

*Universidad de Matanzas
sede "Camilo Cienfuegos"
Facultad de Ciencias Técnicas*



OBTENCIÓN DE MODELO PREDICTIVO DE CONSUMO ELÉCTRICO DEL HOTEL ROYALTON HICACOS

Trabajo de Diploma en Ingeniería Mecánica

Autor: Nelson Javier Aldazábal Hernández

Tutor: Ing. Gabriel Roque Villalonga

Matanzas, 2021

DECLARACIÓN DE AUTORIDAD

Por medio de la presente declaro que soy el único autor de este trabajo de diploma y, en calidad de tal, autorizo a la Universidad de Matanzas «Camilo Cienfuegos» a darle el uso que estime más conveniente.

NOTA DE ACEPTACIÓN

Miembros del Tribunal:

Presidente

Secretario

Vocal

AGRADECIMIENTOS

Quiero agradecer a todos mis compañeros de aula por todos los momentos compartidos, a todos los profesores que nos brindaron sus conocimientos para nuestra formación como profesionales, a mi familia por siempre estar ahí presente, a mi tutor Ing. Gabriel Roque Villalonga por guiarme durante esta última etapa de formación y un agradecimiento especial a mi novia Lianne Laura de León Ramírez por ser la persona en la que siempre puedo buscar apoyo incondicional.

A todos MUCHAS GRACIAS.

RESUMEN

La climatización tiene un alto índice de consumo energético en las edificaciones afectando negativamente el medio ambiente. La implementación de herramientas que contribuyan a una buena gestión de la energía es capaz de reducir considerablemente el impacto negativo que provoca este proceso. Con el objetivo de lograr un uso más eficiente de la energía numerosos autores han desarrollado metodologías para predecir el consumo energético por concepto de climatización en edificaciones. En este trabajo se utilizó una hoja de cálculo de Excel previamente preparada con tres de los métodos más conocidos para la obtención de un modelo predictivo eficaz para el mejoramiento de la gestión energética en el hotel Royalton Hicacos, basados en el cálculo de la temperatura base y de los Días Grados de Enfriamiento, comparando los resultados de estos con los obtenidos mediante el entrenamiento de una red neuronal artificial basada en el algoritmo Perceptrón Multicapa; siendo apreciables mejores resultados por parte del modelo obtenido por el método desarrollado por la *American Society of Heating, Refrigerating and Air-Conditioning Engineers* siendo este el que más se ajusta a las condiciones climatológicas del hotel, seleccionado por presentar el coeficiente de determinación más cercano a la unidad.

Palabras claves: Consumo Energético; Días Grado; Redes Neuronales; Perceptrón Multicapa

ABSTRACT

Air conditioning has a high rate of energy consumption in buildings, negatively affecting the environment. The implementation of tools that contribute to good energy management is capable of considerably reducing the negative impact caused by this process. In order to achieve a more efficient use of energy, numerous authors have developed methodologies to predict energy consumption for air conditioning in buildings. In this work, an Excel spreadsheet previously prepared with three of the best known methods was used to obtain an effective predictive model for the improvement of energy management in the Royalton Hicacos hotel, based on the calculation of the base temperature and Degrees of Cooling Days, comparing the results of these with those obtained by training an artificial neural network based on the Multilayer Perceptron algorithm; Better results being appreciable from the model obtained by the method developed by the American Society of Heating, Refrigerating and Air-Conditioning Engineers, this being the one that best adjusts to the climatic conditions of the hotel, selected for presenting the coefficient of determination closest to unit.

Keywords: Energy consumption; Degree days; Neural Networks; Multilayer Perceptron

TABLA DE CONTENIDO

Introducción	8
Capítulo 1 Revisión Bibliográfica	10
1.1 Consumo energético en edificaciones	10
1.1.1 Consumo energético en instalaciones hoteleras.....	10
1.1.2 Consumo energético en edificaciones por climatización.....	10
1.2 Impacto ambiental de la climatización en edificaciones	11
1.3 Gestión energética	11
1.4 Gestión energética del turismo en Cuba.....	11
1.5 Implementación de la norma ISO 50001.....	12
1.6 Indicadores de desempeño energético.....	12
1.7 Días Grados de enfriamiento.....	13
1.7.1 Temperatura base	15
1.8 Redes Neuronales Artificiales aplicadas a la eficiencia energética	15
1.8.1 Perceptrón Multicapa (PMC).....	16
Capítulo 2 Materiales y métodos	17
2.1 Caracterización del hotel.....	17
2.2 Presentación de los datos estadísticos de consumo, de ocupación y climatológicos del hotel.....	17
2.3 Cálculo de HDO-DGE como indicador de desempeño energético.....	19
2.4 Determinación de la temperatura base.....	19
2.5 Cálculo de los DGE por el método de la <i>American Society of Heating, Refrigerating and Air-Conditioning Engineers (ASHRAE)</i>	19
2.6 Cálculo de los DGE por el método de Erbs.....	20
2.7 Cálculos de los DGE por el método de Hitchin.....	22
2.8 Aplicación de la RNA para la obtención del modelo predictivo.....	23
Capítulo 3 Análisis de los Resultados.....	25
3.1 Análisis de gráficos para la obtención de Tb.....	25
3.2 Análisis de gráficos de modelo de consumo energético por los métodos tradicionales.....	27
3.3 Modelos obtenidos mediante los métodos tradicionales.....	28
3.4 Análisis de los resultados obtenidos por la RNA.....	29
3.5 Comparación de todos los métodos utilizados.....	30
Conclusiones.....	32
Recomendaciones	33
Referencias Bibliográficas	34
Anexos	39
Anexo 1 Vista Aérea del Hotel Royalton Hicacos.....	39
Anexo 2 Código para evaluar en Matlab por el modelo obtenido por la ASHRAE.....	39
Anexo 3 Código para evaluar la RNA en Matlab.....	40

INTRODUCCIÓN

Al hablar de Medio Ambiente en la actualidad, no se pueden pasar por alto las condiciones de deterioro, contaminación, pérdida de la biodiversidad, deforestación por las que atraviesa; así como las fallas institucionales y los incumplimientos de normas ambientales (Lezama and Graizbord, 2010). Parte de estos problemas se deben al consumo de energía existente en edificaciones, de ahí la importancia que tiene una buena gestión de la energía en las instituciones.

La realización de cambios en el sistema organizacional, en los sistemas de planificación y control e incluso en los sistemas de tomas de decisiones, pueden elevar la eficiencia y la racionalización de la energía (Campos Avella et al., 2008).

Actualmente no existe un método definitivo para predecir el consumo energético en un hotel, estos pueden variar dependiendo de muchos factores como son: el movimiento de los ocupantes desde la habitación hacia las áreas exteriores, la presencia de cristales, la diversidad entre habitaciones, así como el amplio uso del sistema de aire acondicionado durante todo el día (Acosta et al., 2011).

El método de los Días Grados de temperatura ha demostrado ser eficiente para obtener modelos predictivos del consumo futuro de una edificación, éste método puede utilizar dos variables en dependencia del clima a analizar, éstas son: Días Grado de Enfriamiento (DGE) y Días Grado de Calentamiento (DGC).

DGE, es un parámetro climático importante utilizado en muchos campos (energía, arquitectura, agricultura, entomología, etc.) y basado en la idea de capturar las variaciones de la temperatura exterior (De Rosa et al., 2015). Así como la Temperatura Base (T_b) que sirve como criterio de comparación para este método, se puede definir como la temperatura a la cual las pérdidas y ganancias de calor son iguales (Bhatnagar et al., 2018).

Otro método utilizado son las Redes Neuronales Artificiales (RNA), estas son consideradas como una potente herramienta a la hora de evaluar problemas prácticos en diferentes ámbitos

(Ilbeigi et al., 2020), en contradicción a esto las RNA en la práctica se consideran de uso complejo, por lo que el personal que lo vaya a utilizar requiere de capacitación en el tema.

Problema de investigación:

El Hotel Royalton Hicacos no cuenta actualmente con un modelo de consumo energético que le permita actuar con inmediatez al gestor ante una variación no planificada del consumo energético.

Para la solución de este problema se plantea la siguiente **hipótesis:**

Realizando una comparación entre los métodos de regresión lineal más utilizados para la predicción del consumo energético y una RNA se puede obtener el modelo de consumo que más se ajuste a las condiciones del Hotel Royalton Hicacos.

Objetivo general:

Determinar el método más adecuado para la modelación del consumo energético del Hotel Royalton Hicacos comparando métodos estadísticos con una RNA.

Objetivos específicos:

1. Revisión bibliográfica del estado del arte sobre los Métodos de los Días Grados y las RNA aplicadas a la predicción del consumo energético en edificaciones.
2. Aplicación de herramienta de cálculo para los Días Grados de Enfriamiento y la Temperatura Base al Hotel Royalton Hicacos, usando datos climatológicos disponibles en el Centro Meteorológico de Varadero para el año 2016.
3. Aplicar RNA para la obtención de un modelo predictivo del consumo.
4. Analizar comparativamente los resultados de todos los modelos, realizar análisis comparativo entre ellos y definir el más factible.

CAPÍTULO 1 REVISIÓN BIBLIOGRÁFICA

En este capítulo se presenta lo más destacado de la bibliografía consultada y disponible sobre las principales temáticas a desarrollar.

