

Artigo Original

recebido em 23/02/2000 e aceito em 17/08/2001

**Algoritmo simulated annealing
inteligente aplicado a la
optimización del imán principal
de una máquina de resonancia
magnética de imágenes**

*Intelligent simulated annealing
algorithm applied to the optimization
of the main magnet for magnetic
resonance imaging machine*

Resumen

Se describe una variante del algoritmo Simulated Annealing aplicada al diseño del imán principal de una máquina de Imágenes por Resonancia Magnética. Se incluye en el algoritmo un proceso de clasificación de soluciones, antes de la evaluación de la función objetivo, utilizando una red neuronal probabilística de base radial. Este procedimiento permite reducir hasta un 50% el número de iteraciones necesarias para arribar al óptimo global. Aplicando el algoritmo que se propone en este trabajo se obtuvo el diseño práctico de un imán resistivo de campo 0.1050 Tesla, el cual produce un campo magnético 2.13 más uniforme que el generado por una configuración obtenida utilizando el algoritmo simulated annealing.

Palabras-Clave: Imán principal, Optimización, RMI, Simulated annealing.

Abstract

This work describes an alternative algorithm of Simulated Annealing (SA) applied to the design of the main magnet for a Magnetic Resonance Imaging machine. The algorithm uses a probabilistic radial base neuronal network to classify the possible solutions, before the objective function evaluation. This procedure allows reducing up to 50% the number of iterations required by simulated annealing to achieve the global maximum, when compared with the SA algorithm. The algorithm was applied to design a 0.1050 Tesla four coil resistive magnet, which produces a magnetic field 2.13 times more uniform than the solution given by SA.

Keywords: MRI, Main magnet, Optimization, Simulated annealing.

Héctor Sánchez López

Centro de Biofísica Médica
Universidad de Oriente
Patricio Lumumba s/n
Santiago de Cuba 90500 - Cuba
e-mail: hsanchez@cbm.uo.edu.cu

Extended Abstract

Introduction

The effectiveness of the stochastic algorithm for magnetic system design has been demonstrated by CROZIER and DODDRELL (1997). One of the most popular algorithms used for this purpose has been the Simulated Annealing (SA). SA is a concept adopted from thermodynamics. Its name originates from its analogy with thermodynamic processes such as freezing liquids and annealing metals, in which the material find its minimum energy state among many local minima if the temperature is decreased in a sufficiently slow rate (ALOTTO et al., 1998). The SA find with high probability the region of the optimum, but it needs several evaluations of the error function in order to obtain the global optimum. Furthermore, in the design problems of some magnetic devices, the objective function depends on the magnetic field evaluation in some region. This calculation is done by numerical methods, which are CPU time consuming. It is intolerable in engineering applications. For this reason, to save optimization time, reducing the SA convergence speed is a significant problem.

Some authors have proposed procedures that in some way save CPU time for the SA algorithm. SIMKIN and TROWBRIDGE (1992) combine SA with a deterministic technique, others propose to control the objective function accuracy (IOAN et al., 1998). EBNER et al. (1998) approximate the real objective function to a virtual objective function using a trained neuronal network; and TANG et al. (1998) applied fuzzy inference to avoid impractical solutions.

This work describes an alternative algorithm of Simulated Annealing using a probabilistic radial base neuronal network to classify the possible solutions. This network, trained in the optimization process, give to SA certain intelligence because it classifies the possible solutions in acceptable or not acceptable before the objective function evaluation. It implies a considerable reduction of CPU time. The algorithm is applied to a practical situation, where the task is to design a resistive magnet for Magnetic Resonance Imaging (MRI) system.

Materials and Methods

Description of the SA algorithm - The thermodynamic basic principle could be used in analogy with the optimization process. The objective function could be defined as the system "energy", the different combinations of free variables in each state as the possible "solutions" or "configurations". In the process, one configuration is accepted with certain probability, even when the value of the actual energy state is greater than the last one accepted. This fact is known as "uphill" movement. The Boltzmann probability distribution along with the Metropolis criteria rule the acceptance of the possible solution (ALOTTO et al., 1998).

