

Identificación basada en algoritmos genéticos

En el capítulo anterior se describió un procedimiento para la determinación de los parámetros del modelo de circuito del motor de inducción basado en los mínimos cuadrados que padecía de ciertas limitaciones. Mediante un método basado en algoritmos genéticos se quieren evitar tales inconvenientes y conseguir un método de identificación de las constantes del modelo de circuito de las máquinas de inducción más robusto.

5.1. Introducción

Como se explicó en el capítulo tres, un algoritmo genético es un método de optimización basado en la selección natural de las especies. En esta técnica, un número inicial de individuos forman la población inicial que tendrá un cierto ajuste con la solución del problema. De esta población se eligen algunos individuos mediante un método que selecciona los mejores individuos para la reproducción con la esperanza de que se consigan mejores individuos que estén más cerca de la solución óptima.

Los algoritmos genéticos difieren de los principales métodos tradicionales de optimización en cuatro puntos fundamentales:

1. Los algoritmos genéticos trabajan con codificaciones de los puntos del espacio de búsqueda en lugar de con los puntos propiamente dichos.
2. La búsqueda se realiza a partir de una población de puntos en lugar de un solo punto.
3. No utilizan derivadas ni otras propiedades de la función objetivo, sino únicamente la función objetivo.
4. Se rigen mediante reglas de transición probabilísticas, no determinísticas.

Muchos de los métodos tradicionales utilizan la estrategia de moverse de un punto al siguiente mediante alguna regla de transición. Por ejemplo, los métodos tradicionales basados en la pendiente pasan del punto actual, x_n , al siguiente, x_{n+1} ,

mediante el incremento (la derivada o el gradiente), Δx , de forma que $x_{n+1} = x_n + \Delta x$. Esto trae consigo la posibilidad de caer en un óptimo local. Por el contrario, los algoritmos genéticos trabajan con una población de puntos simultáneamente. Además no se requiere información auxiliar como conocimientos de derivadas sino que simplemente se necesita la definición de la función objetivo. Finalmente, a diferencia de los métodos tradicionales, los algoritmos genéticos utilizan en el proceso de búsqueda reglas de transición probabilísticas que se utilizan para guiar el proceso hacia regiones del espacio en la que, con alta probabilidad, se encuentra el óptimo.

El hecho de que los métodos tradicionales pueden caer en mínimos locales y que necesitan de un punto de partida cercano a la solución óptima para converger hacia ella hace que sea interesante la opción de aplicar los algoritmos genéticos al problema de la determinación de los parámetros del modelo de circuito de un motor de inducción. Las ecuaciones a resolver son fuertemente no lineales y hay distintas combinaciones de parámetros que pueden encajar en el modelo de circuito de un motor de inducción. Además, no siempre es posible saber de antemano los valores típicos de los parámetros de un motor de inducción por lo que a veces no se dispone de un buen punto de partida para empezar a iterar. Algunos autores han utilizado con anterioridad los algoritmos genéticos para resolver el problema de la identificación de parámetros del motor de inducción [24]-[29].

5.2. Descripción del algoritmo utilizado

Se ha utilizado la función “ga” incluida en Matlab [21], que permite particularizar el algoritmo mediante un determinado número de opciones. Se ha planteado como un problema de optimización con restricciones y por ello se ha creado una función de ajuste y otra función que contiene las restricciones.

La función de ajuste o función “fitness” se ha tomado como el error de ciertas magnitudes. El algoritmo trata de minimizar la diferencia entre el valor de una magnitud del motor calculada a partir de los parámetros del modelo de circuito del motor y el mismo valor obtenido de los datos del catálogo del fabricante. Las magnitudes utilizadas para la función de ajuste han sido el error del par de arranque y la intensidad estática de arranque. También se han intentado combinar ambos objetivos para lograr una solución que, aunque no sea tan precisa como la que se podría obtener por separado, permita con un mismo modelo de jaula simple con parámetros ajustados con el deslizamiento reproducir un buen comportamiento durante el arranque, tanto desde el punto de vista de la intensidad como del par. Las funciones objetivo usadas han sido:

$$f_M = \text{abs} \left(\frac{M_{arr} - M(1)}{M_{arr}} \right) \quad (5.1)$$

$$f_I = \text{abs} \left(\frac{I_{arr} - I(1)}{I_{arr}} \right) \quad (5.2)$$

$$f_{I+M} = \frac{1}{2} \cdot \text{abs} \left(\frac{I_{arr} - I(1)}{I_{arr}} \right) + \frac{1}{2} \cdot \text{abs} \left(\frac{M_{arr} - M(1)}{M_{arr}} \right) \quad (5.3)$$

donde M_{arr} es el par de arranque de catálogo, I_{arr} es la intensidad estatórica de arranque de catálogo, $M(1)$ es el par de arranque calculado e $I(1)$ es la intensidad estatórica durante el arranque calculada. El objetivo ha sido que las funciones se acerquen a cero por lo que se han utilizado valores absolutos para evitar que tomen valores negativos.

Una de las ventajas de los algoritmos genéticos es que no es necesaria una buena solución de partida. Con un punto de partida aleatorio, el programa es capaz de converger. Esto puede ser atribuido al hecho de que el algoritmo genético usa múltiples puntos de partida al contrario que los métodos convencionales de optimización que sólo utilizan uno. Sin embargo, si estuviera disponible, es recomendable introducir una solución de partida cercana al óptimo, para poder reducir el tiempo de cálculo. La solución inicial utilizada ha sido la misma que la utilizada en el método de los mínimos cuadrados. De esta forma, desde el principio se dispone de ciertos individuos (posibles soluciones del problema de identificación) cerca de la solución, que ayudan a la convergencia del algoritmo. Otra posibilidad para reducir el tiempo de cálculo es acotar el espacio de búsqueda. Si se conoce el rango en el que puede estar la solución óptima, puede limitarse la búsqueda a este espacio. De esta forma se desechan muchas soluciones que a priori se sabe que no son buenas como, por ejemplo, parámetros con valores negativos o demasiado pequeños. Un algoritmo genético funciona, en parte, probando soluciones al azar, por lo que restringir el número de posibles soluciones es de gran ayuda para la búsqueda del óptimo. El algoritmo penaliza a los individuos que salen del rango y así impide o dificulta que sean seleccionados para la reproducción. También ayuda en la creación de la población inicial, estando todos sus miembros dentro de un rango “lógico”. La no negatividad de los parámetros puede introducirse en forma de inecuaciones, pero no ha sido necesario hacerlo ya que el espacio de búsqueda quedaba acotado por debajo por los límites de búsqueda impuestos.

El problema ha sido codificado usando variables reales. Las funciones de ajuste y las restricciones se han programado para buscar los parámetros en por unidad o normalizados. De esta forma se reduce el espacio de búsqueda, ya que los valores de todos los parámetros están en un rango entre cero y uno. En consecuencia, el tiempo utilizado por el algoritmo se ha reducido notablemente con respecto a la búsqueda de parámetros en unidades del sistema internacional. Posteriormente se han multiplicado los valores normalizados de parámetros por sus valores base para convertirlos a unidades físicas del S.I.

Las restricciones en forma de igualdad usadas han sido de nuevo los errores en algunas magnitudes. El algoritmo penaliza el incumplimiento de las restricciones multiplicando el valor de la función objetivo (“*fitness*”) del individuo por un factor dado. Las restricciones usadas han sido:

- Modelo de circuito de jaula simple con parámetros ajustados con el deslizamiento:

$$f_1 = \left(\frac{M_{arr} - M(1)}{M_{arr}} \right) \quad (5.4)$$

$$f_2 = \left(\frac{I_{arr} - I(1)}{I_{arr}} \right) \quad (5.5)$$

$$f_3 = \left(\frac{P_u^n - P_u(s_n)}{P_u^n} \right) \quad (5.6)$$

$$f_4 = \left(\frac{P_{in}^n - P_{in}(s_n)}{P_{in}^n} \right) \quad (5.7)$$

$$f_5 = \left(\frac{M_{max} - M(s_{max})}{M_{max}} \right) \quad (5.8)$$

$$f_6 = \left(\frac{Q_{in}^n - Q_{in}(s_n)}{Q_{in}^n} \right) \quad (5.9)$$

- Modelo de circuito de doble jaula:

$$f_1 = \left(\frac{M_{arr} - M(1)}{M_{arr}} \right) \quad (5.10)$$

$$f_2 = \left(\frac{I_{arr} - I(1)}{I_{arr}} \right) \quad (5.11)$$

$$f_3 = \left(\frac{P_u^n - P_u(s_n)}{P_u^n} \right) \quad (5.12)$$

$$f_4 = \left(\frac{M_{max} - M(s_{max})}{M_{max}} \right) \quad (5.13)$$

$$f_5 = \left(\frac{Q_{in}^n - Q_{in}(s_n)}{Q_{in}^n} \right) \quad (5.14)$$

El rendimiento del algoritmo genético puede verse afectado por los valores de las constantes necesarias para su implementación como puede ser la tasa de mutación.

Las constantes que configuran el algoritmo genético se deben escoger de forma que se logre un equilibrio entre tiempo de computación y precisión de la solución. Cada constante puede tener efectos contradictorios en esos factores. La elección depende del factor que sea más conveniente para el objetivo buscado. En este trabajo se ha buscado evitar caer en óptimos locales, como le puede suceder a los métodos tradicionales, por lo que se ha primado la precisión. Para ello es necesario disponer de una población diversificada, lo que conlleva mayor tiempo de cálculo. Una población diversa permite explorar gran cantidad de soluciones lo que hace más probable encontrar el óptimo global.

Se han llevado a cabo numerosas pruebas con los diferentes operadores: selección, mutación y cruce, así como con diferentes valores de las constantes del algoritmo, como tamaño de la población o tasa de mutación. A continuación se explican algunas de las pruebas realizadas en el proceso de selección de la configuración del algoritmo.

