



ESCUELA SUPERIOR POLITÉCNICA DEL LITORAL

Facultad de Ingeniería en Electricidad y Computación

**“ESTIMACIÓN DE LA VELOCIDAD DE UN MOTOR DE
INDUCCIÓN TRIFÁSICO UTILIZANDO REDES
NEURONALES”**

TRABAJO DE TITULACIÓN

Previo a la obtención del Título de:

**MAGISTER EN AUTOMATIZACIÓN Y CONTROL
INDUSTRIAL**

JOSÉ LUIS ROCANO TENEZACA

GUAYAQUIL – ECUADOR

AÑO: 2018

AGRADECIMIENTOS

Un agradecimiento especial a la Escuela Superior Politécnica del Litoral por haberme admitido en la maestría; de igual manera a los docentes por la buena voluntad en su enseñanza. También al director de mi proyecto el Doctor Douglas.

DEDICATORIA

Quiero dedicar este trabajo que lo he realizado con mucho esfuerzo a todos mis seres queridos en especial a mi Esposa Nancy, mi hija Yadira Marisol y a mi hijo Josué Agustín. Dando gracias al Creador espero que los días venideros sean los más felices disfrutando este logro que también les pertenece.

TRIBUNAL DE EVALUACIÓN

.....
Ph.D. César Martín
SUBDECANO DE LA FIEC

.....
Ph.D. Douglas Plaza
DIRECTOR DEL TRABAJO DE TITULACIÓN

.....
M.Sc. Denis Cortés
MIEMBRO PRINCIPAL DEL TRIBUNAL

DECLARACIÓN EXPRESA

"La responsabilidad y la autoría del contenido de este Trabajo de Titulación, me corresponde exclusivamente; y doy consentimiento para que la ESPOL realice la comunicación pública de la obra por cualquier medio con el fin de promover la consulta, difusión y uso público de la producción intelectual"

.....
José Luis Rocano Tenezaca

RESUMEN

El presente proyecto trata sobre la estimación de velocidad angular en un motor de inducción trifásico. El método utilizado está basado en la inteligencia artificial a través de las redes neuronales cuya estructura consta de una capa entrada, una oculta, y la salida que corresponde a la velocidad del motor, teniendo 9 entradas, 10 neuronas en la capa oculta y una neurona en la capa de salida. La sintonización de los pesos sinápticos se lo realizará mediante el algoritmo de retropropagación. La parte práctica de este proyecto consiste en obtener los valores de inductancias y resistencias del motor de inducción trifásico. Para ello se realiza la medición de los voltajes y corrientes trifásicos instantáneos en el instante del arranque de la máquina con un tiempo de duración de 10 segundos. Los datos son procesados y transformados a un sistema de referencia del cual se tratará en los capítulos siguientes. Mediante optimización no lineal se encuentran los valores de dichos parámetros.

Para verificar el método, se hace un estudio del algoritmo Filtro Extendido de Kalman; cuyas matrices de covarianzas se sintonizan mediante un algoritmo genético de la plataforma Matlab.

ÍNDICE GENERAL

AGRADECIMIENTOS.....	ii
DEDICATORIA.....	iii
TRIBUNAL DE EVALUACIÓN.....	iv
DECLARACIÓN EXPRESA.....	v
RESUMEN.....	vi
ÍNDICE GENERAL.....	vii
AGRADECIMIENTOS.....	ii
CAPÍTULO 1.....	1
1. ANTECEDENTES.....	1
1.1 Descripción del problema.....	1
1.2 Solución al problema propuesto.....	1
1.3 Objetivo General.....	2
1.4 Objetivos específicos.....	2
1.5 Metodología.....	2
1.6 Alcance del presente trabajo.....	7
CAPÍTULO 2.....	8
2. MARCO TEÓRCIO.....	8
2.1 Modelo dinámico del motor trifásico.....	8
2.2 Métodos de estimación de los parámetros del motor.....	16
2.3 Métodos de la estimación de la velocidad en motores trifásicos.....	19

2.4 Algoritmo basado en redes neuronales artificiales aplicados en la estimación de variables y parámetros de un motor trifásico.....	20
2.5 Estimación en motores de inducción mediante la aplicación del filtro extendido de Kalman.....	27
CAPÍTULO 3.....	32
3. ESTIMACIÓN DE LOS PARÁMETROS DEL MOTOR.....	32
3.1 Implementación del sistema de adquisición de datos del motor trifásico.....	32
3.2 Identificación del modelo del motor mediante el procesamiento de los datos obtenidos	36
3.3 Validación del modelo propuesto del motor trifásico.....	40
CAPÍTULO 4.....	46
4. IMPLEMENTACIÓN Y ANÁLISIS DEL ESTIMADOR DE VELOCIDAD.....	46
4.1 Configuración de la red neuronal como estimador de velocidad.....	46
4.2 Proceso de entrenamiento de la red neuronal.....	48
4.3 Implementación del control voltaje frecuencia para regular la velocidad del motor trifásico.....	59
4.4 Implementación del filtro extendido deKalman como estimador de velocidad	67
4.5 Análisis comparativo del desempeño de los estimadores basados en redes neuronales y filtro extendido de Kalman.....	74
CONCLUSIONES Y RECOMENDACIONES.....	76
BIBLIOGRAFÍA.....	78

CAPÍTULO 1

1. ANTECEDENTES

En este capítulo se expone la ubicación del problema, así como también los objetivos a perseguir ya que de estos dependerá el alcance de este trabajo. De igual manera se establece una metodología para comenzar el estudio del motor de inducción trifásico que consiste en la revisión del estado del arte sobre temas que involucran, modelado del motor de inducción, estimación de la velocidad mediante inteligencia artificial y filtro extendido de Kalman.

1.1 Descripción de problema.

El motor de inducción trifásico es un sistema no lineal y multivariable ya que el flujo electromagnético, la velocidad, la posición y el par electromagnético pueden presentarse como salidas. El problema surge del acoplamiento de estas variables ya que limitan el control de la velocidad del motor; además agréguese a la incertidumbre paramétrica debido a la variación de la resistencia de los devanados del estator así como también la resistencia del rotor al subir la temperatura cuando el motor se encuentra en operación continua. La velocidad angular del eje del motor se puede medir a través de un encoder, pero la señal puede ser afectada por el ruido electromagnético y genera incertidumbre en el proceso de cuantización en la conversión de la señal analógica a digital.

1.2 Solución al problema propuesto.

En el presente trabajo se desarrolla el modelo del motor de inducción trifásico en el marco de referencia estacionario cuyas ecuaciones diferenciales tienen como coeficientes constantes los valores de las inductancias y resistencias del motor. El sistema se presenta en variables de estados en donde la velocidad angular del motor es la salida. Para superar el inconveniente que se tiene en la medida de la velocidad del motor a través del encoder se propone la estimación de la misma utilizando la inteligencia artificial a través de las redes neuronales artificiales.

1.3 Objetivo General.

El objetivo principal de este trabajo es desarrollar un estimador de velocidad utilizando las Redes Neuronales Artificiales basado en las ecuaciones dinámicas del motor de inducción trifásico jaula de ardilla. Para validar el rendimiento de la técnica a implementar en el presente trabajo, el estudio comprende el análisis comparativo con el Filtro Extendido de Kalman.

1.4 Objetivos específicos.

- Identificar matemáticamente el modelo del motor de inducción trifásico jaula de ardilla en el marco de referencia estacionario.
- Diseñar una red neuronal artificial multi-capa basada en el algoritmo de entrenamiento de retropropagación para sintonizar los pesos sinápticos.
- Comparar y evaluar el desempeño del estimador de velocidad con un filtro de Kalman.

1.5 Metodología.

En este trabajo se presenta la estimación de la velocidad angular del motor de inducción trifásico aplicando las redes neuronales artificiales las mismas que han sido utilizadas, para identificación de parámetros del motor, en la electrónica de potencia para modulación y control.

Para comenzar el estudio del motor de inducción trifásico así como también de la estimación de la velocidad; a continuación se hace una revisión de los artículos en donde se puede destacar el uso del modelo del motor de inducción trifásico en el marco de referencia estacionario. Es importante también destacar la nomenclatura utilizada por los autores, si observamos (α, β) , o (d, q) en las gráficas de este trabajo estaremos tratando del mismo sistema de referencia ortogonal.

En 1995 [1] propone usar una red neuronal artificial (RNA) para la identificación y control de velocidad de un motor de inducción en donde destaca la utilidad del modelo electromagnético en variables de estado establecido en el marco de referencia estacionario (α, β) en tiempo discreto. También menciona que todo sistema no lineal puede ser descrito por un modelo tipo NARMAX (Non-linear Auto Regressive Moving Average with eXogenous inputs) como de la ecuación (1.1).

$$y(k + 1) = f(y(k), \dots, y(k - d_y), u(k), \dots, u(k - u_u)) \quad (1.1)$$

En la Figura 1.1 se puede observar en diagrama de bloques un modelo con propósitos de identificación. Si por ejemplo se desea obtener el modelo del motor de inducción trifásico; la entrada $U(k)$ sería una señal de control industrial de 0 a 20mA o de 0 a 10 Vdc; esta actuará sobre un variador de frecuencia y se obtendrá la salida $Y(k)$ que corresponde a la velocidad del motor.

Este artículo aporta con información valiosa en el sentido que da la pauta para manipular las ecuaciones del modelo dinámico; ya que se requiere variables que sean medibles para ingresar a la red neuronal propuesta.

Al comenzar el estudio de esta parte de la inteligencia artificial, es preciso mencionar que una red neuronal esta compuesta por n capas; en donde el número de neuronas en la primera y última capa son fijas mientras que para las capas intermedias se determinan heurísticamente mediante el entrenamiento de la red.

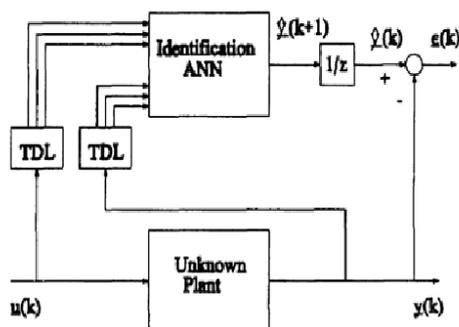


Figura 1.1: Sistema de identificación usando redes neuronales. Tomado de [1]

En [2] se presenta un método de estimación de velocidad del motor de inducción trifásico cuyo modelo es el marco de referencia estacionario, en este sistema se requiere medir los voltajes de fase y corrientes de línea. Las ecuaciones de modelo dinámico son arregladas de tal manera que los flujos magnéticos queden como variables de estado.

Como se puede observar en la Figura 1.2 el sistema necesita que las entradas a la red neuronal sean los flujos denotados en los respectivos ejes; sin embargo

estos no pueden ser medidos directamente razón por la cual se utiliza las ecuaciones de voltaje y corriente para estimarlos. Se cita este artículo debido a que trata sobre las características que tienen las redes neuronales, por mencionar algunas, inmunidad al ruido, tolerancia a fallas y aproximador de funciones no lineales.

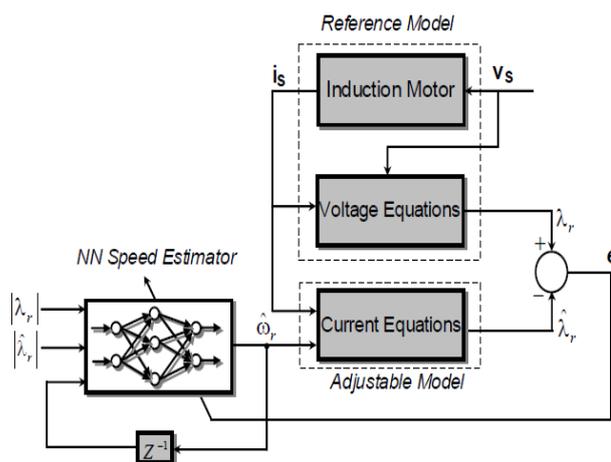


Figura 1.2: Estructura de estimador de velocidad. Tomado de [2]

Una aseveración importante que se encuentra en este artículo, es que el entrenamiento de la red neuronal, bajo diferentes condiciones de carga del motor de inducción trifásico, servirá para estimar la velocidad tanto en estado transitorio como en estado estable.

Para 2009 [3] utiliza un perceptrón multicapa o MPL, por sus siglas en inglés, el cual está entrenado con el algoritmo de retropropagación. El autor hace énfasis en la transformación de las ecuaciones diferenciales de corriente y voltaje en tres (a, b, c) hacia un sistema de referencia ortogonal en dos ejes (α, β), en donde las ecuaciones diferenciales tienen coeficientes constantes cuyos valores corresponden a las inductancias y resistencias del motor trifásico.

La metodología para la estimación de la velocidad mecánica propuesta en este artículo se puede observar en la Figura 1.3.

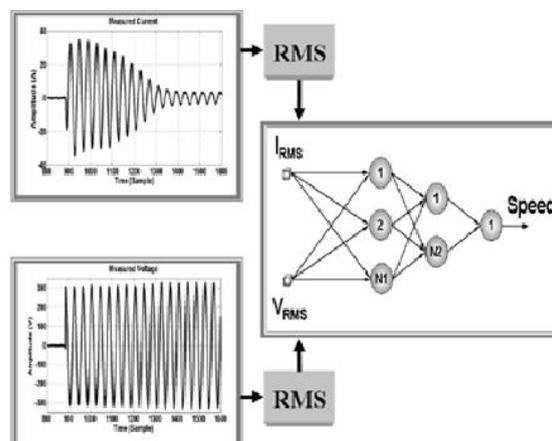


Figura 1.3: Metodología para la estimación de velocidad. Tomado de [3]

El artículo [4] presenta la estimación de la velocidad del motor de inducción cuyo modelo matemático está referido al sistema de referencia estacionario. En este caso las ecuaciones dinámicas importantes son las que denotan el flujo magnético producido por el rotor. Para que sea aplicable la técnica en tiempo real los autores han realizado diversas simplificaciones hasta llegar a la ecuación (1.2).

$$\omega_r = f(V_s(k), V_s(k-1), V_s(k-2), i_s(k), i_s(k-1), \dots, i_s(k-3)) \quad (1.2)$$

Esta ecuación resultante es capaz de estimar la velocidad mecánica del motor de inducción en todo el rango. En la Figura 1.4 se puede observar la estructura para dicha estimación.

También es necesario hacer referencia a la estimación de la velocidad del motor de inducción trifásico por medio del Filtro Extendido de Kalman o EKF, por sus siglas en inglés. El artículo [5] presenta un trabajo experimental, el algoritmo se basa en el modelo dinámico en espacio de estados cuyas variables son los flujos, corrientes en el marco de referencia estacionario y la velocidad angular. Además se realiza un modelo aumentado con el torque con el propósito de observar el comportamiento de la fricción de Coulomb; ya que esta deteriora el control del motor a bajas velocidades. En la Figura 1.5 se puede ver la estructura del algoritmo.

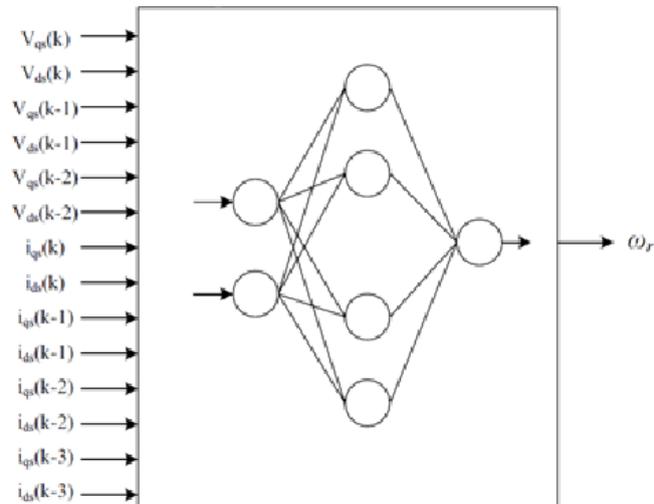


Figura 1.4: Estructura para la estimación de velocidad. Tomado de [4]

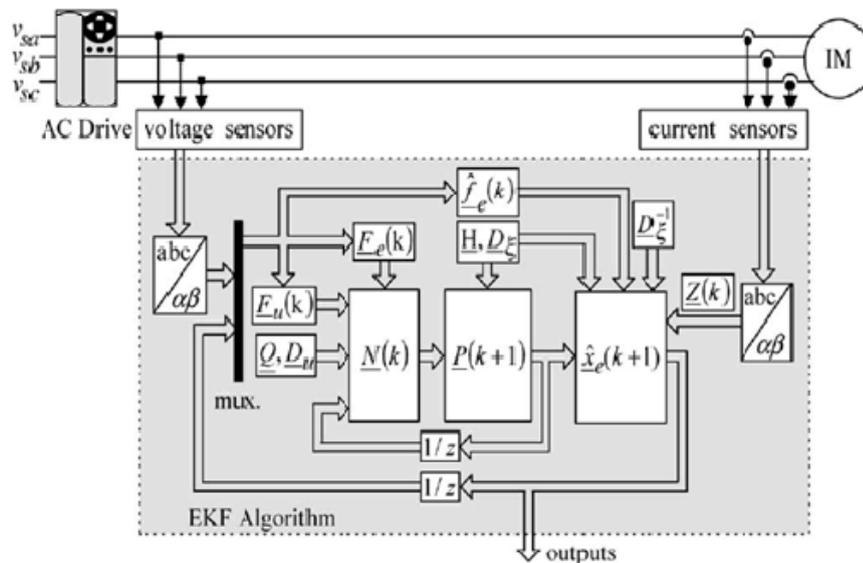


Figura 1.5: Estructura experimental para estimación de velocidad. Tomado de [5]

El artículo [9] detalla ampliamente el algoritmo del Filtro Extendido de Kalman, haciendo uso del modelo dinámico del motor en espacio de estados en tiempo discreto. En este se pueden encontrar cada uno de los pasos y la estructura de las

ecuaciones, así como también las matrices que requiere el algoritmo para la estimación de la velocidad.

Al concluir con la revisión de la literatura, se procede con las simulaciones, del modelo vectorial, con el objeto de observar la respuesta de velocidad ya que este utiliza los parámetros de resistencias e inductancias estimadas mediante optimización, teniendo como entrada al algoritmo valores medidos de corrientes y voltajes trifásicos.

1.6 Alcance del presente trabajo

El desarrollo del presente trabajo de titulación nos permitirá contar con una metodología para la estimación de los parámetros del motor de inducción mediante técnicas de optimización de la impedancia de entrada en el instante de arranque del motor. También se muestra que la inteligencia artificial y observadores de estado pueden ser aplicados a sistemas reales, mediante el desarrollo de accionamientos que sean capaces de controlar la velocidad del motor aplicando dichos algoritmos.

CAPÍTULO 2

2. MARCO TEÓRICO

En este capítulo se presentan las herramientas que nos servirán, para el modelamiento del motor de inducción trifásico en espacio de estados. Para ello se parte de las ecuaciones instantáneas de voltaje para posteriormente ser transformadas a un sistema ortogonal. También se hace referencia a los métodos de estimación de velocidad en motores trifásicos mediante técnicas de optimización utilizando Matlab y finalmente se obtienen los algoritmos tanto de inteligencia artificial como filtro extendido de Kalman propuestos en los objetivos específicos

2.1 Modelo dinámico del motor trifásico

El motor trifásico se compone de dos partes, denominados estator y rotor. La primera consta de bobinados que están separados geoméricamente 120 grados. A las bobinas se alimenta una tensión sinusoidal balanceada, con amplitud acorde al diseño de la máquina, desfasada eléctricamente 120 grados la cual produce una corriente y esta a su vez un campo magnético rotatorio de amplitud constante en el tiempo pero que varía en el espacio; la velocidad de este campo esta en función del número de polos de la máquina, la frecuencia de alimentación y se define como la velocidad de sincronismo cuya unidad de ingeniería es revoluciones por minuto y se expresa de la siguiente manera.

$$s = 120 \frac{f}{p} \quad (2.1)$$

En donde f es la frecuencia de la tensión de alimentación y p el número de polos.

El campo magnético producido por el estator envuelve el núcleo ferromagnético del rotor girando a su alrededor; a partir de ese instante existe un voltaje que se induce en el bobinado del rotor, esto provoca que circule una corriente, generando un campo magnético que interactúa con el campo magnético del estator, este último lo arrastra y por consiguiente

al núcleo ferromagnético dando lugar a la conversión de energía eléctrica en mecánica. En la Figura 2.1 se puede observar un esquema de las bobinas del motor trifásico de inducción.

