

Comparación de la Red Neuronal y del Filtro de Kalman en la Estimación de Velocidad del Motor de Inducción

Jaime A. González, Marcos A. da Silveira y Eduardo J. Pacheco

Resumen—En esta artículo es presentado un estudio comparativo de dos métodos muy utilizados en la estimación de velocidad. El primero es la estimación de velocidad utilizando Inteligencia Artificial por medio de redes neuronales, que se alimentan de las tensiones y corrientes del estator para producir el valor estimado de velocidad, después de haber sido realizado el entrenamiento de la red en forma *off-line*. El segundo método es usar un Filtro Extendido de Kalman, utilizando un modelo del motor en espacios de estado con ruidos blancos gaussianos aditivos de sistema y de medición. Para cada uno de los métodos serán presentadas sus ventajas y desventajas.

Palabras claves—Control sin sensor, motor de inducción, Inteligencia Artificial..

I. INTRODUCCIÓN

Con la aparición de la electrónica de potencia, el desarrollo del motor de inducción en aplicaciones industriales se incrementó fuertemente sobre todo en aplicaciones de velocidad variable, campo éste sólo cubierto casi exclusivamente por los motores de corriente continua. La operación en velocidad variable para el motor de inducción es realizada por la modificación del campo magnético giratorio utilizando fuentes de tensión y frecuencia variable llamadas convertidores.

El primer control aplicado al motor de inducción alimentado por convertidores, fue llamado control escalar o control de tensión / frecuencia. Este control previene la saturación de los circuitos magnéticos o aumento del flujo

magnético cuando se trabaja por debajo de la velocidad base (velocidad a frecuencia de la red, normalmente de 50 Hz o de 60 Hz). Pero este control no mantiene la capacidad del torque electromagnético nominal cuando opera a velocidades por debajo de la velocidad base.

El control vectorial o control de campo orientado [1] - [4] permite un control de velocidad por debajo de la velocidad base, manteniendo la capacidad del torque electromagnético nominal. Este control fundamenta su efectividad en el conocimiento exacto de la posición de sus flujos de campo, siendo el más utilizado el campo magnético del rotor.

Este control obliga a medir, por ejemplo la velocidad del rotor para luego calcular la velocidad o posición del campo del rotor. Para la medición de la velocidad del rotor son utilizados sensores acoplados o colocados cerca del eje del rotor, produciendo problemas de robustez, confiabilidad, alto mantenimiento, etc [5] - [7].

Para eliminar estos problemas, se ha utilizado la estimación de velocidad sin utilizar sensor físico, llamado comúnmente control sin sensor o "*sensorless control*". Este tipo de control utiliza algoritmos basados, en algunos casos, en los modelos del motor [8] - [10] y utilizando como entradas las corrientes y tensiones del estator del motor, genera un estimado de la velocidad del motor.

En este artículo será presentados dos métodos más utilizados y que han mostrado gran efectividad en la estimación de velocidad, como lo son: la estimación con Inteligencia Artificial, utilizando redes neuronales y el Filtro Extendido de Kalman.

II. MODELO DEL MOTOR DE INDUCCIÓN

El modelo del motor de inducción en coordenadas del estator puede ser escrito de la siguiente forma [1]:

Manuscrito recibido el 8 de Diciembre de 2003. (Escriba la fecha en la cual usted envió el artículo al Comité Técnico del I CIBELEC 2004). Este formato fue financiado por la Universidad de Los Andes (aquí se señala, si la hay, la empresa financiadora del trabajo).

J. A. G. Autor está con la Universidad de Los Andes, Av. Tulio Febres Cordero, Facultad de Ingeniería, Escuela de Ingeniería Eléctrica, Mérida, Estado Mérida, Venezuela, Tlf. +58-274-2402897, Fax: +58-274-2402890, E-mail: gj Jaime@ula.ve).

M. A. S. Autor está con la Pontificia Universidad Católica do Río de Janeiro, Rua Marques de São Vicente, Gávea, Departamento de engenharia Elétrica, Rio de Janeiro, Estado R.J., Brasil Tlf. +55-21-5299409, E-mail: marcos@ele.puc-rio.br).