Description of the Intelligent Simulated Annealing (ISA) algorithm - If at the beginning of the process a

certain number of random configurations produced by the SA are chosen, it is possible to train a neuronal network taking the knowledge from this data that have been obtained acceptable and impractical solutions. After that, the trained network could be used to classify the solutions in the designing process. The new algorithm will have a certain "intelligence" because it will accept or reject possible solutions before the evaluation of the objective function.

Basic principle of main magnet design.

The theoretical process on designing a main magnet for MRI is centered to minimize the value of the zonal harmonic coefficients in the magnetic field expansion series. In this work the objective function was defined in terms of the zonal harmonic coefficients as:

$$\min : F = (C_0 - 0.1050)^2 + C_2^2 + C_4^2 + C_6^2 + k_1 \cdot C_8^2 + k_2 \cdot C_{10}^2$$

such that,

$$C_2 < 10^{-3}; C_4 < 10^{-3}; C_6 < 10^{-3}$$

where C_n are the zonal harmonics coefficients of the field expansion, and k_1 and k_2 are weighting factors, adjusted according with the designer interest.

The minimization of this coefficient will produce a configuration that produces a uniform magnetic field.

Results

The algorithm was applied to design a 0.1050 Tesla four coil resistive magnet for an MRI machine. A uniformity less than 12 ppm in a spherical volume with diameter of 0.36 m and free bore access of 0.84 m were required for the design. Four free variables were associated to each coil: the radial and the axial coil position and the radial and axial coil dimension.

The values of the coefficients obtained using the SA are greater than the coefficients obtained using ISA. The ISA could find a solution with minimum coefficients better than SA. The magnetic field produced by the configuration obtained with the ISA is 2.13 times more uniform than the solution obtained by SA. The computing time needed for the SA was 4 hours and 35 minutes and the time needed for the ISA was 2 hours and 21 minutes. The ISA needed less than 50% of the iterations to obtain the optimum, when compared with the SA algorithm.

Conclusion

The ISA algorithm for global optimization was presented and applied to a practical electromagnetic design problem. It was presented in a general way and could be applied to several complex problems. This process could be extended to other stochastic algorithms. The SAI could reduce up to 50% the number of iterations needed by the SA to obtain the global optimum. The solution obtained by the ISA is more accurate than the solutions obtained by the SA.

Introducción

En los últimos años se ha demostrado la efectividad de los algoritmos estocásticos para el diseño de dispositivos magnéticos (CROZIER y DODDRELL, 1997). Uno de los algoritmos más populares utilizados para este propósito ha sido el Simulated Annealing (SA). SA es un concepto adoptado de la termodinámica. Su nombre se origina en la analogía con el proceso termodinámico en el cual el material encuentra el mínimo estado de energía entre varios posibles estados mínimos locales cuando el proceso de reducción de la temperatura se realiza suficientemente lento (ALOTTO *et al.*, 1998). Se conoce que el algoritmo SA encuentra con alta probabilidad la región del óptimo, pero necesita realizar un gran número de evaluaciones de la función objetivo para arribar al mínimo global. Además, en los problemas de diseño de algunos dispositivos generadores de campo magnético, la función objetivo depende de la evaluación del campo magnético en determinadas regiones. Este cálculo se realiza a través de métodos numéricos, los cuales son altamente consumidores de tiempo de CPU. Esto es intolerable en aplicaciones ingenieriles, por lo tanto la reducción del tiempo de optimización es un problema a resolver.

Distintos autores han propuesto técnicas que de alguna manera reducen el tiempo de CPU para el SA. SIMKIN y TROWBRIDGE (1992) combinan el SA con técnicas determinísticas. IOAN *et al.* (1998) proponen controlar la exactitud de la evaluación de la función objetivo. Se ha utilizado una red neuronal para aproximar la función objetivo a una función objetivo virtual (EBNER *et al.*, 1998). Se ha presentado una variante de Simulated Annealing Inteligente (SAI) utilizando inferencia fuzzy con el objetivo de rechazar posibles soluciones no prácticas (TANG *et al.*, 1998). Este procedimiento es altamente consumidor de memoria en una PC, lo que hace complicado su implementación.

