



**Universidad de Cienfuegos
"Carlos Rafael Rodríguez"
Facultad de Ingeniería Mecánica.**



Trabajo de Diploma en Opción al Título de Ingeniero Mecánico

Título: Pronóstico a corto plazo del consumo pico para la gestión energética de la Universidad de Cienfuegos.

Autor: Duniel Yglesias Zurita

Tutores: Dr. C. Julio R. Gómez Sarduy

M.Sc. Jesús A. Peña Acción

Cienfuegos 2017

Dedicatoria

A mis padres y mi hermano por darme toda la confianza y el amor para seguir adelante y formarme profesionalmente.

A mis tutores por su dedicación, esmero, paciencia y comprensión.

A todos mis profesores que me ayudaron y me apoyaron.

Agradecimientos

A mis padres que me dieron la vida y en virtud a su dedicación me esmero cada día y a mi hermano que siempre estuvo a mi lado

Al colectivo de profesores que en estos cinco años han formado parte de mi preparación profesional.

A mis tutores Julio y Jesús por aceptarme como diplomante, por la enseñanza cooperación y disponibilidad para evacuar mis dudas y por su extraordinaria calidad humana.

Al resto de mis familiares y amigos que siempre han estado a mi lado porque su colaboración fue un factor imprescindible.

A todos les estoy eternamente agradecido, ya que sin la unión de todos estos factores no hubiera podido concluir esta etapa, con la seguridad que nos los defraudaré y que todos los consejos dados los pondré en práctica en el momento requerido.

RESUMEN

La predicción del consumo en el horario de máxima demanda contribuye a mejorar la gestión energética. En este trabajo se presentan dos modelos de pronóstico del consumo pico y del consumo total diario para la sede principal de la Universidad de Cienfuegos. Los modelos desarrollados son de regresión lineal múltiple y otro modelo no lineal, basado en una red neuronal artificial (RNA). Se procesaron los datos provenientes de las lecturas de los metros contadores y se trabajó la información para clasificar los días de acuerdo a la intensidad laboral en días de poca actividad y días de actividad normal. Los resultados obtenidos muestran buena correspondencia entre las salidas del modelo y las mediciones reales, lo que demuestra la calidad, evaluada a partir de medidas de precisión como el coeficiente de correlación R^2 y el MAPE. Se demuestra que el modelo no lineal es superior y se puede emplear en el sistema de gestión energética de la Universidad para estimar la estructura de consumo del pico con anticipación.

Palabras claves: pronóstico de consumo, modelo de consumo, redes neuronales, consumo pico.

ABSTRACT

Predicting the peak load contributes to the enhancement of energy management. This thesis presents some models to forecast the peak load of a campus of the university of Cienfuegos, aiming to choose the best one for generalization. The developed models were linear and non-linear, respectively, linear regression and Artificial Neural Networks. The data used was obtained by energy meters. These data was power demand, and calendar data, which were treated and normalized. The results obtained reports a good coincidence between the predicted and real peak load for all developed models, whit high correlation coefficient R^2 and Mean Absolute Percent Error (MAPE), however the accuracy is better for nonlinear models, mainly for Adaptive Neural Networks Inference Systems

Key words: prediction of consumption, consumption model, artificial neutral network, peak load.

Índice

Introducción	7
Capítulo I. Generalidades.	10
1.1-Usos de la energía y sus implicaciones sociales y ambientales	10
1.2-Necesidad de sistemas de gestión de la energía y modelos de pronósticos	13
1.3-Gestión en Universidades. Indicadores Implementados	15
1.3.1 Gestión en Universidades del Mundo	17
1.3.2 Gestión en la Universidad de Cienfuegos.....	18
1.4-La energía en la universidad de Cienfuegos.....	20
1.5-Estado del arte sobre modelos de pronóstico de consumo	23
1.6-Conclusiones parciales	27
Capítulo II. Fundamentos metodológicos	28
2.1. Aspectos generales.....	28
2.2 Modelos lineales.....	29
2.3. Modelos no lineales. Redes neuronales artificiales (RNA)	31
Capítulo III. Resultados.....	40
3.1 Adquisición y procesamiento de datos	40
3.2 Modelo lineal.....	42
3.3 Modelo con RNA.....	47
3.3.2. Diseño de la red.....	48
3.4 Comparación entre modelos.....	52
3.5 Conclusiones parciales	53
CONCLUSIONES	54
RECOMENDACIONES	56
Bibliografía.....	57
ANEXOS	62

Introducción

Las instituciones destinadas a la educación y los servicios se consideran parte del Sector Público, que está conformado por las ramas del Comercio y los Servicios.

Este sector consume alrededor del 3% de la energía que se consume en el país y la tendencia es a crecer debido a factores como crecimiento del turismo, recuperación de la actividad industrial, recuperación de hospitales e instituciones de salud, etc. En el caso específico del consumo de energía en las instituciones del MES y del MINED se incrementa debido a la introducción sistemática de nuevo equipamiento, como computadoras, televisores, sistemas de climatización, etc.

El consumo de energía eléctrica en instituciones dedicadas a la educación y los servicios se diferencia por su magnitud del consumo de las empresas industriales, las que tienen un consumo considerablemente mayor. En general, las instituciones educacionales y de servicios, desde el punto de vista de la eficiencia energética, se catalogan como edificios públicos o conjunto de edificios públicos.

El consumo de energía en edificios públicos tiene un peso alto en la estructura de consumo mundial, aunque es inferior al consumo industrial.

Para el caso de las universidades e instituciones educacionales, es necesario el estudio y determinación de indicadores confiables en el uso de la energía eléctrica como uno de los pasos fundamentales en el establecimiento de sistemas de monitoreo y control de la energía.

La posibilidad de pronosticar el consumo futuro de energía eléctrica es una premisa para el buen funcionamiento de los sistemas de gestión.

En la Universidad de Cienfuegos se ha generado gran parte del arsenal tecnológico para el uso eficiente de la energía, teniendo adscrito el Centro de Estudios de Energía y Medio Ambiente, centro líder en esta temática a nivel nacional. También en esta Universidad se ha trabajado desde hace varios años en el pronóstico de la energía consumida mensualmente para su incorporación en el sistema de gestión energética. Actualmente, a pesar de las medidas tomadas, la estructura de consumo del pico

supera el 16% en la mayoría de los días, incumpliendo con lo establecido por la ONURE para el consumo en este horario. Esta situación constituye el problema científico que motiva esta tesis y que se plantea a continuación

Problema científico:

No existe un modelo de pronóstico confiable para estimar el consumo de energía en el horario pico con tiempo suficiente para tomar medidas que eviten el exceso.

Hipótesis:

El desarrollo de un modelo para el pronóstico a corto plazo del consumo de energía pico de la Universidad de Cienfuegos posibilitará una mejor gestión energética facilitando la toma de decisiones para evitar excesos de consumo en este horario.

Objetivo general:

Desarrollar un modelo para predecir con 24 horas de antelación el consumo de energía en el horario pico para la sede central de la Universidad de Cienfuegos empleando herramientas estadísticas y de computación suave que correlacionen variables energéticas y temporales

Objetivos específicos:

1-Estudiar el estado del arte sobre la gestión energética en las universidades y las herramientas de pronóstico energético aplicables a instituciones de educación superior.

2-Adquirir y procesar la información histórica existente a partir de lecturas de metros contadores instalados.

3-Desarrollar modelos de pronóstico empleando herramientas estadísticas y redes neuronales y comparar la calidad de los mismos.

La tesis se concibe estructurada en tres capítulos:

Capítulo I. Generalidades. Revisión bibliográfica acerca de la gestión energética en centros universitarios y la necesidad de modelos de pronóstico de consumo. Estado del arte sobre los métodos de pronóstico de carga y su aplicación a campus universitarios.

Capítulo II. Fundamentos metodológicos. Trata sobre la fundamentación teórica de los métodos de regresión lineal y sobre modelos no lineales como las redes neuronales artificiales.

Capítulo III. Resultados. Selección de las variables a considerar, procesamiento de la información disponible. Ajuste lineal de los datos y diseño de las redes neuronales para el desarrollo de un modelo no lineal para el pronóstico. Validación del modelo a partir de diferentes estadísticos y su aplicación.

Capítulo I. Generalidades.

1.1-Uso de la energía y sus implicaciones sociales y ambientales

La energía que utiliza el mundo actualmente proviene del sol, parte de ella ha sido almacenada en forma de combustibles fósiles y otra se puede utilizar directa o indirectamente como la energía eólica, solar térmica, solar fotovoltaica, biomasa, energía de las olas e hidráulica.

Desde la primera revolución industrial, el consumo energético global ha sido creciente de manera sostenida. En 1890 el consumo de combustibles fósiles se igualó al de la biomasa empleada en el sector residencial y en la industria. Fue en el siglo XX donde se manifiesta un rápido crecimiento del consumo de combustibles fósiles, con tasas de crecimiento del 2% anuales a partir del 1980.

Primeramente, el carbón era quien tenía la primacía, siendo el principal suministro de energía durante los siglos XVIII y XIX. Sin embargo, con la aparición del automóvil, el desarrollo de la aviación y al generalizarse el uso de la electricidad para disímiles aplicaciones, el petróleo pasó a ser el combustible dominante durante el siglo XX. Este incremento del uso del petróleo se debió fundamentalmente a un descenso en los precios del barril entre 1920 a 1973. A partir de este momento se produce la llamada crisis del petróleo, caracterizada por un incremento de su precio desde 5 USD/barril hasta 45 USD/barril y se produce una contracción en su consumo, tomando de nuevo el carbón la primacía junto a la energía nuclear para la generación de electricidad. Ya en esta época se comienza a tomar conciencia de la necesidad de incrementar la eficiencia en el ahorro y uso racional de la energía.

Los fabricantes de automóviles mejoraron sus diseños y lograron autos con menores índices de consumo. En cuanto al uso final de la electricidad, se empezaron a producir equipos con menores pérdidas, con el empleo de mejores materiales, diseños optimizados y mejoras tecnológicas en el proceso de fabricación. En lugar del costo, la eficiencia pasó a ser el objetivo principal de diseñadores y fabricantes. Las regulaciones comenzaron a impulsar estos productos en el mercado y los países fueron adoptando

medidas que se convirtieron en el marco regulatorio de muchos de ellos para el uso eficiente de la energía.

Actualmente, el sector energético está en un punto de transición y frente a cambios crecientes. A nivel internacional, se predice un crecimiento de la demanda de energía de un tercio sobre los años 2015 a 2040, principalmente en los países que no pertenecen a la OECD (Organization for Economic Cooperation and Development) (IEA, 2015).

El crecimiento de la demanda energética global se debe fundamentalmente a: crecimiento de la población mundial desde 7 000 millones actualmente, hasta 9 000 millones en el 2040, un crecimiento proyectado de la economía mundial del 150% en igual periodo de tiempo, así como a las tendencias en el crecimiento de la urbanización y de la movilidad (WEC, 2016). Al mismo tiempo, el sector energético necesita adaptarse a riesgos emergentes, tales como variabilidad de los patrones de clima y nuevas estructuras de mercado y marcos para integrar nuevas tecnologías, todo en un contexto de incremento en la volatilidad de los precios.

Estas tendencias, a la par con los compromisos de disminuir el impacto ambiental del sector energético, actualmente responsable del 35 al 40 % de las emisiones de gases de efecto invernadero a nivel global, constituyen tensiones para el sector energético. Todo este crecimiento del consumo energético ha traído consecuencias ambientales, económicas, técnicas y sociales, fundamentalmente por el modelo predominante de producción, distribución y uso de la energía basado en combustibles fósiles (petróleo, gas y carbón) como se muestra en la Figura 1.1.

La inequidad en el acceso a la energía es un grave problema global. Esta desigualdad es tan marcada que mientras el consumo anual de energía eléctrica por habitante en el África subsahariana es de 482 KWh, en los Estados Unidos es de 13000 KWh.

La situación actual de la energía en el mundo se caracteriza por ser no homogénea, ya que más del 70% del gasto energético mundial ocurre en los países industrializados, está creciendo continuamente, sobre todo en países en desarrollo de Asia y América Latina, aún persiste una gran parte de la población mundial sin acceso a una fuente fiable de electricidad, las mayores emisiones de gases de efecto invernadero son

producidas por países desarrollados como EEUU, que con apenas el 4.5% de la población mundial, produce casi el 25% de las emisiones globales de CO2.

Es necesario otro modelo alternativo, similar al definido por el Consejo Mundial de la Energía (WEC) que se basa en tres dimensiones: seguridad energética, equidad energética y sostenibilidad ambiental (WEC, 2016). Este modelo se fundamenta en la necesidad de un nuevo paradigma con énfasis en la búsqueda de la sostenibilidad energética. Para esto es fundamental una mayor participación de las fuentes renovables de energía, pero acompañadas de un cambio en la estructura de generación y una reducción del consumo.

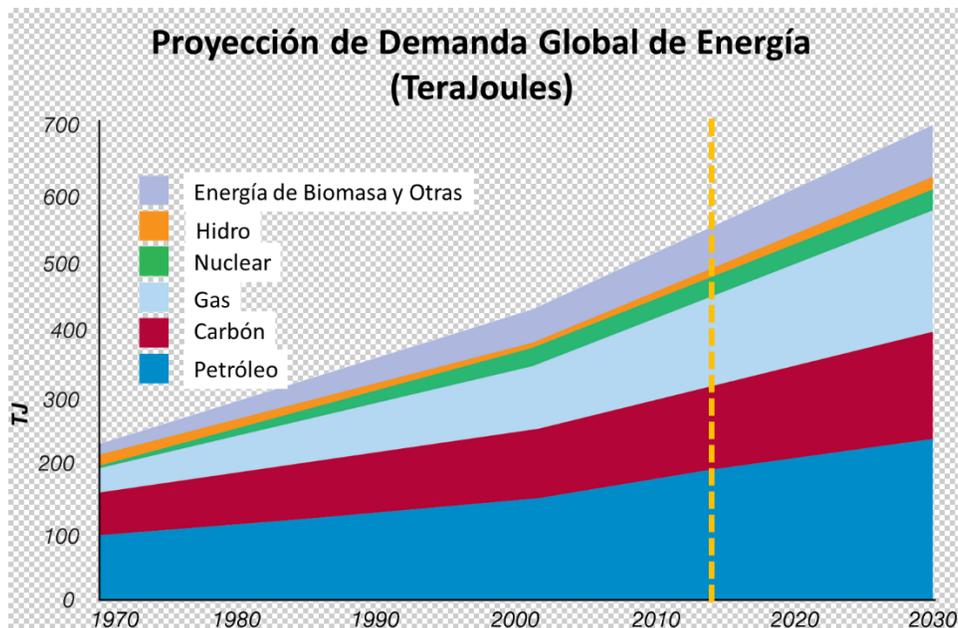


Fig. 1.1. Proyección de la demanda global de energía.

La reducción del consumo energético es posible a través de un incremento en la eficiencia energética, lo cual constituye una de las acciones claves para los líderes mundiales en la actualidad.

Un programa para el uso eficiente de la energía se basa en la reducción de la cantidad de energía eléctrica y de combustibles fósiles que se emplean en todas las actividades de la sociedad, conservando la calidad y el acceso a bienes y servicios (González A. M., 2017).

1.2-Necesidad de sistemas de gestión de la energía y modelos de pronósticos

La eficiencia energética puede incrementarse siguiendo dos caminos: uno basado en mejoras tecnológicas, haciendo inversiones en equipos y sistemas más eficientes y otro basado en una mejor administración de la energía con pocas inversiones, para lo cual se requiere implementar un sistema de gestión energética adecuado.

Para la implementación en Cuba de políticas orientadas a incrementar la eficiencia energética, es necesario comprender en primer lugar que es un país con escasos recursos energéticos (petróleo, gas, carbón mineral o recursos hídricos). Además, la volatilidad de los precios de la energía son manifestaciones de la grave crisis política y económica en que está sumido el mundo de hoy y que repercute negativamente en la economía cubana y en el desarrollo de todos los sectores productivos y de servicios. Por estas razones, es de suma importancia el uso racional y eficiente de la energía, sobre todo a partir de una mejor gestión.

