

IDENTIFICACION DE PARAMETROS UTILIZANDO UN ALGORITMO GENETICO DE OPTIMIZACION, APLICACION AL CIRCUITO EQUIVALENTE DE LA MAQUINA DE INDUCCION.

Ing. Javier Quintana M.

Dr. Hugo Banda Gamboa
Escuela Politécnica Nacional

Abstract

This work reports the results of the application of an optimization genetic algorithm to the identification of parameters of a 5.5 CV wounded rotor induction motor. A genetic algorithm can be applied for searching a global minimum of a rugged hyper function, under noisy conditions, which make impossible the use of a steepest gradient method. A genetic algorithm uses a population of possible solutions as an starting point. This information is subjected to the action of artificial genetic operators, such as reproduction, crossover and mutation, in the process of finding the optimum set of parameters, for a given operating point.

Resumen

En este trabajo se publican los resultados obtenidos al aplicar un algoritmo genético de optimización a la identificación de los parámetros de un motor de inducción de rotor bobinado de 5.5 CV. Un algoritmo genético puede ser aplicado a la búsqueda del mínimo global de funciones que tienen varios mínimos locales, bajo condiciones de ruido, lo que hace imposible la utilización de métodos de gradiente descendente. Un algoritmo genético emplea una población de posibles soluciones como punto partida. Esta información es luego sometida a la acción de operadores genéticos artificiales, como reproducción, cruce y mutación, en la identificación del grupo óptimo de parámetros, para un determinado punto de operación.

Introducción

Un problema muy frecuente en muchos sistemas es el desconocimiento de los valores óptimos de sus parámetros de control, y la inexistencia de un algoritmo directo que permita descubrirlos. Las técnicas tradicionales de optimización dependen en gran medida de una relación determinística entre los parámetros de control y el funcionamiento resultante, un efecto explícito de una señal de entrada en el funcionamiento del sistema. Estas técnicas han mejorado, pero aún no son capaces de optimizar el comportamiento de sistemas muy complejos. El éxito que han alcanzado los métodos convencionales se logra en situaciones en las cuales el sistema puede ser modelado con suficiente precisión, o cuando el número de probables valores de los parámetros es lo suficientemente pequeño como para que puedan ser probados exhaustivamente. En cambio, para muchos sistemas que no pueden ser modelados adecuadamente, o para aquellos cuyo espacio de estado es muy grande, se requiere de una técnica diferente, una técnica que busque efectivamente los valores óptimos de los parámetros de control del sistema.

CORRESPONDENCIA: Dr Hugo A. Banda G.
Escuela Politécnica Nacional
Facultad de Ingeniería Eléctrica
P. O. Box 17-01-121
Quito-Ecuador.

Este es el caso de un motor de inducción, ya que existe un gran número de grupos de parámetros de su circuito equivalente que se adaptan muy bien a cada una de sus diferentes condiciones de funcionamiento bajo carga. Sin embargo, es muy difícil determinar cual de ellos es el grupo óptimo, para cada condición.

En los años setenta, surge una nueva técnica que utiliza los principios de la genética natural en la búsqueda de los parámetros óptimos de sistemas tanto simples como complejos. A esta nueva técnica se la ha denominado como Algoritmos Genéticos de Optimización y Búsqueda.

Estos algoritmos trabajan muy bien en sistemas que tienen un espacio de estado muy amplio, o que están inmersos en un ambiente con mucho ruido. Esta característica muy particular de los algoritmos genéticos, ha llevado a pensar en la posibilidad de utilizarlos en la búsqueda de el grupo óptimo de parámetros de un motor de inducción, para una determinada condición de funcionamiento.

David Goldberg ^[1] define a los algoritmos genéticos como:

"algoritmos de búsqueda basados en los mecanismos de la selección natural y la genética natural, que combinan la sobrevivencia de una estructura de cadenas a una prueba de aptitud con un intercambio de información estructurado aunque a la vez aleatorio, para formar un algoritmo de búsqueda que tenga algo del innovativo instinto de la búsqueda humana".

