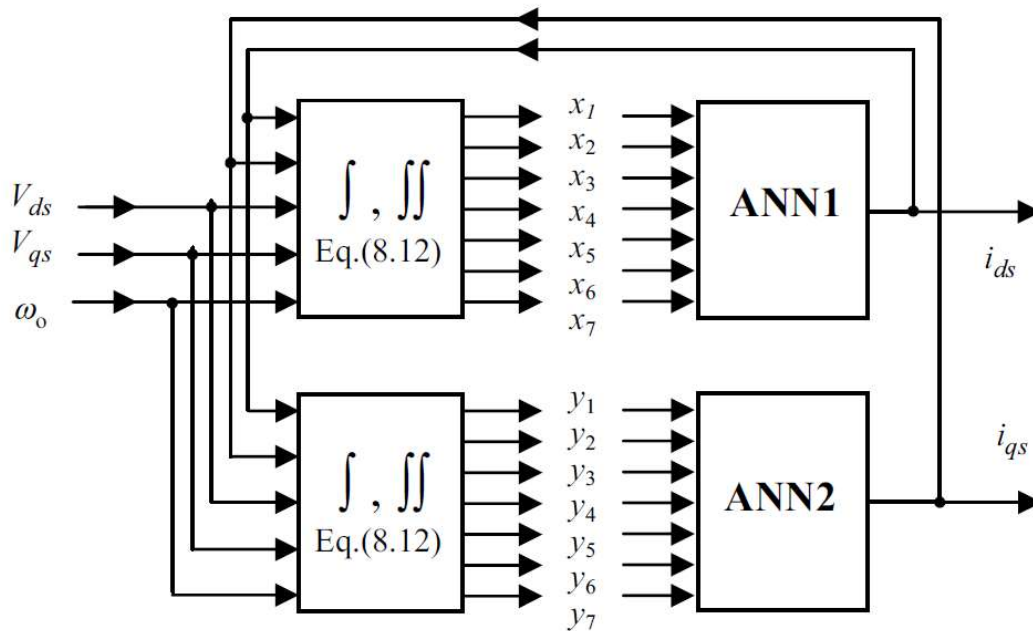


Figura 31. Esquema de entrenamiento para obtener i_{ds} y i_{qs} . Fuente: (Chan & Shi, 2011)

Los voltajes de entrada V_{ds} y V_{qs} , así como la velocidad ω_0 , ingresan al modelo de la máquina de inducción, estos módulos generan las salidas x y y , que ingresan a las RNA, que tienen como salida las corrientes i_{ds} y i_{qs} , que además también ingresan al modelo de la máquina de inducción. Utilizando este esquema es posible, entonces, obtener los parámetros eléctricos del motor.

4.2.3.2. Modelo mecánico basado en RNA

La siguiente figura muestra un esquema propuesto para el entrenamiento de una RNA capaz de estimar la velocidad de un motor de inducción.

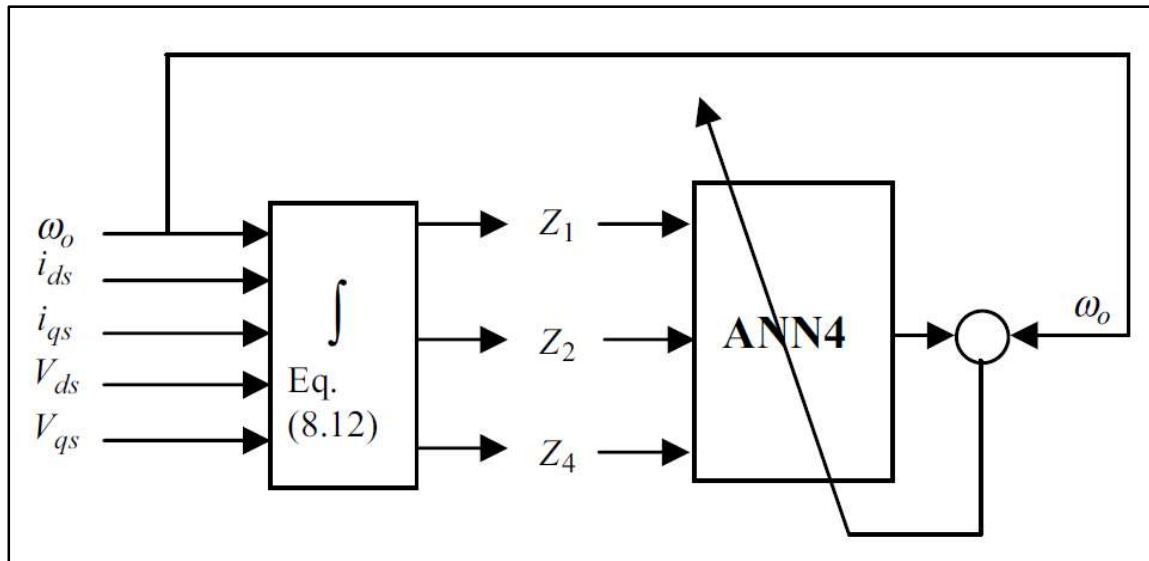


Figura 32. Esquema propuesto para el entrenamiento de un modelo, basado en RNA, para la estimación de la velocidad del motor. (Chan & Shi, 2011)

En este caso, se ingresan al modelo los voltajes v_{ds} y v_{qs} , las corrientes i_{ds} y i_{qs} , además de la velocidad del rotor ω_0 . Entonces, el error, que se produce a partir de la resta de la velocidad estimada por la RNA y la velocidad del rotor del modelo, es lo que se utiliza para entrenar la red.

Si se pueden obtener los parámetros eléctricos y mecánicos del motor de inducción, entonces es posible tener un estimador completo, que estime las corrientes y la velocidad angular del rotor.

En la figura 33, se observa un esquema en el cual se compara la data resultante del modelo matemático del motor de inducción y el modelo RNA del mismo.

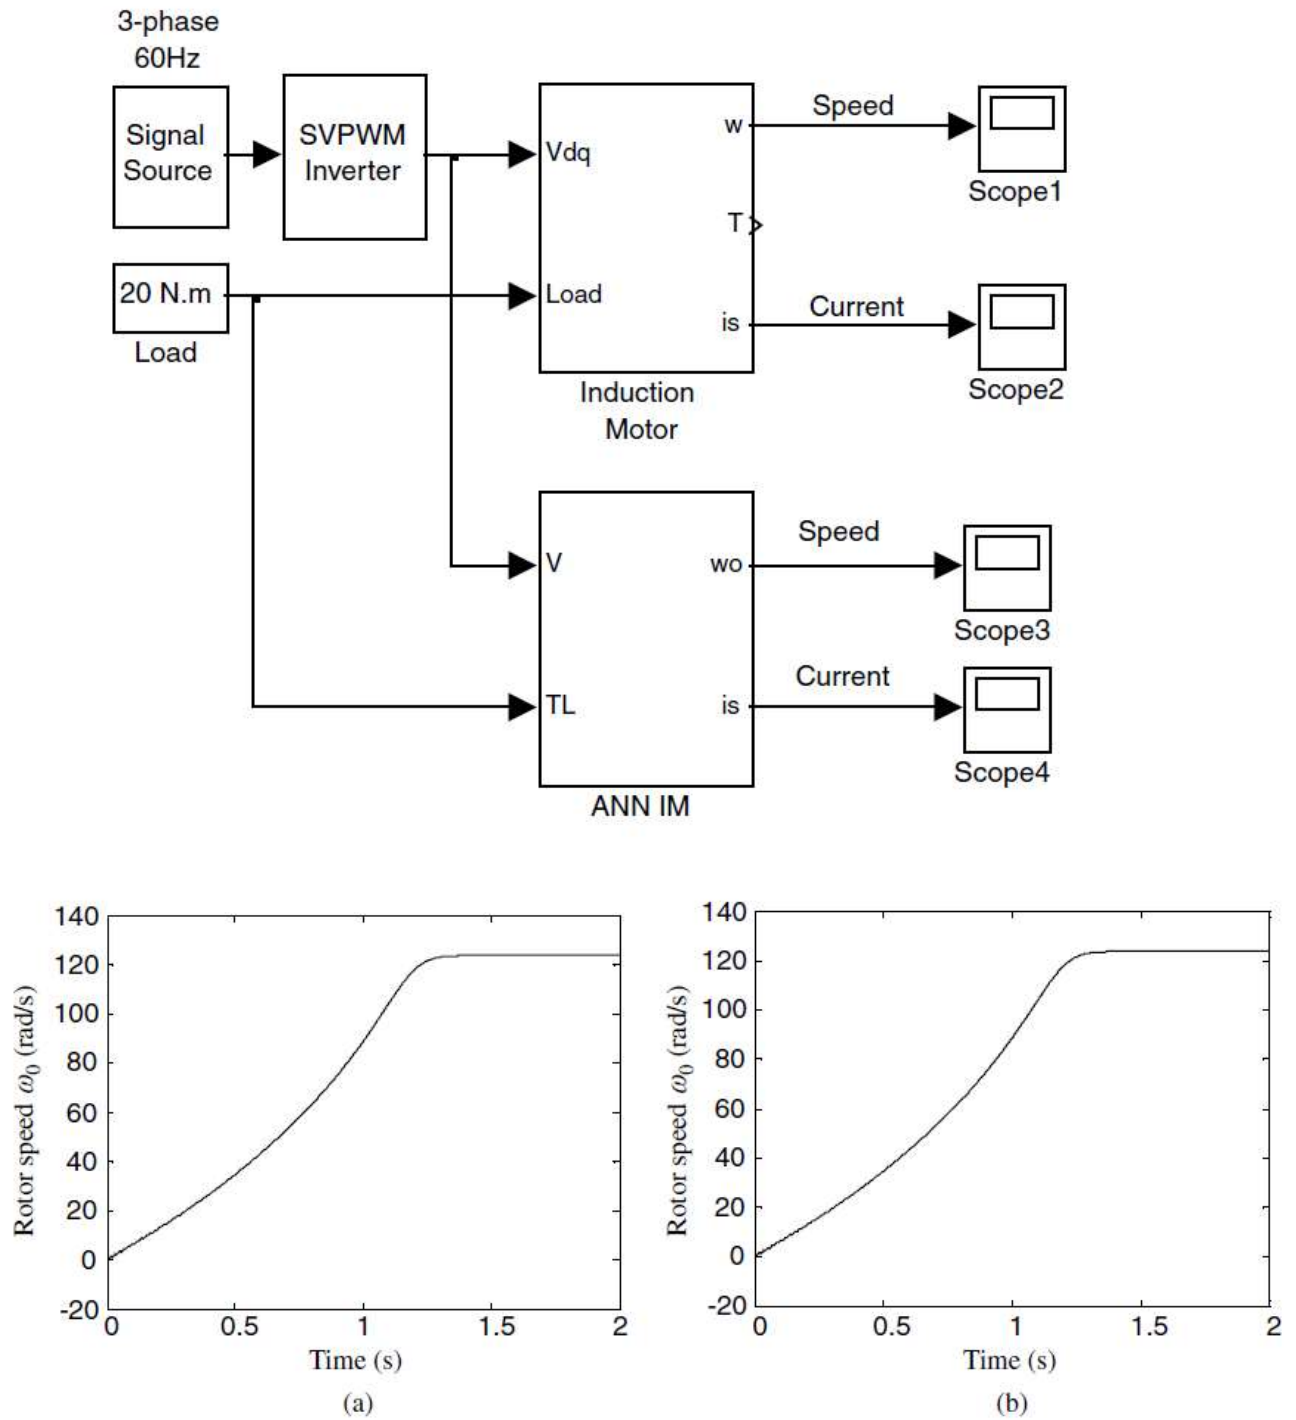


Figura 33. Arriba el esquema para realizar la comparación entre la data obtenida. Abajo, la velocidad de rotor del modelo (a) y la velocidad de rotor estimada (b). Fuente: (Chan & Shi, 2011)

4.2.4. Estimación de velocidad.

Utilizando el parámetro estimador, es posible, a su vez, estimar la carga, el flujo de estator y la velocidad del rotor, en la figura 34 se observa una configuración propuesta para la estimación de la velocidad del motor de inducción que va, sería la base para la implementación del estimador neuronal del proyecto.