Un sistema de gestión constituye una estructura documentada que define la política, los objetivos y las responsabilidades de la organización, y establece los procedimientos y procesos de planificación, control, aseguramiento y mejoramiento. Un sistema de gestión energética también define las responsabilidades, los procedimientos, el entrenamiento, la verificación interna, las acciones correctivas y preventivas, y el mejoramiento.

De manera similar a los sistemas de gestión de la calidad y medio ambiente, establecidos en las normas internacionales ISO 9000 y 14000, la aplicación de un sistema de gestión energética, requiere de una guía, una norma que estandarice lo que hay que hacer para implementarlo, mantenerlo y mejorarlo continuamente, con la menor inversión de recursos, en el menor tiempo y la mayor efectividad.

En este sentido, la Norma ISO 50001 (ONN, 2011) establece un marco internacional para la gestión de todos los aspectos relacionados con la energía, incluidos su uso y adquisición por parte de las instalaciones industriales y comerciales, o de las compañías en su totalidad.

Las organizaciones pueden decidir integrar la Norma ISO 50001 con las de otros sistemas de gestión, tales como las de gestión de calidad, medio ambiente, salud y seguridad ocupacional, responsabilidad social u otras.

Para la ISO, la gestión energética es uno de los cinco campos principales dignos del desarrollo y la promoción que ofrecen las normas internacionales y se espera que esta norma de sistemas de gestión energética logre un mayor incremento de la eficiencia energética a largo plazo (de un 20% o más en las instalaciones industriales). No obstante, dado que la norma está basada en una amplia capacidad de aplicación en todos los sectores económicos nacionales, se espera que afecte hasta un 60% de la demanda energética mundial.

En diciembre del 2011 Cuba realiza la adopción de la ISO 50001 como norma nacional con la referencia NC-ISO 50001:2011. Posteriormente, en el 2014, sale a la luz la norma internacional ISO 50006 que constituye una guía para el establecimiento de la línea base energética y de los indicadores de desempeño energético (EnPI) para una organización (ISO, 2014). Ahora bien, se debe tener en cuenta que ya las empresas de algunos países desarrollados, además de los requerimientos de la ISO 50001, están mirando hacia una certificación de Desempeño Energético Superior (SEP) y necesitan, entre otras cosas Indicadores de Desempeño Energético Superior (SEnPIs) para seguir mejorando su desempeño energético (McKane, 2012), (US DOE EERE).

Los modelos de consumo que se establecen como línea base energética, y que permiten establecer EnPIs para los sistemas de gestión, también se utilizan, entre otras cosas, para planificar consumos de energía en función de planes productivos u otras variables. En este sentido constituyen modelos de pronósticos y si se emplean con este fin permiten a la empresa o entidad de servicios anticiparse a los sobreconsumos y tomar medidas para evitarlos.

Pronosticar el consumo o la demanda de electricidad puede proveer de información aplicable para la evaluación del desempeño energético dentro de la facilidad y para propósitos de mejora de la eficiencia en el uso de la energía particularmente cuando se consideran sistemas de distribución a media y baja tensión. Este tipo de pronóstico también es ventajoso desde el punto de vista económico. De hecho, puede aportar

información valiosa para detectar tempranamente oportunidades y riesgos asociados al uso de la energía. La tendencia en el mercado energético mundial con paradigmas basados en conceptos de redes inteligentes, requiere mejores políticas de gestión de la carga y pronósticos más confiables, tanto para usuarios individuales como a escala del sistema de potencia. La posibilidad de insertar fuentes renovables de energía en el sector empresarial y de servicios necesita modelos que permitan coordinar las incertidumbres propias de estas fuentes con la demanda de la carga. Todos estos aspectos anteriormente señalados pueden ser considerados también en mayor o menor magnitud si el ambiente de trabajo es una institución de educación superior con su campus universitario.

Precisamente en las universidades existen patrones de consumo determinados por el equipamiento existente, la cantidad de estudiantes, el número de estudiantes internos y de ellos cuántos son becados extranjeros. Otras variables que influyen en el consumo son de carácter temporal e incluyen épocas de exámenes, vacaciones, feriados y otras actividades. Sin embargo, los estudios de este tipo realizados hasta el momento en Cuba no se enfocan a pronosticar con tiempo suficiente la demanda, sino más bien a la búsqueda de indicadores de desempeño energético.

1.3-Gestión en Universidades. Indicadores Implementados

La gestión universitaria está asociada al concepto general de gestión o gerencia estratégica. La gerencia estratégica se define como la formulación, ejecución y evaluación de acciones que permitirán que una organización logre sus objetivos. A partir de esta definición, la formulación de estrategias supone una secuencia que incluye la identificación de las debilidades y fortalezas internas de la organización; la determinación de amenazas y oportunidades externas; el establecimiento de misiones; la fijación de objetivos; el desarrollo y análisis de estrategias alternativas, y la decisión de escoger las más convenientes (David, 2005).

Hoy día, las instituciones universitarias son cada vez más conscientes de su realidad competitiva y sobre todo de la importancia de mantenerse vigentes y actualizadas en el nuevo mundo globalizado. De la misma manera son más responsables de su misión en

la sociedad, deseando lograr la permanencia a través de la calidad formativa medida a través de sus diferentes frentes. Las anteriores situaciones, llevan, como en cualquier contexto empresarial, a la racionalización en los gastos de operación con respecto a los ingresos que se logran por diferentes conceptos (Greco, 2010)

Los indicadores pueden estar referidos a tres tipos de elementos dentro de una organización: insumos, procesos y resultados. Los primeros tienen que ver con elementos no elaborados que ingresan al sistema, tales como recursos humanos financieros y físicos que ingresan a programas, actividades o servicios de una universidad.

Los procesos se relacionan con las formas y los métodos que se utilizan para impartir programas, actividades y servicios. Los indicadores de procesos informan acerca de las formas en que los insumos se convierten en productos o resultados. Entre otros, son indicadores de procesos las evaluaciones de rendimiento estudiantil, las tecnologías utilizadas, las mediciones del cumplimiento docente, las evaluaciones de calidad de la enseñanza, etcétera. Los resultados hacen referencia a productos, efectos o impactos que salen del sistema. Son indicadores de resultado: el número o proporción de los egresados, el número de títulos otorgados en un año determinado o los impactos que se producen en la comunidad como consecuencia del desarrollo de programa o actividades de una universidad (Abadie, 2010).

De acuerdo con lo visto anteriormente, se puede incluir un número relativamente grande de elementos a medir, de acuerdo con el tamaño de las instituciones y la caracterización de procesos. No obstante, en el marco de una sociedad del conocimiento, donde existe proliferación de información, ya no es pertinente poseer mucha cantidad de registros de datos, sino más bien que la información sea seleccionada cuidadosamente, se encuentre organizada y procesada. El interés debe estar centrado en la selección y tratamiento de la información más que en la acumulación de la misma. En estos casos, también es relevante concentrarse y priorizar en los asuntos misionales de las organizaciones (Granados, 2004), (David, 2005), (Escuadero, 2001).

1.3.1 Gestión en Universidades del Mundo

El interés en el uso de indicadores ha sido evidente no sólo en los países de Europa Occidental y especialmente en Gran Bretaña, Holanda, Francia, Suecia, Alemania y España, dentro de las características particulares de cada uno de estos sistemas de educación superior, sino también en los Estados Unidos, desde comienzos de la década de los años ochenta. En este último país, la falta de un organismo central de dirección, como es el caso de los ministerios de educación de otros países con una tradición administrativa centralizadora, constituye una limitación muy difícil de superar, debido a la gran magnitud del sistema de educación superior, integrado por cerca de 3.500 instituciones, así como la variedad en sus características y sus propósitos. Sin embargo, las experiencias realizadas recientemente en algunas universidades tanto en el uso de indicadores como de la gerencia de calidad total, permiten proyectar optimismo acerca del uso de estos enfoques en la evaluación de la calidad de la educación superior.

El proyecto Universitario en Colombia ha aceptado el reto de ser cada vez más competitivo y productivo en lo que tiene que ver con el cumplimiento de sus funciones misionales. Por lo anterior, cada vez son más las instituciones que vienen incorporando sistemas de información universitarios que propenden por procesos de toma de decisiones basados en criterios y análisis objetivos de las diferentes situaciones Institucionales. Han desarrollado análisis detallados de viabilidad de la oferta educativa, y lógicamente el acercamiento al asunto de los indicadores de gestión en el mismo contexto.

Desde su estructura de estadísticas e indicadores universitarios incluye en sus diferentes reportes elementos referentes a la investigación, extensión, análisis de la situación del entorno que se clasifica dentro de contexto, estadísticas de la Universidad (datos de admitidos, matriculados, graduados, recursos humanos vinculados a la Universidad), medios de comunicación, salud universitaria, universidad virtual, entre otros.

Las universidades españolas cuentan con gran cantidad de información, sin embargo no en todos los casos cumple con las expectativas de calidad y organización. Algunos

de los inconvenientes encontrados se relacionan con diversidad de archivos construidos con diferentes criterios, falta de confiabilidad de la información, bases de datos incompletas y desiguales, diferencias entre los criterios de organización de información e inexistencia en la utilización de indicadores comunes en las Instituciones de Educación Superior (IES) (Escuadero, 2001).

Otro ejemplo es el que se produce en el contexto específico de las universidades venezolanas, donde el proceso de gestión abarca la dirección, jefatura y/o coordinación que incluyen la formulación, ejecución y evaluación de estrategias, acciones, operaciones y tareas, tanto en forma individual como en grupo, orientadas a la realización de procesos y al logro de los objetivos y metas de unidades o programas académicos en diferentes niveles de la organización.

1.3.2 Gestión en la Universidad de Cienfuegos

Precedentemente se han desarrollado algunas investigaciones, como parte de los estudios relacionados con la implementación de la Tecnología de Gestión Total Eficiente de la Energía en la Universidad de Cienfuegos, en las que se han definido indicadores para la gestión de energía y agua, que se centran en elementos tradicionales de la gestión universitaria: gasto de energía/superficie, gasto de energía/matricula + trabajadores, gasto de agua/matricula, gasto de agua/matricula + trabajadores (Díaz, 2012).

Los análisis documentales realizados hasta la fecha permiten identificar que este tipo de indicadores también son utilizados con frecuencia en la gestión de sistemas energéticos empresariales en diferentes partes del mundo, y verifican las carencias existentes en indicadores de salida o indicadores de producto final.

Tal es así que en los estudios efectuados, se han encontrado componentes de los consumos de materias primas y portadores energéticos, que no tienen una relación directa con los estándares de calidad utilizados en la evaluación del comportamiento de dichos indicadores y es frecuente que algunos de estos componentes del consumo, no se asocien incluso a los productos y se mantengan aún en situaciones extremas bajo

los supuestos de cero matrícula, cero trabajadores o lo que es lo mismo, cero producción si se observa desde una óptica empresarial.

De igual manera, en el caso del establecimiento de indicadores para la gestión energética en inmuebles o edificaciones, el tratamiento es muy tradicional, generalmente a partir de la potencia media consumida por los equipos eléctricos o electrónicos en ellos instalados y los tiempos medios de trabajo de los mismos, sin tener en cuenta otros elementos como el tipo de edificación, sus características arquitectónicas y constructivas, el clima en dependencia de la época del año en las particularidades cubanas y las horas del día, las condiciones del emplazamiento, las condiciones de ubicación de los equipos en los inmuebles (aislamiento térmico, ubicación física, temperaturas externas), el perfil teórico de uso y gestión para el que fue previsto el inmueble inicialmente.

En la terminación del curso escolar 2010-2011 se realizó un trabajo de diploma en el que se integra la Tecnología de Gestión Total Eficiente de la Energía con la norma ISO-500019 y se analizaron algunos indicadores de salida, no obstante, existen otros que no se contemplan y no se desarrollan modelos de consumo que permitan el pronóstico y la planificación.

Otro indicador propuesto se encuentra referido a los estudiantes equivalentes, este también se planteó en una tesis de diploma pero en el curso 2013-2014. El mismo utiliza el término estudiante equivalente para generalizar los trabajadores de servicio social, becados cubanos y externos; entre otros, con un peso correspondiente a cada uno de forma tal que describen el consumo de electricidad.

En resumen, no se han encontrado evidencias, en los modelos de gestión energética que aporta la literatura especializada, de la consideración de elementos asociados a las características operacionales y funcionales del campus y sus instalaciones como:

El uso (uso energético cuando, por ejemplo, la potencia instalada obedece a unas necesidades energéticas directamente relacionadas con el tipo de inmueble, características arquitectónicas, características constructivas, clima externo, las horas del día, las condiciones del emplazamiento y el perfil teórico de uso y gestión previsto inicialmente para el inmueble).

La gestión (diferencias entre las condiciones teóricas previstas y la realidad de funcionamiento del edificio).

No se reportan con frecuencia la aplicación de herramientas como el Análisis del Ciclo de Vida, para la identificación de indicadores de salida y se trabaja por regla general, con indicadores tradicionales de monitoreo de procesos sin enfoques a los productos como la del elemento último en la salida de un proceso. Ello ha llevado también a que los modelos para el pronóstico de consumo de energía y agua reportados por la literatura especializada, tengan fallas por las causas mencionadas con anterioridad y porque no considera la incertidumbre presente en los datos históricos utilizados para pronosticar (Peña Acción, 2012).

Existen otros reportes que se refieren a estudios sobre sistemas de gestión e indicadores de gestión energéticos en la universidad de Cienfuegos, por ejemplo, (Fernández, 2007), (González Y. , 2015), (Ortíz, 2016), pero ninguno se refiere a la predicción del consumo durante el horario de máxima demanda del SEN.

1.4-La energía en la universidad de Cienfuegos

La Universidad de Cienfuegos es un centro de Educación Superior (CES) con dos sedes en la Ciudad de Cienfuegos. La sede Carlos Rafael Rodríguez, es la sede central donde se encuentra el rectorado y además las facultades de Ingeniería, Ciencias Económicas y Empresariales, Estudios Socioculturales y Educación Física.

El sistema de medición de la energía eléctrica cuenta con un metro digital con discriminación horaria y registro de máxima demanda. Para la determinación de las áreas que más peso tienen en el consumo de portadores energéticos se utilizan medios de medición adicionales que permiten conocer con exactitud el gasto de cada área o edificio. Para ello se adquirieron metros contadores adicionales fijos, los que se montaron el área de la Residencia y otros circuitos ramales. El consumo promedio de energía por facultades en esta sede se muestra en la Tabla 1.1.

Tabla 1.1. Consumo promedio diario por facultades

Facultad	curso 09-10	curso 10-11	curso 11-12	curso 12-13	curso 13-14
FING	250,04	306	447,19	270	370
FCEE	87,78	77	28,36	33	55
FCSH	95,79	97	29,03	26	74
FCA	57,66	47	69,26	77	87

En el año 2016 el consumo mensual promedio fue de 44.6 MWh y su comportamiento se muestra en la Figura 1.2.

