

A PSO-BPSO Technique for Hybrid Power Generation System Sizing

O. Llerena-Pizarro, N. Proenza-Perez, C. Tuna, and J. Luz

Abstract—The Particle Swarm Optimization (PSO) algorithm has been widely used in the field of optimization mainly due to its easy implementation, robustness, fast convergence, and low computational cost. However, due to its continuous nature, the PSO cannot be applied directly to real-life problems such as hybrid energy generating systems (HEGS) sizing, which contain continuous and discrete decision variables. In this context, the present work proposes the combination of the original version of the PSO with the binary version of the same algorithm (BPSO) for the sizing of HEGS. The transfer function is the main difference between these two algorithms. In this paper, an S-type transfer function is used to map the continuous space into a discrete space. All components of the HEGS are modeled and simulated during the optimization process. The net present value is defined as the unique objective function. The state of charge (SOC) of the batteries is the main constraint. The proposed PSO-BPSO is used for sizing hybrid power generating systems in the Galapagos Islands in Ecuador. Results show that the best configuration for the studied case is a hybrid system with solar panels, batteries, and diesel generators. Configurations that contain only photovoltaic panels and batteries imply a higher cost due to the oversizing of the battery bank. The proposed PSO-BPSO algorithm revealed to be a simple and powerful tool for efficient energy systems sizing.

Index Terms—Hybrid generation energy systems, PSO-BPSO, Mathematical modeling, Optimal sizing.

I. INTRODUCCIÓN

EL uso de las fuentes de energía renovable para la generación de electricidad, viene siendo considerado como una de las opciones más atractivas para atender adecuadamente el constante aumento en la demanda de este fluido eléctrico.

This study was financed in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Finance Code 001.

Omar R. Llerena-Pizarro is with São Paulo State University, UNESP College of Engineering of Guaratinguetá, Department of Energy, Laboratory of Optimization Energy Systems (LOSE), Institute of Bioenergy Research (IPBEN), Brazil. GIDTEC – Mechanical Engineering Department, Universidad Politécnica Salesiana, Cuenca, Ecuador (e-mail: ollerena@ups.edu.ec).

Nestor Proenza-Perez is with Federal Center of Technological Education Celso Suckow da Fonseca (CEFET/RJ), Angra dos Reis Campus, Brazil (e-mail: nestorproenza@yahoo.es).

Celso Eduardo Tuna Silveira is with São Paulo State University, UNESP College of Engineering of Guaratinguetá, Department of Energy, Laboratory of Optimization Energy Systems (LOSE), Institute of Bioenergy Research (IPBEN), Brazil (e-mail: celso.tuna@unesp.br).

José Luz Silveira is with São Paulo State University, UNESP College of Engineering of Guaratinguetá, Department of Energy, Laboratory of Optimization Energy Systems (LOSE), Institute of Bioenergy Research (IPBEN), Brazil (e-mail: joseluz@feg.unesp.br).

Sin embargo, debido a la intermitencia de estas fuentes (solar, eólica y biomasa), la utilización de los combustibles fósiles aún se muestra más competitivo, principalmente en lo que respecta a confiabilidad [1], [2].

Una de las alternativas para mejorar la confiabilidad, es decir, para mantener el suministro eléctrico de una forma ininterrumpida, es el uso combinado de las fuentes de energía renovable, en conjunto con los combustibles fósiles en un único sistema llamado Sistema Híbrido Generador de Energía (SHGE) [3]. Además de las fuentes renovables (principalmente solar y eólica) y no renovables (generalmente diésel), estos SHGE incorporan una unidad de almacenamiento de energía (entre los más utilizados están las baterías y la producción de hidrógeno) [4], [5].

Por otro lado, el adecuado dimensionamiento de los SHGE trae consigo beneficios técnicos, económicos y ambientales. Sin embargo, encontrar esta óptima solución no es una tarea fácil, principalmente, debido al comportamiento estocástico de la demanda de energía eléctrica y de las fuentes renovables; y debido también al alto número de variables continuas (número de componentes) y discretas (tipo o modelo de componente) que están directamente involucradas en el diseño del sistema [6], [7]. Por lo tanto, a la hora de dimensionar un SHGE es importante contar con una herramienta informática que tenga la capacidad de optimizar el proceso de dimensionamiento; y además que sea de fácil uso y de bajo costo computacional.

En ese contexto, la Optimización por Enjambre de Partículas (PSO, acrónimo en inglés) se muestra como una excelente herramienta para la solución de problemas de optimización mono-objetivo, y viene siendo ampliamente utilizada en el dimensionamiento de sistemas energéticos. El evidente éxito del PSO a la hora de dimensionar un SHGE es debido a la fácil implementación de código, a la robustez, a la convergencia estable y a su alto rendimiento; siendo este último similar al rendimiento alcanzado por los algoritmos genéticos (GA) [8]. Sin embargo, el uso directo de la versión original del PSO en el dimensionamiento de un SHGE presenta una solución nada concomitante con la realidad, esto, debido a que los problemas de la vida real, tal y como el dimensionamiento de un SHGE, contienen variables de decisión continuas (VDC) y variables de decisión discretas (VDD); y debido a la naturaleza de optimización continua de la versión simple del PSO, las soluciones encontradas por el algoritmo, pueden estar lejos de una solución verdadera. Por ejemplo, las soluciones encontradas pueden no ser compatibles con los modelos de los componentes existentes en el mercado local.

En ese contexto, para la solución de este problema, algunas combinaciones del PSO con otras metaheurísticas han sido

presentadas en la literatura. Por ejemplo, el algoritmo GA-PSO, el cual combina los algoritmos genéticos con el PSO [9]; o el PSO-GWO, el cual combina el PSO con el optimizador *Grey Wolf* [10]. Otro claro ejemplo de esta combinación es el algoritmo PSO-QP, el cual combina el PSO con programación cuadrática [11]. Chamba por su lado utilizó y comparó el PSO con el MVMO (*Mean-variance Mapping Optimization*). Este último algoritmo fue utilizado para minimizar los costos totales de un sistema de energía. Los resultados mostraron que el PSO alcanzó resultados similares al MVMO, mostrando así, el excelente rendimiento y robustez de este algoritmo de bajo costo computacional [12]. Como observado, existen varias combinaciones del PSO con otros algoritmos, y cada una de ellas muestra ser una excelente opción para el dimensionamiento de sistemas generadores de energía. Sin embargo, la combinación del PSO con otros algoritmos tiene un impacto directo en el costo computacional, lo cual es perjudicial, principalmente en la optimización basada en simulación, donde el algoritmo tiene que simular el SHGE varias veces antes de encontrar una solución óptima.

