

PREDICCIÓN DEL CONSUMO DE ELECTRICIDAD Y GAS LP EN UN HOTEL MEDIANTE REDES NEURONALES ARTIFICIALES

PREDICTION OF ELECTRICITY AND LPG CONSUMPTION IN A HOTEL USING ARTIFICIAL NEURAL NETWORKS

M.Sc. Reineris Montero Laurencio¹, Dr. Carlos Pérez Tello², M. Sc. Ever Góngora Leyva¹ &
Dr. Secundino Marrero Ramírez¹

1. Centro de Estudio de Energía y Tecnología Avanzada de Moa. Instituto Superior Minero Metalúrgico, Cuba

2. Instituto de Ingeniería. Universidad Autónoma de Baja California, México

rmontero@ismm.edu.cu, carlosperez@uabc.mx, egongora@ismm.edu.cu, smarrero@ismm.edu.cu

Recibido para evaluación: 13 de Octubre de 2009

Aceptación: 10 de Noviembre de 2009

Entrega de versión final: 15 de Diciembre de 2009

Resumen

El presente trabajo se desarrolló con el fin de aportar a la mejora de las herramientas actuales de planificación energética aplicada a hoteles turísticos. Con ello es posible predecir el consumo de energía eléctrica y de gas LP de una instalación con más de un noventa por ciento de precisión, empleando redes neuronales artificiales (RNA) como modelos de ajuste y predictivos. Como variables de entrada a las estructuras de los modelos se tuvieron en cuenta las condiciones climatológicas de la región y el nivel ocupacional. Se realizó una identificación inicial mediante modelación paramétrica y luego se mejoró el resultado con el empleo de Redes Neuronales Artificiales. Para ambos casos se utilizaron las herramientas contenidas en Matlab. La desviación promedio en la predicción de energía eléctrica fue de 0.6% con una desviación estándar del 4%. Para el caso del gas LP la desviación media fue menor al 1% y una desviación estándar del 1.3%.

Palabras Clave: Climatología, hoteles, predicción energética, redes neuronales artificiales.

Abstract

This work was developed in order to improve the current tools for energy planning. This makes possible to predict electricity and LPG consumption in a tourist facility with accuracy higher than 90% by using Artificial Neuronal Networks (ANN) as fitting and predictive models. Local climatology and occupational patterns were used as entering variables for the models. Parametric modeling was performed as starting conditions and then improved with ANN's. Matlab tools were used for calculations. The average deviation when predicting electricity consumption was 0.6% with a standard deviation of 4%. For LPG consumption the average deviation was less than 1% with a standard deviation of 1.3%.

Keywords: Climate, hotels, energy prediction, artificial neural networks

1. INTRODUCCIÓN

La crisis económica global tiene una incidencia significativa en los estándares de funcionamiento de la actividad turística. Cuba no está exenta a esta situación, en el pasado año 2009 se apreció un incremento en la cifra de visitantes sin embargo los ingresos no se comportaron de igual forma. En la actualidad a pesar de las dificultades se aspira a un crecimiento del sector turístico dada su importancia cada vez mayor en nuestra economía.

Por sus características naturales, el territorio cubano es un destino muy atractivo. Es por ello que las cadenas turísticas están obligadas a comercializar un producto de calidad teniendo en cuenta los costos de operación y uno de los aspectos importantes en los que se puede incidir para disminuir significativamente estos costos es la eficiencia energética.

En Cuba los hoteles representan aproximadamente el 8% de las 1000 empresas más consumidoras de energía. Sus instalaciones se caracterizan en general por su elevado, y en ocasiones, poco racional consumo de energéticos. A partir de los diagnósticos energéticos realizados en el polo turístico de Holguín (Montero, et al. 2005) se determinó que los principales portadores energéticos empleados son: electricidad (80-95%), gas licuado (5-9%), diesel (3-7%) y gasolina (2-5%).