El tamaño de la población es uno de los parámetros más determinantes para el buen funcionamiento del algoritmo y tiene gran influencia en la diversidad de la población y en el tiempo de computación. Una población pequeña resta diversidad pero da la posibilidad de poder generar, en un corto espacio de tiempo, una gran cantidad de generaciones. Por otra parte, una población grande mantiene una gran diversidad, por lo que hay mayores posibilidades de encontrar el óptimo pero, por el contrario, necesita mucho tiempo de cálculo. Se han probado diferentes tamaños de población, con los datos de un mismo motor (Tabla 5.1), para hacer la comparación. En la Figura 5.1 se muestra el ajuste del mejor individuo y el de la media de la población para una población de 25 individuos y en la Figura 5.2 para una población de 100 individuos. Se observa que el ajuste globalmente tiende a bajar, pero entre dos iteraciones puede suceder que se incremente su valor. Esto es debido a que la función de ajuste se utiliza para determinar cuál es la mejor solución pero, además, las soluciones deben cumplir las restricciones. Por tanto, sucede que un individuo puede tener un mejor ajuste pero no cumple bien las restricciones y por ello otro individuo con peor ajuste, pero que cumple mejor con las restricciones, es elegido como la mejor solución. En la Tabla 5.2 se muestran los resultados numéricos de cada una de las poblaciones utilizadas para el mismo motor tras 50 generaciones. Se ha escogido una población de 100 individuos ya que, aunque todas las poblaciones lograron resultados similares, ésta demostró ser más robusta que poblaciones más pequeñas. Las poblaciones mayores de cien individuos no han presentado ventajas significativas. El tiempo de cálculo ha resultado ser proporcional al número de individuos, como cabe esperar. Aproximadamente, ha sido necesario un segundo de cálculo por individuo para las cincuenta iteraciones.

Tabla 5.1: Datos del motor utilizado para el ajuste del algoritmo

P_u^n [kW]	186	M_n [Nm]	2998
V [V]	2300	M_{arr} / M_n	0.71
F [Hz]	60	M_{max} / M_n	1.81
Nº polos	12	I_n [A]	72
n_n [rev./min.]	593	I_{arr} / I_n	3.94
η_n [%]	91.3		

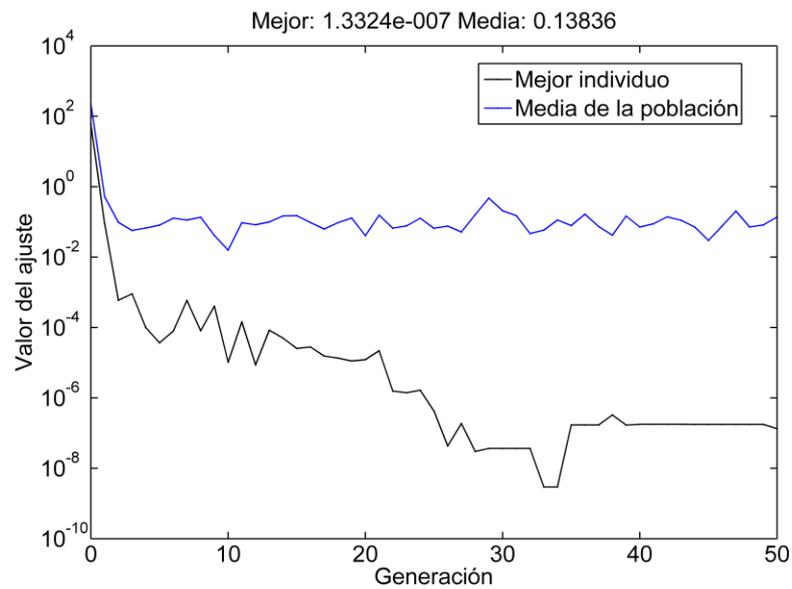


Figura 5.1: Progreso del ajuste para una población de 25 individuos

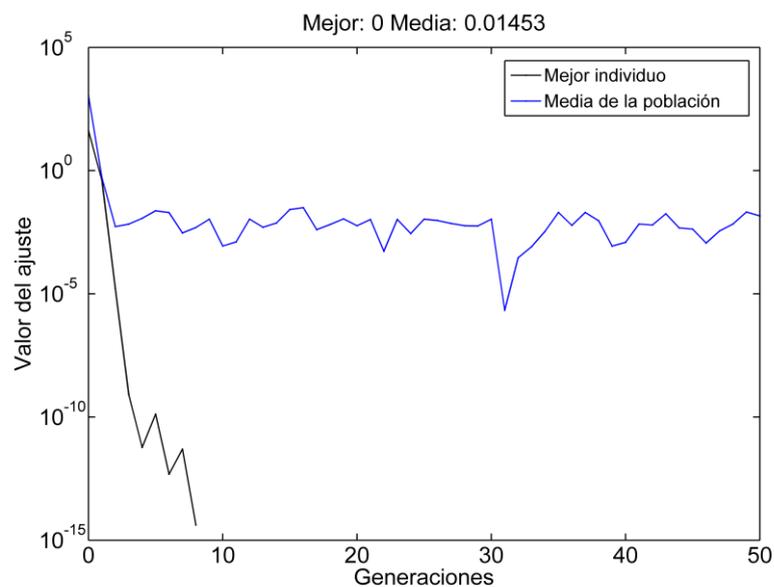


Figura 5.2: Progreso del ajuste para una población de 100 individuos

Tabla 5.2: Valores de los parámetros y errores para distintos tamaños de población

POBLACIÓN	25	50	75	100	150
R_I [p.u.]	0.012346	0.012346	0.012346	0.012346	0.012346
X_I [p.u.]	0.12119	0.12119	0.12119	0.12119	0.12119
R_{20} [p.u.]	0.008209	0.008209	0.008209	0.008209	0.008209
X_{20} [p.u.]	0.1101	0.1101	0.1101	0.1101	0.1101
R_{Fe} [p.u.]	31.68	31.68	31.68	31.68	31.68
X_m [p.u.]	1.1799	1.1799	1.1799	1.1799	1.1799
P_{const} [p.u.]	0.04713	0.04713	0.04713	0.04713	0.04713
Tiempo [s]	28.8	45.7	64.5	84.4	153.3
Error M_{arr}	$-1.34 \cdot 10^{-7}$	$6.26 \cdot 10^{-16}$	$-2.08 \cdot 10^{-16}$	$4.17 \cdot 10^{-16}$	$5.54 \cdot 10^{-10}$
Error M_{max}	$2.45 \cdot 10^{-5}$	$2.45 \cdot 10^{-5}$	$2.45 \cdot 10^{-5}$	$2.45 \cdot 10^{-5}$	$2.45 \cdot 10^{-5}$
Error P_u''	$2.88 \cdot 10^{-8}$	$1.56 \cdot 10^{-16}$	0	$-1.56 \cdot 10^{-16}$	$-6.56 \cdot 10^{-10}$
Error η_n	$-7.64 \cdot 10^{-8}$	$4.83 \cdot 10^{-16}$	$2.41 \cdot 10^{-16}$	$-2.41 \cdot 10^{-16}$	$-2.04 \cdot 10^{-9}$
Error $\cos\phi_n$	$8.26 \cdot 10^{-8}$	$-1.56 \cdot 10^{-16}$	0	$-1.56 \cdot 10^{-16}$	$1.51 \cdot 10^{-9}$
Error I_{arr}	$-6.55 \cdot 10^{-2}$	$-6.55 \cdot 10^{-2}$	$-6.55 \cdot 10^{-2}$	$-6.55 \cdot 10^{-2}$	$-6.55 \cdot 10^{-2}$

La operación de cruce permite generar nuevas soluciones a partir de otras dos potenciales soluciones. Es el operador que generación tras generación va mejorando a la población (posibles soluciones), guiándola hacia el óptimo. La tasa de cruce ejerce una gran influencia en la convergencia del algoritmo. Una tasa de cruce elevada hace que el algoritmo tienda a perder diversidad en pocas generaciones. Es conveniente dejar una parte de la población sin cruzar para conservar la diversidad y evitar una convergencia precoz hacia un óptimo local. Se han ensayado distintas tasas de cruce sobre un mismo motor y en la Tabla 5.3 se muestran los resultados numéricos. En las Figura 5.3 se muestra la evolución del ajuste para una tasa de cruce de 0.4 y en Figura 5.4 para una tasa de cruce de 0.9.

Otro factor que aporta diversidad es la mutación ya que introduce soluciones con nuevas características que pueden sacar a la población de un óptimo local. Sin embargo, los individuos mutados rara vez tienen un buen ajuste, ya que la mutación no tiene en cuenta la historia del resto de generaciones. Una elevada tasa de mutaciones introduce demasiados individuos no deseados, por lo que son recomendables valores reducidos de este parámetro. Se ha escogido una tasa de mutación de un 1%.

Tabla 5.3: Valores de los parámetros y errores para distintas tasas de cruce

TASA DE CRUCE	0.4	0.6	0.7	0.8	0.9
R_l [p.u.]	0.012346	0.012346	0.012346	0.012346	0.012346
X_l [p.u.]	0.12119	0.12119	0.12119	0.12119	0.12119
R_{20} [p.u.]	0.008209	0.008209	0.008209	0.008209	0.008209
X_{20} [p.u.]	0.1101	0.1101	0.1101	0.1101	0.1101
R_{Fe} [p.u.]	31.68	31.68	31.68	31.68	31.68
X_m [p.u.]	1.1799	1.1799	1.1799	1.1799	1.1799
P_{const} [p.u.]	0.04713	0.04713	0.04713	0.04713	0.04713
Tiempo [s]	81.4	82.3	82.9	85.3	84.7
Error M_{arr}	$1.07 \cdot 10^{-6}$	$-1.25 \cdot 10^{-15}$	0	$4.17 \cdot 10^{-16}$	0
Error M_{max}	$2.61 \cdot 10^{-5}$	$2.46 \cdot 10^{-5}$	$2.46 \cdot 10^{-5}$	$2.46 \cdot 10^{-5}$	$2.46 \cdot 10^{-5}$
Error P_u^n	$-1.42 \cdot 10^{-6}$	$6.24 \cdot 10^{-16}$	0	$9.36 \cdot 10^{-16}$	$-1.56 \cdot 10^{-16}$
Error η_n	$-2.14 \cdot 10^{-6}$	$1.57 \cdot 10^{-15}$	0	$9.66 \cdot 10^{-16}$	$4.83 \cdot 10^{-16}$
Error $\cos\phi_n$	$-3.36 \cdot 10^{-7}$	$4.69 \cdot 10^{-16}$	$-1.56 \cdot 10^{-16}$	$1.09 \cdot 10^{-15}$	$-1.56 \cdot 10^{-16}$
Error I_{arr}	$-6,54 \cdot 10^{-2}$	$-6,54 \cdot 10^{-2}$	$-6,54 \cdot 10^{-2}$	$-6,54 \cdot 10^{-2}$	$-6,54 \cdot 10^{-2}$