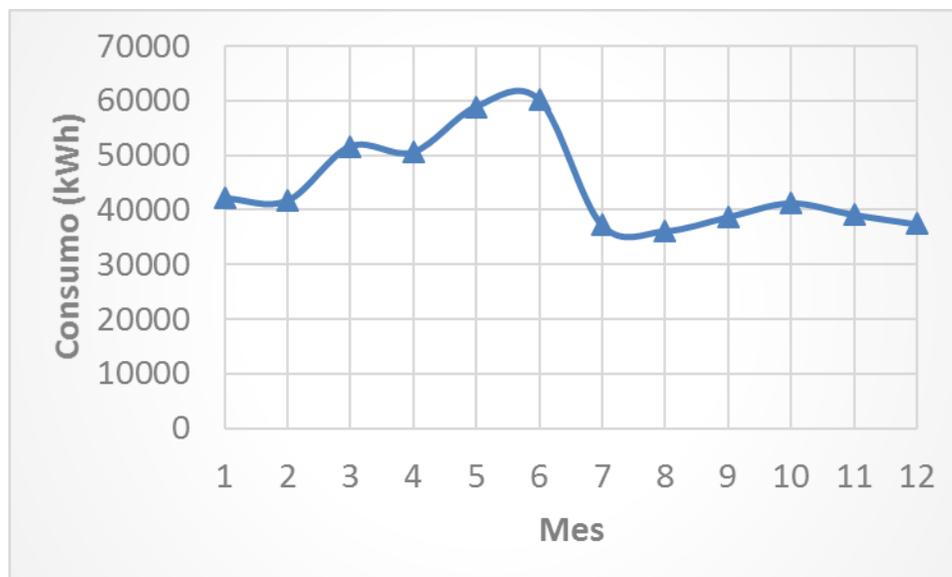


Figura 1.2. Consumo de energía mensual en la sede Carlos Rafael Rodríguez de la Universidad de Cienfuegos en el año 2016. Fuente: Elaboración propia.

Dentro de los indicadores de desempeño energético que le miden a la institución se encuentra la estructura de consumo en el pico. Esto no es más que el porcentaje que del consumo total diario representa el consumo durante el horario de máxima demanda del sistema y debe ser igual o menor a 16%, según requerimientos de la política trazada por la Oficina Nacional de Uso racional de la Energía (ONURE). Cuando es superior se incumple con este indicador y se debe explicar las causas.

Si se hace un análisis de la estructura de consumo en el pico durante el año 2016 se puede apreciar que en 221 ocasiones se superó el 16%. Un gráfico de probabilidad

acumulativa del porcentaje de energía en el pico durante el año 2016 se muestra en la Figura 1.3, de este gráfico se puede afirmar que en el 60% de los días se superó el 16%.

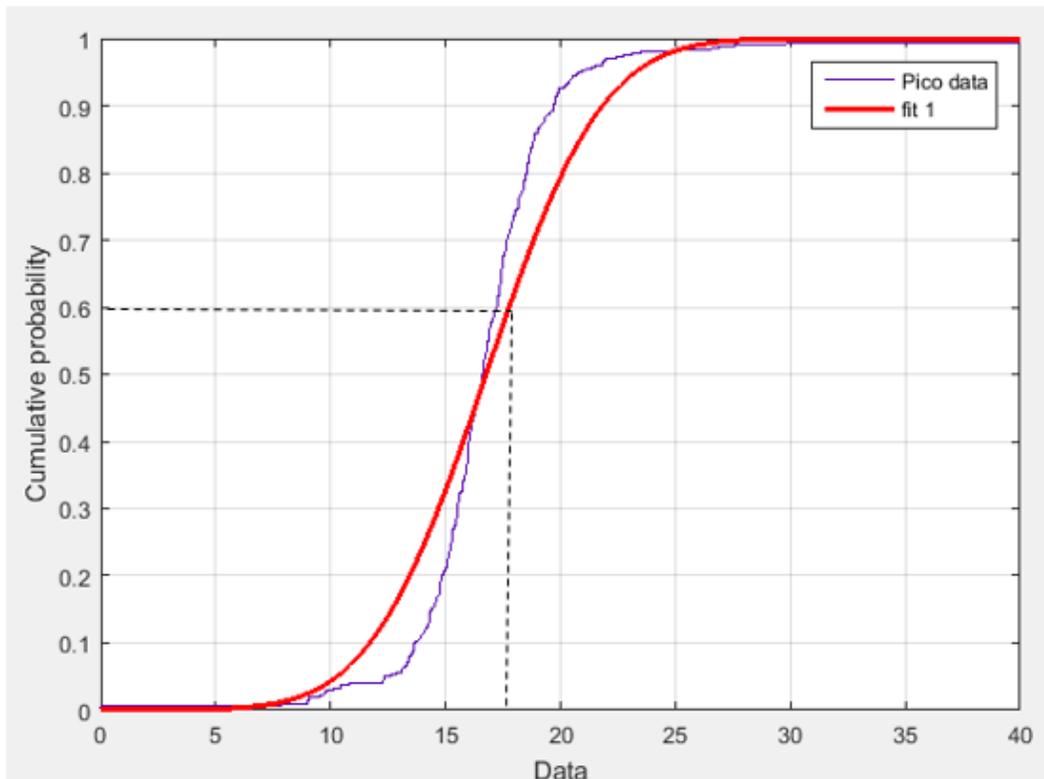


Figura 1.3 Probabilidad acumulativa de la estructura de consumo pico de la Universidad de Cienfuegos durante el año 2016. Fuente: Elaboración propia.

Una vez que se ha determinado que la estructura de consumo pico superó el 16%, el análisis es puramente forense. Lo correcto sería poder anticiparse a este consumo 24 horas antes y poder tomar las medidas necesarias para que no suceda. Para hacer esto se necesita un modelo de pronóstico confiable que considere variables temporales y que tenga en cuenta la historia anterior al evento que se quiere predecir. Este precisamente es el objetivo de esta investigación y se trabajará para establecer el pronóstico de consumo para cada horario establecido en la tarifa, de manera que se pueda estimar anticipadamente el porcentaje que representará el consumo pico del total

diario y en caso de que supere el 16% establecido, tomar las medidas pertinentes para no excederlo.

El pronóstico de consumo y demanda es un tema que ha sido ampliamente abordado en la literatura y continúa investigándose por la importancia en la operación de las redes y sistemas de potencia. A continuación, se trata brevemente sobre el estado del arte en esta temática.

1.5-Estado del arte sobre modelos de pronóstico de consumo

Pronosticar la demanda de potencia es de gran importancia dentro de la gestión energética, sobre todo para la actividad de planificación. Para los sistemas de potencia, el pronóstico de la demanda máxima permite la toma de decisiones como la programación de la capacidad de generación, gestión del combustible, evaluaciones de seguridad y planificación de consumos y transacciones energéticas (Khotanzad, Afkhami-Rohani, Lu, Abaye, Davis, & Maratukulam, 1997).

En los sistemas de potencia están emergiendo nuevos elementos como los vehículos eléctricos, la generación distribuida y las fuentes renovables de energía. Están apareciendo conceptos tales como redes inteligentes de energía, ciudades inteligentes, plantas virtuales, microrredes y edificios y ambientes inteligentes. En este escenario, el volumen de información disponible debido a la gran cantidad de mediciones en varios puntos de la red se ha incrementado y el pronóstico de la demanda está ganando mayor interés (Hernández, y otros, A survey on electric power demand forecasting: future trends in smart grids, microgrids and smart buildings, 2014).

Las técnicas de pronóstico se clasifican de acuerdo al horizonte de tiempo y al objetivo. La primera clasificación comprende Pronóstico de carga de muy corto tiempo (very short-term load forecasting, VSTLF), pronóstico de carga de corto tiempo (short-term load forecasting, STLF) y pronóstico de carga de mediano largo tiempo (medium-term and long-term load forecasting, MTLF and LTLF). VSTLF se refiere a intervalos de tiempo de segundos, minutos y horas y son generalmente utilizados para propósitos de control de flujo. STLF considera desde horas hasta semanas y se utiliza para ajustar la

generación a la demanda. MTLF y LTLF se refieren a predicciones de la demanda con meses y años y son generalmente utilizados para la planificación de las redes.

La segunda clasificación se basa en la cantidad de datos para la predicción de la carga y se divide en dos grupos: los que utilizan solo un valor y los que utilizan múltiples valores para la predicción de la carga. Un ejemplo del primer grupo es el pronóstico de la demanda máxima para el próximo día. Otras clasificaciones se basan en las herramientas y modelos utilizados, por ejemplo modelos de pronóstico lineal y no lineal (Hernández, y otros, A survey on electric power demand forecasting: future trends in smart grids, microgrids and smart buildings, 2014).

En la literatura se reportan muchas investigaciones acerca de la modelación en pronóstico de carga, enfocadas al tipo de modelo, escenario de estudio e influencia de variables temporales y climatológicas. En estas investigaciones se han empleado a menudo, modelos estadísticos, métodos de regresión, métodos de espacio-estado, algoritmos evolutivos, sistemas de inferencia neurodifusos (ANFIS) y redes neuronales artificiales (ANN).

Ramesh y colaboradores publicaron el primer método de pronóstico de carga basados en modelos de regresión lineal (Ramesh, Natarajan, & Bhagat, 1988), sin embargo, estos métodos lineales tienen limitaciones para capturar las no linealidades de las cargas. Actualmente se continúan utilizando, pero los modelos no lineales basados en ANN son los que mayormente se emplean. Desde hace más de un cuarto de siglo se emplean exitosamente las redes neuronales para predecir carga y los investigadores han perfeccionado los modelos obteniendo mayor precisión a costa de mayor complejidad (Zhang, Patuwo, & Hu, 1998).

Algunos investigadores han aplicado el análisis de componentes principales (PCA) para disminuir las variables de entrada y simplificar la arquitectura de las redes (Amin-Naseri & Soroush, 2008), (Saravanan, Kannan, & Thangaraj, 2012) y otros han empleado técnicas de minería de datos combinada con sistemas de inferencia neurodifusos (Motamedi, Zareipour, & Rosehart, 2012) o incluso la combinación de ANN con transformada wavelet (Zhang & Dong, 2001) o con sistemas ANFIS para aumentar la exactitud (Hooshmand, Amooshahi, & Parastegari, 2013). Además, también se ha

reportado el uso de redes secuenciales, una primera red neuronal para pronosticar las variables climatológicas que serán utilizadas como entradas en la segunda red para el pronóstico de la demanda (Kulkarni, Simon, & Sundareswaran, 2013). Un acercamiento reciente a la solución de este tipo de problemas es la combinación de modelos individuales en un solo modelo (Xiao, Wang, Hou, & Wu, 2015), sin embargo, necesitan preselección de datos para eliminar interferencia entre ellos. También se han empleado otros métodos para seleccionar las entradas de las ANN usando coeficientes de correlación y distancia Euclidiana (Ghofrani, Ghayekhloo, Arabali, & Ghayekhloo, 2015).

Un aspecto distintivo de los métodos de pronóstico es la consideración de la influencia de las variables climatológicas sobre el comportamiento de la carga. Aunque existe influencia del clima en la demanda de potencia (Ramesh, Natarajan, & Bhagat, 1988), (Honga, Wang, & White, 2015), (Ortiz Beviá, Ruiz de Elvira, & Alvarez García, 2014), (Lin, Tso, Ho, Mak, Yung, & Ho, 2006), (Eto, 1988), algunos investigadores no la consideran y modelan el consuo como series temporales exclusivamente (Saravanan, Kannan, & Thangaraj, 2012), (Xiao, Wang, Hou, & Wu, 2015), (Ghofrani, Ghayekhloo, Arabali, & Ghayekhloo, 2015), (Filik, Gerek, & Kurban, 2011), (Dalvand, Azami, & Tarimoradi, 2008).

La variable climática que se considera fundamentalmente es la temperatura, aunque algunos otros factores como la humedad relativa, velocidad del viento, y nubosidad pueden ser introducidas en el modelo para mejorar la calidad de mla predicción (Khotanzad, Afkhami-Rohani, Lu, Abaye, Davis, & Maratukulam, 1997), (Ramesh, Natarajan, & Bhagat, 1988), (Amin-Naseri & Soroush, 2008), (Hooshmand, Amooshahi, & Parastegari, 2013), (Kulkarni, Simon, & Sundareswaran, 2013), (Honga, Wang, & White, 2015), (Ortiz Beviá, Ruiz de Elvira, & Alvarez García, 2014), (Lin, Tso, Ho, Mak, Yung, & Ho, 2006), (Eto, 1988), (Li, Sua, & Chu, 2011), (Ghiassi, Zimbra, & Saidane, 2006), (Cárdenas, Romeral, García, & Andrade, 2012), (Nagi, Yap, Nagi, Tiong, & Ahmed, 2011), (Badri, Ameli, & Birjandi, 2012), (Phimphachanh, Chammongthai, Kumhom, & Sangswang, 2004), (Kulkarni & Simmon, 2012), (Berardino & Nwankpa, 2013), (Bagnasco, Saviozzi, Silvestro, Vinci, Grillo, & Zennaro, 2014). En el caso de que el escenario de estudio sea una gran región, con diferentes condiciones climáticas, se

puede utilizar un promedio ponderado de las lecturas de variables climatológicas (Khotanzad, Afkhami-Rohani, Lu, Abaye, Davis, & Maratukulam, 1997).

Debido a que la demanda de potencia es claramente dependiente del sector (industrial, comercial, residencial, administrativo, etc), la influencia de las variables climatológicas puede ser más relevante si las cargas de aire acondicionado o calefacción son predominantes. Se han desarrollado modelos para regiones pequeñas que no consideran el clima (Hernández, Baladrón, Aguiar, Carro, Sanchez-Esguevillas, & Lloret, 2014), pero se reconoce que para trabajos futuros debe ser incluido.

En cuanto a la predicción de carga en las universidades y su empleo en los sistemas de gestión energética, se reportan pocos trabajos en la literatura científica revisada. Por ejemplo, Bagnasco recientemente publicó un trabajo de pronóstico de carga para una facilidad de media tensión de un gran Hospital Universitario localizado en Roma, Italia (Bagnasco, Saviozzi, Silvestro, Vinci, Grillo, & Zennaro, 2014). En su investigación emplea una ANN perceptron multicapas para el modelo lo que reduce el error del pronóstico. El conjunto de datos anuales fue dividido en cuatro subconjuntos estacionales, cada uno con una duración de tres meses.

Aunque los resultados probaron ser razonables, con un error pequeño, las redes necesitan ser entrenadas para cada subconjunto de datos y emplea 96 valores de temperatura diaria medida cada 15 minutos. Esto hace que el método sea complejo al tener que trabajar con cuatro redes neuronales y requerir mucha información. Por otro lado, Bagnasco concluye que la variable temperatura no es necesaria, ya que no conduce a una mejora en la predicción porque la correlación entre la carga y la temperatura no parece suficientemente elevada para esta facilidad.

Basado en este trabajo, Gómez y colaboradores desarrollaron un modelo para la Universidad de Sao Paulo, Brasil, con una metodología simple que puede ser integrada a los sistemas de gestión energética (Gómez Sarduy, Gregio di Santo, & Saidel, 2016).

Los modelos desarrollados en este caso fueron lineales y no lineales, respectivamente, usando regresión lineal y ANN y sistemas ANFIS. Los datos que emplearon fueron la demanda de potencia, variables climáticas y datos temporales, toda esta información fue normalizada y a diferencia de otros investigadores incorporaron una nueva variable

para diferenciar entre días festivos o de poca actividad y días normales. Los valores predichos muestran una buena coincidencia con los datos por otros modelos, aunque para el caso del sistema ANFIS, la precisión es menor.

Otros trabajos dirigidos al pronóstico de consumo en universidades, es el desarrollado por Fernández en su tesis de maestría (Fernández, 2007). En esta investigación, el caso de estudio es precisamente la Universidad de Cienfuegos y emplea modelos ARIMA y redes neuronales para el modelo de pronóstico, pero éste es a mediano plazo (MTLF) para predecir el consumo de energía mensual, no ha sido actualizado y además no incluye la demanda pico diaria en su predicción.

1.6-Conclusiones parciales

1-La demanda de energía de la Universidad de Cienfuegos en su sede central, fue de 1512 kWh promedio diario en el 2016 y el 60% de su estructura de consumo en el horario pico supera el 16% lo que constituye un incumplimiento de los requerimientos de la ONURE y no contribuye al aplanamiento de la curva de demanda en ese horario.

2-En la Universidad de Cienfuegos existe un sistema de gestión establecido, pero no contempla la predicción del consumo en el horario pico y por lo tanto carece de las herramientas para tomar las medidas necesarias de manera anticipada que eviten sobreconsumos en el horario pico.

3-La literatura consultada refiere que existen diversos modelos de pronóstico en función de las variables a pronosticar y el periodo de tiempo que abarca el pronóstico, sin embargo, son escasos los reportes referidos a pronóstico energético en instituciones de educación superior o campus universitarios.