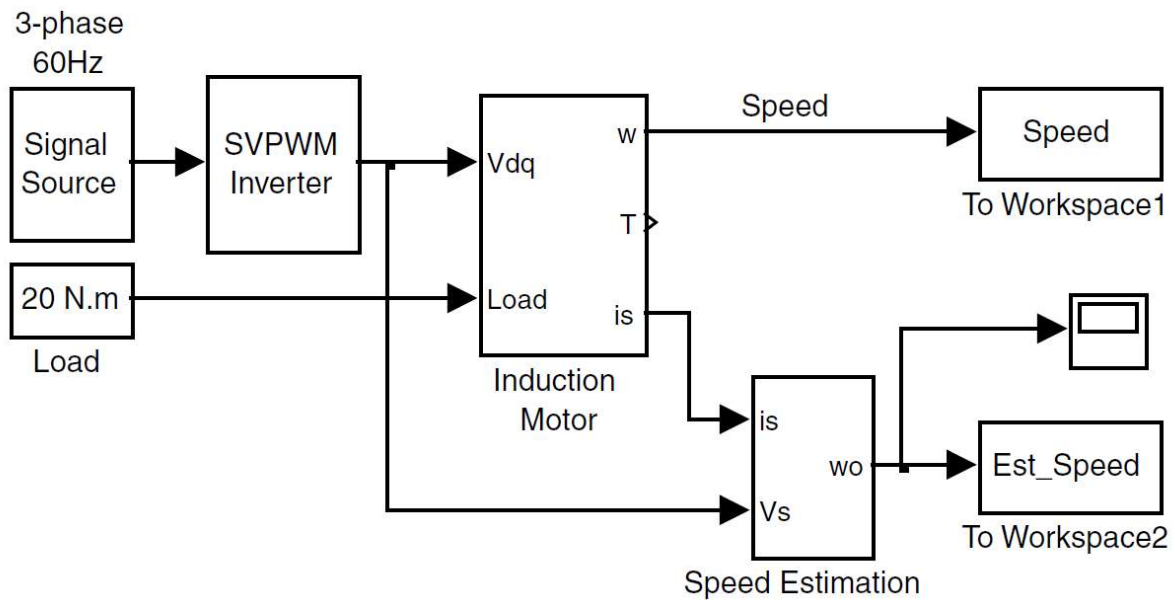


Figura 34. Esquema propuesto para la estimación de la velocidad del rotor. Fuente(Chan & Shi, 2011)

CAPITULO 5

IMPLEMENTACION DEL ESTIMADOR NEURONAL

En el presente capítulo se presenta el desarrollo del control vectorial, en el cual se sustituye el sensor de velocidad por una RNA que estime la velocidad del motor, y se utiliza la información suministrada por dicha red para cerrar el lazo de control.

En la figura 35 se ilustra el diagrama de bloques del estimador propuesto.

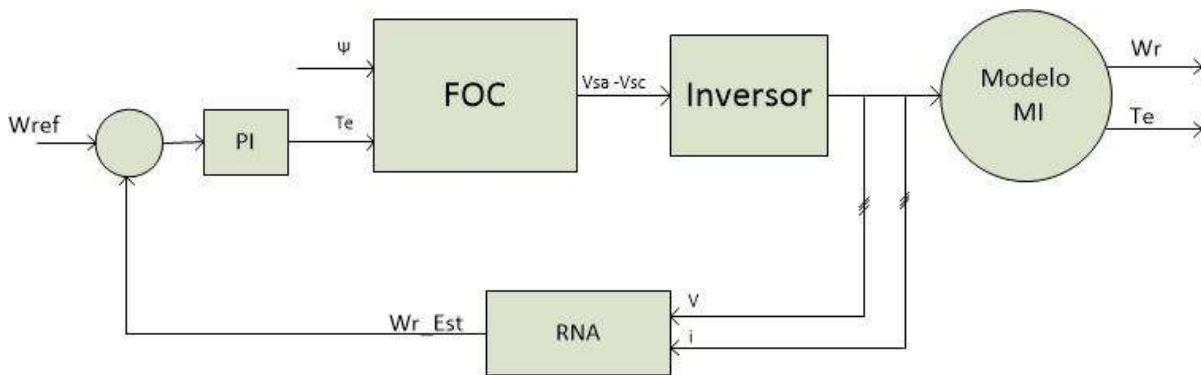


Figura 35. Diagrama de bloques básico del estimador propuesto.

La implementación de la Red Neuronal Artificial para llevar a cabo la estimación de la velocidad se ejecutará en una tarjeta de desarrollo Raspberry Pi, en conjunto con el entorno de programación Simulink / Matlab. En este entorno se desarrollaron los algoritmos necesarios, que luego se volcaron en la tarjeta de desarrollo, desde la cual se ejecutaron de manera autónoma. Por otra parte, las señales entregadas por los sensores de corriente y voltaje ingresan a la tarjeta de desarrollo por medio de los pines GPIO, y se manejan, dentro del entorno Simulink, por medio de los bloques E/S.

El entrenamiento de la RNA es llevado a cabo, en primera instancia, con los datos tomados del modelo del motor que se desarrolló en Simulink. En una segunda fase, la RNA se entrenó con los datos tomados a partir del motor real.

5.1 Configuración de la Red Neuronal.

La RNA utilizada para estimar la velocidad es de arquitectura Feedforward backpropagation, con un método de aprendizaje automático supervisado. Esta RNA tiene 6 entradas, que corresponden a 3 señales de voltaje y 3 señales de corriente, es decir, un sensor de voltaje y un sensor de corriente por cada fase del motor. Como salida se tiene la velocidad estimada del motor de inducción. Esta configuración se observa en la figura 36.

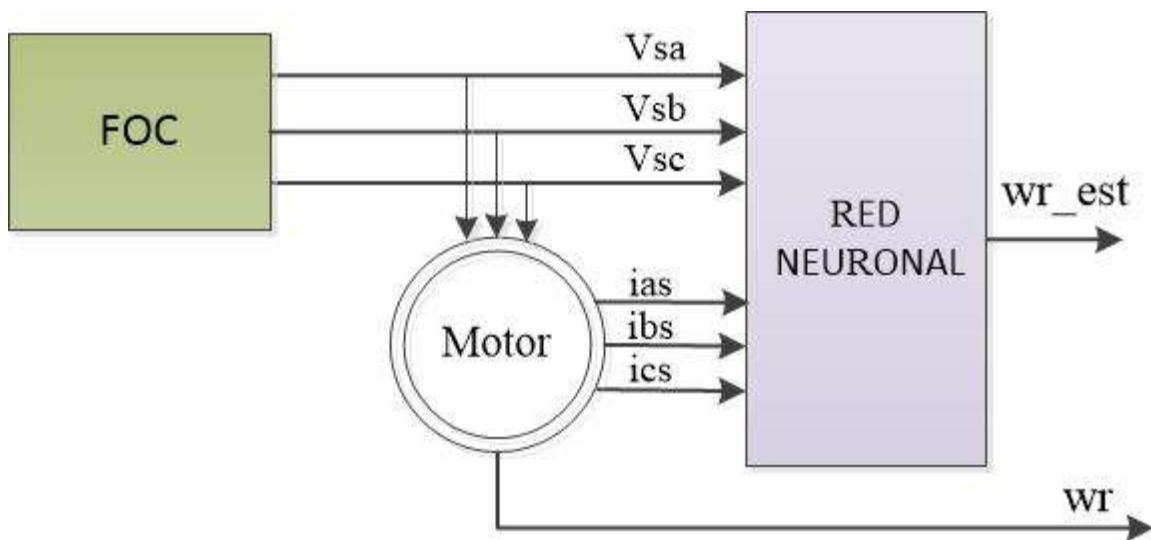


Figura 36. Entradas a la red neuronal.

En las figuras 37 y 38 se observan las señales de corriente y voltaje obtenidas a partir del modelo del motor; la velocidad de trabajo es de 300 rad/seg. En las figuras 38 y 39, por su parte, se muestran las señales de voltaje y corriente tomadas a partir del motor real; en este caso, se muestran las señales obtenidas a tres velocidades distintas, 200 rpm, 500 rpm y 800 rpm. En ambos casos, tanto en la simulación como en la realidad, se utilizó la técnica de control vectorial.




Figura 37. Corrientes del modelo del motor.

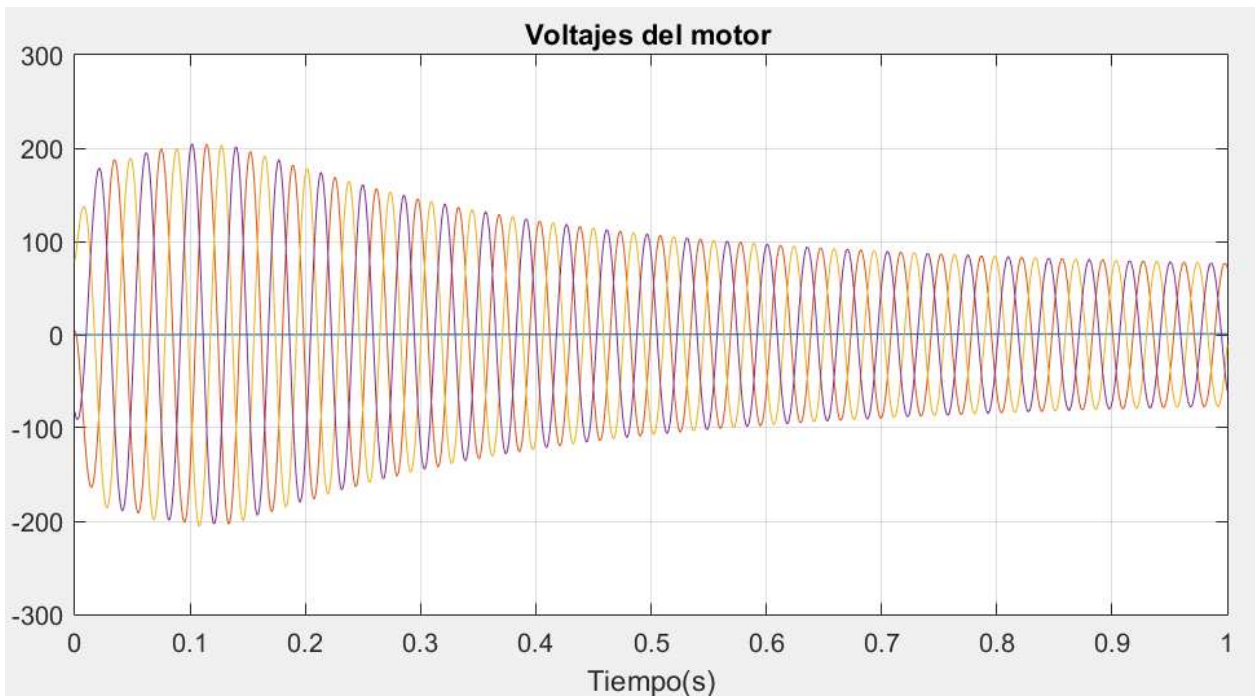


Figura 38. Voltajes del modelo del motor.

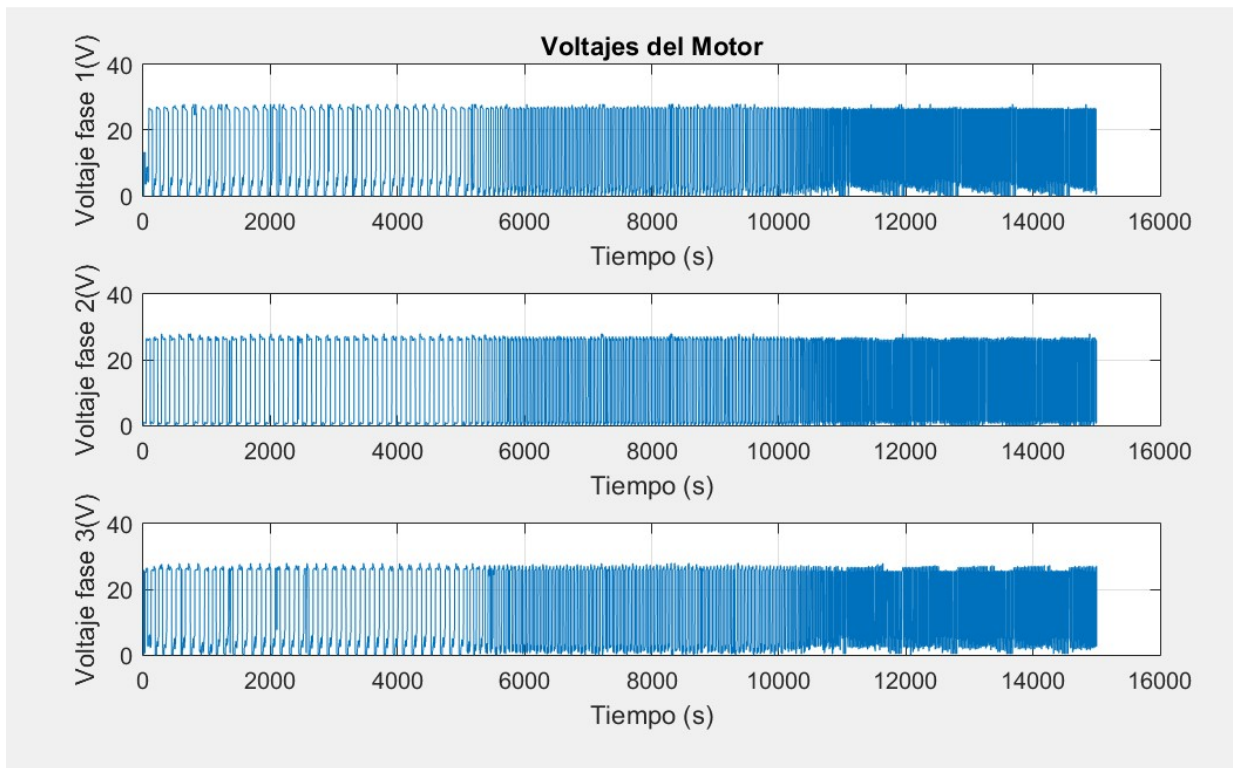


Figura 39. Voltajes del motor con el banco de pruebas.

