

# Parameter estimation and validation of power transformers top oil temperature model by applying genetic algorithms

**Rómulo J. Pérez B.<sup>1</sup>, Enrique Matos Alfonso<sup>2</sup> y Sergio J. Fernández<sup>3</sup>**

<sup>1</sup>Departamento de Ingeniería Eléctrica, Universidad Nacional Experimental Politécnica "Antonio José de Sucre" UNEXPO. Av. Corpahuiaco entre Avs. La Salle y Rotaria, Parque Tecnológico. Barquisimeto, Venezuela. Fax (0251) 4423549. romuloperez2003@gmail.com.

<sup>2</sup>Facultad de Informática, Universidad de Cienfuegos "Carlos Rafael Rodríguez". Cuba. gardero@gmail.com,

<sup>3</sup>Instituto Superior Politécnico "José Antonio Echeverría". CUJAE-CIPEL. Av. 114-11901, Marianao, CP 19390, Ciudad de La Habana, Cuba. Fax 537-2663023. sergiojfernandez@yahoo.es.

## Abstract

This paper presents a technique based on Genetic Algorithms for the parameter estimation and validation of the power transformers top oil temperature model proposed by Lesieutre [1]. For such aim, data are used in on-line diagnosis and monitoring systems, installed in a 100 MVA 230/115/24 kV OA/FA/FOA transformer of Barquisimeto Substation at ENELBAR, Venezuela since the year 2003. The objective of this work is to compare mistake reduction between the model and the top oil temperature measurement when their parameters estimation is considered by genetic algorithms and least-squares. The parameters estimation by genetic algorithms evidence better results of the model, which improves its performance as a power transformer diagnosis tool.

**Key words:** Genetic algorithms, parameter estimation, power transformer.

## Estimación de parámetros y validación del modelo de la temperatura del aceite superior en transformadores de potencia aplicando algoritmos genéticos

### Resumen

Este artículo presenta una técnica basada en Algoritmos Genéticos para la estimación de los parámetros y validación del modelo de la temperatura del aceite superior en transformadores de potencia propuesto por Lesieutre [1]. Para tal fin se emplean datos de un sistema de monitoreo y diagnóstico en línea instalado en un transformador de 100 MVA 230/115/24 kV OA/FA/FOA de la Subestación Barquisimeto de ENELBAR, Venezuela desde el año 2003. El objetivo de este trabajo es comparar la reducción del error entre el modelo y las mediciones reales de la temperatura del aceite superior cuando sus parámetros son estimados por algoritmos genéticos y mínimos cuadrados. La estimación de parámetros por algoritmos genéticos evidencia mejores resultados del modelo, lo cual incrementa su desempeño como herramienta de diagnóstico para transformadores de potencia.

**Palabras clave:** Algoritmos genéticos, estimación de parámetros, transformadores de potencia.

## Introducción

Los Transformadores de Potencia son parte de la estructura principal de las empresas de energía eléctrica venezolanas y del mundo, producto del papel que juegan en la transformación de los distintos niveles de tensión y potencia requeridos por las industrias, empresas y usuarios residenciales. En la actualidad, por razones económicas, de seguridad y medio ambientales, hay un mayor énfasis en mantenerlos un mayor tiempo en servicio de forma confiable y segura. En el caso particular de los sumergidos en aceite, que son los mayoritarios en los sistemas eléctricos, sus fallas catastróficas constituyen un peligro potencial para los seres humanos y el medio ambiente [2].

Desde este punto de vista, en los últimos años, la cargabilidad, el alargamiento de su vida útil y la detección prematura de las fallas han tomado un interés particular en las medianas y grandes empresas. En estos aspectos, el criterio principal que los limita está parcialmente determinado por la capacidad que tiene el transformador de disipar el calor generado internamente hacia el exterior de forma tal de poder trabajar en rangos de temperatura recomendados por el fabricante y las normas.

