

IDENTIFICACIÓN DE ERRORES EN LA ESTIMACIÓN DE ESTADO EN SISTEMAS ELÉCTRICOS USANDO PARTICULAS SWARM

Error identification in power system state estimation using Particule Swarm

RESUMEN

En este artículo se utiliza la técnica de optimización Particule Swarm con el fin de resolver el problema de estimación de estado cuando este presenta errores de difícil detección. Es propuesto un algoritmo que combina la estimación clásica con la teoría de puntos de apalancamiento y resuelto usando un método de optimización combinatorial denominado Particule Swarm. Los resultados reportados presentan un mejor desempeño al ser comparados con los obtenidos por un estimador de estado tradicional y de igual calidad a los reportados con métodos de optimización combinatorial tales como Búsqueda Tabú y Chu-Beasley.

PALABRAS CLAVES: Estimación de estado, detección de errores iterativos y conformativos, optimización combinatorial, Particule Swarm.

ABSTRACT

In this paper a Particle Swarm optimization technique is used in order to solve the state estimation problem when a multiple interacting bad data appear in the classical formulation of the state estimation problem. The methodology used, propose an algorithm that combines the classical estimation with the leverage points theory and solved by using the Particle Swarm optimization technique. Results obtained presents better performance when they are compared with the obtained using a classical state estimator, and the same when optimization techniques like Tabu Search and Chu-Beasley are used.

KEYWORDS: State estimation, interacting and conforming bad data identification, combinatorial optimization, Particule Swarm.

1. INTRODUCCIÓN

La estimación de estado es una herramienta de vital importancia en los centros de control de energía (CCE) para el análisis de los sistemas eléctricos en tiempo real. Su aplicación también se extiende a una serie de problemas entre los que se encuentran la detección de fuentes armónicas y la identificación de medidas erradas en sistemas de distribución, entre otras.

El estimador de estado en los CCE tiene por objetivo determinar el estado correcto de la operación del sistema que permita garantizar una operación segura de la red.

Para cumplir con este propósito se cuenta con información relacionada de los componentes del sistema, disponible en la base de datos y por la información suministrada por el sistema de supervisión y adquisición de datos (SCADA). Dado que las mediciones contienen imprecisiones propias de la lectura de los medidores, los CCE realizan un chequeo previo sobre las medidas con el objeto de descartar aquellas que presentan inconsistencias

HUGO ANDRÉS RUIZ F.

Ingeniero Electricista
Profesor Catedrático
Facultad de Ingenierías
Universidad Tecnológica de Pereira
hugor@ohm.utp.edu.co

ELIANA MIRLEDY TORO O.

Ingeniera Industrial, Ms.C.
Profesor Asistente
Facultad de Ingeniería Industrial
Universidad Tecnológica de Pereira
elianam@utp.edu.co

RAMÓN ALFONSO GALLEGO R.

Ingeniero Electricista, Ph..D.
Profesor Titular
Programa de Ingeniería Eléctrica
Universidad Tecnológica de Pereira
ragr@utp.edu.co

obvias. Sin embargo, existen mediciones que logran evitar este filtro, las cuales deben ser identificadas por el estimador de estado para una posterior eliminación.

Existen tipos de errores de difícil detección por parte de la metodología clásica de estimación de estado y durante el proceso de eliminación de estos, podrían ser excluidas mediciones que no presentan error. La eliminación de mediciones correctas ocasiona deterioro en la calidad de la estimación al disminuir el nivel de redundancia en los datos. Entre estos podrían ser eliminadas mediciones claves, y el sistema presentaría problemas de observabilidad [1]. En la literatura especializada estos errores se clasifican como errores iterativos y conformativos, temática que ha sido tratada por diferentes investigadores [2][3][4]. Una de las propuestas de identificación de este tipo de errores es a través de algoritmos de optimización combinatorial, como Búsqueda Tabú [1][5] y Chu-Beasley [6], y métodos de optimización exacta como Branch and Bound [7], los cuales trabajan en forma coordinada con la metodología clásica de estimación de estado.

En este artículo se trata el problema de estimación de estado con presencia de errores de tipo iterativo y conformativo y se soluciona empleando la técnica Particule Swarm Optimization (PSO). Con el fin de verificar la metodología de solución propuesta se utiliza el sistema de prueba el sistema IEEE de 14 nodos obteniendo resultados de excelente calidad.

