

Un novedoso método para estimar la resistencia rotórica del motor de inducción usando máquinas de vectores de soporte

*Sergio Villasana⁽¹⁾, Antonino Caralli⁽¹⁾, Cesar Seijas⁽¹⁾, Carlos Villanueva⁽¹⁾,
Laura Sáenz⁽²⁾, Francisco Arteaga⁽³⁾*

⁽¹⁾ *Unidad de Investigación en Bioelectrónica, Facultad de Ingeniería, Departamento de Electrónica Escuela de Eléctrica, acaralli@uc.edu.ve*

⁽²⁾ *Universidad de Carabobo, Facultad de Ingeniería, Departamento de Materiales y Procesos de Fabricación Centro de Investigaciones de Mecánica, CIMEC*

⁽³⁾ *Centro de Investigación y Tecnología en Automatización, Electrónica y Control, CITAEC
laura1234@cantv.net.ve, svillaza@uc.edu.ve, acaralli@ieee.org, cseijas@uc.edu.ve, cvillanu@uc.edu.ve,
farteaga@uc.edu.ve*

Resumen

La principal debilidad de los accionamientos basados en control vectorial indirecto del motor de inducción de jaula de ardilla (MIJA) es la incertidumbre en el valor de la constante de tiempo rotórica, la cual se usa en el bloque de control para determinar la posición exacta del flujo rotórico y ubicar los ejes d-q sincrónicos correctamente. El principal parámetro que afecta la variación de la constante de tiempo del rotor es la resistencia rotórica cuyo valor depende de la temperatura, saturación del núcleo y efecto piel. Se diseñó un novedoso estimador de resistencia rotórica del MIJA usando máquinas de vectores de soporte (SVM). Se simuló el accionamiento completo, incluyendo el modelo del MIJA con resistencia rotórica variante en el tiempo. El accionamiento con el estimador a lazo cerrado mostró un buen desempeño cuando se sometió a condiciones de operación diferentes a la de entrenamiento y logró una excelente estimación de la resistencia durante el arranque del motor.

Palabras clave: Control vectorial indirecto, accionamiento, máquinas de vectores de soporte, resistencia rotórica.

A novel method to estimate the rotor resistance of the induction motor using support vector machines

Modern indirect vector control based drives of the squirrel cage induction motor (SCIM) have a main weakness in the true value of the rotor time constant always unknown, which is used by the control block to know the exact position of the rotor flux and locate the synchronous d-q axes correctly. The main parameter affecting the rotor time constant variation is the rotor resistance whose value may change because of temperature rise, flux saturation, and skin effect. A novel rotor resistance estimator of the SCIM was designed using support vector machines (SVM). The all drive including a SCIM model with time-varying rotor resistance was simulated. The complete drive with the rotor resistance estimator in closed loop showed a good performance when was working under operation conditions different to training signals and starting-up an excellent estimation of the rotor resistance, even during start up of the machine.

Keywords: Indirect vector control, drive, support vector machines, rotor resistance.

I. INTRODUCCIÓN

En el presente, la principal desventaja de los accionamientos eléctricos basados en control vectorial indirecto es una alta dependencia de los parámetros de la máquina a ser controlada. La resistencia de rotor es el

parámetro con mayor impacto en la dinámica de los accionamientos modernos, es inaccesible en máquina de inducción de jaula de ardilla y, no es posible medir su valor directamente. Es la principal responsable de la variación de la constante de tiempo de rotor [1] afectando la dinámica de control y evitando la correcta predicción

de flujo durante el transitorio, trayendo como consecuencia que no se pueda conocer la posición del flujo de rotor correctamente, el cual es usado para ubicar los ejes d-q rotando sincrónicamente.

