

ESQUEMA DE DETECCIÓN DE FALLOS DIFUSO BASADO EN MODELADO LINGÜÍSTICO-PRECISO DE UN MOTOR DE INDUCCIÓN

M. J. Fuente * E. Moya ** G. I. Sainz Palmero **

* *Departamento de Ingeniería de Sistemas y Automática.
Facultad de Ciencias, Universidad de Valladolid. Prado de la
Magdalena s/n,*

47011 Valladolid, España. E-mail: maria@autom.uva.es

** *Departamento de Ingeniería de Sistemas y Automática. ETSII.*

*Universidad de Valladolid. Paseo del Cauce s/n,
47011 Valladolid, Spain. E-mail: edumoy@eis.uva.es,
gresai@eis.uva.es*

Resumen: Este artículo presenta un banco de modelos difusos para la detección e identificación de fallos usando el método de modelos múltiples, calculando un modelo difuso no lineal para cada modo de operación del sistema. Una comparación entre la salida de cada uno de estos modelos y las salidas de la planta determina el estado del sistema en cada momento: operación normal o cualquiera de los modos de fallo. Cada uno de los modelos difusos considerados se define mediante un conjunto de reglas difusas que "explican" el comportamiento del sistema.

Estos modelos difusos obtenidos mediante las técnicas habituales son mejorables, a través de las reglas difusas que los definen, tanto cuantitativa como cualitativamente y así aprovechar mejor todo el potencial de la lógica difusa y su capacidad "lingüística". A través de medidas de similitud se simplifican y mejoran los modelos, reduciendo el número total de reglas, eliminando incoherencias, redundancias y mejorando su interpretabilidad. Este método se ha aplicado a un motor de corriente alterna, para ilustrar el comportamiento y la aplicabilidad del mismo. Los resultados muestran que el método de modelos múltiples tiene un comportamiento aceptable para detectar fallos incluso después de simplificar los modelos. *Copyright ©2007 CEA-IFAC*

Palabras clave: Sistemas difusos, medidas de similitud difusas, detección y aislamiento de fallos, método de modelos múltiples, motores de inducción.

1. INTRODUCCIÓN

Los motores de inducción son componentes críticos en muchos procesos industriales. Estos motores están expuestos a una gran variedad de entornos y condiciones de funcionamiento a menudo cambiantes, y a pesar de su robustez en algunas ocasiones fallan, pudiendo ser el coste de esta parada no planificada muy alto. Debido a este tipo de problemas, la monitorización de estas

máquinas eléctricas es de gran interés, existiendo diversidad de metodologías en función del tipo de problemas que se deseen afrontar, mecánicos y/o eléctricos, en los motores de inducción (Benbouzid, 2000).

Actualmente entre las distintas técnicas están en auge aquellas basadas en Inteligencia Artificial (IA) y Soft-computing (Filippetti *et al.*, 2000). Los sistemas de monitorización basados en estas aproximaciones utilizan diferentes señales: corrientes y voltajes del es-

tátor, campos magnéticos, vibraciones, etc., prefiriéndose en general señales como corrientes y voltajes del estátor para permitir la realización de métodos de detección de fallos no invasivos, además de esta manera se pueden utilizar sensores de uso habitual en la industria.

De todos los métodos descritos en la bibliografía (Chen and Patton, 1999) en este artículo se va a emplear la metodología basada en modelos múltiples. Esta aproximación utiliza un conjunto de modelos (en este caso no lineales), para describir los diferentes modos de operación del sistema (funcionamiento normal y con fallos), y por tanto para detectar y diagnosticar fallos, es decir, se plantea un problema de hipótesis múltiples, donde un estudio de las salidas de cada modelo indica cuál es el modelo más adecuado en cada situación.

Los métodos más convencionales para modelar un sistema están basados en ecuaciones matemáticas, por ejemplo ecuaciones diferenciales, que no son adecuadas cuando los sistemas tienen incertidumbre o son complejos o no se dispone de este conocimiento acerca del comportamiento del sistema a modelar. La razón básica de esto es la dificultad, en muchos casos, de encontrar una función o estructura analítica global para los sistemas no lineales. En contraste, otras aproximaciones basadas en softcomputing han permitido abordar estos casos consiguiendo buenos resultados (Bonissoene *et al.*, 1999). De entre estas técnicas destaca la lógica difusa que suministra un marco de representación del conocimiento y su inferencia, tratando de asemejarse a la manera en que los humanos expresan e infieren ese conocimiento (Zadeh, 1965; Zadeh, 1988), siendo capaz de trabajar con la imprecisión y la vaguedad de los conceptos empleados habitualmente en los términos lingüísticos.

Basado en esta aproximación de lógica difusa, el modelado difuso es una de las técnicas más utilizadas para modelar sistemas no lineales, complejos y con incertidumbre, donde el conocimiento a priori es escaso o nulo, o donde es habitual disponer sólo de datos acerca del sistema, o incluso hay que proceder a la extracción del conocimiento de alguna fuente experimental.

