

# DIAGNÓSTICO DEL MANTENIMIENTO CENTRADO EN LA EFICIENCIA DE TURBINAS DE CONTRAPRESIÓN APLICANDO REDES NEURONALES ARTIFICIALES.

Gómez, Julio R.\*; de Armas, Marcos A\*; Monteagudo, José P.\*; Ramos, Fernando\*\*  
[jgomez@ucf.edu.cu](mailto:jgomez@ucf.edu.cu)    [marmas@ucf.edu.cu](mailto:marmas@ucf.edu.cu)    [jpmyanes@ucf.edu.cu](mailto:jpmyanes@ucf.edu.cu)    [framos@ucf.edu.cu](mailto:framos@ucf.edu.cu)

\*Centro de Estudios de Energía y Medio Ambiente. Universidad de Cienfuegos, Cuba

\*\*Sede Universitaria Municipal Cruces. Universidad de Cienfuegos, Cuba.

## RESUMEN

Por diferentes causas las turbinas; durante la explotación, pierden eficiencia y disminuyen su rendimiento relativo efectivo. La aplicación de técnicas de 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 el estado técnico de las turbinas de una planta de cogeneración basados en la estimación del rendimiento de la turbina utilizando el consumo de vapor como indicador con una aplicación experimental en dos turbogeneradores de 4 MW.

**Palabras claves:** *Turbinas de contrapresión, diagnóstico, rendimiento, redes neuronales artificiales.*

## 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 los 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 molienda, 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, entendiéndose, turbogeneradores de contrapresión y niveles de presión de vapor de entrada de 18 kg/cm<sup>2</sup>. 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 científicos 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.

## **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.

### 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.

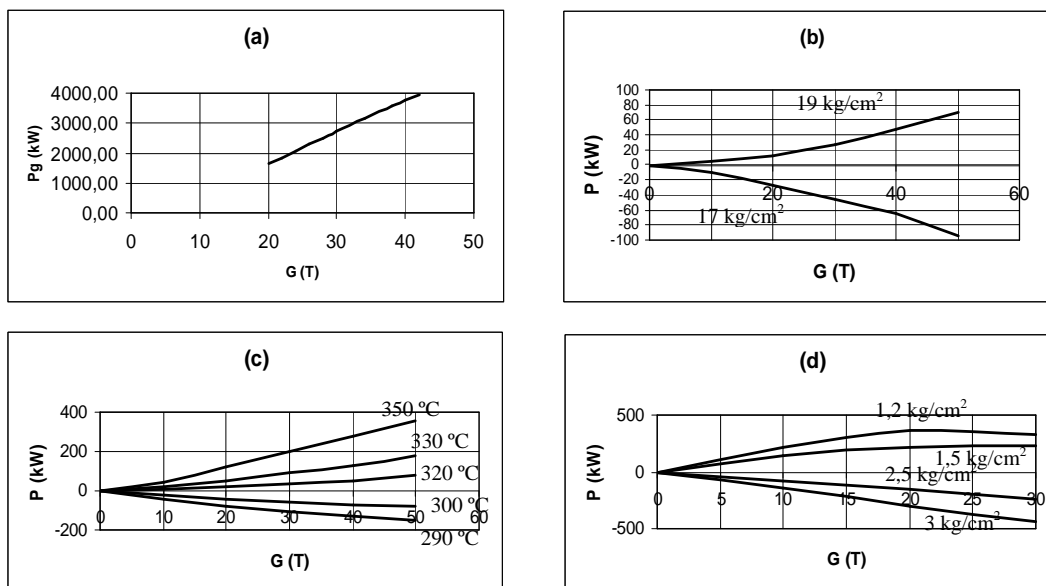


Figura 1. Características de explotación del turbogenerador. (a) Potencia eléctrica vs consumo de vapor para  $P_0=18 \text{ kg/cm}^2 \text{ abs}$ ,  $T_0=310 \text{ °C}$  y  $P_2=2 \text{ kg/cm}^2 \text{ abs}$ . (b) Corrección por presión directa. (c) Corrección por temperatura. (d) Corrección por presión de escape.

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

$$G' = G \cdot \frac{P_g}{P_{g'}} \quad (2)$$

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  $P_o=18 \text{ kg/cm}^2 \text{ abs}$ ,  $T_o=310 \text{ }^\circ\text{C}$  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.

### Diseño y entrenamiento de la red neuronal.

En problemas de ingeniería con una naturaleza altamente no lineal, se han aplicado con éxito las RNA, ya que estas pueden representar con precisión sistemas complejos. Las RNA pueden obtener el conocimiento del comportamiento del sistema a partir de juego de datos y poseen la habilidad de aprender a partir de ejemplos.