1.1 Consumo energético en edificaciones

En las últimas cinco décadas la contaminación y degradación planetaria han aumentado en mayor medida que en los últimos cien años (Iruela et al., 2020); de ahí que el análisis del consumo energético en edificaciones sea una importante labor que permite buscar métodos para aumentar el correcto aprovechamiento de la energía, siendo éste una de las principales directrices de diversas organizaciones del mundo.

El régimen operacional, las características constructivas y las condiciones climatológicas de la región donde se encuentra, son los principales factores que influyen en el consumo energético de las edificaciones (Montero Laurencio et al., 2011). También se considera el flujo de personas como parámetro a tener en cuenta para la predicción del consumo energético (Zhou et al., 2020).

1.1.1 Consumo energético en instalaciones hoteleras

En un hotel los principales focos de consumo provienen de los sistemas de iluminación, los sistemas de bombeo de agua y fundamentalmente de los sistemas de climatización (Shao et al., 2020).

1.1.2 Consumo energético en edificaciones por climatización

Predecir el consumo energético por concepto de climatización en una instalación hotelera es una tarea compleja debido a que el uso de los equipos de enfriamiento no es constante (Zhou et al., 2020)

Varios autores coinciden en que el gasto energético en edificaciones por concepto de climatización ronda entre el 45 y el 65 por ciento del total de consumo. (Randazzo et al., 2020, Shao et al., 2020)

1.2 Impacto ambiental de la climatización en edificaciones

Más de un 10 % del consumo energético global y las emisiones antropogénicas de CO₂ están atribuidas a la climatización y calefacción de edificaciones. El calentamiento global trae como consecuencia el aumento de la demanda de energía para climatización, se estima que en los próximos años el consumo por este concepto sobrepase el 50 % del consumo total, con un incremento más de cuatro veces mayor en la demanda de países desarrollados (Booten et al., 2021).

1.3 Gestión energética

La gestión energética es la optimización del uso de la energía sin disminuir los niveles de prestaciones de la producción o los servicios, buscando que el uso de esta sea más racional y eficiente.

Existen evidencias de que una buena gestión energética trae consigo resultados positivos para el presupuesto destinado al consumo energético. Martín et al. (2010) realizaron un análisis a la empresa textil “Eddio Teijeiro” de Matanzas que permitió establecer medidas para reducir costos por gestión y por perfeccionamiento de dicha instalación, logrando reducir el consumo de energía y determinar las principales oportunidades de ahorro, elaborándose un programa mejor fundamentado de ahorro de energía a corto, mediano y largo plazo.

Una forma interesante de mejorar la eficiencia energética sería la sustitución de equipos anticuados por modernos y más eficientes, esto implica una inversión considerable pero que a mediano y largo plazo trae resultados significativos para la instalación, llegando a alcanzar un porcentaje de ahorro de entre un 10 % y un 30 % (Smith and Parmenter, 2016).

1.4 Gestión energética del turismo en Cuba

En Cuba con el Programa de Ahorro Energético se han logrado avances considerables con el ahorro de más de ocho millones de toneladas de petróleo desde 2005 logrando un impacto positivo en las esferas sociales, medio ambientales y económicas (Madrigal et

al., 2018); sin embargo la gestión energética no alcanzan el nivel deseado (Córdova et al., 2020, Zayas González, 2014).

Numerosos han sido los trabajos destinados a mejorar la gestión energética del turismo en Cuba; realizándose levantamiento de cargas, chequeos físicos de las instalaciones, determinando los principales índices de eficiencia energética, buscando modelos con un mejor coeficiente de regresión lineal; obteniéndose resultados positivos que justifican la búsqueda constante de nuevas y mejores formas de gestión. (Guedes García, 2018, Rodríguez et al., 2017)

1.5 Implementación de la norma ISO 50001

Cuba es firmante del Acuerdo de Paris y por tanto defensora del cumplimiento de la Agenda 2030, para lograr los objetivos de un desarrollo sostenible que no sea nocivo para el medio ambiente se hizo necesaria la implementación de la NC-ISO 50001: 2011, enfocándose principalmente en el mejoramiento de la eficiencia y en el seguimiento de indicadores mensuales para evaluar el rendimiento energético de las instalaciones (Díaz Torres et al., 2020). En 2019 se adoptó la actualización de la norma sustituyendo la anterior por la NC-ISO 50001: 2019.

Las ventajas de implementar un sistema gestión en la industria hotelera, son las facilidades que adoptan al velar por el cumplimiento de legislación además de reducir una importante emisión de gases de efecto invernadero, construyendo una mejor imagen del sector. De igual forma existe una reducción en costos de energía puesto que se tendrá mayor conocimiento de los flujos energéticos con lo que cuenta la empresa favoreciendo la responsabilidad energética-ambiental (Chaparro Muñoz, 2021).

1.6 Indicadores de desempeño energético

Los indicadores de desempeño energético (IDEn) son expresiones y valores usados para controlar y monitorear el uso de la energía, con el objetivo de reducir pérdidas energéticas en cualquier proceso productivo o prestación de servicios, permitiendo realizar ajustes en el plan de gestión encaminados a mantener elevados niveles de eficiencia energética; estos pueden expresarse como una simple medida, un cociente o un

modelo más complejo. Estos deben estar basados en información confiable, ser verificables, contar con una información específica con relación al proceso o sistema y el tiempo, deben poder medir cambios en una condición o situación a través del tiempo, permitir observar de cerca los resultados de iniciativas o acciones, ser instrumentos valiosos para determinar cómo se pueden alcanzar mejores resultados en proyectos de desarrollo (Ibarguen-Valverde et al., 2017).

En la actualidad en el sector hotelero existe la tendencia a utilizar el consumo de energía por unidad de alojamiento rentada, es decir, kilo Watt hora por Habitación Día Ocupada (kWh/HDO). González et al. (2017) plantean que estos índices se han establecido sobre una base empírica, y se manejan como parámetros fijos sin que medie un estudio minucioso en cada hotel, ni se haya validado la efectividad de estos índices de consumo para caracterizar la eficiencia energética; proponen además nuevos indicadores de desempeño energético dado que consideran los actuales como poco efectivos.

El coeficiente de determinación (R^2) se describe como el ajuste lineal que se establece entre dos variables (Rodríguez, 2005). Se considera un R^2 válido, cuando éste es mayor o igual al 75 % (Rodríguez et al., 2017, Velázquez et al., 2014).

1.7 Días Grados de enfriamiento

Los días grados de enfriamiento son la sumatoria de las diferencias de temperaturas entre la temperatura exterior y una temperatura de referencia (Krese et al., 2011), también conocida como temperatura base, la cual es un punto de balance térmico en el cual el sistema de enfriamiento no necesita funcionar para mantener condiciones confortables, el método de los DGE es uno de los más simples para estimar el uso energético de una instalación y provee un registro de predicción simple de cargas (Bhatnagar et al., 2018). La temperatura base puede cambiar con el tiempo y a su vez es diferente para cada edificación (Lindelöf and buildings, 2017).

De Rosa et al. (2015) plantea que la importancia del enfoque de los grados día radica en su capacidad para realizar análisis rápidos en varios campos y con diferentes propósitos.

En la aplicación para edificaciones, los propósitos principales se pueden resumir de la siguiente manera:

- Valoración energética de edificación existente en perspectiva de mantenimiento y rehabilitación.
- Predicciones de desempeño energético para nuevas construcciones en etapa preliminar de diseño.
- Los análisis sobre el estado real del consumo de energía del territorio tienen en cuenta las existencias de edificios existentes, las tipologías de sistemas de calefacción / refrigeración y la distribución demográfica.
- Construcción de análisis de escenarios en términos de previsión de consumo energético, también en perspectiva económica, con el objetivo de seleccionar las medidas políticas adecuadas que garanticen el mayor ahorro energético.

Más allá de predecir el consumo energético en instalaciones, el método de los DGE ha sido ampliamente utilizado por numerosos autores con diversos fines; Ukey and Rai (2021) lo utilizan para evaluar el impacto del calentamiento global en ocho de las mayores ciudades de la India, Atalla et al. (2018) lo utilizaron para crear una base de datos de 147 países desde 1948 hasta 2013 con varias temperaturas de referencia, esta base de datos se desarrolló principalmente para comparar la incidencia del clima en el uso de energía entre países.

Shin and Do (2016) demostraron que un análisis basado en la entalpía puede mejorar la eficacia en la predicción del consumo energético con respecto a un análisis basado en la temperatura exterior de bulbo seco, debido a que este último considera solamente el calor sensible, sin embargo para una predicción más exacta se debe considerar el calor latente en adición al calor sensible, como hace el método basado en la entalpía. Sin embargo éste análisis se realizó en un clima con predominio de bajas temperaturas y no se tiene constancia de éste tipo de trabajo realizado en un clima tropical como el de Cuba.