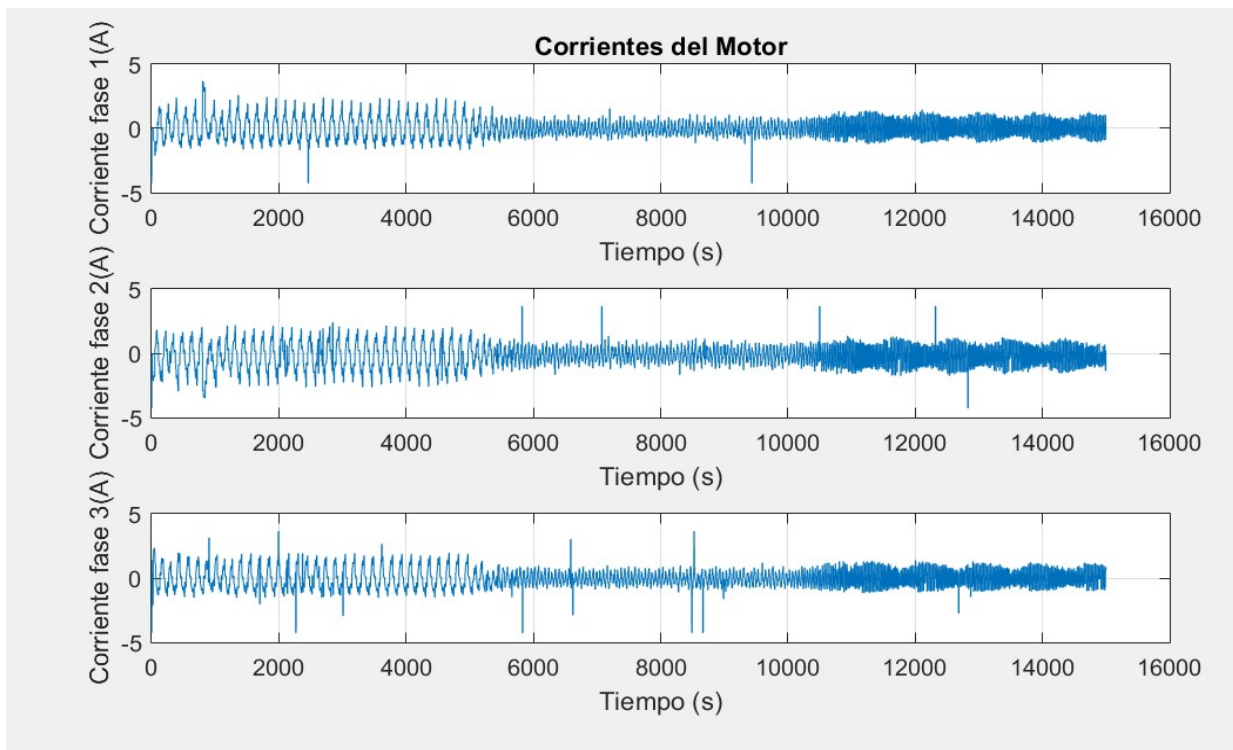


Figura 40. Corrientes del motor con el banco de pruebas.

La creación de la red neuronal en el entorno Matlab se realiza por medio de la función `feedforwardnet`, cuyos argumentos de entrada son el número de capas ocultas y la función de entrenamiento. En este caso, las matrices de entrada se llaman V_s e I_s , en las cuales se incluye toda la información concerniente a los voltajes y las corrientes. Ambas matrices se concatenan en una única matriz llamada I_{np} .

Creación de la RNA.

```
Vs = [Vs1 Vs2 Vs3];  
Is = [Is1 Is2 Is3];  
Inp = [Vs Is];
```

```
net = feedforwardnet(10);
```

5.2 Entrenamiento del estimador neuronal

Para el entrenamiento de la RNA se hizo primero tomando los datos del modelo del motor que se desarrolló en Simulink con el fin de ver el comportamiento del estimador neuronal, y después se hace el entrenamiento con los datos tomados a partir del motor real para desarrollar la estrategia de estimación.

5.2.1 Entrenamiento con los datos del modelo del motor.

En la figura 41 se muestra el entrenamiento de la RNA utilizando la data obtenida a partir del modelo simulado.

Se tomaron 390.000 datos para cada uno de los voltajes y corrientes. Además, se tomaron datos para velocidades desde 0 hasta 300 rad/seg, aumentando en pasos de 5 rad/seg cada vez.

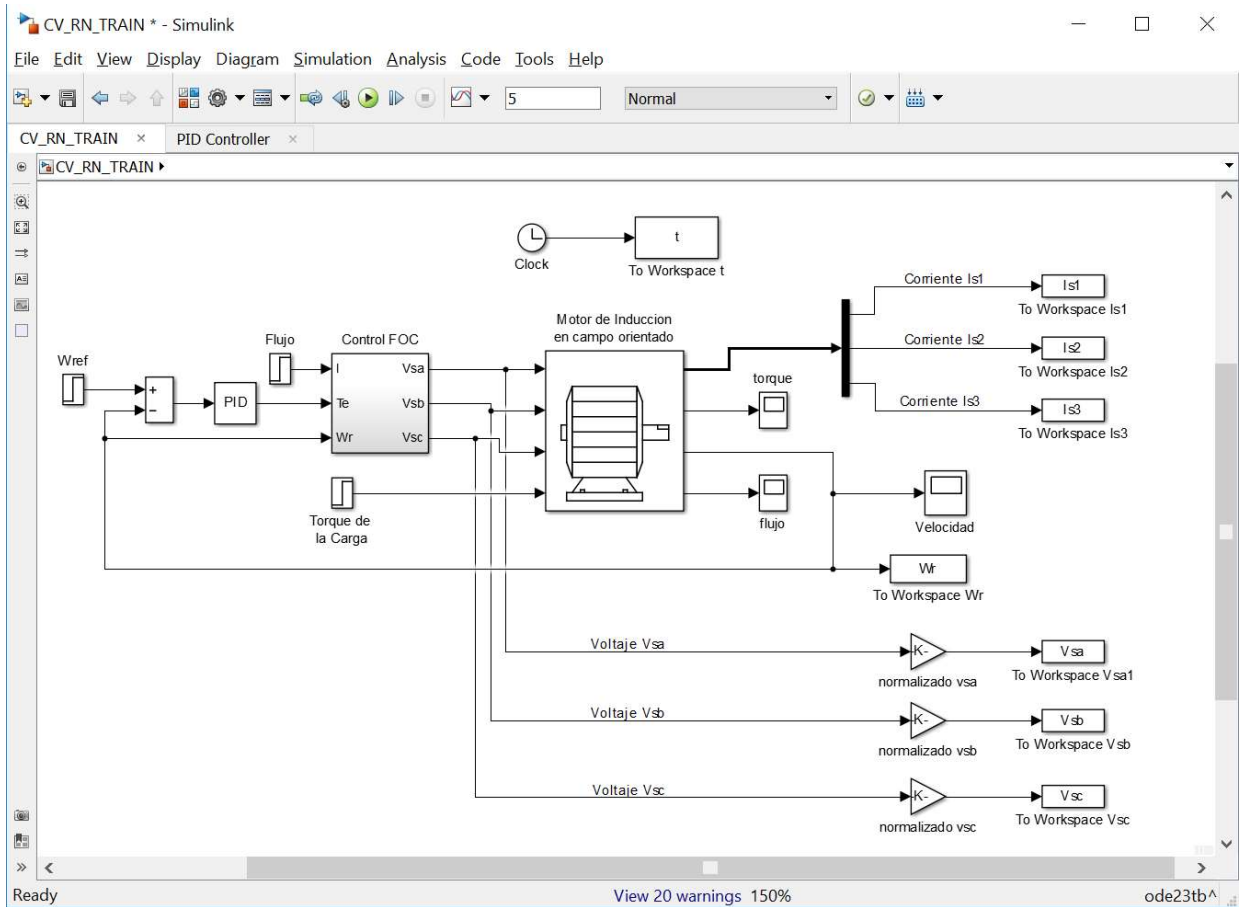


Figura 41. Modelo en Simulink del CV.

Una vez obtenida la data correspondiente, se procede a realizar el entrenamiento de la RNA utilizando la función `trainlm`.

```
net=trainlm(net,Inp',Out');
```

Donde:

`net`: red creada con las respectivas especificaciones.

`inp`: la matriz de datos para la entrada a la red.

`Out`: corresponde a la señal de velocidad de referencia del motor a estimar.

Configurando las épocas de iteraciones a 300.

```
net.trainParam.epochs = 300;
```

En la figura 42 se muestra el proceso de entrenamiento de la RNA y los resultados. Los resultados de dicho entrenamiento se observan en la figura 43, donde se compara la velocidad de referencia y la velocidad estimada por la RNA.

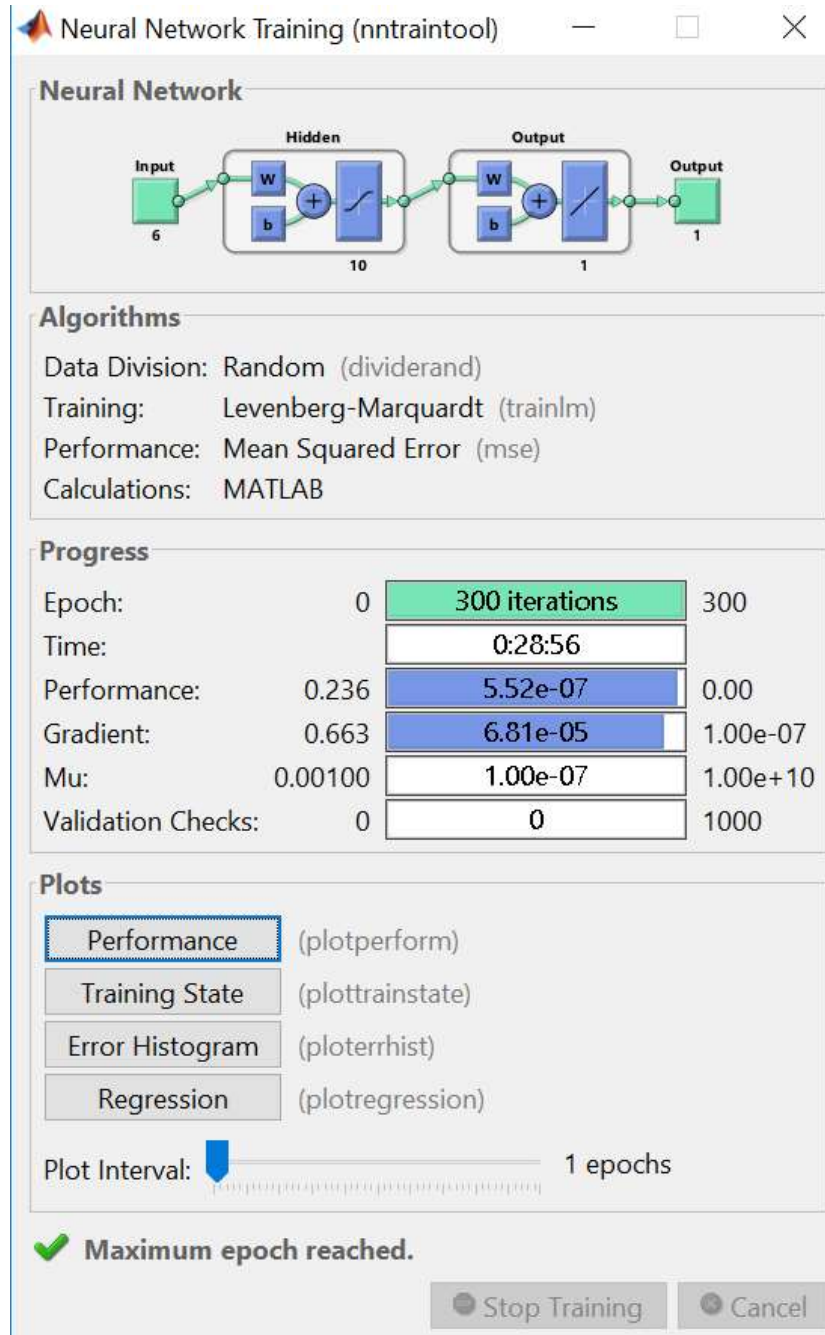


Figura 42. Entrenamiento de la RNA.




Figura 43. Resultados del entrenamiento de la RNA.

5.2.2 Entrenamiento con los datos del banco de pruebas.

Después de haber obtenido resultados satisfactorios con los datos obtenidos a partir de la simulación, se procedió a entrenar la RNA con los datos tomados del sistema real.

En la figura 44 se muestran los bloques que conforman el lazo de control vectorial a utilizar con el motor real.

Los bloques GPIO son utilizados para enviar y/o recibir datos a / desde la tarjeta de desarrollo Raspberry Pi. En este caso, el bloque GPIO 15 es el puerto por el cual se reciben los pulsos entregados por el sensor de velocidad. Estos pulsos de entrada se traducen a una velocidad en RPM por medio de un bloque de conversión; en la figura 43 dicho bloque se resalta en rojo.

El bloque correspondiente al inversor se resalta en color naranja, y es el encargado de recibir las señales provenientes de la estrategia de control vectorial y transformarlas en señales PWM, que accionan los circuitos de potencia, y que son enviados a la tarjeta de desarrollo por medio de los bloques GPIO 16, 18 y 25.