E. J. P. Autor está con la Pontificia Universidad Católica do Río de Janeiro, Rua Marques de São Vicente, Gávea, Departamento de engenharia Elétrica, Rio de Janeiro, Estado R.J., Brasil Tlf. +55-21-5299409, E-mail: pacheco@ele.puc-rio.br).

$$p \begin{bmatrix} i_{sd} \\ i_{sq} \\ \lambda_{rd} \\ \lambda_{rq} \end{bmatrix} = \begin{bmatrix} -a & 0 & b & c\omega_r \\ 0 & -a & -c\omega_r & b \\ d & 0 & -e & -\omega_r \\ 0 & d & \omega_r & -e \end{bmatrix} \begin{bmatrix} i_{ds} \\ i_{qs} \\ \lambda_{rd} \\ \lambda_{rq} \end{bmatrix} + \begin{bmatrix} f & 0 \\ 0 & f \\ 0 & 0 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} u_{sd} \\ u_{sq} \end{bmatrix} \quad (1)$$

$$a = \left(\frac{R_s}{\sigma_1 L_s} + \frac{1 - \sigma_1}{\sigma T_r} \right) \quad b = \frac{M}{T_r \sigma_1 L_s L_r} \quad c = \frac{M}{\sigma_1 L_s L_r} \quad d = \frac{M}{T_r}$$

$$e = \frac{1}{T_r} \quad f = \frac{1}{\sigma_1 L_s} \quad \sigma_1 = 1 - \frac{M^2}{L_s L_r} \quad T_r = \frac{L_r}{R_r}$$

donde i_{ds} e i_{qs} son las corrientes del estator en el eje “d” y “q” respectivamente, λ_{rd} y λ_{rq} son los enlaces de flujo del rotor en el eje d y q respectivamente, ω_r es la velocidad del rotor, u_{sd} u_{sq} son las tensiones del estator en los ejes d y q, L_r y R_r son las impedancias y resistencias del rotor, M la inductancia mutua, T_r la constante de tiempo del rotor, R_s es la resistencia del estator y σ_1 es el factor de enlace total.

La salida del sistema puede ser escrita de la siguiente forma:

$$y = \begin{bmatrix} i_{sd} \\ i_{sq} \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix} \begin{bmatrix} i_{sd} \\ i_{sq} \end{bmatrix} \quad (2)$$

III. REDES NEURONALES

Las redes neuronales son estrategias de control del tipo inteligencia Artificial que proporcionan una herramienta computacional de fácil aplicación y en donde no es necesario conocer ni utilizar el modelo matemático del proceso y una gran cantidad de datos. La red neuronal utilizada es una red del tipo “*feedforward*” con aprendizaje “*backpropagation*”, como es mostrado en la figura 1.




FIG. 1 Red Neuronal *feedforward backpropagation*

Nuestra red tendrá una capa de entrada (o entrada), una capa de salida y una capa escondida. La capa de

entrada de la red neuronal artificial (RNA) recibe todas las informaciones entregadas por los sensores de entrada o dispositivos de adquisición de datos y luego entrega toda esta información para la camada escondida de la RNA multiplicada por un vector de pesos. La camada de salida recibe toda esta información entregada por la camada escondida y produce una salida.

En la etapa de entrenamiento de la red son presentadas a la entrada, un número de datos de entrada con su salida deseada. La red entonces es entrenada para poder estimar un valor de salida de acuerdo con una entrada no presentada en la etapa de entrenamiento.

Los nodos de la camada escondida, son las unidades de procesamiento de la RNA y su estructura es mostrada en la figura 1. El índice j es cualquier unidad de la camada escondida o de salida.




FIG. 2 Configuración de una neurona

donde:

W_{ij} = Es el peso de la unidad i para la unidad j

F = Función, normalmente sigmoideal

Y_j = Salida

La expresión para la salida será:

$$Y_{ij} = \frac{1}{(1 + e^{-x_j})} \quad (3)$$

IV. ADQUISICIÓN DE LOS DATOS DE ENTRADA

Para la adquisición de los datos de entrada para la red neuronal, se utilizó un modelo del motor de inducción realizado en el programa SIMULINK del Matlab. La figura 3 muestra el modelo del motor, utilizando los ejes de referencia girando con el campo magnético giratorio.