Con vista a complementar estos objetivos, en los últimos años, en los países más desarrollados se han instalado sistemas de diagnóstico en tiempo real para transformadores de potencia, con la finalidad de conocer de forma instantánea el estado o condición de los mismos y supervisar su funcionamiento en óptimas condiciones. Uno de los componentes imprescindible en estos sistemas son los modelos térmicos, cuyo desarrollo comienza por los recomendados en la norma IEEE Std. C57.91 [3] e IEC-354 [4], el anexo G de la norma IEEE Std. C57.91-1995 propuesto por Pierce [5] y otros desarrollados en los últimos años por Lesieutre [1], Tylavsky [6], Swift [7, 8], Lachman [9], Predhan [10], Tang [11] y Susa [12-14], entre otros. Su desarrollo y aplicación han variado con el tiempo, pero tanto unos como los otros dependen de los datos obtenidos de las estaciones en tiempo real, de la experiencia en la interpretación de los mismos y de las técnicas utilizadas para su tratamiento.

Por estas razones, en trabajos previos desarrollado por los autores [15-19], se seleccionó el

propuesto por Lesieutre [1]; en los que se han aplicado la estimación de parámetros a partir de mínimos cuadrados lineales y en los más recientes se experimenta con técnicas de inteligencia artificial (algoritmo genético y redes neuronales) cuyos resultados comparativos totales se publicarán en un próximo artículo. Sobre la exactitud del modelo, los autores durante más de cuatro años han obtenido resultados que concuerdan con los manifestados en [1, 6, 20].

Este trabajo enfoca la atención a la reducción del error en la predicción de la temperatura del aceite superior del modelo seleccionado, utilizando para la estimación de sus parámetros la técnica de Algoritmos Genéticos.

## Parte Experimental

### Estación experimental y tratamiento de los datos

En el año 2003 se introdujo una instalación en tiempo real en el autotransformador N° 2 de 100 MVA 230/115/24 kV OA/FA/FOA, de la subestación Barquisimeto propiedad de la Energía Eléctrica de Barquisimeto ENELBAR en Venezuela [18, 19, 21, 22], la cual aporta las variables necesarias que garantizan la aplicabilidad del referido modelo en línea y la de otros modelos que están siendo incorporados al sistema de diagnóstico original. En la Figura 1, se muestra el transformador seleccionado para su estudio.

El tiempo de muestreo escogido fue de 10 minutos. Las variables empleadas en el modelo son la corriente de carga, la temperatura ambiente y la temperatura del aceite superior, las cuales son registradas con equipos de adquisición de datos que garantizan el límite del error en  $\pm 0,5\%$ . El rango de medición de las variables son de hasta 40°C para la temperatura ambiente, hasta 150°C para la temperatura del aceite superior y de 502 A para la corriente de carga. Una vez comenzado a registrar y almacenar dichas variables, las cuales son analizadas estadísticamente, se comprobó que en algunos casos se comportan erráticamente y se observaron problemas eventuales en la medición producto de factores ambientales, picos de corriente de carga y respuesta del instrumento de medición de la temperatura del aceite superior. Para corregir esta situación y poder acceder a datos experimentales confiables



Figura 1. Transformador seleccionado.

para la estimación de parámetros del modelo térmico, se aplicó un control de calidad y filtrado de datos, cuyos procedimientos se explican en detalle en [19].

### Modelo matemático

El modelo para el cálculo de la temperatura del aceite superior dado por la IEEE Std. C57.91 en su cláusula 7 [3], es fundamental para la predicción de la temperatura del aceite superior. Sin embargo, tiene la limitación de que no es el más ideal, para ser aplicado en sistemas de monitoreo en línea (on-line). Buscando corregir esta deficiencia el grupo de investigación del MIT liderado por Lesieutre [1], propuso en el año 1997 el modelo modificado de la temperatura del aceite superior que es una mejora a la indicada en la referencia [3], así ellos proponen:

$$\tau_o * d\theta_o / dt = -\theta_o + \theta_a + \Delta\theta_{ou} \quad (1)$$

que de forma discretizada se expresa:

$$\theta_o[i] = k_1 * \theta_o[i-1] + (1 - k_1) * \theta_a[i] + [k_2 * (K[i])^2 + k_3]^n \quad (2)$$