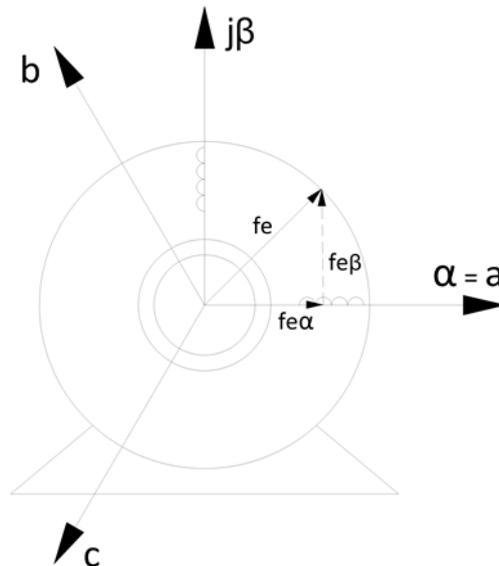


Figura 2.1: Esquema de las bobinas de un motor trifásico

Debido a que las partes del motor están en un movimiento circular, hace que los parámetros tales como las inductancias cambien en el tiempo debido a la orientación espacial del rotor, haciendo que el sistema sea aún más complejo. Para simplificar el modelo de la máquina de inducción se toman las siguientes consideraciones.

- Estator y rotor lisos (entrehierro constante)
- Máquina de inducción trifásica equilibrada y simétrica (bobinas de estator idénticas por y bobinas equivalentes de rotor por fase).
- Comportamiento magnético del hierro lineal prescindiendo de la saturación.
- Permeabilidad magnética del hierro elevada (reluctancia magnética despreciable frente a la del entrehierro).

- Distribución sinusoidal del campo en el entrehierro.

A continuación se desarrolla el modelo del motor de inducción trifásico partiendo de las ecuaciones de voltaje instantáneos en el estator y rotor que rigen el comportamiento de la máquina de la Figura 2.1, en el marco de referencia estacionario.

$$v_{ea} = R_e i_{ea} + \frac{d\lambda_{ea}}{dt} \quad (2.2)$$

$$v_{eb} = R_e i_{eb} + \frac{d\lambda_{eb}}{dt} \quad (2.3)$$

$$v_{ec} = R_e i_{ec} + \frac{d\lambda_{ec}}{dt} \quad (2.4)$$

$$v_{ra} = R_r i_{ra} + \frac{d\lambda_{ra}}{dt} \quad (2.5)$$

$$v_{rb} = R_r i_{rb} + \frac{d\lambda_{rb}}{dt} \quad (2.6)$$

$$v_{rc} = R_r i_{rc} + \frac{d\lambda_{rc}}{dt} \quad (2.7)$$

En donde R_e y R_r corresponden a las resistencias de cada uno de los devanados del estator y rotor, λ_e y λ_r a los flujos magnéticos que atraviesan las espiras del estator y rotor; de igual manera los índices a , b , c indican las fases del motor, recordando que los voltajes y corrientes varían en el tiempo.

Estas ecuaciones que están en un sistema de tres ejes pueden ser transformadas a un sistema de dos ejes utilizando la teoría introducida por Park como menciona [8].

Los vectores espaciales que representan los voltajes, corrientes y enlaces de flujos de las ecuaciones antes mencionadas están dadas por;

$$V_e = c[1v_{ea}(t) + av_{eb}(t) + a^2v_{ec}(t)] \quad (2.8)$$

$$I_e = c[1i_{ea}(t) + ai_{eb}(t) + a^2i_{ec}(t)] \quad (2.9)$$

$$\lambda_e = c[1\lambda_{ea}(t) + a\lambda_{eb}(t) + a^2\lambda_{ec}(t)] \quad (2.10)$$

$$V_r = c[1v_{ra}(t) + av_{rb}(t) + a^2v_{rc}(t)] \quad (2.11)$$

$$I_r = c[1i_{ra}(t) + ai_{rb}(t) + a^2i_{rc}(t)] \quad (2.12)$$

$$\lambda_r = c[1\lambda_{ra}(t) + a\lambda_{rb}(t) + a^2\lambda_{rc}(t)] \quad (2.13)$$

En donde a y a^2 son operadores espaciales, $a = e^{\frac{j2\pi}{3}}$, $a^2 = e^{\frac{j4\pi}{3}}$ y c una constante, igual a $\sqrt{\frac{2}{3}}$, que sirve para conservar la potencia activa en la transformación. De esta manera las corrientes, voltajes y flujos pueden ser expresados por la ecuación 2.14 en el sistema de referencia estacionario fijo, referido al estator.

$$f_e = f_{e\alpha}(t) + jf_{e\beta}(t) \quad (2.14)$$

Como se puede observar en la ecuación el vector espacial se trata de una cantidad compleja que consta de una parte real que coincide con el eje de la fase a y una componente imaginaria ortogonal. Este sistema reduce el número de ecuaciones de tres que son originalmente a dos. En la Figura 2.2 se puede observar dicho sistema.

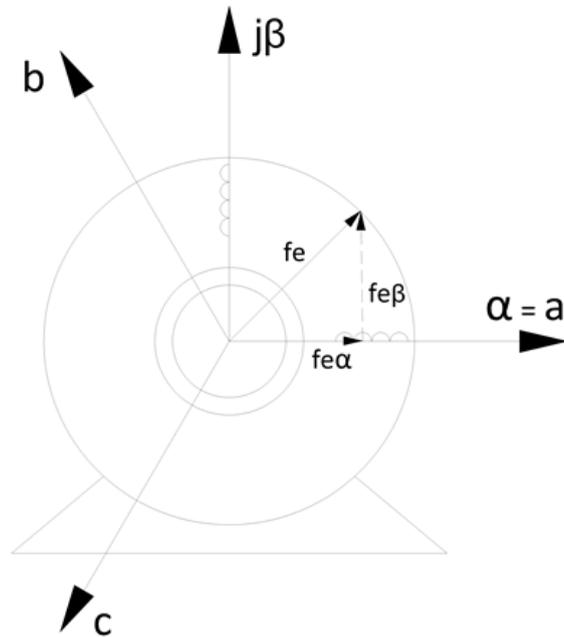


Figura 2.2: Vector espacial en el sistema de ejes de referencia ortogonal $\alpha - \beta$

La dinámica del motor de inducción trifásico en vectores espaciales está definido por las ecuaciones 2.15 y 2.16

$$\mathbf{V}_e = \mathbf{R}_e \mathbf{I}_e + \frac{d\lambda_e}{dt} \quad (2.15)$$

$$\mathbf{V}_r = \mathbf{R}_r \mathbf{I}_r + \frac{d\lambda_r}{dt} \quad (2.16)$$

Las ecuaciones de los enlaces de flujo de magnético tanto del estator como del rotor, en el marco de referencia estacionario referido al estator están dados por las ecuaciones 2.17 y 2.18.

$$\lambda_e = L_e \mathbf{I}_e + L_m \mathbf{I}_r e^{j\theta} \quad (2.17)$$

El vector de enlace de flujo magnético del estator está compuesto por el vector espacial de enlace de flujo magnético producido por las corrientes que circulan por el estator $L_e \mathbf{I}_e$ mas el vector de enlace de flujo mutuo producido por las

corrientes que circulan por el rotor $L_m I_r e^{j\theta}$, en donde la expresión $I_r e^{j\theta}$ es la corriente del rotor referido al marco de referencia estacionario.

$$\lambda_r = L_r I'_r + L_m I_e e^{-j\theta} \quad (2.18)$$

El vector espacial de enlace de flujo magnético del rotor está compuesto por el vector espacial de enlace de flujo magnético producido por las corrientes que circular por el rotor $L_r I'_r$ mas el vector de enlace de flujo mutuo producido por las corrientes que circulan por el estator $L_m I_e e^{-j\theta}$, en donde la expresión $I_e e^{-j\theta}$ es la corriente del estator en el marco de referencia estacionario.

En donde L_m es la inductancia de magnetización de las tres fases del motor. Resolviendo las derivadas de los enlaces de flujos magnéticos y considerando que $\frac{d\theta}{dt} = \omega$, es decir la velocidad angular del rotor, que esta dad en *rad/s*, llegamos a la formulación del modelo dinámico del motor de inducción trifásico que está referido hacia el estator.

$$V_e = R_e I_e + L_e \frac{dI_e}{dt} + L_m \frac{dI_r}{dt} e^{j\theta} + j L_m I_r e^{j\theta} \omega_r \quad (2.19)$$

$$V_r = R_r I_r + L_r \frac{dI_r}{dt} + L_m \frac{dI_e}{dt} e^{-j\theta} - j L_m I_e e^{-j\theta} \omega_r \quad (2.20)$$

Se puede también establecer una relación entre la inductancia L_m y la inductancia mutua total L_{er} , que existe entre el estator y el rotor, por la ecuación 2.21.

$$L_m = \frac{3}{2} L_{er} \quad (2.21)$$

Para tener un correcto modelamiento del motor de inducción trifásico en estado estacionario como en el transitorio, debemos considerar la ecuación de movimiento como menciona [8].

$$T_e - T_l = J \frac{d\omega_r}{dt} + F \omega_r \quad (2.22)$$

En donde T_e es el torque electromagnético desarrollado por el motor cuya unidad es usualmente *Nm*, T_l es el torque de la carga *Nm*, ω_r corresponde a la velocidad

angular del rotor rad/s , J es la inercia que se debe vencer en el instante del arranque y F la constante de fricción de Coulomb.

El torque electromagnético se expresa por la ecuación 2.23.

$$T_e = -p \frac{3}{2} L_m I_e \times I_r e^{j\theta} \quad (2.23)$$

En donde p es el número de polos del motor y \times el producto vectorial.

Desarrollando las ecuaciones de voltajes instantáneos, el modelo del motor de inducción se presenta en forma matricial por la ecuación 2.24.

$$\begin{bmatrix} V_e \\ V_r \end{bmatrix} = \begin{bmatrix} R_e & \frac{3}{2} L_{er} j \omega_r e^{j\theta} \\ -\frac{3}{2} L_{er} j \omega_r e^{-j\theta} & R_r \end{bmatrix} \begin{bmatrix} I_e \\ I_r \end{bmatrix} + \begin{bmatrix} L_e & \frac{3}{2} L_{er} e^{j\theta} \\ \frac{3}{2} L_{er} e^{-j\theta} & L_r \end{bmatrix} \quad (2.24)$$

El modelo de arriba es adecuado para obtener resultados tanto en el estado transitorio como en el estado estable. Mediante transformaciones de matrices se puede llegar al modelo en espacio de estados que nos servirá en el próximo capítulo para comprobar el algoritmo del filtro extendido de Kalman.

Si definimos nuevamente la ecuación instantánea del motor de inducción trifásico por la ecuación 2.25 y aplicamos la transformación que se encuentra en [10] obtendremos un modelo de la máquina en un marco de referencia arbitrario. En donde s denota un sistema estacionario.

$$v_{abcs} = R_{abcs} i_{abcs} + \frac{d\lambda_{abcs}}{dt} \quad (2.25)$$

La ecuación 2.26 establece el cambio de un sistema de tres ejes hacia dos ejes ortogonales.

$$f_{\alpha\beta 0s} = K_s f_{abcs} \quad (2.26)$$

En donde f representa los voltajes, corrientes y enlaces de flujo en los respectivos sistemas de referencia. También se definen las siguientes ecuaciones las mismas que servirán para realizar operaciones y definir la velocidad angular.

$$f_{\alpha\beta 0s} = [f_{\alpha s} \quad f_{\beta s} \quad f_{0s}]' \quad (2.27)$$

$$f_{abcs} = [f_{as} \quad f_{bs} \quad f_{cs}]' \quad (2.28)$$

$$K_s = \frac{2}{3} \begin{bmatrix} \cos\theta & \cos(\theta - \frac{2\pi}{3}) & \cos(\theta + \frac{2\pi}{3}) \\ \sin\theta & \sin(\theta - \frac{2\pi}{3}) & \sin(\theta + \frac{2\pi}{3}) \\ \frac{1}{2} & \frac{1}{2} & \frac{1}{2} \end{bmatrix} \quad (2.29)$$

$$(K_s)^{-1} = \frac{2}{3} \begin{bmatrix} \cos\theta & \sin\theta & 1 \\ \cos(\theta - \frac{2\pi}{3}) & \sin(\theta - \frac{2\pi}{3}) & 1 \\ \cos(\theta + \frac{2\pi}{3}) & \sin(\theta + \frac{2\pi}{3}) & 1 \end{bmatrix} \quad (2.30)$$

$$p(K_s)^{-1} = \frac{2}{3} \begin{bmatrix} -\sin\theta & \cos\theta & 0 \\ -\sin(\theta - \frac{2\pi}{3}) & \cos(\theta - \frac{2\pi}{3}) & 0 \\ -\sin(\theta + \frac{2\pi}{3}) & \cos(\theta + \frac{2\pi}{3}) & 0 \end{bmatrix} \quad (2.31)$$

$$K_s p(K_s)^{-1} = \omega \begin{bmatrix} 0 & 1 & 0 \\ -1 & 0 & 0 \\ -0 & 0 & 0 \end{bmatrix} \quad (2.32)$$

Utilizando las ecuaciones desde 2.25 hasta 2.32 se procede a desarrollar el modelo del motor de inducción trifásico operando sobre las siguientes expresiones.

$$v_{\alpha\beta 0s} = K_s R_s K_s^{-1} i_{\alpha\beta 0s} + p(K_s^{-1} \lambda_{\alpha\beta 0s}) \quad (2.33)$$

$$v_{\alpha\beta 0s} = R_s i_{\alpha\beta 0s} + K_s p K_s^{-1} \lambda_{\alpha\beta 0s} + K_s K_s^{-1} p \lambda_{\alpha\beta 0s} \quad (2.34)$$

Reemplazando $K_s p(K_s)^{-1}$ por ω tenemos,

$$v_{\alpha\beta 0s} = R_s i_{\alpha\beta 0s} + \omega \lambda_{\alpha\beta 0s} + p \lambda_{\alpha\beta 0s} \quad (2.35)$$

Con la ecuación 2.35 podemos definir nuestro modelo matemático del motor de inducción trifásico en el marco de referencia estacionario. Las siguientes ecuaciones están dadas de manera compacta. Los subíndices e y r denotan variables del estator y rotor.

$$v_{\alpha\beta e} = R_e i_{\alpha\beta e} + \omega \lambda_{\alpha\beta e} + p \lambda_{\alpha\beta e} \quad (2.36)$$

$$v'_{\alpha\beta r} = R'_r i_{\alpha\beta r} + (\omega - \omega_r) \lambda'_{\alpha\beta r} + p \lambda'_{\alpha\beta r} \quad (2.37)$$

En donde el apóstrofe en 2.37 indica que las variables están referidas hacia el estator. Ahora consideramos $\omega = 0$ y separando en sus componentes real e imaginario las ecuaciones 2.36 y 2.37 se tiene las siguientes ecuaciones.

$$v_{\alpha e} = R_e i_{\alpha e} + p \lambda_{\alpha e} \quad (2.38)$$

$$v_{\beta e} = R_e i_{\beta e} + p \lambda_{\beta e} \quad (2.39)$$

$$v'_{\alpha r} = R'_r i_{\alpha r} + \omega_r \lambda'_{\alpha r} + p \lambda'_{\alpha r} \quad (2.40)$$

$$v'_{\beta r} = R'_r i_{\beta r} - \omega_r \lambda'_{\beta r} + p \lambda'_{\beta r} \quad (2.41)$$

En forma matricial se define el modelo matemático, del motor de inducción trifásico, por la ecuación 2.42.

$$\frac{d}{dt} \begin{bmatrix} I_{\alpha e} \\ I_{\beta e} \\ \lambda'_{\alpha r} \\ \lambda'_{\beta r} \\ \omega_r \end{bmatrix} = \begin{bmatrix} -\left(\frac{1}{\rho T_e} + \frac{1-\rho}{\rho T_r}\right) & 0 & \frac{L_{er}}{\rho L_e L_r T_r} & \frac{L_{er}}{\rho L_e T_r} \frac{p}{2} \omega_r & 0 \\ 0 & -\left(\frac{1}{\rho T_e} + \frac{1-\rho}{\rho T_r}\right) & -\frac{L_{er}}{\rho L_e T_r} \frac{p}{2} \omega_r & \frac{L_{er}}{\rho L_e L_r T_r} & 0 \\ \frac{L_{er}}{T_r} & 0 & -\frac{1}{T_r} & -\frac{p}{2} \omega_r & 0 \\ 0 & \frac{L_{er}}{T_r} & \frac{p}{2} \omega_r & -\frac{1}{T_r} & 0 \\ -\frac{p L_{er}}{2 J L_r} \lambda_{\beta r} & \frac{p L_{er}}{2 J L_r} \lambda_{\alpha r} & 0 & 0 & -\frac{F}{J} \end{bmatrix} \begin{bmatrix} I_{\alpha e} \\ I_{\beta e} \\ \lambda'_{\alpha r} \\ \lambda'_{\beta r} \\ \omega_r \end{bmatrix} \quad (2.42)$$

2.2 Métodos de estimación de los parámetros del motor

Los parámetros del motor de inducción trifásico se pueden obtener a través de pruebas de rotor sin carga y rotor bloqueado; en donde se mide la corriente, el voltaje y potencia activa en cada una de las fases. El procedimiento es como sigue, se aplica una fuente de voltaje balanceada trifásica, se desprecian las pérdidas rotacionales y dependiendo de la potencia del motor la tensión aplicada

será a 60 Hz o menor. Además se calcula la resistencia del estator con una prueba en corriente continua como indica [11].

La estimación paramétrica es utilizada en aquellos sistemas en donde algunos parámetros no se pueden medir directamente. En el caso del motor de inducción trifásico, los valores de parámetros tales como: resistencia del rotor R_r , inductancia propia del rotor L_r , inductancia de dispersión del rotor L_s , pueden ser obtenidos a través de una estimación paramétrica dinámica con un alto grado de precisión.

Un método para la estimación paramétrica dinámica consiste en utilizar la impedancia instantánea durante el proceso de arranque de la máquina de inducción [6]. Para llegar a la ecuación de dicha impedancia, primeramente se estima el vector espacial de enlace de flujo de estator λ_e mediante la integración del vector espacial de voltaje menos el vector espacial de la caída de tensión óhmica del estator. Cabe destacar que en la ecuación 2.43 se utilizan valores medidos.

$$\lambda_e = L_e I_e + L_{er} I_r = \int_0^t (V_e - R_e I_e) \quad (2.43)$$

Como segundo paso se calcula la corriente del rotor mediante la ecuación 2.44.

$$I_r = \frac{1}{L_{er}} (\lambda_e - R_e I_e) \quad (2.44)$$

Derivando 2.43 se obtiene,

$$\frac{d\lambda_e}{dt} = V_e - R_e I_e \quad (2.45)$$

Si reemplazamos 2.44 en las ecuaciones del modelo del motor se tiene.

$$\left(\frac{R_e}{L_r} - j\omega_r \right) \lambda_e + \frac{d\lambda_e}{dt} - \left(\frac{L_e}{L_r} R_r - j\omega_r \widehat{L}_e \right) I_e - \frac{dI_e}{dt} = 0 \quad (2.46)$$

Por definición de impedancia se tiene la ecuación 2.47.

$$Z_i = \frac{V_e}{I_e} \quad (2.47)$$

Resolviendo las ecuaciones 2.45 y 2.46 se tiene la función de costo para la impedancia instantánea de entrada dada por la ecuación 2.48.

$$\mathbf{Z}_i = R_e + \frac{L_e}{L_r} R_r - j\omega_r \widehat{L}_e + \widehat{L}_e \frac{I_e}{I_e} - \left(\frac{R_e}{L_r} - j\omega_r \right) \frac{\lambda_e}{I_e} \quad (2.48)$$

En donde \widehat{L}_e está definida por la ecuación 2.49.

$$\widehat{L}_e = L_e - \frac{L_e r^2}{L_r} \quad (2.49)$$

Se puede observar que la impedancia instantánea de entrada depende de los valores de voltaje, corriente, flujo de estator y parámetros del motor de inducción trifásico que se desean estimar.

También es necesario estimar la velocidad angular ω_r de igual manera la constante de inercia J y la constante de fricción de Coulomb. Para obtener los valores de estos parámetros se parte con la estimación del par eléctrico aplicando la ecuación 2.50.

$$T_e = \lambda_e \times I_e \quad (2.50)$$

Este par eléctrico produce una aceleración angular y par mecánico que esta dado por la ecuación 2.51.

$$T_e = J \frac{d\omega_r}{dt} + F\omega_r \quad (2.50)$$

Cuando el motor de inducción trifásico llega a su funcionamiento de régimen permanente, después de un tiempo t_0 se tiene un par constante $J\omega_s$ en donde la velocidad angular del rotor es igual a la velocidad de sincronismo y la pendiente de esta curva del estado estable se define como la constante de fricción de Coulomb F . En la Figura 2.3 se puede apreciar lo dicho anteriormente.