En este trabajo se presenta una variante de SAI utilizando una red neuronal probabilística de base radial para la calificación de soluciones. Esta red entrenada en el proceso de optimización dota al SA de cierta «inteligencia» pues permite al algoritmo clasificar las posibles soluciones en aceptables o no antes de la evaluación de la función objetivo. Esto trae consigo un considerable ahorro de tiempo de CPU. El procedimiento es aplicado al diseño de un imán resistivo para Resonancia Magnética de Imágenes (RMI).

Materiales y Métodos

Descripción del algoritmo SA

El principio básico del proceso termodinámico puede ser utilizado en analogía con el proceso de optimización. La función objetivo puede ser considerada como la “energía” del sistema, las diferentes combinaciones de las variables libres en cada estado como las posibles “soluciones” o “configuraciones”. Una configuración es aceptada bajo cierta probabilidad e incluso puede ser que el estado de energía o valor numérico de la función objetivo actual sea superior al anterior. Esto se conoce como movimientos «uphill». La ecuación de distribución de probabilidades de Boltzmann junto al criterio de Metropolis son las reglas que rigen la aceptación o no de una posible configuración (ALOTTO *et al.*, 1998). La probabilidad de aceptación de los movimientos «uphill» o incremento del valor numérico de la función objetivo respecto al último valor aceptado está bajo el control del parámetro estratégico llamado “temperatura”, el cual es bajado con cierta ley durante el proceso.

La probabilidad de aceptación viene dada por la siguiente expresión (ALOTTO *et al.*, 1998):

$$p = \exp\left(-\frac{f_o - f_n}{k \cdot T}\right) \quad (1)$$

donde f_o es el valor numérico de la función objetivo de la configuración previamente aceptada y f_n es el valor actual; k controla la pendiente de la función p y T la temperatura. La ley de disminución de la temperatura está en dependencia del problema y el comportamiento de la función objetivo, por lo general se escoge la siguiente expresión (ALOTTO *et al.*, 1998):

$$T^{k+1} = c \cdot T^k \quad (2)$$

donde T^k es la temperatura actual del proceso y c es un factor entre 0.85-0.90.

Descripción del algoritmo SAI

En el proceso de optimización de un imán resistivo para RMI se conoce que la posible configuración satisface las restricciones del problema sólo después de haber evaluado el campo magnético y de esta manera las soluciones se puede clasificar como aceptables o no. Si al principio se escogen, cierto número de configuraciones aleatorias generadas por el proceso de optimización del algoritmo SA, es posible entrenar una red neuronal en base a estos datos de manera tal que para posteriores configuraciones la

red entrenada pueda clasificar la solución, en aceptable o no, antes de evaluar la función objetivo.

La red neuronal probabilística es una variante de la red neuronal de base radial (CHEN *et al.*, 1991). El software MatLab para la computación técnica, tiene implementada una serie de utilidades de fácil manejo que permiten entrenar y obtener redes neuronales para los más diversos propósitos. El procedimiento *newpnn(P,K,spread)* permite obtener una red para la clasificación (Matlab 5.3, National Instruments). *P* es un vector donde se almacenan las posibles configuraciones escogidas para el entrenamiento y *K* es el vector donde está la clasificación en aceptable o no de cada configuración almacenada en *P*. El parámetro *spread* determina el ancho del área en el espacio de entrada en el cual neurón responde. *Spread* caracteriza las distancias entre cada una de las posibles configuraciones almacenadas en *P*. Si el parámetro *Spread* se escoge muy grande las regiones de respuestas se solapan y la clasificación puede fallar, si por el contrario es muy pequeño la red responderá sólo a un tipo de clasificación cuando se evalúe una nueva después de entrenada la red. Una de las soluciones para escoger el valor óptimo de este parámetro es estudiar los valores numéricos de los grados de libertad del sistema así como las distancias típicas entre ellos. Otra posible solución es determinar, en el proceso, los valores máximos y mínimos de cada uno de los grados de libertad de cada configuración almacenada en *P*, luego se determinan las distancias entre estos valores y posteriormente se promedia. El procedimiento *newpnn* esta basado sobre una filosofía que le permite trabajar con el mínimo consumo de memoria de la PC.