El clima es uno de los puntos de importancia que se debe tener en cuenta para el análisis del consumo de energía eléctrica en los países del trópico. En ocasiones se puede consumir en una misma habitación hasta 10 veces más energía en verano comparándolo con el consumo de invierno. En el caso de Cuba, los meses de julio y agosto son los más calurosos y en meses como mayo, junio, septiembre y octubre, las temperaturas disminuyen debido al incremento de las precipitaciones. Con estas lluvias ocurre un descenso de la temperatura exterior (Monteliet, et al. 2006)

El primer paso para lograr el ahorro de portadores energéticos es su planificación. En el caso específico de los hoteles se realiza comúnmente a partir de valores históricos sin tener en cuenta las perturbaciones que ocurren debido a la variabilidad del clima de un año a otro. Esta situación obliga a buscar herramientas que permitan una mejor predicción energética como base de un enfoque más representativo. Dentro del equipamiento de una instalación turística se reconoce

por varios autores (Monteagudo, et al. 2005) (Monteliet, et al. 2006) (Monteliet, et al. 2008) (Montero, 2005), que la climatización es la que más energía eléctrica consume y la cual puede llegar a ser del orden del 60% del consumo total y se debe, entre otros aspectos, a las condiciones tropicales. Lo anterior indica la importancia de conocer la climatología de cada región y su interrelación con el uso de los portadores energéticos. En el presente trabajo se identifican modelos paramétricos y neuronales que permiten predecir el consumo de electricidad y el gas licuado (LP) en un hotel mediante su interrelación con las variables climatológicas y de ocupación.

2. METODOLOGÍA

Se realizó una revisión del comportamiento diario de los registros históricos de los años 2007 y 2008. Se procesaron además los valores medio mensuales de los últimos 37 años en busca de una tendencia y de los valores mínimos y máximos promedio. Dentro de las variables analizadas se encuentran los valores medios mensuales de la temperatura ambiente (máxima, mínima, media, máxima absoluta y mínima absoluta), la velocidad del viento predominante, el total de lluvias, la presión atmosférica, la humedad relativa y la nubosidad.

Estas magnitudes permiten delimitar un espacio dentro de la carta psicrométrica en la cual se desenvuelve la operación de la climatización del hotel. De este equipamiento depende mayoritariamente el consumo de electricidad de la instalación reflejado en los motores y compresores asociados y el gas LP que en más de un 85% de los hoteles cubanos se utilizan en los sistemas de agua caliente.

La primera parte de la modelación consistió en utilizar los datos correspondientes a los valores medios mensuales de la ocupación de un hotel y las variables climatológicas seleccionadas para identificar el modelo paramétrico que permite estimar el consumo de gas LP. Para mejorar la precisión se utilizó una estructura de red neuronal artificial. Luego se realizó el mismo procedimiento para el caso del consumo de energía eléctrica. Para el caso del consumo de electricidad la modelación paramétrica no brindó ninguna estructura aceptable pero las RNA produjeron mejores resultados predictivos.

3. RESULTADOS

Se utilizaron los datos de la estación climatológica más cercana, situada en Cabo Lucrecia en el municipio de Banes, provincia de Holguín, Cuba, situada a 30 km de la instalación analizada y ubicada en la misma franja costera.

El comportamiento energético debido a la climatización exhibe una tendencia extremadamente marcada a la dependencia con la temperatura ambiente, sin embargo, la temperatura varía a lo largo del día y el rango de oscilación diurna depende de diversos factores entre los que se encuentran la zona geográfica, la cercanía al mar, la velocidad y dirección de los vientos predominantes, y la época del año. De los estudios realizados y reportados hasta la fecha, es concluyente que el efecto de la temperatura ambiente en instalaciones climatizadas es quien controla en mayor medida su comportamiento energético. El conocimiento de esta variable y su variación para cada zona climática es entonces de vital importancia en el análisis termoenergético de cualquier instalación hotelera.