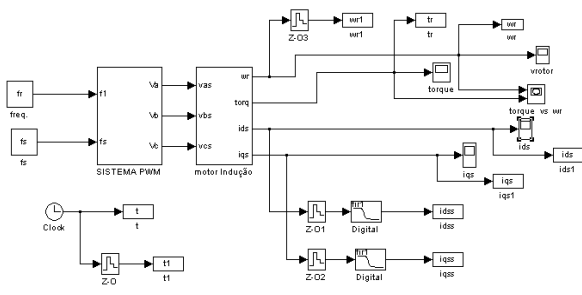


FIG. 3 Modelo del motor de inducción

TABLA 1
DATOS DEL MOTOR DE INDUCCIÓN.

Parámetro	Valor
Ls	144.6 mH
Lr	144.6 mH
M	136 mH
Rs	1 Ω
Rr	1.3 Ω
Pólos	2
J	0.0072 kg m ²

La tabla 1 muestra los datos del motor. El modelo consta de un bloque de entrada PWM, para producir a fuente de tensión trifásica de frecuencia variable, el bloque del motor de inducción y las señales de salida: corriente del estator, velocidad del rotor, torque electromagnético. Es utilizado un filtro para eliminar as frecuencias elevadas debido al uso del método PWM y es simulado un incremento del torque en 1.3 segundos. Las señales de salida para las corrientes, tensiones y velocidad del rotor son mostradas a continuación.

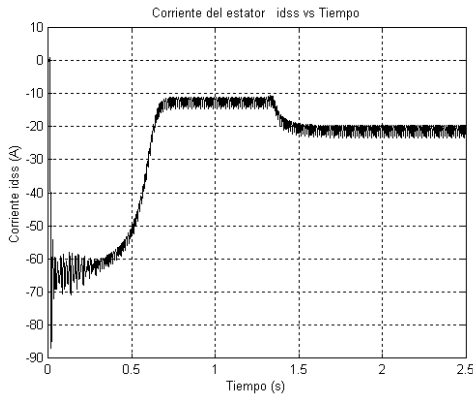


FIG. 4 Corriente del estator idss vs Tiempo

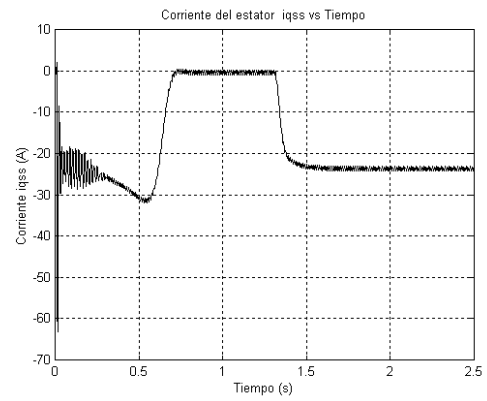


FIG. 5 Corriente del estator iqss vs Tiempo




FIG. 6 Tensión del estator vds vs Tiempo

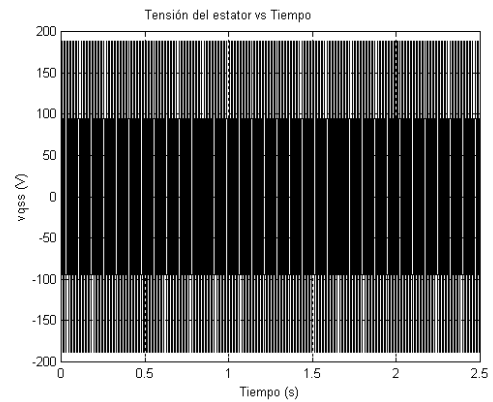


FIG. 7 Tensión del estator vs Tiempo

Al utilizar los ejes d-q girando a la velocidad del campo magnético giratorio, el efecto senoidal es eliminado, como puede verse en las graficas de las corrientes (FIG. 4 y FIG. 5), y por tanto es de esperarse un mejor comportamiento de la RNA a la hora de la estimación.

