

Sintonización de parámetros de modelos dinámicos para OTS de sistemas de potencia

<https://doi.org/10.51378/ilia.vi1.8525>

W. Alguera¹, W. Berríos¹, V. Ibarra¹, J. Vargas¹, J. Martínez¹

¹ Departamento de Ciencias Energéticas y Fluídicas, Universidad Centroamericana José Simeón Cañas, UCA, El Salvador
E-mail: 00084817@uca.edu.sv

Resumen—Un simulador de entrenamiento para operadores en tiempo real de un sistema eléctrico de potencia es una herramienta de suma importancia para introducir al operador al comportamiento eléctrico y dinámico de los sistemas de energía basado en modelos matemáticos de los elementos que los conforman ante diferentes perturbaciones. La presente investigación consiste en el desarrollo de una herramienta informática para la sintonización de parámetros de los modelos dinámicos de unidades generadoras utilizando algoritmos genéticos y optimización por enjambre de partículas. Se realiza la sintonización para el modelo de una central térmica e hidroeléctrica y se compara la eficiencia en cada técnica basado en el índice de desempeño de la raíz del error cuadrático medio (RMSE, por sus siglas en inglés) y tiempos de simulación. Con base a los resultados obtenidos entre las técnicas de sintonización se observa que mediante algoritmos genéticos se logra un menor valor del indicador de desempeño, mientras que optimización por enjambre de partículas se tiene menos precisión, pero requiere menores tiempos de simulación.

Palabras Clave— algoritmo genético, optimización por enjambre de partículas, OTS, sintonización

I. INTRODUCCIÓN

En la actualidad es parte fundamental de los sistemas de Supervisión, Control y Adquisición de Datos (SCADA, por sus siglas en inglés) disponer en ellos lo que la industria del control de sistemas llama “simuladores de entrenamiento” para operadores. El propósito, como deja identificar el nombre genérico, es entrenar a los operadores de sistemas eléctricos de potencia (SEP) en un ambiente muy parecido -sino igual- al percibido en tiempo real. Estos simuladores emulan, entre otros muchos aspectos, la dinámica del comportamiento de los equipos reales, y para cumplir con este cometido basan su respuesta en modelos matemáticos de las variables de estado del sistema, equipo o mando que intentan representar.

Por lo tanto, es esencial que dentro del desarrollo de un sistema de entrenamiento para operadores en tiempo real (OTS por sus siglas en inglés), se utilicen los modelos matemáticos que se acoplen de mejor manera no solo al objetivo deseado sino también a las condiciones que la unidad generadora posee [1]. Es por ello que luego de una investigación dedicada a identificar posibles técnicas de sintonización que ayudasen a determinar el ajuste de los parámetros de un modelo de control para lograr un comportamiento aceptable con algún criterio de desempeño

establecido, las técnicas de Algoritmos Genéticos (AG) y Optimización por Enjambre de Partículas (PSO) demostraron mejores respuestas mediante la simulación de diferentes escenarios haciendo uso de programación en MATLAB® y con ayuda de herramientas derivadas del programa como lo son Simulink® y el Optimization Toolbox™.

II. METODOLOGÍA

A. Herramientas utilizadas

La herramienta donde se desarrollaron los métodos de sintonización fue MATLAB®, junto con algunos de sus complementos como Simulink®, donde se diseñaron los diagramas de bloque de los sistemas de control; y Optimization Toolbox™, donde se ingresó el problema de optimización y se obtuvo un código para AG. El modelo de PSO se realizó al completo con programación en MATLAB®.

B. Modelos matemáticos de sintonización

Considerando la información disponible para implementar un modelo de optimización ideal para la aplicación y las diferencias explicadas en [3], se seleccionó Algoritmos Genéticos y PSO como las técnicas a utilizar. Las técnicas de AG y PSO son importantes en diferentes ramas de la ingeniería, para el caso de esta investigación, una aplicación específica de los sistemas eléctricos de potencia, mediante la optimización de la función del error cuadrático medio para minimizar la diferencia entre la respuesta real de la unidad o máquina generadora y lo percibido en el OTS ante un mismo evento. Ahondar en su fundamento matemático es esencial para llevarlo a un código de programación.

1. Algoritmo genético

En [4] se explica que los algoritmos genéticos fueron introducidos por John H. Holland a principios de los setenta y son, por mucho, la técnica evolutiva más popular en la actualidad. Se basan en el principio de supervivencia de los organismos más aptos y su objetivo principal es encontrar una solución aceptable a un problema por medio del mejoramiento de individuos mediante una función objetivo.