Debido a las especificaciones cubanas de registro de variables climatológicas, el régimen de recolección de datos de la estación de cabo Lucrecia y del sistema meteorológico en general es cada tres horas. En la figura 1 se muestra la temperatura ambiente media horaria para los años 2007 y 2008.

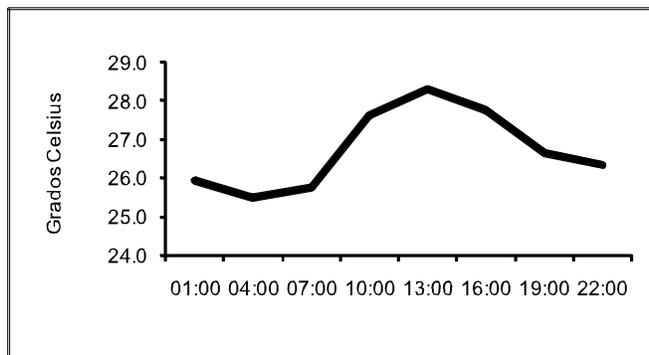


Figura 1. Comportamiento medio de la temperatura ambiente.

Como se aprecia en la Figura 1 los límites inferior y superior de oscilación de la temperatura ambiente se encuentran entre 250C y 280C, respectivamente. Esto indica una variación promedio relativamente pequeña (tres grados en promedio). A pesar de que las variaciones son pequeñas, el sistema de climatización

varía sus regímenes de operación con respecto a estas temperaturas adaptándose además a las cargas parciales. Para tener una mejor idea de la variabilidad de la temperatura ambiente durante todo el año en la región donde se ubica el hotel analizado, se presenta el gráfico de la figura.2. Los meses más calurosos son de mayo a octubre.

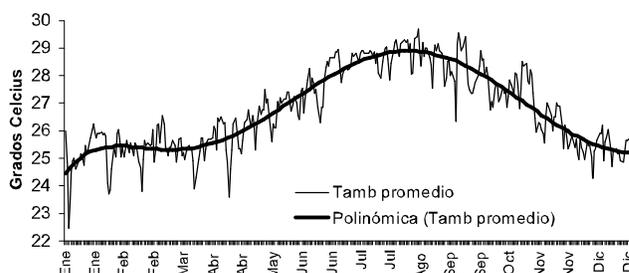


Figura 2. Comportamiento de la temperatura ambiente promedio durante el año.

Otra variable climatológica analizada fue la humedad relativa (Figura 3). De forma general los valores promedios indican un comportamiento alto de la humedad entre 72% y 82 %. Por encima de 80% de 10:00 pm a 7:00 am e inferior durante el resto del día.

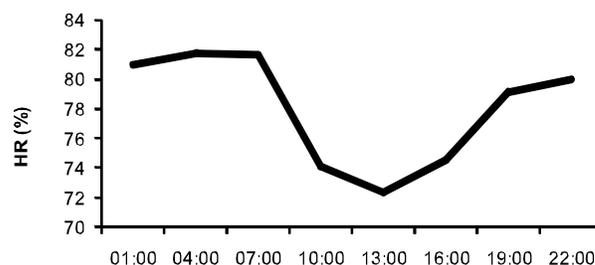


Figura 3. Comportamiento medio de la humedad relativa.

Otras variables climatológicas asociadas a un edificio y que de ella depende el intercambio térmico son: Las lluvias, velocidad del viento predominante, humedad relativa y la nubosidad. En la tabla 1 se muestran los valores mínimo y máximo medios. Estos valores corresponden al periodo de 1970 al 2007. No se dispone de registros históricos de radiación solar por lo que se estimó ésta utilizando la metodología reportada por (McQuinston, Parker, Spitler. 2008). En el transcurso del año las variables climatológicas cambian en correspondencia a los meses. Estas diferencias se hacen notables en el desempeño del equipamiento tecnológico de un hotel y en la operación del mismo.