Las SVMs son algoritmos de cómputo desarrollados por Vapnik y sus colaboradores [2] que han demostrado un excelente desempeño en aplicaciones de regresión y clasificación [3]-[7]. En contraste a las bien conocidas redes neuronales artificiales (RNA), las SVMs implementan el principio de minimización del riesgo estructural (SRM) que trata de minimizar la cota superior del error de generalización, a diferencia del principio de minimización del riesgo empírico (ERM) que minimiza el error de entrenamiento usado en la RNA. Este principio de inducción se basa en el hecho de que el error de generalización está acotado por la suma del error de entrenamiento y un término de intervalo de confianza que depende de la dimensión de Vapnik-Chervonenkis [2]. El SRM permite a la SVM lograr una estructura de red óptima con un balance perfecto entre el riesgo empírico y el intervalo de confianza VC. Otra característica notable de las SVM es que el entrenamiento es equivalente a resolver un problema de programación cuadrática con restricciones lineales que implica que la solución alcanzada por la SVM es única, óptima y sin mínimos locales, en contraste a las RNA que requiere una optimización no lineal durante su entrenamiento con el riesgo de quedar atrapada por mínimos locales. Las SVM fueron usadas originalmente en problemas de clasificación, pero con la introducción de la función de pérdidas e-insensible [2] que han sido aplicadas en problemas de regresión no lineal [4], [5], [8].

II. FUNDAMENTOS TEÓRICOS

A. Modelo del motor de inducción de jaula de ardilla

Las ecuaciones del motor de inducción de jaula de ardilla en un sistema de referencia arbitrario [9] son:

$$\dot{v}_{ds} = \dot{\psi}_{ds} + R_s i_{ds} - \psi_{qs} \omega_s \quad (1)$$

$$\dot{v}_{qs} = \dot{\psi}_{qs} + R_s i_{qs} + \psi_{ds} \omega_s \quad (2)$$

$$\dot{v}_{dr} = \dot{\psi}_{dr} + R_r i_{dr} - (\omega_s - \omega) \psi_{qr} \quad (3)$$

$$\dot{v}_{qr} = \dot{\psi}_{qr} + R_r i_{qr} + (\omega_s - \omega) \psi_{dr} \quad (4)$$

$$T_e = \frac{3P}{2} (\psi_{qr} i_{dr} - \psi_{dr} i_{qr}) \quad (5)$$

$$\dot{\omega} = \frac{P}{2J} (T_e - T_L) \quad (6)$$

donde ω_s es la velocidad del sistema de referencia arbitrario, ω es la velocidad del rotor, v_{ds} , v_{qs} , son los voltajes de estator, i_{ds} , i_{qs} , i_{dr} , i_{qr} son las corrientes de estator y rotor, R_s , R_r son las resistencias de estator y rotor, ψ_{ds} , ψ_{qs} , ψ_{dr} , ψ_{qr} son los enlaces de flujo de estator y rotor, P es el número de polos, T_e , T_L son los pares electromagnéticos y carga, J es el momento de inercia en Kgm^2 , y el punto ($\dot{\cdot}$) sobre los símbolos representa el operador derivada en el tiempo (d/dt).

Colocando los enlaces de flujo en función de las corrientes, fijando las ecuaciones del motor de inducción en un sistema de referencia estacionario (SRE), $\omega_s = 0$, y cambiando las ecuaciones al sistema por unidad:

$$\frac{d}{dt} \mathbf{i}_{qds} = (\mathbf{L}_s \boldsymbol{\sigma} \mathbf{I})^{-1} (\mathbf{v}_{qds} + \omega (\mathbf{L}_m \mathbf{J} \mathbf{i}_{qdr} + \mathbf{L}_r^{-1} \mathbf{L}_m^2 \mathbf{J} \mathbf{i}_{qds}) + \mathbf{L}_r^{-1} \mathbf{L}_m \mathbf{R}_r \mathbf{i}_{qdr} - \mathbf{R}_s \mathbf{i}_{qds}) \omega_B \quad (7)$$