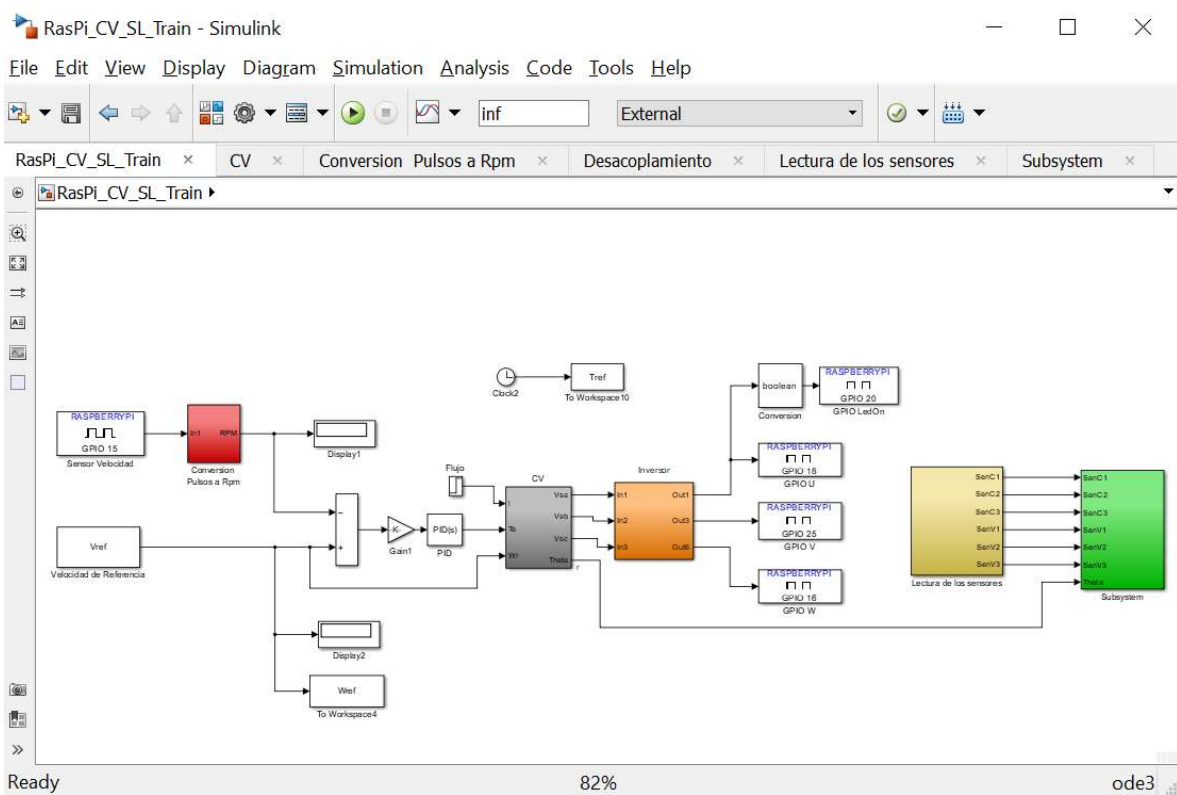


Figura 44. Modelo en Simulink del CV para el banco de pruebas.

La lectura de los sensores de voltaje y corriente se realizó utilizando una tarjeta de desarrollo Arduino, por medio del convertor Análogo/Digital. Así, las señales de los sensores se convierten en datos binarios y se envían a la tarjeta Raspberry Pi. En la figura 45 se muestran los 10 bloques GPIO utilizados para la lectura de los datos binarios de los sensores.

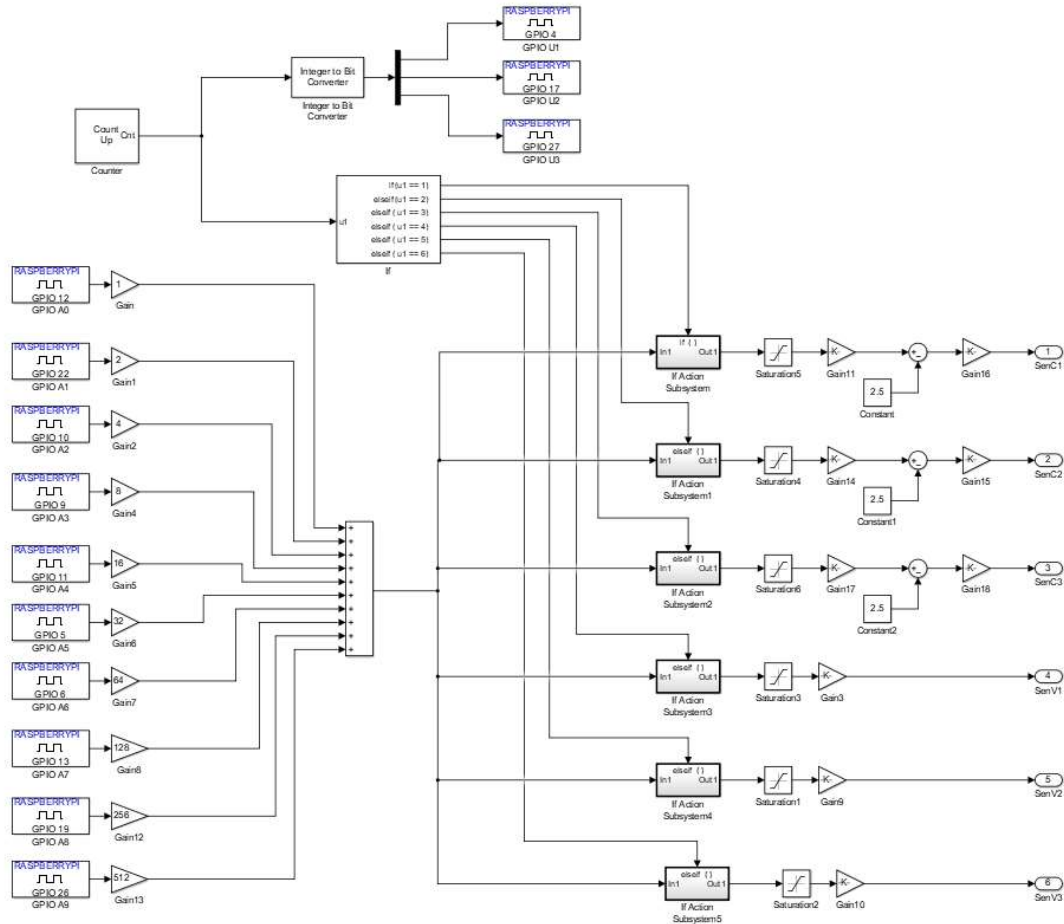


Figura 45. Lectura de los datos de los sensores.

Los datos de voltaje y corriente son enviados al Workspace de Matlab, y son guardados en las matrices Vs e Is respectivamente. Posteriormente, estas matrices se concatenan en una sola matriz llamada Inp .

% Matrices de datos para el entrenamiento de la RNA.

```
Vs = [SenV1 SenV2 SenV3 ];
Is = [SenC1 SenC2 SenC3 ];
Out=Wref;
Inp = [ Vs Is ];
```

%Creación de la RNA.

```
net = feedforwardnet(130);
```

Parámetros de entrenamiento.

```
net.trainParam.epochs = 300;  
net.trainParam.max_fail = 300;  
net = train(net,Inp',Out');
```

% Validacion de la neurona

```
Y=sim(net,Inp');
```

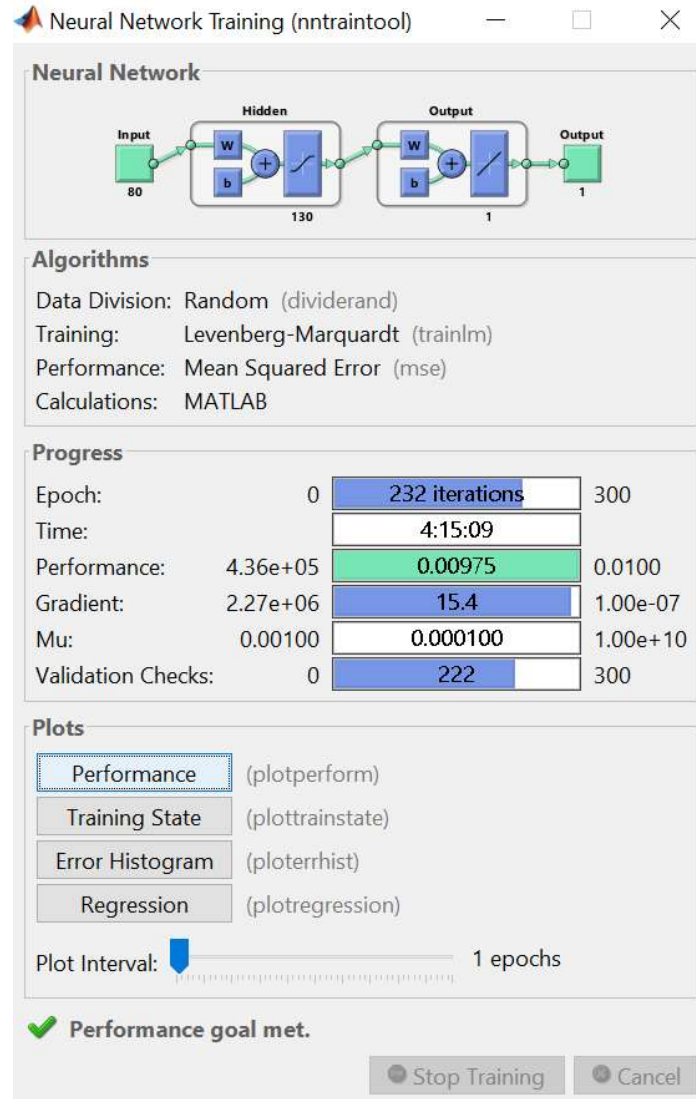


Figura 46. Progreso del entrenamiento de la RNA.

Se tomaron 24.000 datos para realizar el entrenamiento de la RNA, correspondientes a diversas velocidades (50, 100, 150, 200, 250, 300, 350, 400,

450, 500, 550, 600 y 700 rpm). En la figura 46 se observa el proceso de entrenamiento de la RNA. Los resultados del entrenamiento se muestran en la figura 47.




Figura 47. Resultados del entrenamiento.

Una vez realizado el entrenamiento, se procede a generar el bloque en Simulink que contenga a la RNA entrenada, utilizando para ello la función *gensim*.

gensim (net); Genera el bloque de la red neuronal para la simulación.

5.3 Análisis de la simulación del estimador neuronal.

En la figura 48 se muestra el modelo en Simulink del sistema de control vectorial que incluye la RNA para estimación de la velocidad del motor.

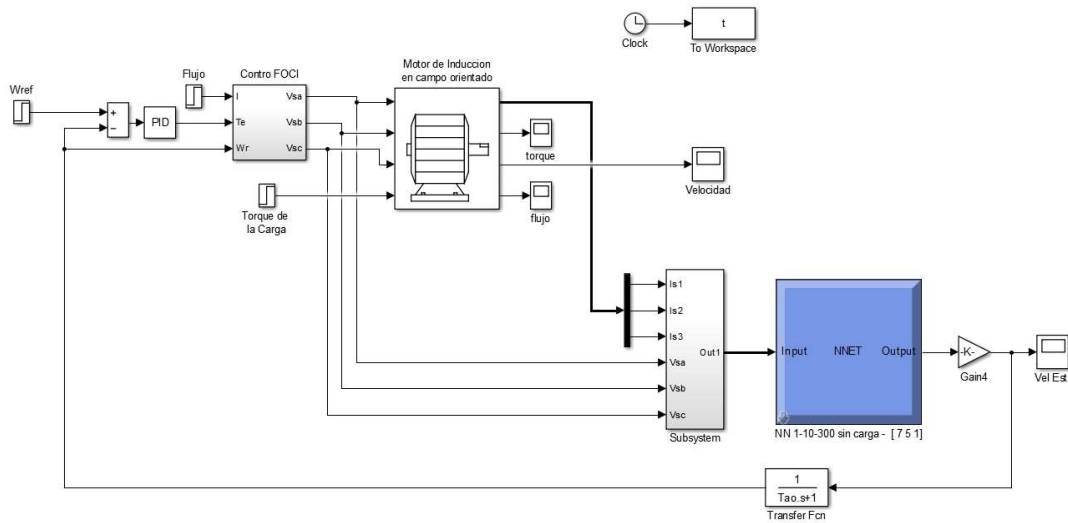


Figura 48. CV con el estimador neuronal.




Figura 49. Respuesta del estimador neuronal del modelo.

En la anterior imagen se observan la velocidad de referencia del motor (arriba) y la velocidad estimada por la RNA (abajo) resultado obtenido por medio de la estrategia de control con estimación por medio de la RNA.

Se utilizaron diferentes velocidades del motor (50, 100, 150, 200 y 250 rad/seg). Se observa que la velocidad estimada va coincidiendo con la velocidad de referencia, lo cual indica que la RNA opera de manera correcta

Para ver la eficiencia del estimador neuronal aplicado al control vectorial, se hacen pruebas aplicando carga al motor y la respuesta del sistema fue optimo como se puede observar en la figura 50.




Figura 500. Respuesta del estimador neuronal con carga.

5.4 Implementación de la estrategia de estimación para el CV.

Para implementar la estrategia de control de velocidad del motor se emplean los siguientes componentes:

- Tarjeta Raspberry Pi Modelo 3B.
- Inversor.
- Sensores de Corriente.
- Sensores de Voltaje.
- Tarjeta Arduino UNO.
- Motor de inducción.