Tabla 1. Valores máximos y mínimos medios históricos de variables climatológicas

Variables climatológicas	Mín.	Máx.
Temperatura máxima media (°C)	26.8	31.2
Temperatura mínima media (°C)	22.0	26.0
Temperatura medias (°C)	24.5	28.5
Temperatura máxima absoluta (°C)	29.2	32.5
Temperatura mínima absoluta (°C)	17.8	23.1
Lluvias mensuales (mm.)	37.7	162.6
Días con lluvias	6.0	14.8
Velocidad del viento predominante (km/h)	14.8	20.0
Humedad relativa (%)	78.9	82.4
Nubosidad	3	4

Otro elemento que incide en el desempeño del equipamiento tecnológico y en la explotación del hotel son las temporadas turísticas. En ellas varía notablemente la ocupación en diferentes meses al igual que cambian las variables climatológicas. Estas temporadas se clasifican y corresponden a los siguientes periodos:

- Temporada alta: del 8 de enero al 6 de abril y del 17 de diciembre al 7 de enero.
- Temporada media: del 16 de abril al 13 de julio y del 3 de septiembre al 16 de diciembre.
- Temporada baja: del 7 al 15 de abril y del 14 de julio al 2 de septiembre.

Los periodos de baja ocupación coinciden con los de mayor temperatura ambiente. Esto obliga a que la climatización opere para satisfacer una ocupación menor pero con cargas térmicas más apreciables. Ante esta situación disminuye la correlación entre el indicador habitación-día ocupado (HDO) y los consumos de gas LP y electricidad. Por ejemplo, en el mes más caluroso y de menor ocupación (agosto), se consume un 20% más de gas que en julio y septiembre. Un caso similar ocurre con la electricidad. Esta tendencia muestra la necesidad de una planificación más acertada de los energéticos.

3.1. Identificación paramétrica del consumo de gas LP

Las técnicas de identificación de sistemas han cobrado gran relevancia en diversas áreas del conocimiento donde se requiere de un modelo para fines de análisis, predicción, simulación, diseño y control (Kunusch, 2003). Con la ayuda del Toolbox de identificación de Matlab inicialmente se realizó una identificación del modelo paramétrico que relaciona el indicador HDO

con el consumo de gas LP del hotel. Se tomaron como variables de entrada los valores promedio de HDO mensuales y como variable de salida los valores promedio del consumo de gas LP de varios años. El indicador HDO se ha venido empleando tradicionalmente en Cuba como variable de decisión para planificación energética de instalaciones hoteleras.

Se utilizó todo el conjunto de modelos paramétricos. Las estructuras que reflejaron el mejor resultado fueron la ARX de tercer orden y la ARMAX de segundo orden con ajuste de 0.87 y 0.82, respectivamente. Se validaron los modelos con los datos de 2 años.

Aprovechando la información de las demás variables climatológicas se determinó que la velocidad del viento predominante es la que mejor se puede incorporar como entrada a una nueva modelación. Esta afirmación se sustenta en que el coeficiente de correlación lineal de las restantes variables es bajo, mientras que en el caso de las HDO y la velocidad del viento es de 0.87 y 0.88 respectivamente.

La velocidad del viento tiene relación con el consumo de gas LP de un hotel ya que el viento lleva implícitas las propiedades del aire. En el caso específico de los hoteles de Sol y Playa la energía absorbida por las edificaciones se hace menos intensa debido a la acción convectiva de los vientos provenientes del mar. Este aspecto favorece la disipación de calor de las estructuras constructivas del hotel.

Al utilizar las herramientas de identificación del Matlab la estructura que mejor relacionó el indicador habitación-día-ocupado (HDO) y la velocidad del viento predominante con el consumo de gas LP fue la ARMAX de segundo orden (ARMAX2221). Para un ajuste de 0.94. Esto mejoró el grado de correlación.