Simplificando para el modo de enfriamiento "n" = 1; se reduce a la expresión del modelo lineal:

$$\theta_o[i] = k_1 * \theta_o[i-1] + (1 - k_1) * \theta_a[i] + k_2 * (K[i])^2 + k_3 \quad (3)$$

Finalmente, resulta un modelo lineal (3) que los autores [1, 6, 15-19, 20, 23] consideran para su simplificación "n"=1 y proceden a la

estimación de sus respectivos parámetros ( $k_1$ ,  $k_2$  y  $k_3$ ).

### Importancia de la estimación de los parámetros del modelo térmico

La aplicabilidad real en campo de este modelo (3), que rige el comportamiento de la temperatura del aceite superior, lleva implícito la obtención suficientemente aproximada de los parámetros que este presenta, a partir de mediciones experimentales de sus variables involucradas. De no ser así, sería imposible obtener una buena predicción del modelo para fines de diagnóstico, debido a que los errores previstos deben ser de baja cuantía (menor a 2°C) [1, 20, 23].

Para estos fines se pueden aplicar métodos de regresión múltiple suficientemente probados y validados como lo son los mínimos cuadrados lineales [1, 6, 15-19, 20, 23] y además está la posibilidad de experimentar con nuevas técnicas como es el caso de los Algoritmos Genéticos que hasta ahora no han sido reportadas en la literatura universal para este tipo de modelo en particular.

En este trabajo se presenta un enfoque basado en Algoritmos Genéticos [24], una técnica de la inteligencia artificial que puede ser usada en la optimización de ecuaciones, sin depender de su naturaleza.

### Breve análisis de algoritmos genéticos

Los Algoritmos Genéticos (AG) son una técnica de la Inteligencia Artificial donde los problemas a resolver son enfocados desde un punto de vista análogo a la teoría de la evolución genética [24-26]. Los AG resuelven problemas clásicos de optimización de ecuaciones:

$$\min_{x \in D} f(x) \quad (4)$$

donde:  $D$  = Espacio de búsqueda.

Haciendo pequeñas transformaciones en la función, se puede análogamente maximizar el valor de  $f(x)$ .

Las posibles soluciones  $x$  al problema planteado son representadas como un vector (o cromosoma) de componentes (o genes), que contienen la información de la solución. Entre ellas se definen procedimientos de selección, cruzamien-

to (encargados de mezclar, de forma aleatoria, partes de la información que tienen dos individuos) y mutación (encargados de cambiar aleatoriamente la información perteneciente a un individuo) [26].

Los individuos son seleccionados por un proceso análogo a la selección natural, que basado en el criterio que se persigue (min. ó máx.  $f(x)$ ) y también en cierta aleatoriedad, escoge los más fuertes; para con ellos realizar cruzamientos y mutaciones explorando el espacio de búsqueda  $D$  y de esta manera encontrar la mejor solución al problema.

Cada paso del proceso define una población (conjunto de  $j$  soluciones posibles) en la cual se conservan las  $z$  (generalmente  $z = 1$ ) mejores soluciones de la población anterior. Este proceso es llamado "Elitismo" [25], importante en los algoritmos genéticos, ya que garantiza la convergencia de estos a medida que aumenta el número de iteraciones.

En la Tabla 1 se describe el procedimiento utilizado para la implementación de un algoritmo genético.

Se define además un criterio adicional de parada para el proceso descrito, que puede estar en función de un valor lo suficientemente "bueno" de  $f(x)$ , una cantidad máxima de generaciones o generaciones sin mejoras en la solución, o incluso en función del tiempo demorado o tiempo demorado sin mejoras en la solución. Al final del proceso se escoge el mejor de los individuos. La convergencia al óptimo global está demostrada cuando los algoritmos genéticos utilizan el proceso de elitismo [25].