$$\frac{d}{dt} \mathbf{i}_{qdr} = (\mathbf{L}_r \boldsymbol{\sigma} \mathbf{I})^{-1} (-\mathbf{L}_s^{-1} \mathbf{L}_m \mathbf{v}_{qds} + \omega (\mathbf{L}_r \mathbf{J} \mathbf{i}_{qdr} + \mathbf{L}_m \mathbf{J} \mathbf{i}_{qds}) + \mathbf{L}_s^{-1} \mathbf{L}_m \mathbf{R}_s \mathbf{i}_{qds} - \mathbf{R}_r \mathbf{i}_{qdr}) \omega_B \quad (8)$$

$$T_e = L_m (i_{qs} i_{dr} - i_{ds} i_{qr}) \quad (9)$$

$$\frac{d}{dt} \omega = \frac{(T_e - T_L)}{2H} \quad (10)$$

donde ω_B es la velocidad angular sincrónica base, H es el momento de inercia en segundos, L_s , L_r , son las inductancias totales de estator y rotor, L_m , es la inductancia mutua, \mathbf{I} es la matriz identidad, \mathbf{J} es la matriz de rotación $\begin{bmatrix} 0 & 1 \\ -1 & 0 \end{bmatrix}$, $\sigma = 1 - L_m^2 / (L_s L_r)$ es el coeficiente de fuga total. Los caracteres en negrita representan una forma matricial o vectorial del parámetro correspondiente o variable ya definida, respectivamente.

B. Regresión usando SVM

Una SVM aplicada como regresor o SVR (Regresor a SVM) estima una función no-lineal usando un conjunto de funciones lineales definidas en un espacio hiperdimensional. Es decir, funciones definidas en un espacio hiperdimensional. Esto es, para un conjunto de datos $\mathbf{G} = \{(\mathbf{x}_i, d_i)\}_i^n$ (donde \mathbf{x}_i es el vector de entrada, d_i es la salida esperada y n es la cantidad de patrones de datos), SVR aproxima la función de regresión utilizando:

$$y = f(\mathbf{x}) = \mathbf{w} \phi(\mathbf{x}) + b \quad (11)$$

donde $\phi(\mathbf{x})$ es el espacio de rasgos hiperdimensional proyectado no linealmente sobre el espacio de entrada.

Los coeficientes \mathbf{w} y b se estiman minimizando:

$$R_{SVMs}(C) = C \frac{1}{n} \sum_{i=1}^n L_{\varepsilon}(d_i, y_i) + \frac{1}{2} \|\mathbf{w}\|^2 \quad (12)$$

donde

$$L_{\varepsilon}(d, y) = \begin{cases} |d - y| - \varepsilon & |d - y| \geq \varepsilon \\ 0 & |d - y| < \varepsilon \end{cases} \quad (13)$$

En la función de riesgo dada por (12), el término $C(1/n) \sum_{i=1}^n L_{\varepsilon}(d_i, y_i)$ es el error empírico (riesgo) mientras el término $(1/2) \|\mathbf{w}\|^2$ es el término de regularización. El parámetro C se conoce como constante regularizada o capacidad de la SVM y determina el compromiso entre el riesgo empírico y el término de regularización. En (13), ε se conoce como tamaño del cilindro hiperdimensional que encierra la función y es equivalente a la exactitud de aproximación sobre los puntos de datos de entrenamiento. C y ε son parámetros a establecer por el diseñador, en un proceso de sintonía durante la etapa de entrenamiento de la SVM.

Para obtener los estimados de \mathbf{w} y b , (13) se transforma en (14), usando variables de flexibilización ξ_i y $\xi_i^{(*)}$ que representan límites superior e inferior en la salida del sistema como se muestra en la Figura 1, esto es, minimizando

$$R_{SVMs}(\mathbf{w}, \xi_i, \xi_i^{(*)}) = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^{(*)}) \quad (14)$$