1.7.1 Temperatura base

Es posible aumentar la temperatura base disminuyendo las ganancias internas de calor dentro del edificio, debido a que ésta es sensible al mejoramiento de la eficiencia de los equipos dentro de la instalación y de la iluminación; también se puede lograr un aumento de la T_b mejorando la envoltura térmica del edificio, para disminuir las ganancias o pérdidas externas de calor. (Bhatnagar et al., 2018). Aumentar la T_b incide positivamente, debido a que al disminuir la diferencia entre temperatura exterior y temperatura de referencia, el tiempo de trabajo del sistema de refrigeración disminuye proporcionalmente.

La precisión del uso de los DGE se basa en la precisión de la temperatura base, que contiene información sobre el clima y el edificio en sí misma y se relaciona con el consumo de energía (Krese et al., 2012).

1.8 Redes Neuronales Artificiales aplicadas a la eficiencia energética

Las RNA son un paradigma matemático que imita el funcionamiento de las redes neuronales biológicas y son generalmente aplicadas en la solución de complejos problemas de diferentes campos. En las redes neuronales el problema se descompone en información elemental contenida dentro de cada neurona. Las redes no se programan previamente, éstas se obtienen de un proceso llamado entrenamiento en el cual aprenden a partir de muestras de entrada y salida (D'Amico et al., 2019).

Las RNA son el método más popular para la optimización basada en modelos sustitutos, con el uso de energía, el sobrecalentamiento, las emisiones de carbono y el costo total como los resultados de predicción más comunes; éstas aprenden la relación entre las entradas de datos y las variables definidas (controladas y no controladas) mediante el análisis de los datos almacenados previamente (García Kerdan and Morillón Gálvez, 2020).

Las RNA son una potente herramienta para la evaluación de problemas prácticos multifacéticos. Uno de los beneficios más importantes de las RNA es la capacidad de estimar la función no lineal continua con precisión predefinida (Ilbeigi et al., 2020).

1.8.1 Perceptrón Multicapa (PMC)

Rodríguez (2017) afirma que el PMC es capaz de actuar como un aproximador universal de funciones: una red *backpropagation* conteniendo al menos una capa oculta con suficientes unidades no lineales puede aproximar cualquier tipo de función o relación continua entre un grupo de variables de entrada y salida. Esta propiedad convierte a las redes perceptrón multicapa en herramientas de propósito general, flexibles y no lineales. Un PMC está compuesto por una capa de entrada, una capa de salida y una o más capas ocultas, aunque se ha demostrado que para la mayoría de problemas basta con una sola capa oculta.

La red neuronal PMC tiene buenas capacidades de modelado no lineal y se utiliza ampliamente en predicción de series de tiempo en campos como la geología, meteorología, y las ciencias de la energía (Jin et al., 2021).

Kim et al. (2020) realizaron un estudio donde compararon métodos tradicionales para la predicción del consumo energético en edificaciones, con una RNA basada en el algoritmo PMC, obteniendo resultados más precisos con la RNA. Sin embargo San Miguel Salas (2016) en un estudio realizado para la predicción del consumo eléctrico para un hospital a través de una red neuronal PMC, no obtuvo los resultados esperados, según el propio autor esto se debe a la falta de alguna variable de entrada extra, y también a la gran variación de temperatura en las estaciones de primavera y otoño.

CAPÍTULO 2 MATERIALES Y MÉTODOS

En este capítulo se realizará una descripción del hotel objeto de estudio y se describirán los métodos a emplear para la obtención del modelo predictivo.

2.1 Caracterización del hotel

El Hotel Royalton Hicacos Resort & SPA perteneciente al grupo Cubanacán, hoteles mixtos, brinda servicios de categoría cinco estrellas y se localiza en un entorno de reserva natural, distinguiéndose por las características de su diseño arquitectónico al estilo constructivo de Varadero en los años 1920-1940.

Abarca una superficie de 7,4 hectáreas donde se destaca como elemento más importante de las áreas exteriores los espejos de agua dulce, rodeados de piedras artificiales y vegetación dando apariencia de lagos.

Con un total de 404 habitaciones, entre ellas figuran una suite presidencial, dos Royal Suites, 401 habitaciones junior suites de las cuales cuatro habitaciones para minusválidos, cuatro habitaciones de acompañantes de minusválidos, 74 habitaciones comunicadas y 319 habitaciones típicas.

El hotel tiene cinco restaurantes distinguidos por una excitante variedad de opciones para desayunos, almuerzos y cenas, además de cinco bares donde nuestros huéspedes pueden disfrutar de una amplia oferta de bebidas nacionales e internacionales, un bistró y una heladería.

2.2 Presentación de los datos estadísticos de consumo, de ocupación y climatológicos del hotel.

Los datos estadísticos sobre el consumo y ocupación del hotel fueron obtenidos a través del gestor energético de dicha instalación y las variables climatológicas se obtuvieron a través del Centro Meteorológico de Varadero para el año 2016.

Para los métodos clásicos fueron utilizados el consumo eléctrico mensual, los HDO correspondientes a cada mes y la temperatura de bulbo seco (TBS) media mensual, dichos valores son mostrados en la tabla 2.1.

Tabla 2.1 Consumo eléctrico mensual, HDO y TBS media mensual del año 2016 del hotel Royalton Hicacos.

<i>Meses</i>	<i>Días</i>	<i>Consumo Eléctrico (kWh)</i>	<i>HDO</i>	<i>TBS Media (°C)</i>
Enero	31	438 302,0	11 922	23,0
Febrero	29	373 208,0	11 156	23,4
Marzo	31	480 562,0	12 030	25,2
Abril	30	535 256,0	11 670	26,2
Mayo	31	576 891,0	12 058	27,4
Junio	30	643 514,0	11 474	28,4
Julio	31	679 279,0	11 806	29,1
Agosto	31	706 133,0	11 153	29,4
Septiembre	30	657 401,0	10 834	28,8
Octubre	31	636 481,0	11 353	27,3
Noviembre	30	502 661,0	11 138	24,8
Diciembre	31	520 863,0	10 625	26,0

Para la RNA fueron utilizados los datos de consumo eléctrico, HDO y la TBS diarios, se presenta en la tabla 2.2 una muestra de los datos procesados.

Tabla 2.2 Consumo, TBS y HDO diarios para el hotel Royalton Hicacos

<i>Año 2016</i>	<i>Consumo de electricidad (kW-h)</i>	<i>TBS media (°C)</i>	<i>HDO</i>
01/01/2016	19 503	28,8	392
02/01/2016	19 013	28,5	384
03/01/2016	17 863	30,2	377

04/01/2016	17 440	26,7	369
05/01/2016	15 512	22,6	353
06/01/2016	14 268	23,8	368
07/01/2016	12 825	26,4	386

2.3 Cálculo de HDO-DGE como indicador de desempeño energético

Para el cálculo del IDEn HDO-DGE, es necesario calcular los DGE, una vez calculados se multiplican por los HDO correspondientes dando como resultado dicho IDEn.

2.4 Determinación de la temperatura base.

Para obtener la T_b se utilizó una hoja de cálculo Excel desarrollada por Villalonga et al. (2021b), donde se insertan los valores de consumo eléctrico y los HDO correspondientes a cada mes y se prueban valores de T_b en un rango que varía desde 14-24 °C, dando un polinomio de segundo grado ($y = \alpha'x^2 + \alpha x + \beta$) en un gráfico de dispersión, luego se selecciona el valor de T_b donde el valor de α' sea más cercano a cero y sea positivo. (Krese et al., 2012)

2.5 Cálculo de los DGE por el método de la *American Society of Heating, Refrigerating and Air-Conditioning Engineers (ASHRAE)*.

La ASHRAE propone un método basado solamente en datos de temperatura media mensuales y consiste en la sumatoria de los valores positivos de las diferencias de temperaturas para cada mes (Indraganti and Boussaa, 2017, Krese et al., 2012).

$$DGE = \sum_1^n (T - T_b)^+ . \quad (2,1)$$

Donde:

n = número de días del mes analizado

T= temperatura media diaria

Tb=temperatura base

El signo positivo indica que solo deben tomarse los valores positivos (los negativos se utilizan para los Días Grados de Calentamiento).

En la tabla 2.3 se muestran los resultados de los DGE y los HDO-DGE para el método de la ASHRAE.

