

ALGORITMO GENÉTICO MODIFICADO CHU-BEASLEY APLICADO A LA IDENTIFICACIÓN DE ERRORES EN LA ESTIMACIÓN DE ESTADO EN SISTEMAS ELÉCTRICOS

Error identification in power system state estimation using a modified chu-Beasley genetic algorithm

RESUMEN

En este artículo se utiliza un algoritmo genético modificado por Chu-Beasley para mejorar la estimación del estado de un sistema eléctrico de potencia. El algoritmo garantiza una población diversa durante todo el proceso de convergencia. Esta población, junto con una técnica de estimación clásica y combinada con la teoría de punto de apalancamiento, permite obtener resultados de buena calidad. Los resultados reportados demuestran un mejor desempeño cuando estos son comparados con los obtenidos por un estimador de estado tradicional.

PALABRAS CLAVES: Estimación de estado, detección de errores iterativos y conformativos, optimización combinatorial, algoritmo genético modificado Chu-Beasley.

ABSTRACT

A genetic algorithm modified by Chu-Beasley is used in this paper to improve a power system state estimation. The proposed algorithm guarantees a diversified population during the convergence time. The proposed technique is able to find a better solution when it is combined with classical estimation algorithms and the theory of leverage points. Numerical results show that a better estimation is achieved when they are compared with results obtained from a classical solution technique.

KEYWORDS: State estimation, Chu-Beasley optimization algorithm, estimation of iterative errors.

1. INTRODUCCIÓN

Una gran cantidad de problemas que tienen interés en ciencia y tecnología pueden modelarse como problemas de optimización. Para resolver estos problemas, una alternativa consiste en diseñar algoritmos aproximados que encuentren soluciones de alta calidad en tiempos razonables. De entre todos los métodos aproximados se destacan las metaheurísticas por su eficiencia, efectividad y flexibilidad. Estos métodos se han aplicado con éxito a una gran variedad de problemas de optimización. Para el caso en estudio se aplicará el algoritmo genético modificado de Chu-Beasley que es una técnica de búsqueda basada en la teoría de la evolución de Darwin.

Uno de estos problemas es el estimador de estado, el cual es un procedimiento matemático que permite estimar el estado más probable de operación del sistema, por medio de datos recolectados de los medidores e información de los parámetros de los componentes de la red. Tiene por objetivo principal identificar y descartar las mediciones que presentan errores en su adquisición. La información recolectada es utilizada por los centros de control de energía (CCE) para evaluar diferentes procedimientos

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 Catedrático
Facultad de Ingeniería Industrial
Universidad Tecnológica de Pereira
elianam@utp.edu.co

HAROLD SALAZAR ISAZA

Ingeniero Electricista, Ph.D(C)
Profesor Asistente
Programa de Ingeniería Eléctrica
Universidad Tecnológica de Pereira
hsi@utp.edu.co

propios de la operación del sistema eléctrico de potencia (SEP), es decir, todo lo relacionado con la seguridad, control y operación del sistema.

En la estimación de estado existen mediciones con presencia de errores iterativos y conformativos, los cuales alteran el funcionamiento adecuado de la metodología clásica. Los errores iterativos afectan los residuos de otras medidas, generalmente las que se encuentran en su vecindad. La influencia de los errores iterativos puede ser negativa sobre las medidas no portadoras de errores. Los errores conformativos hacen que las medidas portadoras de error actúen como mediciones sin presencia de error y provocan que los residuos normalizados tomen un valor alto en las medidas correctas que poseen correlación con los valores erróneos.

El problema de identificación de errores iterativos y conformativos ha sido tratado por diferentes autores. En la referencia [1] y [2], este problema es resuelto usando el método Búsqueda Tabú. En este artículo el problema de identificación de errores iterativos y conformativos es resuelto usando una versión modificada del algoritmo genético, denominado algoritmo de Chu-Beasley. El

algoritmo es verificado usando un sistema de prueba de la IEEE de 14 nodos, obteniendo resultados satisfactorios.

Este artículo está organizado de la siguiente manera. El problema de la estimación de estado es presentado en la sección 2. Sección 3 explica el método de solución y el modelo matemático, en la sección 4 se presentan los resultados de la metodología y en la sección 5 se comentan las conclusiones y recomendaciones de acuerdo a los resultados obtenidos.