En cada generación se crea un nuevo grupo de criaturas artificiales (cadenas), empleando bits o piezas de las anteriores. Siendo aleatorios, los algoritmos genéticos no son un simple camino al azar, sino que explotan, eficientemente, la información histórica, para especular sobre nuevos puntos de búsqueda con una esperanza mejor en su funcionamiento.

begin

t = 0;

Obtener la población inicial A(t);

Evaluar las estructuras contenidas en A(t);

while no se satisfaga condición para terminar do

begin

t = t + 1;

Seleccionar A(t) a partir de A(t - 1);

Recombinar las estructuras en A(t);

Evaluar las estructuras contenidas en A(t);

end

end

Fig. 1. Esquema básico de un algoritmo genético.

Un algoritmo genético básico g_0 , como el presentado en la Fig. 1, con el cual se pueden obtener buenos resultados, en la mayoría de los problemas prácticos, requiere de por lo menos, una población inicial de cadenas o estructuras de cadenas, una función objetivo a cumplirse, y tres operadores básicos: reproducción, cruce y mutación.

La reproducción, es un proceso en el cual las cadenas individuales se copian a un depósito intermedio, de acuerdo al valor de su función objetivo. Intuitivamente, pensamos en la función objetivo como una medida de la utilidad o bondad, la cual se quiere maximizar. El copiar cadenas de acuerdo a su aptitud significa que las cadenas con un valor alto de aptitud tienen una alta probabilidad de contribuir con una o más muestras en la siguiente generación. Es decir, la función objetivo es el árbitro final que decide cuales cadenas deben vivir y cuales deben morir.

Después de la reproducción, viene el proceso de cruce, el cual se lo puede realizar en dos pasos. Primero, se selecciona, al azar, parejas entre aquellas cadenas que se encuentran en el depósito intermedio. Segundo, cada pareja es sometida al proceso de cruce como sigue: se escoge, al azar, un punto de cruce, comprendido entre la primera y la última posición de la cadena menos uno. Luego, se forman dos nuevas cadenas al intercambiar las correspondientes subcadenas formadas por los caracteres comprendidos entre la posición de cruce y el final de la cadena. En la Fig. 2 se muestra un ejemplo de este proceso.

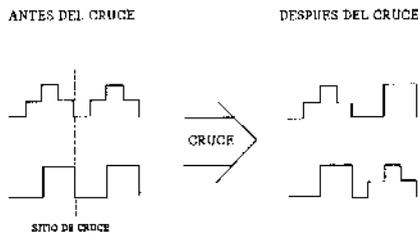


Fig.2. Ejemplo de un proceso de cruce entre cadenas.

Generalmente, el proceso de cruce se realiza de manera simultánea con el proceso de mutación. Es decir, en el momento de intercambiar las subcadenas entre los miembros de una pareja, se analiza si es factible que se mute algún elemento de dichas cadenas. En el caso de que las cadenas hayan sido construidas a partir de un alfabeto binario {0,1}, la mutación consistiría en cambiar un 1 por un 0, y viceversa.

De lo dicho hasta este momento, se puede concluir que los algoritmos genéticos difieren de los procedimientos tradicionales de optimización y búsqueda, en cuatro aspectos:

- 1) Trabajan con un código del grupo de parámetros, y no con los parámetros en sí mismos, ya que éstos se codifican en cadenas de longitud finita en algún alfabeto finito.
- 2) Buscan en una población de puntos, y no en un solo punto.
- 3) Utilizan una función objetivo, y no derivadas u otro conocimiento auxiliar.
- 4) Emplean reglas de transición probabilísticas, y no determinísticas.

Una vez conocidos los principios básicos de los algoritmos genéticos, centremos la atención en su aplicación a la identificación de los parámetros de la máquina de inducción.

Método

Para identificar el grupo de parámetros óptimos del circuito equivalente de la máquina de inducción, correspondientes a una cierta condición de carga, se ha codificado un algoritmo genético que tiene como base el esquema indicado anteriormente en la Fig. 1. Para modelo de la máquina de inducción se escogió el circuito equivalente recomendado por el IEEE Std-112¹⁰, el mismo que se ilustra en la Fig. 3.