2. PROBLEMA DE ESTIMACIÓN DE ESTADO

En la práctica es habitual la presencia de errores en las mediciones que llegan a un CCE. Generalmente, su origen corresponde a problemas en la calibración de los medidores o defectos en su funcionamiento. No obstante, existen otros tipos de errores más críticos que aparecen en el proceso de estimación, como lo son, aquellos de tipo iterativo y conformativo, los cuales se caracterizan por su difícil detección al emplear la metodología clásica de estimación de estado, debido a que sus residuos normalizados poseen un valor pequeño, mientras que mediciones vecinas sin presencia de error resultan con valores residuales elevados, impidiendo de esta manera una correcta identificación.

Para verificar las variables de estado de un sistema eléctrico en tiempo real, los CCE cuentan con una herramienta matemática denominada estimador de estado, que permite a través de información suministrada por equipos de medida, establecer un juicio a priori sobre el comportamiento del sistema y brinda una medida cuantitativa sobre la calidad de los valores estimados antes de realizar una evaluación de seguridad o se tomen algunas acciones de control.

En su modelamiento matemático, los errores de las mediciones se asumen independientes y hacen parte de una distribución de probabilidad normal con media cero y varianza σ^2 . El error de una medición puede expresarse como la diferencia entre su valor real y su valor calculado, de la siguiente forma:

$$e_i = z_i - h_i(x) \quad (1)$$

siendo $h(x)$ un vector de funciones no lineales que relacionan las mediciones con las variables de estado del sistema.

Para cuantificar el error presente en la estimación se tiene en cuenta la función de mínimos cuadrados ponderados:

$$J(x) = \sum_{i=1}^{nm} \frac{(z_i - h_i(x))^2}{\sigma_i^2} \quad (2)$$

Para minimizar (2) se calcula el gradiente y se iguala a cero. ($\partial J(x)/\partial x = 0$). Finalmente usando expansión

en series de Taylor y linealizando alrededor de un punto de operación, se obtiene la siguiente expresión:

$$x^{(k+1)} - x^{(k)} = (G^{(k)})^{(-1)} \cdot (H^{(k)})^{(t)} \cdot R^{(-1)} \cdot e^{(k)} \quad (3)$$

A través de esta ecuación son actualizadas las variables de estado del sistema durante un proceso iterativo.

2.1 DETECCIÓN E IDENTIFICACIÓN DE DATOS ERRÓNEOS

Una vez se han determinado las variables de estado del sistema, estos valores se someten a un proceso de validez estadística para detectar la presencia de datos anormales, con el fin de identificar y eliminar del conjunto de mediciones la información errónea.

Para detectar la presencia de errores en los valores estimados se aplica la prueba denominada chi-cuadrado:

$$J(\hat{x}) \leq \chi_{k,\alpha}^2 \quad (4)$$

Esta expresión indica que para tener unos resultados confiables la suma de los errores ponderados no debe superar el valor de la prueba chi-cuadrado, con k grados de libertad y nivel de confianza α .

Si no se cumple la expresión (4) es necesario emplear otro procedimiento estadístico para saber con certeza cuál es la medición alterada. Esta prueba se conoce con el nombre de t-student y consiste en obtener el máximo valor correspondiente a los residuos normalizados de las mediciones y compararlo con el valor de la distribución t-student con k grados de libertad y nivel de confianza α :

$$\max |r_N| \geq t_{k,\alpha} \quad (5)$$

En caso de tener múltiples errores simultáneos, las pruebas se realizan sobre una medición a la vez y continúa hasta eliminarlas por completo.

2.2 MÉTODOS DE SOLUCIÓN PARA IDENTIFICAR ERRORES DE DIFÍCIL DETECCIÓN

Las mediciones con presencia de errores y residuos normalizados pequeños se caracterizan por su difícil detección al emplear las pruebas estadísticas del estimador de estado clásico. Existen metodologías estadísticas que permiten identificar este tipo de mediciones erróneas, modificando la estructura de la matriz Jacobiana fundamentando su análisis en la identificación de mediciones que se encuentran afectadas significativamente por otra medición específica. No obstante, estas metodologías tienen la dificultad de realizar procedimientos exhaustivos debido a que se

analiza cada medición por separado [8]. Al ser aplicada en sistemas de potencia de gran tamaño y de alto nivel de redundancia, su ejecución toma un tiempo considerable.