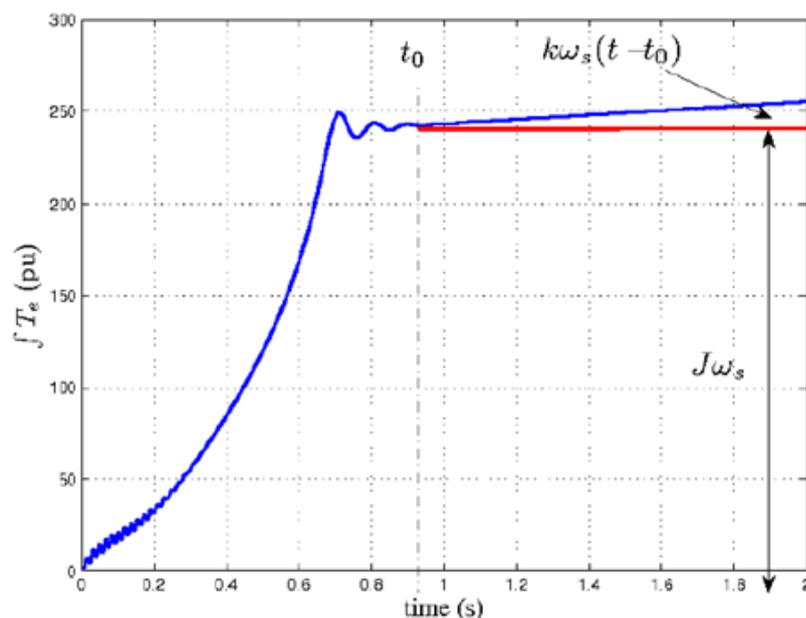


Figura 2.3: Estimación de las constantes de inercia [J] y fricción de Coulomb [F]. Tomado de [6]

2.3 Métodos de estimación de la velocidad en motores trifásicos

La estimación de la velocidad angular en motores de inducción trifásicos se realiza a través de la implementación de algoritmos que están basados en la inteligencia artificial tales como: redes neuronales artificiales, lógica difusa, sistemas neuro-difusos; también se han aplicado con gran éxito los observadores de estado utilizando el Filtro Extendido de Kalman.

Para las redes neuronales artificiales se utiliza el algoritmo de retropropagación (Backpropagation). Para los sistemas neuro-difusos se hace uso de la estructura ANFIS (Adaptive Neuro Fuzzy Inference System), por sus siglas en inglés, la misma que establece un conjunto de reglas de un sistema difuso del tipo Sugeno que son entrenadas por el algoritmo de retropropagación.

El filtro extendido de Kalman utiliza el modelo del motor de inducción trifásico en espacio de estados, para el presente proyecto será en el marco de referencia

estacionario, que se utilizará como algoritmo de comparación para las redes neuronales artificiales.

Para los distintos casos es necesario contar con sensores capaces de medir voltajes y corrientes en el sistema trifásico.

2.4 Algoritmo basado en redes neuronales artificiales aplicados en la estimación de variables y parámetros de un motor trifásico

La Figura 2.4 muestra el modelo de una neurona artificial simple; esta es la base para diseñar redes neuronales artificiales capaces de resolver problemas complejos. De esta podemos identificar tres elementos esenciales.

- Las entradas con sus respectivos pesos sinápticos.
- Una sumatoria de todas las entradas multiplicada por sus respectivos pesos sinápticos.
- Y la función de activación que sirve para limitar la salida de la neurona.

También es necesario destacar el efecto que tiene el sesgo (bias) w_0 , dependiendo si es positivo o negativo aumentará o disminuirá la salida de la neurona. En términos matemáticos podemos describir la k-ésima neurona por la ecuación 2.52.

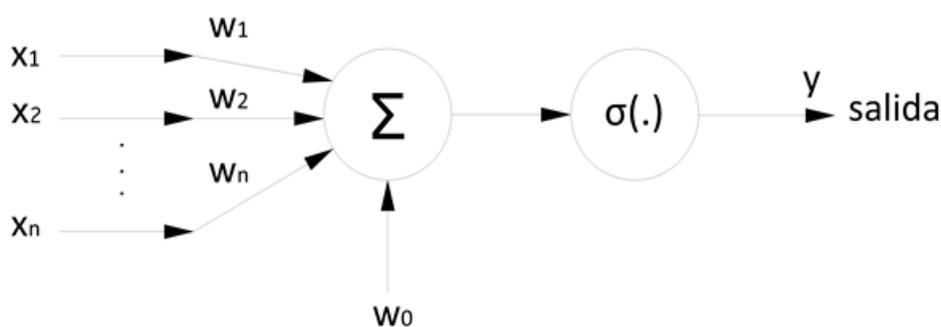


Figura 2.4: Neurona tipo Perceptron

$$y(k) = \sigma\left(\sum_{j=1}^n w_j x_j(k) + w_0\right) \quad (2.52)$$

En donde σ es una función no lineal diferenciable que para el caso del presente proyecto será del tipo binaria sigmoial en la capa de salida y tangencial hiperbólica en la capa oculta y están definidas por las ecuaciones 2.53 y 2.54 respectivamente.

$$\sigma = \frac{1}{1+e^{-\alpha}} \quad (2.53)$$

$$\sigma = \frac{2}{1+e^{-2\alpha}} - 1 \quad (2.54)$$

En las Figuras 2.5 y 2.6 muestras las gráficas para dichas funciones.

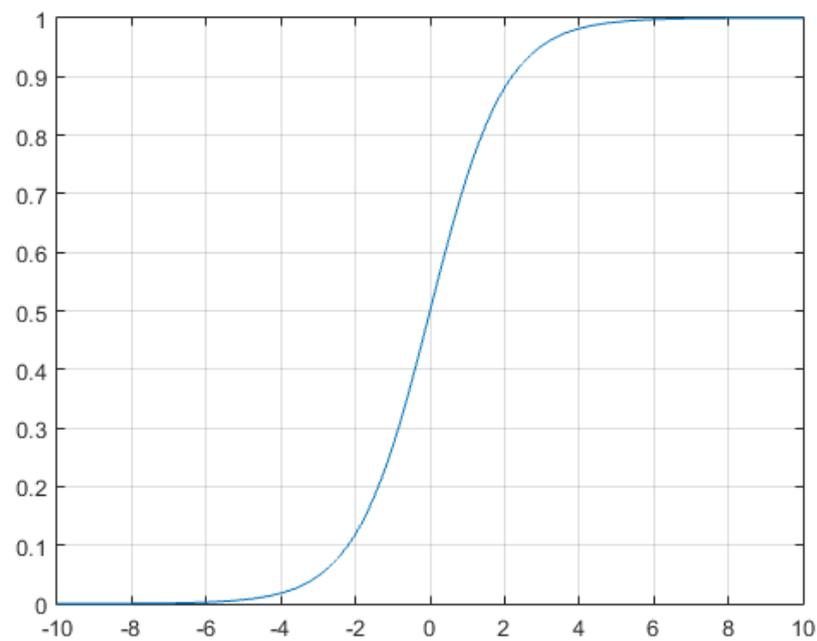


Figura 2.5: Función de activación Sigmoial

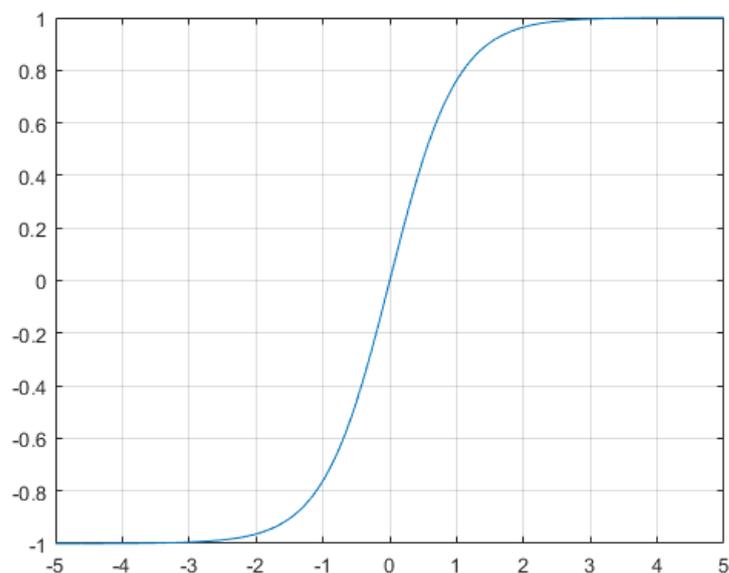


Figura 2.6: Función de activación Tangente hiperbólica

La red neuronal descrita en la sección anterior se denomina Perceptrón como menciona [12]. Al interconectar sucesivas capas de neuronas de este tipo se obtendrá una red neuronal multicapa que debe tener las siguientes características de acuerdo a [13].

- El modelo de cada neurona que pertenece a la red debe incluir una función de activación no lineal.
- La red debe contener una mas capas de neuronas ocultas que no forman parte de las entradas o salidas de la red.
- La red debe proveer un alto grado de conectividad, determinado por la sinapsis de la red. Un cambio en la conectividad de la red requiere un cambio en la población de conexiones sinápticas de sus pesos.

La Figura 2.7 muestra un perceptrón, (MPL) Multilayer Perceptron por sus siglas en inglés, en donde v y w son los pesos sinápticos de la capa oculta y capa de salida respectivamente. Este tipo de red neuronal ha utilizada para resolver

diferentes problemas basados en un entrenamiento supervisado mediante el algoritmo de retropropagación.

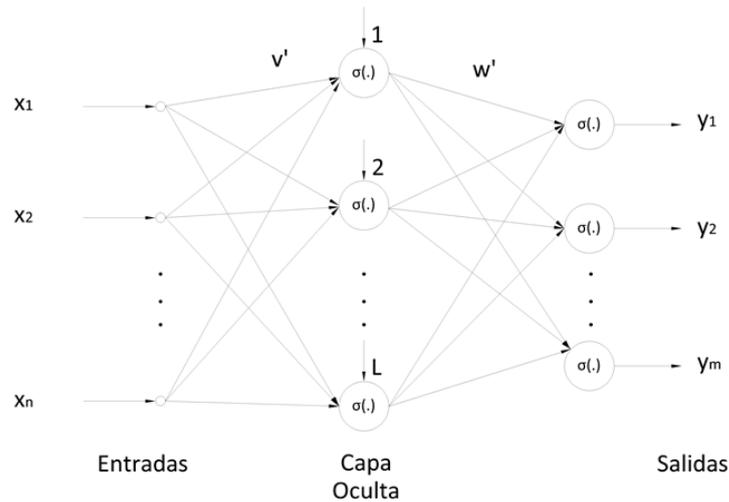


Figura 2.7: Esquema de red neuronal multicapa

El objetivo del proceso de aprendizaje con el algoritmo de retropropagación es ajustar los pesos minimizando la función de error que sirve para medir el rendimiento de la red neuronal. Para la red de la Figura 2.7, la salida en la capa oculta viene dada por la ecuación 2.55 para n igual al número de entradas.

$$z_l = \sigma\left(\sum_{j=1}^n v_{lj}x_j + v_{l0}\right); \quad l = 1, 2, \dots, L \quad (2.55)$$

De la misma manera se calcula la salida total mediante la ecuación 2.56, en donde m es el número de salidas.

$$y_k = \sigma\left(\sum_{l=1}^L w_{kl}z_l + w_{k0}\right); \quad k = 1, 2, \dots, m \quad (2.56)$$

Reemplazando la ecuación 2.55 en 2.56, se tiene.

$$y_k = \sigma\left(\sum_{l=1}^L w_{kl}\sigma\left(\sum_{j=1}^n v_{lj}x_j + v_{l0}\right) + w_{k0}\right); \quad k = 1, 2, \dots, m \quad (2.57)$$

Para desarrollar el algoritmo de retropropagación consideramos la Figura 2.8 como un modelo simplificado general para obtener las ecuaciones que servirán para la programación del algoritmo, en donde los subíndices l y k corresponden a la capa oculta y capa de salida respectivamente.



Figura 2.8: Modelo simplificado de red neuronal

La función de costo que mide el rendimiento de la red neuronal está dada por la ecuación 2.58. Esta describe el error medio cuadrático entre la salida deseada y el valor actual en la k -ésima iteración; el conjunto C incluye todas las neuronas en la capa de salida de la red y el error e_k viene expresada por la ecuación 2.59.

$$E(k) = \frac{1}{2} \sum_{j \in C} e_j^2(k) \quad (2.58)$$

$$e_k = d_k - y_k \quad (2.59)$$

En donde, d_k es el valor deseado que se presenta a la red para su entrenamiento y y_k el valor calculado a las salidas de la red. La corrección de los pesos sinápticos en el algoritmo de retropropagación se hace mediante la derivada parcial del error medio cuadrático de la ecuación 2.58 con respecto a cada uno de los pesos sinápticos de las capas correspondiente aplicando la regla de la cadena. Considerando la Figura 2.8 se tiene para la capa de salida las siguientes ecuaciones.

$$u_k = \sum_{l=1}^L w_{kl} z_l + w_{k0} \quad (2.60)$$

$$\frac{\partial u_k}{\partial w_{kl}} = w_{kl} \quad (2.61)$$

$$\frac{\partial E}{\partial w_{kl}} = \frac{\partial E}{\partial y_k} \frac{\partial y_k}{\partial u_k} \frac{\partial u_k}{\partial w_{kl}} \quad (2.62)$$

$$\frac{\partial E}{\partial y_k} = -(d_k - y_k) \quad (2.63)$$

$$\frac{\partial y_k}{\partial u_k} = \sigma'(u_k) \quad (2.64)$$

$$\frac{\partial u_k}{\partial w_{kl}} = z_l \quad (2.65)$$

Reemplazando las tres últimas ecuaciones en 2.62 se tiene,

$$\frac{\partial E}{\partial w_{kl}} = -e_k \sigma'(u_k) z_l \quad (2.66)$$

Teniendo como la primera derivada la función de activación no lineal $\sigma(\cdot)$ la ecuación 2.67.

$$\sigma' = \sigma(u_k)(1 - \sigma(u_k)) \quad (2.67)$$

El próximo paso es considerar la regla Delta, (Delta Rule) en inglés, para la corrección de Δw_{kl} que viene dada por la ecuación 2.68.

$$\Delta w_{kl} = -\eta \frac{\partial E}{\partial w_{kl}} \quad (2.68)$$

En donde η es un parámetro de que se denomina tasa de aprendizaje del algoritmo y cuyo valor típico es de 0.1.

La corrección de los pesos sinápticos en la capa de salida se expresa por la ecuación 2.69.

$$\Delta w_{kl} = \eta \delta_k z_l \quad (2.69)$$

En donde δ_k es el gradiente local de la capa de salida y esta definido por la ecuación 2.70.

$$\delta_k = e_k \sigma'(u_k) \quad (2.70)$$

Para corregir los pesos de la capa oculta consideramos la ecuación 2.72 y nuevamente aplicando la regla de la cadena se tiene las siguientes ecuaciones.

$$u_j = \sum_{i=1}^n v_{ij} x_i + v_{j0} \quad (2.71)$$

$$\frac{\partial E}{\partial v_{ij}} = \frac{\partial E}{\partial y_k} \frac{\partial y_k}{\partial u_k} \frac{\partial u_k}{\partial z_l} \frac{\partial z_l}{\partial u_l} \frac{\partial u_l}{\partial v_{ij}} \quad (2.72)$$

$$\frac{\partial z_l}{\partial u_l} = \sigma'(u_l) \quad (2.73)$$

$$\frac{\partial u_l}{\partial v_{ij}} = \sigma'(u_l) \quad (2.74)$$

Aplicando la regla delta para la capa oculta.

$$\Delta u_{ij} = -\eta \frac{\partial E}{\partial u_{ij}} \quad (2.75)$$

$$\frac{\partial E}{\partial u_{kl}} = -e_k \sigma'(u_k) w_{kl} \sigma'(u_l) x_j \quad (2.76)$$

$$\Delta u_{ij} = \eta \delta_k w_{kl} \sigma'(u_l) \quad (2.77)$$

El algoritmo que se describe a continuación debe repetirse hasta que el error en la salida se lo suficientemente pequeño. Calculamos la salida utilizando los patrones de entrada.

$$z_l = \sigma(\sum_{j=1}^n v_{lj}x_j + v_{l0}); \quad l = 1, 2, \dots, L \quad (2.78)$$

$$y_k = \sigma(\sum_{l=1}^L w_{kl}z_l + w_{k0}); \quad k = 1, 2, \dots, m \quad (2.79)$$

Propagación del error hacia atrás.

$$e_k = d_k - y_k; \quad k = 1, 2, \dots, m \quad (2.80)$$

$$\delta_k = y_k(1 - y_k)e_k; \quad k = 1, 2, \dots, m \quad (2.81)$$

$$\delta_l = z_l(1 - z_l) \sum_{k=1}^m w_{kl} \delta_k e_k; \quad l = 1, 2, \dots, L \quad (2.82)$$

2.5 Estimación en motores de inducción mediante la aplicación del filtro extendido de Kalman

El filtro extendido de Kalman es un optimizador recursivo estocástico que sirve para estimar variables de estado en tiempo real de un sistema dinámico no lineal ruidoso cuya distribución es Gaussiana y de media cero. A continuación se detallan algunas ventajas por lo cual se utiliza el filtro en estimación de la velocidad de motores de inducción trifásicos.

- El filtro extendido de Kalman tiene un excelente comportamiento dinámico frente a las perturbaciones.
- Puede utilizarse para estimación de la velocidad en el motor de inducción hasta en condiciones de arranque de la máquina.
- Las incertidumbres y no linealidades del motor de inducción trifásico son adecuadas para la naturaleza estocástica del filtro.

Para aplicar el filtro extendido de Kalman como estimador de velocidad en un motor de inducción trifásico, es necesario discretizar el modelo definido por la ecuación 2.42. A continuación se presentan cada una de las ecuaciones para detallar el algoritmo, comenzando por definir algunas constantes.

$$a_1 = \left(\frac{1}{\rho T_e} + \frac{1-\rho}{\rho T_r} \right), \quad a_2 = \frac{L_{er}}{\rho L_e L_r T_r}, \quad a_3 = \frac{L_{er}}{\rho L_e L_r}, \quad a_5 = \frac{L_{er}}{T_r},$$

$$a_6 = \frac{1}{T_r}, \quad a_7 = \frac{p L_{er}}{2 J L_r}, \quad b = \frac{1}{\rho L_e}$$

$$x(k+1) = \left[I_{\alpha e}(k+1) \quad I_{\beta e}(k+1) \quad \lambda'_{\alpha e}(k+1) \quad \lambda'_{\beta e}(k+1) \quad \omega_r(k+1) \right]^T \quad (2.83)$$

$$A(k+1) = \begin{bmatrix} 1-t_s a_1 & 0 & t_s a_2 & t_s a_3 \frac{p}{2} \omega_r(k) & 0 \\ 0 & 1-t_s a_1 & -t_s a_3 \frac{p}{2} \omega_r(k) & t_s a_2 & 0 \\ t_s a_5 & 0 & 1-t_s a_6 & -t_s \frac{p}{2} \omega_r(k) & 0 \\ 0 & t_s a_5 & t_s \frac{p}{2} \omega_r(k)_r & 1-t_s a_6 & 0 \\ -t_s a_7 \lambda_{\beta r}(k) & t_s a_7 \lambda_{\alpha r} & 0 & 0 & 1-t_s \frac{F}{J} \end{bmatrix} \quad (2.84)$$

$$x(k) = \begin{bmatrix} I_{\alpha e}(k) \\ I_{\beta e}(k) \\ \lambda'_{\alpha r}(k) \\ \lambda'_{\beta r}(k) \\ \omega_r(k) \end{bmatrix} \quad (2.85)$$

$$B(k) = \begin{bmatrix} \frac{1}{\rho L_e} & 0 \\ 0 & \frac{1}{\rho L_e} \\ 0 & 0 \\ 0 & 0 \\ 0 & 0 \end{bmatrix} \quad (2.86)$$

$$u(k) \begin{bmatrix} V_{\alpha e}(k) \\ V_{\beta e}(k) \end{bmatrix} \quad (2.87)$$

$$C(k) = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \end{bmatrix} \quad (2.88)$$

$$y(k) \begin{bmatrix} I_{\alpha e}(k) \\ I_{\beta e}(k) \end{bmatrix} \quad (2.89)$$

En donde $\rho = 1 - \frac{L_e r^2}{L_e L_r}$. Con las ecuaciones detalladas anteriormente podemos definir el modelo dinámico no lineal en tiempo discreto del motor de inducción trifásico jaula de ardilla asumiendo que este contiene ruido gaussiano de media cero tanto las ecuaciones del sistema como en las mediciones. Las ecuaciones 2.90 y 2.91 denotan lo expresado.

$$x(k) = A(k)x(k) + B(k)u(k) + v(k) \quad (2.90)$$

$$y(k) = C(k)y(k) + w(k) \quad (2.91)$$

Como se puede apreciar en 2.90 se agregado el vector de ruido de los estados del sistema $v(k)$ cuya matriz de covarianza es Q , de igual manera $w(k)$ representa el ruido de las mediciones de las corrientes del estator con matriz de covarianza R . A continuación se detalla el algoritmo.