2. PROBLEMA DE ESTIMACIÓN DE ESTADO

En la estimación de estado, se emplean diferentes procedimientos y pruebas estadísticas para el cálculo de las variables de estado [3] y [4]. En el modelamiento de dicho problema, el error en las mediciones (e) se calcula como la diferencia entre la medición especificada (z), tales como: potencia activa, potencia reactiva y magnitudes de voltaje, y la medición calculada ($h(x_1, x_2, \dots, x_n)$), donde x representa las variables de estado del sistema, magnitud de voltaje (V) y ángulo de voltaje (θ) descrito de la siguiente forma:

e = error en la medición.

H = matriz Jacobiana que relaciona las mediciones y las variables de estado del sistema

R = matriz de ponderaciones de las mediciones.

G = matriz de ganancia.

$$\begin{aligned} e_1 &= z_1 - h_1(x_1, x_2, \dots, x_n) \\ &\vdots \\ e_n &= z_n - h_n(x_1, x_2, \dots, x_n) \end{aligned} \quad (1)$$

La suma ponderada de los errores al cuadrado tiene la siguiente presentación:

$$f = \sum_{j=1}^n \frac{e_j^2}{\sigma_j^2} = \frac{(z_1 - h_1(x_1, \dots, x_n))^2}{\sigma_1^2} + \dots + \frac{(z_n - h_n(x_1, \dots, x_n))^2}{\sigma_n^2} \quad (2)$$

donde σ_i representa el factor de ponderación de la medición i . Con el fin de minimizar el error, se deriva la ecuación (2) respecto a las variables de estado e igualando a cero se obtiene:

$$H^T R^{-1} \begin{bmatrix} z_1 - h_1(\hat{x}_1, \dots, \hat{x}_n) \\ z_2 - h_2(\hat{x}_1, \dots, \hat{x}_n) \\ \vdots \\ z_n - h_n(\hat{x}_1, \dots, \hat{x}_n) \end{bmatrix} = 0 \quad (3)$$

Para resolver (3) se requiere linealizar las ecuaciones alrededor de un punto de operación $(x_1^{(0)}, \dots, x_n^{(0)})$ usando expansión en series de Taylor. Después de hacer el desarrollo del modelo descrito anteriormente y teniendo

en cuenta que $\Delta x_i^{(k)} = x_i^{(k+1)} - x_i^{(k)}$, se obtiene en forma matricial la siguiente expresión:

$$x^{(k+1)} - x^{(k)} = (G^{(k)})^{(-1)} \cdot (H^{(k)})^{(t)} \cdot R^{(-1)} \cdot e^{(k)} \quad (4)$$

Por medio de (4), se actualizan las variables de estado del sistema en cada iteración, hasta cumplir con el criterio de convergencia, mostrado en (5):

$$\max |x^{(k+1)} - x^{(k)}| < tol \quad (5)$$

2.1 PRUEBAS ESTADÍSTICAS

Después de que han sido estimadas las variables de estado del sistema en (4), se requiere tener certeza acerca de la validez de los resultados obtenidos. Esto se logra a través de pruebas estadísticas.

Los errores estimados presentan una distribución gaussiana, la teoría estadística demuestra que la función $f(\hat{x})$ mostrada en (2) es representada por la distribución chi-cuadrada [5] $\chi_{k,\alpha}^2$ donde k es el número de grados de libertad $k = (nm - 2n - 1)$, α equivale al grado de confianza, nm es igual a el número de mediciones y n es el número de variables de estado del sistema. Se aplica de la forma $f(\hat{x}) \geq \chi_{k,\alpha}^2$, es decir, si la suma de todos los errores es mayor que el valor que arroja la prueba chi-cuadrado, indica presencia de datos anormales dentro de las mediciones.

Con el fin de identificar la medida errada con mayor incidencia en el error global, detectado anteriormente, se lleva a cabo una segunda prueba estadística. Para esta prueba se calculan los residuos normalizados r_N para c/u de las mediciones, representadas por una distribución de probabilidad t-student [5] con k grados de libertad. Esta prueba tiene la forma $\max |r_N| \geq t_{k,\alpha}$, lo cual indica que si el máximo residuo normalizado es mayor que el resultado del estadístico t, con k grados de libertad y un nivel de confianza alfa, identifica la medición errónea.

2.2 CRITERIOS DE OBSERVABILIDAD Y PUNTOS DE APALANCAMIENTO

Un concepto importante en el estimador de estado son las técnicas de observabilidad [6], las cuales permiten determinar si con las mediciones existentes es posible calcular las variables de estado del sistema.