Sujeto a las restricciones:

$$\begin{aligned} d_i - \mathbf{w}\phi(\mathbf{x}) - b_i &\leq \varepsilon + \xi_i \\ \mathbf{w}\phi(\mathbf{x}) + b_i - d_i &\leq \varepsilon + \xi_i^{(*)}, \quad \xi_i^{(*)} \geq 0 \end{aligned} \quad (15)$$

finalmente introduciendo los multiplicadores de Lagrange a_i y a_i^* [2], la función de regresión dada por (11) queda como:

$$f(\mathbf{x}, a_i, a_i^*) = \sum_{i=1}^n (a_i - a_i^*) K(\mathbf{x}, \mathbf{x}_i) + b \quad (16)$$




Figura 1. Error Pre-establecido ε y límites ξ en la función ε -insensible

donde $K(\mathbf{x}_i, \mathbf{x}_j)$ es denominada función “kernel” y a_i y a_i^* son los multiplicadores de Lagrange que satisfacen las restricciones:

$a_i * a_i^* = 0$, $a_i \geq 0$ y $a_i^* \geq 0$, ($i = 1, \dots, n$), y los cuales se calculan maximizando la función dual de (12) que tiene la forma:

$$R(a_i, a_i^*) = \sum_{i=1}^n d_i (a_i - a_i^*) - \varepsilon \sum_{i=1}^n (a_i + a_i^*) - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (a_i - a_i^*) (a_j - a_j^*) K(\mathbf{x}_i, \mathbf{x}_j) \quad (17)$$

Sujeta a:

$$\sum_{i=1}^n (a_i - a_i^*) = 0, \quad 0 \leq a_i \leq C, \quad 0 \leq a_i^* \leq C, \quad i = 1, \dots, n$$

basado en las condiciones de programación cuadrática de Karush-Kuhn-Tucker (KKT) [2], de esos multiplicadores de Lagrange solamente un cierto número tendrán valor no cero y los puntos o vectores asociados tendrán valor mayor que ε , a estos datos o vectores se les denomina vectores de soporte de la SVM. Es evidente de (16) que esos vectores de soporte definen a $f(\mathbf{x})$.

La función “kernel” es igual al producto interno de dos vectores \mathbf{x}_i y \mathbf{x}_j en el espacio de rasgos $\phi(\mathbf{x}_i)$ y $\phi(\mathbf{x}_j)$, es decir: $K(\mathbf{x}_i, \mathbf{x}_j) = \phi(\mathbf{x}_i) * \phi(\mathbf{x}_j)$. La ventaja de usar la función “kernel”, es que el cálculo se realiza en un espacio de rasgos arbitrario sin explícitamente usar $\phi(\mathbf{x})$. Cualquier función que satisfaga las condiciones de Mercer [2] es candidata a ser una función “kernel”, entre las cuales se puede mencionar, funciones polinomiales de la forma $K(\mathbf{x}, \mathbf{y}) = (\mathbf{x} * \mathbf{y} + 1)^d$, donde d es el grado del polinomio, gaussianas $K(\mathbf{x}, \mathbf{y}) = \exp(-1/\sigma^2 (\mathbf{x} - \mathbf{y})^2)$, donde σ es el coeficiente de dispersión de la gaussiana, también conocida como función de base radial (RBF). Desde el punto de vista de su implementación, el entrenamiento de la SVM es equivalente a resolver un cuadrático problema restringido linealmente, es decir, resolver un problema de optimización convexo.

C. Sistema adaptativo con modelo referencia

Los sistemas con modelos de referencia se basan sobre dos modelos (estimadores) con estructuras diferentes de la misma máquina, que estiman la misma variable de estado (en este caso el flujo de rotor) con un conjunto diferente de variables de entrada [10]. Los modelos se llaman modelo de referencia, el cual no incluye la variable a ser estimada, y el modelo adaptativo el cual incluye la variable a ser estimada, y ambos modelos se representan en el sistema de referencia estacionario [11]. Las salidas de los estimadores se comparan y el error es usado como mecanismo de adaptación [12].