Su funcionamiento comienza creando aleatoriamente una población inicial. Cada individuo recibe el nombre de cromosoma, el cual es una posible solución al problema. Los cromosomas van mejorando sus características en cada

iteración, a este proceso se le conoce como generación. Cada generación es evaluada en la función objetivo. Luego, mediante el cruce y mutación, se seleccionan los cromosomas con mayor probabilidad de supervivencia para dar paso a una nueva generación.

El algoritmo AG maneja una población de posibles soluciones y cada solución se representa a través de un cromosoma. La codificación de todas las posibles soluciones en un cromosoma es la primera parte, pero luego se debe determinar un conjunto de operadores de reproducción genético. Estos operadores se aplican sobre los cromosomas y se utilizan para realizar mutaciones y recombinaciones sobre las soluciones del problema [5].

Una vez definida la función objetivo, el algoritmo empieza generando una población inicial de cromosomas. Posteriormente, según se explica en [5], el algoritmo empieza un proceso de iteración, donde cada iteración consiste de la selección, el cruzamiento y la mutación. La fig. 1 muestra el flujograma del algoritmo genético.

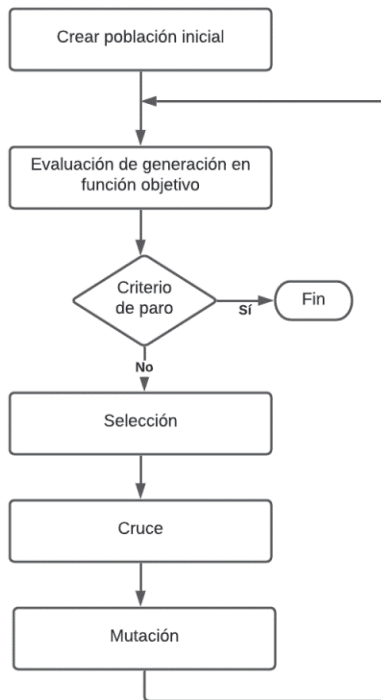


Fig. 1. Flujograma de AG

En [6] se explica que el proceso de selección consiste en seleccionar a los individuos más calificados para continuar y reproducirse hacia una nueva generación. Puesto que se trata de imitar lo que ocurre en la naturaleza, se ha de otorgar un mayor número de oportunidades de reproducción a los individuos más aptos. Algunos de los tipos de selección que se tiene son selección por rueda de ruleta, selección por torneo, selección elitista y selección proporcional a la aptitud.




Fig. 2. Ejemplo de selección donde se otorga un valor dentro de un intervalo de [0,1] a cada individuo

El proceso de cruzamiento recombina la información genética de dos individuos para producir un tercer individuo que comparte la información de los dos anteriores. Este tercer individuo posee características mejores de adaptación al medio [6]




Fig. 3. Ejemplo de cruzamiento de dos individuos

La mutación de un individuo provoca que alguno de sus genes, generalmente uno solo, varíe su valor de forma aleatoria. En [6] se explica que, aunque se pueden seleccionar los individuos directamente de la población actual y mutarlos antes de introducirlos en la nueva población, la mutación se suele utilizar de manera conjunta con el operador de cruce. El operador de mutación busca mantener la diversidad de la población y así evitar que el algoritmo lleve a mínimos locales. Al finalizar la mutación, se tienen individuos completamente nuevos para completar la nueva generación. En la fig. 4 se puede observar un ejemplo sencillo del operador de mutación y cruce.




Fig. 4. Individuos sometidos a la operación de cruzamiento y mutación

Para sintonizar con algoritmos genéticos se utilizó la herramienta “Optimization Toolbox™” de MATLAB®, el cual posee el solucionador AG. El funcionamiento de la herramienta es sencillo, se debe ingresar la función objetivo y especificar el número de variables. A continuación, se deben ingresar las restricciones, para el caso de estudio toma mucha relevancia esta opción ya que los parámetros a sintonizar se limitan a ciertos intervalos, también si la aplicación en estudio lo requiera, se pueden incluir restricciones de inecuaciones lineales, ecuaciones lineales, función de restricción no lineal y variables de los índices enteros, esto es debido a que es una herramienta genérica y la optimización de funciones es aplicable a muchos casos.