Por otro lado, otros trabajos presentan directamente la optimización de sistemas energéticos utilizando el programa computacional HOMER® (*Hybrid Optimization Model for Electric Renewable*) [13]. Este programa realmente es una excelente opción a la hora de optimizar un sistema energético, sin embargo, el hecho de ser un programa pago, limita el uso libre del mismo, desafiando a investigadores de todo el mundo a desarrollar sus propias herramientas de optimización [14].

En ese sentido, la propuesta de este trabajo es implementar un algoritmo que trate independientemente las variables de decisión continuas y las variables de decisión discretas sin incrementar el costo computacional. Para ello, este trabajo combina la versión original del PSO con su versión binaria (BPSO) [15], derivando así, en un algoritmo PSO-BPSO; y es importante mencionar que no se ha encontrado ningún trabajo similar en la literatura especializada que utilice este enfoque para el dimensionamiento de un SHGE. La función de transferencia (FT) es la principal diferencia entre los algoritmos PSO y BPSO, y en este trabajo, se utilizará una FT de tipo S para operar con las variables discretas [16].

Los dos algoritmos serán implementados en el mismo código en Matlab®. El uso del PSO y BPSO complica la codificación del algoritmo. Sin embargo, este enfoque permite un dimensionamiento más realista del SHGE, manteniendo el bajo costo computacional, evitando soluciones prematuras, y con resultados cercanos a otros algoritmos de alto costo computacional.

Finalmente, el algoritmo PSO-BPSO será utilizado para dimensionar SHGE en la Isla Floreana, una de las islas pobladas en las Islas Galápagos en Ecuador. En donde, minimizar el valor presente de los costos de los SHGE será el principal objetivo (NPVc, acrónimo en inglés).

II. MATERIALES Y MÉTODOS

EL SHGE que será dimensionado con el algoritmo propuesto (PSO-BPSO) es presentado en la Figura 1.

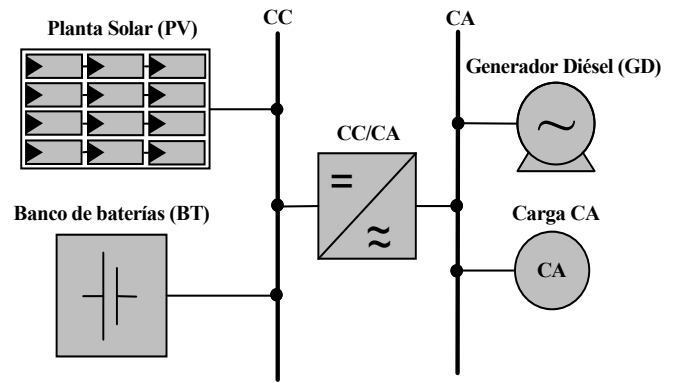


Fig. 1. Configuración del sistema híbrido generador de energía solar-diésel-batería.

En la parte izquierda de la Figura 1, la planta solar y las baterías están conectados al bus de corriente continua (CC), ya en el lado derecho, se puede encontrar la planta a diésel y la carga CA, conectadas en el bus de corriente alterna (CA). Los buses CC y CA son interconectados entre sí mediante un convertidor bidireccional (CC/CA). Además, en la planta solar fotovoltaica se considera también la existencia de un *Maximum Power Point Tracking (MPPT)*.

A. Pre-Dimensionamiento del SHGE

El primer paso para el dimensionamiento del SHGE es realizar un algoritmo que pre-dimensione el mismo. Este pre-dimensionamiento ayuda a definir el intervalo de las variables de decisión continuas (VDC). Es decir, en esta etapa se define el número máximo de componentes que integraría el SHGE. Segundo Roberts [17], definir las variables de decisión continuas, reduce el espacio de búsqueda del problema de optimización, y consecuentemente el tiempo de convergencia del mismo.

Para definir el límite superior de estas variables es utilizada la metodología presentada por Pinho [18] y Pinho y Galindo [19]. Esta metodología, permite obtener el número máximo de componentes de un sistema híbrido generador de energía, considerando únicamente la curva de carga, los recursos renovables existentes, y los datos técnicos de cada componente (principalmente la potencia nominal). Así, para obtener la carga que debe ser atendida es utilizada la ecuación (1).

$$L_{dia} = \frac{L_{año}}{365} \quad (1)$$

donde: Laño – Carga anual a ser atendida [kWh/año].

El siguiente parámetro que debe ser calculado es la demanda reprimida (DR), esta DR permite atender posibles excesos imprevistos en la demanda. 15% de DR es considerado en este trabajo, así, la nueva carga a ser atendida es corregida y calculada con la ecuación (2).

$$L'_{dia} = \left(1 + \frac{DR}{100}\right) \cdot L_{dia} \quad (2)$$

La potencia mínima de la planta solar (PV) depende del número de horas de sol pleno (HSP), conforme ecuación (3).

$$P_{PV_min} = \frac{L'_{dia}}{\left(1 - \frac{\Omega_{PV}}{100}\right)} \cdot HSP \quad (3)$$

donde: Ω_{PV} – Pérdidas por cableado y dispersión [%].

El número máximo de módulos fotovoltaicos es definido a partir de la ecuación (4).

$$N_{PV_max} = INT \left(\frac{P_{PV_min}}{P_{PV_nom}} \right) \quad (4)$$

donde: P_{PV_nom} – Potencia nominal del módulo fotovoltaico [W].

El número máximo de componentes para la unidad generadora a diésel es dimensionado utilizando la ecuación (5). La potencia pico y la eficiencia del conversor son los principales parámetros para el pre-dimensionamiento de esta unidad.

$$N_{GD_max} = INT \cdot \left(\frac{\frac{P_{pico}}{\eta_{conv}/100}}{P_{GD_nom}} \right) \quad (5)$$

donde: P_{GD_nom} – Potencia nominal del generador a diésel [kW].

En lo que respecta al banco de baterías, las ecuaciones (6) y (7) fueron utilizadas para el pre-dimensionamiento.

$$C_{BT} = C_{BT_max} \cdot \left(\frac{P_{D_max}}{100} \right) \quad (6)$$

donde: C_{BT} – Capacidad de energía útil de una batería individual [kWh], y P_{D_max} – Profundidad máxima de descarga.

$$C_{BBT} = \frac{L'_{dia} \cdot N_{aut}}{\left(1 - \frac{\Omega_{c-d}}{100}\right)} \quad (7)$$

donde: C_{BT} – Capacidad de energía útil del banco de baterías [kW], Ω_{c-d} – Porcentaje de pérdidas en la carga y descarga [%] y N_{aut} – Número de horas de autonomía.