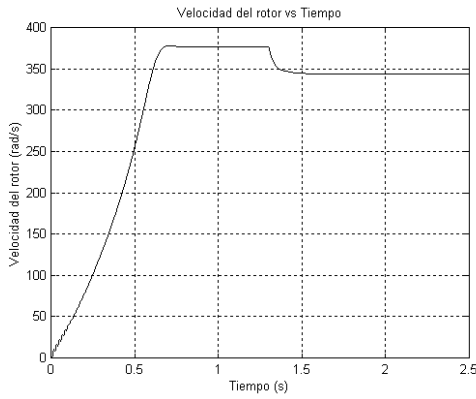


Fig. 8 Velocidad del rotor vs Tiempo

Las graficas de las tensiones muestran el comportamiento “constante” durante la operación del motor, y podría utilizarse un método para estimar también estos valores, pero en este caso, eso no será estudiado. La característica de la velocidad, muestra la región de partida del motor, también llamada de zona de inestabilidad del motor, luego aparece una zona de operación del motor y por último en 1.3 segundos es conectada una carga mecánica al eje, con lo cual la velocidad disminuye.

V. FILTRO DE KALMAN

El Filtro de Kalman es una herramienta eficiente para la estimación de parámetros o de variables de estado cuando el sistema presenta ruidos aditivos de medición y de sistema. La implementación del Filtro de Kalman esta basado en sistemas que puedan ser escritos en variables de estado de la forma:

$$\dot{x} = Ax + Bu + G(t)v_1(t) \quad (4)$$

$$y = Cx + v_2(t) \quad (5)$$

donde, $G(t)$ es la matriz de peso del ruido del sistema, $v_1(t)$ es la matriz del ruido del sistema, $v_2(t)$ es la matriz de ruido de medición. Estas tres matrices son asumidas estacionarias, blancas y gaussianas, es decir con media cero y covarianza conocida.

El algoritmo del Filtro extendido de Kalman es una particularización del filtro, lineal para sistemas de segundo orden que puedan ser linealizados en un punto de operación, como será manipulado el sistema de control del motor de inducción. Este algoritmo para un sistema en variables de estado en la forma discreta puede ser expresado de la siguiente forma:

A. Predicción de Estado:

$$x^f(k) = \Phi(k-1, x^a(k-1), u(k)) \quad (6)$$

con:

$$\Phi(k-1, x^a(k-1), u(k)) = A_k x_k + B_k u_k \quad (7)$$

B. Estimación de la Matriz de Error de Covarianza

$$P^f(k) = \Psi_1(k-1)P^a(k-1)\Psi_1^T(k-1) + \Gamma(k-1)Q\Gamma^T(k-1) \quad (8)$$

donde:

$$\Psi_1 = \frac{\partial \Phi}{\partial x} \Big|_{x=x^f(k)} \quad (9)$$

$$\Gamma = \int_k^{k+1} \Phi(k+1, \tau)G(\tau)d\tau \quad (10)$$

C. Computación de la Matriz de Ganancia

$$K^{KB}(k) = P^f(k)H_1^T(k)[H_1(k)P^f(k)H_1^T(k) + R]^{-1} \quad (11)$$

donde:

$$H_1(k) = \frac{\partial H}{\partial x} \Big|_{x=x^f(k)} \quad (12)$$

$$H(k) = C_k x^f(k) \quad (13)$$

D. Actualización de la Matriz del Error de Covarianza

$$P^a(k) = [I - K^{KB}(y(k) - H(k))] \quad (14)$$

E. Estimación de Estado

$$x^a(k) = x^f(k) + K^{KB}(y(k) - H(k)) \quad (15)$$

El filtro de Kalman, necesita entonces, conocer las matrices Ψ , Γ , H así como los valores de las matrices de covarianza del ruido del sistema y de medición Q y R .

VI. IMPLEMENTACIÓN DEL FILTRO

La ecuación (1) muestra como la velocidad del rotor ω_r esta presente en dicha matriz como un parámetro. La idea del algoritmo es que esta matriz pueda ser aumentada con ω_r de forma tal que ahora la velocidad del rotor ω_r sea un parámetro y una variable de estado. Por lo tanto la ecuación (1) aumentada y discretizada será [11]:

$$\begin{bmatrix} i_{sd}^k \\ i_{sq}^k \\ \lambda_{rd}^k \\ \lambda_{rq}^k \\ \omega_r^k \end{bmatrix} = \begin{bmatrix} 1-akt & 0 & bkt & c\omega_r^{k-1}kt & 0 \\ 0 & 1-akt & -c\omega_r^{k-1}kt & bkt & 0 \\ dkt & 0 & 1-ekt & -\omega_r^{k-1}kt & 0 \\ 0 & dkt & \omega_r^{k-1}kt & 1-ekt & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} i_{sd}^{k-1} \\ i_{sq}^{k-1} \\ \lambda_{rd}^{k-1} \\ \lambda_{rq}^{k-1} \\ \omega_r^{k-1} \end{bmatrix} + \begin{bmatrix} fkt & 0 \\ 0 & fkt \\ 0 & 0 \\ 0 & 0 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} u_{sd}^{k-1} & u_{sq}^{k-1} \end{bmatrix} \quad (16)$$