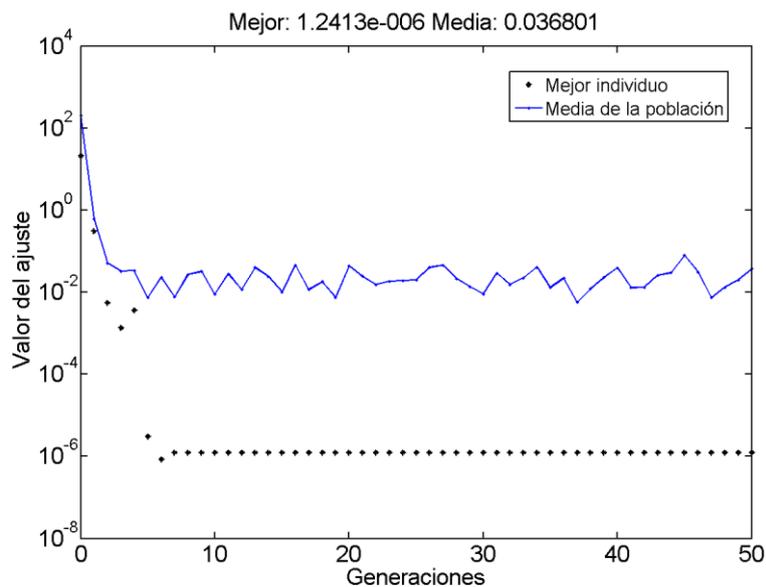


Figura 5.3: Progreso del ajuste para una tasa de cruce de 0.4

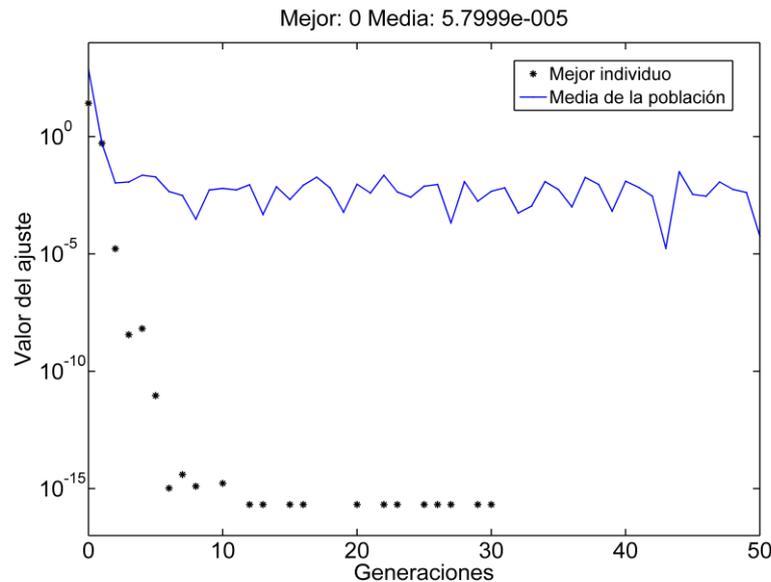


Figura 5.4: Progreso del ajuste para una tasa de cruce de 0.9

Tras numerosas pruebas con diferentes funciones de selección, cruce y mutación, la configuración que mejores resultados ha proporcionado para la identificación del modelo de la mayoría de los motores ha sido:

- Población: 100 individuos
- Operador de selección: Estocástico uniforme
- Elitismo: 2 individuos por iteración
- Tasa de cruce: 0.8
- Tasa de mutación: 0.01
- Operador de mutación: Multipunto
- Operador de cruce: Heurístico
- Criterios de parada: Ajuste = $1 \cdot 10^{-16}$ o límite de 100 generaciones.

5.3. Resultados

Al analizar los resultados de las diferentes pruebas, empleando diversos operadores de cruce y selección, se observaron algunas diferencias en cuanto a velocidad de convergencia pero no en la obtención de los resultados pues en todos los casos fueron similares. Las soluciones obtenidas durante dichas pruebas son una muestra de la fiabilidad de la identificación mediante algoritmo genético. Como se dijo anteriormente, los algoritmos genéticos garantizan un buen resultado, pero no garantiza que sea el mejor. El algoritmo genético ha sido probado con los datos de catálogo de diferentes motores utilizando las configuraciones comentadas anteriormente. Se han utilizado tanto el modelo de

circuito de jaula simple con parámetros ajustados con el deslizamiento como el modelo de circuito de doble jaula.

En algunos casos el algoritmo no ha sido capaz de encontrar una buena solución a la primera. Si, prematuramente, un individuo se reproduce demasiado rápido, se pierde la diversidad de la población y, conforme pasan las generaciones, se hace más difícil que el algoritmo sea capaz de generar individuos mejores. Este hecho ha estado detrás de casi todos los casos de falta de convergencia observados en este trabajo. Al tratarse de un método con una componente aleatoria, la población inicial generada es distinta cada vez que se ejecuta el algoritmo. Por tanto, cuando el algoritmo no ha sido capaz de encontrar una solución satisfactoria, se ha repetido la búsqueda. En casi todos los casos ha sido suficiente una segunda búsqueda para encontrar una buena solución. Del mismo modo, en algunas pruebas se ha llegado a mejores soluciones que en otras, aunque todas con un error global cercano a cero. Por tanto, se ha optado por repetir la búsqueda un número determinado de veces y elegir el mejor ajuste.

5.3.1. Modelo de circuito de jaula simple con parámetros ajustados con el deslizamiento

El método ha sido probado utilizando el modelo de jaula simple con parámetros ajustados con el deslizamiento, Figura 5.5, con datos de motores de diversos catálogos. Como sucedió al utilizar el método de los mínimos cuadrados, de nuevo se obtuvieron los mejores resultados utilizando este modelo de circuito para los motores de alta tensión. Todos los parámetros obtenidos resultaron positivos.

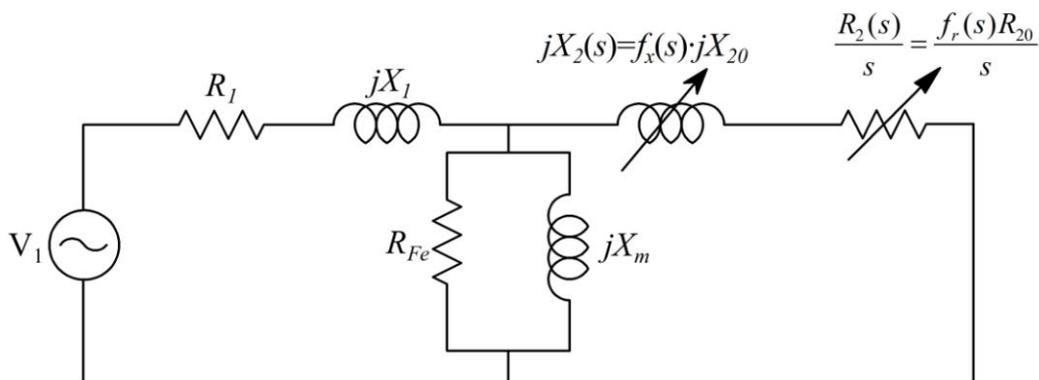


Figura 5.5: Modelo de circuito de jaula simple

En el catálogo de motores NEMA probado con el método de los mínimos cuadrados, aparecían varios motores para los que el algoritmo no logró converger hacia una solución factible. Tras repetidas pruebas, el algoritmo genético no ha sido capaz de encontrar una solución satisfactoria para estos mismos motores.

La Tabla 5.4 muestra los parámetros obtenidos en seis motores de alta tensión seleccionados y los errores obtenidos al calcular determinadas magnitudes utilizando el criterio del par de arranque. Los resultados son idénticos a los obtenidos utilizando el método de los mínimos cuadrados. En el anexo electrónico se encuentran los resultados de los más de 700 motores probados.

Tabla 5.4: Resultados de la identificación de parámetros y errores de seis motores seleccionados

Motor	1	2	3	4	5	6
Tipo	NEMA	NEMA	NEMA	IEC	IEC	IEC
Potencia [kW]	588	918	588	560	560	750
Tensión [V]	2300	2300	2300	3000	10000	3000
Frecuencia [Hz]	60	60	60	50	50	50
Nº Polos	6	6	12	6	4	4
R_l [Ω]	0.113	0.063	0.100	0.127	1.073	0.083
R_l [pu]	0.0162	0.0141	0.0161	0.0079	0.0060	0.0070
X_l [Ω]	1.207	0.598	0.962	0,883	14,958	1,084
X_l [pu]	0.173	0.135	0.152	0,055	0,084	0,090
R_{20} [Ω]	0.075	0.042	0.067	0,085	0,715	0,056
R_{20} [pu]	0.0108	0.0094	0.0107	0,0053	0,0040	0,0046
X_{20} [Ω]	0.686	0.640	1.087	2,263	14,537	1,287
X_{20} [pu]	0.098	0.144	0.171	0,141	0,081	0,107
R_{Fe} [Ω]	592.33	438.46	490.45	1620,33	11928,62	1125,69
R_{Fe} [pu]	84.98	98.97	77.26	100,82	66,80	93,81
X_m [Ω]	18.498	11.426	13.382	34,756	334,144	34,881
X_m [pu]	2.654	2.576	2.107	2,163	1,871	2,907
P_{const} [W]	14470.5	20287.5	17299.1	10161,6	14778,5	14328,9
P_{const} [pu]	0.0243	0.0218	0.0290	0,0181	0,0264	0,0191
Error M_{arr}	0	0	0	$-3,07 \cdot 10^{-16}$	$-1,26 \cdot 10^{-15}$	$-1,18 \cdot 10^{-16}$
Error M_{max}	$-3,83 \cdot 10^{-9}$	$8,86 \cdot 10^{-8}$	$6,80 \cdot 10^{-6}$	$6,21 \cdot 10^{-7}$	$1,95 \cdot 10^{-7}$	$2,21 \cdot 10^{-6}$
Error P_u^n	0	$3,76 \cdot 10^{-16}$	$1,95 \cdot 10^{-16}$	$2,08 \cdot 10^{-16}$	$6,23 \cdot 10^{-16}$	$-1,55 \cdot 10^{-16}$
Error η_n	0	0	0	$-1,15 \cdot 10^{-16}$	$5,19 \cdot 10^{-15}$	$-2,29 \cdot 10^{-16}$
Error $\cos\phi_n$	$1,33 \cdot 10^{-16}$	$1,35 \cdot 10^{-16}$	0	0	$-9,36 \cdot 10^{-16}$	0
Error I_{arr}	-0.127	-0.111	-0.057	0,074	-0,028	-0,029