En la Figura 2 se muestra el esquema de una neurona artificial. Las cantidades de entrada  $x_i$  se combinan linealmente con los pesos  $w_i$  y constituyen el argumento de una función de activación para obtener las salidas. Se emplean diferentes tipos de funciones como la sigmoideal, lineal, hiperbólica, tangente, etc.




**Figura 2. Neurona artificial con función de activación.**

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 feed-forward como la más adecuada para estas aplicaciones [7]. Esta es una red de alimentación progresiva que emplea el mecanismo matemático de retropropagación para "aprender y ajustar", o sea, adaptar los pesos. La arquitectura de la red utilizada en este trabajo se muestra en la Figura 3. 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,  $P_o$ ,  $T_o$ ,  $P_2$ ) está constituido por la carga eléctrica, la presión del vapor directo, la 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 entrada y de la capa oculta es la función tangente sigmooidal hiperbólica (tansig) cuya expresión es:

$$F(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$



**Figura 3. Arquitectura de la RNA diseñada para simular el consumo de vapor de los turbogeneradores**

En este caso la red tiene cuatro neuronas de entrada y una de salida, determinadas por el número de cada una de ellas.

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. El entrenamiento se realizó para cuatro, cinco, seis, siete y ocho neuronas en la capa oculta.

La Tabla 1 muestra el error medio cuadrático; MSE (Mean Square Error) como función del número de neuronas ocultas. Se puede observar que el mejor comportamiento se logra con seis neuronas en la capa oculta, razón por la cual se ha escogido como arquitectura 4-6-1.

La función de la neurona de salida es lineal (purelin) definida como  $F(x) = x$ .

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.

**Tabla 1. Optimización del número de neuronas de la capa oculta. Arquitectura: 4-n-1, razón de aprendizaje: 0,001, épocas: 100.**

No. de neuronas en la capa oculta	Comportamiento del entrenamiento (MSE)
4	7,88E-06
5	8,05E-05
6	7,81E-07
7	1,58E-05
8	1,17E-06

### Simulación neuronal.

La red desarrollada se programó como una función en Matlab 7.0 para su utilización en aplicaciones de optimización de la operación del bloque energético en la industria. El código del modelo neuronal es:

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

$$\text{LW}(3,2) = [-2.0097 \ 1.1274 \ -3.0928 \ 1.9882 \ 1.2067 \ -0.5504]$$

Donde E es el vector de entrada normalizado siguiente:

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

$$b1 = \begin{bmatrix} -9.4536 \\ 10.5090 \\ 5.9129 \\ 2.3596 \end{bmatrix} \quad b2 = \begin{bmatrix} 3.4733 \\ -1.2348 \\ 0.8419 \\ -0.3773 \\ 1.7063 \\ 2.7124 \end{bmatrix} \quad b3 = [0.22186]$$

Las matrices de pesos y de polarizaciones de esta red entrenada son:

$$\text{IW}(1,1) = \begin{bmatrix} 2.4757 & 1.3301 & 3.2603 & -5.2186 \\ 0.5480 & -3.7079 & -5.4314 & -2.8977 \\ -0.3223 & -1.7110 & -2.5048 & -1.9161 \\ 0.7936 & 0.5633 & 0.8507 & -2.9593 \end{bmatrix}$$

$$\text{LW}(2,1) = \begin{bmatrix} -1.7290 & -4.1971 & 0.0480 & -0.2038 \\ -1.2756 & -1.3026 & 0.4669 & 0.2966 \\ 0.4660 & -0.4514 & 0.5498 & -0.2271 \\ -2.7066 & 0.0899 & -2.5179 & 0.7920 \\ -0.1617 & -1.7763 & 0.2019 & 1.6199 \\ 1.1320 & -1.5667 & 0.0254 & -0.8320 \end{bmatrix}$$

El consumo de vapor real se obtiene multiplicando el consumo de vapor normalizado de la salida de la red (G) por el valor máximo del juego de datos de entrenamiento, para este caso:

$$G_{\text{real}} = G * 50.5 \quad (\text{t})$$

La simulación se efectuó para un conjunto de datos tomados de la información del fabricante.

El consumo de vapor obtenido por la RNA, para diversas condiciones de explotación definidas para parámetros del vapor directo desviados por encima y por debajo de los de diseño y diferentes cargas se muestran en la Tabla 2.