3.2. Predicción de consumo de gas LP en el hotel con redes neuronales artificiales

Las técnicas de inteligencia artificial tienen actualmente una extensa aplicación en diversos campos del conocimiento, en particular para reproducir patrones, optimizar, controlar y dirigir sistemas complejos donde las soluciones analíticas pueden ser complicadas, tediosas, difíciles, o requieren de un personal experto y de largos periodos de investigación y trabajo (Armas, Gómez, Pérez, et al. 2007).

El uso de redes neuronales artificiales (RNA) adquiere un papel protagónico debido a su rapidez y exactitud

en los resultados una vez han sido entrenadas satisfactoriamente. Su empleo en la predicción de consumos energéticos de edificios ha sido abordado por otros autores (Anstett, Kreider. 1993) (Yang, Rivard, Zmeureanu. 2005) y a la vez confirman un mejor desempeño con respecto a los modelos de regresión. No obstante en la presente investigación se adapta el uso de esta técnica en un hotel de Sol y Playa con un contexto climatológico y de explotación muy específico.

Es por ello que se entrenó una red neuronal para la estimación del consumo de gas LP utilizando como variables de entrada el indicador HDO y la velocidad del viento predominante. En este caso se seleccionó una RNA de dos capas del tipo *feed-forward backpropagation*, una de las topologías consideradas más poderosas. La selección de este tipo de red responde a sus facilidades en la solución de problemas de ingeniería y su efectividad a la hora de resolver problemas complejos. El modelo propuesto se muestra en la figura.4

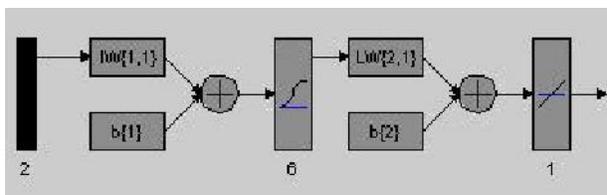


Figura 4. RNA para estimar el consumo mensual de gas LP.

La red neuronal seleccionada utiliza en la primera capa una función del tipo *logsig* (logarítmica sigmoideal) lo que le permite aprender a la red de elementos lineales y no lineales entre los vectores de entrada y los de salida. Esta capa está integrada por seis neuronas. En la segunda capa (capa de salida) se utilizó una función del tipo *purelin* ya que con ella, la red puede tomar cualquier valor y está conformada por una única neurona. La función de entrenamiento escogida fue *trainlm* debido a sus excelentes resultados en aplicaciones de ingeniería ya que consigue alcanzar el criterio de convergencia con más rapidez que las demás funciones de entrenamiento.

El entrenamiento de la red neuronal se realizó por el procedimiento supervisado de retro-propagación de errores con doce juegos de datos que corresponde al promedio de los meses del año, obtenidos de los registros de los años 2000 al 2007. Todas las variables fueron normalizadas para facilitar el trabajo de cálculo. La aportación de cada nueva iteración en términos de reducción del error cuadrático medio es despreciable a partir de las 80 iteraciones alcanzando el valor de 3.6×10^{-5} . Para verificar la calidad de la red y su capacidad de reproducir patrones, se evaluó estadísticamente el error entre la respuesta de la red neuronal y los valores reales registrados para corroborar la calidad de la predicción y de la reproducción del comportamiento del sistema.

3.3. Predicción del consumo de energía eléctrica

Para obtener un modelo se analizaron las variables climatológicas que podían relacionarse para estimar el consumo de electricidad. Los valores son los promedios mensuales obtenidos de una base de datos. El modelo neuronal seleccionado fue del tipo *feed-forward backpropagation* y presenta tres capas en la que se incluye una capa oculta con tres neuronas. El modelo se representa en la figura 5.