Predicción del estado.

La predicción del estado en el tiempo de muestreo $x(k+1)$ se lo realiza a partir de las mediciones de voltaje $u(k)$ y el vector de estado en un tiempo de muestreo anterior $x_{k|k}$. Utilizando las matrices A y B de la ecuación 2.90 se tiene.

$$x_{k+1|k} = A_k x_{k|k} + B_k u(k) \quad (2.92)$$

$$x_{k+1|k} = F(k+1, k, x_{k|k}, u(k)) \quad (2.93)$$

Predicción de la matriz error de covarianza

$$P_{k+1|k} = MP_{k|k}M' + Q \quad (2.94)$$

Donde $M = \frac{\partial F}{\partial x}$ evaluado en $x = \hat{x}_{k|k}$

Cálculo de la ganancia de Kalman

También denominada matriz de corrección.

$$K_{k|k} = P_{k|k-1}N'[P_{k|k-1}+N'+R]^{-1} \quad (2.95)$$

Donde $N = \frac{\partial h}{\partial x}$ evaluado en $x = \hat{x}_{k|k-1}$

Estimación del estado

$$x_{x|x} = x_{x|x-1} + K_k(y_k - \hat{y}_k) \quad (2.96)$$

Para,

$$\hat{y}_k = C_k x_{x|x-1} \quad (2.97)$$

Como último paso se tiene la actualización de la matriz P .

$$P_{x|x} = P_{x|x-1} - K_k \frac{\partial h}{\partial x_{|x|x-1}} P_{x|x-1} \quad (2.98)$$

En la Figura 2.9 se puede observar, en diagrama de bloques la estructura del filtro extendido de Kalman.

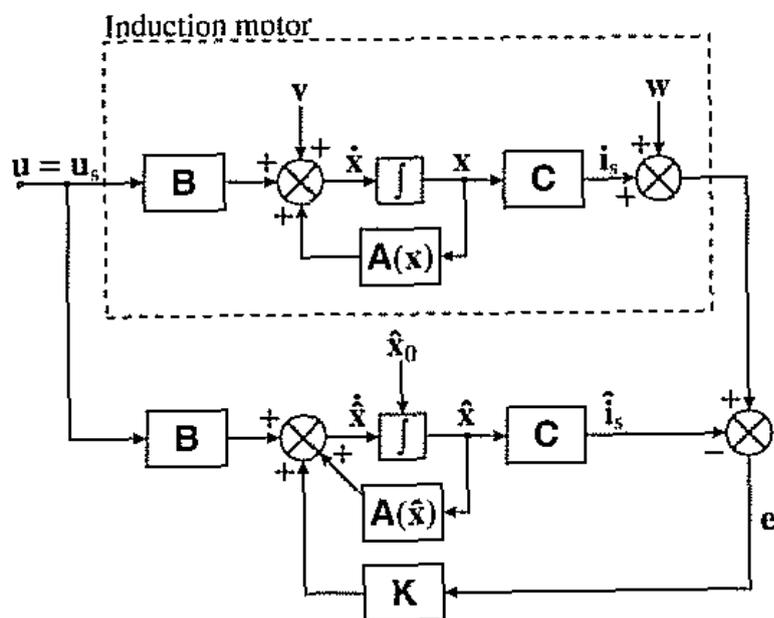


Figura 2.9: Estructura del Filtro Extendido de Kalman

CAPÍTULO 3

3. ESTIMACIÓN DE LOS PARÁMETROS DEL MOTOR

En este capítulo se detallan los parámetros del estator y rotor, encontrados mediante la optimización de la función de costo, tales como las inductancias, constante de inercia y fricción de Coulomb. Conjuntamente con las resistencias asociadas a cada parte del motor, se realizan simulaciones de un modelo en vectores espaciales para finalmente validarlas comparando con las gráficas de los datos reales.

3.1 Implementación del sistema de adquisición de datos del motor trifásico

En esta sección se presenta el desarrollo del experimente realizado para la obtención de los parámetros del motor de inducción trifásico de la Figura 3.1, cuyas especificaciones técnicas se pueden apreciar en la Tabla 1. Este motor es tipo jaula de ardilla que posee anillos rozantes, (no es rotor devanado), con el propósito de tener acceso a la medición de la resistencia del rotor.



Figura 3.1 Motor de inducción trifásico

VEW MOTORS	
MADE IN GERMANY	
IEC/EN	60034-1
3 Mot.Nr./N	406724/001 H
Typ/Type	SPER 132M 4HW
5.5 PS/4.4Kw	COSPHI 0.83
Δ/Y 220/380 V	15/8.8 A
1435 rpm	50 Hz
Th.KI/Th.cl. 155(F/B)	IP 54 85 Kg
Laufer: Y 130 V 19 A	
IM B3ZZ	06/2014

Tabla 1: Especificaciones técnicas

El esquema para la adquisición de los datos del motor en estudio se puede observar en la Figura 3.2, en donde se miden dos voltajes fase-fase y dos corrientes de línea utilizando instrumentación diferencial con una frecuencia de muestreo de 30kHz durante 10 segundos.

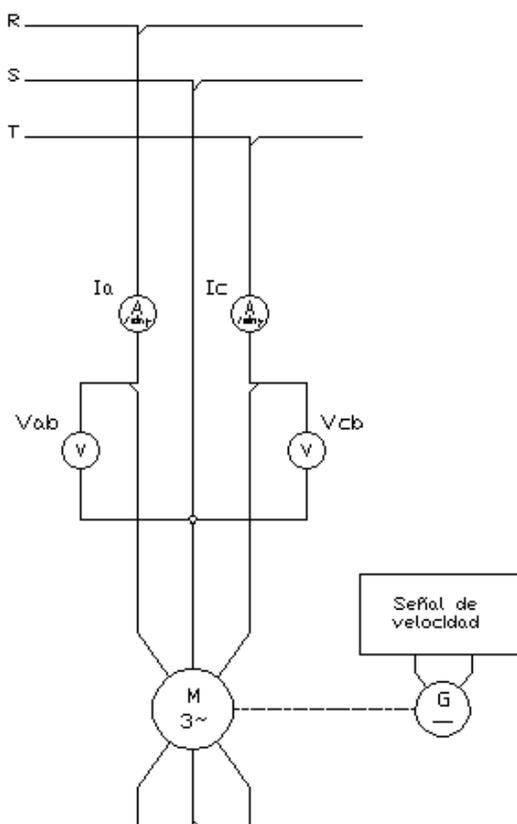


Figura 3.2 Esquema de medición de voltajes y corrientes

La adquisición de los datos se realiza a través de una interface de National Instruments, que consta de un hardware de alta velocidad, este a su vez actúa con un programa desarrollado en la Plataforma Matlab que sirve para almacenar los datos de los voltajes v_{ab} , v_{cb} , de las corrientes i_a , i_c y velocidad del motor. En la Figura 3.3 se muestran las corrientes medidas.

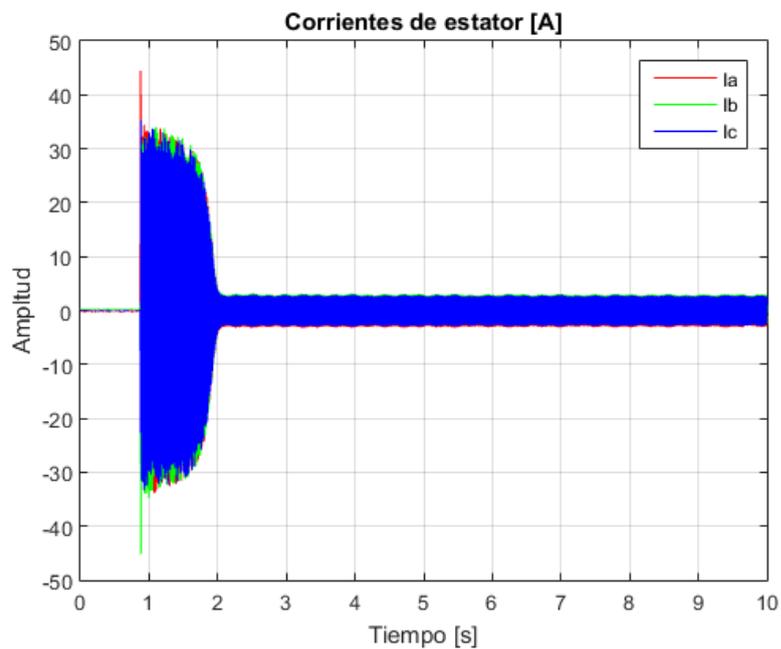


Figura 3.3 Corrientes trifásicas de estator ejes *a*, *b* y *c*

De igual manera se grafican los voltajes de fase, para tener una mejor apreciación se toma una muestra de 1 segundo como indica la Figura 3.4.

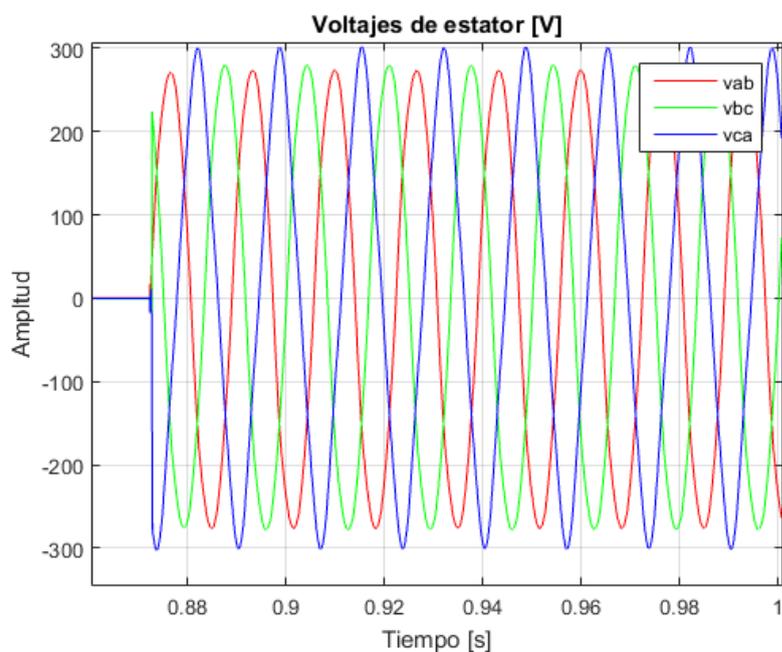


Figura 3.4 Voltajes trifásicos de fase del estator ejes *a*, *b* y *c*

3.2 Identificación del modelo del motor mediante el procesamiento de los datos obtenidos

Con las ecuaciones desarrolladas en la sección 2 del capítulo 2 se procede a realizar las transformaciones vectoriales para los voltajes y corrientes adquiridos en el sistema $a-b-c$. Se debe considerar que los voltajes a procesar son los de línea, en consecuencia los voltajes de fase medidos se deben multiplicar $\sqrt{3}$. Para las corrientes se aplica directamente la fórmula.

En la estimación del enlace de flujo de estator λ_e se tiene como dato la resistencia del estator, la misma que se obtuvo a través de una prueba de corriente continua. En las tablas 2 y 3 se pueden apreciar las medidas.

Estator	V [V]	I [A]	R [Ω]
Resistencia ab	4,680	2,040	2,294
Resistencia bc	4,616	2,005	2,302
Resistencia ca	4,632	2,010	2,304

Tabla 2: Medidas de resistencia de estator

Rotor	V [V]	I [A]	R [Ω]
Resistencia ab	0,797	1,650	0,483
Resistencia bc	0,865	1,710	0,506
Resistencia ca	0,850	1,840	0,462

Tabla 3: Medidas de resistencia de rotor

Debido a que se tiene como referencia el sistema estacionario referido hacia el estator el valor promedio de la resistencia del rotor de 0,483 será transformado al valor de 3.0512 ohmios.

Con el enlace de flujo estimado se puede obtener el par eléctrico mediante la ecuación 2.50 y con la función *cumtrapz* de la plataforma Matlab se obtiene la velocidad estimada que sirve para calcular la constante de inercia J y el coeficiente

de fricción de coulomb F . En la Figura 3.5 se muestra la velocidad estimada conjuntamente con los parámetros que se desean calcular.

Para la constante de inercia J se tiene,

$$J\omega_s = 10.6726 \quad (3.1)$$

$$J = 0.056 \text{ Kgm}^2$$

Y para la constante de fricción de coulomb,

$$F\omega_s = 1.7787 \quad (3.2)$$

$$F = 0.094 \text{ Nms}$$

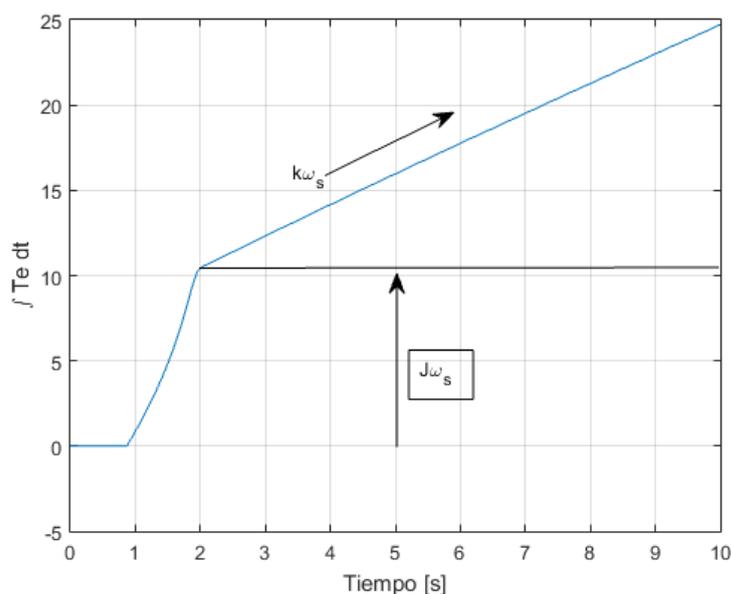


Figura 3.5 Integral del par eléctrico

La estimación de la inductancia mutua L_{er} , la inductancia propia del estator y rotor L_e y L_r respectivamente se lo realiza mediante la optimización de la función de costo que corresponde a la impedancia de entrada en el instante de arranque del motor de inducción. Los datos de las variables necesarias para este procesamiento se encuentran almacenados en el archivo *datos_arr_simens.mat*.

A continuación se grafica la velocidad angular en un sistema por unidad con el propósito de observar la cantidad de muestras que se utilizaron para la optimización.

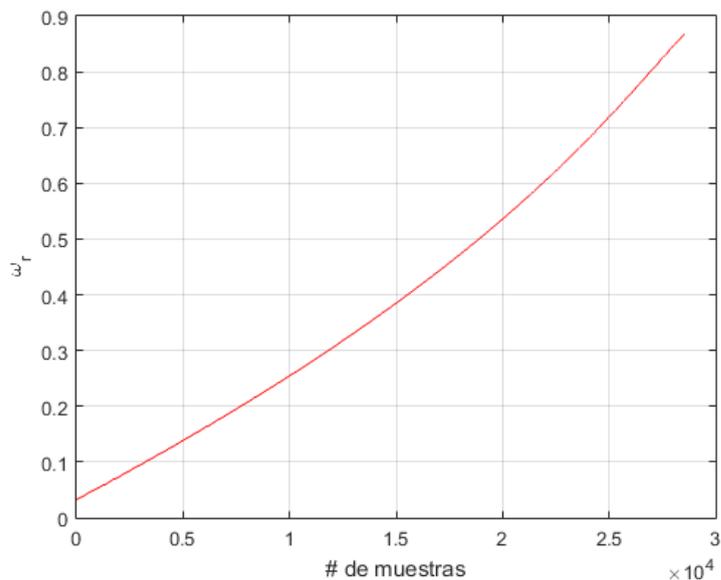


Figura 3.6 Muestras en el instante de arranque del motor

En la tabla 4 se muestran los resultados obtenidos en la optimización de la función de costo, en donde los valores escogidos serán los de mejor rendimiento cuantificados en base al error.

Ler[mH]	Le[mH]	Lr[mH]	error
0,0816	0,0888	0,088	0,079
0,1652	0,172	0,1719	0,0616
0,0818	0,0885	0,0884	0,0307

Tabla 4: Valores de las inductancias obtenidas por optimización

En la tabla 5 se tienen los valores de los parámetros finales del motor que servirán para las simulaciones en el entorno Matlab. Como se mencionó en los capítulos previos la resistencia de estator y rotor son valores medidos

aplicando la ley de Ohm en corriente continua. De igual manera cabe destacar que la resistencia del rotor está referido hacia el estator.

Ler[mH]	Le[mH]	Lr[mH]	Re[Ω]	Rr [Ω]
0,0818	0,0885	0,0884	1,1521	1.52

Tabla 5: Valores finales de los parámetros del motor de inducción

Para verificar la efectividad del método se realizó un segundo arranque del motor de inducción acoplado a un generador cuya constante de inercia es de 0.0854 Kgm² que a su vez nos permitió medir la velocidad que se muestra en la Figura 3.7. Mediante la aplicación del filtro digital, denominado sgolayfilt de Matlab, se elimina la parte ruidosa de la señal de voltaje, para proceder a la transformación a unidades de ingeniería *rad/s* y finalmente obtener la velocidad del motor con la carga antes mencionada.

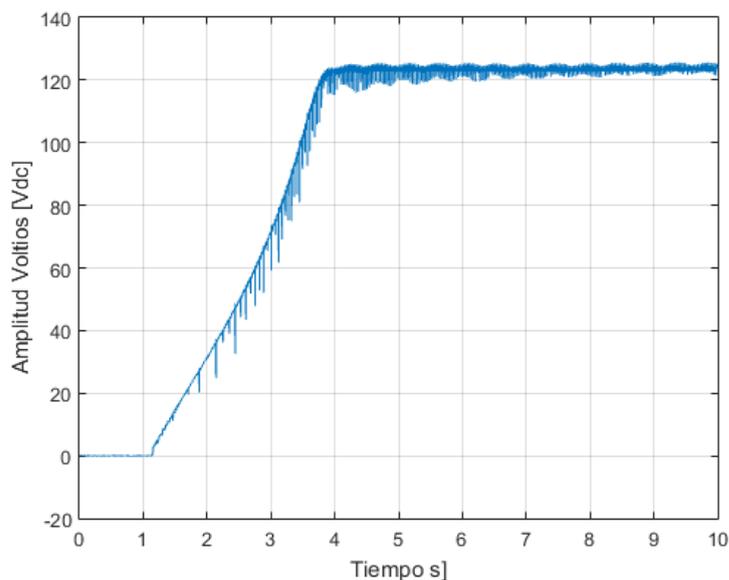


Figura 3.7 Señal de velocidad en base a voltaje DC generado

Se aplica un método sencillo para transformar de voltios a *rad/s*. De acuerdo con la gráfica de arriba calcularemos el valor medio en voltios y normalizaremos el vector de 0 a 1; posteriormente multiplicaremos por

1776 rpm ya que el motor es de cuatro polos y finalmente por el factor $\frac{\pi}{30}$ para la unidad deseada. Ver Figura 3.8.