El número máximos de baterías en el BT es determinado con la ecuación (8).

$$N_{BT_max} = INT \cdot \left(\frac{C_{BBT}}{C_{BT}} \right) \quad (8)$$

Finalmente, el número de componentes mínimo para cada unidad generadora de energía es definido como cero.

B. Simulación de los Componentes del SHGE

La implementación de varios modelos matemáticos es necesario para realizar la simulación de un SHGE. Escoger un modelo adecuado es la principal tarea en esta instancia del diseño. Por un lado, optar por un modelo demasiado simple llevaría a resultados imprecisos y poco confiables, generando como resultado final, un inadecuado dimensionamiento del SHGE. Por otro lado, optar por un modelo complejo, podría generar altos costos computacionales, siendo esto también perjudicial para el algoritmo de optimización. Por lo tanto, el modelo seleccionado, debe ser un modelo simple, pero con la capacidad de representar las principales características observadas experimentalmente de los componentes modelados.

1) Modelo de la planta solar

Para la planta solar es utilizado un modelo de potencia, este modelo es una representación matemática simplificada del punto de máxima potencia del módulo fotovoltaico, y es calculado con la ecuación (9) [20], [21].

$$P_{PV} = Y_{PV} \cdot f_{PV} \cdot \left(\frac{I_T}{I_{T,STC}} \right) \quad (9)$$

donde: Y_{PV} – Potencia de salida bajo condiciones estándares del módulo fotovoltaico [kW], f_{PV} – Factor de reducción de potencia [%], I_T – Irradiación solar incidente [kW/m²] y $I_{T,STC}$ – Irradiación solar en condiciones estándares [kW/m²].

2) Modelo de las baterías

En este trabajo, el comportamiento de carga-descarga del BT es representado matemáticamente con el modelo de batería de plomo-ácido propuesto por Manwell y Jon [22]. Este modelo funciona bajo el concepto de energía disponible, que es la energía que está lista para su uso, y el concepto de energía químicamente conectada, que es energía que no está inmediatamente disponible para su uso. Las principales ecuaciones de este modelo son presentadas en las ecuaciones (10), (11), y (12).

$$E_{1, i+1} = E_1 \cdot e^{-k \cdot t} + \frac{(E \cdot k \cdot c - P) \cdot (1 - e^{-k \cdot t})}{k} + \dots$$

$$\frac{P \cdot c \cdot (k \cdot t - 1 + e^{-k \cdot t})}{k} \quad (10)$$

$$E_{2, i+1} = E_2 \cdot e^{-k \cdot t} + E \cdot (1 - c) \cdot (1 - e^{-k \cdot t}) + \dots$$

$$\frac{P \cdot (1 - c) \cdot (k \cdot t - 1 + e^{-k \cdot t})}{k} \quad (11)$$

$$E = E_{1,i+1} + E_{2,i+1} \quad (12)$$

donde: E – Energía total del BT [kWh], E₁ y E₂ – Energía disponible y energía químicamente conectada, respectivamente (al inicio del proceso de carga y descarga) [kWh], E_{1,i+1} e E_{2,i+1} – Energía disponible y energía químicamente conectada, respectivamente (al final del proceso de carga y descarga) [kWh], P – Potencia [kW], T – Tiempo [h], k – Constante de conductancia [1/h] y c – Tasa de capacidad [-].

3) Modelo del generador a diésel

Con el modelo del generador a diésel es determinado el consumo de combustible (Fc) en L/h, el cual depende de la potencia de salida como se muestra en la ecuación (13) [10], [23].

$$F_c = F_0 \cdot P_{DGN} + F_1 \cdot P_{DG} \quad (13)$$

donde: P_{DGN} – Potencia nominal del generador a diésel [kW], P_{DG} – Salida del generador a diésel [kW], F₀ – Coeficiente de interceptación de la curva de combustible [L/h/W] y F₁ – Slope de la curva de combustible [L/h/kW].

C. Estrategia de Funcionamiento del SHGE

La estrategia de funcionamiento, también conocida como estrategia operativa, son las reglas seguidas por los generadores y las baterías para suministrar energía a la carga CA. La estrategia operacional *Load following (LF)* se aplica en este trabajo para la simulación del SHGE, considerando el generador a diésel como unidad de *back up* [24]. En esta estrategia, el grupo generador a diésel opera estrictamente cuando el generador fotovoltaico y la unidad de BT no pueden atender la demanda de la carga CA. La estrategia de operación utilizada para la simulación del SGHE se muestra en la Figura 2.

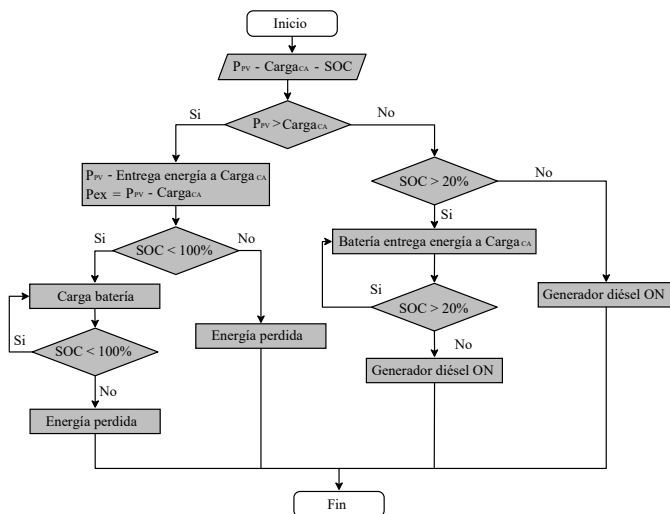


Fig. 2. Estrategia de funcionamiento del SHGE.

Como se puede observar en la Figura 2, el BT solamente será cargado con la energía adicional generada por la planta solar fotovoltaica. Si la energía generada por la planta fotovoltaica supera la capacidad máxima de carga del BT, se perderá esa energía. Por otro lado, los generadores a diésel serán utilizados cuando la planta solar no esté generando energía, y cuando la energía almacenada en las baterías sea menor o igual al 20%.

D. Algoritmo de Optimización

El algoritmo de optimización utilizado en este trabajo es el algoritmo por enjambre de partículas (PSO, acrónimo en inglés). Esta metaheurística ha sido ampliamente utilizada para la solución de problemas matemáticos complejos [25], y fue presentado por primera vez por los investigadores *Eberhart y Kennedy* [26], [27]. Sin embargo, la propuesta original de este algoritmo fue completada por los investigadores *Shi y Eberhart* en 1998 [28].