Se hace notar que la herramienta permite configurar las diferentes etapas que conforman el proceso que se explicó anteriormente de AG. Por último, se genera un código de la herramienta que toma en cuenta todas las consideraciones que se hicieron en la interfaz que se detallan a continuación:

- Tamaño de población: 50 individuos.
- Adecuación de escala: a Rango.
- Función de selección: uniforme estocástico.
- Número de individuos que están garantizados para sobrevivir para la siguiente generación: 2 individuos.
- Fracción de individuos de la siguiente generación que son producidas por cruce: 0.8.
- Criterios de paro: tolerancia de 0.1, el usuario especifica el número máximo de iteraciones y si el valor de tolerancia no cambia después de 50 iteraciones, también se detiene la optimización.

Las demás opciones se dejan por defecto como recomienda el fabricante de la herramienta.

2. PSO

El algoritmo PSO fue presentado James Kennedy y Russel Eberhart en 1995 en una conferencia organizada por la IEEE y se basa en el movimiento natural y la inteligencia de una bandana de pájaros [4]. La idea principal del método es mover un número predefinido de partículas a través de un espacio de búsqueda para encontrar la mejor solución.

Según se explica en [7], PSO inicia con una población inicial. Cada partícula del enjambre representa un candidato a solución del problema. El algoritmo se guía por las experiencias particulares y globales y el movimiento de las partículas hacia la siguiente posición en el espacio de búsqueda. El desempeño de cada partícula se mide usando una función objetivo que se formula con base en el problema a resolver.

Cada partícula es representada por una posición x_i y velocidad v_i en cada iteración. La mejor posición de la partícula en cada iteración se le conoce como P_{best} ; también se evalúa la mejor posición encontrar entre todas las partículas de la población, conocida como G_{best} .

Para cada iteración, la posición y la velocidad de una partícula se actualiza según Ec. 1 y Ec. 2.

$$x_{i,j}^{k+1} = x_{i,j}^k + v_{i,j}^{k+1} \quad (Ec. 1)$$

$$v_{i,j}^{k+1} = wv_{i,j}^k + c_1r_1(Pbest_{i,j}^k - x_{i,j}^k) + c_2r_2(Gbest_j^k - x_{i,j}^k) \quad (Ec. 2)$$

Donde:

- i Índices de las partículas
- j Dimensión del espacio de búsqueda
- $v_{i,j}^k$ Velocidad de la partícula i en la posición actual
- $v_{i,j}^{k+1}$ Velocidad futura de la partícula i
- $x_{i,j}^k$ Posición actual de la partícula i
- $x_{i,j}^{k+1}$ Posición futura de la partícula i
- $Pbest_{i,j}^k$ Mejor solución local
- $Gbest_j^k$ Mejor solución global
- w Peso inercial
- r_1, r_2 Números aleatorios dentro del rango de 0 y 1
- c_1, c_2 Factores de aprendizaje
- k Número de iteración

La fig. 5 presenta un flujograma del trabajo del algoritmo PSO.

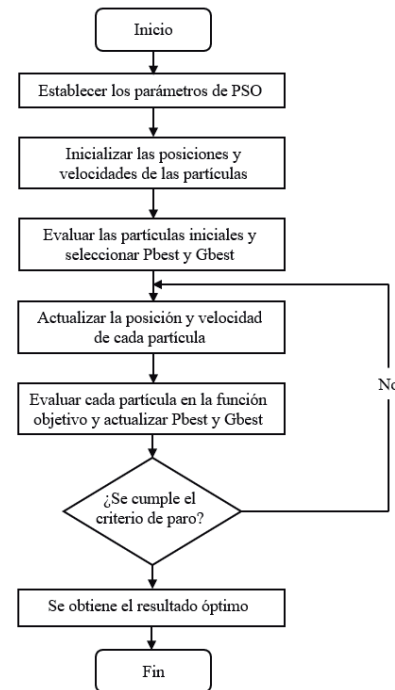


Fig. 5. Flujograma de PSO

A continuación, se detallan los parámetros necesarios para desarrollar el algoritmo de PSO.

El tamaño del enjambre se define como el número de partículas dentro del espacio de búsqueda. Este número

determina las posibles soluciones del problema, entre mayor sea este número, mayor será el espacio de búsqueda que se abarca dentro de los límites establecidos. Según se menciona en [8], numerosos estudios empíricos sugieren que el algoritmo tiene capacidad de llegar a resultados óptimos desde una población pequeña de 10 partículas. Después de realizar pruebas, se encontró que una cantidad adecuada de partículas es de 50.