4-El pronóstico de consumo desarrollado por Fernández en el 2007 para la Universidad de Cienfuegos es un modelo para mediano plazo (MTLF) que permite predecir el consumo de energía mensual, pero no ha sido actualizado y además no incluye la demanda pico diaria en su predicción, por lo que no se ajusta a los objetivos de esta investigación.

Capítulo II. Fundamentos metodológicos

2.1. Aspectos generales

La obtención de un modelo adecuado para el consumo de energía en el periodo de máxima demanda, como cualquier otro proceso de modelación, involucra un compromiso entre precisión y complejidad. La mayor precisión se obtiene añadiendo complejidad al modelo, mientras que modelos más sencillos generalmente conducen a resultados menos precisos. Por esta razón en esta investigación se propone explorar el comportamiento de modelos lineales y no lineales desarrollados para predecir la energía consumida durante el pico.

De acuerdo a la literatura (Hernández, y otros, 2014), esta investigación se caracteriza por:

- Modelos: lineales y no lineales
- Area: campus Universidad de Cienfuegos, sede central
- Horizonte de pronóstico: STLF
- Objetivo: varios valores (consumo horario pico y consumo resto del día)
- Variables: carga eléctrica con datos temporales.

La metodología comprende tres pasos: recolección de información, preprocesamiento de los datos y desarrollo de los modelos de pronóstico.

Inicialmente se recogen los datos históricos (paso 1) y seguidamente se tratan antes de utilizarlos para la modelación (paso 2). Este tratamiento incluye el agrupamiento, conversión y filtrado y creación de nuevas variables para los tipos de días y variables temporales. Posteriormente se desarrollan los diferentes modelos (paso 3) correlacionando los datos seleccionados (variables dependientes como día, mes y tipo de día, consumos 24 horas antes como datos de entrada y el consumo de energía del día y del pico como variables de salida). Para ello se utilizan funciones disponibles en el toolbox del Matlab 2015.

2.2 Modelos lineales

Los métodos de regresión para pronósticos de consumo de energía a corto plazo han sido ampliamente utilizados desde hace más de 30 años (Mirowski, Chen, Ho, & Yu, 2014). debido a que el consumo de energía de la universidad es función de varias variables, los modelos de regresión lineal múltiple (MLR) son más apropiados que la regresión lineal simple. Un modelo de regresión lineal múltiple en estadística es un modelo relaciona una o varias variables que hay que explicar Y a unas variables explicativas X , por una relación funcional $Y = F(X)$. A continuación se hará una breve explicación teórica de este tipo de modelos.

Cuando se ajusta un conjunto de datos existentes a un modelo matemático, siempre se comete un error de estimación entre los datos reales y los que se obtienen con el modelo ajustado. Este error se ha representado en la figura 2.1 como ε .

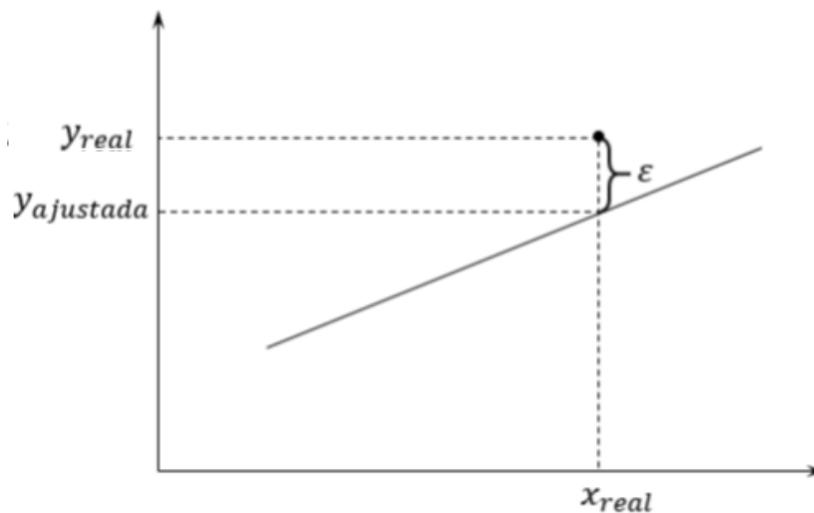


Figura 2.1 Error relativo o de estimación.

Cuando se emplea MLR, en particular cuando el número de variables pasa de dos (ya sean dependientes o independientes), la representación matricial puede facilitar las manipulaciones matemáticas (Walpole, Myers, & Myers, 2008). Suponiendo que se tienen k variables independientes x_1, x_2, \dots, x_k y n observaciones y_1, y_2, \dots, y_n , cada una de las cuales se puede expresar por la ecuación 2.1

$$y_n = \beta_0 + \beta_1 x_{n1} + \beta_2 x_{n2} + \dots + \beta_k x_{nk} + \varepsilon_n \quad (2.1)$$

Este modelo en esencia representa n ecuaciones que describen como se generan los valores de la respuesta y_n . Con el uso de la notación matricial la ecuación 2.1 se puede escribir de la forma siguiente:

$$Y = X\beta + \varepsilon \quad (2.2)$$

De esta manera se puede modelar el consumo de potencia como una combinación lineal de variables relacionadas con el día de la semana, tipo de día, mes, etc. La comprensión e interpretación de este modelo es fácil y no requiere software especializado para su evaluación. Este tipo de modelo matemático provee una formulación global y explícita del comportamiento de la carga.

Considerando un modelo lineal se determina los coeficientes de regresión y correlación para cada combinación de variables y relaciones funcionales. La ventaja de los modelos lineales son su simplicidad y facilidad de uso, sin embargo, en la literatura se reporta que los modelos no lineales tienen mejor comportamiento.

La función en Matlab para obtener un modelo de regresión múltiple es **fitlm**. Con esta función se puede obtener diferentes tipos de modelos de regresión por mínimos cuadrados de acuerdo a la cadena que se introduzca en su argumento. Por ejemplo, la sintaxis siguiente `mdl = fitlm(X,y,'interactions');` ajusta las variables explicativas X con la variable y en un modelo llamado `mdl` que tiene términos lineales de X y términos que son interacciones de las variables X . Las posibilidades de los diferentes modelos se muestran en la tabla 2.1.

Tabla 2.1 Tipos de modelos que se ajustan utilizando la función `fitlm` del Matlab.

Argumento	Tipo de modelo
'constant'	El modelo contiene solamente un término constante (intercepto)
'linear'	El modelo contiene un intercepto y términos lineales de cada predictor
'interactions'	El modelo contiene un intercepto, términos lineales y todos los productos de pares de

	distintos predictores (sin términos cuadráticos)
'purequadratic'	El modelo contiene un intercepto, términos lineales y términos cuadráticos.
'quadratic'	El modelo contiene un intercepto, términos lineales, interacciones y términos cuadráticos.

Los pasos para realizar un modelo lineal en Matlab son los siguientes:

1-Importar los datos en un arreglo o matriz que contiene las variables de entrada por columnas y cada fila es una observación. Cada variable de salida se importa como un vector columna.

2-Crear el modelo usando la función fitlm

3-Simplificar el modelo. Se puede obtener un modelo más sencillo, con menos predictores, pero la misma exactitud en la predicción con la función step, que permite obtener un mejor modelo adicionando o eliminando un término a la vez. Se pueden realizar hasta 10 pasos de adición o eliminación de términos. La sintaxis es:

```
mdl1 = step(mdl, 'NSteps', 10)
```

4-Analizar los residuales

5-Realizar predicciones utilizando nuevos datos.

2.3. Modelos no lineales. Redes neuronales artificiales (RNA)

Aunque el consumo de energía se obtiene con facilidad de las lecturas de los metros contadores, su valor es conocido solamente cuando se ha consumido y no antes. El conocimiento previo de este consumo solamente es posible mediante la predicción a partir de modelos de consumo. La precisión del pronóstico de consumo es de gran valor para los sistemas de gestión energética. Basado en la literatura consultada, las RNA

son una alternativa a los métodos estadísticos clásicos en términos de precisión de los resultados pronosticados (Hernández, y otros, 2014) .

Los modelos no lineales basados en RNA para la predicción han ganado mayor atención desde la segunda mitad de los 80 (Hernández, y otros, 2014). Su capacidad de aprendizaje de la experiencia, capacidad de generalización a nuevos casos y su capacidad para encontrar relaciones complejas y no lineales entre variables de entrada y salida, mediante un proceso conocido como entrenamiento con datos históricos, hacen a las RNA atractivas para modelos de pronóstico de carga. La diferencia fundamental entre los modelos no lineales y lineales es que los primeros no requieren una representación matemática clara para representar la dependencia entre diferentes parámetros para resolver un problema, lo cual ahorra tiempo; mientras los modelos lineales requieren una definición precisa mediante ecuaciones.

Una red neuronal, según (Freeman & Skapura, 1993), es un sistema de procesadores paralelos conectados entre sí. Varias neuronas conectadas en paralelo forman una capa y varias capas conectadas en serie forman la red. Esquemáticamente cada uno de sus elementos de procesamiento (neuronas) se representan como un nodo. Estas conexiones establecen una estructura jerárquica que tratando de emular la fisiología del cerebro busca nuevos modelos de procesamiento para solucionar problemas concretos del mundo real.

La RNA es muy útil debido a su facilidad para aprender, reconocer y aplicar relaciones entre objetos y tramas de objetos propios del mundo real. Por esa razón constituyen una herramienta que puede utilizarse para solucionar problemas complejos. De acuerdo con (Hilera & Martínez, 1995) los principios de funcionamiento más importantes son:

1-Aprendizaje adaptativo: Esta es quizás la característica más importante de las redes neuronales, pueden comportarse en función de un entrenamiento con una serie de ejemplos ilustrativos. De esta forma, no es necesario elaborar un modelo a priori, ni establecer funciones probabilísticas. Además, pueden modificarse constantemente con el fin de adaptarse a nuevas condiciones de trabajo.

2-Autoorganización: Mientras que el aprendizaje es un proceso donde se modifica la información interna de la red neuronal artificial, la auto-organización consiste en la modificación de la red completa con el fin de llevar a cabo un objetivo específico.

Auto-organización significa generalización, de esta forma una red puede responder a datos o situaciones que no ha experimentado antes, pero que puede inferir sobre la base de su entrenamiento. Esta característica es muy útil sobre todo cuando la información de entrada es poco clara o se encuentra incompleta.

3-Tolerancia a fallos: En la computación tradicional la pérdida de un fragmento pequeño de información puede acarrear comúnmente la inutilización del sistema. Las redes neuronales artificiales poseen una alta capacidad de tolerancia a fallos.

Se entiende por ello que pueden reconocer patrones de información con ruido, distorsión o incompletos, pero que, además, pueden seguir trabajando aunque se destruya parte de la red (con cierta degradación). La explicación de este fenómeno consiste en que mientras la computación tradicional almacena la información en espacios únicos, localizados y direccionales, las redes neuronales lo hacen de forma distribuida y con un alto grado de redundancia.

4-Operación en tiempo real: Las redes neuronales artificiales, de todos los métodos existentes, son las más indicadas para el reconocimiento de patrones en tiempo real, debido a que trabajan en paralelo actualizando todas sus instancias simultáneamente. Es importante destacar que esta característica solo se aprecia cuando se implementan redes con hardware especialmente diseñados para el procesamiento paralelo.

5-Fácil inserción en la tecnología existente: Es relativamente sencillo obtener chips especializados para redes neuronales que mejoran su capacidad en ciertas tareas. Ello facilita la integración modular en los sistemas existentes.

Las redes neuronales artificiales tratan de imitar el funcionamiento del cerebro humano y por ende son modelos basados en la inspiración biológica. La neurona biológica tiene una estructura ramificada de entrada (las dendritas) y una estructura ramificada de salida (los axones). Los axones de una célula se conectan con las dendritas de otra y por vía de un proceso conocido como sinapsis la neurona se activa y excita una señal

electroquímica a lo largo del axón. Esta señal transfiere la sinapsis a otras neuronas, las que a su vez pueden excitarse. Es importante señalar que las neuronas solo se excitan sí la señal total recibida en el cuerpo de las células, por conducto de las dendritas, es superior a cierto nivel (umbral de excitación).

De manera similar, las redes neuronales artificiales están formadas por una gran cantidad de neuronas, estas suelen denominarse nodos o unidades de salida. En la Figura 2.2 se muestra la arquitectura de una RNA clásica con variables de entrada, capas de neuronas intermedias u ocultas y una capa de salida. Todas ellas conectadas entre sí.

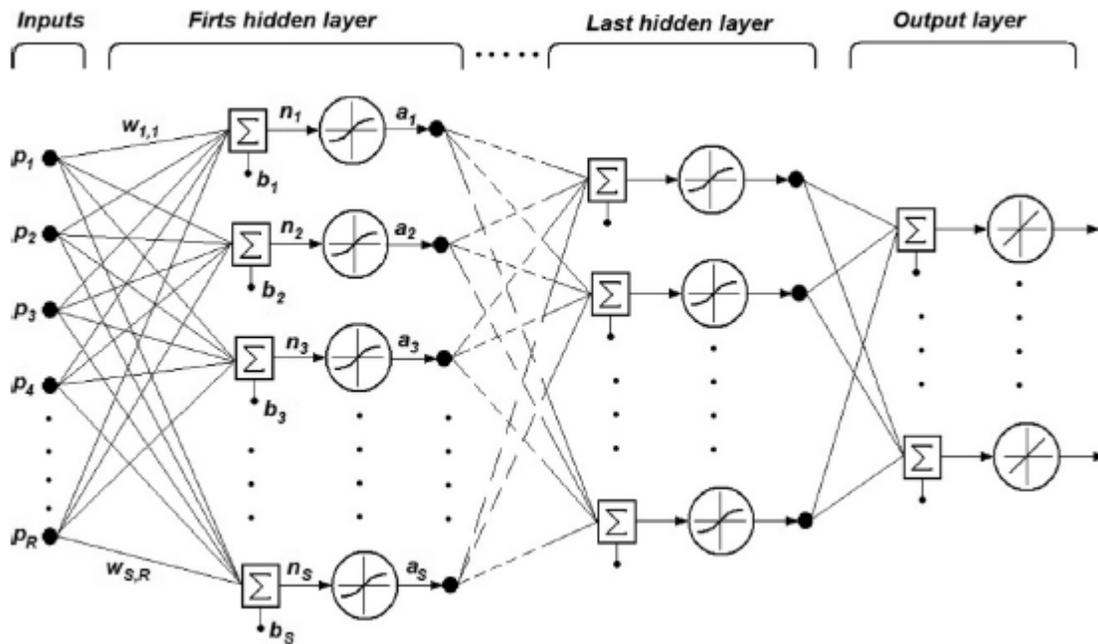


Figura 2.2 Arquitectura de una red neuronal artificial. Fuente: (Gómez Sarduy, Gregio di Santo, & Saidel, 2016)

Un nodo o neurona cuenta con una cantidad variable de entradas que provienen del exterior (p_1, p_2, \dots, p_R). A su vez dispone de una sola salida (por ejemplo, a_1) que transmitirá la información al exterior o hacia otras neuronas. Cada a_s o señal de salida tiene asociada una magnitud llamada peso y se calculará en función de las entradas, por lo cual cada una de ellas es afectada por un determinado peso ($w_{1,1} \cdot p_1 + \dots + w_{1,R} \cdot p_R + b_1$). Los pesos corresponden a la intensidad de los enlaces

sinápticos entre neuronas y varían libremente en función del tiempo y en cada una de las neuronas que forman parte de la red.

El proceso de aprendizaje consiste en hallar los pesos que codifican los conocimientos. Una regla de aprendizaje hace variar el valor de los pesos de una red hasta que estos adoptan un valor constante, cuando esto ocurre se dice que la red ya "ha aprendido". Existen varias topologías, que se clasifican según tres criterios: número de niveles o capas; número de neuronas por nivel; y formas de conexión (Freeman & Skapura, 1993).

