

DIAGNÓSTICO DEL RENDIMIENTO EN TURBINAS DE CONTRAPRESIÓN APLICANDO REDES NEURONALES ARTIFICIALES

DIAGNOSIS OF BACK-PREASURE TURBINE EFFICIENCY APPLYING ARTIFICIAL NEURAL NETWORKS

Julio R. Gómez Sarduy¹, Marcos A. de Armas Teyra¹, José P. Monteagudo Yanes¹, Fernando Ramos Miranda¹ & Evelio Navarro Aladro².

1. Centro de Estudio de Energía y Medio Ambiente (CEEMA), Universidad de Cienfuegos "Carlos R. Rodríguez", Cienfuegos - Cuba.

2. Empresa Azucarera Ciudad Caracas, MINAZ, Cienfuegos - Cuba.

jgomez@ucf.edu.cu, marmas@ucf.edu.cu, jpmmyanes@ucf.edu.cu, framos@ucf.edu.cu

Recibido para evaluación: 26 de Mayo de 2009

Aceptación: 1 de Junio de 2009

Entrega de versión final: 24 de Diciembre de 2008

Resumen

Por diferentes causas las turbinas; durante la explotación, pierden eficiencia y disminuyen su rendimiento relativo efectivo. Las técnicas emergentes como la Inteligencia Artificial, en particular las Redes Neuronales Artificiales (RNA), pueden ser aplicadas para estimar este rendimiento ya que permiten realizar un mapeo de las variables de entrada y salida del sistema y obtener resultados muy cercanos a su comportamiento real.

La complejidad de implementar un sistema de monitoreo en línea se debe a las variaciones de la carga del turbogenerador, desviaciones de los parámetros del vapor y al estado de la máquina fijado como condición normal de referencia. La técnica propuesta elimina este problema considerando una etapa inicial como aprendizaje en la cual el esquema implementado "aprende" las posibles variaciones del sistema antes de que haga falta tomar decisiones en cuanto a acciones correctivas.

En este artículo se presenta un método para diagnosticar variaciones en el rendimiento de la turbina utilizando el consumo de vapor como indicador con una aplicación experimental en dos turbogeneradores de 4 MW.

Palabras Clave: Turbinas de contrapresión, Diagnóstico, Rendimiento, Redes neuronales artificiales.

Abstract

By different motives, the turbines lose efficiency and decrease his performance. The emerging techniques of Artificial Intelligence, artificial neural network for example, can be used to estimate the turbine efficiency and simulate very well his real behavior, because they permit accomplishing a mapping of the input-output variables of the system for experimental datas.

A system of on-line monitoring of turbine efficiency is a complex problem. The complexity of his implementation are due to the steam parameters deviations, loads variations and references conditions. In this stage, with the training, the neural network "learn" the possible variations of the system before decisions of corrective actions.

In this paper a method to diagnose variations in the efficiency of the turbine utilizing steam consumption like indicator are proposed. This application are implemented in two turbogenerators of 4 MW.

Keywords: Steam turbines, Diagnosis, Efficiency, Artificial neural networks.

1. INTRODUCCIÓN

Se conoce bien que la cogeneración es un método eficiente de producir calor y electricidad a partir de una misma fuente de energía. En la industria azucarera esta práctica es común, y en Cuba su evolución ha llevado a la sincronización al Sistema Electroenergético Nacional (SEN) de la mayoría de las industrias azucareras persiguiendo además incrementar la eficiencia al operar siguiendo el perfil térmico de la carga que es, dentro de la cogeneración, la alternativa más eficiente. Esta práctica en el escenario actual es más relevante al posibilitar exportar energía marginal a la red eléctrica a partir de un combustible barato y poco contaminante como el bagazo.

Este objetivo se logra, en primer término, con mejoras en las instalaciones de generación de vapor que garanticen la disponibilidad y la calidad del vapor directo a valores que se corresponden con los de diseño para la explotación de los turbogeneradores. Y en segundo lugar, con mejoras en el resto de la fábrica, entre las que se pueden señalar el nivel de automatización de los procesos, disminución de la velocidad de la última unidad de molida, aprovechamiento de los condensados, etc.