### Algoritmos genéticos para la estimación de parámetros

La estimación de parámetros  $k_1, k_2, k_3, \dots, k_x$  de una ecuación  $f(x)$  se puede definir como un problema de optimización donde la función de optimización (FO) será el mínimo error cuadrático medio (ECM) de la diferencia entre los valores reales (valores obtenidos mediante mediciones) y los valores estimados utilizando los valores de los parámetros en  $f(x)$  o sea:

$$\min_{k \in R^m} \sum_{i=0}^W (f(x_i) - y_i)^2 \tag{5}$$

donde se supone que se tiene un conjunto de entrenamiento  $(x_i, y_i)$  en el cual se encuentran los  $w$  datos a emplear en la estimación de los parámetros.

Un individuo es un vector  $k$  (de  $m$  componentes) de los parámetros de la función  $f(x)$ . Para ese vector de valores reales, se pueden definir las operaciones de mutación y cruzamiento lo que permite que el AG pueda explorar el espacio de soluciones del problema. Como función de optimización, el AG utiliza:

$$f(k_1, k_2, k_3) = \sum_{i=1}^W (\theta'_o[i] - \theta_o[i])^2 \tag{6}$$

donde

$$\theta'_o[i] = k_1 \theta_o[i - 1] + (1 - k_1) \theta_a[i] + k_2 (K[i])^2 + k_3 \tag{7}$$

Estas ecuaciones evalúan la exactitud de los parámetros del modelo, para un conjunto de

Tabla 1  
Procedimiento utilizado para la implementación de un algoritmo genético

Paso	Acción
1	Seleccionar aleatoriamente los $j$ individuos del espacio de búsqueda $D$ , que forman la población inicial.
2	Evaluar los individuos en la función $f(x)$ del problema.
3	Escoger los $z$ mejores individuos y pasarlos directo a la próxima población (elitismo).
4	Realizar la selección natural para elegir los mejores individuos adaptados a $f(x)$ y con ellos realizar mutaciones y cruzamientos para completar los $(j-z)$ individuos de la próxima población.
5	Si el criterio de parada no se ha alcanzado entonces volver al paso "2".
6	Dar como resultado el mejor individuo de la población final.

entrenamiento formado por mediciones experimentales de las magnitudes  $(\theta_a[i], K[i] \text{ y } \theta_o[i])$ .

Para la estimación de parámetros del modelo se empleó el programa Matlab® y su toolbox de algoritmos genéticos [27]. Se implementaron dos algoritmos genéticos con diferentes técnicas de selección, cruzamiento y mutación denominados AG1 y AG2. Sus ajustes fueron seleccionados en función de resultados previos obtenidos de múltiples configuraciones, para así escoger de entre ellas las dos mejores. En la Tabla 2 se muestran sus ajustes.

El resto de los parámetros requeridos por el toolbox quedaron ajustados por defecto [27].

### Metodología para la identificación y validación de los modelos térmicos

Los datos seleccionados para realizar el estudio fueron las semanas 1, 2 y 3 del mes de Octubre de 2007. Los conjuntos de entrenamiento (CE) son formados por las semanas 1 y 2 de forma independiente.

El conjunto de datos donde se evalúan los parámetros encontrados del modelo a partir del de entrenamiento, se denomina conjunto de validación (CV). El conjunto de validación de la semana 1 es la semana 2. El conjunto de validación de la semana 2 es la semana 3.

Se realizan 10 corridas de cada uno de los AG (AG1 y AG2), se calcula el promedio para evi-

tar los efectos estocásticos de estos algoritmos y se presenta la mejor solución particular.

Se realiza la estimación de parámetros del modelo por mínimos cuadrados (MC) empleando el software Gretl [28] para efectos comparativos.