La derivada del flujo de rotor para el modelo de referencia es [13]:

$$\frac{d}{dt} \Psi_{qdr} = \frac{L_r}{L_m} \left(v_{qds} - R_s i_{qds} - \sigma L_s \frac{d}{dt} i_{qds} \right) \quad (18)$$

El modelo de referencia es el modelo de voltaje, el cual estima el flujo de rotor a partir de las ecuaciones de estator, las entradas son las tensiones y corrientes de estator. Integrando (18),

$$\Psi_{qdr}^v = \frac{L_r}{L_m} \left(\int (v_{qds} - R_s i_{qds}) - \sigma L_s i_{qds} \right) \quad (19)$$

El modelo adaptativo es el modelo de corriente y se obtiene integrando (20), de las ecuaciones de rotor en el sistema de referencia estacionario. En este modelo las entradas son las corrientes de estator:

$$\tau_r \dot{\Psi}_{qdr}^i + \Psi_{qdr}^i = \tau_r \omega J \Psi_{qdr}^i + L_m i_{qds} \quad (20)$$

donde los superíndices “v” e “i” representan los modelos de voltaje y corriente respectivamente.

El mecanismo de adaptación consiste en la generación de una señal de error como diferencia entre los flujos de rotor de los modelos [14], [15] o como el producto vectorial de los flujos estimados por dichos modelos [11], el error de entrada entra en un controlador proporcional-integral cuya salida es la resistencia de rotor estimada.

$$e_{fr,pv} = |\Psi_{qdr}^v \times \Psi_{qdr}^i| = |\Psi_{qdr}^v| |\Psi_{qdr}^i| \sin(\alpha) \quad (21)$$

La ecuación (21) muestra como se calcula la señal de error, la cual es proporcional al seno del ángulo α entre los vectores de flujo de rotor estimados. A medida que los vectores de flujo estimados por cada modelo se

van igualando el ángulo se aproximará a cero y el error tenderá a cero.

$$e_{fr,dif} = \Psi_{qdr}^v - \Psi_{qdr}^i \quad (22)$$

La ecuación (22) es el error de flujo convencional calculado como la diferencia de los flujos estimados.

III. PARTE EXPERIMENTAL

A. Diseño del Estimador Usando SVM

El novedoso método en la estimación de la resistencia rotórica consiste en usar un bloque MRAS cuyo mecanismo de adaptación se controla usando una SVM. La SVM es responsable de estimar la resistencia rotórica y realimentar esta estimación al bloque MRAS.

El mecanismo de adaptación basado en SVM del bloque MRAS para estimar la resistencia rotórica, R_r , se diseñó y construyó usando el toolbox SVM desarrollado por S. Gunn en el software matemático MATLAB, disponible para uso académico [5]. La SVR tiene dos (2) entradas una de las cuales es el error de flujo del rotor como una diferencia ($e_{fr,dif}$) y la otra es error de flujo del rotor como magnitud del producto vectorial ($e_{fr,pv}$); tiene una única salida que corresponde a la resistencia rotórica como se indicada en la Figura 2. Los datos de salida de la simulación del control vectorial indirecto se usó como conjunto de entrenamiento de la SVR diseñada, Figura 3, es decir, el entrenamiento no se realizó en línea.

Las condiciones para la simulación indicada fueron par de carga constante en 0.2 por unidad (pu) y velocidad del rotor de 0.973 pu. La Figura 4 muestra el patrón de variación de la resistencia rotórica, y la Figura 5 muestra el flujo del rotor como diferencia (línea punteada) y como producto vectorial (línea continua), de las señales constituidas por 6001 puntos cada una se tomaron muestras equiespaciadas cada 12 puntos conformando una matriz de entrenamiento de 401x2 datos, para obtener la función de regresión objetivo $y = f(x_1, x_2)$. La matriz validación fue construida con los valores originales de la matriz de 6001x2.



Figura 2. SVR para estimación de R_r




Figura 6. Sistema adaptivo con modelo de referencia basado en SVM.