Con estas medidas, se pueden alcanzar indicadores de generación, consumo y entrega de energía eléctrica que se acercan a los límites impuestos por la tecnología comúnmente empleada en estas fábricas, entiéndase, turbogeneradores de contrapresión y niveles de presión de vapor de 18 kg/cm². Sin embargo, aún existen potencialidades para elevar la eficiencia en la explotación del bloque energético a las que son necesarias brindar atención para llegar a un estado de excelencia en el trabajo de la instalación [1].

Uno de los aspectos más significativos es precisamente mantener los turbogeneradores trabajando eficientemente, lo que es posible alcanzar sólo con la aplicación de conocimientos, habilidades y procedimientos científico técnicos superiores a los empleados hasta el momento.

En este trabajo se propone adoptar métodos que permitan mantener o mejorar la eficiencia del turbogenerador y disminuir los costos operacionales con un sistema de mantenimiento centrado en la eficiencia y dirigido a mantener las características operacionales de diseño de estos importantes equipos.

Los sistemas y técnicas de diagnóstico implementados generalmente están dirigidos a evitar averías que lleven a paradas no planificadas de la fábrica y se basan en indicadores de comportamiento tales como vibraciones, tiempo de explotación, temperaturas en diferentes puntos de la máquina, características de los lubricantes, empuje axial, ensayos de balance, tiempo de operación, etc., sin tener en cuenta las prestaciones energéticas del equipo en cuestión [2]. Estos diagnósticos son también la base de la planificación de los ciclos de mantenimiento y de los trabajos de reparaciones necesarios.

En el caso específico de las turbinas, es importante analizar además indicadores energéticos como el consumo específico de vapor, cuyo incremento puede estar relacionado con deterioros mecánicos en el cilindro de la turbina que impiden lograr una operación eficiente de las mismas.

Por diferentes causas las turbinas durante la explotación pierden eficiencia y disminuyen su rendimiento relativo efectivo. El desgaste natural en alabes y sellos, deficiencias en el mantenimiento y en las reparaciones, etc., pueden ser alguna de estas causas. También las incrustaciones en los alabes producto de sedimentos debido al inadecuado tratamiento interno del agua en las calderas, dureza del agua de alimentar por encima de los límites permisibles o contaminaciones, pueden alterar el comportamiento de la turbina y provocar mayores demandas de vapor para unas condiciones de operación determinadas.

La complejidad de implementar un sistema de monitoreo en línea que permita determinar en qué momento la turbina debe ser revisada, cual es el volumen o tipo de reparaciones a efectuar para restablecer la calidad de sus prestaciones o en último caso, que brinde la información necesaria para poder evaluar determinadas alternativas de operación, se debe a las variaciones continuas de la carga del turbogenerador y de los parámetros del vapor con relación al estado de la máquina fijado como condición normal de referencia.

Las técnicas más modernas emergentes como la Inteligencia Artificial, en particular las redes neuronales artificiales; RNA, han sido aplicadas para resolver estas dificultades [3, 4, 5] y obtener modelos de las turbinas más cercanos al comportamiento real. El diagnóstico de las turbinas se puede conseguir a partir de un modelo de comportamiento que sirva de base

para la comparación con las condiciones reales de operación, determinando la desviación de los parámetros nominales.

La utilidad de emplear RNA radica principalmente en que no se necesita conocer el proceso físico del sistema en sí mismo, es suficiente realizar un mapeo de las variables de entrada y salida de dicho sistema. Este proceso constituye una etapa inicial de aprendizaje en la cual el esquema implementado "aprende" las posibles variaciones del sistema antes de que haga falta tomar decisiones en cuanto a acciones correctivas a partir de las especificaciones técnicas del fabricante.

Una vez que se ha obtenido el modelo del patrón de comportamiento dado en fábrica para estas turbinas se compara con el comportamiento real para obtener un indicador que es utilizado como método de diagnóstico del estado técnico de la turbina.