Tradicionalmente, un modelo difuso se construye usando conocimiento acerca del sistema a modelar en forma de reglas difusas, en principio reglas difusas lingüísticas capaces de aprovechar este aspecto de la lógica difusa. Pero estos modelos difusos han sido también obtenidos a partir de datos experimentales, es decir, mediante algún algoritmo de sintonización se genera el conjunto de reglas difusas representando la conducta del sistema modelado. En este caso el resultado suele enfatizar la exactitud global del modelo resultante, sin tener en cuenta, y por tanto perdiendo, ciertos aspectos cuantitativos y cualitativos de la lógica difusa, como por ejemplo la interpretabili-

dad, compactitud, etc., siendo utilizados estos modelos realmente como técnicas de caja negra o gris.

De esta manera existen dos aproximaciones al modelado difuso, en función del criterio o criterios que rijan dicho proceso de modelado:

- Modelado difuso lingüístico, aquí el conjunto de reglas difusas que representa el conocimiento sobre el sistema presenta un elevado grado de interpretabilidad de dicho conocimiento para un experto, a costa, normalmente, de obtener un modelo con muy poca exactitud entre el modelo obtenido y el sistema real.
- Modelado difuso (preciso), este tipo de modelado presenta una gran exactitud, pero la base de reglas difusas generada, por tanto el modelo, sacrifica los aspectos básicos de la aproximación difusa sobre la interpretabilidad de ese conocimiento y su expresión en términos lingüísticos, entre otros aspectos.

Por tanto estas dos aproximaciones del modelado difuso presentan lagunas, un "buen" modelo será aquel que presente una buena exactitud y un adecuado nivel de interpretabilidad y comprensibilidad del conocimiento extraído sobre la conducta del sistema modelado, por tanto, es conveniente obtener una solución de compromiso. Debido a esto, en los últimos años se han propuesto diversas metodologías y aproximaciones para obtener este grado de compromiso en el modelado difuso: métodos para obtener modelos difusos suficientemente exactos y adecuadamente interpretables al mismo tiempo, (Chao *et al.*, 1996; Setnes *et al.*, 1998; Jin, 2000; Casillas *et al.*, 2003a; Casillas *et al.*, 2003b).

Este artículo describe un método de detección e identificación de fallos, usando un banco de modelos difusos para implantar un método de modelos múltiples. Este método se ha aplicado a un motor de inducción real con resultados razonables. Estos modelos difusos se han calculado usando el algoritmo de clustering substractivo (Chiu, 1994), usando sólo medidas (datos de entrada/salida) del sistema. En este caso, la simplicidad e interpretabilidad del conocimiento adquirido por los modelos difusos no es obvio, ya que se obtienen conjuntos difusos excesivamente solapados que describen prácticamente la misma región en el dominio de algunas de las variables consideradas, además un número elevado de las reglas obtenidas son redundantes. Para reducir esta complejidad y mejorar la interpretabilidad del sistema se emplea una medida de similitud para:

- (1) Identificar conjuntos difusos similares y poder reemplazarlos por otros conjuntos más representativos, (Chao *et al.*, 1996; Setnes *et al.*, 1998).
- (2) Reducir el número de reglas que forman el modelo.

Así los modelos difusos empleados para el algoritmo de detección de fallos han sido simplificados, mejo-

rando la interpretabilidad de sus reglas difusas y por tanto haciendo más factible la comprensión de su funcionamiento. Estos nuevos modelos siguen siendo capaces de detectar los fallos considerados y al mismo tiempo el conjunto de reglas obtenido permite asignar términos cualitativos con significado lingüístico a los conjuntos difusos y, por tanto, el conocimiento final adquirido puede ser interpretado más fácilmente.

El artículo está organizado de la siguiente forma. La sección 2 revisa el método de modelos múltiples para la detección de fallos y las técnicas de modelado difuso. En la sección 3 se discute el significado del concepto de medida de similitud. En la Sección 4, se describe la aplicación del método presentado a una planta real, un motor de inducción. Primero se muestra el sistema y después se presentan los resultados obtenidos con el método de modelos múltiples para detectar e identificar distintos fallos en el motor en ambos casos, cuando se usan los modelos originales o los modelos simplificados. Finalmente, se dan las conclusiones en la última sección.