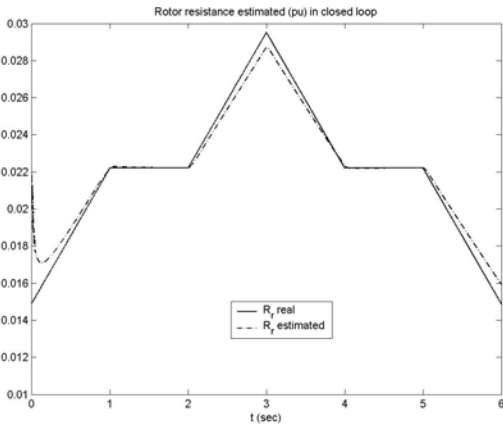


Figura 7. Resistencia rotórica estimada a lazo cerrado.

IV. RESULTADOS DE LA SIMULACIÓN

Para demostrar la capacidad de generalización del estimador se realizaron varios ensayos con diferentes formas variantes en el tiempo de la resistencia de rotor, como se observa en la Figura 8, donde se puede ver el gran desempeño en la estimación lograda por el estimador basado en SVM. La Figura 8 revela que el estimador responde casi instantáneamente durante cambios abruptos de la resistencia.

La Figura 9 muestra el par de errores de flujo como diferencia (punteada) y como producto vectorial (continua) correspondiente a cada patrón de variación de la resistencia de rotor en la Figura 8.

Se observa de las Figuras 5 y 9 que el estimador basado en SVM puede aproximar estrechamente la resistencia de rotor independientemente de la forma del flujo de rotor.

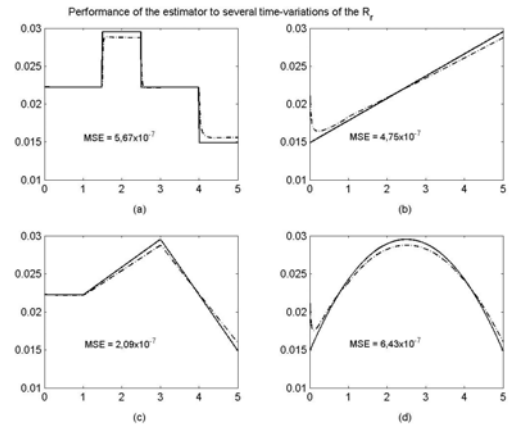


Figura 8. Estimación a lazo cerrado con diferentes variaciones temporales de la resistencia de rotor.

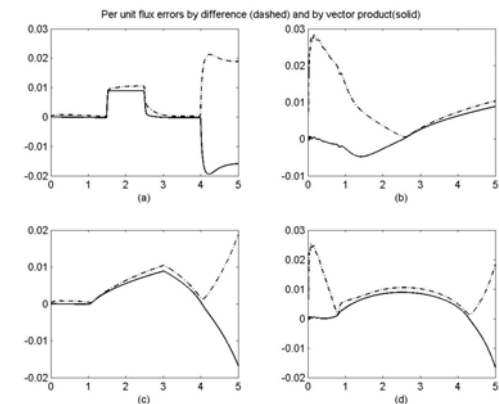


Figura 9. Registro de errores de flujo de acuerdo al patrón variación temporal de la resistencia de rotor, R_r .

La Figura 10 muestra el desempeño del estimador cuando se cambia el par de carga a valores diferentes a su valor (0,2 pu) durante la etapa de entrenamiento.

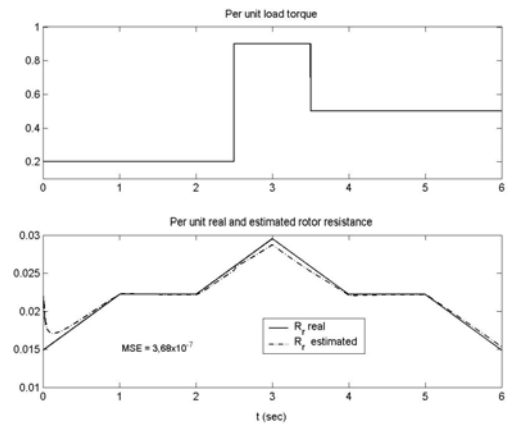


Figura 10. Estimación de la resistencia de rotor con par de carga variable.