Esta aplicación se ejecutó en los dos turbogeneradores de 4 MW de la Empresa Azucarera "Ciudad Caracas" de la provincia de Cienfuegos, Cuba. A continuación se describe en detalles el procedimiento que puede ser generalizado a cualquier instalación.

2. FUNDAMENTACIÓN TEÓRICA DEL MÉTODO

El método de diagnóstico que se propone se basa en la obtención de un indicador que relaciona los consumos de vapor de fábrica y real del turbogenerador para unas condiciones de operación determinadas, es decir, potencia de salida del generador, parámetros del vapor directo y parámetros del escape. Para ello se hace necesario:

- a) Definir el modelo de referencia, en este caso un modelo neuronal entrenado con datos obtenidos de las características de explotación de las turbinas.
- b) Obtención y acondicionamiento de los datos reales. Se toman de los libros de lectura de los operadores de turbina que registran la información de instrumentos de campo cada una hora y se llevan a hojas de cálculo Excel.
- c) Procesamiento de la información. Se lleva a cabo por un programa en Matlab desarrollado al efecto y se presentan los resultados en forma gráfica y con estadísticas descriptivas para su análisis posterior.

Los pasos anteriores se describen con más detalles a continuación.

2.1 Características de operación de la turbina

El valor de la presión de vapor directo influye sustancialmente en la potencia que desarrolla la turbina. Esta influencia depende de su magnitud absoluta, de la contrapresión, del método de distribución del vapor en la turbina y del régimen de funcionamiento. También, las variaciones en la temperatura del vapor afectan la potencia interna de la turbina. Por otro lado, la contrapresión tiene gran importancia para el rendimiento y la potencia desarrollada por la misma, debido fundamentalmente, a la variación de la potencia en el último escalón. Todo lo anterior hace que el modelo de consumo de vapor de una turbina cuando trabaja con parámetros del vapor variables o desviados sea un problema complejo que requiere incluso del conocimiento de factores de diseño. Sin embargo, el fabricante [6] proporciona las características de explotación (Figura 1) que permiten obtener la demanda de vapor para unas condiciones operacionales determinadas. Estas características comprenden el gráfico de dependencia del consumo de vapor con relación a la potencia eléctrica desarrollada y los gráficos de correcciones de la potencia en función de la presión y la temperatura de vapor directo y de la presión de escape con relación al consumo de vapor de la turbina.

La potencia eléctrica generada Pg' , para un consumo dado y con los parámetros del vapor diferente a los nominales, es igual a:

$$Pg' = Pg \pm \sum \Delta Pg \quad (1)$$

Donde:

Pg es el valor actual de la potencia eléctrica generada para los parámetros nominales iniciales y finales del vapor tomada de la Figura 2a.

$\sum \Delta Pg$ es la suma algebraica de todas las correcciones.

El consumo de vapor necesario para obtener la potencia eléctrica Pg a partir de determinados parámetros del vapor se obtiene según la ecuación 2.