2. ESQUEMA DE DETECCIÓN E IDENTIFICACIÓN DE FALLOS

La detección y diagnóstico de fallos (FDD) basada en modelos, también llamada redundancia analítica, consiste en la detección, aislamiento y caracterización de los fallos en los componentes de un sistema o en el propio sistema, basados en un modelo del proceso, (Chen and Patton, 1999; Frank, 1990; Isermann and Balle, 1997). En este artículo se usa un banco de modelos no-lineales basados en diferentes hipótesis de comportamiento del proceso (operación normal y múltiples fallos) para detectar e identificar los fallos de una planta. Los residuos calculados como la diferencia entre la medida de la planta real y la salida de cada uno de los modelos, r_i , se monitorizan y se calcula un índice basado en dichos residuos para indicar que modelo es el más adecuado en cada situación. Es decir, los residuos, y por tanto el índice definido, dan una medida de la eficacia de cada modelo en el seguimiento y predicción del comportamiento de los datos observados de la planta. El índice de comportamiento empleado, (J_i), basado en el control óptimo cuadrático es el siguiente:

$$J_i(t) = \alpha r_i^2(t) + \beta \int_0^t r_i^2(\tau) d\tau \quad (1)$$

donde α y β son parámetros de diseño. Este criterio incorpora medidas de exactitud instantáneas y a largo plazo. El modelo con el índice más bajo se declara como el correcto, es decir, si el modelo i -ésimo es correcto, el residuo r_i es prácticamente cero conteniendo sólo la incertidumbre intrínseca de dicho modelo, y por tanto J_i es también prácticamente nulo. Sin embargo si el modelo i -ésimo no es correcto, r_i no es cero debido a que incluye errores debido a que la

predicción se realiza utilizando un modelo erróneo, y como consecuencia el índice de comportamiento, J_i crece.

2.1 Modelado difuso

Los modelos no-lineales utilizados en este trabajo son sistemas de inferencia difusa del tipo Takagi-Sugeno (TS). Este modelo difuso usa reglas con predicados difusos que establece relaciones entre las variables relevantes del sistema. Los predicados difusos se asocian con términos lingüísticos, y el modelo es de hecho una descripción cualitativa del sistema, usando reglas del tipo:

$$R_i: w_i (IF x_1 \text{ is } A_{i1} \text{ and } x_2 \text{ is } A_{i2} \text{ and } \dots \text{ and } x_n \text{ is } A_{in} THEN y_i = f_i(\cdot)) \quad (2)$$

donde R_i es la regla i -ésima en la base de reglas, x_1, \dots, x_n son las variables de la premisa, es decir, variables de entrada al modelo, y_i es la salida de la regla, A_{i1}, \dots, A_{in} son los conjuntos difusos definidos para cada variable de las premisas y w_i es el peso de la regla. Típicamente, $w_i = 1$ para todas las reglas, es decir, todas tienen la misma importancia, pero este parámetro puede ser ajustado. Normalmente, $f_i(\cdot)$ es una función lineal en las variables de la premisa, es decir:

$$y_i = p_{i0} + p_{i1}x_1 + p_{i2}x_2 + \dots + p_{in}x_n \quad (3)$$

La salida total del modelo se calcula haciendo una media ponderada de los consecuentes de las reglas:

$$\hat{y} = \frac{\sum_{i=1}^N w_i \beta_i y_i}{\sum_{i=1}^N w_i \beta_i} \quad (4)$$

donde N es el número de reglas, β_i es el grado de activación de la premisa de la regla i -ésima e y_i es la contribución de dicha regla. El grado de activación se calcula de la siguiente manera:

$$\beta_i = \prod_{j=1}^n \mu_{ij}(x_j), \quad i = 1, 2, \dots, N \quad (5)$$

donde $\mu_{ij}(x_j)$ es la función de pertenencia del conjunto difuso A_{ij} para la variable de entrada x_j en la premisa de la regla i -ésima. Para obtener el modelo difuso del sistema utilizando sólo medidas de entrada/salida de la planta se usa el método de clustering subtractivo (Chiu, 1994), que hace una partición de los datos en un número determinado de clusters o agrupaciones. Este algoritmo se basa en la densidad de datos incluidos en cada uno de estos clusters para llevar a cabo este proceso. De esta manera obtenemos el número de reglas del modelo TS así como las premisas de cada una de ellas.

Las premisas de cada regla expresada mediante los conjuntos difusos de las distintas variables de entrada

consideradas, se obtienen proyectando estos clusters en los correspondientes ejes del espacio de variables o características.

El consecuente de cada regla del modelo TS se obtiene empleando la red neuro-difusa ANFIS, (Jang, 1993), donde la parte de la premisa se ajusta, de forma inapreciable, usando el método de optimización de retro-propagación del error y la parte de los consecuentes se calcula usando el algoritmo de mínimos cuadrados debido a su estructura lineal. Dada la tarea a realizar, ajuste de los parámetros de los consecuentes, la red ANFIS puede ser sustituida por cualquier método de optimización.

3. SIMILITUD

Los modelos difusos obtenidos a partir de datos experimentales tienen varios problemas, uno de ellos es la explosión en el número de reglas y conjuntos difusos generados, muchos de los cuales pueden ser muy parecidos, lo que origina reglas redundantes y/o inconsistentes. Debido a estos problemas la explicación e interpretabilidad del conocimiento aprendido es muy difícil.