Se han realizado pruebas con diversas funciones objetivo, ajustando la intensidad de arranque o el par de arranque obteniéndose similares valores de convergencia en ambos casos. Cuando se utilizan conjuntamente en la función de ajuste la intensidad de arranque y el del par de arranque, el algoritmo no es capaz de encontrar una solución aceptable. Tanto los errores de esas dos magnitudes como las de las demás empeoran notablemente y no se cumplen las restricciones de igualdad exigidas al algoritmo. En este aspecto, el algoritmo genético no proporciona ventajas sobre el método de los mínimos cuadrados. El algoritmo

genético no ha sido capaz de encontrar un conjunto de parámetros que permita ajustar los valores del par de arranque y la intensidad de arranque conjuntamente, que den lugar a unos errores aceptables, utilizando un modelo de jaula simple. La intensidad de arranque y el par de arranque no son magnitudes independientes sino que están relacionadas por una constante que depende de los valores de los parámetros del modelo de circuito. En la Tabla 5.5 se muestran los parámetros obtenidos para un mismo motor utilizando el criterio de la intensidad de arranque y el del par de arranque.

Tabla 5.5: Tabla comparativa de los criterios utilizados

CRITERIO	M_{arr}	I_{arr}
Tipo	NEMA	NEMA
Potencia [kW]	186	186
Tensión [V]	2300	2300
Frecuencia [Hz]	60	60
Nº Polos	12	12
R_l [Ω]	0.3495	0.3735
R_l [pu]	0.0123	0.0131
X_l [Ω]	3.437	2.226
X_l [pu]	0.1211	0.0785
R_{20} [Ω]	0.233	0.249
R_{20} [pu]	$8.21 \cdot 10^{-3}$	$8.76 \cdot 10^{-3}$
X_{20} [Ω]	3.124	4.843
X_{20} [pu]	0.110	0.171
R_{Fe} [Ω]	898.9	1025.5
R_{Fe} [pu]	31.68	36.14
X_m [Ω]	33.482	35.135
X_m [pu]	1.180	1.238
P_{const} [W]	8786.7	8428.1
P_{const} [pu]	$4.71 \cdot 10^{-2}$	$4.52 \cdot 10^{-2}$
Error M_{arr}	$-6.41 \cdot 10^{-16}$	0.22792
Error M_{max}	$2.55 \cdot 10^{-5}$	$8.04 \cdot 10^{-6}$
Error P_u^n	$1.56 \cdot 10^{-16}$	$1.56 \cdot 10^{-16}$
Error η_n	$-1.21 \cdot 10^{-16}$	0
Error $\cos\phi_n$	$1.56 \cdot 10^{-16}$	$1.56 \cdot 10^{-16}$
Error I_{arr}	$-7.96 \cdot 10^{-2}$	$-2.01 \cdot 10^{-16}$

La Tabla 5.6 muestra algunos datos que se producen durante el proceso iterativo. Para cada iteración, pueden verse tanto el valor de la función objetivo como el valor de la restricción que tiene mayor error. También se observa el número de evaluaciones de la función objetivo que se han llevado a cabo. La última columna indica el número de generaciones que ha sobrevivido el mejor individuo. Este

valor se ha utilizado como criterio de parada. Si tras cierto número de generaciones ha sobrevivido un mismo individuo, probablemente se ha llegado a una buena solución.

Tabla 5.6: Datos durante la evolución de la población algoritmo genético

Generación	Evaluaciones de función	Mejor ajuste	Máxima restricción	Supervivencia del mejor individuo
1	3300	0.0446231	0.1563	0
2	8400	$1.62 \cdot 10^{-6}$	$6.06 \cdot 10^{-4}$	0
3	13300	$2.95 \cdot 10^{-8}$	$6.03 \cdot 10^{-7}$	0
4	18400	$1.96 \cdot 10^{-8}$	$2.31 \cdot 10^{-8}$	0
5	23500	$2.47 \cdot 10^{-11}$	$6.06 \cdot 10^{-11}$	0
6	28600	$1.49 \cdot 10^{-15}$	$3.70 \cdot 10^{-11}$	0
7	33700	$1.27 \cdot 10^{-13}$	$1.28 \cdot 10^{-13}$	0
8	38800	$1.22 \cdot 10^{-13}$	$1.22 \cdot 10^{-13}$	0
9	43900	0	$4.68 \cdot 10^{-16}$	0
10	49000	0	$4.68 \cdot 10^{-16}$	1
11	52200	0	$3.12 \cdot 10^{-16}$	2
12	55400	0	$3.12 \cdot 10^{-16}$	3
13	58600	0	$3.12 \cdot 10^{-16}$	4
14	61800	0	$3.12 \cdot 10^{-16}$	5
15	65000	0	$3.12 \cdot 10^{-16}$	6
16	68200	0	$3.12 \cdot 10^{-16}$	7
17	71400	0	$3.12 \cdot 10^{-16}$	8
18	74600	0	$3.12 \cdot 10^{-16}$	9
19	77800	0	$3.12 \cdot 10^{-16}$	10
20	81000	0	$3.12 \cdot 10^{-16}$	11

5.3.2. Modelo de circuito de doble jaula

Para aplicar el algoritmo genético al modelo de circuito de doble jaula, Figura 5.6, de forma similar a la utilizada en el método de los mínimos cuadrados, es preciso resolver de forma previa un problema de mínimos cuadrados utilizando un modelo de jaula simple para hallar el punto de deslizamiento de par máximo. A diferencia del modelo de circuito de jaula simple, el modelo de doble jaula no tiene una expresión sencilla para el par máximo de la que extraer el dato del deslizamiento de par máximo. El tiempo utilizado por el método de los mínimos cuadrados para este paso es insignificante comparado con el que necesita el algoritmo genético para resolver el modelo completo. También se han realizado pruebas tratando de introducir el deslizamiento de par máximo como una incógnita del sistema. Para ello, se ha calculado el deslizamiento de par máximo

hallando el máximo de la función del par, de forma numérica, para cada iteración. Los deslizamientos calculados de esta forma no han diferido en gran medida de los calculados mediante el modelo de circuito de jaula simple. Sin embargo, la introducción de un nuevo parámetro y la búsqueda de forma numérica del máximo de una función ha resultado un método ineficiente y no ha aportado ventajas significativas. Por tanto se ha optado por el método de calcular el deslizamiento haciendo uso de un modelo de circuito de jaula simple.

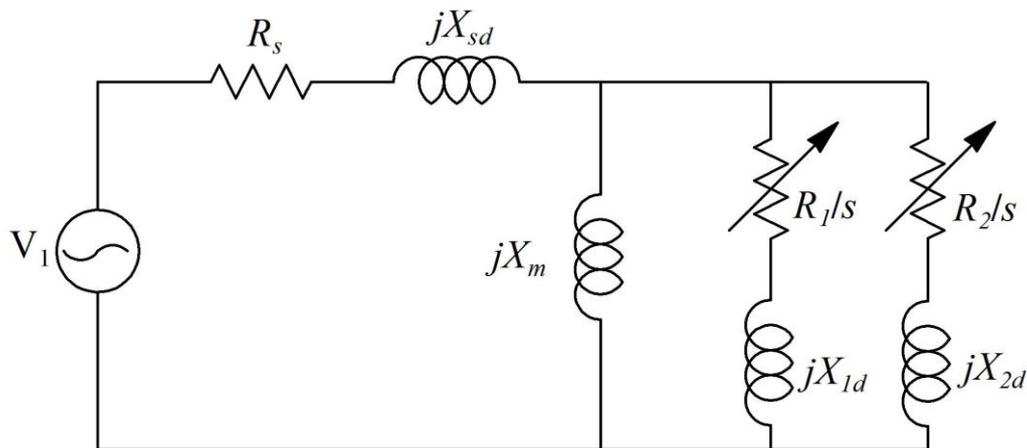


Figura 5.6: Modelo de circuito de doble jaula

Al igual que con el método de los mínimos cuadrados, el algoritmo ha convergido para todos los motores de alta tensión y ha encontrado las mismas dificultades en los de baja tensión. La Tabla 5.7 muestra los parámetros obtenidos en seis motores seleccionados de alta tensión y los errores obtenidos al calcular determinadas magnitudes. En los casos en los que se alcanzó la convergencia, los parámetros obtenidos han sido exactamente los mismos que los obtenidos mediante el método de los mínimos cuadrados. Los errores a su vez han sido del mismo orden que con el método de los mínimos cuadrados.

5.4. Otras pruebas realizadas

Los resultados de las pruebas realizadas han mostrado que los niveles de error de las soluciones encontradas son, en general, muy pequeños. Para tratar de determinar si el algoritmo encuentra el óptimo del problema se ha llevado a cabo un test de repetición. Se ha probado el algoritmo genético con los datos de un motor, (Tabla 5.8), repitiendo el experimento 50 veces, utilizando la misma configuración del algoritmo. La Tabla 5.9 muestra de forma resumida los resultados de la prueba. La solución hallada en los 50 ensayos ha sido prácticamente idéntica, con una máxima diferencia de un error de $3.90 \cdot 10^{-13}$. Una gran cantidad de

valores de error han resultado por debajo de la precisión de la máquina (errores que aparecen con valor cero). Por tanto, aunque no hay garantía de óptimo, la solución está muy cerca de ser óptima en todos los casos.