Los factores de aprendizaje c_1 y c_2 representan factores de confianza de cada partícula, c_1 representa la confianza que la partícula tiene en sí misma, mientras que c_2 es la confianza que tiene con sus partículas vecinas [8]. En [9] se recomienda que los valores deben estar cerca entre sí para asegurar la convergencia del problema. Para la investigación, se trabajó con valores de 1.4 y 2.5 para c_1 y c_2 respectivamente.

El peso inercial controla el movimiento de la partícula al ponderar la contribución de la velocidad anterior y cuánto del recuerdo de esta velocidad influye en la nueva velocidad de la partícula [8]. Según [8] la inercia varía entre los rangos de 0.4 a 0.9.

C. Función objetivo

Los algoritmos de optimización explicados son procesos iterativos, repetidas iteraciones de cada algoritmo se ejecutan hasta que se cumpla un criterio de paro definido previamente. Uno de los criterios de paro, que a su vez es parte fundamental de los algoritmos es la función objetivo, también conocida como función *fitness*. Esta función permite evaluar el desempeño de los candidatos a solución dentro del proceso de optimización, ya sean individuos (AG) o partículas (PSO) y representa el problema de optimización.

Las técnicas de sintonización buscan encontrar el mejor ajuste de los parámetros de los modelos de control de centrales de generación, para el caso de nuestra investigación centrales hidroeléctricas y térmicas, con el objetivo de replicar la respuesta real de las máquinas ante diferentes disturbios propios de la naturaleza del SEP. Con esto en mente, la función objetivo a evaluar con los algoritmos de optimización es el indicador de desempeño de la técnica de la Raíz del Error Cuadrático Medio (RMSE). Cada algoritmo buscará minimizar el valor del RMSE, tal que la curva del modelo presente un error lo más pequeño posible y represente a la curva real de potencia eléctrica de la unidad de generación.

La función objetivo entonces, está dada por la Ec. 3.

$$FO: RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y})^2} \quad [MW] \quad (Ec. 3)$$

Donde:

- y_i Valor obtenido (MW)
- \hat{y} Valor real (MW)
- n Número de datos utilizados

D. Modelos dinámicos del OTS

Luego de definir claramente el objetivo que persigue la investigación se procedió a seleccionar los modelos dinámicos, que son un punto clave al momento de elaborar un OTS. Dependiendo de la elección de estos se obtienen diferentes tiempos de simulación, resultados y exigencias del equipo. Es por ello que deben evaluarse variaciones de modelos estudiados previamente para poder elegir el que mejor responda a los objetivos buscados.

Una de las conclusiones presentadas en [1], donde se muestran tres niveles de modelos, es que utilizar un modelo dinámico de tercer nivel no siempre arrojará los mejores resultados, debido a que ciertas consideraciones son dejadas de lado y comprometen la fidelidad de la respuesta, en especial cuando la planta es más compleja.

Teniendo en consideración esta base, se estructuraron los modelos dinámicos hidroeléctrico y térmico mostrados en fig. 6 y fig. 7.