Para reducir la complejidad de los modelos difusos obtenidos se va a realizar una simplificación basada en medidas de similitud. La similitud se define como el grado en el cual dos conjuntos difusos son similares. Es decir, dos conjuntos difusos se consideran similares si están definidos por funciones de pertenencia muy solapadas y asignan aproximadamente el mismo grado de pertenencia a los elementos en su universo de discurso.

Hay muchas formas de definir una medida de similitud (Setnes *et al.*, 1998), pero en este artículo se usa una medida de similitud basada en las operaciones teóricas de unión e intersección de conjuntos difusos:

$$\text{Similitud}(A \approx B) = S(A, B) = \frac{M(A \vee B)}{M(A \wedge B)} \quad (6)$$

donde M es el tamaño del conjunto difuso, y los operadores \cup e \cap representan la unión e intersección de conjuntos difusos respectivamente. Esta expresión puede reescribirse en términos de las funciones de pertenencia como:

$$S(A, B) = \frac{\sum_{j=1}^m [\mu_A(x_j) \wedge \mu_B(x_j)]}{\sum_{j=1}^m [\mu_A(x_j) \vee \mu_B(x_j)]} \quad (7)$$

en el universo discreto $X = \{x_j \mid j = 1, 2, \dots, m\}$. \wedge y \vee son los operadores máximo y mínimo respectivamente, es decir, una de las formas más usuales de implementar la unión e intersección de conjuntos difusos. Esta medida de similitud refleja la idea de una transición gradual desde conjuntos difusos totalmente iguales a conjuntos difusos completamente distintos, es decir, $0 \leq S(A, B) \leq 1$.

Esta medida de similitud, eq.(6), va a usarse para calcular la similitud entre conjuntos difusos en la base o conjunto de reglas. Dos o más conjuntos similares pueden eliminarse y sustituirse por un conjunto difuso nuevo que sea una representación de todos los conjuntos difusos similares. Dos conjuntos van a ser similares si su medida de similitud es mayor que un cierto umbral, γ , con $0 \leq \gamma \leq 1$. Una forma de calcular el nuevo conjunto difuso mezcla de dos conjuntos similares es tomar el soporte de $A \cup B$ como el soporte del nuevo conjunto difuso C . El núcleo (o kernel) de C se obtiene sumando los parámetros que describen los núcleos de A y B , los cuales están descritos por:

$$\mu_A(x, m_A, \sigma_A) = \exp\left[-\frac{(x - m_A)^2}{\sigma_A^2}\right] \quad (8)$$

es decir, se usan funciones gaussianas como funciones de pertenencia de los conjuntos difusos. Combinando A y B se obtiene C definido por $\mu_C(x, m_C, \sigma_C)$, donde:

$$\begin{aligned} m_C &= \lambda_1 * m_A + (1 - \lambda_1) * m_B \\ \sigma_C &= \lambda_2 * \sigma_A + (1 - \lambda_2) * \sigma_B \end{aligned} \quad (9)$$

Los parámetros $\lambda_1, \lambda_2 \in [0, 1]$ determinan cual de los conjuntos difusos A o B tiene más influencia en el núcleo de C , en este artículo $\lambda_1 = \lambda_2 = 0.5$. Sustituyendo este nuevo conjunto difuso por los conjuntos similares en la base de reglas, los conjuntos difusos necesarios para construir el modelo disminuyen.

En los modelos difusos el grado de similitud de las premisas de las reglas lleva a tener reglas redundantes y/o incoherentes en función del grado de similitud de los consecuentes. Basándose en la medida de similitud descrita anteriormente, eq.(6), se mide el grado de redundancia entre reglas para eliminar las reglas difusas que presentan un alto grado de redundancia, es decir, aquellas con un alto grado de similitud en el antecedente y el consecuente. Reajustándose los parámetros de los consecuentes del modelo TS como se describe en el párrafo siguiente.

Las reglas incoherentes aparecen cuando sólo la parte de las premisas de las reglas es similar, pero no los consecuentes, lo que puede generar en una contradicción en la base de reglas, sobre todo cuando se desea una interpretación y comprensión de esas reglas. Para resolver este nuevo problema y mantener un adecuado grado de precisión en los modelos de TS, una de las reglas es eliminada y los parámetros consecuentes del conjunto de reglas reducido se calculan de nuevo, usando el algoritmo de mínimos cuadrados, con datos experimentales, es decir, con las mismas medidas de entrada/salida del sistema usadas para obtener el modelo difuso original.




Figura 1. Planta de laboratorio.