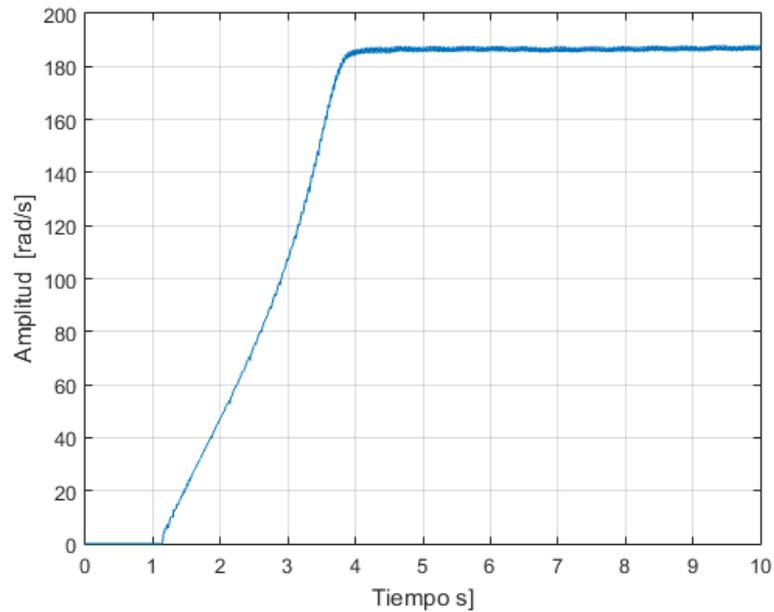


Figura 3.8 Velocidad del motor de inducción trifásico

3.3 Validación del modelo propuesto del motor trifásico

En esta sección se presentan las simulaciones realizadas en la plataforma matlab del modelo implementado en vectores espaciales; utilizando los datos de la tabla 6. A continuación la función del modelo realizada en matlab.

```
function dy=motor_VS(t,y)
global Rs Rr Ls Lm Lr J v w Tm p F
ie=y(1);
ir=y(2);
wm=y(3);
theta=y(4);

%y(4)=theta;
```

```

R=[Rs,0;0,Rr];%matriz elaborada con las ecuaciones del libro
L=(3/2)*[Ls,Lm*exp(j*theta);Lm*exp(-j*theta),Lr];% matriz despejada de la
formula original del libro

ve=sqrt(2/3)*[1 exp(j*2*pi/3) exp(j*4*pi/3)]*v*[sin(w*t);sin(w*t-2*pi/3);sin(w*t-
4*pi/3)]; % no hay variacion entre
%los dos sistemas

p_i=inv(L)*([ve;0]-([Rs,j*wm*(3/2)*Lm*exp(j*theta);-j*wm*(3/2)*Lm*exp(-
j*theta),Rr])*[ie;ir]);
%p_wm=-(p/(J))*(3/2)*Lm*(real(ie).*imag(ir*exp(j*theta)))-
real(ir*exp(j*theta)).*(imag(ie)))-Tm;
%p_wm=(p/(J*377))*((3/2)*(Lm*imag(ie.*conj(ir*exp(j*theta))))-Tm/J -F*wm/J);
%p_wm=(p)*(1/J)*((3/2)*(Lm*imag(ie.*conj(ir*exp(j*theta))))+Tm);
p_wm=-(3*p/(2*J))*Lm*(real(ie).*imag(ir*exp(j*theta))-
real(ir*exp(j*theta)).*(imag(ie)))-Tm/J-F*wm/J;% aceleracion angular
%ecuacion del torque electromagnético
p_theta=wm;% derivada del angulo del rotor = la velocidad angular
dy=[p_i;p_wm;p_theta];

```

Ler[mH]	Le[mH]	Lr[mH]	R e[Ω]	Rr [Ω]	J [Kgm ²]	F [Nm.s]
0,0818	0,0885	0,0884	1,1521	1.52	0,0566	0,0097

Tabla 6: Parámetros del motor de inducción trifásico

En la Figura 3.9 se muestran las corrientes vectoriales real así como también las simuladas en el modelo desarrollado en este trabajo. Para este caso nuestra validación del modelo y de los parámetros encontrados se lo realizará comparando las gráficas de las variables antes mencionadas. La carga simulada para el arranque del motor de inducción trifásico corresponde a $J = 0.0854 \text{ Kgm}^2$

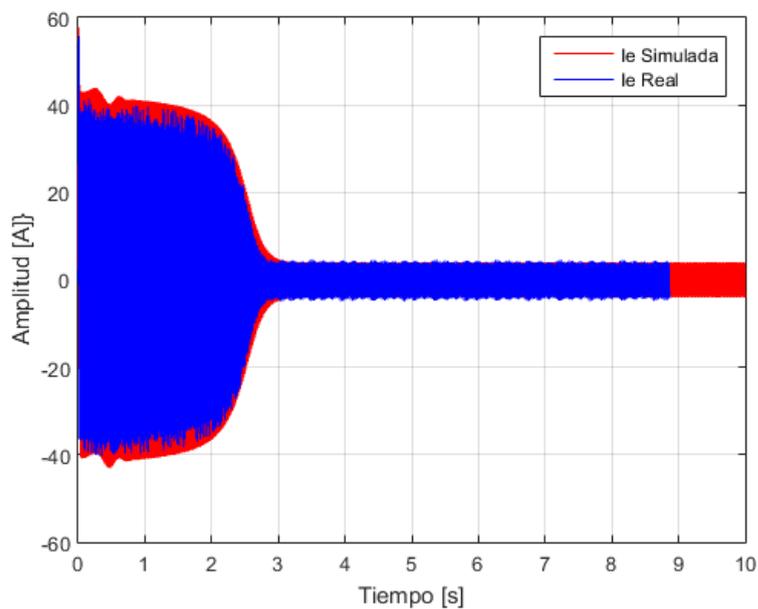


Figura 3.9 Corrientes de estator en sistema ortogonal $\alpha - \beta$

Para apreciar de mejor manera las señales de corrientes, se realiza una gráfica ampliada en estado estacionario como muestra la Figura 3.10.

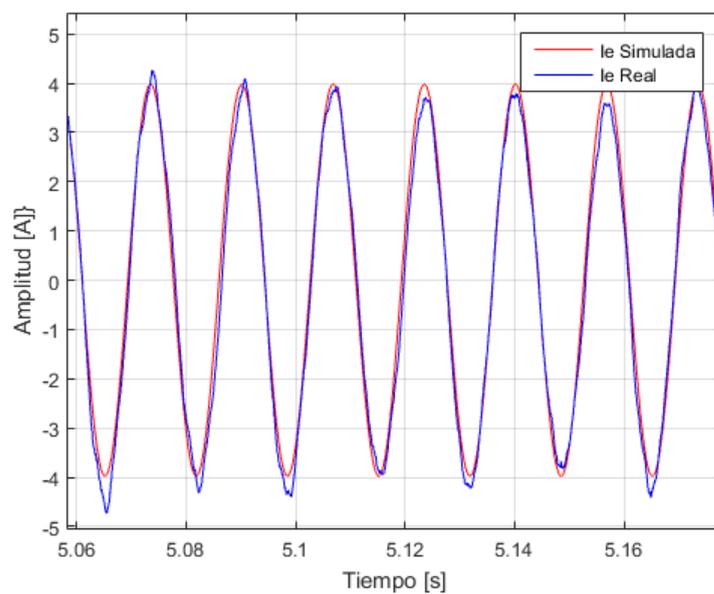


Figura 3.10 Corrientes vectoriales real vs simulada en estado estacionario sistema ortogonal $\alpha - \beta$

De la misma manera para la velocidad angular. Ver Figura 3.11

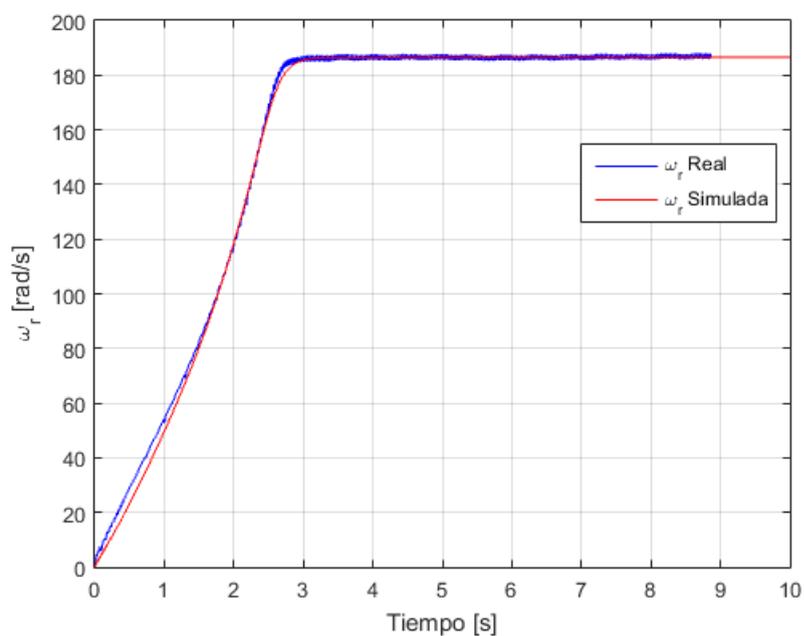


Figura 3.11 Velocidad angular real vs simulada

Continuando con la verificación de los parámetros del motor de inducción, en las siguientes gráficas se muestran las corrientes y velocidades en un arranque en vacío del motor.

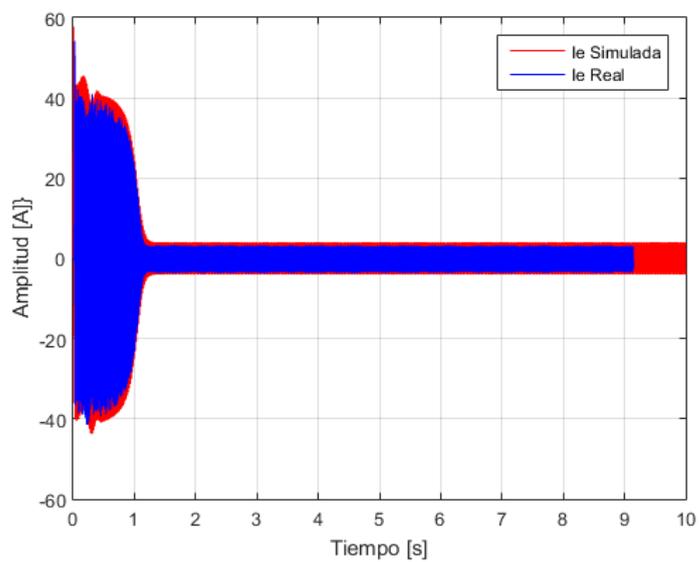


Figura 3.12 Corrientes vectoriales real vs simulada arranque en vacío sistema ortogonal $\alpha - \beta$

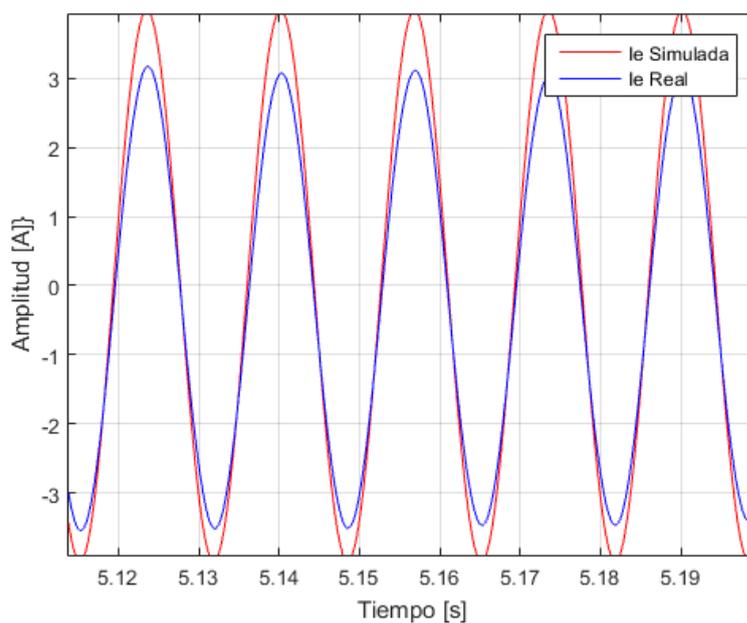


Figura 3.13 Corrientes vectoriales real vs simulada arranque en vacío sistema ortogonal $\alpha - \beta$ (ampliación)

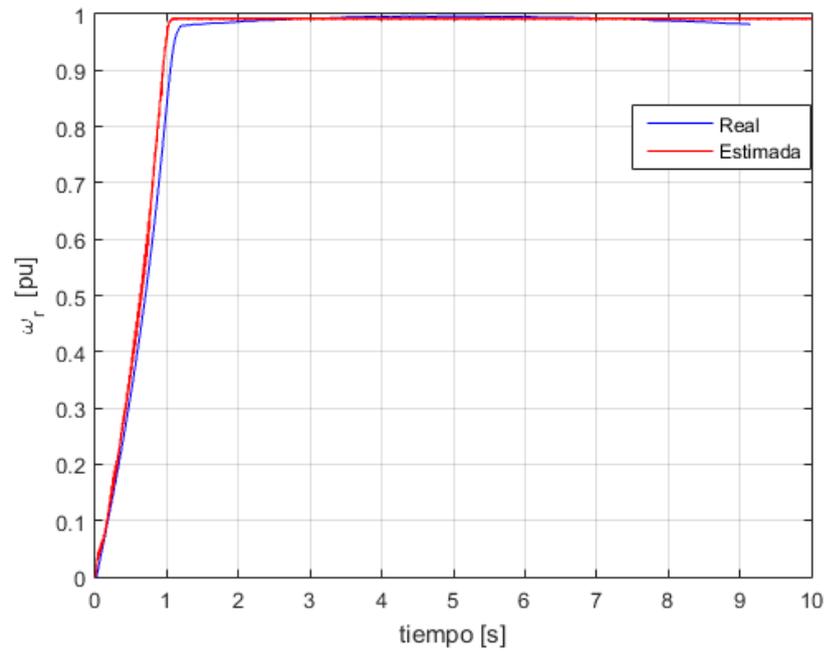


Figura 3.14 Velocidad angular real vs simulada en un sistema por unidad

CAPÍTULO 4

4. IMPLEMENTACIÓN Y ANÁLISIS DEL ESTIMADOR DE VELOCIDAD

El capítulo 4 presenta el desarrollo del estimador de velocidad, se menciona la metodología usada para la obtención de los datos para el entrenamiento de la red. Se realizan varias simulaciones de prueba y error para encontrar la estructura que mejor aproxime la velocidad estimada a la velocidad real; que para el caso en estudio la primera será la velocidad obtenida del quinto estado del modelo no lineal del motor en un arranque en vacío. Finalmente para realizar la comparación, se simula un control en lazo cerrado de voltaje-frecuencia. El objetivo de este es comprobar que el entrenamiento de la red neuronal siga una referencia de velocidad. De igual manera para el Filtro Extendido de Kalman.

4.1 Configuración de la red neuronal como estimador de velocidad

En este capítulo se presenta el desarrollo del estimador de velocidad basado en el algoritmo de retropropagación (Backpropagation), desarrollado en el capítulo 2. A continuación se hace un resumen de los pasos a seguir para la programación del mismo.

1. Se inicializan los pesos sinápticos de cada una de las capas con valores aleatorios entre 0 y 1, de igual manera se escoge la tasa de aprendizaje η .
2. Aplicamos los patrones x_j a la capa de entrada.
3. Propagamos los patrones desde la capa de entrada hacia la capa de salida mediante.

$$z_l = \sigma\left(\sum_{j=1}^n v_{lj}x_j + v_{l0}\right); \quad l = 1, 2, \dots, L \quad (4.1)$$

$$y_k = \sigma\left(\sum_{l=1}^L w_{kl}z_l + w_{k0}\right); \quad k = 1, 2, \dots, m \quad (4.2)$$

4. Calculamos el error en la capa de salida de la siguiente manera.

$$e_k = d_k - y_k \quad k = 1, 2, \dots, m \quad (4.3)$$

$$E(k) = \frac{1}{2} \sum_{j=c} e_l^2(k) \quad (4.4)$$

5. Como siguiente paso se tiene el cálculo del gradiente δ_k en la capa de salida.

$$\delta_k = y_k(1 - y_k)e_k; \quad k = 1, 2, \dots, m \quad (4.5)$$

6. Calculamos el gradiente δ_l en la capa escondida.

$$\delta_l = z_l(1 - z_l) \sum_{k=1}^m w_{kl} \delta_k; \quad l = 1, 2, \dots, L \quad (4.6)$$

7. Actualizamos los pesos sinápticos.

8. Presentamos el siguiente patrón a la capa de entrada x_{j+1} .

Para el presente trabajo se tiene una estructura de 9 entradas, 10 neuronas en la capa escondida y la capa de salida que corresponde a la velocidad angular del motor de inducción trifásico. Ver Figura 4.1.

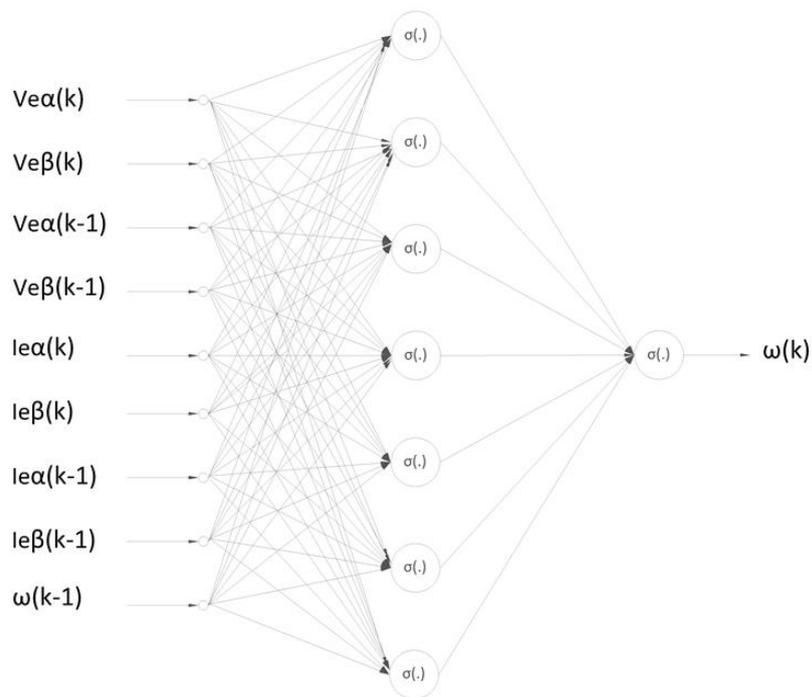


Figura 4.1 Estructura de la red neuronal para el entrenamiento

4.2 Proceso de entrenamiento de la red neuronal

Como se indicó anteriormente las redes neuronales multicapa son capas de neuronas conectadas en cascada. Al inicio los pesos sinápticos se eligen aleatoriamente en este instante la salida deseada será totalmente diferente al patrón dado, es aquí en donde se compara la salida y los pesos se ajustan mediante el algoritmo supervisado de retropropagación hasta que el error sea lo suficientemente pequeño.

A continuación se describen los pasos a seguir para el entrenamiento de la red neuronal para el presente trabajo.

1. Simulación del motor de inducción trifásico aplicando el modelo de estado estacionario referido hacia el estator y los parámetros obtenidos mediante la optimización. Para este paso se utiliza matlab simulink.
2. Almacenar los datos para diferentes puntos de trabajo, tanto salidas como entradas.

3. Elegimos los datos de entrada.
4. Elegimos los datos de velocidad angular como patrón de entrenamiento.
5. Al terminar se prueba la red neuronal para diferentes patrones para verificar que el entrenamiento ha sido satisfactorio.