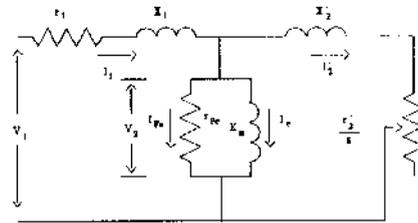


Fig.3. Circuito equivalente por fase de la máquina de inducción.

Para encontrar un grupo de parámetros óptimos de la máquina de inducción se define la siguiente función de error:

$$E = \frac{1}{3} \{ [Re(Z_e) - Re(Z_r)]^2 + \frac{1}{3} [Im(Z_e) - Im(Z_r)]^2 + \frac{1}{3} [T_r - T_e]^2$$

en donde:

- E se refiere al error medio cuadrático.
- Z se refiere a la impedancia compleja que se presenta en los terminales de entrada a la máquina bajo prueba.
- T corresponde al torque en el eje de la máquina.
- El subíndice r, corresponde a los valores tomados como referencia.
- El subíndice e, corresponde a los valores obtenidos durante el proceso de búsqueda.
- Re, corresponde a la parte real.
- Im, corresponde a la parte imaginaria.

Los valores referenciales de impedancia compleja de entrada a la máquina y de torque en el eje, se calculan a partir de los datos de voltaje, corriente, potencia y deslizamiento, obtenidos al realizar a la máquina una prueba de carga. Una vez que se han calculado los valores de referencia éstos se convierten en una constante durante el proceso de búsqueda.

La estimación de los valores de impedancia compleja de entrada y de torque en el eje, durante el proceso de búsqueda de los parámetros óptimos, se la hace a partir del circuito equivalente indicado en la Fig. 3. En el caso específico del torque en el eje, éste se calcula utilizando la ecuación:

$$T_e = \frac{1}{w_s} \frac{3 \cdot V_1^2 \cdot \left(\frac{R_2}{s}\right)}{\left(R_1 + \frac{R_2}{s}\right)^2 + (X_1 + X_2)^2}$$

en donde, w_s es la velocidad de sincronismo de la máquina, expresada en radianes/segundo.

Al evaluar de esta manera el error, es posible identificar los grupos de parámetros del circuito equivalente de la máquina con los cuales se obtienen valores de impedancia y torque lo más aproximados a aquellos tomados como referencia. A estos grupos los podemos considerar como los más aptos dentro de la población. Visto de esta manera, la aptitud de un grupo de parámetros se puede definir como el inverso del error que se obtiene al evaluar con ellos la función de error.

Para aplicar el algoritmo genético de búsqueda es necesario contar con una población inicial de grupos de parámetros, la misma que se la obtuvo siguiendo el procedimiento que recomienda el IEEE Std-112 para el cálculo de los parámetros del circuito equivalente indicado en la Fig. 3. Debido a los requerimientos de este trabajo, el tamaño de la población inicial se fijó en 100 integrantes. Adicionalmente, si bien es cierto que son seis los parámetros que conforman el circuito equivalente considerado, en realidad las incógnitas son solo cuatro: R_2 , X_1 , X_2 y R_e . Esto se debe a que el método de cálculo utilizado considera como conocido de antemano el valor de R_1 y, $X_1 = X_2$ en razón de lo que dicta la norma NEMA MG-1 para el caso de un motor de inducción de rotor devanado.

Una vez obtenida esta población inicial, cada grupo de parámetros toma la forma de una cadena binaria de 40 bits que representa a dicho grupo, en donde cada parámetro debe codificarse en subcadenas de 10 bits. Luego, se prueba cada una de estas cadenas para determinar su aptitud, considerando que ésta es igual al inverso del valor obtenido al evaluar la función de error.

Evaluada la aptitud para cada uno de los grupos de parámetros de la población, éstos se copian a un depósito intermedio un número de veces proporcional a su aptitud, cuando ésta es comparada con el promedio de toda la población, formando así una nueva población tentativa con igual número de miembros que la anterior. Esto es lo que se conoce como el proceso de reproducción.

Después, para producir una diversidad, las cadenas representativas de los grupos de parámetros que se encuentran en el depósito intermedio, son apareadas aleatoriamente. Cada cadena apareada intercambia con su correspondiente pareja una porción de sus bits escogida al azar. Esto produce un nuevo grupo de miembros, los cuales tienden a mantener muchas de las características de sus predecesores pero permiten ampliar el espacio de búsqueda. Este es lo que se conoce como el proceso de cruce.