2.3 MODELO MATEMÁTICO

La función objetivo o función de evaluación proporciona información acerca de la calidad de la configuración que ha sido propuesta. Esta información permite establecer una comparación entre configuraciones. La función objetivo utilizada para esta aplicación está representada por la siguiente ecuación:

$$fobj(x) = n_{bad} + \beta \cdot \max\{0; f(\hat{x}) - \lambda\} \quad (6)$$

n_{bad} Número de mediciones consideradas erróneas.

$f(\hat{x})$ Suma ponderada de los errores al cuadrado.

λ Valor suministrado por la prueba chi-cuadrada.

β Factor de penalización.

En la formulación (6) se penaliza la función objetivo en caso de que la restricción representada por el índice $f(\hat{x})$ sea violada, es decir, si la configuración indica presencia de errores grandes.

3. MÉTODO DE SOLUCIÓN

A principios del siglo XX se da inicio a estudios del comportamiento social de los individuos tratando de entender la influencia que presentaban sobre los demás integrantes de un grupo. Las investigaciones realizadas por Reynolds sobre las aves [9], simulando su comportamiento individual y colectivo dieron origen a la técnica combinatorial denominada PSO. Basados en estos conceptos Kennedy y Eberhart en 1995 presentaron la formulación matemática del modelo PSO [10].

El método PSO es una metaheurística perteneciente al grupo de los algoritmos evolutivos y su estrategia se fundamenta en el comportamiento social de los animales tales como las bandadas de aves, bancos de peces o enjambres de abejas, los cuales actúan como si fueran un solo individuo. En estos grupos de animales se establecen relaciones entre los individuos, se crean jerarquías dependiendo de las características de los mismos, existiendo un líder grupal reconocido y seguido por los demás miembros del grupo. El papel de líder puede cambiar si existe otro individuo con mejores características que el líder existente. Cuando el grupo se organiza para realizar una tarea, el líder guía a los demás individuos hacia una región promisoría, sin embargo, los demás miembros del grupo durante su recorrido pueden inferir sobre una nueva dirección con el objetivo de tener un mejor éxito en la misión.

Esta técnica presenta cierta similitud con los algoritmos genéticos, ya que el proceso incluye una población, realizando una búsqueda óptima a través de actualizaciones de esta. A pesar de no poseer operadores de recombinación y mutación, cuenta con otros operadores que permiten trasladarse a través del espacio de solución y de esta manera detectar soluciones de muy alta calidad, con la posibilidad que una de ellas corresponda al óptimo global del problema.

En PSO la exploración del espacio de solución se realiza a través de una población de individuos conocidos como partículas, donde cada uno de ellas representa una posible solución del problema. La ubicación de cada partícula sobre la región de búsqueda está determinada mediante su posición, la cual, representa el valor que toman las variables de decisión del problema.

Cada partícula cambia de posición de acuerdo a su velocidad teniendo en cuenta la mejor solución encontrada por ésta a lo largo del proceso (pbest) y a la información del líder del cúmulo (gbest). El operador pbest (individual best) compara la posición actual de una partícula con la mejor posición que ha presentado durante el proceso de búsqueda. Mientras que el operador gbest (global best) estudia el comportamiento del grupo, almacenando la posición del líder actual del cúmulo.

3.1 POBLACIÓN INICIAL

Las técnicas heurísticas dependiendo de la complejidad matemática del problema generan la población inicial de forma aleatoria o utilizando métodos constructivos basados en factores de sensibilidad cuya finalidad consiste en iniciar la búsqueda en una región atractiva con el fin de disminuir tiempo y esfuerzo computacional. El caso de estudio presentado en este artículo inicia con un conjunto de partículas generadas de forma aleatoria alcanzando el óptimo del problema. Sin embargo, en la medida que se estudian sistemas grandes y de alta complejidad matemática cobra fuerza el uso de población inicial generada con base en métodos constructivos.

Una población está constituida por k partículas y cada una de estas en el estado i representa una alternativa de solución, la cual es interpretada en el problema a través de la posición de la partícula. Cada partícula se representa mediante un vector cuyas posiciones indican los valores de las variables del problema (Ver figura 1) y simbolizan un punto dentro del espacio de solución. Inicialmente se generan n partículas con valores aleatorios dentro del rango de las variables y a través de la función objetivo se determina la calidad de la solución.

$$x_i = \begin{bmatrix} x_{i1} & x_{i2} & \cdots & x_{in} \end{bmatrix}$$

Figura 1. Posición de la i -ésima partícula

3.2 SELECCIÓN DEL LÍDER

En PSO durante cada iteración se debe seleccionar el líder del grupo comparando los valores de la función objetivo de cada partícula con la función objetivo del líder, siendo éste último aquella partícula que posee el mejor valor (incumbente global). Durante el proceso de optimización, cada vez que una partícula mejore el valor de su función objetivo, se debe actualizar el valor de su mejor ubicación local Pbest y cada vez que exista un cambio de líder, se debe actualizar el valor de la mejor ubicación global Gbest.