De la misma manera que en los algoritmos genéticos (AG), el PSO consta de una población inicial de individuos, que se llaman partículas. Cada una de estas partículas (puntos multidimensionales) representa una potencial solución dentro de un conjunto de soluciones (espacio de búsqueda). Así, la estrategia de optimización del PSO está basada en el comportamiento de estas partículas (evaluar, comprar, e imitar). Matemáticamente este modelo es representado con la ecuación (14).

$$\left. \begin{aligned} \vec{X}_i^{t+1} &= \vec{X}_i^t + \vec{V}_i^{t+1} \\ \vec{V}_i^{t+1} &= \underbrace{w \cdot \vec{V}_i^t}_{\text{inercia}} + c_1 \cdot r_1 \cdot (\vec{P}_i^t - \vec{X}_i^t) \\ &+ c_2 \cdot r_2 \cdot (\vec{G}^t - \vec{X}_i^t) \end{aligned} \right\} \text{PSO} \quad (14)$$

donde: r_1 y r_2 – Números aleatorios entre 0 y 1, c_1 y c_2 – Constantes positivas, \vec{P}_i^t – Mejor posición individual de las partículas, \vec{G}^t – Mejor posición global en el enjambre en la iteración t, \vec{V}_i^t – Velocidad en la iteración t, \vec{X}_i^{t+1} – Posición de la partícula (Xi) en la iteración (t+1), \vec{V}_i^{t+1} – Velocidad en la iteración t+1 y w – Número variable entre 0,2 e 0,9.

En un problema real, tal como el dimensionamiento de un SHGE, además de las variables de decisión continuas, son comúnmente encontradas las variables de decisión discretas. En este contexto, la versión original del PSO, por su naturaleza continua, no lograría realizar la búsqueda en un espacio discreto, imposibilitando así, el uso directo de este algoritmo para el adecuado dimensionamiento del SHGE. Por lo tanto, para poder manejar correctamente las variables discretas del problema, la versión binaria del PSO se utiliza de manera conjunta con la versión original del PSO, formando así un algoritmo híbrido PSO-BPSO.

La versión binaria del PSO fue introducida por primera vez

por Kennedy y Eberhart [15]. La función de transferencia (FT) y el procedimiento de actualización de la posición de las partículas son las principales diferencias entre el PSO y el BPSO [29]. En este trabajo, una FT en forma de S se utiliza para convertir el espacio de búsqueda continua, en un espacio de búsqueda discreto; en este caso, las posiciones de las partículas se actualizan entre 0 y 1. Así, el sigmoide TF en forma de S se implementa como la segunda parte del algoritmo propuesto en este trabajo (PSO-BPSO), el cual es representado por la ecuación (15) [16].

$$T(\vec{V}_i^{t+1}) = \frac{1}{1 + e^{-\vec{V}_i^{t+1}}} \quad (15)$$

donde: \vec{V}_i^{t+1} – Velocidad de las partículas en la iteración ($t + 1$).

Las posiciones de las partículas se actualizan de acuerdo con la ecuación (16).

$$\vec{X}_i^{t+1} = \begin{cases} 1 & \text{if } r < T(\vec{V}_i^{t+1}) \\ 0 & \text{if } r \geq T(\vec{V}_i^{t+1}) \end{cases} \quad (16)$$

donde: R – Número aleatorio entre 0 y 1.

III. PROBLEMA DE OPTIMIZACIÓN

A. Definición del Problema de Optimización

El problema de optimización para el dimensionamiento del SHGE es definido por la ecuación (17), y el mismo está representado en la Figura 3.

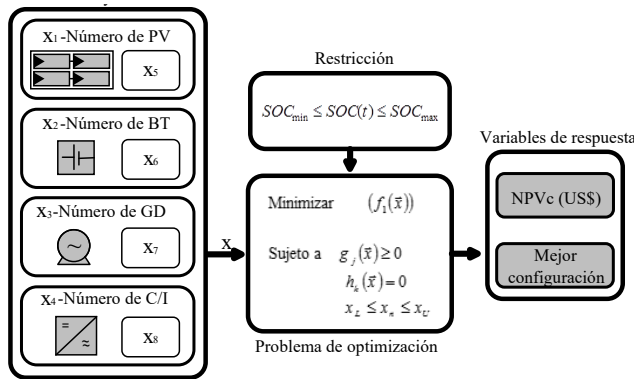


Fig. 3. Problema de optimización.

$$\text{Minimizar } (f_1(\vec{x}))$$

$$\begin{aligned} \text{Sujeto a } g_j(\vec{x}) &\geq 0 & j = 1, 2, \dots, J \\ h_k(\vec{x}) &= 0 & k = 1, 2, \dots, K \\ x_L &\leq x_n \leq x_U \end{aligned} \quad (17)$$

donde: $f_1(\vec{x})$ – Función objetivo, \vec{x} – Vector de decisión, $g_j(\vec{x})$ e $h_k(\vec{x})$ – Restricción igual o mayor que, y restricción de igualdad, respectivamente y x_L y x_U – Límites inferior y superior del vector de decisión.

La función objetivo (NPVc) se calcula con la ecuación (18).

$$NPVc = \frac{C_{TOTAL}}{CRF} \quad (18)$$

donde: C_{TOTAL} – Costo total anualizado y CRF – Factor de recuperación de capital.

La metodología completa utilizada para el cálculo del costo total anualizado y del CRF es presentada en los trabajos de Galindo et al. [30] y de Roberts et al. [31].

Finalmente, el banco de baterías está sujeto a la restricción presentada en la ecuación (19).

$$SOC_{\min} \leq SOC(t) \leq SOC_{\max} \quad (19)$$

donde: SOC – Estado de carga, SOC_{\min} – 20% de la capacidad máxima del BT y SOC_{\max} – Capacidad máxima del BT.

B. Vector de Decisión

El vector de decisión es formado por las variables de decisión continuas y las variables de decisión discretas. Un vector de decisión de 8 variables es considerado en este problema de optimización, conforme mostrado en la ecuación (20).

$$\vec{x} = [x_1, x_2, x_3, x_4, x_5, x_6, x_7, x_8] \quad (20)$$

donde: x_1 a x_4 – Variables de decisión continuas, las cuales representan la cantidad de paneles fotovoltaicos, baterías, convertidores, y generador a diésel, respectivamente y x_5 a x_8 – Variables de decisión discretas, las cuales representan los modelos de los paneles fotovoltaicos, modelos de las baterías, modelos de los convertidores y modelos de los generadores a diésel.