En la Figura 4.2 se presente el modelo del motor de inducción trifásico cuyo bloque **motorCon**, contiene una función especial de matlab en donde se encuentra programado el código en espacios de estados, como se puede ver a continuación.

```
function [ sys x0] = motorCont( t,x,u,flag,x1,x2,x3,x4,x5)
global Rs Rr Ls Lr Lm p J F Tr Ts a1 a2 a3 b a5 a6 a7
Tr = Lr/Rr;
Ts = Ls/Rs;
rho = 1-((Lm^2)/(Ls*Lr));
a1 = -(1/(rho*Ts)+(1-rho)/(rho *Tr));
a2 = Lm/(rho*Ls*Lr*Tr);
a3 = Lm/(rho*Ls*Lr);
b = 1/(rho*Ls);
a5 = Lm/Tr;
a6 = 1/Tr;
% % % %a7 = 3*p*p*Lm/(2*J*Lr);
a7 = p*Lm/(2*J*Lr);

if flag==0,
x0 = zeros(5,1);
sys = [5,0,5,3,0,1];%6to elemento para procesos 0=discreto 1= continu

elseif flag ==1,

U=[u(1);u(2);u(3)];

sys1=[a1 0 a2 a3*x(5)*p/2 0;
```

```
0 a1 -a3*x(5)*p/2 a2 0;  
a5 0 -a6 -x(5)*p/2 0 ;  
0 a5 x(5)*p/2 -a6 0;  
-a7*x(4) a7*x(3) 0 0 -F/J ]*[x(1);x(2);x(3);x(4);x(5)]+...  
[u(1)*b; u(2)*b;0;0;-u(3)/J];  
sys =sys1;  
elseif flag==3,  
  
    sys=x;  
else  
    sys =[];  
end
```

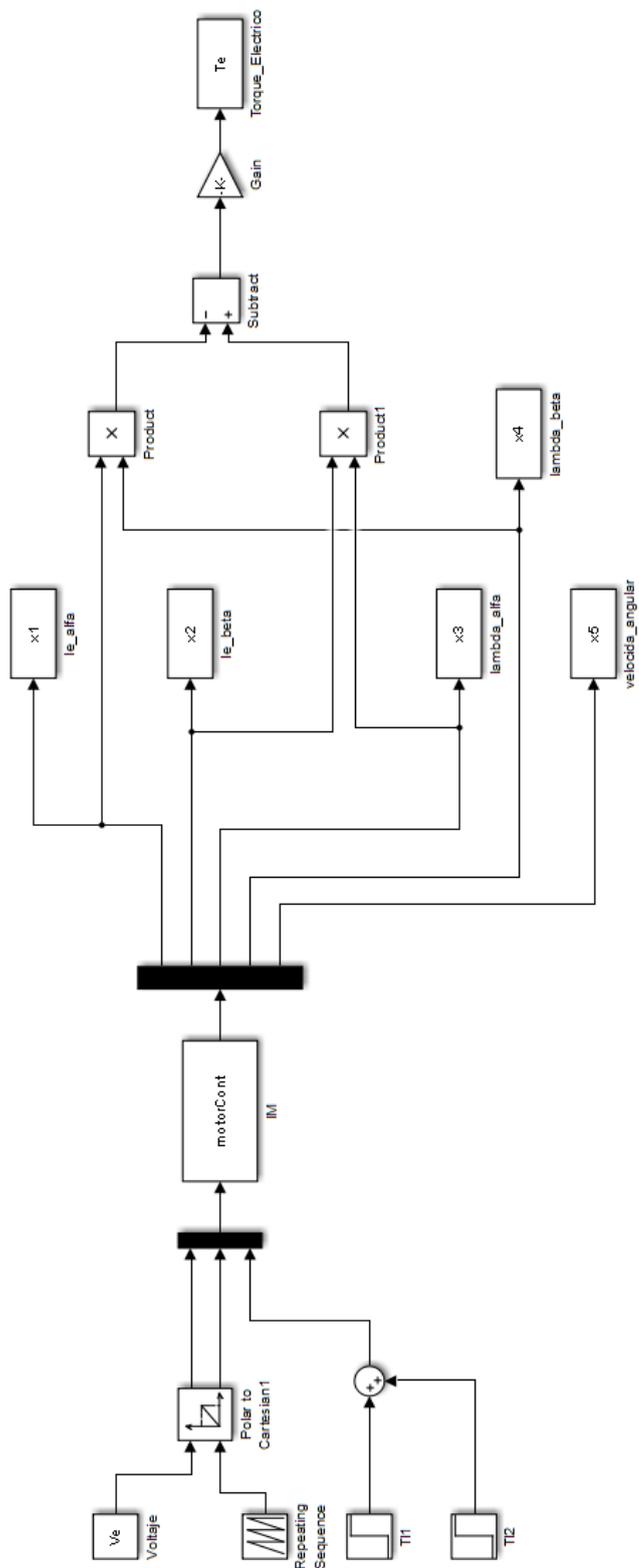


Figura 4.2 Modelo en simulink del motor de inducción trifásico

Los datos que se obtienen de la simulación se guardarán en el archivo **datos simulados.mat** el mismo que contendrá los voltajes, corrientes y velocidad angular en el marco de referencia estacionario; cuyos valores son las entradas para el entrenamiento de la red neuronal.

El patrón de la velocidad ω_r que se utilizará para el entrenamiento de la red neuronal se puede observar en la Figura 4.3. Para ingresar los datos de entrada hacia la red neuronal, existe la posibilidad de normalizar los voltajes y corrientes, pero en este caso se lleva el modelo del motor de inducción trifásico a un sistema por unidad cuyas bases se establecen en la tabla 7 para los datos de la maquina en estudio.

La conversión de una magnitud en particular se lo hace con la ecuación 4.7.

V_b	S_b	t_b	T_b	ω_b	I_b	Z_b	L_b
456	4800	$\frac{1}{\omega_b}$	$\frac{S_b}{188.5}$	377	$\frac{S_b}{\sqrt{3}V_b}$	$\frac{V_b^2}{S_b}$	$\frac{S_b}{\omega_b}$

Tabla 7: Magnitudes bases para un sistema por unidad

$$X_{pu} = \frac{X_{SI}}{X_b} \quad (4.7)$$

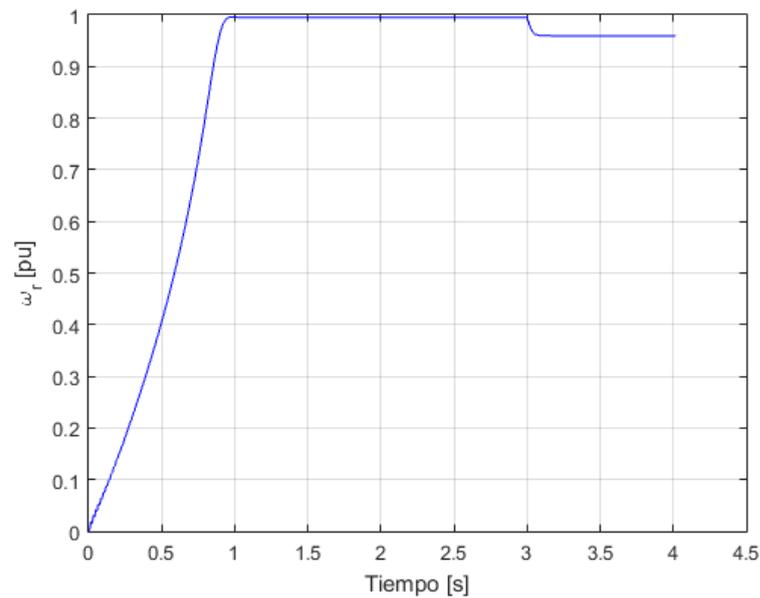


Figura 4.3 Patrón de velocidad para el entrenamiento de la red neuronal

Los datos de entrada hacia la red neuronal son los valores medidos de voltaje, corriente y velocidad angular y sus respectivas señales en retraso.

$$v_{e\alpha}(k), v_{e\alpha}(k-1)$$

$$v_{e\beta}(k), v_{e\beta}(k-1)$$

$$I_{e\alpha}(k), I_{e\alpha}(k-1)$$

$$I_{e\beta}(k), I_{e\beta}(k-1)$$

$$\omega_r(k-1)$$

A continuación se presenta los resultados obtenidos de las simulaciones realizadas en la plataforma Matlab. La tabla 8 en su columna 5 muestra el error para cada una de las configuraciones. En la Figura 4.4 se muestra la gráfica para la estructura que corresponde a la fila 1 de la tabla; en donde el algoritmo alcanzó las épocas, pero no así el error que se tuvo como objetivo.

ENTRADAS	OCULTA	SALIDAS	ÉPOCAS	MSE1	MSE
9	3	1	200000	0,0001	0,00040812
9	4	1	200000	0,0001	0,00010068
9	5	1	200000	0,0001	0,00011359
9	7	1	43031	0,0001	0,0001
9	10	1	22030	0,0001	0,000099999
9	10	1	200000	0,00001	0,000034179
9	10	1	250000	0,00001	0,000018773

Tabla 8: Entrenamiento de la red neuronal

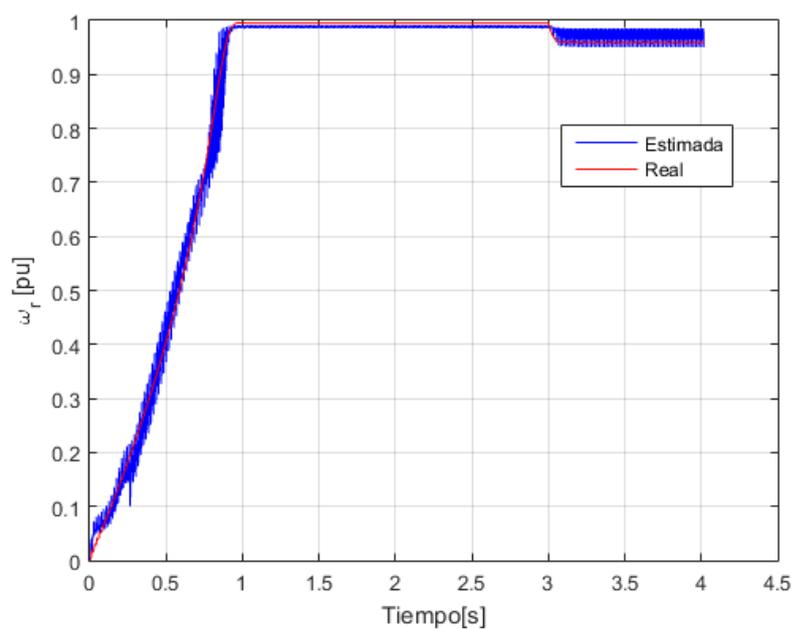


Figura 4.4 Estimación estructura [9 3 1]

Para un segundo entrenamiento se tiene una estructura [9 4 1], sin embargo no se logra obtener el error deseado. Ver la Figura 4.5.

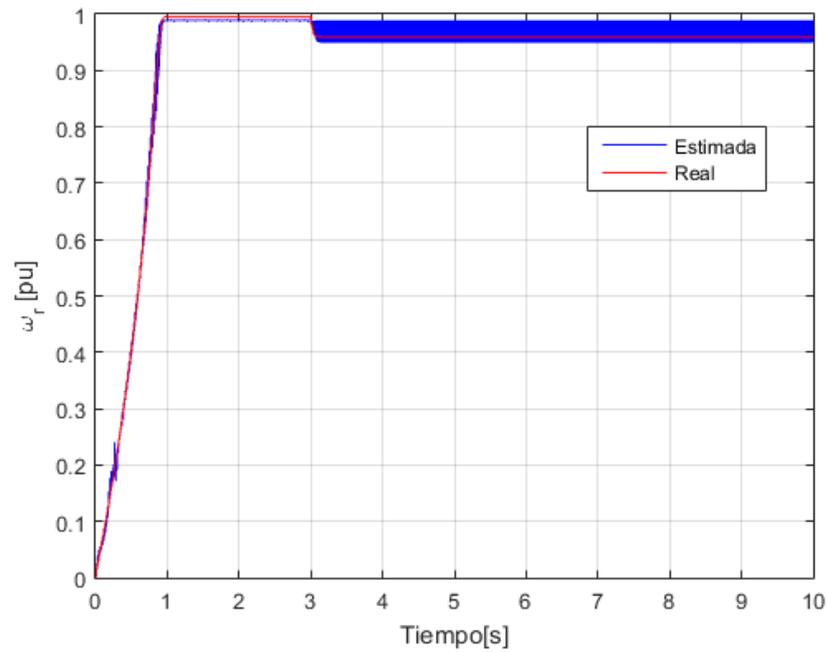


Figura 4.5 Estimación estructura [9 4 1]

Con una estructura [9 5 1], el error se incrementa una de las causas puede ser debido a la inicialización de forma aleatoria de los pesos sinápticos.

La siguiente estructura [9 7 1], alcanza el error objetivo con un mínimo de épocas como se puede observar en la tabla, sin embargo el rendimiento de la red no es el esperado, debido a que existe oscilaciones en el régimen permanente.

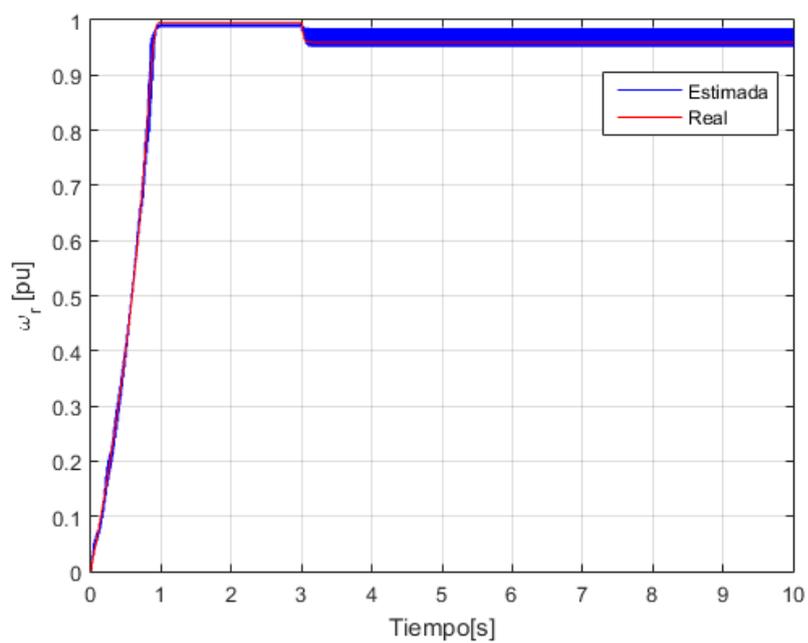


Figura 4.6 Estimación estructura [9 5 1]

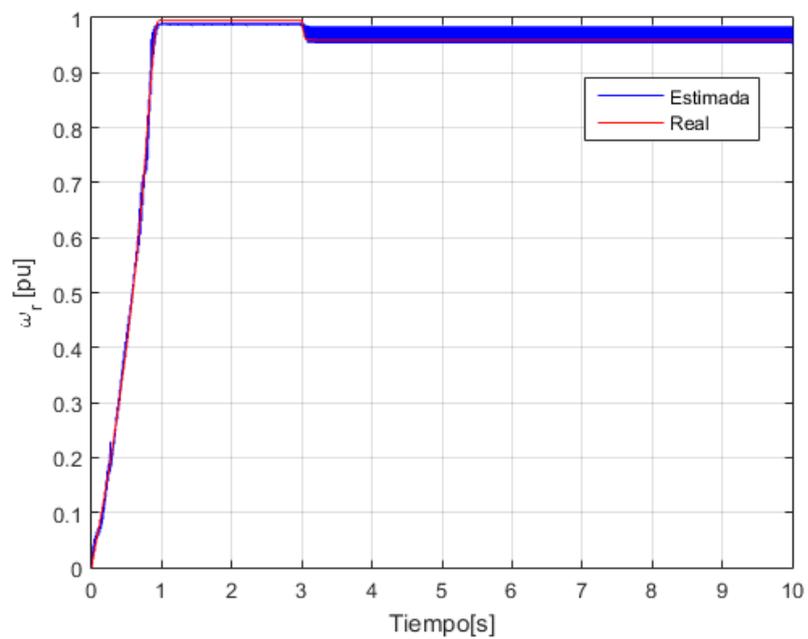


Figura 4.7 Estimación estructura [9 7 1]

Para un nuevo entrenamiento de la red neuronal, se mantiene el error objetivo pero se modifica el número de neuronas en la capa oculta, formando una estructura [9 10 1]. En este caso las oscilaciones en la parte de régimen permanente disminuyen. Ver Figura 4.8.

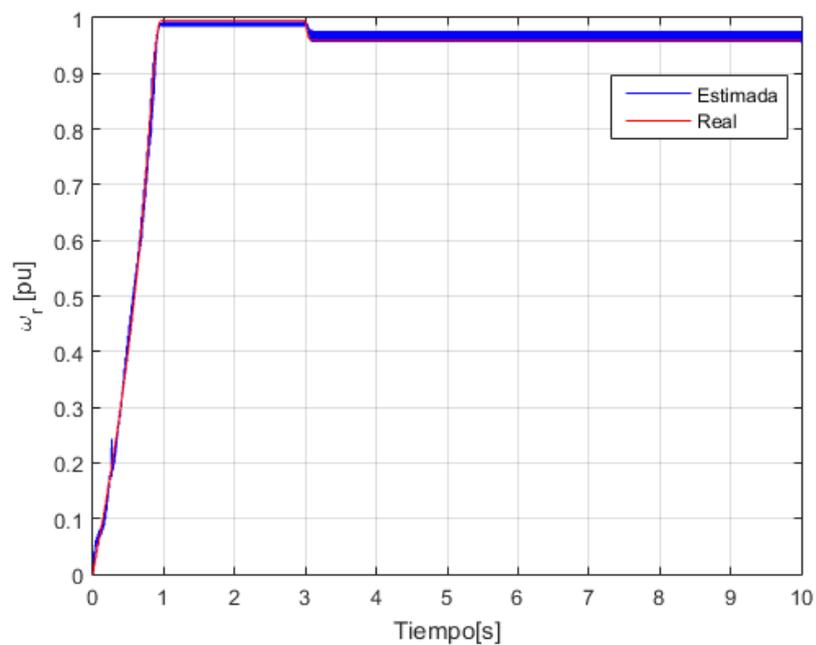


Figura 4.8 Estimación estructura [9 10 1]

En una estructura [9 10 1] apuntando a un error objetivo de 0.00001 e incrementando el número de épocas, según la Figura 4.9, la red neuronal parece tener sus pesos sinópticos ajustados.

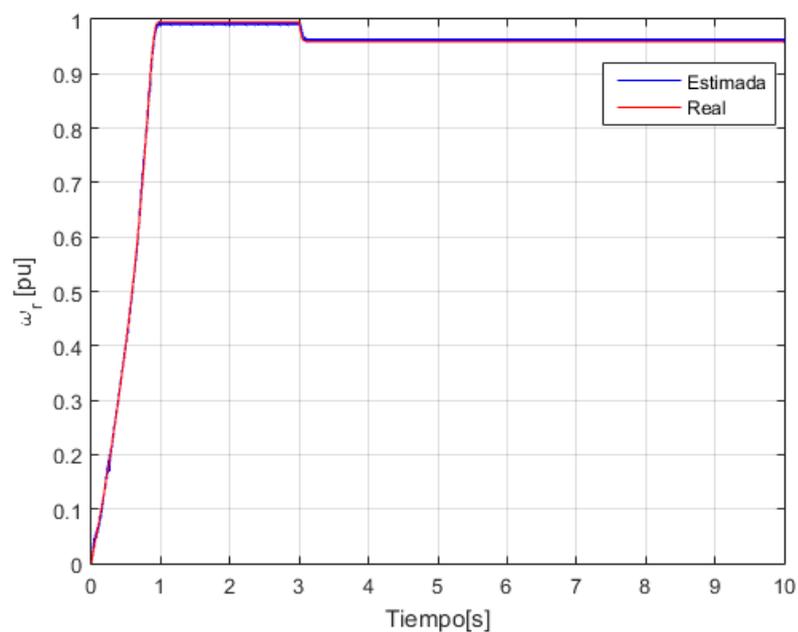


Figura 4.9 Estimación estructura [9 10 1] con 250000 épocas

A continuación la Figura 4.10 muestra el comportamiento de las corrientes y del torque electromagnético. El tiempo de simulación es de 5 segundos con simulaciones de carga en 1.5 y 3.7 segundos

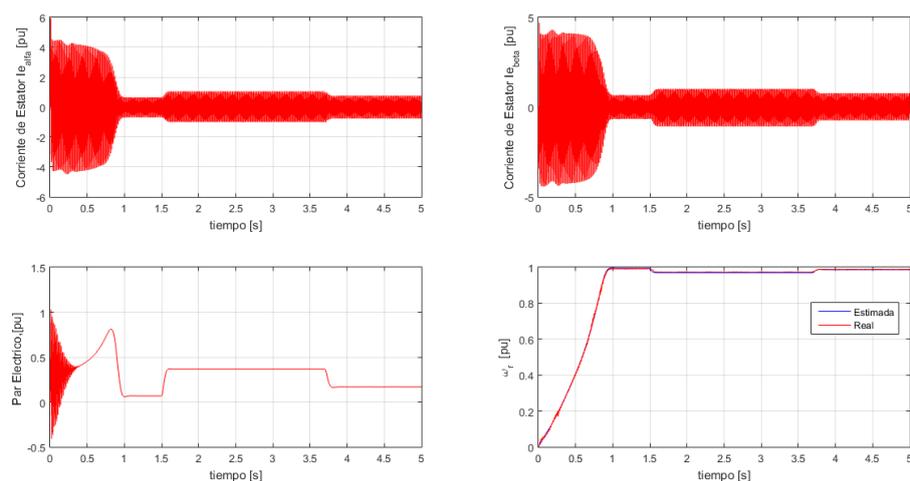


Figura 4.10 Comportamiento par eléctrico velocidad y corrientes vectoriales

Para la validación de la estructura conjuntamente con los pesos sinápticos obtenidos del entrenamiento supervisado de la red se realiza un gráfica de la velocidad real del motor y de la velocidad estimada con los datos que corresponde a la simulación del modelo del motor en un sistema por unidad. En la Figura 4.11 se puede observar el resultado.