Los criterios matemáticos empleados para evaluar los resultados de la estimación de parámetros son:

- Raíz del error cuadrático medio (RECM); dado por la expresión:

$$\sqrt{\frac{1}{W} \sum_{i=0}^W (\theta'_o[i] - \theta_o[i])^2} \quad (8)$$

- Media de los valores absolutos de los errores (ME) evaluados en todos los puntos:

$$\frac{1}{W} \sum_{i=0}^W |\theta'_o[i] - \theta_o[i]| \quad (9)$$

- Error Máximo (EMax) evaluado en todos los puntos:

$$\max_{0 \leq i \leq W} |\theta'_o[i] - \theta_o[i]| \quad (10)$$

## Resultados

A continuación se presenta en la Tabla 3 los resultados correspondientes a la estimación de parámetros por ambas técnicas para el modelo seleccionado.

Tabla 2  
Configuraciones de los AG seleccionados

Parámetros Ajustados	AG1	AG2
Tamaño de la población	80	80
Numero de generaciones	200	200
Número máximo de generaciones sin mejorar la solución	151	151
Tiempo máximo de generaciones sin mejorar la solución	Infinito	Infinito
Tipo de selección	Por Torneo de 4	Estocástica Uniforme
Tipo de cruzamiento	Intermedio (Intermediate)	Dispersado (Scattered)
Tipo de mutación	Gausiana de escala 1 y encogimiento 1	Uniforme con razón de 0,01

Tabla 3  
Resultados de la estimación de parámetros

Ajuste	Algoritmo	Corrida	Parámetros de la Ecuación			Errores en el Conjunto de Entrenamiento (°C)			Errores en el Conjunto de Validación (°C)		
			$k_1$	$k_2$	$k_3$	RECM	EM	EMax	RECM	EM	EMax
AG1		Promedio	0,9696	0,5237	0,3272	0,2685	0,1888	1,1317	0,2127	0,1432	1,3314
		Mejor Resultado	0,975	0,4416	0,2672	0,2689	0,1906	1,1090	0,2138	0,1463	1,3110
Semana 1	AG2	Promedio	0,9707	0,54595	0,3023	0,2684	0,1886	1,1333	0,2128	0,1432	1,3336
		Mejor Resultado	0,9718	0,3983	0,338	0,2687	0,1909	1,1050	0,2132	0,1461	1,3050
MC		Única	0,9708	0,5518	0,2979	0,2683	0,1886	1,1322	0,2129	0,1433	1,3301
AG1		Promedio	0,96905	0,49402	0,35581	0,2127	0,1441	1,3319	0,152	0,1146	0,7994
		Mejor Resultado	0,9771	0,4243	0,2417	0,2148	0,148	1,3090	0,1579	0,1201	0,7683
Semana 2	AG2	Promedio	0,9674	0,48753	0,38736	0,2128	0,1444	1,3334	0,1516	0,1141	0,8039
		Mejor Resultado	0,9641	0,1367	0,5835	0,2163	0,1552	1,2820	0,1582	0,1212	0,7809
MC		Única	0,9695	0,5027	0,3451	0,2127	0,1442	1,3295	0,1519	0,1145	0,8015

### Conjunto de entrenamiento

Al comparar los valores de los errores descritos en la Tabla 3, correspondientes al CE en la semana 1, se observa que la temperatura del aceite superior identificada con AG2 es más exacta que la identificada con AG1 y MC. El EMax de la identificación AG2 es de  $1,105^{\circ}\text{C}$ , mientras que del AG1 es  $1,109^{\circ}\text{C}$  y el del MC es de  $1,13^{\circ}\text{C}$ , lo que resulta en una mejora en la reducción del EMax del 2,65% con respecto al MC. Las RECM y EM se mantienen en valores muy similares. La identificación con AG1 es inclusive aun más exacta que la de MC.

En el CE en la semana 2, se observa que el EMax de la identificación AG2 es de  $1,28^{\circ}\text{C}$ , mientras que del AG1 es  $1,30^{\circ}\text{C}$  y el del MC es de  $1,33^{\circ}\text{C}$ , lo que resulta en una mejora en la reducción del EMax del 3,75% con respecto al MC. Las RECM y EM se mantienen en valores muy similares.