Existe una gran variedad de modelos de redes neuronales. Estos dependen del objetivo para el cual fueron diseñados y del problema práctico que solucionan. Hoy día, su éxito depende en, gran medida, del valor comercial que logren alcanzar sus aplicaciones. En dependencia de ello unos serán más populares que otros. Entre los más conocidos están el Perceptrón Multicapas, Adaline/Madaline (utilizado en el diseño y realización de filtros, para llevar a cabo la eliminación del ruido en señales portadoras de información, modems, etcétera), el back propagation (utilizado en el proyecto de la máquina de escribir neural fonética) y el modelo de los mapas auto-organizados (Self-Organizing Map, SOM). Este último es conocido como modelo de Kohonen por ser este su creador (Sotolongo & Guzman, 2001).

De la multitud de modelos y variantes que de hecho existen, aproximadamente una quincena son utilizados con asiduidad en las aplicaciones prácticas. Por tanto, para llevar a cabo el estudio sistemático de los modelos se precisa algún tipo de clasificación. Los dos conceptos que más caracterizan un modelo neuronal son el tipo de aprendizaje y la arquitectura de la red, por ello, se considera de suma importancia que la clasificación atienda ambos aspectos.

De esta manera, en primer lugar, se realiza una distinción en cuanto al tipo de aprendizaje, por lo que aparece una primera clasificación en modelos supervisados, no supervisados, de aprendizaje híbrido y modelos de aprendizaje reforzado. A su vez, y dentro de cada uno de los grandes grupos, se tiene en cuenta el tipo de topología de la red, por lo que se distinguen además entre redes realimentadas y redes unidireccionales (no realimentadas). El conjunto de modelos de redes no realimentadas

y de aprendizaje supervisado es el más numeroso. Dentro de este grupo el más utilizado ha sido el Perceptrón Multicapa o MLP (Multilayer Perceptron)

Dentro de las herramientas disponibles para el diseño de redes neuronales se tiene la función `nntool` del toolbox de Matlab. Con esta función se llama a la interfaz gráfica de usuario (GUI) que permite el diseño y entrenamiento de redes neuronales artificiales. Esta GUI se muestra en la Figura 2.3 y contiene los botones para importar los datos, crear una nueva red y exportar los resultados.

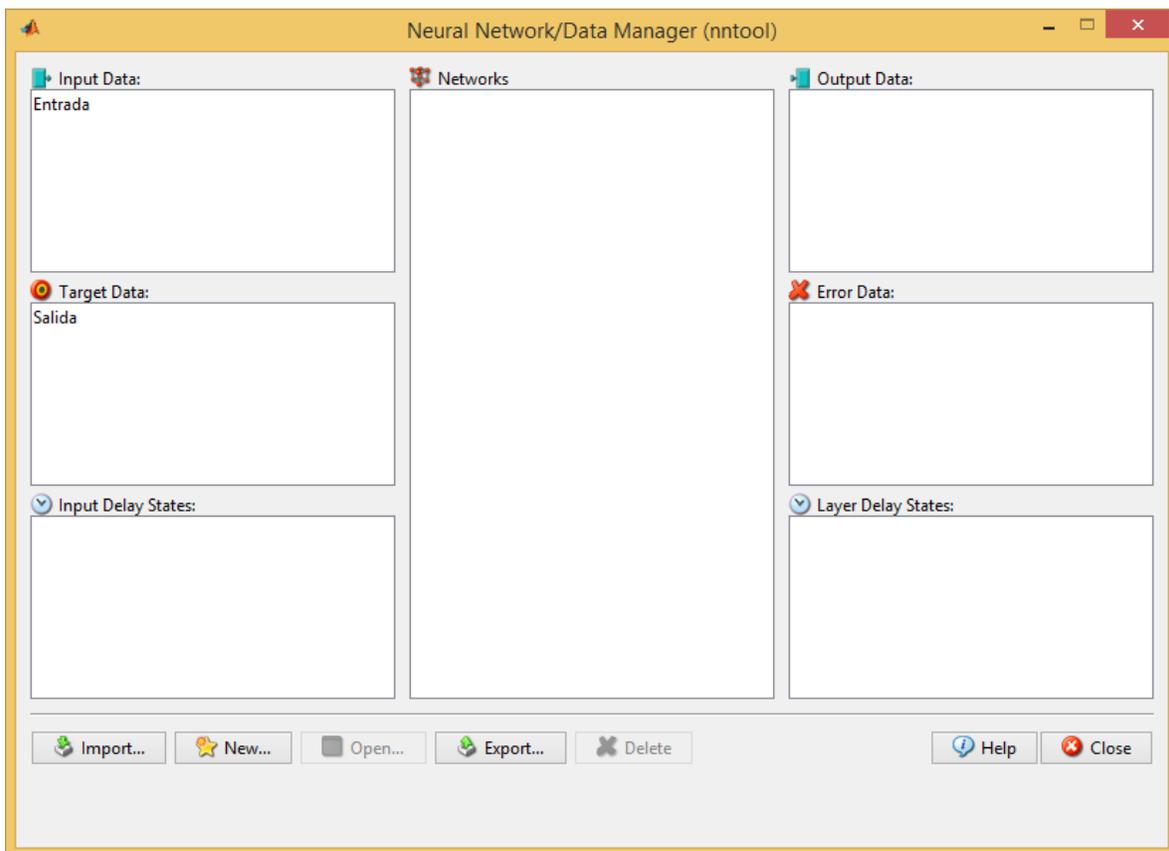


Figura 2.3. GUI para diseño y entrenamiento de redes neuronales artificiales en Matlab.

Una vez que se hace click en el botón `New` para crear una nueva red, aparece la ventana que se muestra en la Figura 2.4. Esta permite nombrar la red para identificarla a la hora de guardarla o exportarla, seleccionar el tipo de red, los datos de entrada y los objetivos, así como el algoritmo de entrenamiento y la función de comportamiento, entre otras.

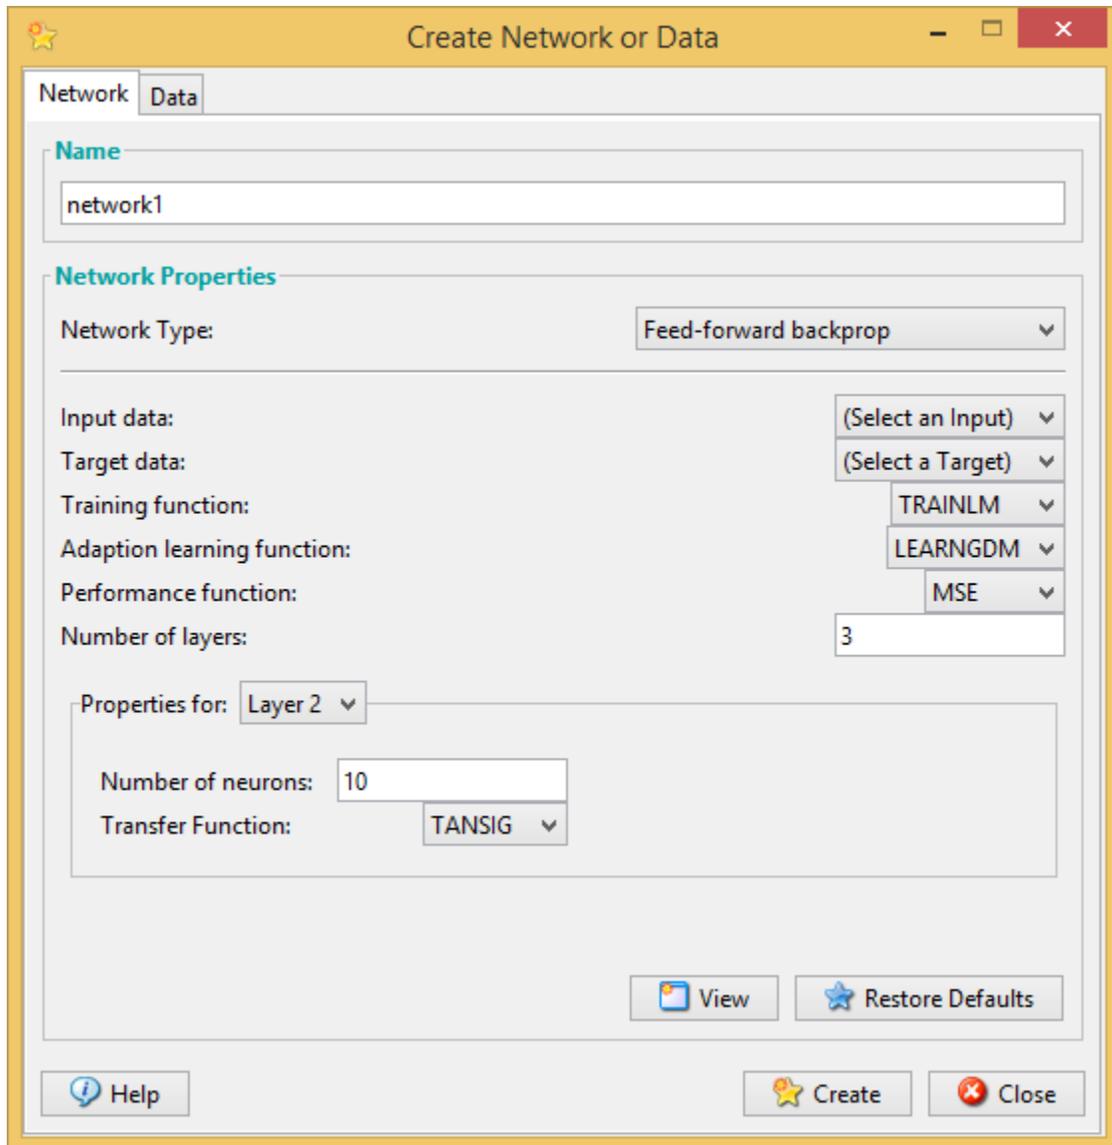


Figura 2.4. Ventana para el diseño de la red.

Una vez que el usuario ha definido el número de capas introduce las propiedades que definen la arquitectura de la red (número de neuronas de cada capa y función transferencia).

Para el entrenamiento, se toma por defecto un 60% de los datos para entrenar la red y un 20% para los subconjuntos de validación y prueba. El comportamiento de la red estará definido por el error cuadrático medio (MSE) y el usuario puede realizar una prueba de pos-entrenamiento para verificar la capacidad de generalización que tiene la

red. Para ello calcula la correlación existente entre los valores dados por la red en su salida y los valores reales introducidos como objetivos para el entrenamiento.

2.4 Medidas de precisión

Una vez desarrollados los modelos se analiza su exactitud. Una medida de la misma se define a menudo en términos del error en el ajuste, que es la diferencia entre el valor estimado por el modelo y el valor real. Entre las medidas de exactitud más utilizadas están: el coeficiente de correlación (R^2) y el porcentaje de error absoluto medio (MAPE).

El coeficiente de correlación se calcula como:

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \hat{y})^2}{\sum_{i=1}^n (y_i - \hat{y})^2} \quad (2.1)$$

Donde: \hat{y}_i es el valor estimado por el modelo, y_i es el valor real, \hat{y} es el valor medio y n es el número de observaciones de la muestra.

El porcentaje de error absoluto medio es un parámetro estadístico que da una idea global de la diferencia entre la predicción y el valor real y se calcula como:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{(\hat{y}_i - y_i)}{y_i} \right| \cdot 100 \quad (2.2)$$

Para una comparación cuantitativa entre los modelos se define el porcentaje de mejora λ (Gómez Sarduy, Gregio di Santo, & Saidel, 2016). Esta medida se calcula como:

2.5 Conclusiones parciales

1- Los métodos de regresión para pronósticos de consumo de energía a corto plazo han sido ampliamente utilizados desde hace más de 30 años, por ser más sencillos y definir una expresión matemática que puede ser evaluada fácilmente sin software especializados.

2-Los modelos basados en RNA (modelos no lineales) para la predicción han ganado mayor atención desde la segunda mitad de los 80 debido a su capacidad de aprendizaje de la experiencia, capacidad de generalización a nuevos casos y su

capacidad para encontrar relaciones complejas y no lineales entre variables de entrada y salida.

3-Las medidas de precisión más utilizadas, según la literatura científica consultada, para evaluar la exactitud de los modelos de pronóstico son: el coeficiente de correlación (R^2) y el porcentaje de error absoluto medio (MAPE)

4-Para la obtención del modelo de pronóstico se utiliza el Matlab con las funciones `fitlm` y `nnTool` para el caso del modelo de regresión lineal y el modelo basado en redes neuronales respectivamente.

Capítulo III. Resultados

3.1 Adquisición y procesamiento de datos

Comoquiera que el objetivo del trabajo es encontrar un modelo para el pronóstico a corto plazo del consumo de energía por horario de la tarifa y determinar con 24 h de antelación si el consumo del horario pico excederá el 16% del consumo total del día de manera que se puedan tomar las medidas necesarias para su mitigación, entonces es necesario conocer estos consumos históricos para un periodo base y utilizarlos para desarrollar el modelo de pronóstico.

Para desarrollar este modelo, la información se obtuvo de la base de datos que contiene lecturas diarias del metro contador para cada horario de la tarifa. Esto permite disponer de los datos de consumo diario para el horario de madrugada, día y pico. Las variables temporales son las correspondientes al mes y al día. De esta manera se tienen las siguientes variables:

Mes: indica el mes del año con valores de 1 a 12

Día: indica el día de la semana desde 1 a 7, siendo 1 para el domingo y 7 para el sábado

Consumo total y Consumo Pico: son los consumos de energía en kWh para todo el día y durante el pico.

En el Anexo A se puede ver esta información para el año 2016 considerado como base para el estudio.

El procesamiento de los datos comienza con un análisis de clusterización para determinar si existen datos que se puedan agrupar en función del tipo de día o de algún periodo específico o que sigan un patrón estacional.

Los grupos se determinan utilizando la técnica de clusterización k-Means. Este análisis de clúster, también llamado análisis de segmentación o taxonomía, crea grupos de datos. La clusterización K-Means es un método de particionar adecuadamente una gran cantidad de datos. El procedimiento sigue una simple y fácil manera de clasificar un

conjunto de datos dados a través de cierto número de clústers fijados previamente. La idea principal es definir k centroides, uno para cada clúster.

Se utilizó la función `kmeans` del Matlab 2015, por la cual los datos fueron particionados en k grupos mutuamente excluyentes. Como resultado de esta función, se asigna un índice de clúster a cada observación. En general el algoritmo tiene tres pasos hasta la convergencia.

Paso 1: Determinar la coordenada del centroide

Paso 2: Determinar el cuadrado de la distancia Euclídeana de cada objeto a los centroides

Paso 3: Agrupar los objetos basados en la mínima distancia.

Considerando que los datos de consumo diario pueden ser segmentados en dos clúster de datos, entonces se emplea la función `kmeans`. En la Figura 2.1 se observa que los datos se han agrupado en dos grandes grupos. Estos grupos contienen el consumo pico para valores bajos de consumo total del día (puntos azules) y consumo pico para valores mayores del consumo total del día (puntos rojos).