El procedimiento puede ser dividido en tres ciclos anidados: 1) Exploración a lo largo de cada grado de libertad con un ancho de paso de búsqueda determinado, y entrenamiento o evaluación de la red neuronal. 2) Ajuste del ancho de paso de búsqueda y 3) Reducción de la temperatura de acuerdo a la ley (2).

Ciclo (1) interno - Generación de una nueva configuración a partir de la aceptada anteriormente (*Ns* veces). La nueva configuración es obtenida perturbando cada grado de libertad mediante la siguiente expresión:

$$x_n = x_0 + s \cdot rnd \quad (3)$$

donde x_0 es la configuración previamente aceptada, s es el ancho de paso actual y rnd es un vector de números aleatorios en el rango $[-1,1]$.

Si la red no ha sido entrenada se evalúa la función objetivo y se continúa creando los datos para el

entrenamiento. Se somete la configuración al criterio de aceptación según (1). En caso contrario (red entrenada), se evalúa a través de la red si la nueva configuración cumple con las restricciones o no. Si no cumple, se desecha y no se evalúa en la función objetivo ni se somete al criterio de Metropolis.

Ciclo (2) medio - Se ajusta el vector s . (Se realiza *Nss* veces). En este ciclo se trata de ajustar el ancho de paso de manera tal que la relación se mantenga 1:1 entre las configuraciones aceptadas, según (1), y las no aceptadas (SIMKIN y TROWBRIDGE, 1992). Un gran número de configuraciones aceptadas significa que la nueva configuración está muy cerca de la anteriormente aceptada, por lo tanto es preciso explorar otras regiones. Por el contrario si el número de configuraciones aceptadas es muy pequeño, entonces la configuración está muy alejada de una zona de buenas soluciones. El nuevo valor del ancho de paso es obtenido multiplicando el vector s utilizado en el ciclo anterior por una función calculada en base a la razón entre las configuraciones aceptadas y desechadas (ALOTTO *et al.*, 1998).

Ciclo (3) exterior - Se reduce la temperatura aplicando la ley (2). En el procedimiento se toman en cuenta dos criterios de terminación, el primero es que, si la temperatura está por debajo de un valor predeterminado por el diseñador, se considera que el "sistema" está congelado y el proceso termina, el segundo es que si los últimos 20 valores de la función objetivo no varían en un rango de error predeterminado se termina el proceso.

El algoritmo se implementó en el lenguaje para la computación técnica MatLab 5.3. La sintaxis de la función implementada es completamente compatible con los procedimientos de optimización que ofrece el software. Presenta una interface gráfica con el usuario y facilidades para la investigación de funciones objetivos. Mediante esta interface el usuario puede forzar la terminación del proceso o "congelando" el sistema para una rápida convergencia. También permite aumentar la temperatura en aras de explorar otras regiones. La interface permite detener la optimización con el SAI y continuar con un algoritmo determinístico para lograr una rápida convergencia (SIMKIN y TROWBRIDGE, 1992).