La identificación con AG1 es aún más exacta que la de MC. En la Figura 2 se observa el error de ambas predicciones para la semana 2.

### Conjunto de validación

En el CV correspondiente a la semana 2, la identificada con AG2 (Tabla 3) es más exacta que la identificada con AG1 y MC. El EMax de la identificación AG2 es de  $1,30^{\circ}\text{C}$ , mientras que del AG1 es  $1,31^{\circ}\text{C}$  y el del MC es de  $1,33^{\circ}\text{C}$ , lo que resulta en una mejora en la reducción del EMax del 2,25% con respecto al MC. Las RECM y EM se mantienen en valores muy similares.

En el CV en la semana 3, el EMax de la identificación AG1 es de  $0,76^{\circ}\text{C}$ , mientras que del AG2 es  $0,78^{\circ}\text{C}$  y el del MC es de  $0,80^{\circ}\text{C}$ , lo que resulta en una mejora en la reducción del EMax del 5% con respecto al MC. Las RECM y EM se mantienen en valores muy similares. Se observa además que la identificación con AG2 es aun más exacta que la de MC. En la Figura 3 se observa el error en el CV para la semana 3.

En la Figura 4 se observa el desempeño de los modelos identificados en la porción donde ocurre el mayor EMax para el CV de la semana 3.




Figura 2. Error de entrenamiento en la semana 2.

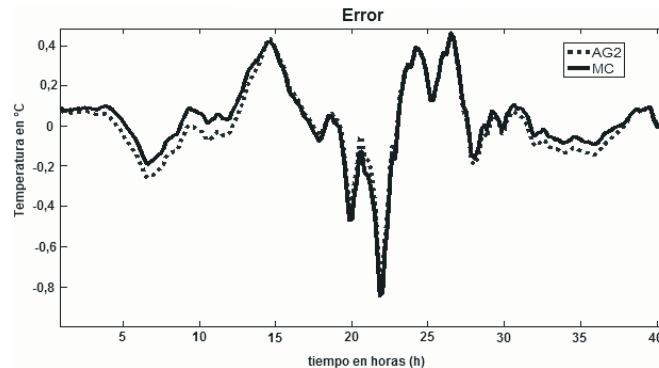


Figura 3. Error en el conjunto de validación semana 3.

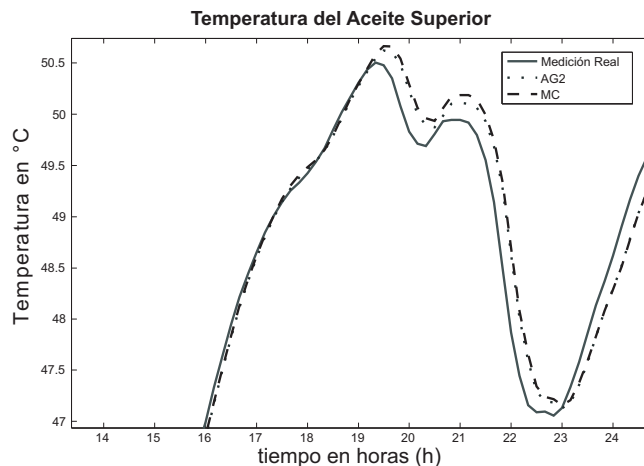


Figura 4. Temperatura del aceite superior medida y modelada por AG2 y MC.

## Conclusiones y Recomendaciones

Se ha evidenciado de acuerdo a los resultados prácticos obtenidos que el uso de los algoritmos genéticos en sus dos variantes AG1 y AG2, para la estimación de parámetros del modelo seleccionado, tiene un mejor desempeño que la estimación de parámetros por mínimos cuadrados lineales, que se refleja en un menor EMax al compararlo con los valores experimentales medidos y donde además las RECM y EM se encuentran en valores muy cercanos al obtenido por MC.