3.3 FUNCIÓN DE VELOCIDAD

La velocidad permite actualizar la posición de cada partícula. El vector de velocidad representa el gradiente de cada individuo dentro del cúmulo, es decir, guía a las partículas durante el proceso de búsqueda. Al igual que la posición, la velocidad se representa a través de un vector cuyas dimensiones deben ser iguales (Ver figura 2). La velocidad contiene información de la experiencia local y colectiva del grupo. Para calcular la velocidad de cada partícula se usa la siguiente expresión:

$$v_i(t+1) = w \cdot v_{i-1}(t) + c_1 \cdot rand \cdot (Pbest - x_i(t)) + c_2 \cdot Rand \cdot (Gbest - x_i(t)) \quad (7)$$

$$v_i = \begin{bmatrix} v_{i1} & v_{i2} & \dots & v_{in} \end{bmatrix}$$

Figura 2. Velocidad de la i-ésima partícula

Donde:

Velocidad actual (v_{i-1}): Dirección de vuelo que presenta una partícula. Al inicio del proceso las partículas parten del reposo.

Factor de inercia (w): Factor de ponderación que actúa sobre la velocidad actual de la partícula. Un valor elevado puede ocasionar una búsqueda muy exhaustiva mientras que un valor demasiado pequeño conlleva a que la exploración se realice de manera fugaz.

Constantes de aceleración c_1 y c_2 : Valores que direccionan a las partículas hacia su mejor ubicación local o global respectivamente. La adecuada calibración de estos valores permite que la población no se homogenice durante el proceso.

Rand y *rand*: Valores aleatorios pertenecientes a una distribución de probabilidad uniforme.

3.4 ACTUALIZACIÓN DE LA POSICIÓN

Para determinar la nueva posición de las partículas se aplica la siguiente ecuación:

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (8)$$

Como la posición actualizada de las partículas debe satisfacer las restricciones de las variables del problema, es necesario definir un rango de valores para las velocidades evitando de esta manera sobrepasar el límite impuesto.




Figura 3. Esquema de la nueva posición de la partícula

3.5 CODIFICACIÓN

Las variables de un problema de optimización pueden ser representadas a través de valores enteros, reales o binarios. Dado que en estimación de estado inicialmente se cuenta con un conjunto de mediciones, donde algunas de ellas en determinado momento pueden ser o no incluidas en el proceso, se utiliza una codificación de tipo binario. Por tanto, los posibles estados de una medición i se definen por una variable que toma los siguientes valores:

- $d_i = 0$, si la i -ésima medida es incorrecta.
- $d_i = 1$, si la i -ésima medida es correcta.

Teniendo en cuenta lo anterior, una alternativa de solución dada por una partícula dentro del cúmulo se representa de la siguiente forma:

$$dk = \begin{bmatrix} 1 & 2 & 3 & 4 & \dots & n \\ 0 & 1 & 1 & 1 & \dots & 0 \end{bmatrix}$$

Figura 4. Codificación del problema

Dado que el tipo de codificación implementado para la metodología propuesta en este artículo posee una representación binaria será adoptado el algoritmo básico PSO teniendo en cuenta este tipo de codificación.

1. Las notas de pie de página deberán estar en la página donde se citan. Letra Times New Roman de 8 puntos

En la versión binaria, al igual que en la versión continua, la posición de una partícula es actualizada a través del operador de velocidad (8), el cual es representado con valores continuos y para este caso se hace necesario implementar una función de activación que permita transformar estos valores a números binarios. La función que se emplea para este propósito se conoce como función sigmoideal (habitualmente utilizada en redes neuronales) cuyo rango de valores se encuentra en el intervalo [0,1] (ver figura 5).