4. APLICACIÓN A UN MOTOR DE INDUCCIÓN REAL

El sistema es una planta de laboratorio compuesta por dos motores de inducción Leroy-Somer LS132ST (Figura 1), cada uno de los cuales presenta las siguientes características: velocidad nominal 1420 rpm, intensidad 12A, rendimiento 81 %, frecuencia de alimentación 50 Hz, factor de potencia 0.85 con una potencia de 5.5 Kw. Constructivamente contienen 3 fases, 4 polos, 28 barras de rotor y 36 ranuras de estátor, siendo la conexión de estos motores de tipo delta. Uno de los motores es el que se va a monitorizar y detectar fallos, y el otro se utiliza para simular carga variable en el sistema. El motor tiene un conjunto de sensores para monitorización, empleándose en este caso voltaje, corriente, temperatura, flujo magnético y encoders ópticos para medir velocidad y desplazamiento angular. Los experimentos llevados a cabo sólo tienen en cuenta fallos no destructivos debido al coste económico de los fallos destructivos. Se han generado diferentes tipos de fallos en el motor real:

- Funcionamiento normal (FN).
- Fallo de alimentación, desequilibrio severo en una de las tres fases (DT).
- Fallo de alimentación, desequilibrio débil en una de las tres fases (DP).
- Variación en la resistencia del estator en una de las tres fases (RE).
- Fallo en el encoder que mide la velocidad angular (FE).
- Fallo en el sensor de voltaje en una de las tres fases (FT).

Los datos fueron tomados de los sensores del motor a una frecuencia de 250KHz. Para cada tipo de funcionamiento (normal y los distintos fallos) se obtuvieron entre 2 y 4 conjuntos de datos, conteniendo cada uno entre 35000-40000 muestras de las variables involucradas en el sistema: las 3 corrientes de fase (I_1, I_2, I_3), tensiones en las tres fases (V_1, V_2, V_3) y la velocidad angular (ω). Un conjunto de datos se utilizó en la fase de aprendizaje y obtención de los modelos difusos y los otros conjuntos se utilizaron para validar los modelos obtenidos mediante validación cruzada. Para mejorar el comportamiento en el proceso pos-




Figura 2. Respuesta del modelo de funcionamiento normal (FN) vs. respuesta real de validación.

terior de clasificación, las variables eléctricas fueron procesadas usando sus valores eficaces.

4.1 Detección y Aislamiento de Fallos

Primero, se construye un banco de modelos difusos tipo TS, uno por cada modo de operación del motor de inducción, es decir, seis modelos difusos identificados a partir de los datos medidos del motor, usando el algoritmo de clustering subtractivo y el sistema neuro-difuso ANFIS. Las entradas son las mismas para todos los modelos y son: las 3 corrientes de fase, los tres potenciales y el valor del par en el instante actual $T(k)$, y la salida es la predicción del par del motor para el instante de muestreo siguiente $T(k+1)$. El par motor se calcula de la siguiente forma:

$$T(k) = \frac{\eta P_T}{2\pi\omega(k)} \quad (10)$$

donde η es el rendimiento, $\omega(k)$ es la velocidad angular en rps (que multiplicando por 2π corresponde a rad/s) y P_T es la potencia activa, que se calcula en función de las corrientes (I_i) y de los potenciales (V_i) como:

$$P_T = \frac{1}{k} \sum_{i=1}^3 \left(\sum_{k=0}^{k=K} V_i(k) I_i(k) \right) \quad (11)$$

Los resultados para el comportamiento normal con los datos de validación se muestran en la Figura 2. En este caso se obtiene un modelo con 12 reglas y un total de 84 conjuntos difusos. La respuesta del modelo ante los datos de validación es adecuada con una medida del error cuadrático medio (MSE) de $1.43 \cdot 10^{-6}$. Se ha calculado un modelo TS para cada modo de operación, y en la Tabla 1 está representado el número de reglas obtenidos para cada modelo, así como la medida MSE para cada uno de ellos con los datos de validación.

Ahora, para detectar fallos, se pasan los datos del motor de inducción de cada modo de operación por

Tabla 1. Número de reglas y MSE de validación obtenidos para cada modelo difuso generado

Modelo	Reglas	MSE
<i>FN</i>	12	$1.43 \cdot 10^{-6}$
<i>DT</i>	19	$8.69 \cdot 10^{-5}$
<i>DP</i>	19	$9.04 \cdot 10^{-5}$
<i>RE</i>	27	$3.29 \cdot 10^{-6}$
<i>FE</i>	27	$1.26 \cdot 10^{-6}$
<i>FT</i>	22	$8.08 \cdot 10^{-6}$




Figura 3. Respuesta del modelo difuso FT (para fallo tipo 6) ante respuesta normal del motor

los distintos modelos obtenidos. Se calcula un residuo para cada modelo como la diferencia entre los datos reales y la salida de cada modelo difuso. A partir de esto se calcula el índice de comportamiento J_i según la eq.(1), para el modo de funcionamiento i -ésimo, con $i = 1, 2, \dots, 6$. El valor mínimo de J_i indica cuál es el modelo más adecuado en la situación actual, es decir, detecta el modo de comportamiento del motor, (normal o los diferentes tipos de fallo). Debido a que cuando los datos reales se pasan a través del modelo que no es adecuado, aparece un error muy grande, como se puede ver en la Figura 3, donde los datos reales de situación normal se pasan a través del modelo difuso construido con datos de fallo 6 (FT), fallo en el sensor de potencial de la fase 1. Se puede comparar el comportamiento del método de FDD entre las Figuras 2 y 3 donde en el primer caso se tienen datos normales con modelo FN y en el segundo caso datos normales con modelo FT.