**Tabla 2. Resultados de la simulación neuronal y el método gráfico de catálogo.**

Condiciones de explotación			Consumo de vapor (T)		% Error
Potencia (kW)	Parámetros desviados del vapor		Modelo Neuronal	Método del fabricante	
	Presión de vapor directo (kg/cm <sup>2</sup> abs)	Temperatura del vapor directo (°C)			
4000	17	290	44.47	44.49	-0.045
4000	19	320	41.19	41.01	0.438
3500	17	290	39.39	38.28	2.899
3500	19	320	36.56	36.00	1.555
3000	17	290	34.36	34.98	-1.772
3000	19	320	31.91	32.11	-0.622

### 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:

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

Donde:

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

$\Delta H_o$  es el salto entálpico disponible, en kJ/kg.

$\eta_{ri}$  es el rendimiento relativo interno de la turbina, en pu.

$\eta_m$  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:

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

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 4.




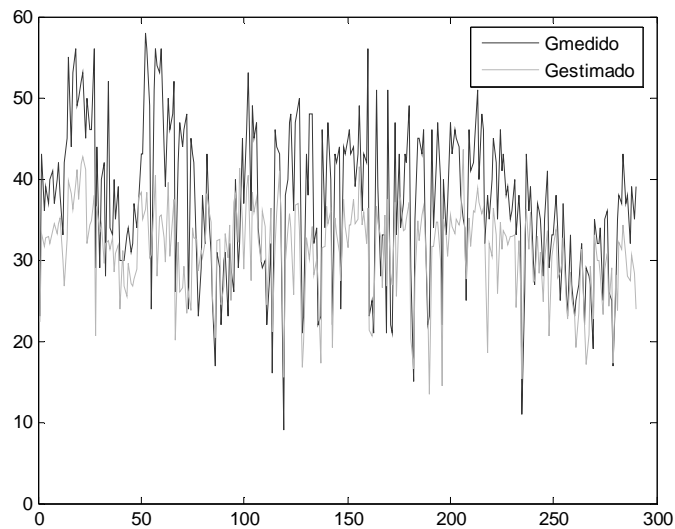
Figura 4. Esquema para determinar el indicador de disminución del rendimiento relativo efectivo de la turbina.

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 ( $P_1$ ) en  $\text{kg/cm}^2$  abs, la temperatura del vapor directo ( $T_1$ ) en  $^\circ\text{C}$ , la contrapresión ( $P_2$ ) en  $\text{kg/cm}^2$  abs y la potencia eléctrica generada ( $Pe$ ) 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.


#### ANÁLISIS DE LOS 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 5 y 6. 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 5. Consumos de vapor medido y estimado por el modelo para el Turbo 1**



**Figura 6. 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 7 y 8.

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 7. Factor k indicativo de la variación del rendimiento relativo del Turbogenerador 1**



**Figura 8. Factor k indicativo de la variación del rendimiento relativo del Turbogenerador 2**

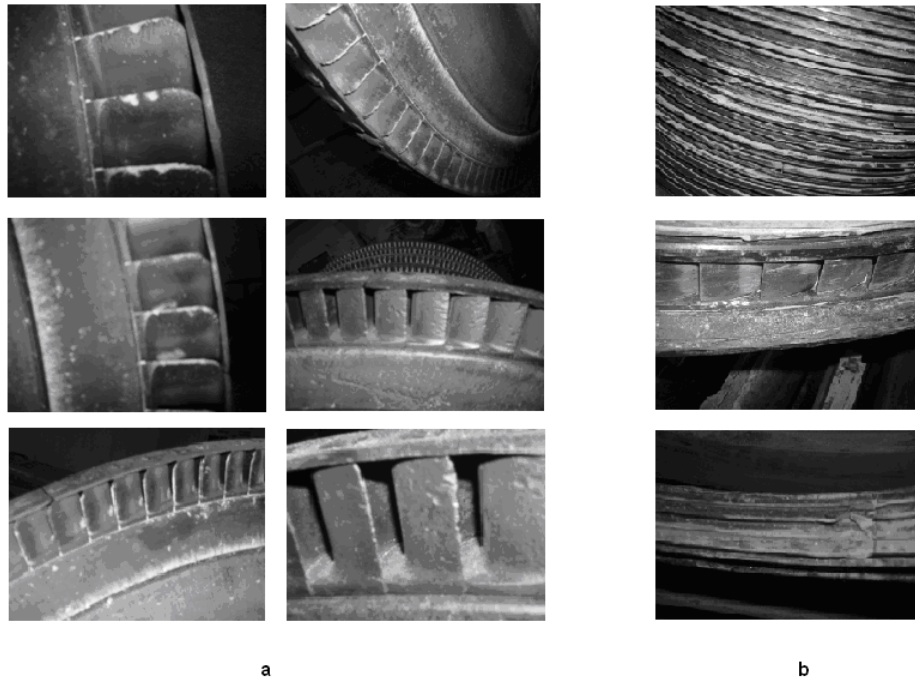
Puede observarse que en virtud de estos resultados obtenidos la disminución del rendimiento en el turbogenerador 2 es mayor que en el 1 lo cual es indicativo de deterioros mecánicos en esta máquina que la conducen a esta pérdida en el rendimiento como se evidenció posteriormente (Figuras 9 y 10).