En la figura 52 se muestra el diagrama de bloques del sistema de control a implementar.

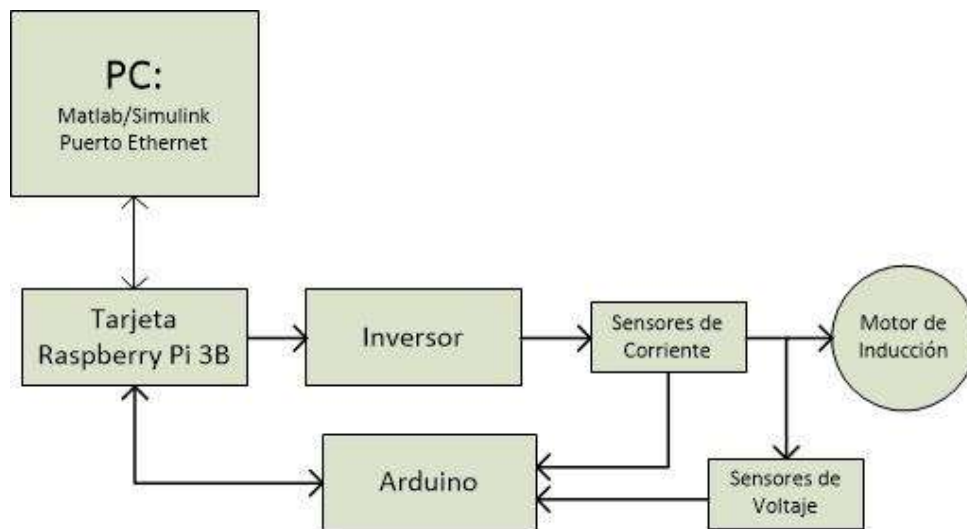


Figura 51. Diagrama en bloques del banco de pruebas.

5.4.1 Tarjeta Raspberry Pi

La tarjeta Raspberry es un computador básico de 85 x 56 mm, conocido también como una Computadora de Placa Simple (Single Board Computer, SBC), debido a que integra la mayoría de los elementos que componen una computadora funcional a un precio asequible.

La Raspberry Pi modelo 3B cuenta con un microprocesador de 1.2 GHz de cuatro núcleos, una memoria RAM de 1GB, 24 pines I/O. Estas características básicas convierten a esta tarjeta en una opción viable para la implementación de la estrategia de control.

A continuación, se presentan los datos técnicos más relevantes de la tarjeta Raspberry Pi modelo 3B.

- Microprocesador:
 - Chipset Broadcom BCM2387.
 - 1,2 GHz de cuatro núcleos ARM Cortex-A53 de 64 bits.
- RAM:
 - 1GB LPDDR2.
- Conectividad:
 - Ethernet socket Ethernet 10/100 BaseT
 - Conector GPIO (General Purpose Input/Output) para entradas y salidas digitales: Proporciona 27 pines GPIO, así como 3,3 V, +5 V y GND líneas de suministro
 - Ranura de tarjeta de memoria Empuje / tire Micro SDIO.

En la figura 53 se ilustra la tarjeta de desarrollo a utilizar.




Figura 52. Raspberry Pi 3B (Cruceira Aragón & Gonzalez Sanchez, s.f.)

5.4.2 Sensores de Corriente y Voltaje

El sensor de corriente utilizado en el banco de pruebas es el ACS712, del fabricante Allegro MicroSystems. Este sensor utiliza el efecto Hall para detectar el campo magnético que se produce por la inducción de la corriente que circula por la línea que se está sensando. El sensor entrega una señal de voltaje proporcional a la corriente medida. El modelo específico utilizado en este trabajo es el ACS712-05A, que tiene una sensibilidad de 185 mV/A, y trabaja con un voltaje de alimentación de 5V.

El sensor utilizado para sensar el voltaje de cada una de las líneas que alimentan el motor es el FZ0430. Este sensor es un divisor de voltaje con resistencias de 30 K y 7.5 K. La máxima tensión que puede medir este módulo es de 25 V, y usa una tensión de alimentación de 5V.

En las figuras 54 y 55 se muestran fotografías de los sensores de corriente y voltaje utilizados.




Figura 53. Sensor de Corriente.




Figura 54. Sensor de voltaje.

5.4.3 Arduino Uno.

Una de las limitantes de la tarjeta Raspberry es no contar con entradas ADC nativas. Por esto, se hace necesario utilizar una tarjeta Arduino UNO que sirva con intérprete entre los sensores de corriente y voltaje, que entregan una señal de voltaje analógica, y la tarjeta de desarrollo Raspberry, que, de manera nativa, recibe e interpreta señales binarias.

La tarjeta Arduino UNO cuenta con 6 pines de entrada analógica, por medio de los cuales se conectan los sensores de voltaje y corriente, y un conversor ADC de 10 bits de resolución. También cuenta con 14 pines de entrada y salida binaria. Entonces, la señal entregada por cada uno de los sensores se convierte en un número binario de 10 bits, el cual se envía de forma paralela a la tarjeta Raspberry Pi utilizando 10 pines I/O de la tarjeta Arduino. Adicionalmente, se envía a la tarjeta Raspberry una señal, utilizando para ello 3 pines más, para identificar a qué sensor corresponde el dato enviado en un instante determinado.

5.4.4 Motor de Inducción

El motor empleado para realizar las pruebas es un motor trifásico de marca Siemens, con referencia S1 IP55. Algunas de las características técnicas de dicha máquina son:

- 1 HP de potencia.
- Velocidad de 1660 RPM.
- Frecuencia de trabajo de 60 Hz.

En la figura 56 se muestran una imagen del motor con un freno inductivo acoplado; dicho freno hará las veces de carga para el motor.



Figura 55. Motor trifásico Siemens.

5.4.5 Sensor de velocidad.

Para capturar la data correspondiente a la velocidad del motor real y poder utilizarla en el entrenamiento de la RNA de estimador, se utilizó un sensor LM393, sensor infrarrojo de tipo herradura. En la imagen 57 se puede ver una fotografía del sensor. Este tipo de sensores está compuesto por un LED infrarrojo y un receptor infrarrojo, cada uno a un lado de la herradura; al interrumpirse el rayo de luz infrarroja, la salida del sensor se convierte en un cero lógico, y cuando el rayo no es interrumpido la salida es un uno lógico. Para sensar la velocidad con este tipo de instrumento se hace necesario acoplar un disco ranurado. Para el presente trabajo se utilizó un disco de 24 ranuras, el cual se muestra en la figura 58.




Figura 56. Sensor de velocidad.




Figura 57. Disco ranurado.

Para conocer la velocidad, se mide el tiempo que tarda el disco en dar una vuelta completa, es decir, se cuentan 24 pulsos bajos. Utilizando este tiempo se calcula la velocidad en RPM. En la figura 59 se muestra el código en Simulink utilizado para realizar dicho cálculo.

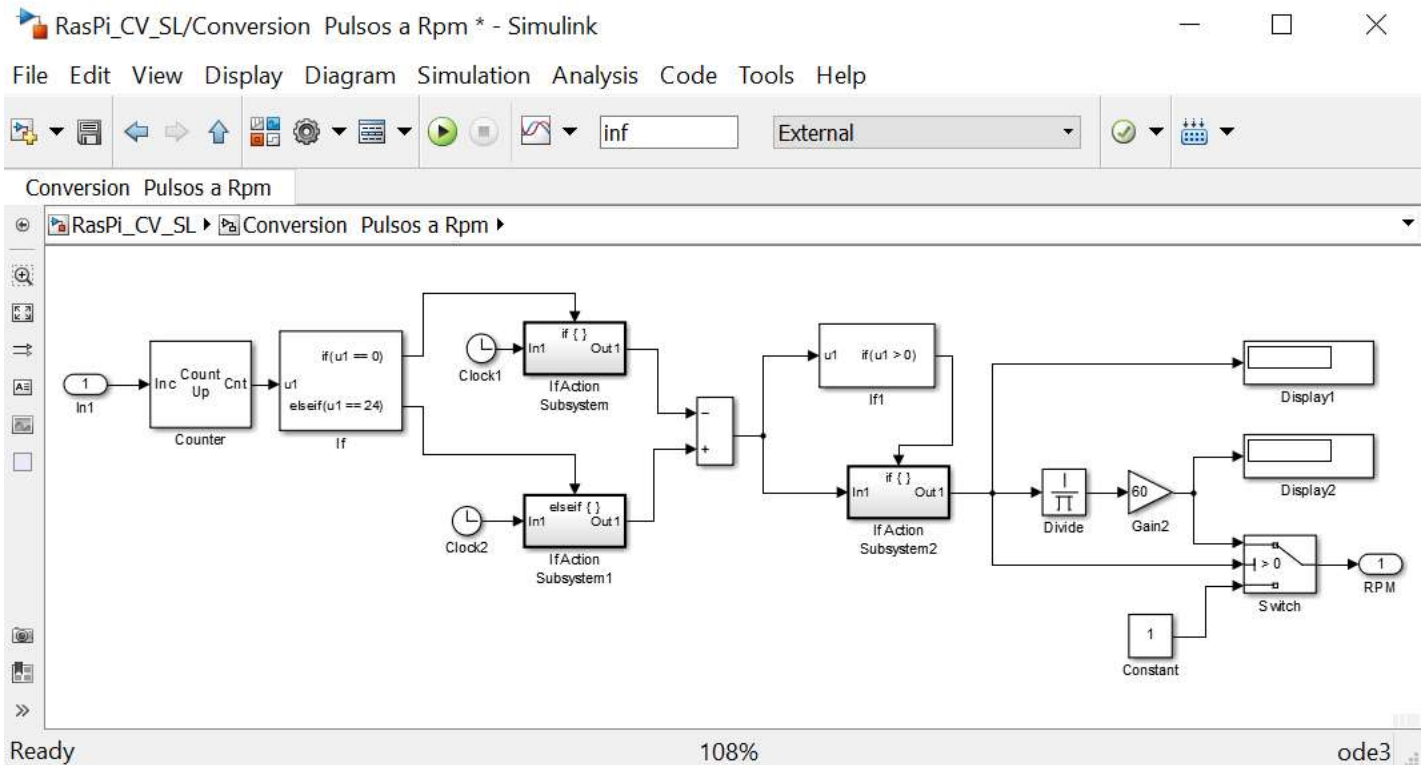


Figura 58. Diagrama de bloques del modelo para el cálculo de la velocidad.

5.4.6 Banco de pruebas.

En la figura 60 se muestran los elementos correspondientes a la etapa de control y potencia:

- Tarjeta Raspberry Pi modelo 3B.
- Sensores de voltaje y corriente.
- Tarjeta Arduino UNO.
- Fuente de voltaje.
- Circuito de potencia.

En la figura 61 se muestra una fotografía de todo el banco de pruebas completo, utilizado para llevar a cabo los experimentos concernientes al desarrollo del proyecto.




Figura 59. Etapa de Control y Potencia.




Figura 60. Banco de pruebas.

CAPITULO VI

VALIDACIÓN DEL SISTEMA

En el presente capítulo se muestran los resultados obtenidos a partir de la implementación del lazo de control vectorial. Se muestran las pruebas hechas con diferentes velocidades y cómo se comporta el sistema tanto en vacío como con carga. Se evidencia, así mismo, la robustez de las redes neuronales para el control vectorial sensorless cuando se aplica carga al motor.

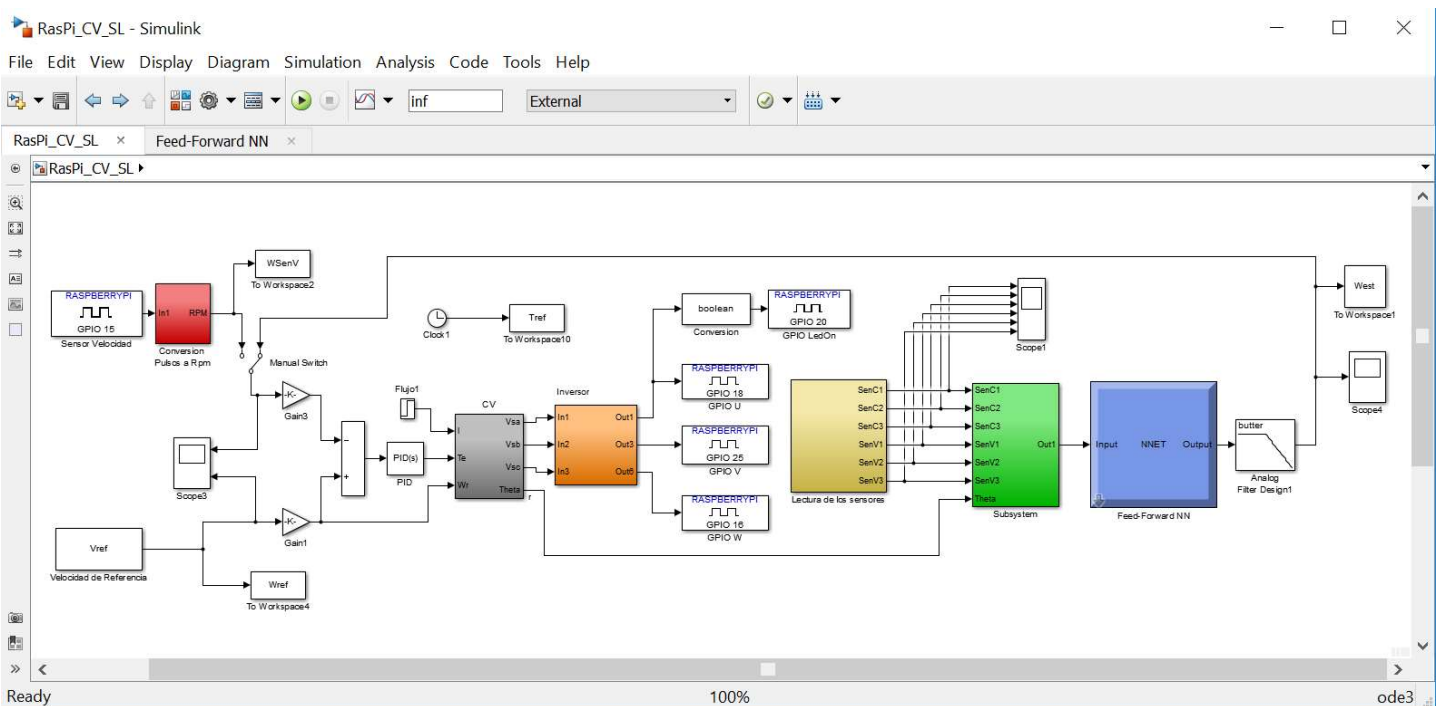


Figura 61. Diagrama de bloques usado para el estimador neuronal.