Los puntos de apalancamiento son mediciones que influyen en los resultados del estimador de estado, modificando los valores estimados. Los puntos de apalancamiento evitan visualizar la presencia de datos

erróneos en la iteración, al presentar interacción con otros datos. Este efecto de enmascaramiento produce residuos normalizados pequeños asociados con los datos erróneos, lo cual hace que no sean detectables [2].

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. Además, la restricción de observabilidad se verifica aplicando la teoría de puntos de apalancamiento.

3. MÉTODO DE SOLUCIÓN

La detección de errores como problema combinatorio fue propuesta en [7] para el tratamiento de errores múltiples, iterativos y conformativos basado en la teoría de decisión. En la estimación de estado se presentan dificultades en la detección de medidas erróneas debido a que la metodología clásica interpreta algunas mediciones incorrectas como correctas, lo cual ocurre debido a la correlación que se presenta entre ellas. Por esta razón se proponen metodologías de tipo combinatorial, tales como el algoritmo genético de Chu-Beasley, a fin de modelar el problema de estimación de estado como un problema de optimización. Este problema combinatorio permite establecer una serie de soluciones donde cada una representa una alternativa que puede contener mediciones correctas o combinaciones de correctas e incorrectas.

El algoritmo Chu-Beasley es una versión modificada del algoritmo genético básico, la principal característica consiste en mantener diversidad entre los cromosomas que conforman la población durante todo el proceso. En cada generación es reemplazado un solo cromosoma (alternativa) en la población, siempre y cuando, cumpla con las condiciones de optimalidad y/o factibilidad establecidas. Dicho mecanismo busca que en cada ciclo generacional, la calidad de la solución sea mejorada por optimalidad y/o factibilidad. Durante el proceso en la

población se reemplaza sistemáticamente un único descendiente. Esta estrategia tiene como ventaja encontrar soluciones de alta calidad y garantizar diversidad en la población a lo largo de las generaciones.

3.1 CODIFICACIÓN

El algoritmo genético permite implementar la codificación con variables binarias, enteras o reales, esto depende de la naturaleza de las variables. En este caso específico se adoptó la codificación binaria ya que representa satisfactoriamente el estado de las variables.

En términos del algoritmo genético un cromosoma es un elemento de la población que representa una posible solución del problema.

Los posibles estados de un medidor i se definen por una variable binaria 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.

La población de alternativas de solución se conforma por un número determinado de cromosomas como el mostrado en la Figura 1.

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

Figura 1. Codificación del problema.

n representa el número de mediciones que existen en el sistema.

3.2 POBLACIÓN INICIAL

Algunas metaheurísticas inician el proceso iterativo generando una población inicial a través de algoritmos inicializadores, intentando con esto, encontrar soluciones de muy alta calidad que estén próximas a la solución óptima del problema. Este modo de inicialización es usado en problemas de alta complejidad matemática. En la teoría se tiene establecido que la obtención del óptimo global es independiente de la solución inicial. La experiencia ha mostrado que la obtención de soluciones de alta calidad en problemas de gran complejidad matemática depende del punto en el cual se inicie el proceso. En problemas de baja o mediana complejidad matemática, como es el caso estudiado en este artículo, la generación de la población inicial podrá ser efectuada de forma aleatoria alcanzándose la solución óptima.

Para generar la población inicial del caso en estudio se usó el siguiente criterio: el tamaño del cromosoma depende del número de mediciones. Se generan tantos números aleatorios como genes tenga el cromosoma, si el número aleatorio generado es menor que 0.75 el valor del

gen es igual a 1 y cero en caso contrario, esto con el fin de que la configuración tenga la mayor cantidad de unos para garantizar la observabilidad del sistema [6].

3.3 SELECCIÓN

En la literatura especializada se contemplan diferentes algoritmos de selección para definir los padres. En este trabajo se estudiaron dos tipos de selección: por ruleta y torneo. Finalmente, en el desarrollo de este artículo se utilizó selección por torneo.

La selección por torneo consiste en escoger la alternativa que tenga mejor función objetivo de los k cromosomas seleccionadas aleatoriamente (Figura 3). El éxito de aplicar esta metodología radica en escoger adecuadamente un valor de k que se ajuste a cada problema en particular teniendo en cuenta tamaño y complejidad de la aplicación. Un valor de k muy alto puede eventualmente hacer caer el proceso en óptimos locales de muy baja calidad. El valor de k puede ser variable dependiendo el tamaño de la población; un valor recomendado de k es 2. En problemas con población grande el valor de k podrá ser mayor o igual a 2.