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.



**Figura 9. Fotografías de la turbina 2 mostrando afectaciones en el perfil de alabes (a) y sellos (b).**



**Figura 10. Fotografías de la turbina 1 mostrando el buen estado técnico de alabes (a) y sellos (b).**

## 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. "Aspectos a considerar en una empresa cogeneradora de la industria azucarera". Tesis de Maestría. Facultad de Ingeniería Eléctrica. Universidad Central de Las Villas. Cuba. 1996.
- [2] Badía, J. C., et al., "Manual de procedimientos para la reparación de turbinas de vapor". Publicaciones IMAGO, La Habana, Cuba, 1997.
- [3] Gómez, J. R., et al., "Inteligencia artificial aplicada a la distribución de carga en un sistema de cogeneración". Revista Energética, No. 39, Julio de 2008.
- [4] Boccaletti, C., Cerri, G., Seyedan, B. "A neural network simulator of gas turbine with a waste heat recovery section". Journal of Engineering for Gas Turbines and Power. April 2001, Vol. 123. pp. 371-376.
- [5] Gómez, J.R., De Armas, M. 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, Oct. 2006.
- [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., Burch, R. F. "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., Beale, M. Neural network toolbox for use with Matlab. User's Guide. Version 3.0. January 1998.
- [9] Restrepo García, H. F., Peña Reyes, C. A., Pérez Uribe, A., "Hacia el desarrollo de nuevas máquinas computacionales: lecciones que aprendemos de la naturaleza". Energía y Computación, vol. IX, no. 2, Segundo semestre de 2000.

## Biografía de los autores.



**Julio Rafael Gómez Sarduy** nació en Cienfuegos en 1963. Se graduó como Ingeniero Electricista en la Universidad Central de las Villas, Cuba, en 1986, en 1996 obtiene una Maestría en la misma universidad y el grado de Dr. en Ciencias Técnicas, en el

2006. Profesor Auxiliar. Trabaja en el Centro de Estudios de Energía y Medio Ambiente de la

Universidad de Cienfuegos, Cuba. Temáticas de interés: máquinas asincrónicas; ahorro en sistemas eléctricos industriales; calidad de la energía e investiga en la aplicación de la inteligencia artificial a problemas de identificación paramétrica de máquinas eléctricas con el empleo de algoritmos genéticos, y la aplicación de modelos neuronales y neurodifusos para la modelación y el control de sistemas y equipos energéticos.



**Marcos Alberto de Armas** nació en Cienfuegos, Cuba, el 19 de Septiembre de 1953. Se graduó en la Universidad Central de Las Villas con el título de Ingeniero Electricista en 1977. Obtiene el grado de Dr. en Ciencias en el 2000. Actualmente trabaja en el Centro de Estudios de Energía y Medio

Ambiente de la Universidad de Cienfuegos, Cuba. Entre sus campos de interés está el uso racional de la energía, la calidad de la energía eléctrica, el ajuste, montaje y puesta en marcha de sistemas de generación de energía eléctrica, la generación distribuida y la inteligencia artificial aplicada a los sistemas energéticos.



**José Pedro Monteagudo Yanes** es Profesor Titular del Centro de Estudio de Energía y Medio Ambiente (CEEMA) de la Universidad de Cienfuegos. Cuba. Labora en la Educación Superior Cubana desde 1975. Está titulado de Ingeniero Mecánico en la Universidad

Central de Las Villas y de Doctor en Ciencias Técnicas.

Ha ofrecido cursos de pregrado y postgrado como profesor invitado en Cuba, México, Colombia y Venezuela

Ha realizado trabajos conjuntos de investigación en el Instituto Politécnico de Odessa (Ucrania) y la Politécnica de Silesia (Polonia).

Es miembro del Tribunal Nacional para la defensa de grados científicos de la República de Cuba en la Rama Mecánica.



**Fernando Ramos** nació en Cienfuegos en 1951. Se graduó de Ingeniero Químico en la Universidad central de Las Villas y de Máster en eficiencia Energética en la Universidad de Cienfuegos en el año 1998. Posee una vasta

experiencia industrial en la rama azucarera. Ejerció profesionalmente en la Empresa Azucarera Ciudad Caracas, Cienfuegos, Cuba, como Jefe de fabricación e Inversionista y actualmente se desempeña como Jefe de Carrera en la Sede Universitaria Municipal de Cruces.