En la figura anterior, figura 62, se muestra el diagrama en bloques del estimador neuronal, dónde se agrega el bloque RNA (bloque azul), que se encarga de estimar la velocidad que tiene el motor, en función de los voltajes y corrientes de cada fase de la máquina. Esta señal de velocidad estimada será la utilizada para cerrar el lazo de control indirecto.

En las figuras 63 se observa el comportamiento de la velocidad del motor en vacío,

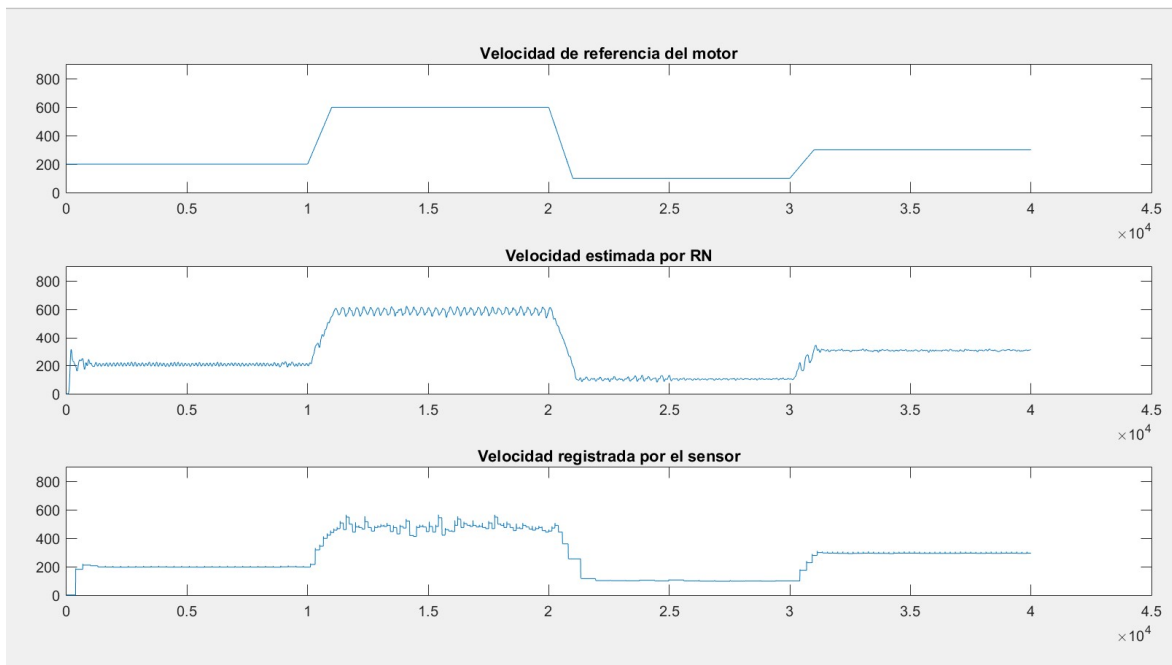



Figura 62. Respuesta del estimador neuronal para 100 200, 300 y 600 rpm.

En la anterior imagen se observan la velocidad de referencia (arriba), la velocidad estimada por la RNA (centro) y la velocidad medida por el sensor de herradura (abajo). Se inicia con una velocidad de 200 RPM, se produce luego un cambio de velocidad a 600 RPM, luego se baja la velocidad de referencia a 150 RPM y por último se establece la velocidad en 300 RPM.

Para validar que la velocidad del motor es la correcta, se utilizó un tacómetro manual para corroborar la velocidad del motor trifásico.

Los resultados de esta prueba se presentan en la figura 64. En la figura 64(a) se observan la velocidad de referencia (color verde), la velocidad estimada (color rojo) y la velocidad sensada por el sensor infrarrojo (color azul). En la figura 64(b) se muestran los resultados obtenidos con el tacómetro adicional.



(a)



(b)

Figura 63. Respuesta del estimador neuronal para 150, 300 y 400 rpm. (a)Comparación de las velocidades. (b) Registro de la velocidad con el tacómetro.

Como prueba final, se aplicó carga al motor, aplicando para ello tensión en el freno inductivo acoplado al rotor del motor. Se hicieron tres pruebas: 150 RPM, 200 RPM y 300 RPM.

En la figura 65 se muestran las velocidades obtenidas en la primera prueba. La secuencia fue la siguiente: se inició el sistema y a los 15 segundos se aplicó la carga, se observa que el sistema se estabiliza en el valor de referencia; a los 25 segundos se retiró la carga, se observa que la velocidad del sistema tiende a aumentar, pero la estrategia de control lo hace llegar, nuevamente, al valor de referencia.




Figura 64. Comportamiento del estimador neuronal en condición de carga para 150 rpm.

De la misma forma se hicieron pruebas a 200 rpm y 300 rpm. En las siguientes imágenes se puede observar el comportamiento del estimador neuronal.




Figura 65. Comportamiento del estimador neuronal en condición de carga para 200 rpm.




Figura 66. Comportamiento del estimador neuronal en condición de carga para 200 rpm.




Figura 67. Comportamiento del estimador neuronal en condición de carga para 300 rpm.




Figura 68. Comportamiento del estimador neuronal en condición de carga para 300 rpm.

CONCLUSIONES

Se demostró, por medio del presente trabajo, que es posible cerrar un lazo de control para una máquina de inducción trifásica, de tipo jaula de ardilla, utilizando, en lugar de un sensor de velocidad, una RNA que estime la velocidad del motor utilizando para ello las corrientes y voltajes de cada una de las fases de la máquina. Esto queda evidenciado en el análisis de las gráficas 63 a la 69, las cuales muestran la comparativa entre el sistema simulado, la velocidad estimada por la RNA y la velocidad real del motor.

Se concentraron los esfuerzos en controlar la máquina en un rango de RPM inferior a 500. Esto para demostrar que la técnica de control vectorial Sensorless es eficaz aún en dicho rango de velocidades. Una vez más, las gráficas 63 a la 69 muestran resultados positivos en dicho escenario.

Se demostró que el conjunto SIMULINK - Raspberry Pi 3B, es una solución, a nivel de hardware, válida para el problema presentado: controlar una máquina de inducción trifásica, a bajas velocidades, utilizando la estrategia control vectorial Sensorless.

Se demostró, por medio del trabajo realizado, que es posible diseñar y entrenar una RNA que estime la velocidad de una máquina de inducción, usando como data de entrenamiento diversos patrones de corriente y voltaje, característicos de diferentes velocidades de rotación de la máquina.

Las señales PWM, generadas por la tarjeta Raspberry Pi 3B, equivalentes a la señal de control, se convirtieron, con la ayuda de una tarjeta Arduino UNO, en las señales de disparo del inversor que controla los voltajes de cada una de las fases de la máquina. Con esto se demostró la viabilidad de la integración de las plataformas tecnológicas seleccionadas para llevar a cabo la estrategia de control diseñada en el presente trabajo.

Para terminar, se recomienda Implementar nuevas configuraciones de inversores para suministrar una onda senoidal con bajo contenido armónico para mejorar la

eficiencia energética del sistema evitando sobrecalentamiento en los devanados del motor evitando así la disminución de la vida útil de la máquina y explorar nuevas estrategias de inteligencia artificial en la estimación de velocidad para todo el rango de velocidad.

Efectuar nuevos proyectos de investigación tomando como base la presente investigación con el fin de analizar los inconvenientes y beneficios al utilizar una sola fase del sistema eléctrico (Sistema monofásico) y convertirla en tres fases.

Explorar sobre las limitaciones en intensidad de la corriente para realizarlo en motores de mayor potencia y visualizarlos en el medidor de red y computador.

BIBLIOGRAFIA

- Agrebi Zorgani, Y., Koubaa, Y., & Boussak, M. (2016). MRAS state estimator for speed sensorless ISFOC induction motor drives with Luenberger load torque estimation. *Science Direct*, 308-317.
- Ali Sowilam, G. (2000). *aplicación de las redes neuronales en los sistemas de control vectorial de los motores de inducción*. Universidad Politécnica de Cataluña.
- Ali Sowilam, G. (2000). *Aplicación de las redes neuronales en los sistemas de control vectorial de los motores de inducción*. Universidad Politécnica de Cataluña: Tesis doctoral.
- Aller, J. (2006). *MÁQUINAS ELÉCTRICAS ROTATIVAS: Introducción a la Teoría General*. Venezuela: Equinoocio.
- Aller, J., & Restrepo, J. (Junio de 2004). TÉCNICA COMBINADA DE CONTROL DE LA MÁQUINA DE INDUCCIÓN SIN SENSORES DE VELOCIDAD. *Revista de la Facultad de Ingeniería*.
- Alzate Gomes, A., Escobar Mejia, A., & Andres Torres, C. (2009). Control vectorial de la maquina de induccion. *Scientia et Technica Año XV, No 43,, 55-60*.
- (2012). *APLICACIÓN DE REDES NEURONALES AL CONTROL DE VELOCIDAD EN MOTORES DE CORRIENTE ALTERNA*. Universidad de Pamplona., Pamplona.
- Arnanzb, R., García, F., & Miguelc, L. (2016). Métodos de control de motores de inducción: síntesis de la situación actual Métodos de control de motores de inducción: síntesis de la situación actual. *Revista Iberoamericana de Automática e Informática industrial*, 381-392.
- Arnanzb, R., García, F., & Miguelc, L. (2016). Métodos de control de motores de inducción: síntesis de la situación actual. *Revista Iberoamericana de Automática e Informática industrial 13*, 381–392.
- Aros, N., & Aros, M. (2012). Control vectorial sin sensor de velocidad en la máquina de secado - CMPC celulosa Santa Fe. *XVI Congreso Internacional de Ingeniería de Proyectos Valencia*.
- Avendaño González, L., & González Tamayo , J. (2013). Simulación de control vectorial a un motor de inducción. *Scientia et Technica*.

- Barambones, O. (2009). A Sensorless Vector control of Induction Motor Drives based on Artificial Neural Networks. *Proceedings of the 7th IFAC Symposium*, 185-190.
- Barbi, I. (1988). *Introdução ao Estudo do Motor de Indução*. Universidade Federal de Santa Catarina,.
- Blaschke, F. (May 1972). The principle of field orientation as Applied to the New “transvektor” Close –loop Control system for Rotating- Field machines. *Siemens Rev*, 517-525.
- Caicedo P., E. (2014). *Diseño e implementación de un convertidor de potencia multinivel modular de 5 a 81 escalones*. Pamplona.
- Chan, T.-F., & Shi, K. (2011). *Applied intelligent control of induction motor drives*. Asia: John Wiley & Sons.
- Chapman, J. (2012). *Maquinas Eléctricas*. Mexico: : McGrawHill, Quinta Edición.
- Cheles, M. (2008). Sensorless Field Oriented Control (FOC) of an AC Induction Motor (ACIM). *Microchip Technology Inc*.
- Cruceira Aragón, R., & Gonzalez Sanchez, M. (s.f.). *ingeniérate*. Obtenido de <https://ingenierate.com/2017/10/03/raspberry-pi-caracteristicas-aplicaciones/>
- Diaz R, J. L., Cote U, J. E., & Pardo G, A. (2013). Inversor de Potencia PWM Didáctico. *LACCEI*.
- Diaz, J., & Pardo, A. (2006). Estrategias avanzadas de control en accionamiento de corriente alterna. *Revista Ciencia e Ingeniería. Vol. 25 No.1*.
- Douiri, M., & Nasser, T. (2010). Direct torque control of induction motor based on artificial neural networks with estimate and regulation speed using the mras and neural PI controller. *Journal of Theoretical and Applied Information Technology*.
- Fitzgerald, A., Kingsley, Jr., C., & Umans, S. (2003). *Electric Machinery*. New York: McGraw-Hill Higher Education.
- Fraile Mora, J. (2003). *Máquinas Eléctricas*. España: McGrawHill, quinta edición .
- González Castellanos , J., & Pabón Vanegas, E. (2015). comparación de la red neuronal y del filtro de kalman en la estimación de velocidad del motor de inducción. *Revista Ingeniería al Día*.