Tabla 5.7: Parámetros y errores de seis motores seleccionados

Motor	1	2	3	4	5	6
Tipo	NEMA	NEMA	NEMA	IEC	IEC	IEC
Potencia [kW]	588	918	588	560	560	750
Tensión [V]	2300	2300	2300	3000	10000	3000
Frecuencia [Hz]	60	60	60	50	50	50
Nº Polos	6	6	12	6	4	4
R_l [Ω]	0.1069	0.0569	0.0846	0.0926	0.8333	0.0648
R_l [pu]	0.0121	0.0100	0.0095	0.0058	0.0047	0.0054
R_2 [Ω]	0.274	0.162	0.334	0.756	5.298	0.396
R_2 [pu]	0.0309	0.0285	0.0377	0.0470	0.0297	0.0330
X_m [Ω]	18.021	11.000	12.805	32.418	323.830	33.121
X_m [pu]	2.032	1.938	1.444	2.017	1.813	2.760
X_{sd} [Ω]	0.969	0.578	1.015	1.517	15.651	1.205
X_{sd} [pu]	0.109	0.102	0.114	0.094	0.088	0.100
X_{1d} [Ω]	1.699	1.116	1.495	1.678	17.017	1.427
X_{1d} [pu]	0.196	0.197	0.169	0.104	0.095	0.119
X_{2d} [Ω]	0.484	0.289	0.507	0.759	7.826	0.603
X_{2d} [pu]	0.0546	0.0509	0.0572	0.0472	0.0438	0.0502
R_s [Ω]	0.160	0.085	0.127	0.139	1.250	0.097
R_s [pu]	0.0181	0.0151	0.0143	0.0086	0.0070	0.0081
Error M_{arr}	$6.49 \cdot 10^{-16}$	$4.55 \cdot 10^{-16}$	0	0	0	$-4.74 \cdot 10^{-16}$
Error M_{max}	$-1.88 \cdot 10^{-16}$	$1.67 \cdot 10^{-16}$	0	0	0	$-1.42 \cdot 10^{-16}$
Error P_u^n	$-3.90 \cdot 10^{-16}$	$-3.37 \cdot 10^{-15}$	0	$2.08 \cdot 10^{-16}$	0	$-3.26 \cdot 10^{-16}$
Error I_{arr}	$8.34 \cdot 10^{-16}$	$-5.56 \cdot 10^{-15}$	0	$1.42 \cdot 10^{-16}$	0	$-2.87 \cdot 10^{-16}$

Tabla 5.8: Datos del motor utilizado en la prueba de repetición

Datos del motor	
Tipo	NEMA
Potencia [kW]	186
Tensión [V]	2300
Frecuencia [Hz]	60
Nº Polos	12
M_n [Nm]	2997.7
M_{arr} [Nm]	2128.4
I_{arr} [A]	283.68
$\cos\phi_n$	0.71

Tabla 5.9: Resultados de la prueba de repetición

Modelo de circuito	Jaula simple con parámetros ajustados con el deslizamiento	Max. Error M_{arr}	$1.00 \cdot 10^{-13}$
Criterio utilizado	M_{arr}	Min. Error M_{arr}	0
Tipo	NEMA		
Potencia [kW]	186	Max. Error M_{max}	$2.55 \cdot 10^{-5}$
Tensión [V]	2300	Min. Error M_{max}	$2.55 \cdot 10^{-5}$
Frecuencia [Hz]	60		
Nº Polos	12	Max. Error P_u^n	$1.75 \cdot 10^{-13}$
R_l [Ω]	0.3495	Min. Error P_u^n	0
R_j [pu]	0.0123		
X_l [Ω]	3.437	Max. Error η_n	$3.90 \cdot 10^{-13}$
X_j [pu]	0.1211	Min. Error η_n	0
R_{20} [Ω]	0.233		
R_{20} [pu]	$8.21 \cdot 10^{-3}$	Max. Error $\cos\phi_n$	$7.94 \cdot 10^{-14}$
X_{20} [Ω]	3.124	Min. Error $\cos\phi_n$	0
X_{20} [pu]	0.110		
R_{Fe} [Ω]	898.9	Max. Error I_{arr}	$-7.96 \cdot 10^{-2}$
R_{Fe} [pu]	31.68	Min. Error I_{arr}	$-7.96 \cdot 10^{-2}$
X_m [Ω]	33.482		
X_m [pu]	1.180		
P_{const} [W]	8786.7		
P_{const} [pu]	$4.71 \cdot 10^{-2}$		

Una de las bondades de los algoritmos genéticos, es que no necesitan un punto de partida cercano al óptimo para encontrar una buena solución. Para comprobar si el algoritmo genético mejora de alguna manera al proporcionarle una solución inicial, se han comparado dos casos: uno sin utilizar una solución inicial y otro suministrando una solución aproximada a la óptima. Se han utilizado los mismos datos del motor de la prueba de repetición, Tabla 5.8. El tiempo utilizado por el algoritmo genético utilizando una solución inicial, ha sido prácticamente el mismo que sin utilizar una solución inicial. Sin embargo, el algoritmo genético con una solución inicial se ha mostrado más robusto ya que siempre ha convergido hacia una buena solución mientras que, el algoritmo que no hace uso de la misma, ha convergido varias veces a soluciones con niveles altos de error. En la Tabla 5.10 se muestran seis ejecuciones del algoritmo genético sin utilizar una solución inicial. Se observa que de las seis ejecuciones, dos de ellas han convergido a un mismo mínimo local y las otras cuatro han convergido prácticamente a la misma solución con niveles pequeños de error. En la Tabla 5.11 se muestran seis ejecuciones del algoritmo genético utilizando una solución de partida. En los seis casos el algoritmo convergió a soluciones con niveles bajos de error. Por tanto, la principal ventaja de utilizar una solución inicial, ha sido el aumento de la fiabilidad del algoritmo genético.

Tabla 5.10: Pruebas sin la utilización de una solución inicial

Prueba nº	1	2	3	4	5	6
R_l [Ω]	0.1748	0.3057	0.3057	0.3057	0.1748	0.3057
R_l [pu]	0.00616	0.01077	0.01077	0.01077	0.00616	0.01077
R_2 [Ω]	0.4906	1.0698	1.0698	1.0698	0.4906	1.0698
R_2 [pu]	0.0173	0.0377	0.0377	0.0377	0.0173	0.0377
X_m [Ω]	170.26	31.78	31.78	31.78	170.26	31.78
X_m [pu]	6.00	1.12	1.12	1.12	6.00	1.12
X_{sd} [Ω]	2.83	3.30	3.30	3.30	2.83	3.30
X_{sd} [pu]	0.0996	0.1163	0.1163	0.1163	0.0996	0.1163
X_{1d} [Ω]	21.98	4.879	4.879	4.879	21.98	4.879
X_{1d} [pu]	0.7748	0.1722	0.1722	0.1722	0.7748	0.1722
X_{2d} [Ω]	1.41	1.65	1.65	1.65	1.41	1.65
X_{2d} [pu]	0.0498	0.0582	0.0582	0.0582	0.0498	0.0582
R_s [Ω]	0.2622	0.4586	0.4586	0.4586	0.2622	0.4586
R_s [pu]	0.00924	0.01616	0.01616	0.01616	0.00924	0.01616
Error M_{arr}	-0.0477	0	0	0	-0.0477	0
Error M_{max}	-0.0654	0	0	$-1.67 \cdot 10^{-16}$	-0.0654	$-1.67 \cdot 10^{-16}$
Error P_u^n	-0.00366	0	0	0	-0.00366	0
Error I_{arr}	0.1118	$2.00 \cdot 10^{-16}$	$2.00 \cdot 10^{-16}$	$2.00 \cdot 10^{-16}$	0.1118	$2.00 \cdot 10^{-16}$
Tiempo [s]	14.1	22.3	20.2	19.2	12.6	32.3

Tabla 5.11: Pruebas con la utilización de una solución inicial

Prueba nº	1	2	3	4	5	6
R_l [Ω]	0.3057	0.3057	0.3057	0.3057	0.3057	0.3057
R_l [pu]	0.01077	0.01077	0.01077	0.01077	0.01077	0.01077
R_2 [Ω]	1.0698	1.0698	1.0698	1.0698	1.0698	1.0698
R_2 [pu]	0.0377	0.0377	0.0377	0.0377	0.0377	0.0377
X_m [Ω]	31.78	31.78	31.78	31.78	31.78	31.78
X_m [pu]	1.12	1.12	1.12	1.12	1.12	1.12
X_{sd} [Ω]	3.30	3.30	3.30	3.30	3.30	3.30
X_{sd} [pu]	0.1163	0.1163	0.1163	0.1163	0.1163	0.1163
X_{1d} [Ω]	4.879	4.879	4.879	4.879	4.879	4.879
X_{1d} [pu]	0.1722	0.1722	0.1722	0.1722	0.1722	0.1722
X_{2d} [Ω]	1.65	1.65	1.65	1.65	1.65	1.65
X_{2d} [pu]	0.0582	0.0582	0.0582	0.0582	0.0582	0.0582
R_s [Ω]	0.4586	0.4586	0.4586	0.4586	0.4586	0.4586
R_s [pu]	0.01616	0.01616	0.01616	0.01616	0.01616	0.01616
Error M_{arr}	0	0	0	0	0	$2.13 \cdot 10^{-16}$
Error M_{max}	$5.02 \cdot 10^{-16}$	$1.67 \cdot 10^{-16}$	$1.67 \cdot 10^{-16}$	0	0	$-2.51 \cdot 10^{-15}$
Error P_u^n	0	$-3.12 \cdot 10^{-16}$	0	0	0	$3.12 \cdot 10^{-15}$
Error I_{arr}	$-8.01 \cdot 10^{-16}$	$2.00 \cdot 10^{-16}$	0	0	$2.00 \cdot 10^{-16}$	0
Tiempo [s]	24.2	22.9	20.1	25.6	23.5	20.9

Se ha investigado la influencia de las tolerancias de los datos de los catálogos sobre los resultados de la identificación. Como se explicó anteriormente, los datos proporcionados por el fabricante están sometidos a amplios márgenes de variación ya que la norma que los regula permite en ciertos casos hasta un 20% de desviación sobre el valor real de un dato. Además, esto se suma a que los datos que figuran en un catálogo no se refieren a una máquina en concreto sino que son valores promedio de un conjunto de máquinas a las que se le han realizado pruebas de laboratorio. La identificación se ha mostrado, en algunos casos, relativamente sensible a los errores en los datos del catálogo. La Tabla 5.12 muestra las diferencias obtenidas en el cálculo de los parámetros de un motor IEC de baja tensión variando tan solo un 2% su potencia nominal. En ese caso se produce una variación importante en los niveles de los errores las magnitudes calculadas.