$$G' = G \cdot \frac{Pg}{Pg'} \quad (2)$$

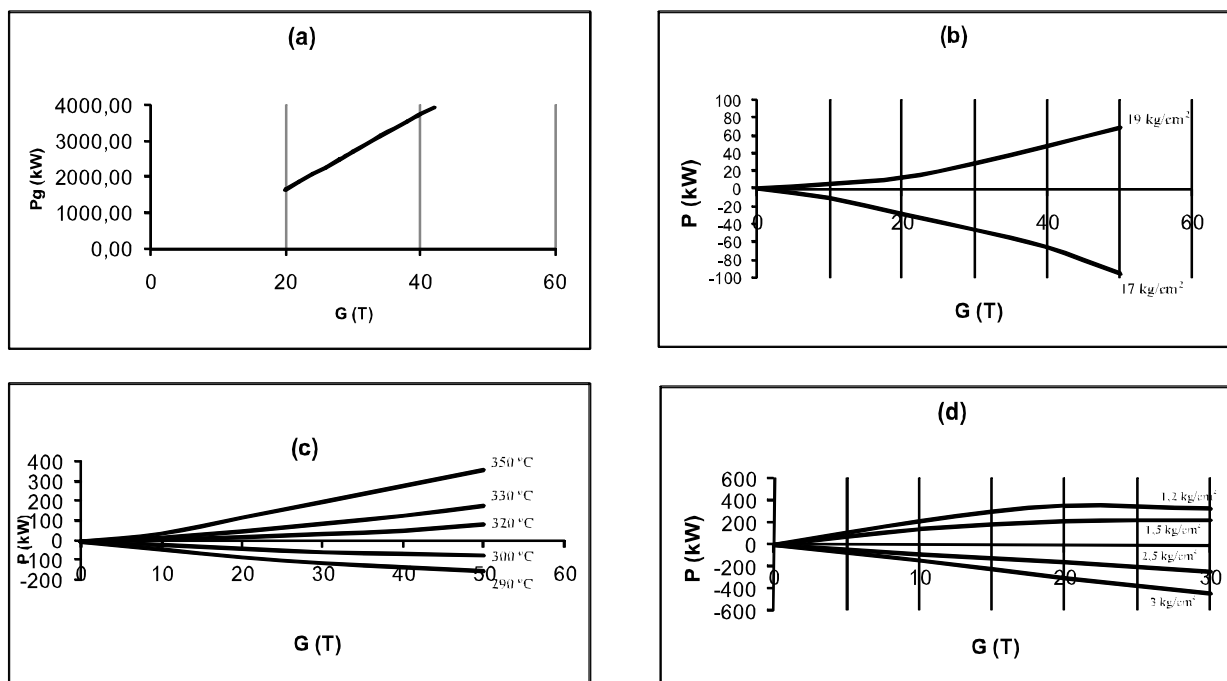


Figura 1. Características de explotación del turbogenerador.

(a) Dependencia de la potencia eléctrica respecto al consumo de vapor para $P_o=18 \text{ kg/cm}^2 \text{ abs}$, $T_o=310^\circ\text{C}$ y $P_2=2 \text{ kg/cm}^2 \text{ abs}$. (b) Corrección por presión de vapor directo. (c) Corrección por temperatura del vapor directo. (d) Corrección por presión de escape.

Donde:

G es el consumo de vapor necesario para generar la potencia eléctrica P_g si los parámetros iniciales y finales del vapor fueran los de diseño.

Los pasos para determinar el consumo de vapor son los siguientes:

- 1°. Determinar el consumo de vapor G para los parámetros nominales.
- 2°. Con este consumo de vapor determinar las correcciones por: presión y temperatura de vapor directo y por presión de escape a partir de las características de explotación (curvas de la Figura 1 (c), (d) y (f) para el caso del turbogenerador con $P_o=18 \text{ kg/cm}^2 \text{ abs}$, $T_o=310^\circ\text{C}$ y $P_2=2 \text{ kg/cm}^2 \text{ abs}$).
- 3°. Calcular la potencia que se pudiera desarrollar con los parámetros dados aplicando la expresión (1).
- 4°. Calcular el consumo de vapor real para estos parámetros aplicando la expresión (2).

La propia concepción gráfica del método dificulta su implementación analítica en condiciones reales de explotación ya que se basa en una serie de familias de curvas con naturaleza no lineal y para valores discretos

de los parámetros del vapor. Por estas razones y para obtener un patrón de comportamiento más apropiado de la turbina se propone en este trabajo desarrollar un modelo neuronal del turbogenerador. El objetivo de entrenar una RNA es caracterizar el consumo de vapor de la turbina en función de los parámetros del vapor a la entrada y salida de la turbina y de la carga del generador sin necesidad del procedimiento gráfico, de forma continua y que pueda ser empleado en tiempo real. Como se ha dicho, la red neuronal diseñada al efecto se entrena con datos obtenidos del prototipo numérico dado por el fabricante.

El esquema de diagnóstico de variación del rendimiento relativo efectivo de la turbina está basado en el entrenamiento de esta red y en el monitoreo del consumo del turbogenerador.