- Gunabalan, R., & Subbiah, V. (2015). Speed Sensorless Vector Control of Induction Motor Drive with PI and Fuzzy Controller. *International Journal of Power Electronics and Drive System (IJPEDS)*, 315-325.
- Haykin, S. (1999). *Neural Networks: A Comprehensive Foundation*. Upper Saddle River, NJ, USA: Prentice Hall.
- Hirokazu, T., & Hori, Y. (1993). Speed Sensorless Field - Orientation Control of the Induction Machine. *IEEE*.
- Holtz, J. (2002). Sensorless Control of induction motor drives. *IEEE*, 1359-1394.
- Hussain, S., & Abid Bazaz, M. (2016). Neural Network Observer Design for Sensorless Control of Induction Motor Drive. *ScienceDirect*, 106–111.
- João, C., & Palma, P. (1999). *Accionamentos Eletromecânicos de Velocidade Variável*. Lisboa: Fundação Calouste Gulbenkian.
- Kakhim, A., Rezak, M., & O'Kelly, D. (s.f.). A PWM inverter using on-line control algorithms. *UPEC*, 333-336.
- Kanmachi, T., & Takahashi, I. (1997). Sensorless Speed Control of a induction Motor with No influence of resistance Variation. *IEEE*.
- Markadeh, G., & Soltani, J. (2006). Robust Direct Torque and Flux Control of Adjustable Speed Sensorless Induction Machine Drive based on Space Vector Modulation using a PI Predictive Controller. *Electrical Engineering Vol. 88, No. 6*, 485 – 496.
- Martínez Q, C., Díaz R, J., & Pardo G, A. (2012). Aplicación de redes neuronales al control de velocidad en motores de corriente alterna. *Colombiana de Tecnologías de Avanzada, V 2 - Numero 20*.
- Martínez, C. (2012). *Aplicación de redes neuronales al control de velocidad en motores de corriente alterna*. Pamplona.
- Mehrotra, P., Quaicoe, J., & Venkatesan. (1996). Speed estimation of Induction Motor Using Artificial Neural Networks. *IEEE Ind. Applicat. Magazine*, 881-886.
- Montanari, M., Peresada, S., & Tilli, A. (2000). Speed Sensorless Control of Induction Motor based on Indirect Field - Orientation. *IEEE*.

- Orille, A., Sowilam, G., & Valencia, J. (1999). A new simulation of symmetrical three phase induction motor under transformations of park. *Computers & Industrial Engineering* 37, 359-362.
- Ponce Cruz, P. (2010). *Inteligencia Artificial con aplicaciones a la ingeniería*. México.: Alfaomega Grupo Editor, S.A. de C.V.
- Ponce Cruz, P. (2010). *Inteligencia artificial con aplicaciones a la ingeniería*. México: Alfaomega.
- Pyne, M., Chatterjee, A., & Dasgupta, S. (2014). Speed estimation of three phase induction motor using artificial neural network. *International Journal of Energy and Power Engineering*, 52-56.
- Pyne, M., Chatterjee, A., & Dasgupta, S. (2014). Speed estimation of three phase induction motor using artificial neural network. *International Journal of Energy and Power Engineering.*, 52-54.
- Rashid, M. (1995). *Electrónica de Potencia, Circuitos, dispositivos y aplicaciones*. Mexico: Prentice Hall Hispanoamericana, S.A.
- Richardson, D., & Caisse, A. (1997). *Máquinas Eléctricas Rotativas y Transformadores*. México: Prentice Hall, Cuarta Edición.
- Richardson, D., & Caisse, A. (1997). *Máquinas Eléctricas Rotativas y Transformadores*. México.: Prentice Hall, Cuarta Edición.
- Richardson, D., & Caisse, A. (1997). *Máquinas Eléctricas Rotativas y Transformadores*. México. : Prentice Hall, Cuarta Edición.
- Richardson, D., & Caisse, A. (1997). *Máquinas Eléctricas Rotativas y Transformadores*.
- Richardson, D., & Caisse, A. (1997). *Máquinas Eléctricas Rotativas y Transformadores*. México.: Prentice Hall, Cuarta Edición.
- Sánchez, S., & Giraldo, E. (2008). MODELADO DEL MOTOR DE INDUCCIÓN EN EL SISTEMA DE COORDENADAS DE. *Scientia et Technica, Universidad Tecnológica de Pereira.*, 89-93.
- Seijas, C., & Rodríguez, I. (2015). SIMULACIÓN DE MÁQUINAS A.C. CONTROLADAS VECTORIALMENTE USANDO REDES NEURONALES ARTIFICIALES. *Ingeniería UC*.

- Sotelo Neyra , V. (2007). Controlador de velocidad para motores AC utilizando técnicas de campo orientado y redes neuronales con un Sistema híbrido FPGA-DSP. 8º CONGRESSO IBEROAMERICANO DE ENGENHARIA MECANICA.
- Sung-Hoe, H., Kyo-Beum, L., & Dong-Won, K. (December 2005). Sensorless Speed Control System Using a Neural Network. *International Journal of Control, Automation, and Systems*, vol. 3, no. 4, 612-619.
- Tajima, H., & Hori, Y. (1991). Speed Sensorless Field Orientation control of the Induction Machine. *IEEE*.
- Vas, P., Stronach, A., & Rashed, M. (1999). Implementation of ANN - Based Sensorless Induction motor drivers. *IEEE*.
- Wildi, T. (2007). *Maquinas Electricas y Sisitemas de Potencia Sexta Edicion*. Mexico: PRENTICE HALL.
- Yoon , K., & Sang-Sun, K. (1998). Speed Sensorless Vector Control of High - Speed Induction Motors using intelligent Control Algorithm. *IEEE*.
- Zolfaghari, M., Abbas Taher, S., & Vindel Munuz, D. (2016). Neural network based sensorless direct power control of permanent magnet synchronous motor. *Science direct*, 729-740.
- Zolfaghari, M., Abbas Taher, S., & Vindel Munuz, D. (2016). Neural network-based sensorless direct power control of permanent magnet synchronous motor. *SCIENCEDIRECT*, 729–740.

ESTIMATION OF THE INDUCTION ENGINE SPEED USING NEURAL NETWORKS**ESTIMACIÓN DE LA VELOCIDAD DEL MOTOR DE INDUCCIÓN UTILIZANDO REDES NEURONALES**

Ing. Martin Gallo Nieves, PhD. Jaime António Gonzalez, MSc Jorge Luis Diaz, MSc Jesús A Velazco O.

Universidad de Pamplona, Grupo de investigación en **Sistemas Energéticos**.
Ciudadela Universitaria. Pamplona, Norte de Santander, Colombia.
Tel.: 57-7-5685303, Fax: 57-7-5685303, Ext. 144
E-mail: {martingallo6, gcjaime, jdiazcu, javelazco }@gmail.com

Abstract: This article presents a way to measure the speed of the induction motor and is estimating it (not measuring it directly from the motor rotor) and for this purpose artificial neural networks will be used; The development of the article begins with the modeling of the induction motor obtaining the equations of the stresses in the axes q and d referred to the stator and the rotor respectively. Having already the motor model, we proceed to do the neural network training with the data obtained from the simulation of the motor model in SIMULINK. And finally the results of the process for the estimation of the speed are presented.

Keywords: Induction motor, Speed estimation, artificial neural networks.

Resumen: En este artículo se presenta una forma de medir la velocidad del motor de inducción y es estimándola (no midiéndola directamente del rotor del motor) y para tal fin se va a utilizar redes neuronales artificiales; el desarrollo del artículo inicia con el modelado del motor de inducción obteniendo las ecuaciones de las tensiones en los ejes q y d referidas al estator y al rotor respectivamente. Teniendo ya el modelo del motor se procede a hacer el entrenamiento de la red neuronal con la data obtenida de la simulación del modelo del motor en SIMULINK. Y finalmente se presentan los resultados del proceso para la estimación de la velocidad.

Palabras clave: Motor de Inducción, Estimación de velocidad, redes neuronales artificiales.

1. INTRODUCCION

Los motores de inducción trifásicos o asíncronos son hoy en día los motores eléctricos más usados en los procesos industriales para suministrar potencia mecánica. Fuerte, robusto y sencillo con un mínimo mantenimiento (Richardson y Caisse, 1997) y (João y Palma, 1999).

Sin embargo, gran parte de los equipos utilizados en la industria deben funcionar a velocidades

variables y controladas de forma ágil y precisa para su buen desempeño.

Dentro de las estrategias de control de los motores de inducción, se hace necesario la medición de la velocidad del rotor, con la finalidad de cumplir con dichas estrategias, (González, Azevedo y Pacheco, 2000) y (González, 2000). Esta medición venía efectuándose a partir de medidores de velocidad analógicos que presentan problemas. Luego aparecieron medidores de velocidad discretos

tales como los resolver, encoder y medidores fotoelectricos que presentan algunas desventajas. En el presente trabajo pretende aplicar una estrategia de estimación de velocidad basado en inteligencia artificial utilizando redes neuronales que muestran excelentes resultados aplicando una estrategia novedosa a partir de la utilización de retardos de la data utilizada. (Mehrotra, Quaicoe y Venkatesan, 1996)

Para tal objetivo se inicia con el estudio del motor de inducción en régimen permanente para obtener el modelo matemático y así realizar la simulación y comprobación en diferentes condiciones de trabajo. Teniendo el modelo del motor se realiza el entrenamiento de la red Neuronal que sería una red tipo BACK PROPAGATION y los datos para el entrenamiento son los voltajes que alimentan al motor (Vds y Vdq) y las corrientes del motor (iqs e ids) y para un mejor resultado se van usar retardos.

2. EL MOTOR DE INDUCCIÓN

El motor de inducción trifásico tal como se muestra en la figura 1, está formado por un rotor, que puede ser de dos tipos: de jaula de ardilla ó rotor bobinado y un estator en el cual se alojan un devanado trifásico desfasado 120°. La función de éste devanado trifásico es la de producir el campo magnético B_s giratorio necesario para conversión de energía.




Fig. 1. Motor de Inducción

La velocidad de rotación del campo magnético está dada por (Chapman, 2012):

$$n_s = \frac{120 f_e}{P} \quad (1)$$

Dónde:

f_e = frecuencia del sistema (Hz)

P = Número de polos de la máquina.

2.1 Modelo matemático del Motor de Inducción

Para aplicar las diferentes técnicas de control de velocidad del motor de inducción se hace necesario de disponer de un modelo matemático que facilite el análisis del motor y la manipulación de las variables propias para el control; a continuación se presentan las ecuaciones de tensión de la máquina trifásica asumiendo los ejes de referencias d-q. (Gamal, 2000):

$$u_{qs} = p\phi_{qs} + \phi_{ds}\omega + r_s i_{qs} \quad (2)$$

$$u_{ds} = p\phi_{ds} - \phi_{qs}\omega + r_s i_{ds} \quad (3)$$

$$u'_{qr} = p\phi_{qr} + \phi'_{dr}(\omega - \omega_r) + r'_r i'_{qr} \quad (4)$$

$$u'_{dr} = p\phi'_{dr} - \phi'_{qr}(\omega - \omega_r) + r'_r i'_{dr} \quad (5)$$

Donde:

ϕ : son los enlaces de flujo.

u_{qs} y u_{ds} : tensiones del estator

u'_{qr} , u'_{dr} : tensiones del rotor que se asuman cero.

ω es la velocidad angular del sistema de referencia arbitrario y ω_r es la velocidad angular del rotor.

Las ecuaciones para corriente son:

$$i_{qs} = \frac{1}{x_{ls}} (\Psi_{qs} - \Psi_{mq}) \quad (6)$$

$$i_{ds} = \frac{1}{x_{ls}} (\Psi_{ds} - \Psi_{md}) \quad (7)$$

$$i'_{qr} = \frac{1}{x'_{lr}} (\Psi'_{qr} - \Psi_{mq}) \quad (8)$$

$$i'_{dr} = \frac{1}{x'_{lr}} (\Psi'_{dr} - \Psi_{md}) \quad (9)$$

Donde:

i_{qs} y i_{ds} : son las corrientes del estator en los respectivos eje q y el eje d.

i'_{qr} y i'_{dr} : las corrientes del rotor en los eje q y el eje d referidas al estator

Asumiendo un nuevo cambios de variables, se tiene: $\Psi_{qs} = \omega_e \phi_{qs}$

Siendo:

ω_e : la velocidad angular eléctrica base correspondiente a la frecuencia nominal.

X'_{ls} y X'_{lr} : reactancias de dispersión del estator y el rotor referidas al estator.