Diseño del Imán Principal

De los sistemas de bobinas generadores de campo magnético de una máquina de RMI, uno de los componentes que juega un papel fundamental es el imán principal. Este dispositivo tiene que ser diseñado de manera

tal que el campo magnético generado, en una esfera centrada en el origen de diámetro equivalente a dimensiones de la parte del cuerpo humano que se examina, sea altamente homogéneo (una decena de partes por millón) y estable a lo largo del tiempo. Ver Figura 1. Al mismo tiempo se exigen requisitos físicos, eléctricos y mecánicos, tales como: baja potencia disipada, alta eficiencia, facilidad de acceso a la zona de estudio, compactación del sistema y baja interacción con el ambiente (SÁNCHEZ, 1998a). Estos requisitos están altamente relacionados y compiten unos contra otros. La tarea consiste en encontrar una configuración real y práctica en la cual exista un compromiso óptimo entre todos los requisitos. Sin lugar a dudas es un problema típico de optimización.

Debido a la simetría en el imán, sólo se tienen en cuenta los órdenes pares de los armónicos zonales de la expansión en serie del campo (CROZIER y DODDRELL, 1997). El proceso de diseño teórico está centrado en minimizar o anular la mayor cantidad de armónicos zonales, que están asociados al comportamiento espacial en la expansión.

En este trabajo la función objetivo se define en términos que representan la uniformidad del campo:

$$\min : F = (C_0 - 0.1050)^2 + C_2^2 + C_4^2 + C_6^2 + k_1 \cdot C_8^2 + k_2 \cdot C_{10}^2 \quad (4)$$

tal que:

$$C_2 < 10^{-3}; C_4 < 10^{-3}; C_6 < 10^{-3}$$

donde C_n son los coeficientes de los armónicos zonales, k_1 y k_2 son factores de peso que se ajustan en dependencia del interés del diseñador (SÁNCHEZ, 1998b).

Los armónicos zonales fueron evaluados para cada espira de cada bobina utilizando la expresión desarrollada en KITAMURA *et al.* (1994).

Todas aquellas configuraciones cuyos armónicos de segundo, cuarto y sexto orden sean mayores que 10^{-3} no tienen sentido ser analizadas por el algoritmo de optimización. El análisis de estas posibles soluciones trae como consecuencia la pérdida de tiempo del algoritmo SA en corregir el ancho de paso para llegar al óptimo. Simplemente el SAI, con la red neuronal entrenada, desecha estos casos.

Resultados

Verificación del SAI

Se verificó el algoritmo SAI con funciones clásicas, introduciendo en la función objetivo restricciones artificiales. Se consideró $N_s = 10$, $N_{ss} = 10$, $T = 0.01$ y el paso inicial $s = 0.1$. Los mínimos globales fueron encontrados y las posibles configuraciones que no cumplían las restricciones fueron desechadas antes de la evaluación de la función objetivo.

En la Tabla 1 se muestran los resultados de una de las funciones multimodales que fueron minimizadas por el algoritmo SAI. La función minimizada fue la de Rosenbrock (CHUN *et al.*, 1998). Esta función tiene el mínimo global en el punto (1,1,1,1).

En la tabla se muestran los resultados del SA y el SAI. Como se puede observar el SAI puede encontrar el óptimo global con 1.88 veces menos iteraciones que el SA, además la exactitud del algoritmo SAI es mucho mejor pues el ajuste de paso se realiza en regiones que están dentro de las restricciones impuestas. En SA, este ajuste se realiza teniendo en cuenta las soluciones que cumplen las restricciones y las que no las




Figura 1. Un cuadrante de la sección transversal del imán resistivo. W_1 , W_2 , H_1 y H_2 son las dimensiones axial y radial de cada bobina. **Figure 1.** One quadrant of the cross section of the resistive magnet. W_1 , W_2 , H_1 y H_2 are the axial and the radial dimension of each coil.

Tabla 1. Resultados de la minimización de la función de Rosembrock. **Table 1.** Minimization Results of Rosembrock's function

	SA	SAI
Punto Inicial	(0.5,0.5,0.5,0.5)	(0.5,0.5,0.5,0.5)
Mínimo	(0.999999, 0.999997, 0.999994, 0.999989)	(1.00000, 1.00000, 1.00000, 1.00000)
Valor óptimo	2.45993×10^{-10}	0
Iteraciones	2289	1218

cumplen. La red neuronal entrenada trabaja como un filtro de soluciones no aceptables o que no cumplen con las restricciones impuestas al problema.