$$sig(v_i) = \frac{1}{1 + \exp(-v_i)} \quad (9)$$

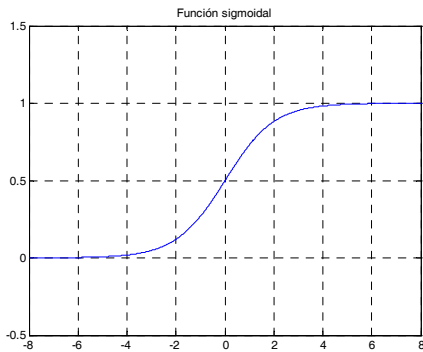


Figura 5. Gráfica de la función sigmoideal

La posición de la partícula asumirá un valor binario (0 ó 1). Dicha posición es actualizada teniendo en cuenta los valores de velocidad, los cuales son calculadas usando la ecuación (9). El valor obtenido es comparado con el umbral ρ , el cual puede tomar valores entre [0,1]. El rango típico sugerido es [0.5–0.7]. El procedimiento seguido para la actualización de la posición es el siguiente:

$$\begin{aligned} \text{si } \rho < sig(v_{i1}), & \quad x_{i1} = 1 \\ \text{en caso contrario,} & \quad x_{i1} = 0 \end{aligned} \quad (10)$$

El procedimiento anterior se constituye en una adecuación para el cálculo de la posición de las partículas para la versión binaria de PSO.

3.6 CRITERIO DE PARADA

Los algoritmos de optimización precisan de un criterio que les permita decidir cuando finalizar la exploración del espacio de solución. Entre los criterios de parada más empleados en dichos algoritmos se encuentran:

- Si durante un número de iteraciones no se ha mejorado la incumbente, se escoge esta solución y se da por finalizado el proceso.

- Hasta cumplir un número máximo de iteraciones.

Siendo la última opción la considerada en este artículo.

3.7 DESCRIPCIÓN DEL ALGORITMO

El procedimiento empleado por el algoritmo PSO es presentado en el siguiente diagrama:

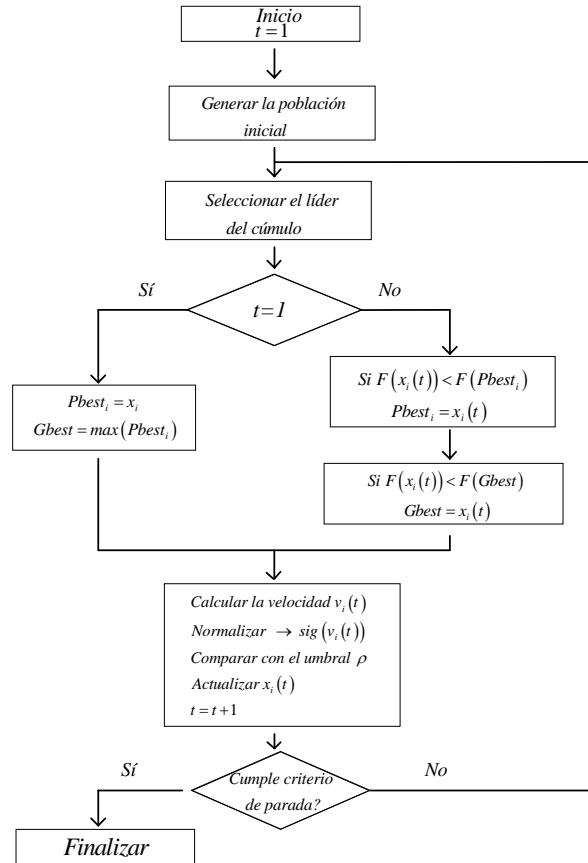


Figura 6. Diagrama de bloques del algoritmo PSO

4 RESULTADOS

El sistema de prueba considerado cuenta con 14 nodos, 20 líneas y 58 mediciones, de las cuales 6 fueron alteradas a propósito, debido a que después de realizar múltiples casos de estimación se encontró que estas mediciones son difíciles de detectar por la metodología clásica, y presentan errores de tipo iterativo y conformativo. Los datos del sistema y las mediciones alteradas se muestran en [7].

Al correr el estimador de estado convencional con la información anterior son detectadas como erróneas las siguientes mediciones:

$z_{32} = Q_{3-4}^{**}$	$z_{43} = P_{14-9}^{**}$	$z_{34} = Q_{2-5}$
$z_3 = Q_{4-3}$	$z_5 = P_3^{**}$	$z_{33} = P_{2-5}$
$z_{12} = Q_7^{**}$	$z_{50} = V_6^{**}$	$z_{47} = V_3^{**}$

Tabla 1. Mediciones detectadas por el estimador clásico

En la tabla anterior las mediciones marcadas con (**) contienen errores de tipo iterativo y conformativo, el resto de medidas no contienen errores. Se aprecia cómo la metodología clásica elimina del proceso tanto mediciones alteradas como mediciones correctas.