donde kt es el tiempo de muestreo. La función Φ será:

$$\Phi = \begin{bmatrix} (1-akt)i_{sd}^{k-1} + (bkt)\lambda_{rd}^{k-1} + (c\omega_r^{k-1}kt)\lambda_{rq}^{k-1} + (fkt)u_{sd}^{k-1} \\ (1-akt)i_{sq}^{k-1} - (c\omega_r^{k-1}kt)\lambda_{rd}^{k-1} + (bkt)\lambda_{rq}^{k-1} + (fkt)u_{sq}^{k-1} \\ (dkt)i_{sd}^{k-1} + (1-ekt)\lambda_{rd}^{k-1} - (\omega_r^{k-1}kt)\lambda_{rq}^{k-1} \\ (dkt)i_{sq}^{k-1} + (\omega_r^{k-1}kt)\lambda_{rd}^{k-1} + (1-ekt)\lambda_{rq}^{k-1} \\ \omega_r^{k-1} \end{bmatrix} \quad (17)$$

$$H = C(k-1)x(k-1) = \begin{bmatrix} i_{sd}^{k-1} \\ i_{sq}^{k-1} \end{bmatrix} \quad (18)$$

$$H_1 = \frac{\partial H}{\partial x} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \end{bmatrix} \quad (19)$$

$$\Psi_1 = \frac{\partial \Phi}{\partial x} = \begin{bmatrix} 1-akt & 0 & bkt & c\omega_r^{k-1}kt & ckt\lambda_{rq}^{k-1} \\ 0 & 1-akt & -c\omega_r^{k-1}kt & bkt & -ckt\lambda_{rd}^{k-1} \\ dkt & 0 & 1-ekt & -\omega_r^{k-1}kt & -kt\lambda_{rq}^{k-1} \\ 0 & dkt & \omega_r^{k-1}kt & 1-ekt & kt\lambda_{rd}^{k-1} \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (20)$$

Con las ecuaciones ajustadas para la aplicación del Filtro de Kalman Extendido (6) – (15) se procede a simular el comportamiento del motor bajo una condición semejante al caso de la red neuronal obteniéndose los resultados que serán mostrados en la sección siguiente.

VII. RESULTADOS

Para la estimación de la velocidad de un motor de inducción, se utilizará una RNA del tipo “*feedforward back propagation*” con 4 entradas, una camada escondida y una camada de salida, donde las entradas y la salida serán: entradas:

- i_{ds}
- i_{qs}
- v_{ds}

- v_{qs}

salida:

- velocidad(ω_r)

En la etapa de entrenamiento serán utilizados únicamente 30% de los datos de las entradas. Fueron testadas diferentes configuraciones para la cantidad de neuronas colocados en la camada escondida así como también con el número de épocas. La configuración que dio mejor resultado fue la de usar 9 neuronas en la camada escondida con tan solo 200 épocas en la etapa de entrenamiento, que representa una disminución del tiempo de computación así como en la calidad de la estimación de la velocidad, presentada en [12]. Fue verificado que, para más de 12 neuronas en la camada escondida, el algoritmo presenta sobre entrenamiento llevando a una estimación muy nerviosa, es decir con mucho ruido.

La figura 9 muestra la respuesta del algoritmo para el caso planteado en la sección anterior.




FIG. 9 Velocidad estimada utilizando Red Neuronal

El resultado de la estimación muestra que en la etapa de aceleración del motor, la velocidad estimada presenta algunas variaciones fuertes al comienzo de la estimación, debido principalmente al comportamiento de las señales de entrada de la corriente que presentan un comportamiento muy nervioso en la zona del transitorio del motor (ver figura 4 y 5). Después de 0.3 segundos el algoritmo consigue estimar muy bien la velocidad del motor, aun cuando no ha terminado la zona de aceleración del motor. Para el caso de incremento de carga, el algoritmo consigue seguir dicha variación sin producir grandes diferencias.