Figura 2. Selección de los padres para $k = 2$

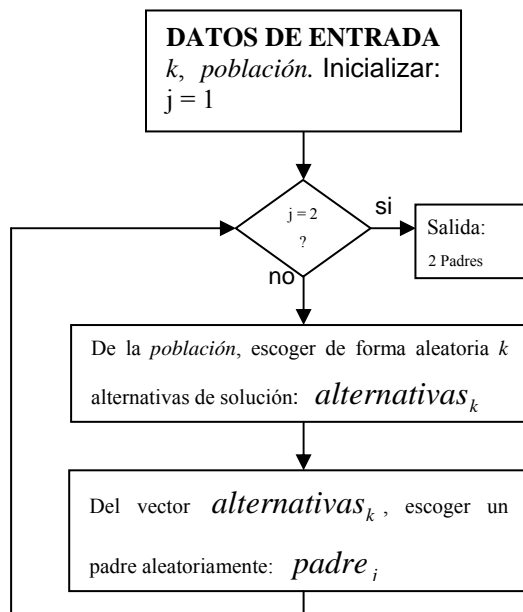


Figura 3. Proceso de Selección

3.4 RECOMBINACIÓN

Con los dos padres seleccionados, el siguiente paso consiste en combinarlos de forma tal que se obtengan los descendientes. De estos dos descendientes uno será eliminado y el otro entrará a formar parte de la población, siempre y cuando cumpla con los criterios de optimalidad y/o factibilidad establecidos. Lo anterior representa una diferencia significativa con respecto al método tradicional del algoritmo genético y se traduce, en este caso, en una estrategia eficiente de búsqueda local.

En el proceso de recombinación es necesario definir el número p de puntos de recombinación. Dichos puntos son escogidos de forma aleatoria. Posteriormente, se combinan las características de los padres haciendo un cruzamiento de las porciones de cromosoma existentes entre cada punto de recombinación como se muestra en las Figuras 4 y 5 para un cromosoma de 8 genes y un punto de recombinación.




Figura 4. Proceso de recombinación




Figura 5. Selección del hijo

El objetivo de recombinar es encontrar nuevas alternativas de solución que permitan intercambiar medidas que mejoren la estimación

3.5 MUTACIÓN

El proceso de mutación se encuentra fuertemente ligado al concepto de intensificación en el vecindario. Así, una mutación drástica puede alejar el proceso de la zona de búsqueda actual y llevarlas a regiones distantes, determinando una especie de diversidad. Por otra parte, una mutación débil eventualmente puede ocasionar convergencias a soluciones locales y no permite una solución eficiente alrededor de la solución actual.

La mutación aplicada para el caso en estudio consiste en generar un número aleatorio y realizar la mutación si este valor es mayor a 0.85. Si la mutación es aceptada, se genera un número aleatorio entre uno y la longitud del cromosoma para cambiar el valor del gen de uno para cero ó viceversa, ver Figura 6.




Figura 6. Proceso de mutación

Con este operador se pretende explorar el espacio de soluciones a fin de encontrar alternativas con mejor función objetivo.

3.6 MEJORA DE LA FACTIBILIDAD

Este proceso busca mejorar el valor de la función objetivo y garantizar que la configuración sea observable. El proceso consiste en evaluar la alternativa actual haciendo las reasignaciones que garanticen la observabilidad de la configuración, cambiando aleatoriamente genes con valor cero por uno tomando como límite un número máximo de mediciones en valor cero.

3.7 MEJORA DE LA OPTIMALIDAD

El proceso consiste en evaluar el descendiente haciendo que algunos de los genes con valor cero se cambie por uno y evaluando la función objetivo. Las reasignaciones que permitan la observabilidad del sistema y mejoren la función objetivo son almacenadas. Finalmente, de todas las reasignaciones almacenadas se escoge la que mas favorezca la función objetivo. Es importante notar que la alternativa resultante se diferencia de la alternativa original solamente en un elemento.