Este banco de modelos difusos es capaz de detectar todos los fallos, como es posible ver en la Figura 4, donde se representa la evolución temporal del índice de comportamiento J_i para cada uno de los modelos TS cuando el motor opera en condiciones normales. Siempre, el menor valor de J_i indica el modelo correcto, esto es posible verlo en la Figura 5, donde se representa el número de muestras en el cual el índice J_i es el menor para la misma situación, es decir, el motor está en la condición 1, que representa la situación de condición normal, para casi el 100% de las muestras. Se podría representar una gráfica similar para cada caso, pero es más útil mostrar la Tabla 2 donde se representa la exactitud en %, es decir, el número de muestras en las cuales el índice J_i es menor en cada situación.




Figura 4. Evolución temporal de J_i por modelo en ausencia de fallos en el motor.




Figura 5. J_i para condiciones normales de operación. El menor valor de los J_i es, básicamente, J_1 , (1: situación de no fallo).

Tabla 2. Precisión (en %) de cada modelo difuso cuando se emplean en clasificación

Modo	J_1	J_2	J_3	J_4	J_5	J_6
<i>FN</i>	98.07	1.53	0	0	0.35	0.05
<i>DT</i>	0	93.68	0	0	0	6.32
<i>DP</i>	0	0	100	0	0	0
<i>RE</i>	0	5.2	0	94.80	0	0
<i>FE</i>	0.04	0.44	0.12	0	99.12	0.28
<i>FT</i>	0	0	2.76	0	0	97.24

4.2 Reducción de la base de reglas

Los modelos difusos TS obtenidos para cada situación del motor, tienen un gran número de reglas y de conjuntos difusos. Por ejemplo, los conjuntos difusos para la variable de entrada 4, I_1 , en el modelo de comportamiento normal tiene 12 conjuntos difusos, como puede verse en la Figura 6. Esta figura muestra que se ha generado una gran redundancia de conjuntos difusos similares, es decir, que hay un gran solapamiento entre los conjuntos difusos. Lo mismo ocurre para las otras entradas (V_1 , V_2 , V_3 , I_2 , I_3 y $T(k)$). Asignar




Figura 6. Funciones de pertenencia del modelo original (funcionamiento normal (FN)) para la entrada I_1 .

Tabla 3. Número de reglas y MSE en validación obtenidos para cada modelo difuso simplificado

Model	Rules	MSE
<i>FN</i>	3	$1.85 \cdot 10^{-6}$
<i>DT</i>	7	$1.38 \cdot 10^{-5}$
<i>DP</i>	4	$8.99 \cdot 10^{-6}$
<i>RE</i>	6	$2.41 \cdot 10^{-6}$
<i>FE</i>	4	$2.35 \cdot 10^{-6}$
<i>FT</i>	4	$4.42 \cdot 10^{-6}$

etiquetas con significado lingüístico a estos conjuntos difusos para hacer una descripción lingüística y una evaluación experta del conocimiento adquirido es prácticamente imposible.

Se ha aplicado el método descrito en la Sección 3 varias veces con valores diferentes del umbral γ (cuando la medida de similitud de dos conjuntos difusos es mayor que este umbral, ambos conjuntos difusos son sustituidos por uno nuevo combinación de ambos) para reducir el conjunto de reglas. Y una vez que este conjunto se ha reducido, los modelos son entrenados de nuevo con los datos medidos del motor, para calcular los nuevos consecuentes de las reglas. Los resultados mostrados aquí, tienen el umbral $\gamma = 0.5$ para la similitud entre conjuntos difusos y $\gamma = 0.1$ para la similitud entre conjuntos difusos de diferentes reglas, es decir, un caso extremo. El número de reglas para cada nuevo modelo y la medida MSE calculada para cada modelo obtenido con datos de validación se muestran en la Tabla 3. Esta tabla muestra que el modelo original puede simplificarse y reducirse substancialmente sin sacrificar demasiado la exactitud.

En la Figura 7, están representados los conjuntos difusos del modelo FN simplificado (es decir, el modelo en condiciones normales de operación) obtenidos usando $\gamma = 0.5$, para la entrada I_1 . Para este caso, obtener un modelo cualitativo asignando etiquetas lingüísticas a los conjuntos difusos es mucho más sencillo que con el modelo original. Como se muestra en dicha figura, el universo de discurso de esta variable se ha particionado en tres regiones, 'bajo', 'medio' y 'alto'; es posible hacer lo mismo con el resto de las variables de entrada y obtener un modelo lingüístico para el




Figura 7. Funciones de pertenencia para el modelo FN simplificado para la entrada I_1 .