Además, es importante mencionar que el número de modelos de cada componente (VDD) utilizado en el problema de optimización afecta directamente al tamaño real del vector de decisión. Así, en este trabajo, se optó por 4 modelos diferentes de cada componente, por lo tanto, será necesario de dos bits por cada variable discreta, pues esto permitirá la asignación de un valor en cada combinación (00,01,10,11). Por lo tanto, a la hora de programar, el vector de decisión real será de dimensión 12 (4 para VDC y 8 para VDD).

C. Funcionamiento del PSO-BPSO

En la Figura 4, en el paso 1, se observan los parámetros de entrada del algoritmo. En este caso, noP es el número de partículas del PSO-BPSO y noI es el número de iteraciones. En el paso 2, el algoritmo de pre-dimensionamiento es ejecutado con el objetivo de establecer el límite del espacio de búsqueda

del problema de optimización (variables de decisión continua). En otras palabras, el número máximo de componentes necesarios para atender la carga CA se calcula en este paso. Posteriormente, en el paso 3, el primer vector de decisión es generado, para eso, primeramente, deben ser inicializadas las partículas del PSO y del BPSO. En el paso 4, cada vector de decisión es simulado. El NPVc, SOC, y la cantidad total de energía generada por el sistema son calculados en este paso. En el paso 5, si la restricción no cumple con los criterios establecidos, el algoritmo va directamente al paso 6. En el caso contrario, se evalúan todas las partículas; y se actualiza el Pi (mejor personal) y el G (mejor global). Luego, si se cumplen los criterios de detención del algoritmo, el vector G contiene la configuración óptima, y el algoritmo va al paso 7. Si no se cumplen los criterios de detención, se ejecuta el paso 6. En el paso 6, los vectores de posición y velocidad se actualizan con las representaciones matemáticas del PSO y BPSO, y se genera y simula un nuevo vector. Esta secuencia se repite hasta que se cumpla el criterio de detención del algoritmo (número de iteraciones). En el paso 7, el algoritmo devuelve la mejor configuración del SHGE.

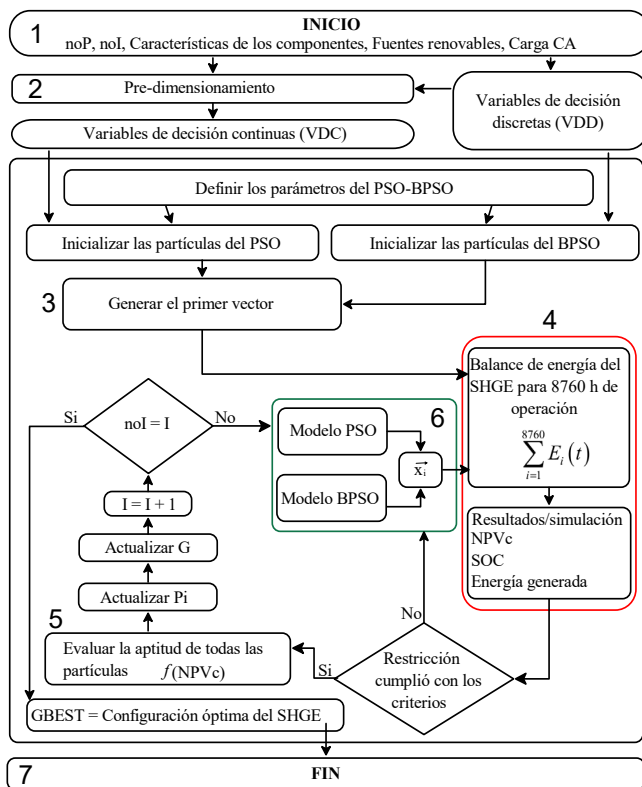


Fig. 4. Funcionamiento del PSO-BPSO.

IV. RESULTADOS

A. Irradiación Solar y Carga CA

Debido a que la procedencia de los datos meteorológicos y los datos de la carga CA no afectan el rendimiento del algoritmo, los mismos son generados en el programa computacional HOMER®.

Para el caso de la irradiación solar, como es común, esta es diferente en cada hora, día y mes, y su comportamiento está

marcado por dos estaciones (estación lluviosa y estación seca).

La estación lluviosa comienza en diciembre y termina en mayo, y es en esta estación donde se generará más energía solar fotovoltaica, pues la cantidad de irradiación solar en esos meses será la más grande del año. Lo opuesto ocurre en la estación seca, que va de junio a noviembre.

Así, de la simulación se encontró que la irradiación solar promedio anual para las Islas Galápagos es de 6,04 kWh/m²/día, la irradiación máxima es en febrero con 6,74 kWh/m²/día, y la mínima es en julio con 5,31 kWh/m²/día.

Por otro lado, en lo que respecta a la carga CA, de acuerdo con el Ministerio de Electricidad y Energía Renovable de Ecuador, para el 2025, será necesaria una generación extra diaria de 55,34 kWh/día para atender la demanda eléctrica de la Isla Floreana [32]. Así, los 2 SHGE dimensionados en este trabajo son dimensionados con miras a atender esta demanda extra.

B. Variables de Decisión Continuas (VDC) y Variables de Decisión Discretas (VDD)

La Tabla I presenta las variables de decisión continuas y las variables de decisión discretas utilizadas en el dimensionamiento del SHGE. Estos resultados provienen del algoritmo de pre-dimensionamiento. Cuatro modelos de cada componente se incorporaron a dicho algoritmo. Los modelos de los componentes son seleccionados directamente del fabricante debido a la falta de variedad en el mercado local.

TABLA I
VARIABLES DE DECISIÓN CONTINUAS Y DISCRETAS DEL PROBLEMA DE OPTIMIZACIÓN

Variables	Isla Floreana
x_1 (PV)	[0, 400]
x_2 (BT)	[0, 240]
x_3 (CONV)	[0, 5]
x_4 (DG)	[0, 4]
x_5 (PV)	{0,040; 0,060; 0,080; 0,120} kW
x_6 (BT)	{0,476; 0,712; 1,920; 2,390} kWh
x_7 (CONV)	{3; 5; 10; 20} kW
x_8 (DG)	{3; 10; 20; 50} kW
N° de combinaciones	265,42 x 10 ⁶

Como se observa en la Tabla I, el número de combinaciones del problema de optimización para el dimensionamiento del SHGE es de 265,42 x 10⁶. En esta Tabla I, también se puede encontrar el número máximo de componentes (VDC), así como el modelo de cada componente utilizado (VDD).