3.8 DESCRIPCIÓN DEL ALGORITMO

El procedimiento seguido en el algoritmo Chu-Beasley es el siguiente:

- 1 Generar una población inicial
- 2 Se obtienen 2 alternativas *padre* usando selección por torneo de la población actual
- 3 Se obtiene una alternativa *hijo* aplicando *Recombinación* a los *padres* obtenidos en el paso anterior
- 4 Se obtiene una *alternativa modificada* aplicando *Mutación* siempre y cuando el parámetro obtenido lo permita.
- 5 Si la configuración no es *observable* se *repara* obteniendo una alternativa observable. Esto se logra aplicando de forma consecutiva un proceso de mutación hasta encontrar un número máximo de ceros en la configuración.
- 6 Para modificar la población se propone la siguiente estrategia:
 - a. Si la alternativa actual es infactible y a su vez es menos infactible que la peor

infactible de la población, entonces reemplazar la peor infactible por la alternativa actual.

- b. Si la configuración es factible y existe por lo menos una infactible en la población actual, entonces reemplazar la peor infactible por la alternativa actual.
- c. Si la configuración es factible y todas las alternativas de la población actual son factibles, entonces reemplazar la alternativa con peor función objetivo por la alternativa actual. Lo anterior se realiza sólo si la alternativa actual es de mejor calidad que la peor de la población.

- 7 En caso contrario desechar la alternativa resultante y volver al paso 2.
- 8 El proceso termina hasta cumplir el criterio de parada. En este caso se considera un número máximo de iteraciones.

4 RESULTADOS

Se ha considerado un sistema de prueba [8] de 14 nodos y 20 líneas (ver Figura 7), y se cuenta con 58 mediciones. En primera instancia, se aplica un flujo de carga para determinar los voltajes (magnitud y ángulo) en cada uno de los nodos del sistema, una vez se conocen estas cantidades, se obtienen las mediciones del sistema que servirán como datos de entrada al estimador de estado. Posteriormente, se procede a alterar algunas mediciones, de tal manera que en su gran mayoría contengan errores del tipo iterativo y conformativo ver Tabla 1.

$z_1 = P_1 = 1.9306$	$z_2 = Q_1 = 0.2618$	$z_3 = P_2 = 0.2165$	$z_4 = Q_2 = 1.0032$
$z_5 = P_3 = -0.5405$	$z_6 = Q_3 = -0.195$	$z_7 = P_4 = -0.464$	$z_8 = Q_4 = -0.10$
$z_9 = P_6 = -0.13$	$z_{10} = Q_5 = -0.094$	$z_{11} = P_7 = -0.02$	$z_{12} = Q_7 = -0.73 **$
$z_{13} = P_8 = -0.03$	$z_{14} = Q_8 = -0.0009$	$z_{15} = P_{10} = -0.091$	$z_{16} = Q_{10} = -0.06$
$z_{17} = P_{11} = -0.034$	$z_{18} = Q_{11} = -0.8 **$	$z_{19} = P_{12} = -0.062$	$z_{20} = Q_{12} = -0.022$
$z_{21} = P_{13} = -0.1347$	$z_{22} = Q_{13} = -0.08$	$z_{23} = P_{14} = -0.149$	$z_{24} = Q_{14} = -0.0489$
$z_{25} = P_{1-2} = 1.2843$	$z_{26} = Q_{1-2} = -0.0323$	$z_{27} = P_{1-5} = 0.6461$	$z_{28} = Q_{1-5} = 0.294$
$z_{29} = P_{2-3} = 0.5159$	$z_{30} = Q_{2-3} = 0.2934$	$z_{31} = P_{2-4} = 0.5402$	$z_{32} = Q_{2-4} = 0.8 **$
$z_{33} = P_{3-5} = 0.4158$	$z_{34} = Q_{3-5} = 0.2846$	$z_{35} = P_{3-4} = -0.040$	$z_{36} = Q_{3-4} = 0.0529$
$z_{37} = P_{4-3} = 0.0404$	$z_{38} = Q_{4-3} = -0.0676$	$z_{39} = P_{4-5} = -0.5142$	$z_{40} = Q_{4-5} = -0.1812$
$z_{41} = P_{7-8} = 0.03$	$z_{42} = Q_{7-8} = 0.0011$	$z_{43} = P_{14-9} = -0.7 **$	$z_{44} = Q_{14-9} = -0.0341$
$z_{45} = P_{14-13} = -0.0516$	$z_{46} = Q_{14-13} = -0.0145$	$z_{47} = V_3 = 0.952 **$	$z_{48} = V_4 = 0.9443$
$z_{49} = V_5 = 0.96$	$z_{50} = V_6 = 0.876 **$	$z_{51} = V_7 = 0.887$	$z_{52} = V_8 = 0.887$
$z_{53} = V_9 = 0.8594$	$z_{54} = V_{10} = 0.8531$	$z_{55} = V_{11} = 0.8603$	$z_{56} = V_{12} = 0.8554$
$z_{57} = V_{13} = 0.8497$	$z_{58} = V_{14} = 0.8291$		

Tabla 1. Mediciones del sistema

Para el estudio en cuestión fueron alteradas 6 mediciones marcadas con (**), las que contienen errores iterativos y conformativos. Dichas medidas, después de analizar múltiples estudios de estimación, resultaron ser difíciles de detectar por la metodología clásica.