2.2 Diseño y entrenamiento de la red neuronal

Las neuronas simples se combinan para construir una red cuya arquitectura puede ser muy variada. La topología, las características de los nodos y las reglas de aprendizaje o entrenamiento, caracterizan el modelo de la RNA. La literatura técnica sugiere la red multicapa de propagación hacia adelante como la más adecuada para estas aplicaciones [7].

Esta es una red donde el conjunto de neuronas está ordenado en niveles, de modo que los enlaces se establecen desde neuronas en el nivel i a neuronas en el nivel j ($i < j$), por lo que la información fluye unidireccionalmente desde las unidades de entrada a las unidades de salida. Típicamente existe una capa de unidades sensoras, una o más capas ocultas de neuronas, y una capa de neuronas que producen la salida. La arquitectura de la red utilizada en este trabajo se muestra en la Figura 2. La primera capa de la izquierda contiene las neuronas de entrada, la capa intermedia contiene las neuronas ocultas y la última

capa de la derecha una neurona de salida. Aunque puede emplearse una arquitectura con múltiples capas ocultas, se ha demostrado que con una sola capa oculta usualmente es suficiente [7]. El vector de entrada (kW , Po , To , $P2$) está constituido por la carga eléctrica, la presión y temperatura del vapor directo y la contrapresión. Estas magnitudes determinan el consumo de vapor G de la turbina, el cual constituye la salida de la RNA.

La función empleada en las neuronas de la capa oculta es la función tangente sigmoideal hiperbólica ($tansig$) y la función de las neuronas de salida es lineal ($purelin$)




Figura 2. Arquitectura de la RNA diseñada para simular el consumo de vapor de los turbogeneradores.

En correspondencia con el número de entradas y salidas previstas, la red tiene cuatro neuronas de entrada y una de salida. Seleccionar el número adecuado de neuronas ocultas es un aspecto importante y para ello se entrenó la red variando el número de estas y manteniendo otros parámetros constantes.

La red desarrollada se programó como una función en Matlab 7.0. El código del modelo neuronal es:

$$G = \text{purelin}(LW(3,2) * (\text{tansig}(LW(2,1) * (\text{tansig}(LW(1,1) * E + b1)) + b2)) + b3)$$

Donde:

E es el vector de entrada normalizado siguiente:

$$E = \begin{bmatrix} kW/\max(kW) \\ Po/\max(Po) \\ To/\max(To) \\ P2/\max(P2) \end{bmatrix}$$

Siendo:

kW : potencia de salida del generador, en kW.

Po : presión del vapor directo, en kg/cm² abs.

To : temperatura del vapor directo, en °C.

$P2$: presión del vapor de escape, en kg/cm² abs.

\max : valor máximo del respectivo argumento presente en los datos reales.

Las redes para ambos turbogeneradores fueron entrenadas con 660 juegos de datos representativos de las posibles combinaciones de parámetros del vapor y potencia generada. Cada variable de entrada y salida en el conjunto de datos fue normalizada utilizando el máximo valor de la variable como se recomienda en [7]. El 70 % de los datos se utilizó para el entrenamiento, el 15% para la validación y el 15% para prueba.

3. MÉTODO DE DIAGNÓSTICO

Una vez diseñada la RNA que estima el consumo de vapor de la turbina para diferentes condiciones de explotación se implementa el esquema de comparación. La relación entre el consumo de vapor medido y el estimado por la red entrenada es el indicador del comportamiento de la eficiencia. El consumo de vapor del turbogenerador está dado por:

$$G = \frac{3600 \cdot Pe}{\Delta H_o \cdot \eta_{ri} \cdot \eta_m \cdot \eta_{g.el}} \quad \text{t/h} \quad (3)$$

Donde:

Pe es la potencia eléctrica a la salida del generador, en kW.

ΔH_o es el salto entálpico disponible, en kJ/kg.

η_{ri} es el rendimiento relativo interno de la turbina, en pu.

η_m es el rendimiento mecánico, en pu.

$\eta_{g.el}$ es el rendimiento del generador eléctrico, en pu.