De igual forma se observa que el algoritmo AG2, tiene un mejor comportamiento promedio que el AG1, motivado por el uso de diferentes parámetros de cruzamiento, mutación y selección.

Se sugiere el desarrollo de trabajos futuros en la estimación por algoritmo genético de parámetros de otros modelos desarrollados para la temperatura del aceite superior.

Finalmente, se puede observar que ambas técnicas (AG y MC) son excelentes para la predicción de la temperatura del aceite superior y que se evidencian por su bajo error máximo, raíz del error cuadrático medio y media de los valores absolutos de los errores que están muy por debajo de 2°C, utilizados por diferentes autores [1, 6, 23] e instituciones internacionales para la validación de sus resultados experimentales.

## Símbolos y Acrónimos

$\theta_o$  : Temperatura del aceite superior, °C.  
 $\theta_a$  : Temperatura ambiente, °C.

$\Delta \theta_{ou}$  : Último aumento de temperatura del aceite superior °C.

$k_1, k_2, k_3$ : Parámetros del modelo

$n$  : Exponente empírico usado para calcular la variación de  $\Delta \theta_o$  con los cambios en la corriente de carga.

$\tau_o$  : Constante de tiempo térmica del aceite superior, horas.

$K$  : Relación de corriente de carga / a corriente nominal.

## Referencias Bibliográficas

1. Lesieutre B., Hagman W., Kirtley J.: "An Improved Transformer Top Oil Temperature Model for Use in An On-Line Monitoring and Diagnostic System". IEEE Transactions on Power Delivery, Vol. 12, N° 1, (1997) 249-256.
2. Morris, T.: "Comparing Parameter Estimation Techniques for an Electrical Power Transformer Oil Temperature Prediction Model". Langley Research Center. NASA (1999) 3-87.
3. IEEE, Guide for Loading Mineral-Oil-Immersed Transformers. Standard C57.91-1995, (1995)
4. IEC, Loading Guide for Oil Immersed Power Transformers. IEC-354-91, (1991).
5. Pierce, L.W., "Predicting Liquid Filled Transformer Loading Capability". IEEE Transactions on Industry Applications, Vol. 30, N° 1, (1994) 170-178.