Tabla 5.12: Diferencias entre parámetros obtenidos con datos originales y modificados

Datos	Originales	Modificados
Tipo	IEC	IEC
Potencia [kW]	4.00	4.08
Tensión [V]	400	400
Frecuencia [Hz]	50	50
Nº Polos	2	2
R_1 [Ω]	1.456	1.437
R_2 [Ω]	3.911	3.792
X_m [Ω]	53.86	52.97
X_{sd} [Ω]	1.666	1.651
X_{1d} [Ω]	0.8330	0.9390
X_{2d} [Ω]	0.8330	0.8254
R_s [Ω]	2.184	2.155
Error M_{arr}	$2.47 \cdot 10^{-3}$	0
Error M_{max}	$-2.61 \cdot 10^{-3}$	$-3.01 \cdot 10^{-16}$
Error P_u^n	$3.09 \cdot 10^{-3}$	$2.23 \cdot 10^{-16}$
Error I_{arr}	$-3.61 \cdot 10^{-3}$	0

Se han realizado un ensayo modificando los datos de entrada, variando su valor en un tanto por ciento. Las magnitudes que se han modificado han sido: P_u^n , M_{max} , M_{arr} y M_n . La Tabla 5.13 muestra la variación realizada en los datos en tanto por ciento, los valores de los parámetros encontrados y los errores para un motor IEC de alta tensión. El algoritmo converge en todos los casos y los niveles de error de todas las magnitudes son bajos. La Tabla 5.14 muestra los resultados de la misma prueba para un motor de baja tensión. En este caso se observa que el algoritmo se ha mostrado más sensible a los datos de entrada. Existen grandes variaciones de los parámetros al variar las magnitudes de entrada. Este hecho concuerda con los resultados obtenidos en los ensayos realizados con los datos de catálogo de

motores de baja tensión en los que los niveles de error han sido elevados en un número considerable de motores.

Tabla 5.13: Prueba de sensibilidad a los datos de entrada de un motor IEC de alta tensión

Tipo motor		Motor IEC, 132 kW, 3000 V, 2 polos, 50 Hz									
Modelo de circuito		Jaula simple con parámetros ajustados con del deslizamiento									
Criterio		M_{arr}									
Dato	Var.	Parámetros							Errores		
		R_l [Ω]	X_l [Ω]	R_{20} [Ω]	X_{20} [Ω]	R_{Fe} [Ω]	X_m [Ω]	P_{const} [W]	M_{arr}	M_{max}	P_u^n
P_u^n	Nom.	0.87	6.13	0.58	5.34	3774.2	256.7	4306.2	$6.7 \cdot 10^{-16}$	$1.4 \cdot 10^{-5}$	$-2.2 \cdot 10^{-16}$
	1%	0.86	6.08	0.57	5.42	3736.1	256.7	4350.2	0	$1.4 \cdot 10^{-5}$	0
	2%	0.84	6.02	0.56	5.50	3698.7	256.7	4394.2	$-3.4 \cdot 10^{-16}$	$1.3 \cdot 10^{-5}$	$-2.2 \cdot 10^{-16}$
	5%	0.83	5.84	0.55	5.73	3590.7	257.3	4526.5	$3.4 \cdot 10^{-16}$	$1.3 \cdot 10^{-5}$	0
	10%	0.78	5.58	0.52	6.11	3423.8	259.5	4747.9	0	$1.2 \cdot 10^{-5}$	0
	-1%	0.87	6.20	0.58	5.26	3813.2	256.7	4262.2	0	$1.4 \cdot 10^{-5}$	0
	-2%	0.89	6.26	0.59	5.18	3852.9	256.9	4218.3	$1.2 \cdot 10^{-16}$	$1.4 \cdot 10^{-5}$	$1.1 \cdot 10^{-16}$
	-5%	0.92	6.45	0.61	4.93	3977.2	257.6	4086.8	$-5.6 \cdot 10^{-16}$	$1.4 \cdot 10^{-5}$	$2.3 \cdot 10^{-16}$
M_{max}	Nom.	0.86	6.13	0.57	5.34	3774.2	256.7	4306.2	$6.7 \cdot 10^{-16}$	$1.4 \cdot 10^{-5}$	$-2.2 \cdot 10^{-16}$
	1%	0.86	6.24	0.57	5.08	3769.0	253.9	4307.1	$-3.4 \cdot 10^{-16}$	$1.3 \cdot 10^{-5}$	0
	2%	0.86	6.35	0.57	4.83	3763.9	251.3	4308.1	$-2.2 \cdot 10^{-16}$	$1.4 \cdot 10^{-5}$	0
	5%	0.86	6.65	0.57	4.11	3749.2	244.1	4311.2	$6.7 \cdot 10^{-16}$	$1.3 \cdot 10^{-5}$	0
	10%	0.86	7.11	0.57	3.04	3726.8	234.1	4316.8	0	$1.1 \cdot 10^{-5}$	0
	-1%	0.87	6.02	0.58	5.61	3779.6	259.6	4305.3	0	$1.4 \cdot 10^{-5}$	0
	-2%	0.87	5.90	0.58	5.89	3785.1	262.7	4304.5	$-2.2 \cdot 10^{-16}$	$1.4 \cdot 10^{-5}$	0
	-5%	0.87	5.53	0.58	6.78	3802.4	273.1	4302.4	$1.1 \cdot 10^{-16}$	$1.3 \cdot 10^{-5}$	0
M_{arr}	Nom.	0.86	6.13	0.57	5.34	3774.2	256.6	4306.1	$6.7 \cdot 10^{-16}$	$1.3 \cdot 10^{-5}$	$-2.2 \cdot 10^{-16}$
	1%	0.86	6.02	0.57	5.47	3780.3	256.9	4304.3	$-1.7 \cdot 10^{-15}$	$1.4 \cdot 10^{-5}$	0
	2%	0.86	5.91	0.57	5.60	3786.3	257.3	4302.6	$2.1 \cdot 10^{-16}$	$1.4 \cdot 10^{-5}$	0
	5%	0.86	5.58	0.57	5.99	3804.4	258.3	4297.4	0	$1.4 \cdot 10^{-5}$	0
	10%	0.86	5.05	0.57	6.63	3833.9	260.1	4289.2	$-1.0 \cdot 10^{-15}$	$1.4 \cdot 10^{-5}$	0
	-1%	0.86	6.24	0.57	5.20	3768.1	256.3	4308.0	0	$1.4 \cdot 10^{-5}$	0
	-2%	0.86	6.36	0.57	5.07	3761.9	256.0	4309.8	$1.1 \cdot 10^{-16}$	$1.3 \cdot 10^{-5}$	0
	-5%	0.86	6.71	0.57	4.67	3743.3	255.2	4315.5	$9.4 \cdot 10^{-16}$	$1.3 \cdot 10^{-5}$	0
M_n	Nom.	0.87	6.13	0.58	5.34	3774.2	256.6	4306.1	$6.7 \cdot 10^{-16}$	$1.4 \cdot 10^{-5}$	$-2.2 \cdot 10^{-16}$
	1%	0.87	6.13	0.58	5.21	3775.0	254.1	4305.3	$2.2 \cdot 10^{-16}$	$1.4 \cdot 10^{-5}$	0
	2%	0.87	6.13	0.58	5.08	3775.8	251.8	4304.4	0	$1.4 \cdot 10^{-5}$	0
	5%	0.87	6.12	0.58	4.71	3778.1	245.2	4302.0	$-4.2 \cdot 10^{-16}$	$1.4 \cdot 10^{-5}$	0
	10%	0.87	6.10	0.58	4.15	3781.6	235.8	4298.6	$-2.0 \cdot 10^{-16}$	$1.5 \cdot 10^{-5}$	0
	-1%	0.87	6.13	0.58	5.47	3773.4	259.2	4307.1	$-1.1 \cdot 10^{-16}$	$1.4 \cdot 10^{-5}$	0
	-2%	0.86	6.13	0.57	5.61	3772.6	261.9	4308.0	$3.4 \cdot 10^{-16}$	$1.3 \cdot 10^{-5}$	0
	-5%	0.86	6.13	0.57	6.05	3770.0	270.9	4311.2	$3.5 \cdot 10^{-16}$	$1.3 \cdot 10^{-5}$	0
-10%	0.86	6.12	0.57	6.87	3765.2	289.1	4317.5	$-3.7 \cdot 10^{-16}$	$1.2 \cdot 10^{-5}$	0	

Tabla 5.14: Prueba de sensibilidad a los datos de entrada de un motor IEC de baja tensión