Al implementar el caso de prueba con la metodología propuesta son identificadas efectivamente las medidas erradas, $z_{12} = Q_7$, $z_{18} = Q_{11}$, $z_{32} = Q_{3-4}$, $z_{43} = P_{14-9}$, $z_{47} = V_3$, $z_{50} = V_6$. las cuales coinciden con las mediciones alteradas inicialmente.

Los parámetros del algoritmo PSO empleados en la simulación se muestran en la tabla 2.

Número de partículas	10
Velocidad inicial	0
Factor de inercia (w)	0.2
Cte de aceleración (c ₁)	5
Cte de aceleración (c ₂)	0.1
Valor umbral	0.7
Máximo de iteraciones	80

Tabla 2. Parámetros del algoritmo PSO




Figura 7. Evolución de una partícula dentro del proceso

En el gráfico anterior se puede apreciar el recorrido realizado por una partícula a lo largo del proceso. Además se puede apreciar como la partícula durante el proceso presenta altibajos el valor de su función objetivo. Lo anterior se explica debido a que durante el proceso se presenta cambio de líder efectuando cambios de posición en la partícula.

5 CONCLUSIONES Y RECOMENDACIONES

La metodología propuesta presenta un mejor desempeño en comparación con los métodos estadísticos de la estimación clásica y resultados similares a los obtenidos con las técnicas de optimización combinatorial Búsqueda Tabú y Chu-Beasley.

Los resultados que se obtienen al aplicar de forma combinada el método clásico de estimación de estado con la técnica de optimización PSO muestran efectividad en la identificación de errores de tipo iterativo y conformativo.

Cuando se analizan sistemas de gran tamaño y alta complejidad matemática los métodos estadísticos clásicos presentan mayor dificultad para una correcta identificación de este tipo de error y un tiempo computacional elevado. Al aplicar esta técnicas combinatoriales en sistemas complejos se espera una buena identificación y tiempos de cómputo razonables.

6 BIBLIOGRAFÍA

[1] N. G. Bretas. Network observability: Theory and algorithms based on triangular factorization and path graph concepts. IEE Proceedings: Generation, Transmission, and Distribution, vol. 143, pp. 123-128, Jan 1996.

[2] E. Asada, A. García, R. Romero. Identifying multiple interacting bad data in power system state estimation. IEEE Power Engineering Society General Meeting, vol. 1, pp. 571-577 Jun 2005.

[3] E. Handschin, F. Schweppe, J. Kohlas, A. Fiechter. Bad data analysis for power system state estimation. IEEE Transactions on Power Apparatus and Systems, vol. 94, pp. 329-337 Mar 1975.

[4] A. Monticelli. State estimation in electric power systems – A generalized Approach. Kluwer Academic Publishers. pp. 227-265 1999.

[5] H. Ruiz, E. Toro, M. Granada. Identificación de errores grandes en la estimación de estado usando Búsqueda Tabú. Scientia et Technica No 34. pp. 355-360 Universidad Tecnológica de Pereira, May 2007.

[6] Ruiz, H.; Toro, E.; Salazar, H. Algoritmo genético modificado Chu-Beasley aplicado a la identificación de errores en la estimación de estado de sistemas eléctricos. Scientia et Técnica No 37. pp. 25-30 Universidad Tecnológica de Pereira, Ago 2007.

[7] A. Monticelli, F. Wu, M. Yen. Multiple bad data identification for state estimation by combinatorial optimization. IEEE Transactions on Power Apparatus and Systems, vol 1, pp -361-369 1 Jul 1986.

[8] J.B.A. London, N. G. Bretas. Undetectable errors in power system measurement. Anais do IX Simpósio de Especialistas em Planejamento da Operação e Expansão Eléctrica. Rio de Janeiro, May 2004.

[9] Reynolds, W. Flocks, herds and schools: A distributed behavioral model. Computer graphics. 1987.

[10] Kennedy and Eberhart, editors. Particle swarm optimization, vol 4. 1995.

1. Las notas de pie de página deberán estar en la página donde se citan. Letra Times New Roman de 8 puntos