Figura 8. Respuesta del modelo difuso FN simplificado vs. respuesta normal del motor.

comportamiento normal del motor de inducción, como puede verse en la ecuación 12. La respuesta de este modelo simplificado para los mismos datos de validación que los usados en la Figura 2 se muestran en la Figura 8. Hay muy poca diferencia entre ambas gráficas, es decir entre el resultado de validación para el modelo de comportamiento normal original y el simplificado.

Regla1 : SI V_1 es BAJO Y V_2 es MEDIO Y V_3 es ALTO Y I_1 es BAJO Y I_2 es MEDIO Y I_3 es ALTO Y $T(t-1)$ es MEDIO ENTONCES
 $y = -0.106 V_1 + 0.09142 V_2 - 0.0978 V_3$
 $+ 0.09679 I_1 - 0.04086 I_2 + 0.1338 I_3 +$
 $0.8532 T(t-1) + 0.04175$

Regla2 : SI V_1 es MEDIO Y V_2 es ALTO Y V_3 es BAJO Y I_1 es MEDIO Y I_2 es ALTO Y I_3 es BAJO Y $T(t-1)$ es ALTO ENTONCES
 $y = 0.002928 V_1 + 0.001463 V_2 + 0.0004452 V_3$
 $- 0.009393 I_1 - 0.007347 I_2 + 0.007515 I_3$
 $+ 0.9988 T(t-1) + 0.0095211$ (12)

Regla3 : SI V_1 es ALTO Y V_2 es BAJO Y V_3 es MEDIO Y I_1 es ALTO Y I_2 es BAJO Y I_3 es MEDIO Y $T(t-1)$ es ALTO ENTONCES
 $y = -0.004258 V_1 - 0.007074 V_2 - 0.004797 V_3$
 $- 0.04356 I_1 - 0.03929 I_2 - 0.04218 I_3$
 $+ 0.9998 T(t-1) + 0.07481$




Figura 9. Evolución de J_i para cada modelo simplificado ante un desequilibrio leve en la alimentación en la primera fase (modo de operación 3).

Ahora, es necesario probar que este nuevo banco de modelos difusos es capaz de detectar e identificar los fallos. Como antes, los datos recogidos del motor de inducción real en todas las situaciones de funcionamiento posibles, se pasan a través del banco de modelos. Se calcula el mismo índice de comportamiento J_i , para cada modelo y cada posible situación, como se muestra en la Figura 9 donde se representa la evolución temporal del índice J_i para cada modelo simplificado cuando hay un fallo en la alimentación, un desequilibrio leve en la primera fase (DP). El valor menor de esta medida indica la situación actual del motor de inducción, es decir, condición normal o alguno de los fallos. Si el índice mínimo J_i en cada periodo de muestreo se almacena en una variable y hacemos una gráfica de dicha variable aparece la Figura 10, donde es posible ver que el mínimo valor de J_i en cada periodo de muestreo es el correspondiente al modo 3, es decir, al desequilibrio leve en la alimentación de la primera fase. Como antes se podría representar una gráfica similar para cada situación.

Finalmente en la Tabla 4 se representa el número de muestras correctamente clasificadas en %, es decir, el número de muestras en las cuales el índice J_i es menor en cada situación, para los modelos simplificados. Comparando las Tablas 2 y 4 puede concluirse que el modelo difuso simplificado es lingüístico, es decir, se puede obtener conocimiento interpretable de él, pero a costa de una pequeña pérdida en las propiedades de clasificación de los modelos, es decir, en este caso la exactitud baja comparado con el banco de modelos original.

5. CONCLUSIONES

Este artículo presenta un banco de modelo difusos de TS para implementar un esquema de detección y aislamiento de fallos, basado en el método de modelos




Figura 10. Número de veces que J_i es mínimo. En este caso el mínimo es J_3 casi el 100% de las muestras. Este valor indica el modo actual de operación: modo 3 (*modelo DP*)

Tabla 4. Índice J y precisión de cada modelo difuso simplificado para clasificar fallos (%)

Modo	J_1	J_2	J_3	J_4	J_5	J_6
FN	97.56	0.05	1.77	0	0.51	0.11
DT	5.10	84.75	7.02	0	0	3.13
DP	0	0	100	0	0	0
RE	8.0	0	0	92.0	0	0
FE	0	0.08	3.0	0	96.36	0.56
FT	0	0	5.4	0	0	94.6

múltiples, y su aplicación a un sistema real: un motor de inducción. Los modelos difusos (uno para cada modo de operación del motor, normal y con distintos fallos) se han obtenido aplicando el método de clustering substractivo a partir de datos de entrada/salida del sistema. Los resultados muestran que esta método multi-modelo puede detectar e identificar todos los modos de operación del motor de inducción.