Si se conoce que el rendimiento relativo efectivo de la turbina es $\eta_{re} = \eta_{ri} \cdot \eta_m$, entonces:

$$G = \frac{3600 \cdot Pe}{\Delta H_o \cdot \eta_{re} \cdot \eta_{g.el}} \quad \text{T/h} \quad (4)$$

Como el rendimiento del generador es mayoritariamente dependiente de su estado de carga, entonces, para una potencia eléctrica dada, cualquier desviación entre el consumo de vapor estimado por la red entrenada y las mediciones reales puede ser interpretada como el efecto de la variación en el rendimiento relativo efectivo de la turbina. De esta manera, despreciando el efecto que pueda tener las variaciones del rendimiento del generador por variaciones en el factor de potencia u otras causas y a partir de la expresión (4), se puede expresar que:

$$k = \frac{\eta_{re} \text{ medido}}{\eta_{re} \text{ estimado}} = \frac{G \text{ estimado}}{G \text{ medido}} \quad (5)$$

El esquema para determinar el indicador de variación del rendimiento se muestra en la Figura 3.




Figura 3. Esquema para determinar el indicador de disminución del rendimiento relativo efectivo de la turbina.

Las mediciones son obtenidas de los registradores instalados o de las lecturas horarias de los operadores que contemplan el flujo de vapor a la turbina (G) en t,

la presión del vapor directo (P1) en kg/cm² abs, la temperatura del vapor directo (T1) en °C, la contrapresión (P2) en kg/cm² abs y la potencia

eléctrica generada (P_e) en kW. Debido a que durante la operación normal, las condiciones operacionales tienen un pequeño rango de variación, se tomaron mediciones especiales para abarcar todo el espectro de operación posible.

4. ANÁLISIS DE RESULTADOS OBTENIDOS

Para la evaluación de las variaciones en el rendimiento se desarrolló una aplicación en Matlab [8]. Con este programa y las mediciones realizadas se determina el consumo de vapor teórico dado por el modelo neuronal y se compara con el valor medido. Los resultados se grafican como se muestra en las Figuras 4 y 5. En estas figuras se aprecia que en ambos casos el valor real es superior al estimado por el modelo que caracteriza el consumo de vapor teórico según datos del fabricante para esas condiciones operacionales.




Figura 4. Consumos de vapor medido y estimado por el modelo para el Turbo 1




Figura 5. Consumos de vapor medido y estimado por el modelo para el Turbo 2

La relación entre estos valores da un índice k proporcional a la relación existente entre los diferentes rendimientos para la condición real y estimada dado por la ecuación (5). Este indicador para las dos turbinas se puede ver graficado en las Figuras 6 y 7.

En caso de concordancia entre el estado real y el dado por el fabricante de la turbina el valor del coeficiente es la unidad. Un valor inferior indica una reducción en el rendimiento del turbogenerador con relación al que debía tener en condiciones técnicas ideales según el fabricante. Para el caso del turbogenerador 1, el valor medio de la relación entre los rendimientos es 0.87 con una desviación estándar de 0.17. Para el caso del turbogenerador 2 el valor medio es de 0.73 con una desviación estándar de 0.11.




Figura 6. Factor k indicativo de la variación del rendimiento relativo del Turbogenerador 1




Figura 7. Factor k indicativo de la variación del rendimiento relativo del Turbogenerador 2

Puede observarse que en virtud de estos resultados obtenidos la disminución del rendimiento en el turbogenerador 2 es mayor que en el 1 lo cual es indicativo de deterioros mecánicos en esta máquina que la conducen a esta pérdida en el rendimiento como se evidenció posteriormente (Figuras 8 y 9).




Figura 8. Fotografías de la turbina 2 mostrando afectaciones en el perfil de alabes (a) y sellos (b).



Figura 9. Fotografías de la turbina 1 mostrando el buen estado técnico de alabes (a) y sellos (b).