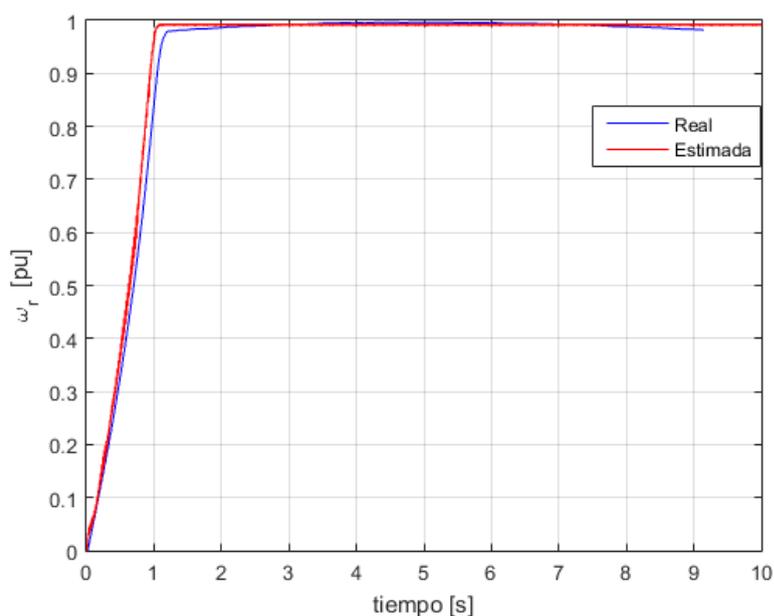


Figura 4.11 Validación de la velocidad angular del motor trifásico

4.3 Implementación del control voltaje frecuencia para regular la velocidad del motor trifásico

El control voltaje frecuencia es el más utilizado a nivel industrial; este consiste en modificar la fuente de alimentación trifásica variando la frecuencia de la red, de esta manera se mantiene constante la densidad de flujo magnético. En la Figura 4.12 se puede observar la característica de este tipo de control.

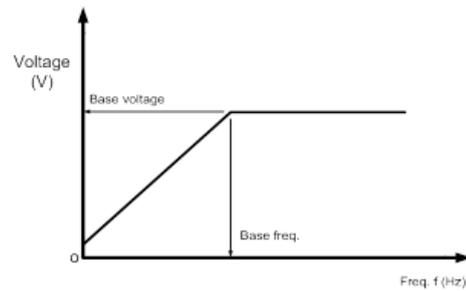


Figura 4.12 Control Voltaje – Frecuencia

Para simular este tipo de control en la plataforma Matlab-Simulink y verificar que la red neuronal puede seguir una referencia de velocidad tanto en sentido hacia adelante como en reversa; se sintonizó un controlador PID (Proporcional Integral Derivativo) el cual está dentro de un control en lazo cerrado como indica la Figura 4.13, y cuyas constantes se listan a continuación.

$$Kp = 3$$

$$Ki = 0.1$$

$$Kd = 0$$

Los datos de la señal de control voltaje – frecuencia corresponden a los de la Figura 4.14.

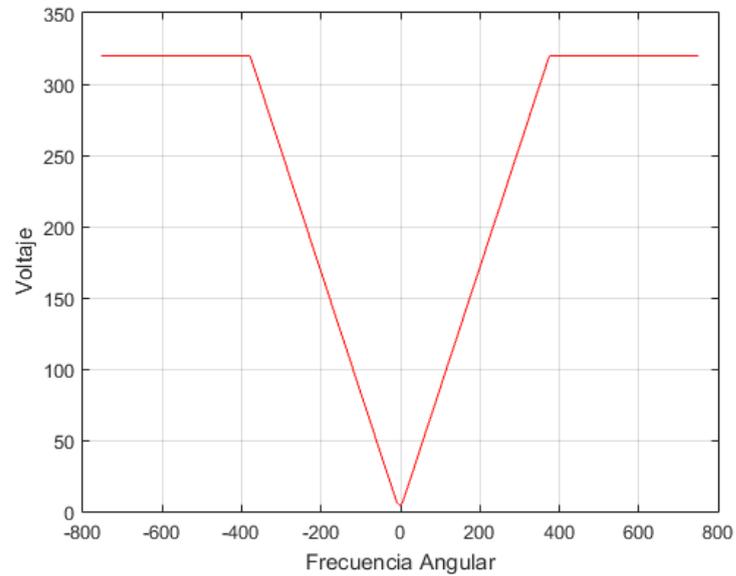


Figura 4.14 Señal de control voltaje – frecuencia

La señal de referencia de velocidad esta dada por los siguientes datos:

$$t = [0 \ 1 \ 1:5 \ 2 \ 2:5 \ 3:5 \ 4:5 \ 5:5 \ 6:5 \ 7:5 \ 8:5 \ 10]$$

$$r = [0 \ 0 \ 188 \ 188 \ -188 \ -188 \ 188 \ 188 \ -188 \ -188 \ 0 \ 0]$$

Se simula en un tiempo de 10 segundos velocidades en sentido hacia adelante (positivas) y en sentido reversa (negativas). Ver Figura 4.15.

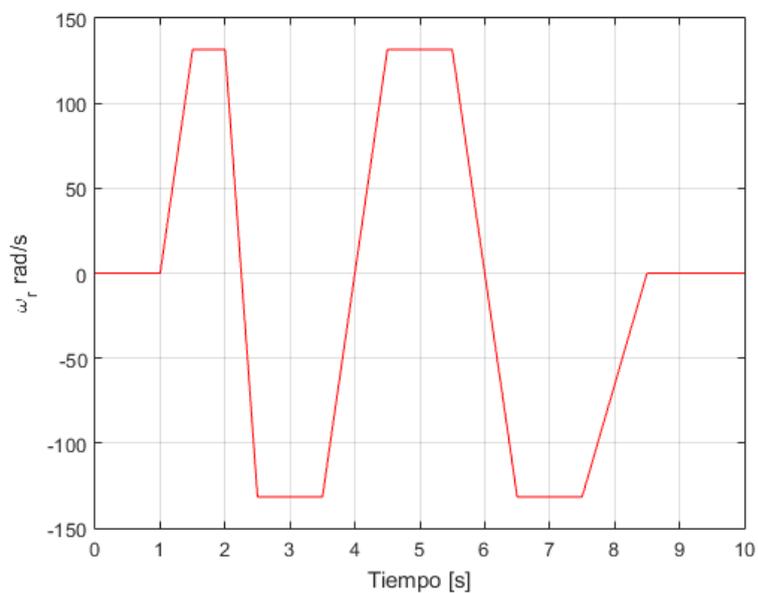


Figura 4.15 Señal de referencia

Para este escenario las simulaciones se realizaron con las magnitudes en el sistema internacional de unidades, y escalas en amplitud. Con estas aclaraciones se entrenaron los pesos sinápticos con una estructura [9 10 1], directamente ya que se tuvo la experiencia en el primer entrenamiento con las otras estructuras. De la Figura 4.16, se puede decir que el controlador PID cumple con el objetivo de seguir la referencia; así mismo las corrientes están dentro del límite de arranque de la máquina.

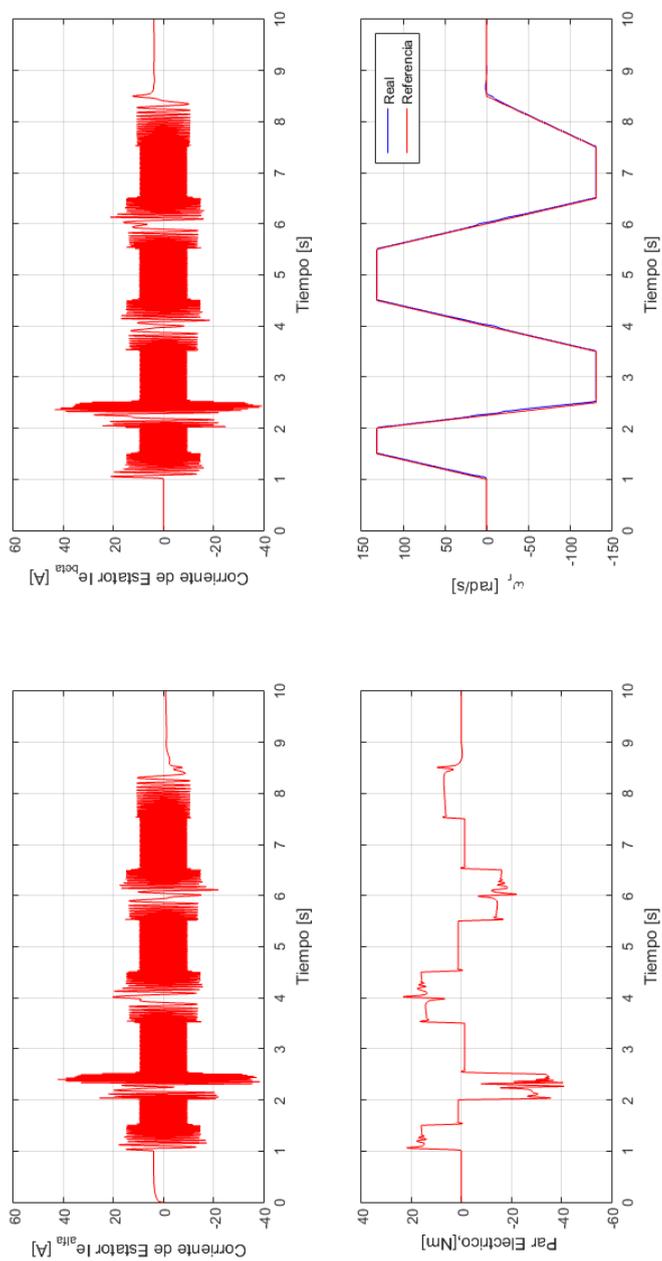


Figura 4.16 Simulación con el 70 % de la velocidad nominal

Para el entrenamiento de la red neuronal se escogieron el 50 % de los datos de la simulación anterior, las funciones de activación de la capa oculta y capa de salida serán tangentes hiperbólicas, debido a que se simularán comportamientos en reversa del motor de inducción trifásico.

Con los pesos ajustados se procede a simular en un tiempo de 10 segundos a la velocidad nominal. En la Figura 4.17 se puede observar el resultado.

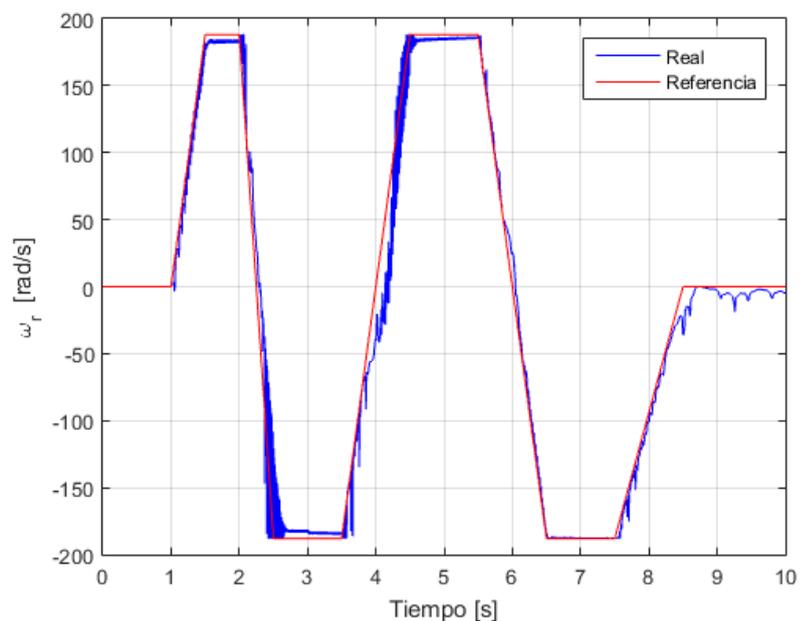


Figura 4.17 Control de velocidad del motor doble giro

En la siguiente simulación se realiza un control de velocidad solamente en un sentido, con los mismos pesos, hasta llegar a la velocidad nominal. La Figura 4.18, expresa claramente la versatilidad del algoritmo de retropropagación para la estimación de la velocidad del motor de inducción trifásico.

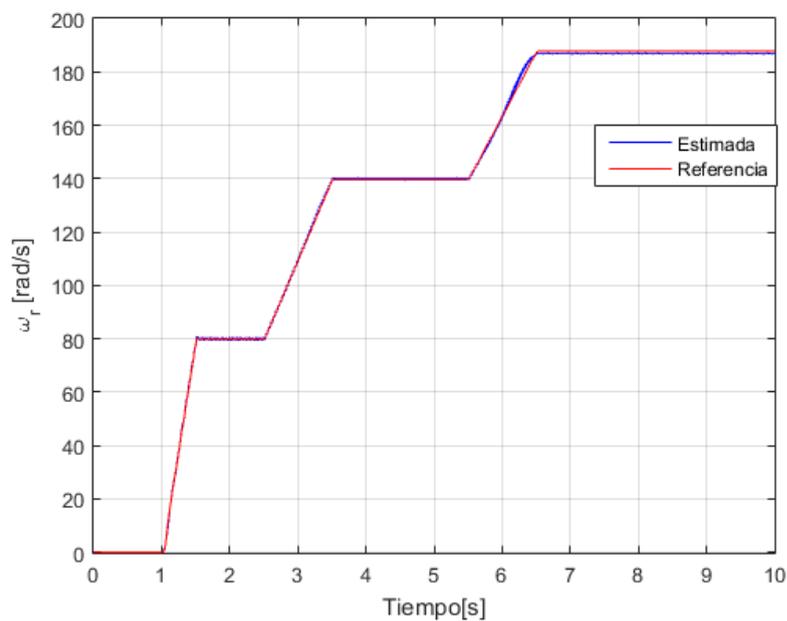


Figura 4.18 Control de velocidad en un sentido de giro

4.4 Implementación del filtro extendido de Kalman como estimador de velocidad

Para las simulaciones de esta sección se presenta el modelo de la Figura 4.19. El bloque EKF contiene una S-FUNCTION en donde se encuentra programado el algoritmo del Filtro Extendido de Kalman.

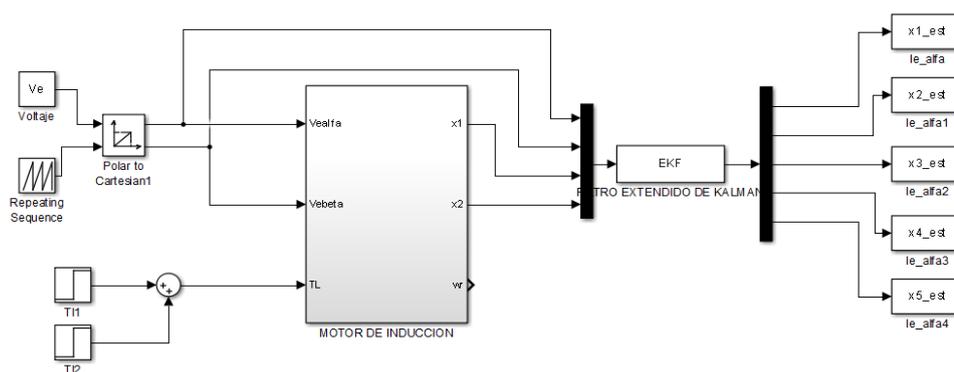


Figura 4.19 Modelo para el filtro extendido de Kalman

Como se puede observar claramente en la figura de arriba, este algoritmo trabaja con los voltajes y corrientes medidos cuyos valores son transformados al marco de referencia estacionario. Las matrices de covarianzas, del sistema y de las mediciones fueron sintonizadas manualmente obteniendo valores que se muestran a continuación.

$$Q = \begin{bmatrix} 0.3 & 0 & 0 & 0 & 0 \\ 0 & 0.99 & 0 & 0 & 0 \\ 0 & 0 & 0.001 & 0 & 0 \\ 0 & 0 & 0 & 0.000001 & 0 \\ 0 & 0 & 0 & 0 & 0.006 \end{bmatrix}$$

$$G = \begin{bmatrix} 0.00389 & 0 & 0 & 0 & 0 \\ 0 & 0.00389 & 0 & 0 & 0 \\ 0 & 0 & 0.000301 & 0 & 0 \\ 0 & 0 & 0 & 0.000280 & 0 \\ 0 & 0 & 0 & 0 & 0.01 \end{bmatrix}$$

$$R = \begin{bmatrix} 0.00008 & 0 \\ 0 & 0.00008 \end{bmatrix}$$

Los parámetros para realizar esta simulación están en el sistema internacional de unidades sin escalamiento en amplitud.

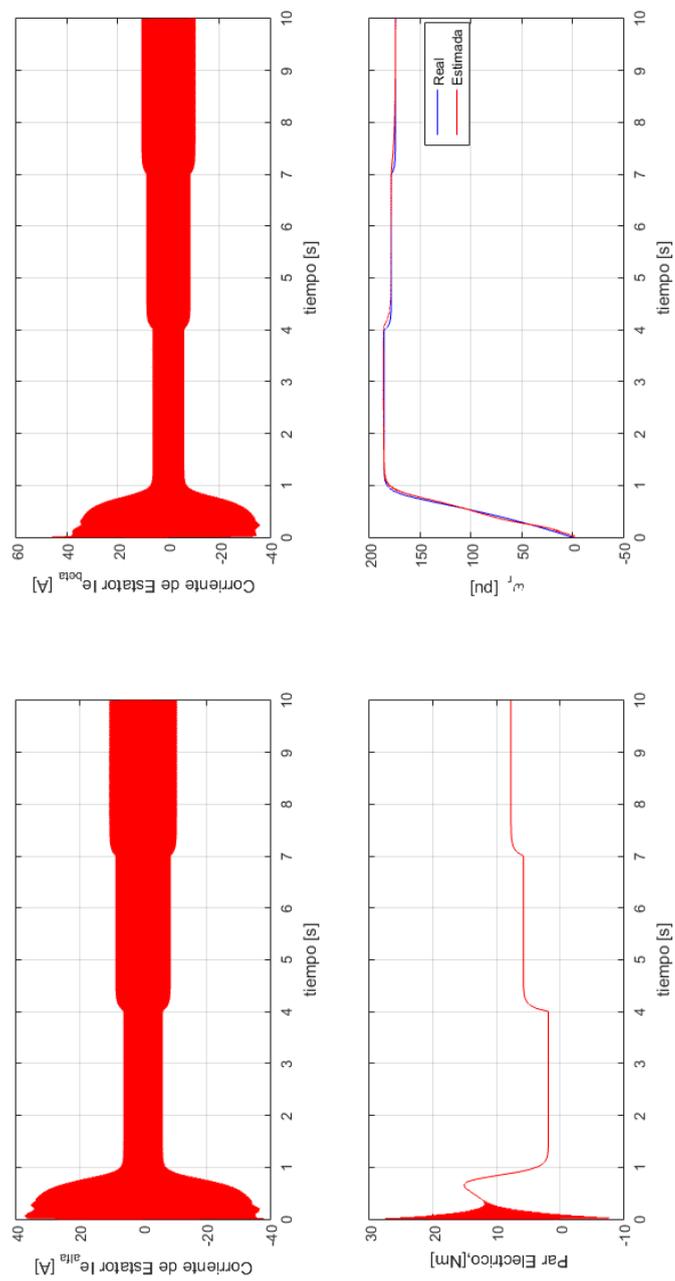


Figura 4.20 Velocidad estimada mediante EKF

En el afán de mejorar el rendimiento del filtro en la estimación de velocidad del motor; se encontraron las matrices óptimas mediante optimización aplicando Algoritmos Genéticos (AG) en donde la función de costo a minimizar es la diferencia entre la velocidad real y la velocidad estimada. La función @ga de la plataforma Matlab se inició como indica el código a continuación.

```
function x1=Start_GA()

X0=rand(20,12);
lb=ones(1,12)*0.000001;
lb=lb';
ub=ones(1,12)*0.1;
ub=ub';
options = gaoptimset(@ga);
options = gaoptimset(options,'MutationFcn',@mutationadaptfeasible);
options = gaoptimset(options,'PopulationSize',100);
%options = gaoptimset(options,'InitialPopulation',X0);
options = gaoptimset(options,'Generations',100);
options = gaoptimset(options,'Tolfun',1e-3);
options = gaoptimset(options, 'EliteCount',2);
options = gaoptimset(options, 'CrossoverFraction',0.8);
options = gaoptimset(options,'PlotFcns',{@gplotbestf },'Display','iter');

%[xx,fval,exitflag]=ga(@costo,12, options)
[xx,fval,exitflag]=ga(@costo,12,[],[],[],[],lb,ub,[], options)
assignin('base','fval',fval);
x1=xx;
assignin('base','x1',x1);
[A,B]=size(x1);
Error=sum(x1.^2)/A;
assignin('base','Error',Error);
G=diag(x1(1:5));
Q=diag(x1(6:10));
```

```

R=diag(x1(11:12));
assignin('base','G',G);
assignin('base','Q',Q);
assignin('base','R',R);
end

```

El resultado para las matrices de covarianzas, evaluando la función de costo de la Figura 4.21, es el siguiente.

$$Q = \begin{bmatrix} 0.0022 & 0 & 0 & 0 & 0 \\ 0 & 0.0009 & 0 & 0 & 0 \\ 0 & 0 & 0.0001 & 0 & 0 \\ 0 & 0 & 0 & 0.0001 & 0 \\ 0 & 0 & 0 & 0 & 0.0054 \end{bmatrix}$$

$$G = \begin{bmatrix} 0.00520 & 0 & 0 & 0 & 0 \\ 0 & 0.0055 & 0 & 0 & 0 \\ 0 & 0 & 0.0001 & 0 & 0 \\ 0 & 0 & 0 & 0.0020 & 0 \\ 0 & 0 & 0 & 0 & 0.0083 \end{bmatrix}$$

$$R = \begin{bmatrix} 0.00005590 & 0 \\ 0 & 0.0005805 \end{bmatrix}$$

El rendimiento del algoritmo genético de 100 individuos compuesto de 12 cromosomas que corresponden a los valores de la diagonal de las matrices Q, G y R se puede observar en la Figura 4.22.