Tabla 2.3 Indicadores obtenidos por el método ASHRAE para $T_b = 22^{\circ}\text{C}$

<i>Meses</i>	<i>Días</i>	<i>Consumo Eléctrico (kWh)</i>	<i>HDO</i>	<i>TBS Media ($^{\circ}\text{C}$)</i>	<i>DGE</i>	<i>HDO-DGE</i>
Enero	31	438 302,0	11 922,0	23,0	42,4	505 492,8
Febrero	28	373 208,0	11 156,0	23,4	42,2	470 783,2
Marzo	31	480 562,0	12 030,0	25,2	101,1	1 215 631,5
Abril	30	535 256,0	11 670,0	26,2	127,1	1 482 673,5
Mayo	31	576 891,0	12 058,0	27,4	168,1	2 026 346,9
Junio	30	643 514,0	11 474,0	28,4	191,3	2 194 402,5
Julio	31	679 279,0	11 806,0	29,1	221,0	2 609 126,0
Agosto	31	706 133,0	11 153,0	29,4	229,5	2 559 613,5
Septiembre	30	657 401,0	10 834,0	28,8	203,8	2 207 427,5
Octubre	31	636 481,0	11 353,0	27,3	163,3	1 853 944,9
Noviembre	30	502 661,0	11 138,0	24,8	85,3	949 514,5
Diciembre	31	520 863,0	10 625,0	26,0	123,8	1 314 843,8

2.6 Cálculo de los DGE por el método de Erbs.

El método presentado por Erbs et al. (1983) utiliza la desviación estándar de las temperaturas medias diarias alrededor de la media mensual para estimar la variabilidad de temperatura media diaria dentro del mes y calcula la desviación estándar de la temperatura media mensual alrededor del año. Se formula como se muestra en la ecuación 2,2.

$$DGE = \sigma_m * (Dm)^{1,5} * \left[\frac{h}{2} + \frac{\text{Ln}(e^{-ah} + e^{ah})}{2a} \right] \quad (2,2)$$

Donde:

Dm = número de días del mes

σ_m = desviación estándar de las temperaturas medias mensuales de todos los meses del año

$$h = \frac{(Ta - Tb)}{\sigma_m (Dm)^{0,5}} \quad (2,3)$$

$$a = 1,698(Dm)^{0,5} \quad (2,4)$$

$$\sigma_m = 3,54 - 0,029Ta + 0,00644\sigma_y \quad (2,5)$$

Donde:

σ_m = desviación estándar de la temperaturas medias mensuales de todos los meses del año

En la tabla 2.4 se muestran los resultados obtenidos para los DGE y los HDO-DGE para el método de Erbs.

Tabla 2.4 Indicadores obtenidos por el método de Erbs para Tb = 22,5°C

<i>Meses</i>	<i>Días</i>	<i>Consumo Eléctrico (kWh)</i>	<i>HDO</i>	<i>TBS Media (°C)</i>	<i>DGE</i>	<i>HDO-DGE</i>
Enero	31	438 302,0	11 922,0	23,0	27,1	323 188,0

Febrero	28	373 208,0	11 156,0	23,4	32,6	363 736,1
Marzo	31	480 562,0	12 030,0	25,2	84,4	1 015 826,1
Abril	30	535 256,0	11 670,0	26,2	112,3	1 310 658,2
Mayo	31	576 891,0	12 058,0	27,4	152,6	1 840 130,1
Junio	30	643 514,0	11 474,0	28,4	176,3	2 022 448,1
Julio	31	679 279,0	11 806,0	29,1	205,5	2 426 168,4
Agosto	31	706 133,0	11 153,0	29,4	214,0	2 386 752,9
Septiembre	30	657 401,0	10 834,0	28,8	188,8	2 044 987,3
Octubre	31	636 481,0	11 353,0	27,3	147,9	1 678 764,0
Noviembre	30	502 661,0	11 138,0	24,8	71,7	798 790,1
Diciembre	31	520 863,0	10 625,0	26,0	108,6	1 154 044,4

2.7 Cálculos de los DGE por el método de Hitchin.

Hitchin (1983) propone un método basado en la temperatura media mensual y en las desviaciones estándar a lo largo del mes. Se formula como:

$$DGE = \frac{Dm * (Tb - Tm)}{1 - e^{-k(Tb - Tm)}} \quad (2,6)$$

Donde:

Tm = Temperatura promedio mensual.

La variable k es la constante de la localidad y se calcula como:

$$k = \frac{2,5}{\sigma_t} \quad (2,7)$$

Donde:

σ_t = desviación estándar de las temperaturas del mes.

En la tabla 2.5 se muestran los resultados obtenidos para los DGE y los HDO-DGE para el método de Hitchin.

Tabla 2.5 Indicadores obtenidos por el método de Hitchin para $T_b = 21,5^{\circ}\text{C}$

<i>Meses</i>	<i>Días</i>	<i>Consumo Eléctrico (kWh)</i>	<i>HDO</i>	<i>TBS Media ($^{\circ}\text{C}$)</i>	<i>DGE</i>	<i>HDO-DGE</i>
Enero	31	438 302,0	11 922,0	23,0	55,0	655 383,3
Febrero	28	373 208,0	11 156,0	23,4	54,6	608 646,5
Marzo	31	480 562,0	12 030,0	25,2	115,1	1 384 113,6
Abril	30	535 256,0	11 670,0	26,2	142,1	1 657 731,7
Mayo	31	576 891,0	12 058,0	27,4	183,6	2 213 252,3
Junio	30	643 514,0	11 474,0	28,4	206,3	2 366 512,5
Julio	31	679 279,0	11 806,0	29,1	236,5	2 792 119,0
Agosto	31	706 133,0	11 153,0	29,4	245,0	2 732 485,1
Septiembre	30	657 401,0	10 834,0	28,8	218,8	2 369 937,5
Octubre	31	636 481,0	11 353,0	27,3	178,8	2 029 928,9
Noviembre	30	502 661,0	11 138,0	24,8	100,3	1 116 632,3
Diciembre	31	520 863,0	10 625,0	26,0	139,3	1 479 537,8

2.8 Aplicación de la RNA para la obtención del modelo predictivo.

La red neuronal fue utilizada sobre el software Matlab 2013, se tomaron datos como el consumo energético diario, los HDO y la temperatura media durante el año 2016 para el entrenamiento de la red, una vez entrenada la red devuelve como valor de salida una predicción del consumo eléctrico de la instalación. Es necesario para un buen desempeño de la red, emplear una cantidad suficiente de datos, en este caso se utilizarán 366 datos de entrada, se implementó una búsqueda aleatoria para determinar el número adecuado de neuronas en la capa. Para implementar la estrategia de búsqueda se dividió primeramente el conjunto de datos en tres subconjuntos: entrenamiento validación y prueba. A continuación, se ejecutó un ciclo en el cual, en cada iteración, se generó una red neuronal con un número aleatorio de neuronas en la capa oculta y se entrenó con el primer subconjunto de datos utilizando una función de entrenamiento también escogida de

manera aleatoria. Al finalizar el entrenamiento, se evaluó el modelo con el segundo subconjunto de datos y si los resultados obtenidos superaban a los de todas las iteraciones previas se actualizaba el mejor modelo global con el modelo de la iteración en curso. Este proceso se repitió hasta cumplir con un criterio de parada previamente definido. Al finalizar el ciclo, el mejor modelo global se evaluó con el tercer subconjunto de datos para determinar su capacidad de predicción. La arquitectura de la RNA se muestra en la figura 2.1. (Villalonga et al., 2021a)

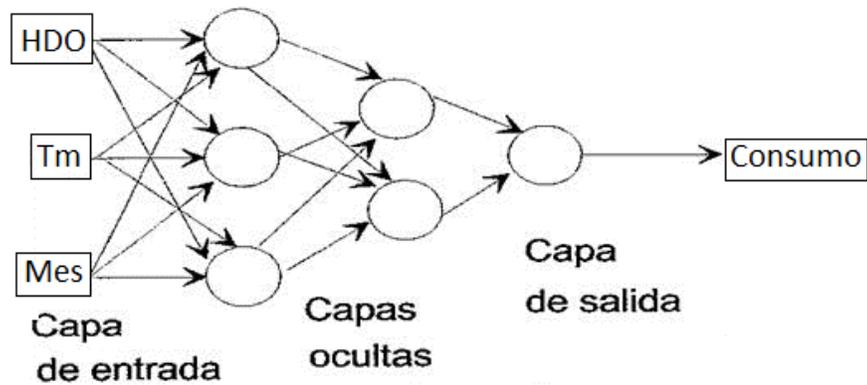


Figura 2.1 Arquitectura de la Red Neuronal Artificial Utilizada

CAPÍTULO 3 ANÁLISIS DE LOS RESULTADOS

En este capítulo se realizará un análisis de los resultados obtenidos a través de los distintos métodos aplicados.

3.1 Análisis de gráficos para la obtención de T_b .

En la figura 3.1 se puede observar el gráfico de dispersión obtenido por el método ASHRAE con el que se obtiene 22 °C como T_b por ser el valor con el que el coeficiente que acompaña la variable de segundo orden se hace más cercano a cero, el procedimiento es similar para el método de Erbs que se representa en la figura 3.2, obteniendo 22,5 °C como T_b y para el método de Hitchin representado en la figura 3.3 el valor de T_b es 21,5 °C.

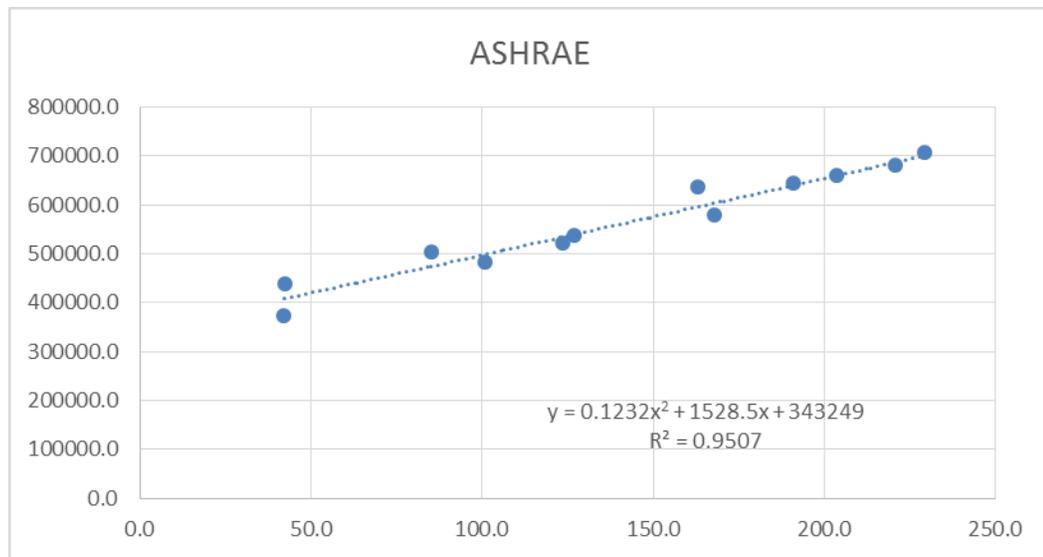


Figura 3.1 Gráfico de dispersión Consumo vs DGE, ecuación polinómica resultante y R^2 por el método de la ASHRAE.