Tipo motor		Motor IEC, 4 kW, 400 V, 2 polos, 50 Hz										
Modelo de circuito		Jaula simple con parámetros ajustados con del deslizamiento										
Criterio		M_{arr}										
Dato	Var.	Parámetros							Errores			
		R_l [Ω]	X_l [Ω]	R_{20} [Ω]	X_{20} [Ω]	R_{Fe} [Ω]	X_m [Ω]	P_{const} [W]	M_{arr}	M_{max}	P_u^n	
P_u^n	Nom.	1.47	3.41	0.98	$4.00 \cdot 10^{-3}$	905.9	59.9	285.6	$4.3 \cdot 10^{-3}$	$-7.0 \cdot 10^{-3}$	$1.3 \cdot 10^{-3}$	
	1%	1.45	3.42	0.97	$3.96 \cdot 10^{-3}$	872.6	59.4	296.1	$3.1 \cdot 10^{-3}$	$-5.3 \cdot 10^{-3}$	$1.0 \cdot 10^{-3}$	
	2%	1.45	3.42	0.97	$3.92 \cdot 10^{-3}$	841.2	58.83	306.6	$2.1 \cdot 10^{-5}$	$-3.6 \cdot 10^{-3}$	$7.1 \cdot 10^{-4}$	
	5%	1.42	3.39	0.94	$4.96 \cdot 10^{-2}$	772.0	57.5	333.1	0	$4.2 \cdot 10^{-7}$	0	
	10%	1.35	3.20	0.90	0.322	738.6	55.8	348.5	$2.0 \cdot 10^{-16}$	$1.3 \cdot 10^{-5}$	$-6.2 \cdot 10^{-16}$	
	-1%	1.48	3.41	0.99	$4.04 \cdot 10^{-3}$	941.3	60.5	275.3	$5.2 \cdot 10^{-3}$	$-8.2 \cdot 10^{-3}$	$1.6 \cdot 10^{-3}$	
	-2%	1.48	3.41	0.99	$4.08 \cdot 10^{-3}$	978.7	61.0	265.1	$6.2 \cdot 10^{-3}$	$-1.1 \cdot 10^{-2}$	$1.9 \cdot 10^{-3}$	
	-5%	1.53	3.40	1.02	$4.21 \cdot 10^{-3}$	1106.1	62.7	235.7	$9.5 \cdot 10^{-3}$	$-1.6 \cdot 10^{-2}$	$2.8 \cdot 10^{-3}$	
-10%	1.59	3.38	1.06	$4.44 \cdot 10^{-3}$	1383.8	65.9	189.9	$1.5 \cdot 10^{-2}$	$-2.6 \cdot 10^{-3}$	$4.1 \cdot 10^{-3}$		
M_{max}	Nom.	1.47	3.42	0.98	$4.0 \cdot 10^{-3}$	906.0	60.0	285.6	$4.2 \cdot 10^{-3}$	$-7.1 \cdot 10^{-3}$	$1.3 \cdot 10^{-3}$	
	1%	1.45	3.41	0.97	$4.0 \cdot 10^{-3}$	968.2	60.1	267.6	$6.7 \cdot 10^{-3}$	$-1.1 \cdot 10^{-3}$	$2.1 \cdot 10^{-3}$	
	2%	1.45	3.40	0.97	$4.0 \cdot 10^{-3}$	1037.6	60.2	250.0	$9.3 \cdot 10^{-3}$	$-1.5 \cdot 10^{-2}$	$2.8 \cdot 10^{-3}$	
	5%	1.42	3.38	0.94	$4.0 \cdot 10^{-3}$	1303.6	60.6	199.6	$1.7 \cdot 10^{-2}$	$-2.9 \cdot 10^{-2}$	$4.8 \cdot 10^{-3}$	
	10%	1.36	3.34	0.91	$4.0 \cdot 10^{-3}$	2119.7	61.1	123.3	$2.9 \cdot 10^{-2}$	$-5.2 \cdot 10^{-2}$	$7.7 \cdot 10^{-3}$	
	-1%	1.48	3.43	0.99	$4.0 \cdot 10^{-3}$	849.9	59.8	304.1	$1.6 \cdot 10^{-3}$	$-2.7 \cdot 10^{-3}$	$5.3 \cdot 10^{-4}$	
	-2%	1.50	3.39	1.00	0.063	819.0	59.8	315.7	0	$7.5 \cdot 10^{-7}$	0	
	-5%	1.51	3.04	1.01	0.577	836.1	60.6	312.6	0	$5.8 \cdot 10^{-5}$	$-2.2 \cdot 10^{-16}$	
-10%	1.54	2.37	1.03	1.586	869.5	62.2	307.0	0	$3.9 \cdot 10^{-4}$	0		
M_{arr}	Nom.	1.47	3.42	0.98	$4.0 \cdot 10^{-3}$	906.0	60.0	285.6	$4.2 \cdot 10^{-3}$	$-7.1 \cdot 10^{-3}$	$1.3 \cdot 10^{-3}$	
	1%	1.48	3.39	0.99	$4.0 \cdot 10^{-3}$	873.5	59.8	296.3	$2.6 \cdot 10^{-3}$	$-4.4 \cdot 10^{-3}$	$8.6 \cdot 10^{-4}$	
	2%	1.50	3.36	1.00	$4.0 \cdot 10^{-3}$	843.4	59.6	307.0	$1.1 \cdot 10^{-3}$	$-1.9 \cdot 10^{-3}$	$3.7 \cdot 10^{-4}$	
	5%	1.51	3.12	1.01	0.214	832.3	59.5	313.2	0	$1.1 \cdot 10^{-5}$	$2.2 \cdot 10^{-16}$	
	10%	1.54	2.61	1.03	0.704	858.0	59.6	308.7	0	$1.4 \cdot 10^{-3}$	0	
	-1%	1.47	3.45	0.98	$4.0 \cdot 10^{-3}$	941.1	60.2	274.9	$5.7 \cdot 10^{-3}$	$-9.7 \cdot 10^{-3}$	$1.8 \cdot 10^{-3}$	
	-2%	1.45	3.48	0.97	$4.0 \cdot 10^{-3}$	979.3	60.4	264.1	$7.3 \cdot 10^{-3}$	$-1.2 \cdot 10^{-3}$	$2.3 \cdot 10^{-3}$	
	-5%	1.43	3.57	0.95	$4.0 \cdot 10^{-3}$	1116.0	61.0	231.5	$1.2 \cdot 10^{-3}$	$-2.1 \cdot 10^{-2}$	$3.7 \cdot 10^{-3}$	
-10%	1.38	3.71	0.92	$4.0 \cdot 10^{-3}$	1460.7	62.0	176.5	$2.1 \cdot 10^{-3}$	$-3.6 \cdot 10^{-2}$	$6.1 \cdot 10^{-3}$		
M_n	Nom.	1.47	3.42	0.98	$4.0 \cdot 10^{-3}$	906.0	60.0	285.6	$4.2 \cdot 10^{-3}$	$-7.1 \cdot 10^{-3}$	$1.3 \cdot 10^{-3}$	
	1%	1.47	3.38	0.98	$4.0 \cdot 10^{-3}$	931.6	59.9	278.2	$5.2 \cdot 10^{-3}$	$-8.7 \cdot 10^{-3}$	$1.6 \cdot 10^{-3}$	
	2%	1.47	3.35	0.98	$4.0 \cdot 10^{-3}$	958.1	59.8	270.9	$6.2 \cdot 10^{-3}$	$-1.1 \cdot 10^{-2}$	$1.9 \cdot 10^{-3}$	
	5%	1.45	3.24	0.97	$4.0 \cdot 10^{-3}$	1043.0	59.7	249.9	$9.2 \cdot 10^{-3}$	$-1.5 \cdot 10^{-2}$	$2.7 \cdot 10^{-3}$	
	10%	1.44	3.08	0.96	$4.0 \cdot 10^{-3}$	1205.3	59.4	217.7	$1.4 \cdot 10^{-2}$	$-2.4 \cdot 10^{-2}$	$3.9 \cdot 10^{-3}$	
	-1%	1.48	3.46	0.99	$4.0 \cdot 10^{-3}$	881.2	60.0	293.2	$3.1 \cdot 10^{-3}$	$-5.3 \cdot 10^{-3}$	$1.9 \cdot 10^{-3}$	
	-2%	1.48	3.49	0.99	$4.0 \cdot 10^{-3}$	857.1	60.1	301.0	$2.1 \cdot 10^{-3}$	$-3.5 \cdot 10^{-3}$	$7.0 \cdot 10^{-4}$	
	-5%	1.50	3.56	1.00	0.068	810.8	60.4	317.2	0	$6.7 \cdot 10^{-7}$	0	
-10%	1.50	3.52	1.00	0.423	812.9	61.7	316.8	$6.6 \cdot 10^{-16}$	$1.8 \cdot 10^{-5}$	$3.4 \cdot 10^{-16}$		

5.5. Comparación entre la identificación mediante algoritmos genéticos y mínimos cuadrados

En los resultados de las pruebas de identificación realizadas con el algoritmo genético ya se han comentado algunas diferencias entre los dos métodos

utilizados: el de los mínimos cuadrados y el del algoritmo genético. Los valores de los parámetros obtenidos son muy similares en ambos casos, indicando que los dos métodos convergen hacia una misma solución que, por tanto, con una alta probabilidad es la óptima. Los errores en las magnitudes calculadas son del mismo orden en ambos métodos por lo que las soluciones halladas no son una diferencia remarcable entre ambos métodos. Sí lo es la forma de llegar a ellas.

La primera diferencia importante es el tiempo utilizado por ambos métodos. En el tiempo en que la herramienta “*fsolve*” que utiliza los mínimos cuadrados calcula los parámetros de los motores de todo un catálogo, (unos 300 motores), la herramienta “*ga*” utilizando algoritmos genéticos, tan solo es capaz de encontrar los parámetros de dos motores.

Otro aspecto importante es el hecho de disponer o no de un buen punto de partida. El algoritmo genético es poco sensible a la solución de partida proporcionada y aunque comience lejos del óptimo es muy probable que, en un número determinado de iteraciones, sea capaz de converger hacia el óptimo. Es posible que se produzca un estancamiento por una convergencia prematura del algoritmo, lo que ha podido resolverse con una segunda ejecución. Sin embargo, el método de los mínimos cuadrados es relativamente sensible a la solución inicial. A veces, una pequeña diferencia en la solución inicial, lleva a un resultado distinto o, incluso, hace imposible la convergencia. En general, cuanta menos información se tenga sobre el problema, más aconsejable se hace el uso del algoritmo genético.