La Figura 11 muestra el desempeño del accionamiento con cambios lineales de la velocidad y dos condiciones de par de carga. Las líneas punteadas y continuas representan las respuestas a un 100% y un 20% de par de carga respectivamente. Se puede ver como la velocidad del rotor sigue la referencia de velocidad, sin embargo, se observa una pequeña distorsión de la curva de velocidad, a un 100% de par de carga, debido a la saturación de los controladores PI de corriente, ver Figura 12.

La Figura 12 muestra que la estimación de la resistencia de rotor no depende de la carga y que la saturación de los controladores PI no afecta a dicho proceso de estimación.

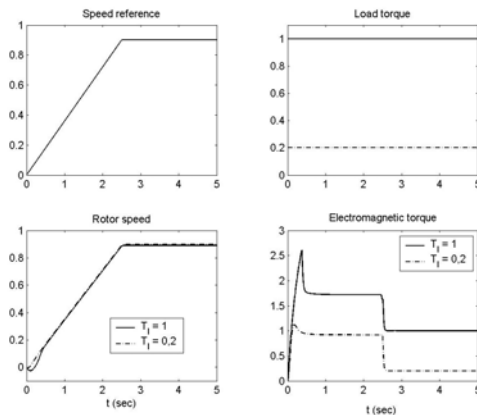


Figura 11. Desempeño el accionamiento con cambio lineal de la referencia de velocidad y dos condiciones de par de carga, 100%, (continua), 20% (punteada).

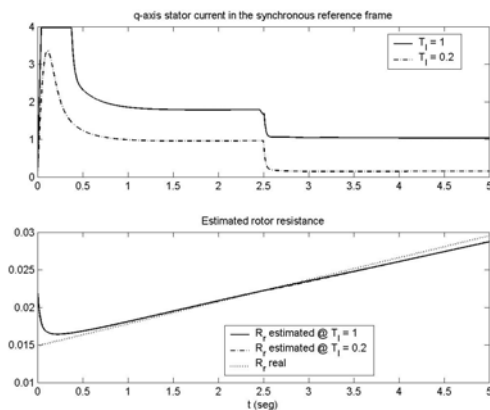


Figura 12. Estimación de la resistencia de rotor con cambio lineal de la referencia de velocidad y dos condiciones de par de carga, 100%, (continua), 20% (punteada).

V. CONCLUSIONES

Esta investigación demostró que el estimador de resistencia rotórica basado en SVM puede estimar el comportamiento temporal (independiente de su forma) de la resistencia rotórica de un MI aun en condiciones de operación diferentes de las usadas en la fase de entrenamiento, lo cual nos lleva a la conclusión del excelente grado de generalización lograda pro el estimador en desarrollo. El accionamiento con el estimador de resistencia rotórica mostró un correcto desempeño cuando fue obligado a operar en esas condiciones.

La SVM demostró, después de varios ensayos, su alta capacidad en la estimación de la resistencia rotórica con baja cantidad de datos (pocos vectores de soporte) comparado con el numero de muestras originales usados durante la etapa de entrenamiento.

Un punto resaltante a ser observado es que durante el proceso de estimación de la resistencia rotórica no se hizo ninguna suposición acerca de operación en régimen permanente [16] o cuasi-permanente [15], lo que permitió funcionar adecuadamente aún en la etapa del transitorio de arranque de la maquina.

Los resultados demostraron que independientemente de la forma del comportamiento de los errores de flujo y/o el nivel de carga, el estimador a SVM fue capaz de estimar la resistencia rotórica.

La implementación del algoritmo de la SVM es mas simple que el de una RNA en aplicaciones de estimación de funciones no lineal, ya que la primera tiene una sola capa en su arquitectura mientras que la RNA requiere capas intermedias y por tanto el volumen de cálculo es menor en SVM que en RNA.