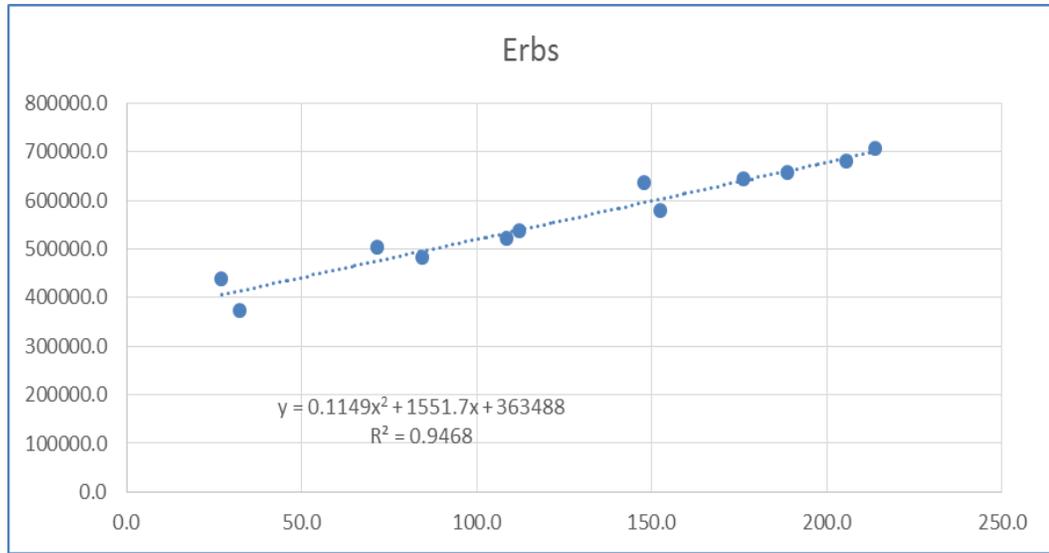


Figura 3.2 Gráfico de dispersión Consumo vs DGE, ecuación polinómica resultante y R^2 por el método de Erbs.

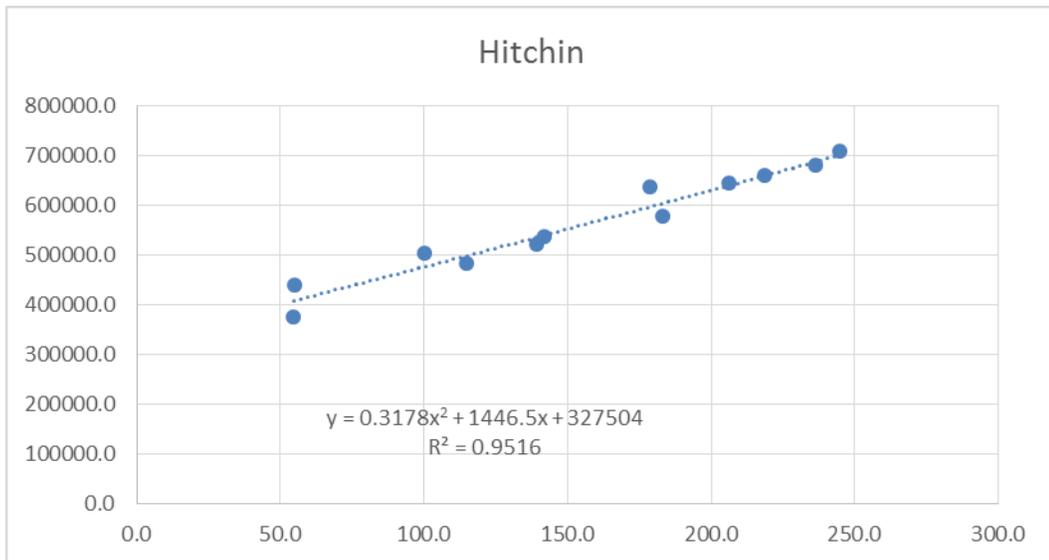


Figura 3.3 Gráfico de dispersión Consumo vs DGE, ecuación polinómica resultante y R^2 por el método de Hitchin.

Como se puede observar existe una elevado coeficiente de determinación entre el consumo energético y el indicador DGE confirmando que os valores de Tb obtenidos son permisibles

3.2 Análisis de gráficos de modelo de consumo energético por los métodos tradicionales.

En la figura 3.4 se puede observar el modelo de consumo obtenido por el método de la ASHRAE, siendo este una función lineal ($y = ax + b$) donde y es el consumo energético, x es el indicador HDO-DGE y b es el consumo mínimo asociado a la climatización, lo mismo ocurre para el modelo obtenido por el método de Erbs y por el método de Hitchin, representados en las figuras 3.5 y 3.6 respectivamente.

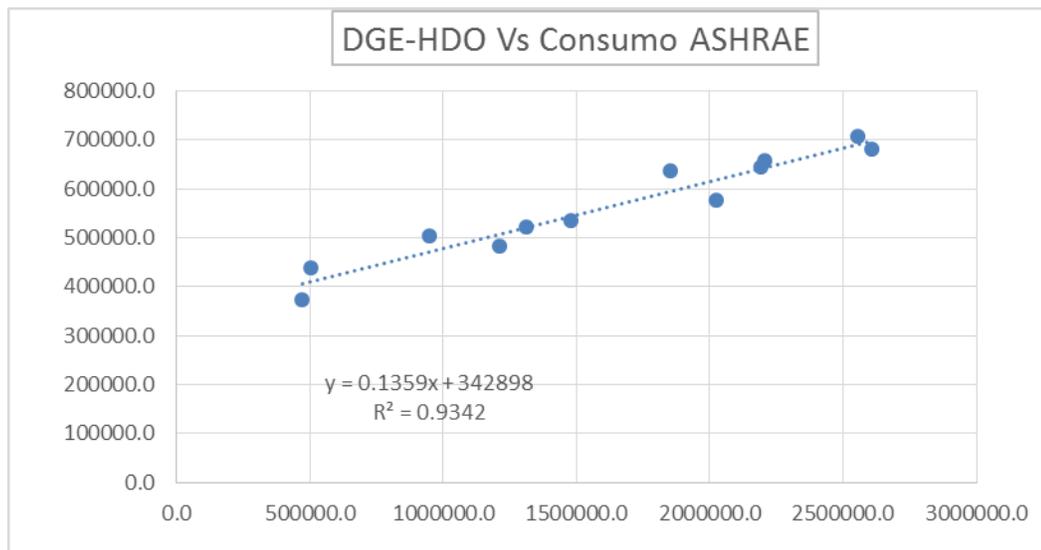


Figura 3.4 Gráfico de dispersión Consumo vs DGE-HDO y R^2 por el método de la ASHRAE.

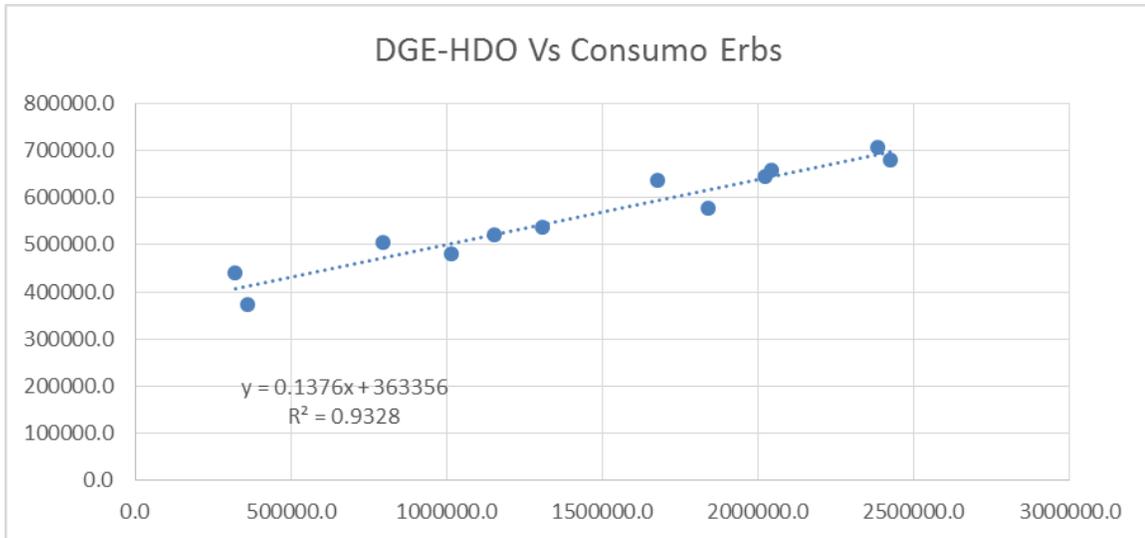


Figura 3.5 Gráfico de dispersión Consumo vs DGE-HDO y R^2 por el método de Erbs.