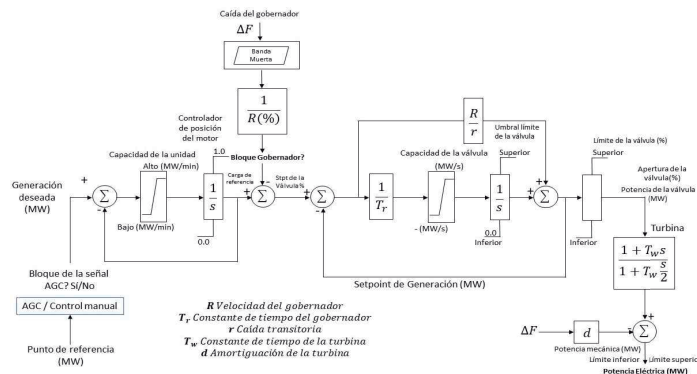


Fig. 6. Diagrama de bloques de modelo de central hidroeléctrica

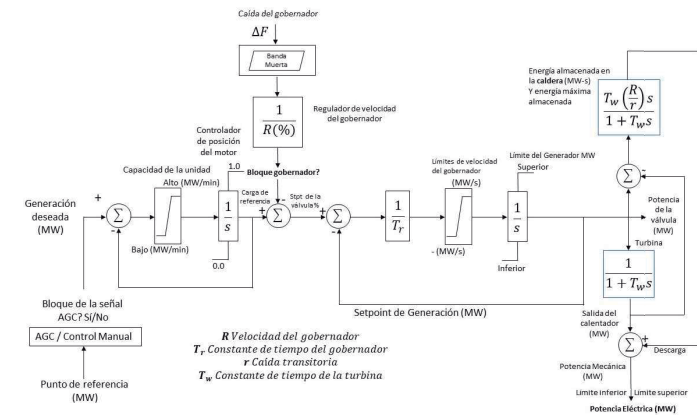


Fig. 7. Diagrama de bloques de modelo de central térmica

Las variables a sintonizar para los modelos de control son las constantes de tiempo del gobernador y de la turbina, T_g y T_w respectivamente; la velocidad del gobernador R y la caída transitoria r . Según el estudio hecho en [10], los bloques que corresponden a las saturaciones de las unidades generadoras se mantienen constantes, ya que sus valores están dados por los límites reales de cada unidad. Las posiciones de las

válvulas controladas por el gobernador también son tomadas como constantes para la sintonización.

Se realizaron ensayos de sintonización con el objetivo de comparar y analizar el desempeño de AG y PSO, para llevar a cabo estas pruebas de sintonización se hizo un pre procesamiento de datos antes de importar los datos al sintonizador. Se realizaron cuatro pruebas de sintonización: sintonización de un modelo térmico mediante AG, sintonización de un modelo térmico mediante PSO, sintonización de un modelo hidroeléctrico mediante AG y sintonización de un modelo hidroeléctrico mediante PSO. Los ensayos de sintonización se ejecutaron tomando como base los datos registrados por los equipos de medición de potencia y frecuencia de la UT.

El espacio de búsqueda de los algoritmos se definió dentro de los límites de 0.1 a 50 para cada variable, con el objetivo de permitir a cada técnica explorar todo el espacio y reducir la posibilidad de caer en mínimos locales que eviten resolver el problema de optimización de forma óptima.

E. Criterios de paro

La función objetivo representa el problema de optimización y para nuestro estudio, buscamos minimizarla. Al llegar a un valor de RMSE que permita concluir que la curva del modelo es representativa de la curva real de potencia generada por la unidad, se detiene la simulación; sin embargo, este no es el único criterio de paro que tienen los algoritmos, ya que cuando el valor de la función objetivo necesario para el paro es un valor previamente establecido pero, no tiene por qué siempre llegar a este valor, se puede dar el caso que se encuentre muy cerca del valor definido pero que aún no sea capaz de alcanzarlo. Para estos casos se necesita un segundo criterio de paro que estará definido por el número máximo de iteraciones.

F. Preprocesamiento de datos

Se debe definir el formato de la base de datos que se ingresará al programa, para este caso se definió que debido a la compatibilidad entre el software MATLAB® y Microsoft Excel® lo más conveniente sería utilizar esta herramienta para la importación de datos. El formato se estableció tomando en cuenta la estructura del código del programa, procurando mantener el orden y claridad de la base de datos para la comprensión del usuario. El formato se muestra en la tabla 1.

Tabla 1. Formato de importación de datos

Potencia Eléctrica Real (MW)	Set Point AGC (MW)	Frecuencia (Hz)
-	-	-

Se trabajó con patrones de datos que contengan escalones ascendentes y descendentes para representar de manera más acertada las situaciones que se podrían analizar en un OTS.

Además, este tipo de función facilita el análisis matemático y experimental de los sistemas de control. Otro aspecto a tomar en cuenta es la cantidad de datos a procesar para la sintonización de parámetros, se debe encontrar un equilibrio entre un número de datos que garantice una precisión óptima de resultados y a su vez, el tiempo de procesamiento no sea demasiado prolongado debido a una cantidad extensa de datos.

La capacidad de procesamiento de datos del equipo en el cual se ejecute el programa también será un factor a tomar en cuenta para la cantidad de datos que se ingresaran al programa. El proceso para definir el número óptimo de datos se estableció de forma heurística buscando encontrar el equilibrio mencionado anteriormente. El rango del número de registros obtenido fue de 2400 a 3500, con los cuales se obtuvieron resultados con una precisión aceptable y con tiempos de procesamiento relativamente cortos.