VII. REFERENCIAS

- [1] D. W. Novotny and T. A. Lipo, "Principles of Vector Control and Field Orientation," in Introduction to Field Orientation and High Performance AC Drives, 1985 IEEE Industry Applications Society Annual Meeting, pp. 2-1 to 2-65.
- [2] V. N. Vapnik,. The Nature of Statistical Learning Theory, New York: Springer-Verlag, 1995.
- [3] A. D. Back (1998, Aug.). Classification using Support Vector Machines. RIKEN Brain Science Institute, Wako-shi, Saitama, Japan [Online]. Available: <http://andrewback.com/webpapers/svm/index.php>

- [4] T. Frontzek, T. Navin and R. Eckmiller (2001, Aug.). Predicting the Nonlinear Dynamics of Biological Neurons using Support Vector Machines with Different Kernels. Department of Computer Science VI, University of Bonn, F. R. Germany [Online]. Available: <http://www.kyb.mpg.de/publications/pdfs/pdf1939.pdf>
- [5] S. A. Villazana, C. O. Seijas, A. Caralli, C. Villanueva, and F. Arteaga, "Rotor Resistance Estimator Using Support Vector Machines and Model Reference Adaptive System," in *Proceedings of the 2006 IEEE International Symposium on Industrial Electronics*, pp. 2417-2421.
- [6] S. Gunn. (1997, November 10). Support Vector Machines for Classification and Regression. Speech and Intelligent Systems Research Group, University of Southampton, U.S.A. [Online]. Available: <http://www.isis.ecs.soton.ac.uk/research/svm/svm.html>
- [7] I. Guyon, J. Weston, S. Barnhill, and V. Vapnik (2002, Aug.). Gene selection for cancer classification using support vector machines. *Machine Learning* [Online]. Available: http://www.tsi.enst.fr/~campedel/Biblio/FeatureSelection/Guyon_GeneSelection_2000.pdf
- [8] S. Mukherjee, E. Osuna, and F. Girosi, "Nonlinear Prediction of Chaotic Time Series using a Support Vector Machines," in *Neural Networks for Signal Processing VII-Proceedings of the 1997 IEEE Workshop*, pages 511-520.
- [9] P. C. Krause, O. Wasynczuk, S. D. Sudhoff, *Analisis of Electric Machinery*, New York : IEEE Press, 1995.
- [10] J. Holtz, "Methods for speed sensorless control of AC drives," in *Sensorless Control of AC Motors*, K. Rajashekara, Ed. Piscataway, NJ: IEEE Press, 1996.
- [11] V. Vasić, S. Vukosavić, "Robust MRAS-Based Algorithm for Stator Resistance and Rotor Speed Identification," in *IEEE Power Engineering Review*, pp. 39-41. November, 2001.
- [12] Vas P., Tiitinen P., "Sensorless Vector and Direct-Torque-Controlled Drives," in *Power Electronics Handbook*, M. Rashid, Ed. San Diego: Academic Press, 2001 pp. 735-767.
- [13] P. Vas, *Sensorless Vector and Direct Torque Control*, New York: Oxford University Press, 1998.
- [14] C. Schauder, "Adaptive Speed Identification for Vector Control of Induction Motors without Rotational Transducers", *IEEE Transactions On Industry Applications*, vol. 28, pp 1054-1061, Sept/Oct. 1992.
- [15] P. Vas. "Artificial-Intelligence-Based Drives Electrical Machines and Drives", New York: Oxford University Press, 1999.
- [16] A. Pavlov and A. Zarembo, "Real-Time Rotor and Stator Resistances Estimation of an Induction Motor" in *Proc. 5th IFAC Symposium on Nonlinear Control Systems*, St. Petersburg, July 2001.
- [17] A. Cepeda y J. Chassande, "Simulación del Control por Orientación de Campo del Par de la Máquina de Inducción con Adaptación de la Resistencia Rotórica," *Revista de la Facultad de Ingeniería de la U.C.V.*, vol. 15, No 1, pp. 57-68, 2000.