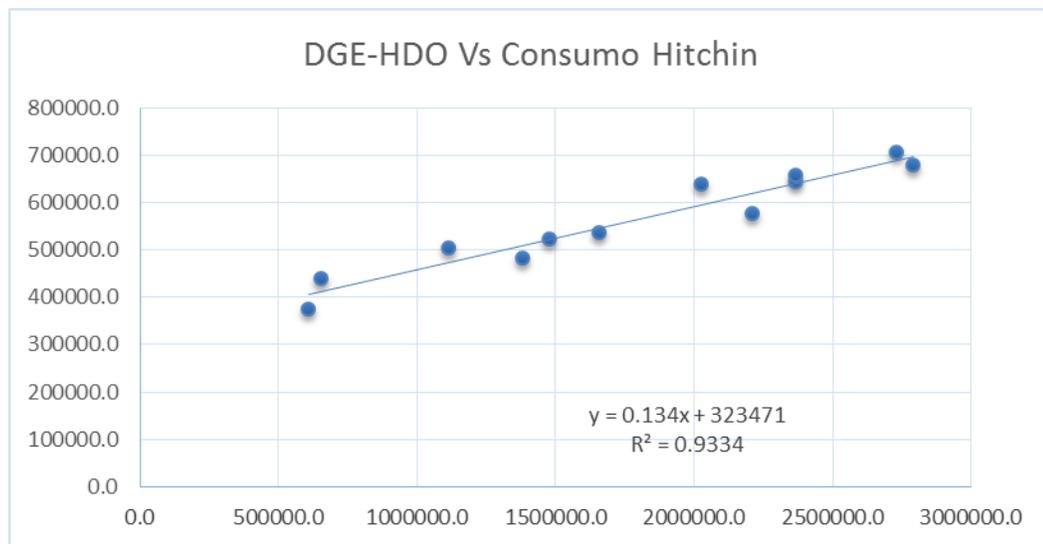


Figura 3.6 Gráfico de dispersión Consumo vs DGE-HDO y R^2 por el método de Hitchin.

En general se obtuvieron buenos resultados para los tres métodos dando un R^2 mayor a 0.93 demostrando que existe una buena correlación.

3.3 Modelos obtenidos mediante los métodos tradicionales.

En la figura 3.7 se muestran los modelos obtenidos.

Tabla 3.1 Resumen de modelos obtenidos por los métodos clásicos

<i>Métodos</i>	<i>Modelo</i>	R^2
ASRHAE	$y = 0,1359x + 342898$	0,934
Erbs	$y = 0,1376x + 363356$	0,933
Hitchin	$y = 0,134x + 323471$	0,933

Donde:

y = Predicción de consumo energético

x = HDO·DGE

3.4 Análisis de los resultados obtenidos por la RNA.

El modelo obtenido mediante las RNA no alcanzó el resultado esperado, sin embargo se puede observar en la figura 3.7 que la mayoría de las predicciones entran en el rango de las bandas de error al 10 %, el R^2 tuvo un valor de 0,825 siendo inferior al de los modelos obtenidos por los métodos clásicos, con un error absoluto experimental del 6 %, éste resultado puede ser consecuencia de escasos datos de entrada, o bien podría deberse a un entrenamiento deficiente de la red.

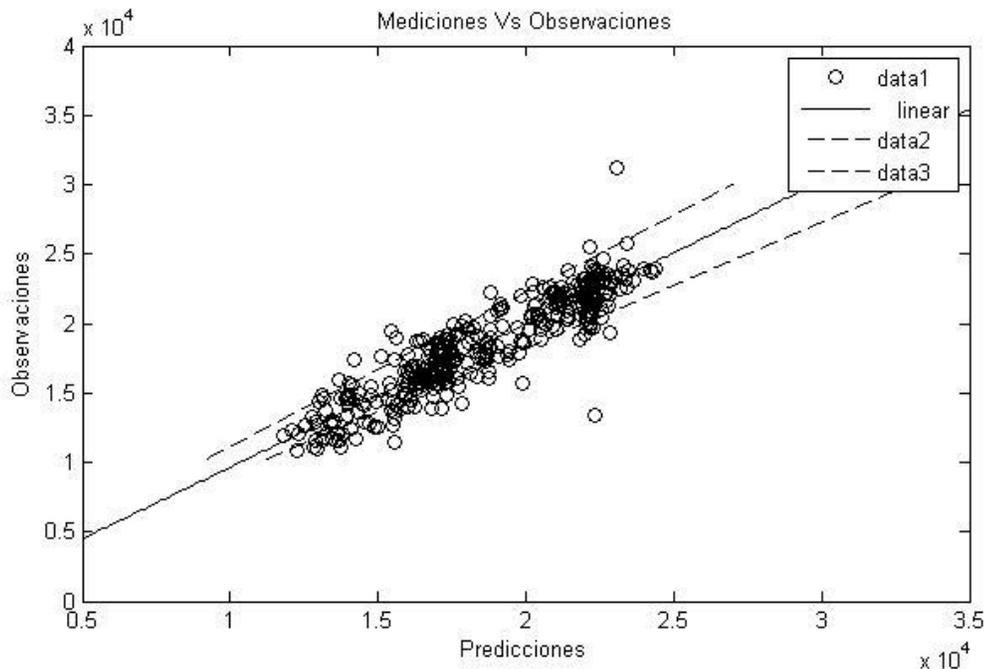


Figura 3.7 Gráfico de dispersión mediciones contra observaciones obtenido mediante la RNA

En el gráfico de residuales mostrado en la figura 3.8 se puede observar que existe una varianza aceptable para los valores obtenidos, exceptuando dos valores que distan de los valores reales

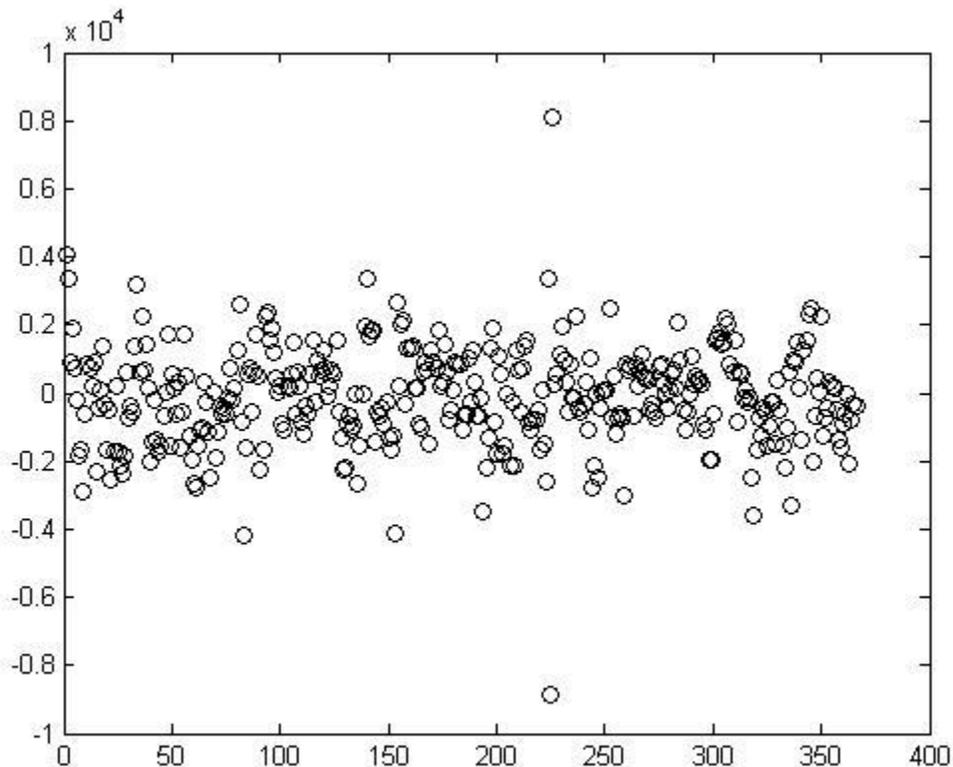


Figura 3.8 Gráfico de residuales obtenido mediante la RNA

3.5 Comparación de todos los métodos utilizados.

En la tabla 3.2 se muestra un resumen de los cuatro métodos utilizados, seleccionando de ellos el que mejor R^2 presenta.

Tabla 3.2 Comparación entre los métodos de la ASHRAE, Erbs, Hitchin y la RNA para el hotel Royalton Hicacos.