C. Resultados del Algoritmo de Optimización

El capital inicial fue estimado usando la técnica de Boehm [33]. Los costos de sustitución, y de operación y mantenimiento fueron obtenidos de la literatura [34], [35]. El precio local del diésel es de 0,66 US\$/L (diésel premium) [36]. Además, la tasa de interés para la inversión pública en Ecuador es adoptada

(8,58%) [37]. El tiempo de vida del SHGE es de 25 años.

Los parámetros configurados en el algoritmo son mostrados en la Tabla II.

Parámetro	Valor Asignado
Número de partículas	80
Número de iteraciones	100
Inercia mínima	0,2
Inercia máxima	0,9
c1	2
c2	2
Dimensión del vector VDC	4
Dimensión del vector VDD	8
Dimensión total del problema	12

La configuración mostrada en la Tabla II es la mejor configuración en términos de rendimiento para este caso específico de estudio. El algoritmo es implementado en Matlab® y es ejecutado en un computador equipado con Windows 7, 64 bits, Intel Core i5-4570 3.20GHz y 4 Gb de RAM. El tiempo de convergencia del algoritmo fue menor a 4 minutos.

El enfoque de este algoritmo es mono-objetivo, y dicho objetivo es minimizar el valor presente neto de los costos. Se considera que en ninguna circunstancia la isla estudiada quedará sin energía, es decir, la confiabilidad es igual al 100%. La Tabla III muestra los resultados de la optimización del algoritmo PSO-BPSO para la Isla Floreana. Dos configuraciones de sistema híbrido fueron implementadas, la primera fue únicamente un sistema PV/BT, y la segunda fue un sistema PV/BT/DG.

SHGE	Carga (kW/día)	PV (kWp)	BT (kWh)	CONV (kW)	DG (kW)	NPVc (US\$)
PV/BT PSO-BPSO	55,34	19,68 (164x0,120)	57,36 (24x2,390)	10,00 (1x10)	-	132218
HOMER®		18	81	9,09	-	129570
PV/BT/DG PSO-BPSO	55,34	12,00 (100x0,120)	46,08 (24x1,920)	5,00 (1x5)	10,00 (1x10)	99356
HOMER®		10,20	48	3,92	12	122633

Observando la Tabla III, se puede decir que, para atender la demanda de la Isla Floreana en el 2025, será necesario de un sistema híbrido PV/BT/DG, el cual deberá estar compuesto por una potencia instalada en la planta solar de 12 kW_p, una potencia instalada en la planta a diésel de 10 kW, y una capacidad en las baterías de 46,08 kWh. El costo para este

SHGE es de US\$ 99356. En el caso de que el sistema contenga únicamente paneles solares y baterías (PV/BT), la potencia instalada en la planta solar fotovoltaica se incrementa para 19,68 kW_p, y la capacidad en el banco de baterías será de 57,36 kWh. El costo de este último sistema es 32862 US\$ más caro que el anterior, esto debido al sobre dimensionamiento del banco de baterías para garantizar una confiabilidad del 100%.

Con el objetivo de validar el algoritmo propuesto en este trabajo, en la Tabla III también se presentan los resultados obtenidos en el programa computacional HOMER® (*Hybrid Optimization of Multiple Energy Resources*, en inglés).

Los mismos datos de irradiación solar y carga de CA se usaron el dimensionamiento con este programa de computadora. Para los dos casos, se muestra que el NPVc es casi similar. En lo que respecta a las potencias instaladas, en los dos casos la potencia instalada encontrada por HOMER® es casi la misma que la encontrada por el PSO-BPSO. Las pequeñas diferencias en los resultados se deben principalmente a la gran variedad de componentes que tiene el software HOMER® (que no es una realidad en la práctica). Por lo tanto, estos resultados corroboran el correcto funcionamiento del algoritmo propuesto (PSO-BPSO).

Finalmente, la Figura 5 presenta la evolución del PSO-BPSO para el sistema híbrido PV/BT/DG.

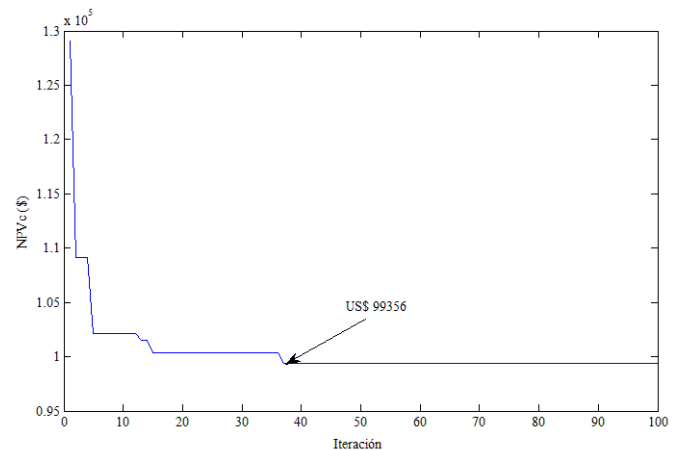


Fig. 5. Evolución del algoritmo para la Isla Floreana.

De la Figura 5 se puede observar que el algoritmo converge antes de la iteración 40, mostrando así la rápida convergencia del PSO-BPSO propuesto en este trabajo.

V. CONCLUSIONES

Un algoritmo de optimización para el dimensionamiento de sistemas híbridos generadores de energía fue implementado. El PSO-BPSO, combina las dos versiones del método de optimización por enjambre de partículas. El principal objetivo es minimizar el NPVc. Esta propuesta fue utilizada para dimensionar sistemas híbridos solar-diésel-baterías en las Islas Galápagos en Ecuador.

Se puede concluir que el algoritmo propuesto es una simple, pero poderosa herramienta para resolver problemas de dimensionamiento de sistemas energéticos de un único objetivo. Para el caso del sistema PV/BT/DG, el algoritmo

encontró una óptima configuración antes de la iteración 40. En los 2 casos estudiados, el PSO-BPSO consiguió converger en un tiempo menor a 4 minutos.

El principal parámetro para el dimensionamiento de los sistemas es la demanda eléctrica. Los resultados muestran que, para poder atender dicha demanda, la Isla Florena deberá contar con un SHGE con una potencia instalada en la planta solar de 12 kW_p, una potencia instalada en la planta a diésel de 10 kW, y una capacidad en las baterías de 46,08 kWh. El costo para el SHGE es de US\$ 99356. En el caso de utilizar un sistema únicamente con paneles solares y baterías, el costo se incrementa en más de US\$ 30000, esto debido principalmente al sobre dimensionamiento del banco de baterías.

AGRADECIMIENTOS

El presente trabajo fue realizado con apoyo de la Coordinación de Perfeccionamiento de Personas de Nivel Superior – Brasil (CAPES) – Código de Funcionamiento – 001.