III. RESULTADOS Y DISCUSIÓN

Para evaluar los resultados se grafica el comportamiento de los modelos hidroeléctricos y térmicos utilizando las técnicas de sintonización de parámetros seleccionadas. Las variables a sintonizar para los modelos de control son las constantes de tiempo del gobernador y de la turbina, T_g y T_w respectivamente; la velocidad del gobernador R y la caída transitoria r .

A. Modelo de central hidroeléctrica

Para este caso de estudio se tomaron como base los datos del *setpoint* del Control Automático de Voltaje (AGC, por sus siglas en inglés) del generador y su respuesta real tomada por el equipo de medición de la central hidroeléctrica 5 de Noviembre. La sintonización utilizando PSO se observa gráficamente en la fig. 8 y se detalla los resultados en la tabla 2.




Fig.8. Sintonización con PSO de modelo hidroeléctrico

Tabla 2. Parámetros sintonizados con PSO de modelo hidroeléctrico

# Iteraciones	Constante de tiempo de la turbina. (T_w)	Velocidad del gobernador (R)	Caída transitoria (r)	Constante de tiempo del gobernador (T_r)	RMSE
25	1.81886	49.5311	6.8624	3.96068	0.391051

En la fig. 9 se muestra la gráfica de la sintonización con AG, obteniéndose los resultados detallados en la tabla 3.




Fig. 9. Sintonización con AG de modelo hidroeléctrico

Tabla 3. Parámetros sintonizados con AG de modelo hidroeléctrico

Iteraciones	Constante de tiempo de la turbina. (Tw)	Velocidad de gobernador (R)	Caída transitoria (r)	Constante de tiempo del gobernador (Tr)	RMSE
1	2.90885	10.9917	0.560595	0.319922	0.402552
10	1.81886	48.9686	7.3624	4.14818	0.391136
25	1.81886	49.5311	6.8624	3.96068	0.391051
50	1.8257	49.7108	6.51865	3.83568	0.3910
Δ % a primer iter.	37.24 %	352.26 %	1062.81 %	1098.94 %	2.87 %

Se observa que la técnica de sintonización de AG proporcionó mejores resultados comparándola contra PSO tomando como base el índice de desempeño RSME, sin embargo, el tiempo de simulación requerido para PSO es menor para completar las 25 iteraciones. Los valores de los parámetros con PSO no presentaron un cambio en el indicador de desempeño, aun cuando éstos cambiaron, no se vio reflejado significativamente en el RMSE, manteniéndose sin cambiar para un número significativo de iteraciones. En cambio, la técnica de AG permite mostrar una evolución en el desempeño del algoritmo, evidenciado por la disminución según el número de iteraciones del RMSE.

B. Modelo de central térmica

Para este caso de estudio se tomó como base los datos del setpoint de AGC y su respuesta real de una de las unidades generadoras de la planta térmica Acajutla. La fig. 10 muestra la gráfica de la sintonización con PSO, obteniéndose los resultados detallados en la tabla 4.




Fig. 10. Sintonización con PSO de modelo térmico

Tabla 4. Parámetros sintonizados con PSO de modelo hidroeléctrico

# Iteraciones	Constante de tiempo de la turbina. (Tw)	Velocidad del gobernador (R)	Caída transitoria (r)	Constante de tiempo del gobernador (Tr)	RMSE
25	1.81886	49.5311	6.8624	3.96068	0.391051

La fig. 11 muestra la gráfica de la sintonización del modelo de la central térmica con AG, donde se obtuvo los resultados detallados en la tabla 5.




Fig. 11. Sintonización con AG de modelo térmico

Tabla 5. Parámetros sintonizados con AG de modelo térmico

# Iteraciones	Constante de tiempo de la turbina. (Tw)	Velocidad del gobernador (R)	Caída transitoria (r)	Constante de tiempo del gobernador (Tr)	RMSE
1	0.1	36.9092	18.7184	5.74997	0.252121
10	0.1	37.1624	3.78809	1.40892	0.173494
25	0.33878	17.8525	1.80522	0.447057	0.17405
50	0.24910	20.1131	2.06129	0.811204	0.173894
Δ % a primer iter.	149.10 %	45.51 %	88.99 %	85.892 %	31.03 %

Al igual que en el caso del modelo hidroeléctrico, se observa que la técnica de sintonización de AG proporcionó mejores resultados comparándolo contra PSO tomando como base el índice de desempeño RSME, sin embargo, el tiempo de simulación requerido para PSO es menor para completar

las 25 iteraciones. De igual forma al modelo hidroeléctrico, los valores de los parámetros con PSO no presentaron un cambio en el indicador de desempeño, manteniéndose sin cambiar para un número significativo de iteraciones. En cambio, la técnica de AG permite mostrar una evolución en el desempeño del algoritmo, evidenciado por la disminución según el número de iteraciones del RMSE.