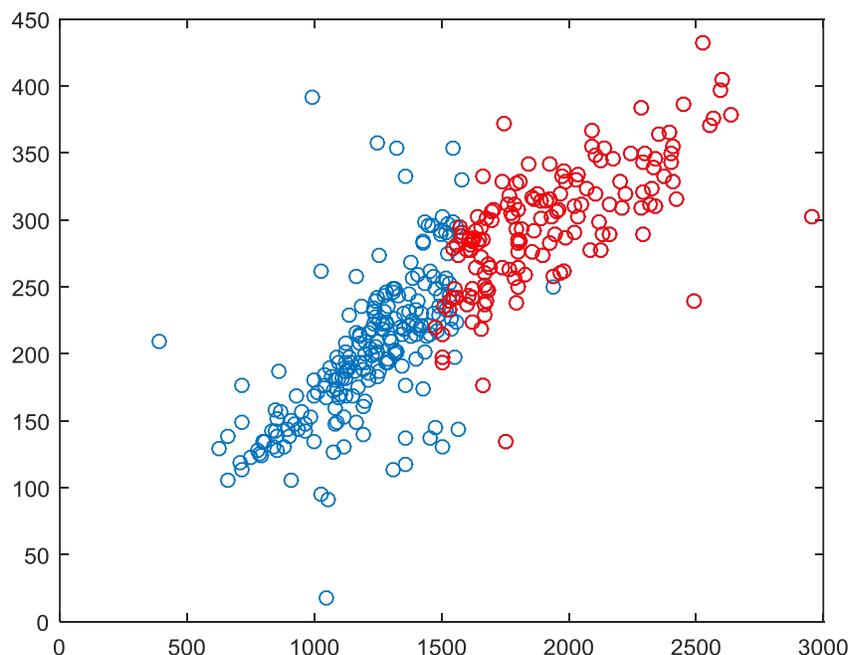


Figura 3.1. Consumo de energía en el horario pico registrado vs consumo de energía total en el año 2016.

Haciéndose un análisis de las observaciones con índice $k=1$, que son los datos con marcadores en azul, se observa que se corresponden con fines de semana, periodo vacacional, final y comienzo del curso académico y otros días de actividad reducida. Por esta razón se establece una nueva variable, denominada **Día-Tipo**. Esta variable se le asignará valor cero para días de actividad reducida y valor uno para días normales.

3.2 Modelo lineal

Como se explicó en el epígrafe 2.2, en Matlab se pueden obtener diferentes modelos de regresión utilizando el método de los mínimos cuadrados. Para el caso que interesa en esta investigación, se necesita obtener un modelo para el consumo pico y otro modelo para el consumo total, con el objetivo de estimar la estructura de consumo en el horario de máxima demanda.

Como primer paso se importaron los datos y se construyó la matriz de variables de entrada o predictores. Esta matriz tiene la siguiente estructura:

$$X = [X_1 \ X_2 \ X_3 \ X_4 \ X_5 \ X_6]$$

Cada columna representa una variable considerada en el modelo, las cuales son:

X₁: mes del año con valores de 1 a 12

X₂: día de la semana, 1 para el domingo y 7 para el sábado

X₃: 0 para día de poca actividad (incluye fines de semana, vacaciones, feriados y otros) y 1 para día de actividad normal

X₄: es el tipo de día 24 horas antes del pronóstico

X₅: es el consumo de energía en el horario pico el día antes del pronóstico, en kWh.

X₆: es el consumo de energía del día antes del pronóstico, en kWh.

Para el caso de las variables de salida, estos son dos vectores que contienen los valores del consumo de energía en el horario pico y del consumo de energía total del día, o sea:

$Y1 = ConsumoPico$

$Y2 = ConsumoTotal$

Los resultados del ajuste para el modelo de consumo pico se muestran en el **Anexo B** y la expresión obtenida para el modelo simplificado es:

$$\hat{Y}1 = 263.38 - 3.5594X_1 + 16.68X_2 + 156.04X_3 + 354.72X_4 - 0.7676X_5 - 0.1016X_6 + 0.5185X_1X_2 - 0.0081X_1X_5 - 6.5114X_2X_3 - 23.493X_3X_4 - 0.3096X_3X_5 + 0.0285X_3X_6 - 1.0049X_4X_5 - 0.0686X_4X_6 + 0.00055X_5X_6 - 2.5886X_2^2 + 0.0017X_5^2 \quad (3.1)$$

El coeficiente de correlación R^2 ajustado es 0.831 y la raíz del error medio cuadrático es 28.5 kWh. Los residuales se ajustan a una distribución normal como se muestra en la Figura 3.2.

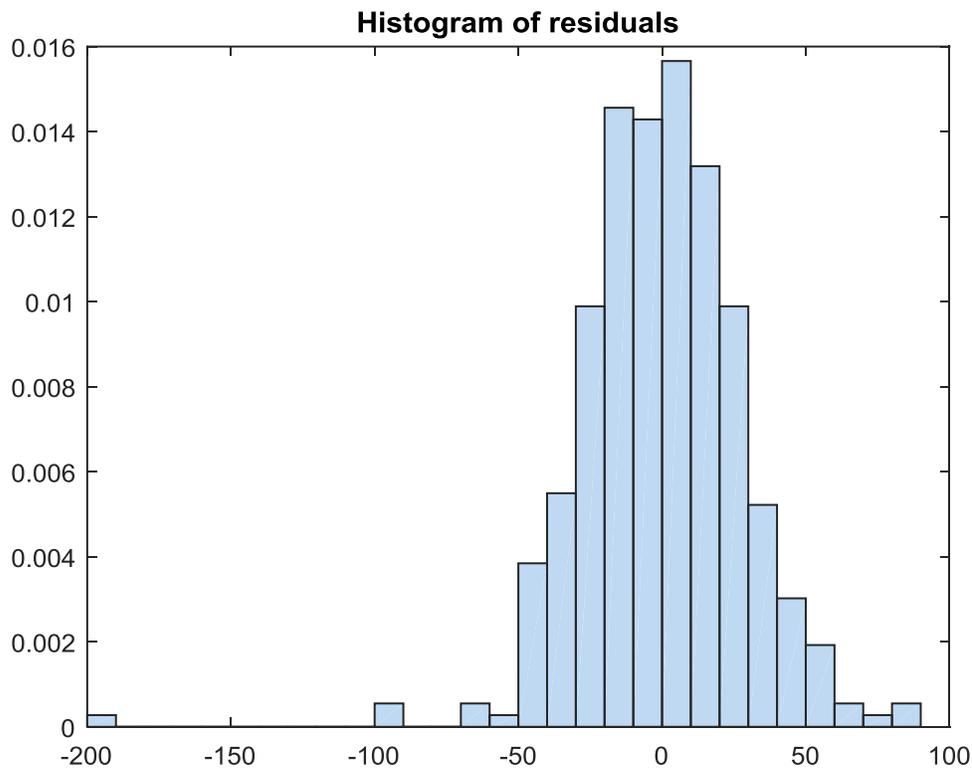


Figura 3.2 Histograma de los residuales del modelo simplificado de Consumo Pico

Para verificar la bondad del ajuste se grafican en un mismo plano los valores reales del consumo pico y los estimados por el modelo. Se puede apreciar en la Figura 3.3 que el modelo sigue con bastante exactitud el perfil de consumo pico real. No obstante, se

calcula el coeficiente de correlación entre ambas magnitudes (real y estimado) como una medida de exactitud según se planteó en el epígrafe 2.4. Los resultados se muestran en la Figura 3.4.

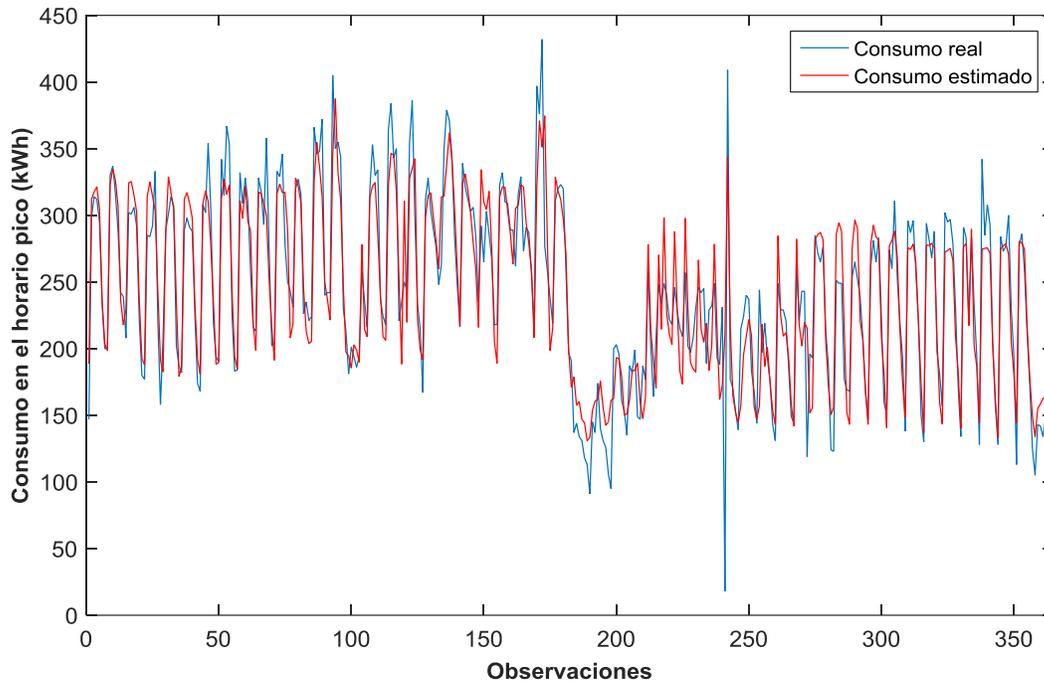


Figura 3.3 Comportamiento del consumo real y estimado por el modelo en el horario pico para el año 2016.

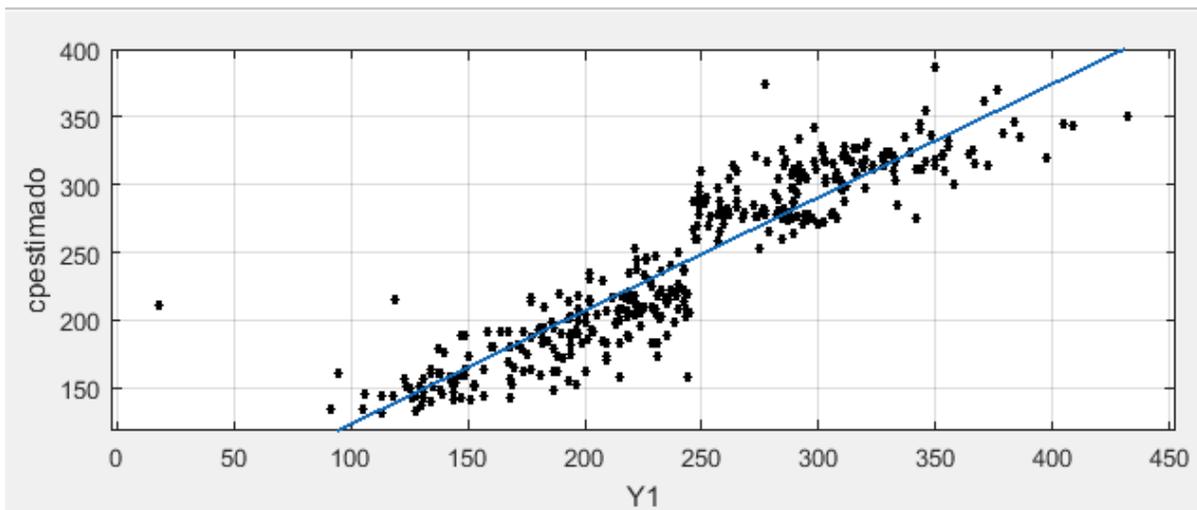


Figura 3.4 Correlación entre los valores estimados y reales del consumo pico. El coeficiente de correlación calculado según ecuación (2.1) es $R^2=0.839$.

Para este modelo el MAPE según la ecuación (2.2) es 11.97%

Para el consumo total, los resultados también se muestran en el Anexo B y la expresión es:

$$\hat{Y}_2 = 36.775 + 149.4X_1 + 107.21X_2 + 838.62X_3 + 90.176X_4 + 4.0946X_5 - 0.1966X_6 + 3.7296X_1X_2 + 36.507X_1X_4 - 0.4149X_1X_5 + 0.0219X_1X_6 - 87X_2X_3 + 40.417X_2X_4 - 149.84X_3X_4 - 0.3709X_4X_6 - 9.435X_1^2 - 17.148X_2^2 + 0.00018X_6^2 \quad (3.2)$$

El coeficiente de correlación R^2 ajustado es 0.751 y la raíz del error medio cuadrático es 219 kWh. Los residuales también se ajustan a una distribución normal como se muestra en la Figura 3.5.

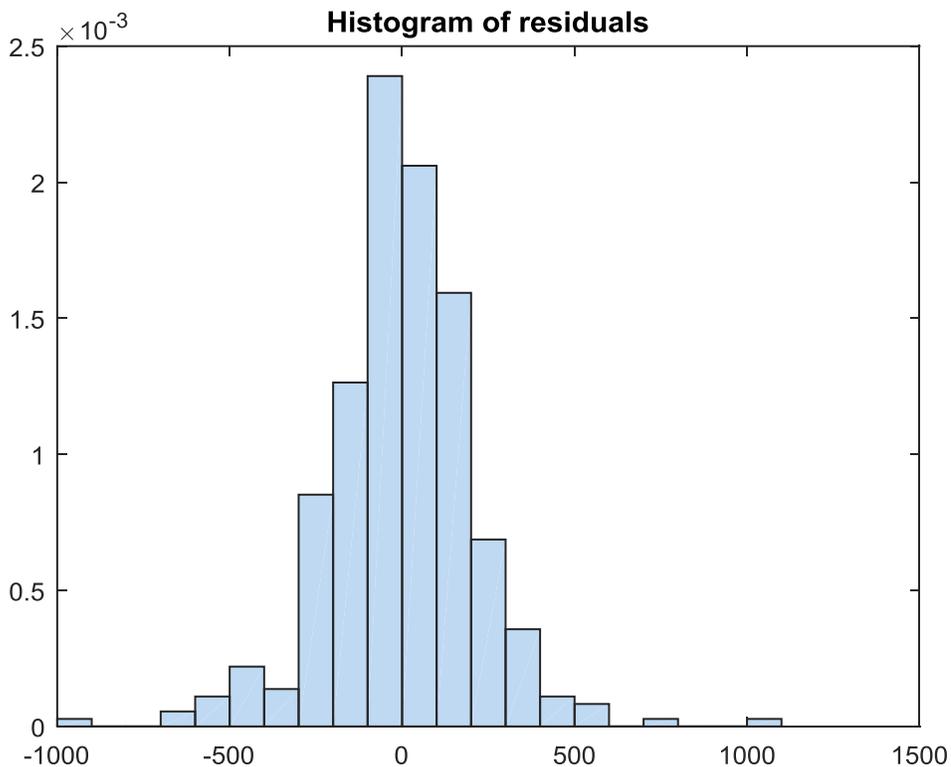


Figura 3.5. Histograma de los residuales del modelo simplificado de Consumo Total

De igual manera si se grafica el valor real y estimado del consumo total del día se puede ver que se corresponden con bastante similitud como se muestra en la Figura 3.6.

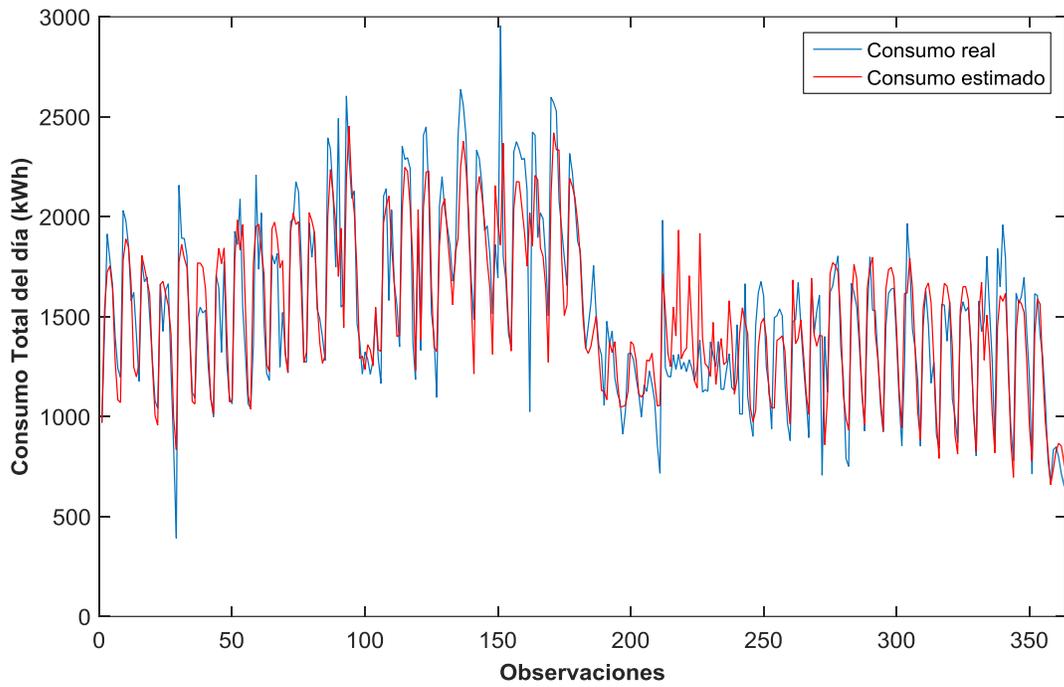


Figura 3.6. Comportamiento del consumo diario real y estimado por el modelo para el año 2016.