REFERENCIAS

- [1] A. Mohammed, J. Pasupuleti, T. Khatib, and W. Elmenreich, "A review of process and operational system control of hybrid photovoltaic/diesel generator systems," *Renew. Sustain. Energy Rev.*, vol. 44, pp. 436–446, 2015.
- [2] A. U. Chávez-Ramírez, J. C. Cruz, R. Espinosa-Lumbreras, J. Ledesma-García, S. M. Durón-Torres, and L. G. Arriaga, "Design and set up of a hybrid power system (PV-WT-URFC) for a stand-alone application in Mexico," *Int. J. Hydrogen Energy*, vol. 38, no. 28, pp. 12623–12633, 2013.
- [3] R. Siddaiah and R. P. Saini, "A review on planning, configurations, modeling and optimization techniques of hybrid renewable energy systems for off grid applications," *Renew. Sustain. Energy Rev.*, vol. 58, pp. 376–396, 2016.
- [4] A. Maleki and F. Pourfayaz, "Optimal sizing of autonomous hybrid photovoltaic/wind/battery power system with LPSP technology by using evolutionary algorithms," *Sol. Energy*, vol. 115, pp. 471–483, 2015.
- [5] Y. Z. Yang, P. J. Chen, C. S. Lin, and F. C. Wang, "Iterative Optimization for Hybrid PEMFC Power System," 2017.
- [6] S. M. Dawoud, X. Lin, and M. I. Okba, "Hybrid renewable microgrid optimization techniques: A review," *Renew. Sustain. Energy Rev.*, vol. 82, no. May 2017, pp. 2039–2052, 2018.
- [7] T. Tezer, R. Yaman, and G. Yaman, "Evaluation of approaches used for optimization of stand-alone hybrid renewable energy systems," *Renew. Sustain. Energy Rev.*, vol. 73, no. February 2017, pp. 840–853, 2017.
- [8] H. Borhanazad, S. Mekhilef, V. G. Ganapathy, M. Modiri-delshad, and A. Mirtaheri, "Optimization of micro-grid system using MOPSO Article in Renewable Energy · November 2014," *Renew. Energy*, vol. 71, no. November, pp. 295–306, 2014.
- [9] N. Ghorbani, A. Kasaeian, A. Toopshekan, L. Bahrami, and A. Maghami, "Optimizing a Hybrid Wind-PV-Battery System Using GA-PSO and MOPSO for Reducing Cost and Increasing Reliability," *Energy*, vol. 154, 2017.
- [10] A. M. Abdelshafy, H. Hassan, and J. Jurasz, "Optimal design of a grid-connected desalination plant powered by renewable energy resources using a hybrid PSO-GWO approach," *Energy Convers. Manag.*, vol. 173, no. May, pp. 331–347, 2018.
- [11] M. H. Moradi, M. Eskandari, and S. M. Hosseinian, "Operational Strategy Optimization in an Optimal Sized Smart Microgrid," *IEEE Trans. Smart Grid*, vol. 6, no. 3, pp. 1087–1095, 2015.
- [12] M. Chamba and O. Ano, "Economic dispatch of energy and reserve in competitive markets using meta-heuristic algorithms," *IEEE Lat. Am. Trans.*, vol. 11, no. 1, pp. 473–478, 2013.
- [13] D. K. Yadav, S. P. Girimaji, and T. S. Bhatti, "Optimal hybrid power system design for rural electrification," *ICPCES 2012 - 2012 2nd Int. Conf. Power, Control Embed. Syst.*, pp. 1–6, 2012.
- [14] C. Bustos, D. Watts, and H. Ren, "MicroGrid operation and design optimization with synthetic wins and solar resources," *IEEE Lat. Am. Trans.*, vol. 10, no. 2, pp. 1550–1562, 2012.
- [15] J. Kennedy and R. Eberhart, "A discrete binary version of the particle swarm algorithm," *Eng. Technol.*, pp. 4–8, 1997.
- [16] S. Mirjalili, S. Z. M. Hashim, G. Taherzadeh, S. Z. Mirjalili, and S. Salehi, "A Study of Different Transfer Functions for Binary Version of Particle Swarm Optimization," *Gem '11*, vol. 1, no. 1, pp. 2–7, 2011.
- [17] J. J. Roberts, "Otimização de sistemas híbridos de geração de energia solar-eólico-diesel através de métodos metaheurísticos e função multiobjetivos," Universidade Estadual Paulista, 2016.
- [18] J. T. Pinho, "Manual De Implantação De Sistemas Híbridos Fotovoltaico-Eólico-Diesel Para Geração De Energia Elétrica," p. 132, 2008.
- [19] J. T. Pinho and M. A. Galdino, *Manual de Engenharia para Sistemas Fotovoltaicos*. Rio de Janeiro, 2014.
- [20] A. Jones and C. Underwood, "A modelling method for building-integrated photovoltaic power supply," *Build. Serv. Eng. Res. Technol.*, vol. 23, no. 3, pp. 167–177, 2002.
- [21] J. J. Roberts, A. A. Mendiburu, and A. Marotta Cassula, "Assessment of photovoltaic performance models for system simulation," *Renew. Sustain. Energy Rev.*, vol. 72, no. May, pp. 1107–1123, 2017.
- [22] J. F. Manwell and G. Jon, "Lead acid battery storage model for hybrid energy systems," vol. 50, no. 5, pp. 399–405, 1993.
- [23] O. B. B, N. D, S. V, A. N. P, and N. M, "Multi-objective optimization of hybrid PV/wind/diesel/battery systems for decentralized application by minimizing the levelized cost of energy and the CO2 emissions," *Int. J. Phys. Sci.*, vol. 10, no. 5, pp. 192–203, 2015.
- [24] C. D. Barley and C. B. Winn, "Optimal dispatch strategy in remote hybrid power systems," *Sol. Energy*, vol. 58, no. 4–6, pp. 165–179, 1996.
- [25] H. Garg, "A hybrid PSO-GA algorithm for constrained optimization problems," *Appl. Math. Comput.*, vol. 274, pp. 292–305, 2016.
- [26] R. Eberhart and J. Kennedy, "A new optimizer using particle swarm theory," *MHS'95. Proc. Sixth Int. Symp. Micro Mach. Hum. Sci.*, pp. 39–43, 1995.
- [27] J. Kennedy and R. Eberhart, "Particle swarm optimization," *Neural Networks, 1995. Proceedings., IEEE Int. Conf.*, vol. 4, pp. 1942–1948 vol.4, 1995.
- [28] Y. Shi and R. Eberhart, "A modified particle swarm optimizer," *1998 IEEE Int. Conf. Evol. Comput. Proceedings. IEEE World Congr. Comput. Intell. (Cat. No.98TH8360)*, pp. 69–73, 1998.
- [29] S. Mirjalili and A. Lewis, "S-shaped versus V-shaped transfer functions for binary Particle Swarm Optimization," *Swarm Evol. Comput.*, vol. 9, pp. 1–14, 2013.
- [30] A. L. Galindo Noguera, L. S. Mendoza Castellanos, E. E. Silva Lora, and V. R. Melian Cobas, "Optimum design of a hybrid diesel-ORC / photovoltaic system using PSO: Case study for the city of Cujubim, Brazil," *Energy*, vol. 142, pp. 33–45, 2018.
- [31] J. José, A. Marotta, J. Luz, C. Bortoni, and A. Z. Mendiburu, "Robust multi-objective optimization of a renewable based hybrid power system," *Appl. Energy*, vol. 223, no. January, pp. 52–68, 2018.
- [32] MEER, *Plan Mestro de Electricidad 2016-2025*. Quito, 2017.
- [33] F. R. Boehm, *Design Analysis of Thermal Systems*. NY: John Wiley & Sons, 1987.
- [34] J. J. Roberts, A. Marotta Cassula, J. L. Silveira, E. da Costa Bortoni, and A. Z. Mendiburu, "Robust multi-objective optimization of a renewable based hybrid power system," *Appl. Energy*, vol. 223, no. April, pp. 52–68, 2018.
- [35] D. P. Clarke, Y. M. Al-Abdeli, and G. Kothapalli, "Multi-objective optimisation of renewable hybrid energy systems with desalination," *Energy*, vol. 88, pp. 457–468, 2015.
- [36] EP PETROECUADOR, "Precios de venta a nivel de terminal para las comercializadoras calificadas y autorizadas a nivel nacional," Quito, 2018.
- [37] Banco Central del Ecuador, "Tasas de Interés." [Online]. Available: <https://contenido.bce.fin.ec/documentos/Estadisticas/SectorMonFin/TasasInteres/TasasVigentes102018.htm>. [Accessed: 13-Nov-2018].