Luego del cruce, la población debe experimentar la mutación. En este paso, una porción de sus bits, del total de la población, es alterado al azar. Típicamente se modifica un promedio de un bit en cien. Esta función previene al algoritmo de la pérdida de alguna información potencialmente útil.

Una vez que se han aplicado los tres operadores básicos, se obtiene una nueva población de posibles parámetros de la máquina, cuyos miembros reúnen, casi siempre, mejores características de aptitud que sus predecesores. A continuación, se evalúa la aptitud de cada uno de los grupos de parámetros miembros de esta nueva población, para después aplicar nuevamente los tres operadores genéticos básicos, para de esta manera obtener otra población.

Este proceso se repite el número de veces (generaciones) necesarias para que el mejor grupo de parámetros, miembro de la última población obtenida, minimice la función de error hasta un valor aproximado de 10^{-4} . Cuando esto ocurre, éste grupo de parámetros se convierte en el grupo óptimo de la máquina de inducción, para las condiciones de funcionamiento de la máquina tomadas como referencia.

Resultados

El algoritmo genético de optimización y búsqueda se aplicó a la identificación de los parámetros óptimos del circuito equivalente de un motor de inducción trifásico de rotor devanado de 5.5 CV, para diversas condiciones de funcionamiento de la máquina tomadas como referencia, las mismas que van desde vacío a la plena carga.

Las condiciones de impedancia de entrada y torque en el eje tomadas como referencia se presentan en la Tabla No.1; en tanto que en la Tabla No.2 se indican los datos de voltaje, corriente, potencia y deslizamiento medidos durante las pruebas de carga realizadas a la máquina y que sirvieron para obtener dichas referencias.

Adicionalmente, de manera experimental se determinó que el valor de la resistencia de estator R_1 es igual a 0.8936 ohmios. El valor de esta resistencia se obtuvo por medio de la prueba del voltímetro-amperímetro, considerando que el estator de la máquina está en conexión delta. El valor de esta resistencia se convierte en una constante y no debe ser alterado durante el proceso genético de búsqueda.

En la Tabla No.3 se incluyen los grupos de parámetros, miembros de la población inicial, que mejor se adaptan a cada una de las condiciones de referencia. Estos valores se presentan únicamente para compararlos con aquellos que se obtienen luego de aplicado el algoritmo genético.

Finalmente, en la Tabla No.4, se indican los grupos de parámetros óptimos del circuito equivalente, correspondientes a cada una de las condiciones de referencia, obtenidos luego de aplicado el algoritmo genético de optimización y búsqueda.

Discusión

Como se puede observar en la Tabla No.3, los errores obtenidos con los mejores grupos de parámetros de la población inicial son bastante aceptables para las cuatro primeras condiciones de referencia, razón por la cual se los podría considerar como los más idóneos para dichas condiciones, siempre que no se utilice un algoritmo genético en la búsqueda de los parámetros óptimos.

Sin embargo, para las condiciones de referencia de las pruebas de carga No.5 a No.9, estos errores son bastante altos, lo que indica que de ninguna manera se los puede considerar como los más adecuados. Además, se puede observar que el error aumenta conforme las condiciones de funcionamiento de la máquina que sirven de referencia se acercan a la condición de vacío. Esto puede deberse a las aproximaciones en que incurre el método utilizado para obtener la población inicial, como por ejemplo el despreciar las pérdidas que se producen en la máquina por efecto de la fricción y la ventilación, las mismas que toman mayor importancia cuando la máquina funciona en vacío.

TABLA No.1 Impedancias de entrada y torque en el eje, tomadas como referencia en la búsqueda de los parámetros óptimos del motor de inducción.