Puede señalarse como una de las grandes ventajas del algoritmo SA la independencia existente entre la solución final esperada y las condiciones iniciales o punto inicial (ALOTTO *et al.*, 1998). Precisamente este hecho es lo que hace beneficioso dicho algoritmo para enfrentar problemas de optimización donde no existe un conocimiento a priori del comportamiento del sistema ni de la solución óptima que se desee obtener. Al ser ejecutado el algoritmo SA desde diferentes puntos iniciales a los mostrados en la Tabla 1, produjo resultados que se diferenciaron en 0.1 ppm a los mostrados en la Tabla 1. El resultado producido por SAI resultó ser el mismo que se muestra en la tabla.

Diseño del electroimán para la Máquina de RMI Giroimag.

El algoritmo presentado en este trabajo, fue utilizado para obtener el diseño óptimo de un imán resistivo de 0.1050 Tesla, de acceso libre de 84 cm de diámetro y una uniformidad de campo menor a 12 ppm (raíz cuadrática media) en una esfera centrada en el origen de 36 cm de diámetro.

El imán está compuesto por cuatro bobinas. Las variables libres en el proceso de diseño para cada

bobina fueron: las dimensiones y posiciones axiales y radiales de las bobinas (Figura 1). El valor del parámetro temperatura fue escogido $T = 10^{-4}$, el paso inicial para cada variable fue de 1 cm. Si la temperatura se escoge muy alta ($T > 1$) el sistema puede explorar regiones en el espacio de soluciones que no son de interés, por el contrario, si se escoge muy pequeña ($T < 10^{-6}$) el sistema sólo explora regiones muy cercanas a la configuración inicial, y puede ser atrapado en un mínimo local. Por lo tanto, fue preciso sintonizar el algoritmo estudiando previamente el comportamiento de los primeros valores de la función objetivo. Una solución a este problema puede ser, iniciar con una temperatura equivalente al valor inicial de la función objetivo.

En la Tabla 2, se muestran los principales resultados obtenidos con ambos algoritmos después de la optimización del imán. Los resultados muestran que los coeficientes obtenidos de la solución encontrada utilizando el algoritmo SAI son menores que los obtenidos por el SA, cuestión que favorece a la uniformidad del campo magnético en la región de interés. El campo magnético generado por el diseño obtenido con el algoritmo SAI es 2.13 veces más uniforme que el obtenido con la configuración encontrada por el SA. Este hecho se debe a que el ajuste de paso realizado por el SAI es mucho más efectivo pues son tomadas en cuenta configuraciones que conllevan al algoritmos a una óptima solución, por el contrario el SA toma en consideración todas las configuraciones generadas por el algoritmo y esto produce excesivos ajustes de paso y un refinamiento ineficiente. Este hecho trae como consecuencia la superioridad del SAI sobre el SA.

El procedimiento se ejecutó en una PC/Dual Pentium 233 MHz. El tiempo de cómputo con el SA fue de 4 horas con 35 minutos y con el SAI 2 horas 21 minutos. Los resultados obtenidos con el SAI son

Tabla 2. Resultados de la optimización del imán. **Table 2.** Optimization Results of the Designed Magnet

		SA	SAI
Homogeneidad	Pico-pico (ppm)	46.68	43.14
	RCM (ppm)	12.89	11.96
Armónicos de Campo	C_2 (Tesla/m ²)	5.79×10^{-5}	5.27×10^{-5}
	C_4 (Tesla/m ⁴)	-2.16×10^{-5}	-2.39×10^{-5}
	C_6 (Tesla/m ⁶)	-6.89×10^{-6}	-6.41×10^{-6}
	C_8 (Tesla/m ⁸)	-3.64	-3.40
	C_{10} (Tesla/m ¹⁰)	7.63	7.27
Iteraciones		2571	1276

superiores al SA, este último empleó aproximadamente el doble de las iteraciones para arribar al óptimo global.