Con las especificaciones del Filtro de Kalman Extendido se procedió a implementar, obteniéndose la siguiente respuesta:

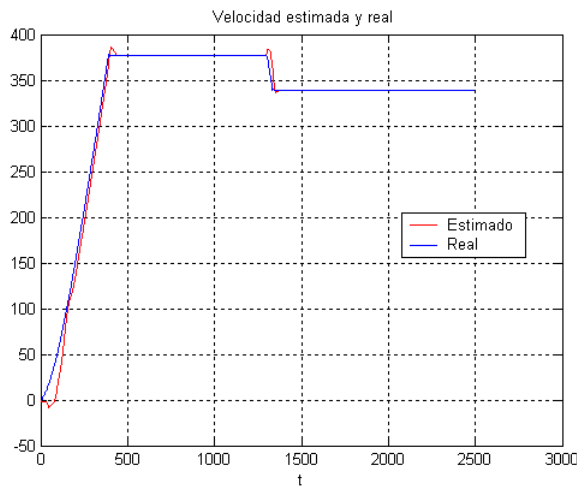


FIG. 10 Velocidad del motor estimada y real utilizando Filtro de Kalman Extendido

La respuesta obtenida con el Filtro de Kalman Extendido, muestra una respuesta menos ruidosa y una velocidad estimada satisfactoria, producto de una solución recursiva que conlleva a un esfuerzo computacional mayor que con la red neuronal.

Luego se procedió a implementar una respuesta más compleja, encontrándose que al modificar el comportamiento de la velocidad, la red neuronal no consiguió seguir la variación de la velocidad. Al contrario, de la red neuronal, el Filtro Extendido de Kalman pudo seguir la variación de la velocidad, tal como puede observarse en las figuras siguientes:

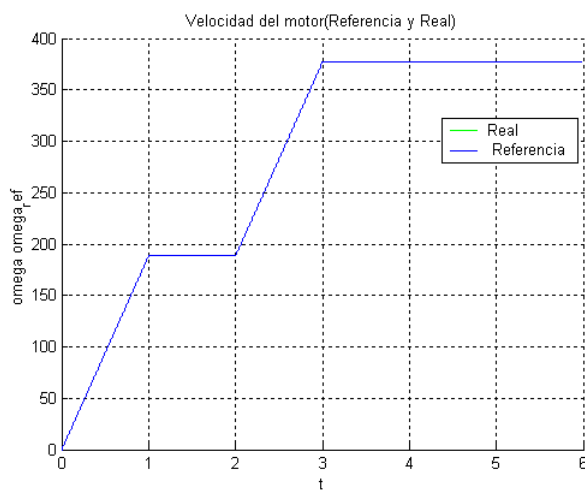


FIG. 11 Velocidad del motor de referencia

La figura 11 muestra la velocidad de referencia y real que fue utilizada para comparar la respuesta de los algoritmos utilizados con red neuronal y Filtro de Kalman.

La figura 12 muestra la velocidad estimada por la red neuronal, donde puede observarse que la respuesta no sigue los cambios de la velocidad.

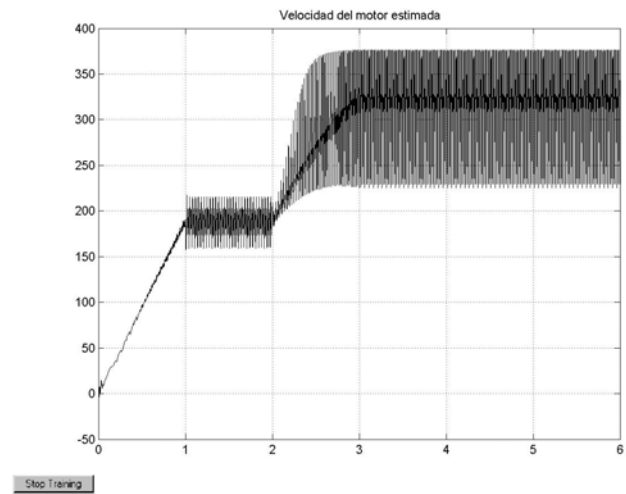


FIG. 12 Velocidad estimada con red neuronal

En la figura 13 se muestra como el Filtro de Kalman puede estimar en forma satisfactoria la velocidad del motor de inducción, para una condición de variación de velocidad más compleja.