Al correr el estimador de estado fueron detectadas como mediciones erradas las presentadas en la Tabla 2, usando las pruebas estadísticas chi-cuadrado y t-student.

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

Tabla 2. Medidas detectadas por el estimador clásico

Al analizar los resultados del estimador de estado, presentados en la Tabla 2, se observa que en efecto fueron identificadas las seis mediciones alteradas inicialmente y tres más que no debían haber sido identificadas como erróneas.

Parámetros usados en la simulación:

Tamaño de la población = 20.

Tasa de cruzamiento = 1.

Tasa de mutación = 0.15.

Número de participantes en el torneo $k = 2$.

Factor de penalización $\beta = 0.01$.

Número máximo de mediciones con valor cero = 6.




Figura 7. Sistema IEEE 14 nodos




Figura 8. Evolución del Proceso Generacional

En la Figura 8, el valor óptimo corresponde a 6, ya que, la función objetivo es la suma del número de mediciones erradas mas un factor de penalización dado por las pruebas estadísticas.

De los resultados obtenidos se observa que el algoritmo identifica como 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 corresponden efectivamente a las que fueron alteradas inicialmente. Existe la posibilidad que entre las mediciones erradas existan algunas de ellas que sean del

tipo iterativo y conformativo. A pesar de esto el algoritmo propuesto las identifica eficientemente.

5. CONCLUSIONES Y RECOMENDACIONES

En algunas situaciones la metodología clásica WLS de estimación de estado no identifica correctamente las mediciones que presentan errores, suministrando de este modo, un estimativo que no es correcto sobre el comportamiento del sistema estudiado. En el sistema de prueba de este artículo, la metodología clásica de estimación elimina mediciones que no presentan ningún tipo de error. Esta pérdida de información puede conducir a que el sistema sea no observable, de no contarse con un nivel de redundancia alto.

Los resultados que arroja la implementación combinada de la teoría clásica WLS (Weighted Least Square) y el algoritmo de optimización combinatorial Chu-Beasley muestran eficiencia en la identificación de mediciones erradas y que sean del tipo iterativo y conformativo.

Este artículo brinda un enfoque alternativo en el estudio de la estimación de estado, pues además de utilizar la metodología clásica, implementa criterios de observabilidad y utiliza la técnica combinatorial de Chu-Beasley.

Diferentes técnicas de estimación serán comparadas en trabajos futuros. Esto permitirá establecer las ventajas y desventajas de cada una de ellas.

BIBLIOGRAFÍA

- [1] Asada, E.; García, A; and Romero, R. *Identifying multiple interacting bad data in power system state estimation*. IEEE Power Engineering Society General Meeting, Vol. 1 Jun 2005.
- [2] Ruiz, H.; Toro, E.; y Granada, M. *Identificación de errores grandes en la estimación de estado usando Búsqueda Tabú*. Revista Scientia et Técnica, No 34, Mayo 2007. Universidad Tecnológica de Pereira.
- [3] Grainger, J.; Stevenson, W. D. *Análisis de Sistemas de Potencia*, Mc Graw Hill, México 1998.
- [4] Stagg, G.; El Abiad, A. *Computer Methods in Power System Analysis*, Mc Graw Hill, 1968.
- [5] Walpole M. *Probabilidad y Estadística para ingenieros*, Mc Graw Hill, 1995.
- [6] Monticelli, A; and Wu, F.F. *Network Observability: Theory*. IEEE Trans. Power System, vol Pas 104, no. 5, May 1985.
- [7] Monticelli, A. *State Estimation in Electric Power Systems: A Generalized Approach*, Editora Kluwer, 1999.
- [8] El-Habachi, A; *Generation mix planning using genetic algorithm*. IEEE Power Engineering Society Summer Meeting. Vol. 1 2002.