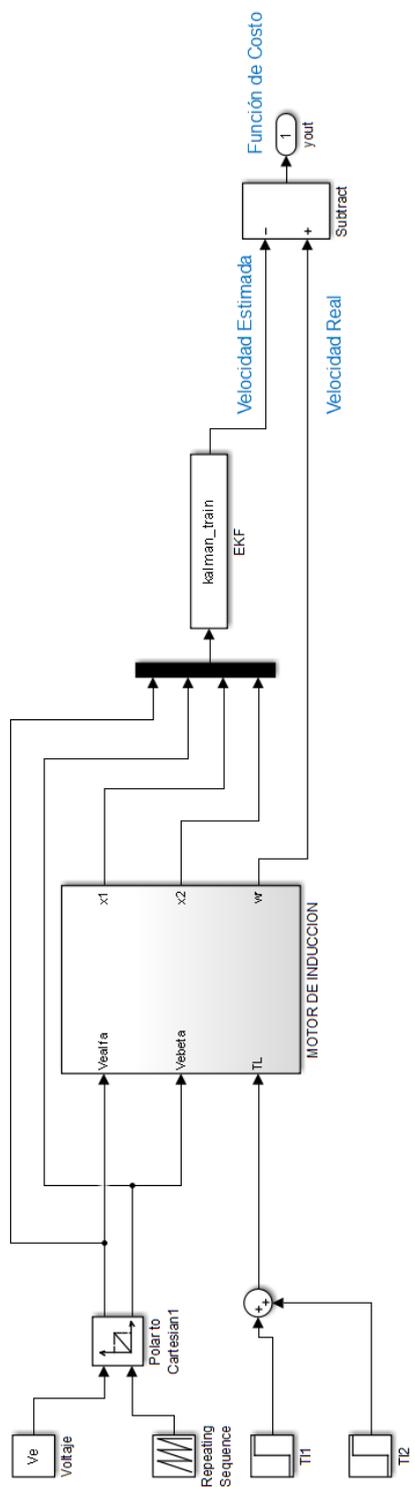


Figura 4.21 Función de costo

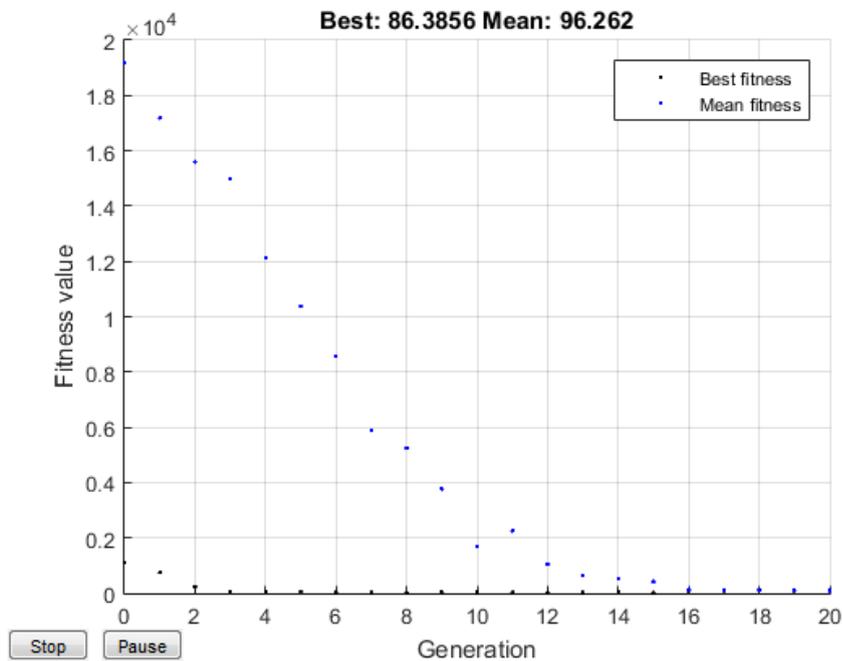


Figura 4.22 Función de evaluación en 20 generaciones

De igual manera podemos aplicar el filtro extendido de Kalman en un control de voltaje-frecuencia. A continuación se presentan las matrices obtenidas mediante optimización con algoritmos genéticos.

$$Q = \begin{bmatrix} 0.0039 & 0 & 0 & 0 & 0 \\ 0 & 0.0003 & 0 & 0 & 0 \\ 0 & 0 & 0.0013 & 0 & 0 \\ 0 & 0 & 0 & 0.0008 & 0 \\ 0 & 0 & 0 & 0 & 0.0095 \end{bmatrix}$$

$$G = \begin{bmatrix} 0.0060 & 0 & 0 & 0 & 0 \\ 0 & 0.0006 & 0 & 0 & 0 \\ 0 & 0 & 0.0003 & 0 & 0 \\ 0 & 0 & 0 & 0.0002 & 0 \\ 0 & 0 & 0 & 0 & 0.0094 \end{bmatrix}$$

$$R = \begin{bmatrix} 0.00000025 & 23 & 0 \\ 0 & 0 & 0.00000047 & 65 \end{bmatrix}$$

En la Figura 4.23 se puede observar el desempeño del algoritmo, que de la misma manera consta de 100 individuos cada uno con 12 cromosomas y 20 generaciones a evaluar.

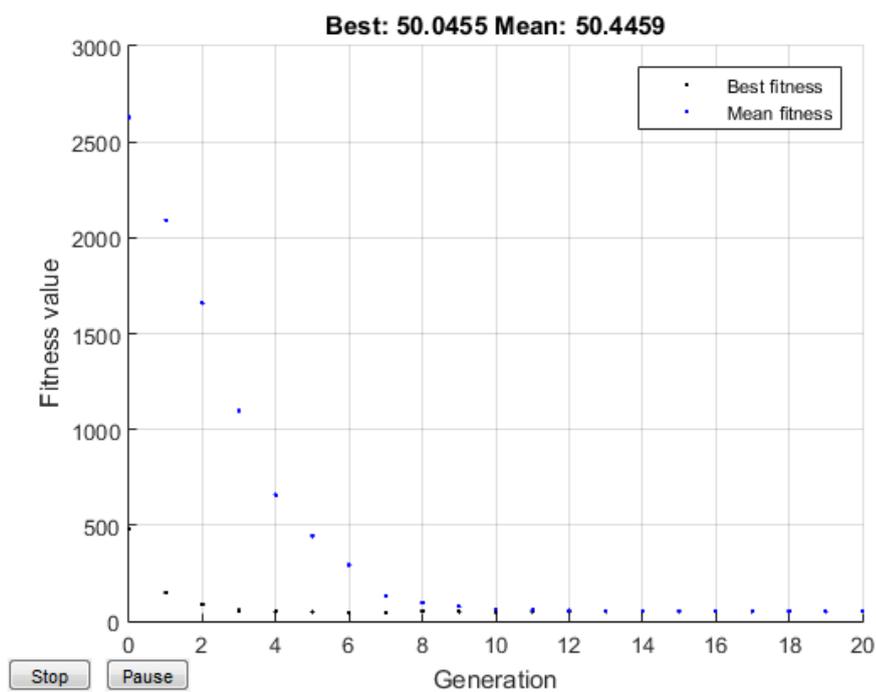


Figura 4.23 Función de evaluación para control voltaje - frecuencia

La estimación y control de la velocidad del motor de inducción, aplicando filtro extendido de Kalman, mediante la técnica voltaje-frecuencia se presenta en la Figura 4.24.

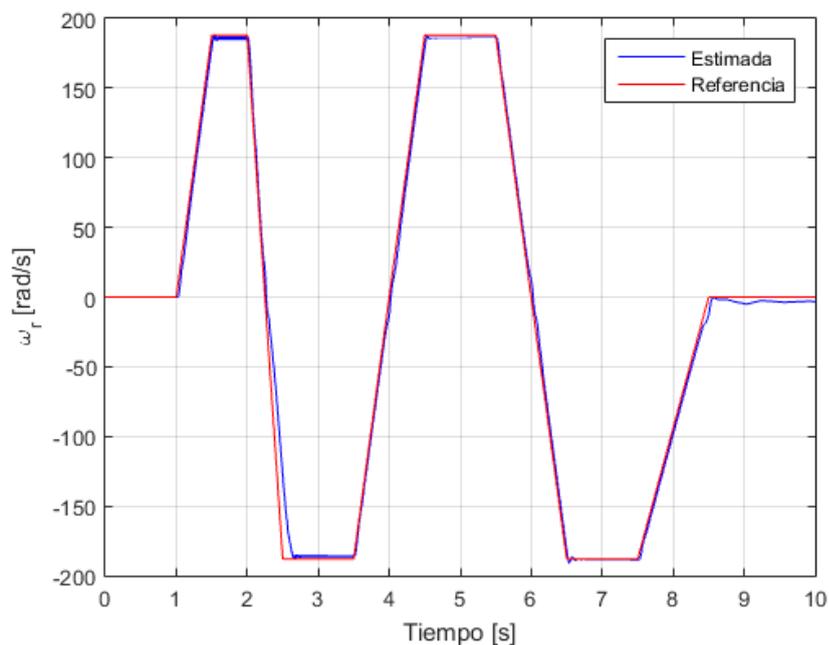


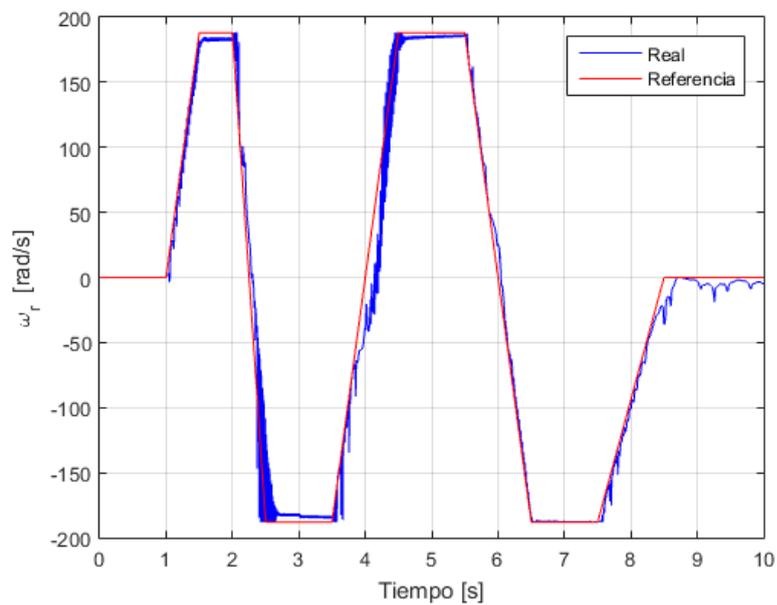
Figura 4.24 Control y estimación de la velocidad mediante EKF

4.5 Análisis comparativo del desempeño de los estimadores basado en redes neuronales y filtro extendido de Kalman

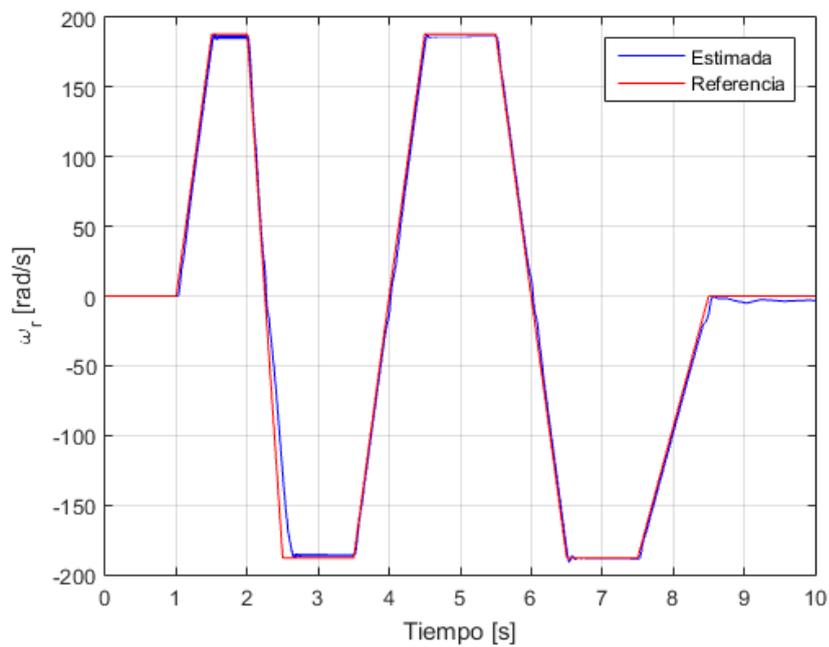
El escenario adecuado para medir el desempeño de los estimadores de velocidad del motor de inducción trifásico, es el control de velocidad mediante voltaje frecuencia. En la Figura 4.25 se puede observar el comportamiento para cada uno de los algoritmos.

La respuesta de la red neuronal artificial es como sigue: en el instante de aceleración del motor se tiene una estimación bastante aceptable, en lo que refiere a la desaceleración la estimación se vuelve ruidosa, esto se debe al comportamiento de las señales de entrada (corrientes y voltajes).

La respuesta para el filtro extendido del Kalman, la estimación es menos ruidosa pero se encuentra retrasada como se puede observar en la Figura 4.25



(a) RNA



(b) EKF

Figura 4.25 Velocidades estimadas

CONCLUSIONES Y RECOMENDACIONES

En este trabajo de titulación se abordó el estudio de dos algoritmos importantes, el primero corresponde a la inteligencia artificial y el segundo a la clase de estimadores de estado, retropropagación (Backpropagation) y Filtro Extendido de Kalman o (Extended Kalman Filter), por sus siglas en inglés, respectivamente. Cumpliendo uno de los objetivos se desarrolló el modelo del motor de inducción trifásico, primeramente en vectores espaciales ya que es fácil de entender y nos da la posibilidad de analizar sus parámetros que están referidos al estator y rotor. Luego se introdujo la transformación para establecer el modelo en espacio de estados en el marco de referencia estacionario con los parámetros del rotor referidos hacia el estator.

Se logró resultados satisfactorios en uno de los temas que corresponde a la estimación de los parámetros del motor de inducción con datos medidos reales de voltaje y corriente. De acuerdo con la experiencia en la industria y por la literatura, se puede afirmar que los valores numéricos obtenidos están dentro del rango para el motor de inducción trifásico en mención. Una de las metodologías para validar, fue la observación de la corriente de estado estacionario, que es de 4 amperios.

Para los demás valores, a pesar de que se contaba con un error aceptable, las corrientes de estado estacionario superaban los 8 amperios.

El algoritmo de retropropagación basado en el método de gradiente descendente utilizado para la estimación de la velocidad del motor de inducción trifásico; fue entrenado en un sistema por unidad, en donde los valores de los parámetros de la maquina son calculados a través de sus unidades bases, con el objeto de no escalar los valores de voltaje y corriente; obteniendo un excelente rendimiento de la red neuronal a las perturbaciones de torque introducidas.

En lo que se refiere al filtro extendido de Kalman, el modelo del motor fue discretizado considerando una aproximación lineal como recomienda la literatura por la menor carga computacional que ofrece, para una implementación en tiempo

real. Mediante las simulaciones realizadas se ha comprobado que ambas técnicas de estimación pueden seguir una referencia de velocidad, el grado de exactitud dependerá de los pesos sinápticos entrenados, para la red neuronal y de los valores de la diagonal de las matrices Q, G y R para el filtro extendido de Kalman.

Para finalizar también podemos mencionar el gran aporte de la Optimización, mediante diferentes técnicas, que nos sirvió para encontrar los parámetros del motor de inducción y los valores de las matrices de covarianzas.

La teoría introducida en este trabajo abre una puerta para estudios futuros acerca del motor de inducción no solamente en la estimación de velocidad sino para el control del mismo. Este último puede ser bastante efectivo si además se consideran los parámetros del motor que varían en el tiempo tales como, la resistencia del rotor y estator.

Es posible una implementación en tiempo real de los dos algoritmos ya que en la actualidad se cuenta con DSP's que pueden realizar todos los cálculos en un tiempo menor al tiempo de muestreo. Combinando las teorías de Redes Neuronales y Lógica Difusa se podría llegar a desarrollar un tema de control tolerante a fallas del motor de inducción.

BIBLIOGRAFÍA

- [1] M. T. Wishart and R. G. Harley, "Identification and control of induction machines using artificial neural networks," *IEEE Transactions on Industry Applications*, vol. 31, no. 3, pp. 612–619, 1995. XI, XVII, 3, 5
- [2] S.-H. Kim, T.-S. Park, J.-Y. Yoo, and G.-T. Park, "Speedsensorless vector control of an induction motor using neural network speed estimation," *IEEE Transactions on Industrial Electronics*, vol. 48, no. 3, pp. 609–614, 2001. XI, 5, 6
- [3] A. Goedel, I. da Silva, M. Suetake, C. do Nascimento, and S. da Silva, "Compact artificial neural network for induction motor speed estimation," in *Electrical Machines and Systems, 2009. ICEMS 2009. International Conference on*, pp. 1–6, IEEE, 2009. XI, 6, 7
- [4] L. Yi and P. Yonghong, "Application of fuzzy neural network in the speed control system of induction motor," in *Computer Science and Automation Engineering (CSAE), 2011 IEEE International Conference on*, vol. 3, pp. 673–677, IEEE, 2011. XI, 7, 8
- [5] M. Barut, S. Bogosyan, and M. Gokasan, "Speed-sensorless estimation for induction motors using extended kalman filters," *IEEE Transactions on Industrial Electronics*, vol. 54, no. 1, pp. 272–280, 2007. XI, 8, 9
- [6] A. J. Manuel, *Estimación Paramétrica de la Máquina de inducción*. Universidad Simon Bolívar. XI, 12, 23
- [7] P. Mehrotra, J. E. Quicoe, and R. Venkatesan, "Speed estimation of induction motor using artificial neural networks," in *Industrial Electronics, Control, and Instrumentation, 1996., Proceedings of the 1996 IEEE IECON 22nd International Conference on*, vol. 2, pp. 881–886, IEEE, 1996. XVII
- [8] P. Vas, *Sensorless Vector and Direct Torque Control*. Oxford Science Publications. XIX, 14, 18

- [9] K. Shi, T. Chan, Y. Wong, and S. Ho, "Speed estimation of an induction motor drive using an optimized extended kalman filter," *IEEE Transactions on Industrial Electronics*, vol. 49, no. 1, pp. 124–133, 2002. 9
- [10] O. W. Paul C. Krause and S. D. Sudhoff, *Analysis of Electric Machinery and Drive Systems*. Jhon Wilet and Sons, INC, Publication. 19
- [11] F. A., *Aquinas Eléctricas*. McGraw Hill. 22