Prueba No.	IMPEDANCIA DE ENTRADA		Torque en el eje (Nm)
	REAL (ohmios)	IMAGINARIA (ohmios)	
1	6.4891	3.0570	24.00
2	7.3129	4.2417	21.38
3	8.4985	5.3274	17.75
4	9.6667	6.8293	13.37
5	10.3930	9.5140	9.63
6	10.5799	12.9873	5.75
7	10.0923	14.4405	4.75
8	10.5794	15.1683	3.75
9	8.3333	18.1445	1.88

TABLA No.2 Datos obtenidos a partir de las pruebas de carga efectuadas al motor de inducción trifásico, necesarias para calcular las referencias.

Prueba No.	Deslizamiento	Torque (Nm)	Voltaje (V)	Corriente (A)	Potencia (W)
1	0.0833	24.000	205.0	16.5	5300
2	0.0666	21.375	205.0	14.0	4300
3	0.0611	17.750	205.0	11.8	3550
4	0.0500	13.375	205.0	10.0	2900
5	0.0444	9.625	205.0	8.4	2200
6	0.0333	5.750	206.0	7.1	1600
7	0.0333	4.750	207.5	6.8	1400
8	0.0277	3.750	205.0	6.4	1300
9	0.0222	1.875	207.5	6.0	900

TABLA No.3 Características de los grupos de parámetros, miembros de la población inicial, que mejor se adaptan a las condiciones de referencia.

No.	MEJOR GRUPO DE PARAMETROS, MIEMBRO DE LA POBLACION INICIAL					IMPEDANCIA DE ENTRADA		TORQUE EN EL EJE (Nm)	ERROR
	R1 (ohms)	R2 (ohms)	X1 = X2 (ohms)	Xm (ohms)	Rfe (ohms)	REAL (ohms)	IMAG (ohms)		
1	0.8936	0.5832	0.8514	19.3743	146.9201	6.4624	3.4453	23.93	0.0521
2	0.8936	0.5408	0.9005	19.6309	184.9831	7.1540	4.0751	21.43	0.0188
3	0.8936	0.6348	0.9001	20.0536	173.8837	8.3196	5.1630	17.74	0.0197
4	0.8936	0.7180	0.8993	20.8323	157.4331	9.8296	7.0771	13.57	0.0429
5	0.8936	0.8270	0.8937	21.0520	172.0057	10.7359	9.1934	10.81	0.5364
6	0.8936	0.8270	0.8937	21.0520	172.0057	11.0891	11.736	8.41	2.5993
7	0.8936	0.8270	0.8937	21.0520	172.0057	11.0891	11.736	8.53	7.5281
8	0.8936	0.8270	0.8937	21.0520	172.0057	10.9770	13.345	7.02	4.7163
9	0.8936	0.8270	0.8937	21.0520	172.0057	10.5412	15.123	5.84	9.8943

TABLA No.4 Resultados obtenidos luego de aplicado el algoritmo genético de optimización y búsqueda.

No	PARAMETROS OPTIMOS DEL CIRCUITO EQUIVALENTE DEL MOTOR DE INDUCCION.					IMPEDANCIA DE ENTRADA		TORQUE EN EL EJE (Nm)	B R R O R
	R1 (ohms)	R2 (ohms)	X1=X2 (ohms)	Xm (ohms)	Rfe (ohms)	REAL (ohms)	IMAG (ohms)		
1	0.8936	0.5856	0.7904	21.4956	75.9238	6.4826	3.0573	24.01	4.4E-5
2	0.8936	0.5456	0.8343	19.1202	916.5500	7.3060	4.2362	21.38	3.6E-5
3	0.8936	0.6344	0.8978	20.3959	402.6354	8.4950	5.3380	17.76	5.2E-5
4	0.8936	0.7319	0.8831	20.4839	99.1496	9.6660	6.8239	13.38	7.5E-5
5	0.8936	0.9417	0.8295	19.7801	97.5660	10.3976	9.5160	9.63	1.6E-5
6	0.8936	1.2392	0.9319	20.0880	73.2845	10.5692	12.985	5.76	5.1E-5
7	0.8936	1.5416	0.4685	20.1320	88.8563	10.1001	14.450	4.75	5.3E-5
8	0.8936	1.5807	3.2440	20.1760	42.4047	10.5727	15.165	3.74	4.8E-5
9	0.8936	2.6635	1.0490	20.3519	76.7155	8.3184	18.146	1.88	7.6E-5

Adicionalmente, el torque en el eje tomado como referencia, y que se mide experimentalmente durante las diferentes pruebas de carga, no puede considerarse como muy preciso en razón de que se utilizó un medidor mecánico conectado al eje de la máquina, el cual introduce muchos errores.