Las ecuaciones de tension resultantes son:

$$\Psi_{mq} = X_m (i_{qs} + i'_{qr}) \quad (10)$$

$$\Psi_{md} = X_m (i_{ds} + i'_{dr}) \quad (11)$$

Reemplazando las ecuaciones de corrientes en la ecuaciones de voltaje se tiene que las tensiones en los eje q y el eje d referidas al estator y al rotor resultantes:

$$\Psi_{qs} = \frac{\omega_e}{p} \left[u_{qs} - \frac{\omega}{\omega_e} \Psi_{ds} + \frac{r_s}{X'_{ls}} (\Psi_{mq} - \Psi_{qs}) \right] \quad (12)$$

$$\Psi_{ds} = \frac{\omega_e}{p} \left[u_{ds} - \frac{\omega}{\omega_e} \Psi_{qs} + \frac{r_s}{X'_{ls}} (\Psi_{md} - \Psi_{ds}) \right] \quad (13)$$

$$\Psi'_{qr} = \frac{\omega_r}{p} \left[u'_{qr} - \left(\frac{\omega - \omega_r}{\omega_e} \right) \Psi'_{dr} + \frac{r'_r}{X'_{lr}} (\Psi_{mq} - \Psi'_{qr}) \right] \quad (14)$$

$$\Psi'_{dr} = \frac{\omega_r}{p} \left[u'_{dr} - \left(\frac{\omega - \omega_r}{\omega_e} \right) \Psi'_{qr} + \frac{r'_r}{X'_{lr}} (\Psi_{md} - \Psi'_{dr}) \right] \quad (15)$$

La ecuación de Par:

$$M_e = \frac{n}{2} \frac{P}{2} \frac{1}{\omega_e} (\Psi'_{qr} i'_{dr} - \Psi'_{dr} i'_{qr}) \quad (16)$$

La ecuación de velocidad es:

$$\omega_r = \frac{1}{p} \left(\frac{M_e - M_l}{\frac{2}{P} J} \right) \omega_e \quad (17)$$

2.2 El Modelo para la simulación del Motor de Inducción

Acontinuación se presenta modelo del motor de inducción (Fig. 2) resultado de las ecuaciones de las tensiones en los eje q y el eje d referidas al estator y al rotor respectivamente, dicho modelo es realizado con los bloques de SIMULNK (Rodríguez, Pineda y Cárdenas, 2012) para la respectiva simulación.




Fig. 2. El modelo del motor

Antes de proceder a la simulación del modelo del motor en SIMULINK hay que hacer la tansfomación del sistema trifásico "abc" al sistema de referencia "dq", dicha transformación se hace con las siguientes ecuaciones:

Ecuaciones de transformación

$$\begin{bmatrix} f_{ds} \\ f_{qs} \\ f_{0s} \end{bmatrix} = \frac{2}{3} \begin{bmatrix} \cos \theta & \cos\left(\theta - \frac{2\pi}{3}\right) & \cos\left(\theta + \frac{2\pi}{3}\right) \\ -\text{sen} \theta & -\text{sen}\left(\theta - \frac{2\pi}{3}\right) & -\text{sen}\left(\theta + \frac{2\pi}{3}\right) \\ \frac{1}{2} & \frac{1}{2} & \frac{1}{2} \end{bmatrix} \begin{bmatrix} f_{as} \\ f_{bs} \\ f_{cs} \end{bmatrix}$$

En la figura 3, se muestra el modelo de abc's a dq's para la transformación del sistema trifásico "abc" al sistema de referencia "dq" realizado en SIMULINK.




Fig. 3. Transformación del sistema trifásico "abc" al sistema de referencia "dq".

Teniendo ya el sistema de referencia en "dq", se procede a la simulación dinámica del motor de inducción paa ver su comportamiento y que se hará en SIMULINK.




Fig. 4. Modelo del motor de inducción con PWM.

En la figura 4 se presenta el modelo completo que lo alimenta un sistema PWM; dicho modelo permite simular el motor en las siguientes de referencias:

- Sistema de referencia fijado al campo $\omega = \omega_e$
- Sistema de referencia fijado al rotor $\omega = \omega_r$
- Sistema de referencia fijado al estator $\omega = 0$

2.3 Resultados de la simulación

Los datos del motor que son utilizados para la simulación se presentan en la tabla 1 (González, Silveira y Pacheco, 2004).

Tabla 1. Datos del motor de inducción

Elemento	Valor
r_s	1.0 (ohm)
r_r	1.3(ohm)
L_r	144.6(mH)
M	35.4(mH)
P	2 polos
J	0.022 Kg-m ²
Lm	136.0 (mH)

Para el modelo con alimentación PWM, con los ejes de referencia (d-q), funcionando en vacío se procede a obtener las características de velocidad del rotor, torque y corrientes del estator con los sistemas de referencia fijado tanto en el estator $w=0$, como fijado al campo $w=w_e$, a partir del modelo mostrado en la figura 4.




Fig. 5. Señal de la velocidad del motor en vacío

La señal de velocidad resultante del modelo del motor se visualiza en la figura 5, donde muestra que la velocidad del motor alcanzó los 377 rad/seg en 1.5 segundos.




Fig. 6. Torque del motor en condición de vacío.




Fig. 7. Torque vs Velocidad del rotor en vacío

El torque del motor de inducción en condición de vacío se observan en las figuras 6 y 7, en función del tiempo (fig. 6) y en función de la velocidad del rotor en vacío (fig. 7).




Fig. 8. Corrientes del estator con el eje de referencia d-q en el estator.




Fig. 9. Corrientes del estator con el eje de referencia d-q girando a la velocidad sincrónica.

En las figuras 8 y 9, muestran las corrientes del estator en el eje d-q, para diferentes posiciones de dicho eje de referencia; mostrando que las corrientes de la figura 9, no son senoidales y por tanto es la que se va a usar para el entrenamiento de la red neuronal propuesta para disminuir la complejidad de la misma.

3. IMPLEMENTACIÓN DEL ESTIMADOR

Dentro de la estrategia de estimación con inteligencia artificial que se va a aplicar en éste son las redes neuronales artificiales (RNA), siendo estas inspiradas en la estructura y funcionamiento de los sistemas nerviosos, donde la neurona es el elemento fundamental. (Ponce, 2010) y (Gallo y Duran, 2007) siendo estas las encargadas de aprender un comportamiento basado en una información de entrada y que sean capaces de tomar acciones basado en el entrenamiento de las mismas (Martínez, Díaz y Pardo, 2012) y (Araque, Díaz y Gualdrón, 2013).




Fig. 10. Arquitectura de la red neuronal artificial.

En general las neuronas suelen agruparse en estructuras llamadas capas y que se pueden distinguir tres tipos de capas, la capa de entrada, capa de salida y la capa oculta tal como se muestra en la figura 10 (Caballero, Velasco y Pardo, 2013)

3.2 Configuración de la Red Neuronal propuesta.

El diagrama de bloques usado para la estimación de la velocidad del motor es el que se ve en la figura 11, la red neuronal que se implementó es la BACK PROPAGATION que emplea el método de aprendizaje automático supervisado.




Fig. 11. Diagrama de bloques general para la estimación de la velocidad con red neuronal.

Los datos que se usaron para el entrenamiento de la red neuronal son las dos señales de voltaje que alimentan al motor (V_{ds} y V_{dq}) y las dos señales de corriente de salida del motor girando a la velocidad sincrónica (i_{qs} e i_{ds}).

Para dar mayor robustez en el estimador se usaron retardos en la data para el entrenamiento de la red neuronal como se observa en la figura 12.




Fig. 12. Data para el entrenamiento de la RN

En la creación de la red neuronal se usaron 1 neuronas en la capa oculta, 12 neuronas en la capa de entrada y 1 neurona en la capa de salida.

Haciendo uso del comando newff que lo dispone el MATLAB, y de esta forma se crea la red neuronal artificial. Y para el entrenamiento de la red se hizo con el comando trainlm.

```
net = newff([MinMax],[12 3 1],{'tansig' 'tansig' 'purelin'},'trainlm');
```

```
net=trainlm(net,Inp',Out');
```

El entrenamiento de la red neuronal demoró 47 segundos para 500 interacciones.




Fig. 13. Diagrama de bloques del modelo para la estimación con redes neuronales.

En la figura 13 se tiene el diagrama en bloques del modelo del motor con las redes neuronales que se entrenaron con 2 y 3 retardos de la data y dicho modelo se simulará en SIMULINK.

Para revisar el comportamiento de la estrategia utilizada para la estimación se va a simular el motor en vacío y con carga.

Realizando la simulación del modelo con las redes entrenadas, tenemos las señales que se ven en la figura 14.




Fig. 14. Resultados de la estimación

Se puede apreciar en la figura 14, que la red neuronal la que mejor dio resultado, es la señal con la red neuronal de usando 3 retardos y en la figura 15, se muestra la comparación de la velocidad real (color azul) con la señal estimada (color rojo), mostrando muy buenos resultados.

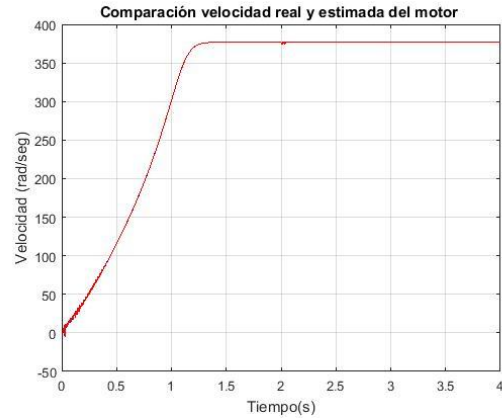


Fig. 15. Señal de velocidad estimada al vacío

Por ultimo nos queda probar la red neuronal aplicándole carga al motor, y el resultado obtenido se ve en la figura 16, donde muestra la comparación entre la señal de velocidad estimada con la real y los resultados son muy buenos, la red neuronal demostró ser robusta pues ha respondido muy bien ante los cambios del motor.

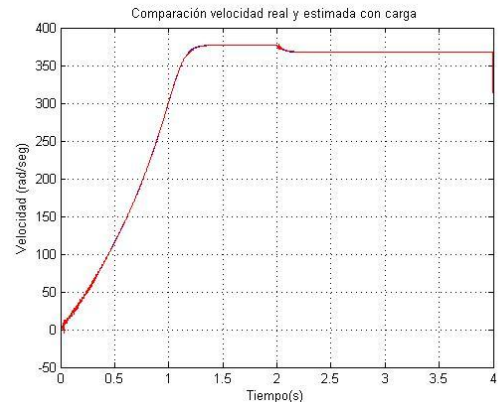


Fig. 16. Señal de velocidad estimada con carga

4. CONCLUSIONES

- Las redes neuronales mostraron ser una buena estrategia para la estimación de la velocidad, ya que al compararla con la velocidad del motor coinciden con la señal estimada (entregada por la red neuronal).
- A partir de la figura 14 se demuestra que la red neuronal muestra una mejor respuesta al utilizar 3 retardos en la data de entrenamiento.
- La robustez mostrada por el estimador es adecuada para las variaciones de carga del motor, como se observa en la figura 16.

REFERENCIAS

- Richardson, D. y Caisse, A. (1997). Máquinas Eléctricas Rotativas y Transformadores, Prentice Hall, Cuarta Edición, México.
- João, C. y Palma, P. (1999). Accionamentos Eletromecânicos de Velocidade Variável, Fundação Calouste Gulbenkian, Lisboa,
- González, J. Azevedo, M. y Pacheco, E. (2000). “Control vectorial del Motor de Inducción para el Control de Velocidad del Rotor por cambio de Frecuencia”, II Congreso Venezolano de Ingeniería Eléctrica, Mérida,
- González, J. (2000). “Considerações sobre o Controle dos Motores de Indução Alimentados por Conversores Estáticos”, Dissertação de Mestrado, PUC-Rio, Agosto.
- Mehrotra , P. Quaicoe, J. y Venkatesan. (1996) “Speed estimation of Induction Motor Using Artificial Neural Networks”. IEEE Ind. Applicat. Magazine, pp 881-886.
- Chapman, J. Maquinas Eléctricas,(2012) Editorial, McGrawHill, Quinta Edición
- Gamal, A. (2000) “Tesis: aplicación de las redes neuronales en los sistemas de control vectorial de los motores de inducción”, departamento de Ingeniería Eléctrica, Universidad Politécnica de Cataluña.
- Rodríguez, Oscar. Pineda, R. Cárdenas Pedro. (2012). Herramientas EJS 3D/MATLAB para el control del sistema no lineal aplicado al péndulo invertido sobre carro deslizante. Revista colombiana de tecnologías de Avanzada. 1 (19). Pág. 28 – 34.
- González, J. Silveira, M. y Pacheco, J. (2004). Comparación de la red neuronal y el filtro de Kalman en la estimación de velocidad del motor de inducción.
- Ponce C., P. (2010). Inteligencia artificial con aplicaciones a la ingeniería, Editorial McGrawHill, México
- Gallo N., M. Duran A.,C. (2007) Integrated System Approach for the Automatic Speech Recognition using Linear predict Coding and Neural Networks. IEEE, Electronics, Robotics and Automotive Mechanics Conference. CERMA 2007
- Martínez Q., C. Díaz R., J. L. y Pardo G., A. (Junio de 2012). Aplicación de redes neuronales al control de velocidad en motores de corriente alterna. Revista Colombiana de Tecnologías de Avanzada, V 2 - Numero 20.
- Araque G J., Díaz R J.L., Gualdrón G O.E. (2013). Optimización del THD en un convertidor multinivel monofásico usando algoritmos genéticos. Revista colombiana de tecnologías de Avanzada. 1 (21). Pág. 60 - 66.
- Caballero A, Velasco G, Pardo García A. (2013). Differentiations Of Objects In Diffuse Databases. Revista colombiana de tecnologías de Avanzada. 2 (22). Pág. 131 – 137.