La red neuronal contiene seis vectores de entrada, cinco de ellos son variables climatológicas: temperatura ambiente, presión atmosférica, velocidad del viento predominante, humedad relativa, y total de lluvias mensuales. El sexto vector es el mes del año. La red utiliza en la primera capa una función *logsig* con seis neuronas que representa el total de vectores de entrada. En la capa oculta la función utilizada fue *purelin* con tres neuronas. En la capa de salida la función también es *pureline* con una sola neurona debido a que el modelo sólo tiene un vector de salida: el consumo mensual de energía eléctrica. La función de entrenamiento utilizada fue *trainlm* y se empleó el método de mínimos cuadrados.

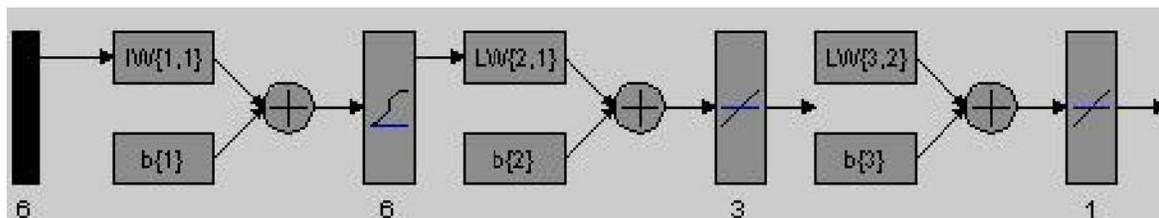


Figura 5. RNA para estimar el consumo de electricidad mensual.

Se realizaron varios entrenamientos, ya que uno de los objetivos fue dotar a la red de un número adecuado de neuronas en la capa oculta para que sea capaz de aprender las características de las posibles relaciones existentes entre los datos de la muestra. Esto le permite a la RNA posteriormente realizar mejores predicciones sobre valores futuros. Se demuestra en esta estructura que el consumo de energía eléctrica depende más de la climatología que de la ocupación. Cuando se incorporó el indicador HDO el resultado no mejoró. El entrenamiento se realizó por el procedimiento supervisado de retropropagación de errores con 60 juegos de datos. De ellos los 48 primeros son para el entrenamiento, los que se corresponde a los meses de los años del 2002 al 2005 y los 12 restantes del año 2008 se utilizaron para la validación. La red disminuyó

el error al valor mínimo posible en menos de 200 *epochs* (0.00026). Este valor indica que la aportación de cada nueva iteración en términos de reducción del error cuadrático medio es despreciable a partir del número óptimo de iteraciones.

En la tabla 2 se muestran los resultados estadísticos de la comparación entre los valores reales registrados y los calculados por el modelo neuronal. Se aprecia que la desviación media de los consumos de electricidad es del orden del 0.6% con una desviación estándar del 4%, en tanto que para el consumo de gas LP la desviación promedio es mucho menor (0.004%) con una desviación estándar de 1.3% lo cual indica que el modelado con la red neuronal artificial reproduce excelentemente el comportamiento del sistema físico real y dentro de los parámetros de confianza estadística.

Tabla 2. Análisis estadístico de consumo de electricidad y gas LP para el hotel analizado.

Mes	Consumo (kWh)			Gas LP (L)		
	Real	Calculado	Desviación (%)	Real	Calculado	Desviación (%)
Enero	225647	231208	-2.5%	8700.8	8700.8	0.0%
Febrero	207713	213791	-2.9%	7438.4	7438.3	0.0%
Marzo	249014	261687	-5.1%	7093.9	7093.8	0.0%
Abril	241861	244920	-1.3%	5965.6	5965.3	0.0%
Mayo	181553	173007	4.7%	3524	3514.3	0.3%
Junio	171402	165245	3.6%	4173	4310.4	-3.3%
Julio	227496	225096	1.1%	3935	3941.5	-0.2%
Agosto	239834	224203	6.5%	4551.4	4546.2	0.1%
Septiembre	223714	232695	-4.0%	4016.1	3999.8	0.4%
Octubre	205795	193534	6.0%	4510.3	4393.9	2.6%
Noviembre	225715	219768	2.6%	5955.1	5954	0.0%
Diciembre	208512	211627	-1.5%	7781.3	7780.3	0.0%
		Prom. desv.	0.6%		Prom. desv.	-0.004%
		Desv. estándar	4.0%		Desv. estándar	1.3%