A pesar de estos inconvenientes, en la Tabla No.4 se puede observar que el algoritmo genético de optimización y búsqueda implementado para este trabajo, sí permite encontrar los grupos de parámetros del circuito equivalente de la máquina bajo prueba que mejor se adaptan a las diferentes condiciones de funcionamiento tomadas como referencia, minimizando el error hasta valores que se encuentran en el orden de 10^{-5} . Esto significa que estos grupos de parámetros son los óptimos para cada una de estas condiciones de carga de la máquina bajo prueba.

Conclusiones

En este trabajo, se ha implementado, y probado, un algoritmo genético capaz de identificar los parámetros del circuito equivalente de un motor de inducción trifásico, que permitan una mejor aproximación a los valores de impedancia de entrada y torque en el eje tomados como referencia, y que corresponden a una determinada condición de funcionamiento de la máquina bajo prueba. Los resultados obtenidos indican que los algoritmos genéticos sí pueden ser utilizados para este propósito, con la única condición de que los valores que sirven de referencia deben ser medidos con suficiente exactitud, ya que a esa condición busca converger el algoritmo. La experiencia con el algoritmo ha permitido comprobar su robustez y su capacidad para encontrar los resultados deseados aún bajo condiciones de ruido e inconsistencia de los datos.

BIBLIOGRAFIA

[1] Grefenstette J, Baker J. *How Genetic Algorithms Work: A Critical Look at Implicit Parallelism*. Proceedings of the Third International Conference on Genetic Algorithms, George Mason University, June 1989, Morgan Kaufmann Publishers.

[2] Goldberg David. *Genetic Algorithms in Search, Optimization and Machine Learning*. Addison - Wesley Publishing Co., 1989.

[3] Yuval David. *Genetic Algorithms and Robotics, A Heuristic Strategy for Optimization*. World Scientific Publishing, 1991.

[4] IEEE. *IEEE Standard Test Procedure for Polyphase Induction Motors and Generators*. IEEE Std - 112, 1991.

[5] Almeida Domínguez Julio César. *Métodos para Determinar los Parámetros del Circuito Equivalente de la Máquina de Inducción Polifásica*. Tesis de Ingeniería Eléctrica, Escuela Politécnica Nacional, 1980, Quito - Ecuador.



Javier Quintana M. Nació en la ciudad de Guayaquil el 6 de Febrero de 1967. Obtuvo el título de Bachiller en Humanidades Modernas en el Colegio Particular Mixto Brasil de la ciudad de Quito. Sus estudios superiores los realizó en la Escuela Politécnica Nacional, obteniendo el título de Ingeniero en Electrónica y Control en Abril de 1994.

Hugo A. Banda G. Nació en Quito el 7 de Julio de 1950. Sus estudios superiores los realizó en la Escuela Politécnica Nacional, graduándose de Ingeniero en Electrónica y Telecomunicaciones en 1975. En 1978, la Universidad de Bradford, Inglaterra le otorgó el título de MSc. en Electrónica de Potencia, y en 1990 en la Universidad de Dundee, Escocia obtuvo el título de PhD en Inteligencia Artificial. Entre Julio de 1990 y Diciembre de 1991 fue miembro del personal académico del Departamento de Matemáticas y Ciencias de la Computación, Universidad de Dundee, Escocia, como investigador en aplicaciones de la Visión por Computadora en la medicina. Tiene publicados diversos trabajos de investigación sobre aplicaciones de la electrónica y la informática en el campo industrial y en bioingeniería.



Ha actuado como consultor para proyectos de investigación en Ciencia y Tecnología en el programa BID-FUNDACYT y en el programa ONUDI-CEBCA. Sus campos de interés incluyen los sistemas automáticos industriales y los sistemas de inteligencia artificial.

Actualmente se desempeña como profesor principal en la Facultad de Ingeniería Eléctrica y en la Facultad de Ingeniería de Sistemas.