Pero, los modelo difusos, especialmente cuando se obtienen a partir de datos experimentales, contienen un número muy elevado de conjuntos difusos y de reglas. Un estudio más profundo de los conjuntos difusos obtenidos revela que muchos de ellos son muy similares, representando más o menos el mismo concepto. Esta redundancia hace que la interpretación lingüística del modelo sea prácticamente imposible. En este artículo, se usa una medida de similitud para simplificar la base de reglas obtenida a partir de los datos, mediante la creación de conjuntos difusos nuevos como combinación de los conjuntos difusos que tienen un grado de similitud por encima de un cierto umbral, eliminando reglas difusas con la misma premisa y entrenando nuevamente los modelos con los mismos datos para calcular los nuevos consecuentes de las reglas. Este método se ha aplicado con éxito a un motor de inducción real, obteniéndose un banco de modelos difusos simplificados que pueden modelar las diferentes condiciones de operación del sistema.

Estos nuevos modelos se han usado para implementar un esquema FDD basado nuevamente en el modelado múltiple, y los resultados muestran que los nuevos modelos pueden detectar todos los fallos, pero con un grado menor de exactitud. También pueden ser interpretados debido al reducido número de reglas en la base de reglas difusas, como se ha mostrado para el caso del funcionamiento normal del motor. Ahora, el trabajo futuro consiste en interpretar el conocimiento adquirido para los diferentes modos de operación del motor, así como una simplificación más sistemática de los modelos difusos obtenidos, utilizando programación multiobjetivo, de forma que al hacer un modelo se tenga en cuenta no sólo la exactitud de dicho modelo, sino también otros aspectos como su grado de interpretabilidad (en términos de números de reglas, número de conjuntos difusos, etc.).

RECONOCIMIENTOS

Este trabajo se ha realizado gracias al soporte del Ministerio de Educación y Ciencia, a través del proyecto DPI2006-15716-C02-02.

REFERENCIAS

- Benbouzid, M. (2000). A review of induction motors signature analysis as a medium for fault detection. *IEEE Trans. on Industrial Electronics* **47**(5), 984–993.
- Bonissone, P. P., Y. Chen, K. Goebel and P. S. Khedkar (1999). Hybrid soft computing systems: Industrial and commercial applications. In: *Proceedings of the IEEE*. Vol. 87. pp. 1641–1667.
- Casillas, J., O. Cordon, F. Herrera and L. Magdalena (2003a). *Interpretability Issues in Fuzzy Modeling*. Studies in Fuzziness and Softcomputing, Springer-Verlag. Berlin Heidelberg.
- Casillas, J., O. Cordon, Herrera F. and L. Magdalena (2003b). *Accuracy Improvements in Linguistic Fuzzy Modeling*. Studies in Fuzziness and Softcomputing, Springer-Verlag. Berlin Heidelberg.
- Chao, C.T., Y.J. Chen and C.C. Teng (1996). Simplification of fuzzy-neural systems using similarity analysis. *IEEE. Trans. on Systems, Man and Cybernetics - Part B: Cybernetics*. **26** (2), 344–354.
- Chen, J. and R. J. Patton (1999). *Robust Model-Based Diagnosis for Dynamics Systems*. . Kluber. Academic Publisher.
- Chiu, S.L. (1994). Fuzzy model identification based on cluster estimation. *Intelligent and Fuzzy Systems* **2**, 267–278.
- Filippetti, F., G. Franceschini, C. Tassoni and P. Vas (2000). Recent developments of induction motor drives fault diagnosis using AI techniques. *IEEE Trans. on Industrial Electronics* **47** (5), 994–1004.
- Frank, P.M. (1990). Fault diagnosis in dynamic systems using analytical and knowledge-based redundancy - a survey and some new results.. *Automatica*. **26**, 459–474.
- Isermann, R. and P. Balle (1997). Trends in the application of model-based fault detection and diagnosis of technical processes. *Control Engineering Practice* **5** (5), 705–719.
- Jang, J.R. (1993). ANFIS: Adaptive-network-based fuzzy inference system. *IEEE Trans. on Systems, Man and Cybernetics* **23**, 665–685.
- Jin, Y. (2000). Fuzzy modeling of high-dimensional systems: Complexity reduction and interpretability improvement. *IEEE Trans. on Fuzzy Systems* **8** (2), 212–221.
- Setnes, M., R. Babuska, U. Kaymak and H.R. Van Nauta Lemke (1998). Similarity measures in fuzzy rule base simplification. *IEEE trans. on Systems, Man and Cybernetics, Part B: Cybernetics*. **28** (3), 376–386.
- Zadeh, L. A. (1965). Fuzzy sets. *Information Control* **8**, 338–353.
- Zadeh, L. A. (1988). Fuzzy logic. *Computer* **21**, 83–92.