<i>Comparación entre todos los métodos</i>		
<i>Métodos</i>	<i>R2</i>	<i>Mejor</i>
ASHRAE	0,934	X
Erbs	0,933	
Hitchin	0,933	
RNA	0,825	

CONCLUSIONES

1. Se confirmó que los indicadores seleccionados para la gestión energética del hotel son efectivos, dado que estos presentaron una buena correlación con los modelos obtenidos.
2. Se empleó la herramienta de cálculo para la obtención de modelos capaces de predecir con precisión el consumo energético del hotel Royalton Hicacos.
3. Se determinó que el modelo predictivo que más se ajusta a los parámetros climatológicos del hotel Royalton Hicacos, es el obtenido mediante el método de la ASHRAE.

RECOMENDACIONES

1. Se recomienda el uso del modelo obtenido por el método de la ASHRAE por parte del gestor energético del hotel.
2. Se recomienda realizar este estudio para otros hoteles del polo que no cuenten con un modelo predictivo que se ajuste a sus parámetros climatológicos.
3. Se recomienda ampliar la base de datos de los parámetros climatológicos para facilitar futuros estudios sobre el tema.

REFERENCIAS BIBLIOGRÁFICAS

- ACOSTA, A. V., GONZÁLEZ, A. I., ZAMARREÑO, J. M. & ÁLVAREZ, V. 2011. Modelo para la Predicción Energética de una Instalación Hotelera. *Revista Iberoamericana de Automática e Informática Industrial RIAI*, 8, 309-322.
- ATALLA, T., GUALDI, S. & LANZA, A. 2018. A global degree days database for energy-related applications. *Energy*, 143, 1048-1055.
- BHATNAGAR, M., MATHUR, J. & GARG, V. 2018. Determining base temperature for heating and cooling degree-days for India. *Journal of Building Engineering*, 18, 270-280.
- BOOTEN, C., RAO, P., RAPP, V., JACKSON, R. & PRASHER, R. 2021. Theoretical Minimum Thermal Load in Buildings. *Joule*, 5, 24-46.
- CAMPOS AVELLA, J. C., PRÍAS CAICEDO, O. F., QUISPE OQUEÑA, E. C., VIDAL MEDINA, J. R. & LORA FIGUEROA, E. D. 2008. El MGIE, un modelo de gestión energética para el sector productivo nacional.
- CHAPARRO MUÑOZ, H. D. 2021. Propuesta para la implementación de la NTC-ISO 50001 en la fábrica Taller de Cerveza.
- CÓRDOVA, A. S., CORZO, A. V. A. & NODA, A. L. A. J. R. C. D. I. 2020. Sistema de monitorización de consumo de energía eléctrica en el Hotel Nacional de Cuba. 11, 22-32.
- D'AMICO, A., CIULLA, G., TRAVERSO, M., LO BRANO, V. & PALUMBO, E. 2019. Artificial Neural Networks to assess energy and environmental performance of buildings: An Italian case study. *Journal of Cleaner Production*, 239, 117993.
- DE ROSA, M., BIANCO, V., SCARPA, F. & TAGLIAFICO, L. A. 2015. Historical trends and current state of heating and cooling degree days in Italy. *Energy Conversion and Management*, 90, 323-335.

- DÍAZ TORRES, Y., ALVARES GUERRA PLASENCIA, M. A., VALDÉS LÓPEZ, A., PIMENTEL CABRERA, L., CASTILLO BARRIOS, O. & HAESLONCK, D. 2020. Implementation of the energy management standard NC 50001 (up to energetic-planning phase) in a telecommunication company %J *Ingeniería Energética*. 41.
- ERBS, D. G., BECKMAN, W. A. & KLEIN, S. A. Estimation of degree-days and ambient temperature bin data from monthly-average temperatures. 1983.
- GARCÍA Kerdan, I. & MORILLÓN GÁLVEZ, D. 2020. Artificial neural network structure optimisation for accurately prediction of exergy, comfort and life cycle cost performance of a low energy building. *Applied Energy*, 280, 115862.
- GONZÁLEZ, A. M., NORDELO, A. B., YANES, J. P. M., BEDREGAL, H. R. V. & TOCA, C. E. S. J. I. E. 2017. Nuevos índices de consumo energético para hoteles tropicales; New energy indicators for tropical hotels. 38, 198-207.
- GUEDES GARCÍA, D. 2018. *Acciones para mejorar la gestión energética en el Hotel Los Pinos*. Universidad Central" Marta Abreu" de Las Villas, Facultad de Ingeniería
- HITCHIN, E. R. 1983. Estimating monthly degree-days. 4, 159 - 162.
- IBARGUEN-VALVERDE, J. L., ANGULO-LÓPEZ, J. E., RODRÍGUEZ-SALCEDO, J. & PRÍAS-CAICEDO, O. J. D. 2017. Indicadores de desempeño energético: Una ruta hacia la sustentabilidad. "Caso de estudio una industria torrefactora de café". 84, 184-191.
- ILBEIGI, M., GHOMEISHI, M. & DEHGHANBANADAKI, A. 2020. Prediction and optimization of energy consumption in an office building using artificial neural network and a genetic algorithm. *Sustainable Cities and Society*, 61, 102325.
- INDRAGANTI, M. & BOUSSAA, D. 2017. A method to estimate the heating and cooling degree-days for different climatic zones of Saudi Arabia. 38, 327-350.

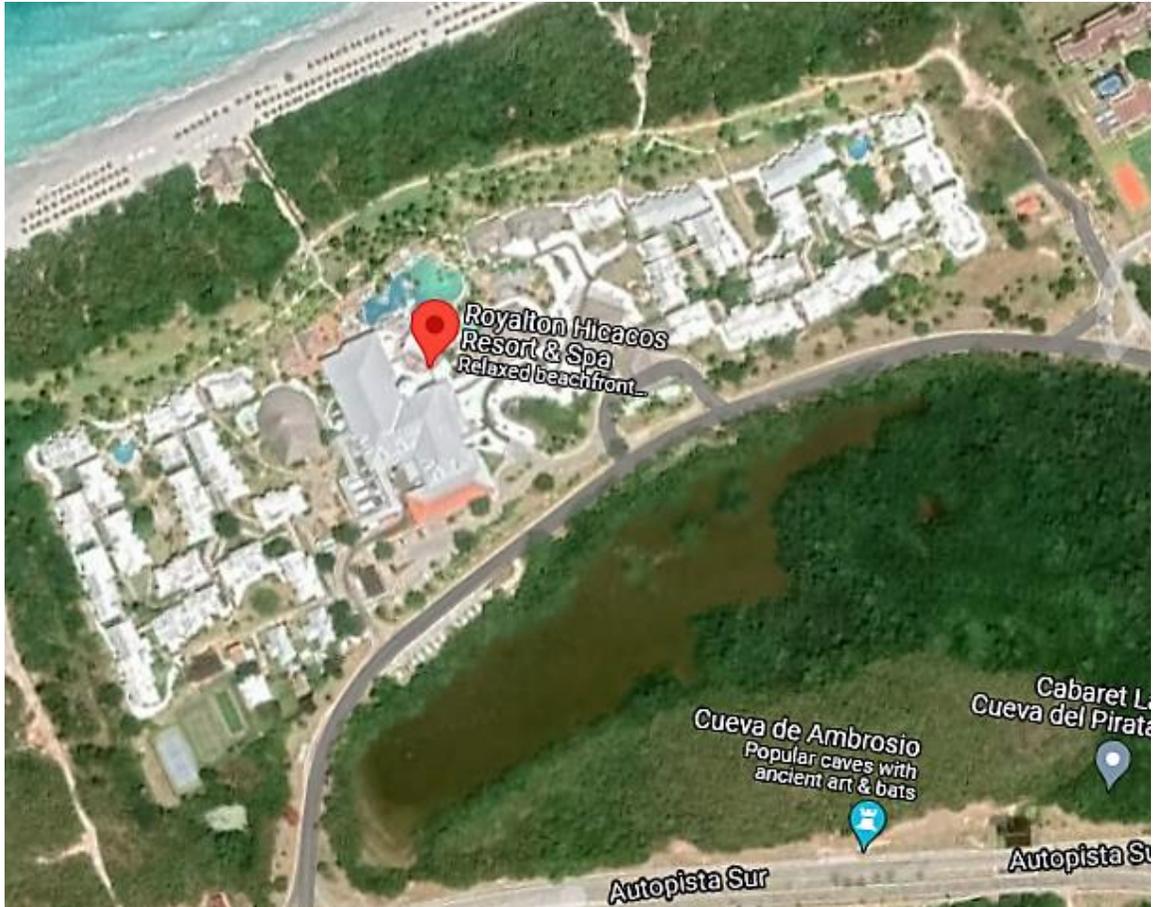
- IRUELA, J. R. S., RUIZ, L. G. B., PEGALAJAR, M. C. & CAPEL, M. I. 2020. A parallel solution with GPU technology to predict energy consumption in spatially distributed buildings using evolutionary optimization and artificial neural networks. *Energy Conversion and Management*, 207, 112535.
- JIN, X., GUO, J., SHEN, Y., LIU, X. & ZHAO, C. 2021. Application of singular spectrum analysis and multilayer perceptron in the mid-long-term polar motion prediction. *Advances in Space Research*, 68, 3562-3573.
- KIM, M. K., KIM, Y.-S. & SREBRIC, J. 2020. Predictions of electricity consumption in a campus building using occupant rates and weather elements with sensitivity analysis: Artificial neural network vs. linear regression. *Sustainable Cities and Society*, 62, 102385.
- KRESE, G., PREK, M. & BUTALA, V. 2011. Incorporation of latent loads into the cooling degree days concept. *Energy and Buildings*, 43, 1757-1764.
- KRESE, G., PREK, M. & BUTALA, V. 2012. Analysis of Building Electric Energy Consumption Data Using an Improved Cooling Degree Day Method. *Strojnicki Vestnik*, 58, 107-114.
- LINDELÖF, D. J. E. & BUILDINGS 2017. Bayesian estimation of a building's base temperature for the calculation of heating degree-days. 134, 154-161.
- MADRIGAL, J. A., CABELLO ERAS, J. J., HERNÁNDEZ HERRERA, H., SOUSA SANTOS, V. & BALBIS MOREJÓN, M. J. I. R. C. D. I. 2018. Planificación energética para el ahorro de fueloil en una lavandería industrial. 26, 86-96.
- MARTÍN, J. L. L., GARCÍA, J. L. & DOMÍNGUEZ, E. T. E. T. 2010. ANÁLISIS PARA EL PERFECCIONAMIENTO DE LA EFICIENCIA ENERGÉTICA EN LA EMPRESA TEXTIL EDDIO TEJEIRO "BELLOTEX". ANALYSIS FOR THE IMPROVEMENT OF THE POWER ENERGETIC FFICIENCY IN THE TEXTILE COMPANY EDDIO TEJEIRO" BELLOTEX".