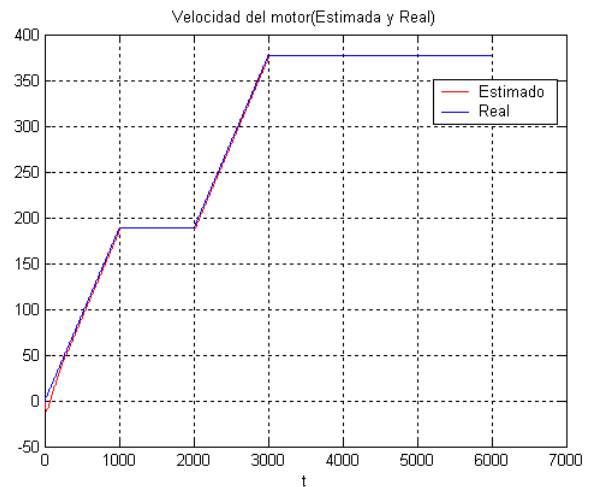


FIG. 13 Velocidad estimada y de referencia utilizando Filtro Extendido de Kalman.

VIII. CONCLUSIONES

En este artículo fue presentado una comparación entre los algoritmos de red neuronal y Filtro de Kalman, donde pudo observarse que el filtro de Kalman presenta una respuesta satisfactoria aún cuando ocurran variaciones de velocidad mientras que la red neuronal no respondió de la misma forma. El Filtro de Kalman en contrapartida presenta un gasto computacional mayor que la red neuronal. Por último la red neuronal necesita de un trabajo adicional, al requerir de entrenamiento en forma “off-line” mientras que el Filtro de Kalman, si se conoce la naturaleza de su ruido [13], puede ser

implementado en forma “on-line”.

REFERENCIAS BIBLIOGRÁFICAS

- [1] Richardson D., and Caisse A., **Máquinas Eléctricas Rotativas y Transformadores**, Cuarta Edición, Prentice Hall, Mexico, 1997.
- [2] João C. P. Palma, **Accionamentos Eletromecânicos de Velocidade Variável**, Fundação Calouste Gulbenkian, Lisboa, 1999.
- [3] Leonhard W., **Control of Electrical Drives**, EESES , Springer-Verlag, 1990.
- [4] Krause PC, Wasynczuk O., **Electromechanical motion devices**, Mc Graw Hill, New York, 1989.
- [5] W. Leonhard, “**Adjustable-speed ac drives**”. Proceedings of the IEEE 76(4), a998 pp 455 – 471.
- [6] B. K. Bose, **Power Electronics and AC Drives**, Prentice Hall, Englewood Cliffs, New – Jersey, 1986..
- [7] J. González, M. Azevedo and E. Pacheco, “**Control vectorial del Motor de Inducción para el Control de Velocidad del Rotor por cambio de Frecuencia**”, II Congreso Venezolano de Ingeniería Eléctrica, Mérida, 2000.
- [8] T. Ohtani, N Takada and K. Tanaka, “**Vector Control of Induction Motors without Rotational Transducers**”. IEE Industry Application Society Meeting, 1989, pp 500 – 507.
- [9] J. González, “**Considerações sobre o Controle dos Motores de Indução Alimentados por Conversores Estáticos**”, Dissertação de Mestrado, PUC-Rio, Agosto 2000.
- [10] C Shauder, “**Adaptative Speed Identification for Vector Control of Induction Motors without Rotational Transducers**”. IEE Industry Application Society Conference, 1989, pp 493 – 499.
- [11] H. Tajima and Y. Hori, “**Speed Sensor-less Fiel-orientation Control of the Induction Machine**”, IEEE Trans. Industry Application, Vol 29 N 1, 1993, pp 175 – 180.
- [12] M. Simoes and B. Bose, “**Neural Network Based Estimation of Feedback Signals for a Vector Controlled Induction Motor**”, Proceedings of IEEE Applied Power Electronics Conference, a994, pp 471 – 479.
- [13] J. A. G. Castellanos, M. da Silveira, “**Controle On-line e sem sensores Eletromecânicos de máquinas de Indução via Filtros Quadráticos**”, Congreso Brasileiro de Automatização (CBA), Brasil, 2004.