La diferencia entre el consumo total del año 2008 entre los valores calculados y reales corresponden aproximadamente al consumo de un día de temporada alta del hotel, esto es más que aceptable para las características deseadas de precisión de estimación y confiabilidad estadística.

4. CONCLUSIONES

Los modelos neuronales utilizados demostraron que la predicción y correlación de consumo de electricidad y gas LP en el hotel analizado son confiables dentro de

los parámetros requeridos de estimación y seguimiento del comportamiento estacional. Por otra parte, el empleo de redes neuronales artificiales produce resultados más cercanos a los reales que con los modelos paramétricos convencionales que utilizan. En esta ocasión se incluyeron diferentes variables como factores de entrada entre las que se encuentran temperatura ambiental, velocidad del viento, humedad relativa, precipitación pluvial, entre otras. Sin embargo se está realizando el análisis de algunas de tales variables a fin de determinar su verdadero grado de interacción e impacto y con el propósito de optimizar el empleo de la información climatológica requerida. Se espera incorporar un nuevo

criterio que integre el comportamiento climático de una manera más sencilla y que aporte un mejor nivel de correlación y predicción del comportamiento energético y que permita, asimismo, generalizar la metodología a cualesquier instalación, sea hotelera o no.

AGRADECIMIENTOS

Al Instituto de Meteorología de la provincia de Holguín, Cuba, por su especial colaboración con la información climatológica requerida para presentar estos resultados.

BIBLIOGRAFÍA

- [1] Anstett, M. and Kreider, J.F., 1993. Application Of Neural Networking Models To Predict Energy Use. ASHRAE Transactions 99 (1), pp. 505-517.
- [2] Armas, T.M., Gómez, S.J., Pérez, T.C., et al, 2007. Inteligencia Artificial Aplicada al Análisis de Sistemas Energéticos. Colombia: Fundación Universitaria Tecnológico Comfenalco Cartagena, Colombia. 269 P.
- [3] Kunusch, C. 2003. Identificación de Sistemas Dinámicos. Universidad de la Plata. Facultad de Ingeniería, 39 P.
- [4] Monteagudo, Y.J., et al, 2005. Considerar los factores climatológicos durante la explotación reduce el consumo de potencia en los chiller en más de un 15%. Facultad de Ingeniería Mecánica. Universidad de Cienfuegos. CIER.Cuba.
- [5] Montelier, H.S., et al. 2006. Influencia de las principales variables climatológicas en la operación de los sistemas de climatización por agua helada. Cienfuegos. 4^{to} Taller de Energía y Medio Ambiente, Cienfuegos. Cuba.
- [6] Montelier, H.S., et al. 2008. Reducción del consumo de energía en instalaciones con sistemas de climatización centralizadas todo agua a flujo constante. Tesis Doctoral. Universidad de Cienfuegos. 102 P.
- [7] Montero, L.R., et al. 2005. Diagnósticos Energéticos y su influencia en la Gestión Empresarial en Hoteles. III Convención "Entorno Agrario 2005"
- [8] McQuinston, F., Parker, J. y Spittler, J., 2008. Calefacción, ventilación y aire acondicionado. pp.3-58.
- [9] Yang, J., Hugues R. and Radu Z., 2005. Building energy prediction with adaptive artificial neural networks. [en línea]. [Consulta: mayo, 2009]. Disponible en: http://www.ibpsa.org/m_papers.asp.