Omar R. Llerena-Pizarro. Graduado en Ingeniería Electrónica por la Universidad Politécnica Salesiana, Ecuador. Máster y Doctorando en Ingeniería Mecánica área Térmica en la Universidad Estatal Paulista, Brasil (UNESP). Su área de actuación está vinculada al modelado matemático y los algoritmos de optimización. Actualmente, se desempeña como auxiliar de laboratorio en la Universidad Politécnica Salesiana, como investigador en el Grupo de Optimización de Sistemas Energéticos de la FEG/UNESP Guaratinguetá, Brasil, y como profesor becado en el departamento de ingeniería eléctrica de la FEG/UNESP.



Nestor Proenza-Perez. Graduado en Ingeniería Mecánica por la Universidad de Camaguey, Cuba en el año 2003. Tiene maestría en Eficiencia Energética - Universidad de Camaguey (2010). Doctorado en el área de Energía por la Universidad Estadual Paulista (2016). Miembro del Grupo de Optimización de Sistemas Energéticos (LOSE) y del Instituto de Investigación en Bionenergía (IPBEN) de Guaratinguetá / SP. Tiene experiencia en el área de Ingeniería Mecánica, con énfasis en Ingeniería Térmica, actuando principalmente en los siguientes temas: biomasa, gas pobre, energía, motores de combustión interna y gasificación. Es profesor de mecánica de los fluidos, Termodinámica y máquinas con flujo, así como de Sistemas Fluido-mecánicos y laboratorios de Fenómenos de Transporte. Profesor de Enseñanza Básica Técnica y Tecnológica (EBTT) del Centro Federal de Educación Tecnológica Celso Suckow da Fonseca (CEFET / RJ).



Celso Eduardo Tuna. Ingeniero Mecánico en la Universidad Estatal Paulista Júlio de Mesquita Filho (1989), Master y Doctor en Ingeniería Mecánica en la Universidad Estatal Paulista Júlio de Mesquita Filho (1995, 1999) en el área de Transmisión y Conversión de Energía. Actualmente es profesor asociado (desde abril de 2019) en la Universidad Estatal Paulista - Julio de Mesquita Filho (UNESP) Campus de Guaratinguetá - Facultad de Ingeniería, Departamento de Energía (Profesor asistente Doctor de 2009 a 2019, Profesor suplente de 2005 a 2009). Beca CNPQ Nivel 2 de Investigación y Productividad desde marzo de 2016. Profesor del curso de posgrado en Ingeniería Mecánica de la Unesp de Guaratinguetá. Profesor del curso de posgrado integrado (PhD) en Bioenergía en Unesp / Usp / Unicamp. Presidente de CLAGTEE (Congreso Latinoamericano de Generación de Energía Eléctrica). Vicecoordinador del laboratorio asociado de Guaratinguetá en IPBEN Unesp (Instituto de Investigación de Bioenergía) desde 2015. Coordinador del Proyecto Capes Brafitec (desde 2015).

Fue Coordinador del curso de Licenciatura en Matemáticas (2003 a 2009) y Profesor en el Campus de Lorena del Centro Universitario Salesiano de São Paulo (UNISAL) (2000 a 2009). Tiene experiencia en Energía, actuando en los siguientes temas: auditoría energética, cogeneración, termoeconomía, exergía, termodinámica, conservación de energía y bioenergía. ORCIDicsoft0002-2020-7063. Investigador Id Y-9381-2018.



José Luz Silveira. Graduado en Ingeniería Mecánica por la Universidad Federal de Itajubá, graduado en Matemática por la Fundación de Enseñanza e Investigación de Itajubá Facultad de Filosofía, Ciencias y Letras, maestría en Ingeniería Mecánica por la Universidad Federal de Itajubá y doctorado en Ingeniería Mecánica por la Facultad de Ingeniería Mecánica - UNICAMP. Actualmente es Profesor Titular de la UNESP/FEG. Tiene experiencia en el área de Ingeniería Mecánica, con énfasis en Termodinámica y Transferencia de Calor, actuando principalmente en los temas: Cogeneración, Análisis Económico, Célula de Combustible, Análisis Termodinámico, Análisis Técnico y Biocombustibles. Actualmente, es Vicecoordinador Ejecutivo del Instituto de Investigación en Bioenergía (IPBEN - Rio Claro - UNESP), Coordinador del Instituto de Investigación en Bioenergía del campus de Guaratinguetá (IPBEN - FEG - UNESP), Coordinador del Laboratorio de Optimización de Sistemas Energéticos LOSE - FEG - UNESP).