- MONTERO LAURENCIO, R., HECHAVARRÍA HERNÁNDEZ, J. & BORROTO NORDELO, A. 2011. Carga térmica y consumo energético en edificación turística con climatización centralizada a flujo variable %J Universidad, Ciencia y Tecnología. 15, 196-205.
- RANDAZZO, T., DE CIAN, E. & MISTRY, M. N. 2020. Air conditioning and electricity expenditure: The role of climate in temperate countries. *Economic Modelling*, 90, 273-287.
- RODRÍGUEZ, E. M. J. A. J. Y. E. E. 2005. Errores frecuentes en la interpretación del coeficiente de determinación lineal. 315-331.
- RODRÍGUEZ, L. R., INSUASTI, J. A. P., PEÑA, W. Y., SIERRA, C. O., ARROYAVE, C. P. S., SOTO, C. A. P., VISPO, N. F. S., PINCHAO, J. M. H., TORRES, R. D. G. & LARA, G. R. J. R. T.-E. 2017. Método de cálculo del índice de eficiencia energética de los hoteles. 30.
- RODRÍGUEZ, R. P. 2017. Redes Neuronales Artificiales. Conceptos básicos y algunas aplicaciones en Energía. July.
- SAN MIGUEL SALAS, J. 2016. *Desarrollo con MATLAB de una red neuronal para estimar la demanda de energía eléctrica*. info:eu-repo/semantics/masterThesis.
- SHAO, M., WANG, X., BU, Z., CHEN, X. & WANG, Y. 2020. Prediction of energy consumption in hotel buildings via support vector machines. *Sustainable Cities and Society*, 57, 102128.
- SHIN, M. & DO, S. L. 2016. Prediction of cooling energy use in buildings using an enthalpy-based cooling degree days method in a hot and humid climate. *Energy and Buildings*, 110, 57-70.
- SMITH, C. B. & PARMENTER, K. E. 2016. Chapter 3 - General Principles of Energy Management. In: SMITH, C. B. & PARMENTER, K. E. (eds.) *Energy Management Principles (Second Edition)*. Oxford: Elsevier.

- UKEY, R. & RAI, A. C. 2021. Impact of global warming on heating and cooling degree days in major Indian cities. *Energy and Buildings*, 244, 111050.
- VELÁZQUEZ, L. F., MORALES, T. C. & INFANTE, L. A. J. I. E. 2014. Aplicacion de gestion total eficiente de energia en el Centro Internacional de Salud" La Pradera". 35, 112-121.
- VILLALONGA, G. R., MORALES, O. F. G. & HERNÁNDEZ, Y. J. C. 2021a. Aplicación de Inteligencia Artificial en la obtención de modelo de comportamiento de consumo eléctrico en un hotel en Varadero *III Conferencia Científica Internacional de la Universidad de Cienfuegos*.
- VILLALONGA, G. R., MORALES, O. G. & MEDINA, Y. C. 2021b. HERRAMIENTA DE CÁLCULO PARA LA OBTENCIÓN DE TEMPERATURA BASE EN INSTALACIONES HOTELERAS. *X Convencioón Científica Internacional: Universidad Integrada e Innovadora*
- ZAYAS GONZÁLEZ, A. 2014. *Gestión total eficiente de la energía eléctrica*. Universidad Central" Marta Abreu" de Las Villas.
- ZHOU, C., FANG, Z., XU, X., ZHANG, X., DING, Y., JIANG, X. & JI, Y. 2020. Using long short-term memory networks to predict energy consumption of air-conditioning systems. *Sustainable Cities and Society*, 55, 102000.

ANEXOS

Anexo 1 Vista Aérea del Hotel Royalton Hicacos



Anexo 1 Vista Satelital del Hotel Royalton Hicacos

Anexo 2 Código para evaluar en Matlab por el modelo obtenido por la ASHRAE

```
% Evaluando valores de consumo en el modelo de consumo  
obtenido  
%por ASHRAE  
clear all;  
clc;  
load('dat2015');  
x=dat2015(:,1).*dat2015(:,2);  
  
mod=zeros(12,1);  
for fil=1:12;  
y=0.1359*x(fil,:)+342898;
```

```

mod(fil,:)=y;
end
plot (dat2015(:,3) , mod, 'ko');
hold 'on'
title('Mediciones Vs Predicciones');
xlabel ('Mediciones');
hold 'on'
Xxx=300000:800000;
Yyy=1.1*Xxx;
plot(Yyy,Xxx, 'k--')
hold on;
    Yyy=0.9*Xxx;
plot(Yyy,Xxx, 'k--')
hold 'on'
    ylabel ('Predicciones');
    set(gca, 'FontSize',18, 'fontWeight', 'bold')
    set(findall(gcf, 'type', 'text'), 'FontSize',18, 'fontWeight', 'bold')
    ppp=polyfit(mod,dat2015(:,3), 1);
    disp(num2str(ppp))
    cd=corrcoef(mod,dat2015(:,3));
    cd(1,2);
    rR=cd(1,2);
    rdD=rR^2;
    disp(num2str(rdD))
    Error=(sum(abs(((dat2015(:,3)-mod)./dat2015(:,3))*100)))/12

```

Anexo 3 Código para evaluar la RNA en Matlab

```

clear all;
clc;
load('datdia2015');
load('my_model');
months = zeros(1,365); % Generating
aproximate data for months
months(1:30) = 1;
months(31:60) = 2;
months(61:90) = 3;
months(91:120) = 4;
months(121:150) = 5;
months(151:180) = 6;
months(181:210) = 7;
months(211:240) = 8;
months(241:270) = 9;
months(271:300) = 10;
months(301:330) = 11;
months(331:365) = 12;

in = cat(1, datdia2015, months);
In=in(2:4,:);
out=in(1,:);
test=best_net(In);

% Generating approximate data for
months
oute =sum(out(:,1:30));

```

```

outf =sum(out(:,31:60));
outm =sum(out(:,61:90));
outab =sum(out(:,91:120));
outmy = sum(out(:,121:150));
outj = sum(out(:,151:180));
outjl = sum(out(:,181:210));
outa = sum(out(:,211:240));
outs = sum(out(:,241:270));
outo = sum(out(:,271:300));
outn = sum(out(:,301:330));
outd = sum(out(:,331:365));
anno=[oute;outf;outm;outab;outmy;outj;outjl;outa;outs;outo;outn;outd];

teste =sum(test(:,1:30));
testf =sum(test(:,31:60));
testm =sum(test(:,61:90));
testab =sum(test(:,91:120));
testmy = sum(test(:,121:150));
testj = sum(test(:,151:180));
testjl = sum(test(:,181:210));
testa = sum(test(:,211:240));
tests = sum(test(:,241:270));
testo = sum(test(:,271:300));
testn = sum(test(:,301:330));
testd = sum(test(:,331:365));
annot=[teste;testf;testm;testab;testmy;testj;testjl;testa;tests;testo;testn;testd];

plot (anno , annot, 'ko');
hold 'on'
title('Mediciones Vs Predicciones');
xlabel ('Mediciones');
hold 'on'
Xxx=300000:800000;
Yyy=1.1*Xxx;
plot(Yyy,Xxx,'k--')
hold on;
    Yyym=0.9*Xxx;
plot(Yyym,Xxx,'k--')
hold 'on'
    ylabel ('Predicciones');
    set(gca, 'FontSize',18, 'fontWeight', 'bold')
    set(findall(gcf, 'type', 'text'), 'FontSize',18, 'fontWeight', 'bold')
    ppp=polyfit(annot,anno, 1);
    disp(num2str(ppp))
    cd=corrcoef(annot,anno);
    cd(1,2);
    rR=cd(1,2);
    rdD=rR^2;
    disp(num2str(rdD))

```