IV. CONCLUSIONES

En el trabajo de investigación se desarrolló una herramienta computacional basada en métodos de optimización con algoritmos genéticos y enjambre de partículas, que permitió ajustar los parámetros de los modelos utilizados en el OTS obteniendo resultados representativos a la respuesta real de una unidad generadora operando en tiempo real en el sistema eléctrico de potencia. Resultados que permiten al operador estar preparado ante diferentes eventos propios de la naturaleza del sistema.

Con base en las simulaciones y resultados obtenidos entre las técnicas de sintonización se observa que mediante AG se logra un menor valor del indicador de desempeño y con PSO se requiere menor tiempo de simulación, además para garantizar valores óptimos de los parámetros sintonizados se establecieron dos criterios de paro, con número de iteraciones o cumpliendo cierta tolerancia para encontrar el mínimo relativo lo suficientemente bajo para que su respuesta se considere aceptable. Se concluye sobre la importancia de poseer la información suficiente de potencia eléctrica real y Set-Point del AGC para poder seleccionar un rango de datos que garanticen una buena sintonización.

A partir de los resultados de la sintonización de los diferentes casos de estudio, queda en evidencia la relación directamente proporcional entre la complejidad de los modelos y el tiempo de simulación necesario para llegar a una respuesta aceptada, desde modelos con una sola variable con tiempos de convergencia pequeños hasta los modelos del OTS con cuatro variables y con todo un sistema de control complejo, con entradas de datos reales que no siguen una estabilidad total debido a la naturaleza del SEP. En la misma línea, los algoritmos presentan un mejor desempeño con cada iteración realizada, mejorando así sus modelos internos de posición de partículas y generaciones.

Se observó que en los modelos de los generadores en donde se incorporó como entrada el cambio de frecuencia del sistema, fue indispensable retomar como bibliografía el ROBCP para definir el porcentaje de operación de la banda muerta del gobernador y con ello se logró una mayor aproximación a la realidad, ya que el modelo en sintonización percibía en alguna medida a la red.

REFERENCIAS

- [1]. V. Kola, A. Bose y P. Anderson, "Power Plant Models for Operator Training Simulators," en *IEEE Transactions on Power Systems*, 1989, pp. 559-565.
- [2]. J. Camarillo, A. Saavedra y C. Ramos, "Recomendaciones para Seleccionar Índices para la Validación de Modelos," *Tecnológicas*, vol. 1, pp. 109-122, octubre 2013.
- [3]. A. Arias y A. Zapata, "Evaluación de metodologías de sintonización para controladores PI en microrredes eléctricas," Tesis de pregrado, Universidad de La Salle, 2020.
- [4]. B. Acevedo, J. Fonseca y J. Gómez, "Desarrollo de una herramienta en MATLAB para Sintonización de Controladores PID utilizando algoritmos genéticos basado en técnicas de optimización multiobjetivo," *SENA*, vol. 1, pp. 81-102.
- [5]. S. Sivanandam y S. Deepa, *Introduction to Genetic Algorithms*. Berlin: Springer, 2008.
- [6]. M. Gestal, D. Rivero, J. Rabuñal, J. Dorado y A. Pazos, "Algoritmos Genéticos. Introducción a los Algoritmos Genéticos y la Programación Genética," *Universidad da Coruña: Servizo de Publicacións*, España, 2010.
- [7]. R. Lluyac, "Sintonización de un controlador PID usando Particle Swarm Optimization para el AGC de un Sistema Eléctrico Multiárea," Tesis de Máster, Universidad de Sevilla, 2014.
- [8]. A. Engelbrecht, *Computational Intelligence: An Introduction*. Chichester: John Wiley & Sons Inc, 2007.
- [9]. M. Clerc, *Particle Swarm Optimization*. Londres: Wiley-ITSE, 2005.
- [10]. A. Harb, L. Mili, A. Nayfeh y C. Chin, "On the Effect of the Machine Saturation on SSR in Power System," en *Electric Machines and Power Systems*, 2000, pp. 1019-1035.