La complejidad del método puede ser otro factor determinante para su elección. El ajuste del método de los mínimos cuadrados es mucho más simple que el del algoritmo genético. Poner a punto un algoritmo genético puede resultar complicado puesto que consta de varios tipos de operadores como son el cruce o la mutación que, a su vez, pueden ser realizados de diferentes formas debiendo ser seleccionadas para que prevalezcan una serie de características deseables. Esto no ocurre con los mínimos cuadrados en los que el usuario no toma tanto partido en la forma de guiar al algoritmo hacia la solución.

5.6. Método híbrido

La identificación por mínimos cuadrados ha resultado ser muy rápida pero necesita una buena solución inicial para converger. El algoritmo genético siempre da buenos resultados, empiece donde empiece, pero es un método lento. Por tanto, es interesante combinar las ventajas de ambos métodos de identificación y obtener lo mejor de cada uno de ellos. En primer lugar se utiliza el algoritmo genético para encontrar una solución de partida aproximada y, en segundo lugar, se ejecuta una búsqueda utilizando mínimos cuadrados que, partiendo de una buena solución inicial, ha demostrado ser un método muy eficiente. De esta manera, se puede obtener una buena precisión en un tiempo menor y sin la necesidad de disponer de una buena solución inicial.

El algoritmo genético, en la mayoría de los casos, ha proporcionado una buena precisión, con nivel de errores del orden de 10^{-5} , en las cinco primeras iteraciones.

Sin embargo, para alcanzar niveles de error del orden de 10^{-16} , alcanzadas en pocas décimas de segundo por el método de los mínimos cuadrados, el algoritmo genético necesita varias decenas de segundos. Se ha optado por interrumpir el algoritmo genético al alcanzar una precisión del orden de 10^{-5} e iniciar en ese momento una búsqueda por mínimos cuadrados más eficiente.

En la Tabla 5.15 se muestran los tiempos utilizados por el algoritmo genético y por el método híbrido para hallar los parámetros del motor de la Tabla 5.8, utilizando el modelo de circuito de doble jaula.

Tabla 5.15: Parámetros y errores utilizando el algoritmo genético y el método híbrido para un mismo motor

	Algoritmo genético	Híbrido
Tiempo [s]	18.4	5.2
R_1 [Ω]	0.306	0.306
R_1 [pu]	$1.08 \cdot 10^{-2}$	$1.08 \cdot 10^{-2}$
R_2 [Ω]	1.070	1.070
R_2 [pu]	$3.77 \cdot 10^{-2}$	$3.77 \cdot 10^{-2}$
X_m [Ω]	31.8	31.8
X_m [pu]	1.12	1.12
X_{sd} [Ω]	3.302	3.302
X_{sd} [pu]	0.116	0.116
X_{1d} [Ω]	4.88	4.88
X_{1d} [pu]	0.172	0.172
X_{2d} [Ω]	1.651	1.651
X_{2d} [pu]	$5.82 \cdot 10^{-2}$	$5.82 \cdot 10^{-2}$
R_s [Ω]	0.459	0.459
R_s [pu]	$1.62 \cdot 10^{-2}$	$1.62 \cdot 10^{-2}$
Error M_{arr}	0	$2.14 \cdot 10^{-16}$
Error M_{max}	0	$-1.68 \cdot 10^{-16}$
Error P_u^n	0	0
Error I_{arr}	0	0

Como puede observarse, los parámetros obtenidos combinando los algoritmos han sido exactamente los mismos que con el algoritmo genético, pero se han calculado en una tercera parte de tiempo. Prácticamente la totalidad del tiempo empleado por el método híbrido se corresponde con el tiempo empleado por el algoritmo genético.

5.7. Comparación de resultados

Al igual que con el método de los mínimos cuadrados, se ha realizado una comparación entre los resultados obtenidos con los algoritmo genético e híbrido y

los obtenidos mediante otras fuentes o medios. Para las comparaciones se han utilizado los datos de un motor que figuran en la Tabla 5.16.

En la Tabla 5.17 se muestran los valores de los parámetros del modelo de circuito de doble jaula, calculados mediante el algoritmo genético y el método híbrido, y la solución inicial utilizada para calcularlos, junto con los errores de las magnitudes calculadas a partir de los parámetros. En esta comparación y las siguientes, se han utilizado parámetros con cuatro cifras decimales para el cálculo de los errores.

Tabla 5.16: Datos del motor utilizado en la comparación

Datos del motor			
V [V]	380	Tipo	IEC
P_u^n [kW]	110	f [Hz]	50
I_n [A]	184	η_N [%]	95.8
n_n [rev./min]	2977	M_n [Nm]	353
$\cos\phi_n$ [pu]	0.90	M_{arr}/M_n	2.4
I_{arr}/I_n	8.3	M_{max}/M_n	3.1

Tabla 5.17: Comparación entre la solución inicial y la calculada para un motor seleccionado

Modelo	Doble jaula				
	Solución Inicial	Algoritmo Genético	Diferencia [%]	Híbrido	Diferencia [%]
R_l [pu]	0.0064	0.0077	-20.3	0.0077	-20.3
R_2 [pu]	0.0318	0.0645	-102.8	0.0645	-102.8
X_m [pu]	2.5283	2.7436	-8.5	2.7436	-8.5
X_{sd} [pu]	0.0454	0.0648	-42.7	0.0648	-42.7
X_{1d} [pu]	0.0545	0.0975	-78.8	0.0975	-78.8
X_{2d} [pu]	0.0273	0.0324	-18.7	0.0324	-18.7
R_s [pu]	0.0095	0.0116	-22.1	0.0116	-22.1
Error M_{arr}	0.06536	$-7.04 \cdot 10^{-4}$		$-7.04 \cdot 10^{-4}$	
Error M_{max}	0.60435	$-1.62 \cdot 10^{-4}$		$-1.62 \cdot 10^{-4}$	
Error P_u^n	0.3233	$4.77 \cdot 10^{-3}$		$4.77 \cdot 10^{-3}$	
Error I_{arr}	0.54673	$-6.54 \cdot 10^{-5}$		$-6.54 \cdot 10^{-5}$	

Las fórmulas empíricas para el cálculo de los parámetros del modelo de circuito de doble jaula en función de la potencia calculadas por Pedra [22] son:

$$R_s = 0.0362P_n^{-0.3926}$$

$$R_l = 0.0724P_n^{-0.3924}$$

$$R_2 = 0.1250P_n^{-0.0829}$$

$$X_m = 1.2609P_n^{0.1277}$$

$$X_{sd} = 0.0519P_n^{0.0533}$$

$$X_{1d} = 0.1366P_n^{-0.0093}$$

$$X_{2d} = X_{sd}$$

La Tabla 5.18 muestra los valores de los parámetros del modelo de circuito de doble jaula obtenidos mediante las fórmulas anteriores, así como los obtenidos por el algoritmo genético y el método híbrido, para el motor de la Tabla 5.16. Los errores se han calculado utilizando la misma función en todos los casos.

Tabla 5.18: Valores de los parámetros por distintos métodos para un motor seleccionado, Caso 1

Modelo	Doble jaula				
	Pedra [22]	Algoritmo Genético	Diferencia [%]	Híbrido	Diferencia [%]
R_1 [pu]	0.0114	0.0077	32.4	0.0077	32.4
R_2 [pu]	0.0847	0.0645	23.8	0.0645	23.8
X_m [pu]	2.2980	2.7436	-19.4	2.7436	-19.4
X_{sd} [pu]	0.0666	0.0648	2.7	0.0648	2.7
X_{1d} [pu]	0.1307	0.0975	24.2	0.0975	24.2
X_{2d} [pu]	0.0666	0.0324	51.3	0.0324	51.3
R_s [pu]	0.0057	0.0116	-103.5	0.0116	-103.5
Error M_{arr}	-0.18867	$-7.04 \cdot 10^{-4}$		$-7.04 \cdot 10^{-4}$	
Error M_{max}	-0.14676	$-1.62 \cdot 10^{-4}$		$-1.62 \cdot 10^{-4}$	
Error P_u^n	-0.30245	$4.77 \cdot 10^{-3}$		$4.77 \cdot 10^{-3}$	
Error I_{arr}	-0.13579	$-6.54 \cdot 10^{-5}$		$-6.54 \cdot 10^{-5}$	

La Tabla 5.19 muestra los parámetros identificados del modelo de circuito de doble jaula del motor de la Tabla 5.16, obtenidos por el algoritmo genético y el método híbrido, así como por Pedra y Córcoles [17] utilizando una identificación por mínimos cuadrados. Para realizar la comparación se ha utilizado la misma función para calcular el error y el mismo número de decimales en todos los casos.

Tabla 5.19: Valores de los parámetros por distintos métodos para un motor seleccionado, Caso 2

Modelo	Doble jaula				
	Pedra [17]	Algoritmo Genético	Diferencia [%]	Híbrido	Diferencia [%]
R_1 [pu]	0.0080	0.0077	3.75	0.0077	3.75
R_2 [pu]	0.0510	0.0645	-26.47	0.0645	-26.47
X_m [pu]	2.7251	2.7436	-0.68	2.7436	-0.68
X_{sd} [pu]	0.0638	0.0648	-1.57	0.0648	-1.57
X_{1d} [pu]	0.1050	0.0975	7.14	0.0975	7.14
X_{2d} [pu]	0.0319	0.0324	-1.50	0.0324	-1.50
R_s [pu]	0.0120	0.0116	3.40	0.0116	3.40
Error M_{arr}	$-5.84 \cdot 10^{-4}$	$-7.04 \cdot 10^{-4}$		$-7.04 \cdot 10^{-4}$	
Error M_{max}	$-7.03 \cdot 10^{-4}$	$-1.62 \cdot 10^{-4}$		$-1.62 \cdot 10^{-4}$	
Error P_u^n	$-7.74 \cdot 10^{-4}$	$4.77 \cdot 10^{-3}$		$4.77 \cdot 10^{-3}$	
Error I_{arr}	$5.31 \cdot 10^{-2}$	$-6.54 \cdot 10^{-5}$		$-6.54 \cdot 10^{-5}$	

Como puede observarse, los errores obtenidos son del mismo orden que los que resultan utilizando los métodos descritos en la literatura.