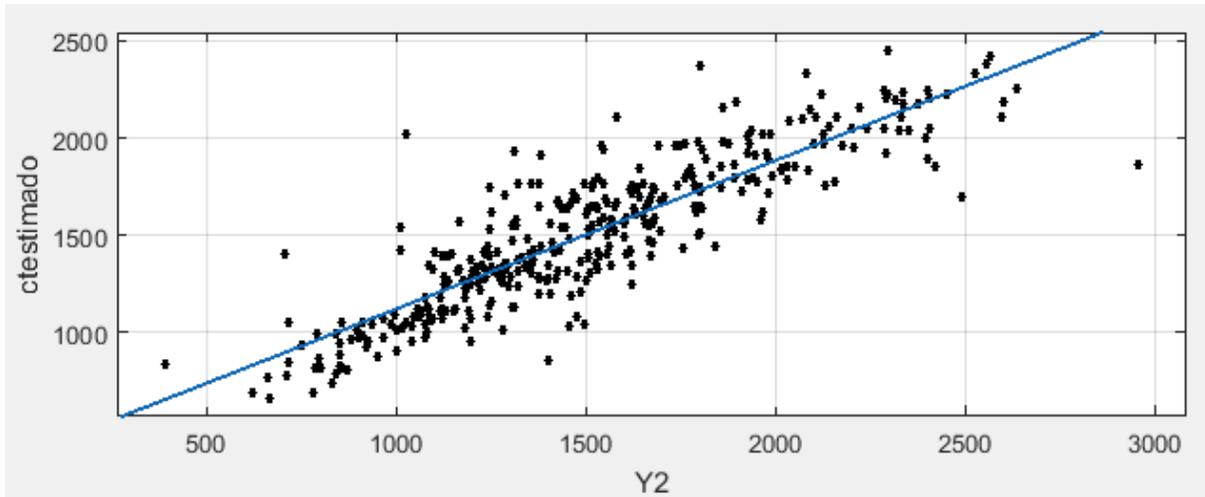


Figura 3.7. Correlación entre los valores estimados y reales del consumo total diario. El coeficiente de correlación calculado según ecuación (2.1) es $R^2=0.7618$.

El MAPE para el modelo de consumo diario total es de 10.72 %

3.3 Modelo con RNA

El modelo de red neuronal desarrollada en Matlab 2015 se puede representar como se muestra en la Figura 3.8. Los datos contienen 365 muestras correspondientes a cada día del año 2016 tomado como base, de los cuales 60% son usados para entrenamiento, 20% para validación y 20% para prueba.

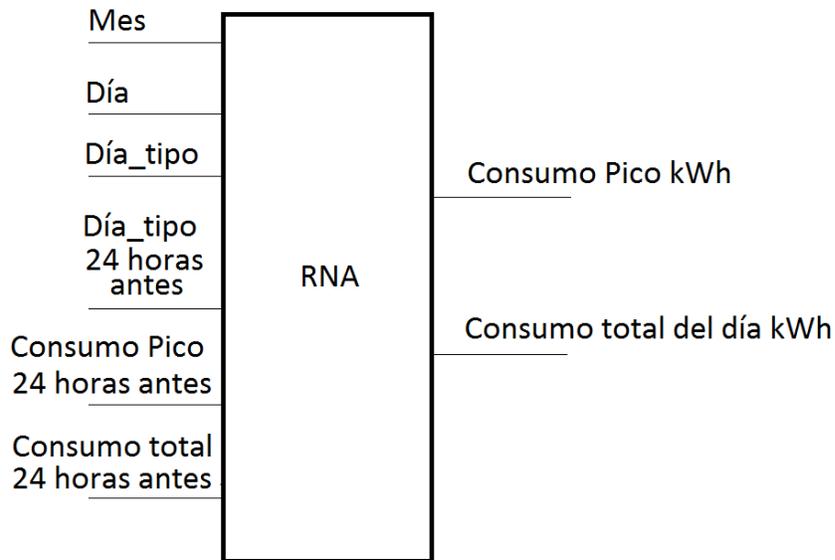


Figura 3.8 Esquema general del modelo de pronóstico basado en RNA

3.3.1. Normalización de los datos.

Las variables de entrada y los objetivos para el entrenamiento de la red, excepto el tipo de día que toma valores de 0 y 1, son normalizados mediante una transformación lineal a valores en el intervalo [0,1]. La normalización se realiza mediante la ecuación (3.3).

$$Xn_i = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (3.3)$$

Donde: Xn_i es la variable X_i normalizada, X_{max} y X_{min} son los valores máximos y mínimos de la variable X_i respectivamente.

Los valores máximos y mínimos para la normalización de los datos se muestran en la Tabla 3.1

Tabla 3.1 Valores extremos para la normalización de los datos.

Variable	Valor mínimo	Valor máximo
Mes	1	12
Día	1	7
Consumo pico	18 kWh	432 kWh
Consumo total	391.5 kWh	2956.48 kWh

3.3.2. Diseño de la red

Para el diseño de la red se adopta una configuración de dos capas ocultas y una capa de salida. La Tabla 3.2 muestra la arquitectura y el comportamiento de 6 redes probadas.

Tabla 3.2. Arquitectura y comportamiento de las redes ensayadas

Nombre de la red	Arquitectura de la red			MSE	R ²
	Capa 1	Capa 2	Capa 3		
RNA1	10	10	2	0.00277	0.93957
RNA2	10	20	2	0.00231	0.9264
RNA3	10	30	2	0.00176	0.89642
RNA4	10	40	2	0.00148	0.90463
RNA5	10	50	2	0.00161	0.91255
RNA6	10	100	2	0.000572	0.91955

Se puede apreciar que durante el entrenamiento, la primera red (RNA1) alcanza mayor valor de R². Este estadístico nos indica la capacidad de generalización de la red y es el coeficiente de correlación entre los valores del consumo pico y total resultantes del modelo y los valores de consumo pico y total medidos. Este coeficiente de correlación significa la fidelidad para reproducir el comportamiento de un objeto o proceso

simulado. La Figura 3.9 muestra la arquitectura de la red y las Figura 3.10 y 3.11 muestran la evolución del comportamiento y del coeficiente de correlación para todos los subconjuntos de datos de la RNA1.

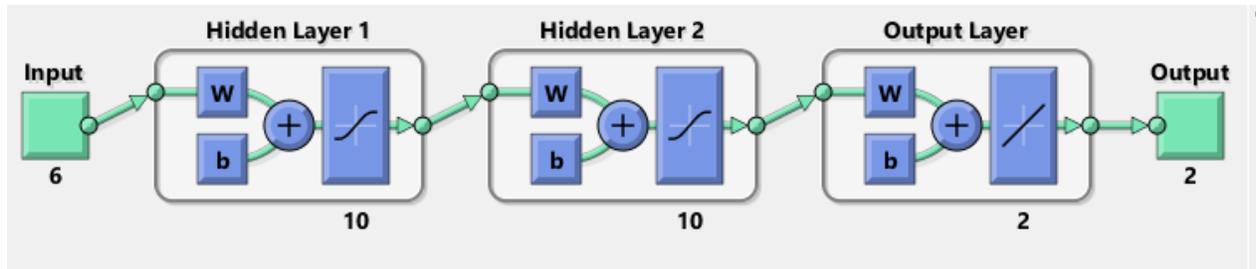


Figura 3.9. Arquitectura de la red neuronal RNA1 para pronóstico de consumo pico y total de la Universidad de Cienfuegos

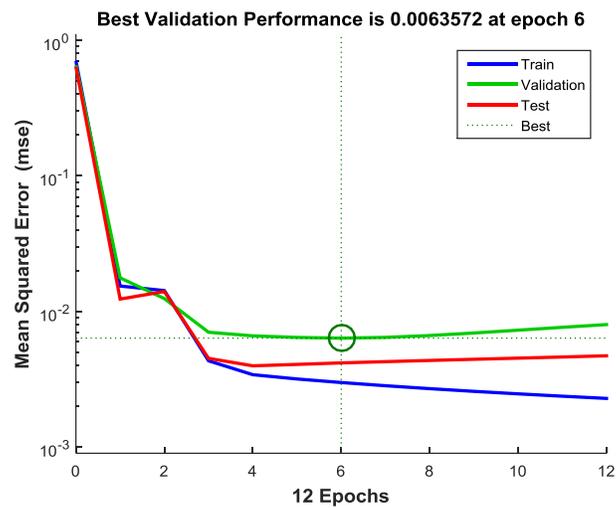


Figura 3.10 Comportamiento del error medio cuadrático MSE para los conjuntos de datos de entrenamiento, validación y prueba.

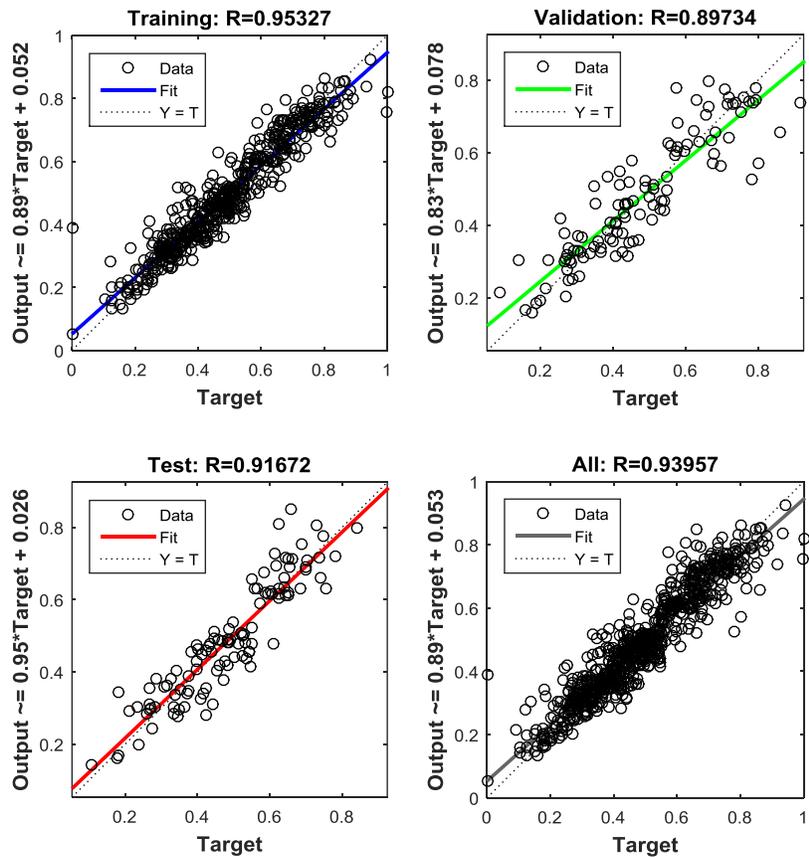


Figura 3.11. Coeficiente de correlación entre los valores dados por el modelo y los valores reales para los datos de entrenamiento, validación y prueba.

Una vez seleccionada la red RNA1 como la herramienta para pronosticar el consumo pico y total de la Universidad, se grafican los resultados de la red y los valores de consumo medidos para verificar la calidad del modelo. En las Figuras 3.12 y 3.13 se muestran estas gráficas comparativas para el consumo pico y para el consumo total respectivamente.

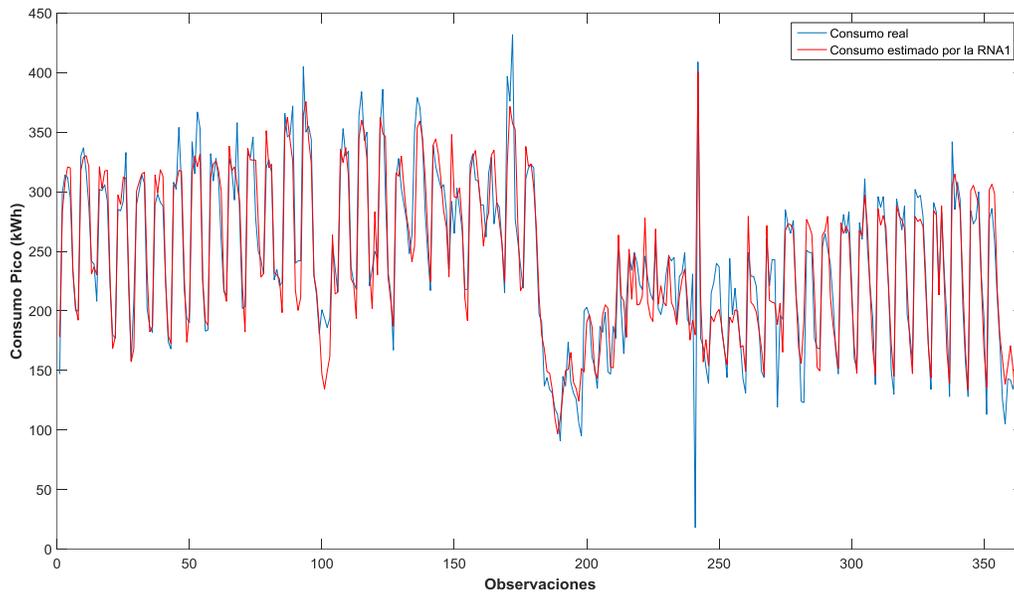


Figura 3.12 Consumo pico real y estimado por la red neuronal RNA1 para el año 2016

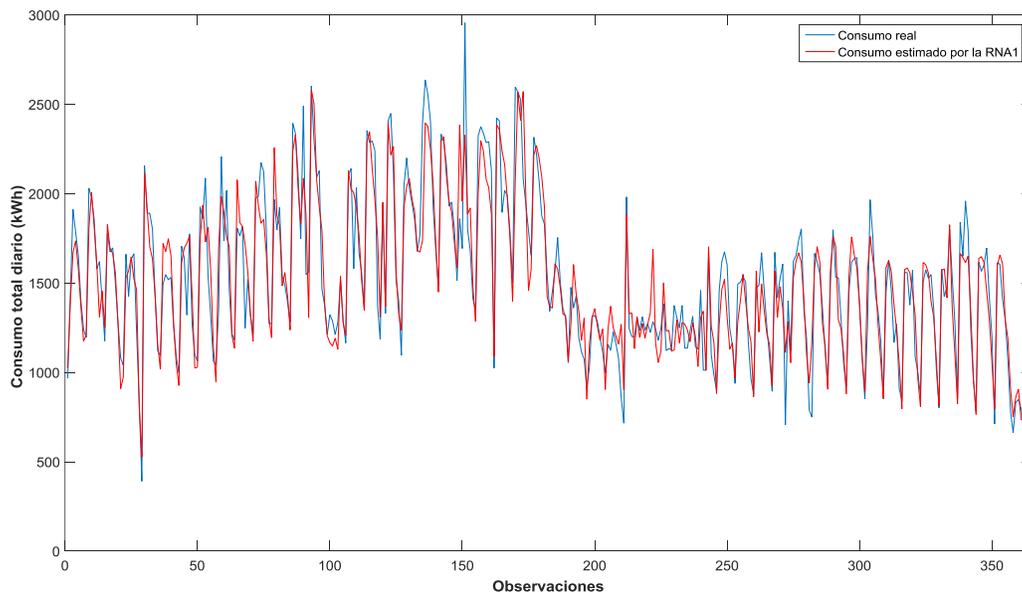


Figura 3.13 Consumo total real y estimado por la red neuronal RNA1 para el año 2016

El MAPE calculado según la ecuación (2.2) para el consumo pico es de 10.32% y para el consumo total es de 8.033%.