Conclusiones

Se presentó el algoritmo de optimización global SAI, el cual puede ser aplicado a cualquier tipo de problema de optimización donde exista alta complejidad de la función objetivo.

El SAI está dotado de cierta «inteligencia» pues es capaz de determinar antes de la evaluación de la función objetivo la factibilidad de la solución. Esto facilita encontrar con menos iteraciones que el SA la región del óptimo, porque sólo son analizadas las soluciones de interés para el diseñador y el paso se ajusta de acuerdo con las soluciones que cumplen las restricciones. Este hecho hace posible obtener soluciones más exactas que las producidas por el SA.

El proceso de clasificación de soluciones puede ser aplicado a cualquier otro algoritmo estocástico de optimización para reducir el tiempo de diseño.

El SAI puede reducir hasta el 50% el número de iteraciones que necesita el SA para llegar al óptimo global.

Referencias

- Crozier, S., Doddrell, D.M.. (1997), "Compact MRI Magnet Design by Stochastic Optimization", *Journal of Magnetic Resonance*, v.127, n. 2, p. 233-237.
- Alotto, P.G., Eranda, C., Brandstatter, B., Furntratt, G., Magele, C., Molinari, G., Nervi, M., Preis, K., Repetto, M., Richter, K.R. (1998), "Stochastic Algorithms in Electromagnetic Optimization", *IEEE Transactions on Magnetism*, v. 34, n. 5, p. 3674-3684 [Part 2].
- Simkin, J., Trowbridge, C.W. (1992), "Optimizing Electromagnetic Devices Combining Direct Search Methods with Simulated Annealing", *IEEE Transactions on Magnetism*, v. 28, n. 2, p. 1545-1548.
- Ioan, D., Ciuprina, G., Dumitrescu, C. (1998), "Use of Stochastic Algorithms for Distributed Architectures in the Optimization of Electromagnetic Devices", *IEEE Transactions on Magnetism*, v. 34, n. 5, p. 3000-3003 [Part 1].
- Ebner, T., Magele, C., Brandstatter, B.R., Richter, K.R. (1998), "Utilizing Feed Forward Neural Networks for Acceleration of Global Optimization Procedures", *IEEE Transactions on Magnetism*, v. 34, n.5, p. 2928-2931 [Part 1].
- Tang, R.Y., Sun, J.Z., Li, Y., Cui, X. (1998), "Optimization of Electromagnetic Devices by Using Intelligent Simulated Annealing Algorithm", *IEEE Transactions on Magnetism*, v. 34, n.5, p.2992-2995 [Part 1].
- Chen, S., Cowan, C.F.N., Grant, P.M. (1991), "Orthogonal Least-Squares Learning Algorithm for Radial Basis Function Networks", *IEEE Transactions on Neural Networks*, v. 2, n. 2, p. 302-309.
- Chun, J.S., Jung, H K., Hahn, S. Y. (1998), "A Study on Comparison of Optimization Performances Between Immune Algorithm and Other Heuristic Algorithms", *IEEE Transactions on Magnetism*, v. 34, n. 5, p. 2972-2975 [Part 1].
- Sánchez, H. (1998a), "Diseño Mejorado de Bobinas de Gradientes Transversales para las Máquinas de Imágenes por Resonancia Magnética Giroimag", *Revista Mexicana de Física*, v. 44, n.5, p.470-472.
- Sánchez, H. (1998b), "Diseño y optimización de Electroimanes para las Máquinas de Resonancia Magnética de Imágenes", *Memorias del Primer Congreso Latinoamericano de Ingeniería Biomédica Mazatlán, México*, p. 678-680.
- Kitamura, M., Kakukawa, S., Mori, K., Tominaka, T. (1994), "An Optimal-Design Technique for Coil Configurations in Iron-Shielded MRI Magnets", *IEEE Transactions on Magnetism*, v.30, no.4, p.2352-2355 [Part 2].