6. Tylavsky, D., He, Q., McCulla, G. y Hunt, J.: "Transformer Top-Oil Temperature Modeling and Simulation". IEEE Transactions on Industry Applications, Vol. 36, N° 5, (2000) 1219-1225.
7. Swift, G., Bray, R., Menzies, R.: "A Fundamental Approach to Transformer Thermal Modeling. Part I". IEEE Transactions on Power Delivery, Vol. 16, N° 2, (2001) 171-175.
8. Swift, G., Bray, R., Menzies, R.: "A Fundamental Approach to Transformer Thermal Modeling. Part II". IEEE Transactions on Power Delivery, Vol. 16, N° 2, (2001) 176-180.
9. Lachman, M., Griffin, P., Walter, W. y Wilson, A.: "Real-Time Dynamic Loading and Thermal Diagnostic of Power Transformers". IEEE Transactions on Power Delivery, Vol. 18, N° 1, (2003) 142-148.
10. Pradhan, M., Ramu T.: "Prediction of Hottest Spot Temperature (HST) in Power and Station Transformers". IEEE Transactions on Power Delivery, Vol. 18, N° 4, (2003) 1275-1283.
11. Tang, W., Wu, H., Richardson, Z.: "A Simplified Transformer Thermal Model Based on Thermal-Electric Analogy". IEEE Transactions on Power Delivery, Vol. 19, N° 3, (2004) 1112-1119.
12. Susa, D., Lehtonen, M., y Hasse, N.: "Dynamic Thermal Modelling of Power Transformers". IEEE Transactions on Power Delivery, Vol. 20, N° 1, (2005) 197-204.
13. Susa, D., Lehtonen, M.: "Dynamic Thermal Modelling of Power Transformers-Further Development: part I". IEEE Transactions on Power Delivery, Vol. 21, N° 4, (2006) 1961-1970.
14. Susa, D., Lehtonen, M.: "Dynamic Thermal Modelling of Power Transformers: further Development-part II". IEEE Transactions on Power Delivery, Vol. 21, N° 4, (2006) 1971-1980.
15. Ramírez, O., Fernández, S.: "Introducción de un modelo térmico para el diagnóstico en tiempo real de transformadores". Memorias del Simposio Internacional Sobre Diagnóstico en Equipos Eléctricos y procesos Industriales DIAGNOS' 2000. Ciudad de La Habana, Cuba, (2000) 54-57
16. Ramírez, O.: "Modelación físico-matemática para el diagnóstico de grandes transformadores en tiempo real"- Tesis presentada en opción al grado científico de Doctor en Ciencias Técnicas. ISPJAE- CUBA. (2001) 35-74.
17. Pérez R, Fernández S, Ramírez O.: "Modernos métodos de diagnóstico aplicados a grandes transformadores en tiempo real", Revista Edelca, Año XXV, N° 4, (2002) 22-23.
18. Pérez R., Ramírez O., Fernández S.: "Sistema de Diagnostico de Transformadores de Potencia a Distancia". Revista Universidad Ciencia y Tecnología. Volumen 10, N° 41, (2006) 269-275.
19. Pérez, R., Fernández, Y., Matos, E., Fernández S.: "Procesamiento de Datos Mediante Wavelet para la Modelación Térmica de Grandes Transformadores". Artículo actualmente arbitrado para su publicación en la Revista Técnica de la Universidad del Zulia. Venezuela.
20. Tylavsky, D., Mao X., McCulla, G.: "Transformer Thermal Modeling: Improving Reliability Using Data Quality Control". IEEE Transactions on Power Delivery, Vol. 21, N° 3, (2006) 1357-1366.
21. Fernández, S., Ramírez O.: "Mediciones Fundamentales para el Diagnostico de Transformadores en Tiempo Real. Parte I". Revista Ingeniería Energética. Vol. XVIII, Números 1, 2 y 3, (1996) 7-12.
22. Fernández, S., Ramírez, O.: Leal, A., Cabrera, L.J., "Hardware y software para el diagnóstico en tiempo real del estado de transformadores de potencia". Memorias del evento: "Reunión de verano de potencia y exposición industrial de la IEEE Acapulco, México (1997) 87-91.
23. Vilaithong, R., Tenbohlen, S., Stirl T.: "Improved Top Oil Temperature model for Unsteady-State Conditions of Power Transformers". Proceedings of the XIVth International Symposium on High Voltage Engineering, China (2005) F-42. Disponible en [www.uni-stuttgart.de/ieh/forschung/veroeffentlichungen/2005\\_ish\\_rummiya.pdf](http://www.uni-stuttgart.de/ieh/forschung/veroeffentlichungen/2005_ish_rummiya.pdf).

24. Gen, M., Cheng, R.: "Genetic Algorithms and Engineering Optimization". Wiley-IEEE, (2000).
  25. Coello, C.: "Introducción a la Computación Evolutiva (Notas de Curso)", CINEVESTAV-IPN. Instituto Politécnico Nacional México (2003).
  26. Günter, R.: "Convergence Analysis of Canonical Genetic Algorithms". IEEE Transactions on Neural Networks, Vol. 5, (1994) 96-101.
  27. Matlab®. The Language of Technical Computing. Toolbox Genetic Algorithm. Version 7.2.0.232,(2006). [http://www.mathworks.com/access/helpdesk\\_r13/help/toolbox/gads/gads\\_re3.html#6174](http://www.mathworks.com/access/helpdesk_r13/help/toolbox/gads/gads_re3.html#6174).
  28. Software "Gnu Regression, Econometrics and Time-series Library". Gret1 (2006).
- Recibido el 10 de Agosto de 2008  
En forma revisada el 6 de Julio de 2009