Si se asume que la sustitución de alabes en la primera etapa del rotor y la sustitución de los sellos en el rotor y en los diafragmas de la turbina 2 incrementan su rendimiento hasta un valor similar al de la turbina 1, es decir, hasta 0.87 del rendimiento dado por el modelo teórico; el incremento potencial en la generación estará dado por:

$$kW_{0.87} = kW_{actuales} \cdot \frac{0.87}{0.73} = kW_{actuales} \cdot 1.19$$

Incrementos del orden del 19% en la generación de potencia del turbogenerador 2 de esta fábrica, trae aparejados beneficios económicos importantes y también en el ámbito social y ambiental. Una evaluación de esta naturaleza solo es posible si se dispone de herramientas como la desarrollada en este trabajo.

5. CONCLUSIONES

El método de diagnóstico que se propone para los turbogeneradores está basado en su comportamiento energético y en la aplicación de técnicas de inteligencia artificial como son las redes neuronales artificiales, permitiendo la toma de decisiones desde una óptica más amplia lo que implica una clara adhesión a un modelo centrado en la eficiencia energética y no solamente teniendo en cuenta consideraciones puramente mecánicas.

Como se deduce de la explicación del procedimiento, es fácil de implementar on-line si fuera necesario dentro de un sistema supervisorio a partir de los datos del fabricante, mediciones de campo y redes neuronales artificiales pero requiere una adaptación de los conceptos dominantes actualmente en el campo del mantenimiento mecánico.

En el caso de estudio que se refiere, se ha provisto a la empresa de una evaluación que cuantifica energéticamente el deterioro de los turbogeneradores detectándose antes de las reparaciones que la peor condición la presentaba el turbogenerador 2, hecho que se comprobó posteriormente en el desarme. Por otra parte, la búsqueda de una magnitud (factor k) que permite no solo la realización de valoraciones cualitativas comparativas, sino estimar los posibles incrementos en la generación de tomarse las medidas pertinentes, también constituye un aspecto primordial. Por ejemplo, el hecho de que se pueda estimar un incremento del 19% si se realizan las reparaciones adecuadas, constituye una herramienta para la evaluación económica y el impacto socio-ambiental de las propuestas de reparaciones para estas máquinas, aspecto que no ha tenido un tratamiento similar hasta la fecha.

BIBLIOGRAFÍA

- [1] Gómez, J. R., 1996. Aspectos a considerar en una empresa cogeneradora de la industria azucarera. Tesis de Maestría. Facultad de Ingeniería Eléctrica. Universidad Central de Las Villas. Cuba.
- [2] Badía, J. C., et al., 1997. Manual de procedimientos para la reparación de turbinas de vapor. Publicaciones IMAGO, La Habana, Cuba.
- [3] Gómez, J. R., et al., 2008. Inteligencia artificial aplicada a la distribución de carga en un sistema de cogeneración.

Revista Energética, No. 39.

- [4] Boccaletti, C., Cerri, G. and Seyedan, B., 2001. A neural network simulator of gas turbine with a waste heat recovery section. *Journal of Engineering for Gas Turbines and Power*, Vol. 123. pp. 371-376.
- [5] Gómez, J.R. y De Armas, M., 2006. La Inteligencia Artificial al servicio de la Energía Renovable. Modelo Neuronal de un turbogenerador tipo P-4-20/2TK con parámetros desviados. *Revista Ecosolar*. No. 18.
- [6] Turbinas de vapor de contrapresión P-2,5-20/2TK y P-4-20/2TK. Descripción técnica e instrucciones de explotación 103-M-0225. Moscú. Tercera edición.
- [7] Halpin, S. M. and Burch, R. F., 1997. Applicability of neural networks to industrial and commercial power systems: A tutorial overview. *IEEE Transactions on Industry Applications*, Vol. 33, No. 5, Sept. 1997. pp 1355-1361.
- [8] Demuth, H. and Beale, M., 1998. *Neural network toolbox for use with Matlab. User's Guide. Version 3.0.* January.
- [9] Restrepo, H F., Peña, C.A. y Pérez, A., 2000. Hacia el desarrollo de nuevas máquinas computacionales: lecciones que aprendemos de la naturaleza. *Energía y Computación*, vol. IX. No. 2.