3.4 Comparación entre modelos

Los tipos de modelos obtenidos se comparan considerando el valor del porcentaje de error absoluto medio (MAPE). Como se muestra en la Figura 3.14, el modelo no lineal tiene un mejor comportamiento de acuerdo a este parámetro.

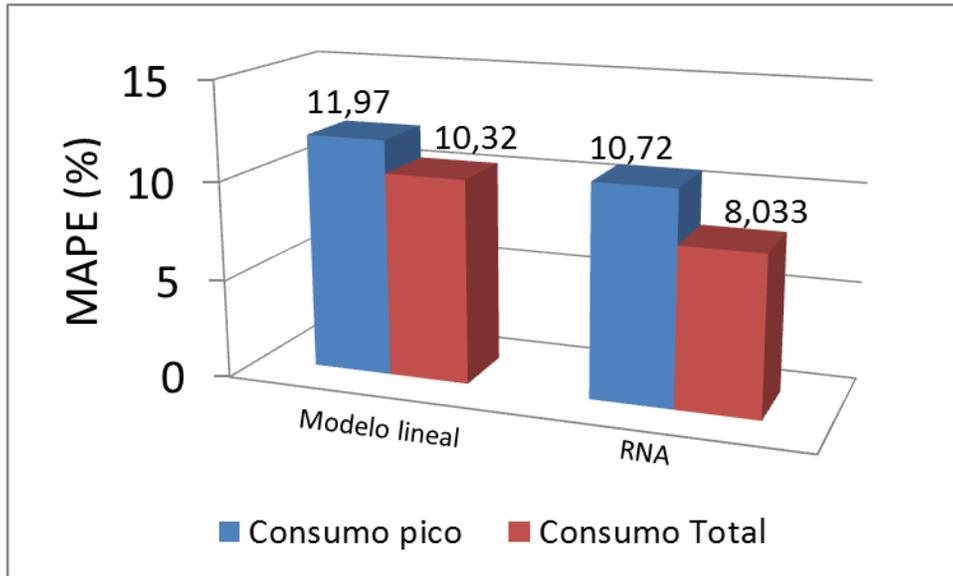


Figura 3.14. Comparación del MAPE para ambos tipos de modelos.

Para una mejor comparación de los modelos desde el punto de vista cuantitativo, se define el porcentaje de mejora en (Hao, Dipti, & Abbas, 2014). Este porcentaje de mejora se denomina λ y se determina como:

$$\lambda = \left(\frac{MAPE^{ML} - MAPE^{RNA}}{MAPE^{ML}} \right) \cdot 100\% \quad (3.4)$$

Donde: $MAPE^{ML}$ es el porcentaje de error absoluto medio del modelo lineal y $MAPE^{RNA}$ es el porcentaje de error absoluto medio del modelo neuronal a comparar.

El porcentaje de mejora del modelo neuronal con relación al modelo lineal, para el pronóstico del consumo pico y para el pronóstico del consumo total es de $\lambda_{\text{cons-pico}}=13.78\%$ y $\lambda_{\text{cons-total}}=25.07\%$.

Para el uso de la red neuronal como predictor de consumo se siguen los siguientes pasos:

1-Desarrollar el modelo neuronal con datos históricos.

2-Preparar la información de entrada correspondiente a 24 horas antes del pronóstico deseado

3-Reentrenar la red incluyendo los valores reales del día pronosticado para su actualización.

4-Repetir los pasos 2 y 3 cada vez que sea necesario.

3.5 Conclusiones parciales

1-Para el procesamiento de los datos se considera una nueva variable que caracteriza la actividad del día. Para esto se utilizó una herramienta de clusterización del Matlab que emplea el algoritmo kmean para el agrupamiento resultando dos tipos de días: Días de poca actividad (incluyen viernes, sábado y domingo, días feriados y periodo de vacaciones) y días de actividad normal.

2-Se desarrollaron modelos de regresión lineal múltiple para el consumo pico y para el consumo total del día que consideran variables temporales y de consumo energético del día previo al pronóstico. El porcentaje de error absoluto medio (MAPE) para ambos modelos es 11.97% y 10.72% respectivamente.

2-Se probaron varias arquitecturas de RNA, siendo la de mejor R^2 y por ende la que mejor capacidad de generalizar posee, la denominada RNA1 con una arquitectura 10-10-2. El porcentaje de error absoluto medio (MAPE) de este modelo para el año 2016 es de 10,32% y 8.033% para el consumo pico y para el consumo total respectivamente.

3-Aunque el modelo lineal es más fácil de entender, su exactitud es menor que la del modelo no lineal basado en RNA. El porcentaje de mejora de la red neuronal con relación al modelo de regresión lineal se basa en el parámetro estadístico MAPE y es 13.78% mejor que el lineal para el consumo pico y 25.07% mejor que el lineal para el consumo total.

CONCLUSIONES

1-En la Universidad de Cienfuegos existe un sistema de gestión establecido, pero no contempla la predicción del consumo en el horario pico y por lo tanto carece de las herramientas para tomar las medidas necesarias de manera anticipada que eviten sobreconsumos en este horario y excesos en la estructura de consumo del pico.

2-La literatura consultada refiere que existen diversos modelos de pronóstico en función de las variables a pronosticar y el periodo de tiempo que abarca el pronóstico, sin embargo, son escasos los reportes referidos a pronóstico energético en instituciones de educación superior o campus universitarios. La tendencia actual es a emplear modelos no lineales basados en RNA fundamentalmente.

3- Los métodos de regresión para pronósticos de consumo de energía a corto plazo han sido ampliamente utilizados, por ser más sencillos y definir una expresión matemática que puede ser evaluada fácilmente sin software especializados, pero los modelos basados en RNA (modelos no lineales) para la predicción han ganado mayor atención debido a su capacidad de aprendizaje, capacidad de generalización y su capacidad para encontrar relaciones complejas y no lineales entre variables de entrada y salida.

4-Para el procesamiento de los datos se consideró una nueva variable que caracteriza la actividad del día, como resultado de aplicar el algoritmo de clusterización kmean para el agrupamiento. Los tipos de días clasificados son: Días de poca actividad (incluyen viernes, sábado y domingo, días feriados y periodo de vacaciones) y días de actividad normal.

5-Se desarrollaron modelos de regresión lineal múltiple para el consumo pico y para el consumo total del día que correlacionan variables temporales y de consumo energético del día previo al pronóstico con el consumo pico y total. El porcentaje de error absoluto medio (MAPE) para ambos modelos es 11.97% y 10.72% respectivamente.

6-Se desarrolló una red neuronal de tres capas y arquitectura 10-10-2. El porcentaje de error absoluto medio (MAPE) de este modelo para el año 2016 es de 10,32% y 8.033% para el consumo pico y para el consumo total respectivamente. El modelo neuronal

supera al lineal en un 13.78% para el consumo pico y en un 25.07% para el consumo total.

7-El modelo de pronóstico obtenido puede ser incorporado como una herramienta al sistema de gestión energética de la universidad ya que permite estimar con 24 horas de anticipación el consumo de energía del día y del horario de máxima demanda y por lo tanto estimar la estructura de consumo del pico y tomar las medidas necesarias para evitar su exceso.

RECOMENDACIONES

1-Continuar investigando otras arquitecturas y tipos de RNA para mejorar la precisión del modelo.

2-Investigar la influencia en el modelo de variables climatológicas.

Bibliografía

- Abadie, P. (2010). Estudio sobre indicadores y costos en la educación superior.
- Amin-Naseri, M. R., & Soroush, A. R. (2008). Combined use of unsupervised and supervised learning for daily peak load forecasting. *Energy Conversion and Management*, 49, 1302-1308.
- Ates, S. A., & Durakbasa, N. M. (2012). Evaluation of corporate energy management practices of energy intensive industries in Turkey. *Energy*(45), 81-91.
- Badri, A., Ameli, Z., & Birjandi, A. M. (2012). Application of artificial neural networks and fuzzy logic methods for short-term load forecasting. *Energy Procedia*, 14, 1883-1888.
- Bagnasco, A., Saviozzi, M., Silvestro, F., Vinci, A., Grillo, S., & Zennaro, E. (2014). Artificial neural network application to load forecasting in a large hospital facility. *IEEE International Conference on Probabilistic Methods Applied to Power Systems (PMAPS)*, (págs. 1-6). Durham.
- Berardino, J., & Nwankpa, C. (2013). Inclusion of temporal effects in forecasting building electrical loads for demand resource planning. *IEEE Grenoble PowerTech (POWERTECH)*, (págs. 1-6). Grenoble.
- Borroto, A., Montesino, M., Viego, P., Odobez, N., & Soldatti, M. E. (mayo-agosto de 2014). Barreras y factores claves para promover la eficiencia energética en la industria. *Universidad y Sociedad*, 6(2), 30-36.
- Cabello, J. J., Sousa, V., Sagastume, A., Alvarez-Guerra, M., Haeseldonckx, D., & Vandecasteele, C. (2016). Tools to improve forecasting and control of the electricity consumption in hotels. *Journal of Cleaner Production*(137), 803-812.
- Cárdenas, J. J., Romeral, L., García, A., & Andrade, F. (2012). Load forecasting framework of electricity consumptions for an intelligent energy management system in the user-side. *Expert Systems Application*, 39, 5557-5565.
- Chan, D. Y.-L., Huang, C.-F., Lin, W.-C., & Hong, G.-B. (2014). Energy efficiency benchmarking of energy intensive industries in Taiwan. *Energy conversion and management*(77), 216-220.
- Correa, J., Borroto, A. E., Alpha, M., Roxana, G., Curbelo, M., & Díaz, A. M. (ene.-abr. de 2014). Diseño y aplicación de un procedimiento para la planificación energética según la NC-ISO 50001:2011. *Ingeniería Energética*, 35(1), 38-47.
- Dalvand, M., Azami, S., & Tarimoradi, H. (2008). long-term load forecasting of Iranian power grid using fuzzy and artificial neural network. *IEEE 43rd International universities Power Engineering Conference, UPEC 2008*, (págs. 1-4). Padova.
- David, F. R. (2005). *La gerencia estratégica*. Santa Fe, Bogotá: Legis Editores S.A.
- Díaz, A. M. (2012). *Propuesta de Norma para la implementación de la NC ISO 50001:2011 a partir de su integración con el Sistema de Gestión Total y Eficiente de la Energía*. (Trabajo de Diploma) Universidad de Cienfuegos: Carlos Rafael Rodríguez, Cienfuegos, Cuba. Cienfuegos.
- Escuadero, T. (2001). *Indicadores: Información Estratégica para el Sistema Universitario Español*. España.

- Eto, J. H. (1988). On using degree-days to account for the effects of weather on annual energy use in office buildings. *Energy Buildings*, 12, 113-127.
- Fernández, R. D. (2007). *Sistema de gestión y pronóstico de energía eléctrica en la UCF*. (Tesis de maestría), Universidad de Cienfuegos, CEEMA, Cienfuegos.
- Filik, U., Gerek, O., & Kurban, M. (2011). Hourly forecasting of long term electric energy demand using novel mathematical. *International Journal Innovation Computing, Information and Control*, 7(6), 3445-3557.
- Freeman, J., & Skapura, D. (1993). *Redes neuronales. Algoritmos, aplicaciones y técnicas de propagación*. México.
- Ghiassi, M., Zimbra, D. K., & Saidane, H. (2006). Medium term system load forecasting with a dynamic artificial neural network model. *Electric Power System Research*, 76, 302-316.
- Ghofrani, M., Ghayekhloo, M., Arabali, A., & Ghayekhloo, A. (2015). A hybrid short-term load forecasting with a new input selection framework. *Energy*, 81, 1-10.
- Giacone, E., & Mancó, S. (2012). Energy efficiency measurement in industrial processes. *Energy*(38), 331-345.
- Gielen, D., & Taylor, P. (2009). Indicators for industrial energy efficiency in India. *Energy*(34), 962–969.
- Gómez Sarduy, J. R., Gregio di Santo, K., & Saidel, M. (2016). Linear and non linear methods for prediction of peak load at University of sao paulo. *Measurement*, 78, 187-201.
- González, A. M. (29 de mayo de 2017). Energías Limpias. *Economía. Separata de Trabajadores*, pág. 02.
- González, Y. (2015). *Propuesta de Indicadores de Gestión para la Universidad de Cienfuegos*. (Trabajo de Diploma), Universidad de Cienfuegos, Facultad de Ingeniería, Cienfuegos.
- Granados, A. (2004). *Propuesta para la construcción de indicadores de gestión de la universidad pública a partir de la experiencia de la Universidad Nacional de Colombia*. Universidad Nacional de Colombia, Oficina Nacional de Planeación, Bogotá.
- Greco, C. (2010). *Indicadores de la gestión universitaria. Herramientas para la gestión estratégica y la mejora de la calidad*. Argentina: Universidad nacional de Quilmes,.
- Hao, Q., Dipti, S., & Abbas, K. (2014). Uncertainty handling using neural network-based prediction intervals for electrical load forecasting. *Energy*, 916-925.
- Hernández, L., Baladrón, C., Aguiar, J. M., Carro, B., Sanchez-Esguevillas, A. J., & Lloret, J. (2014). Artificial neural networks for short-term load forecasting in microgrids environment. *Energy*, 75, 252-264.
- Hernández, L., Baladrón, C., Aguiar, J. M., Carro, B., Sánchez-Esguevillas, A. J., Lloret, J., y otros. (2014). A survey on electric power demand forecasting: future trends in smart grids, microgrids and smart buildings. *IEEE Commun. Surveys Tutorials*, 16(3), 1460-1495.
- Hilera, J., & Martínez, V. (1995). *Redes neuronales artificiales: fundamentos, modelos y aplicaciones*. madrid.

- Honga, T., Wang, P., & White, L. (2015). Weather station selection for electric load forecasting. *Int. J. forecast.*, 31, 286-295.
- Hooshmand, R.-A., Amooshahi, H., & Parastegari, M. (2013). A hybrid intelligent algorithm based short-term load forecasting approach. *Electric Power Energy Systems*, 45, 313-324.
- IEA. (2015). *World Energy Outlook 2015 (Executive summary)*. International Energy Agency.
- IEA. (2016). *Key world energy statistical*.
- ISO. (2011). International Standard ISO 50001. Energy Management systems-Requirements with guidance for use.
- ISO. (2014). International Standard ISO 50006 standard. Energy management systems —Measuring energy performance using Measuring energy performance using energy baselines (EnB) and energy performance indicators (EnPI) —General principles and guidance.
- Kablan, M. M. (2003). Energy conservation projects implementation at Jordan's industrial sector: a total quality management approach. *Energy*(28), 1533-1543.
- Khotanzad, A., Afkhami-Rohani, R., Lu, T. L., Abaye, A., Davis, M., & Maratukulam, D. J. (1997). ANNSTLF- a neural network based electric load forecasting system. *IEEE Transaction on Neural Networks*, 8(4), 835-840.
- Kulkarni, S., & Simmon, S. (2012). A new spike based neural network for short-term electrical load forecasting. *IEEE Fourth International Conference on Computational intelligence and Communication networks*, (págs. 804-808). Mathura.
- Kulkarni, S., Simon, S. P., & Sundareswaran, K. (2013). A spiking neural network (SNN) forecast engine for short-term electrical load forecasting. *Application Soft Computing*, 13, 3628-3635.
- Lapido, M., Borroto, A., Gómez, J. R., & Montesino, M. (2015). La Red de Eficiencia Energética en acciones nacionales para la implementación de la norma NC ISO 50001. *Congreso Universidad*, IV(3), 1-14.
- Li, K., Sua, H., & Chu, J. (2011). Forecasting building energy consumption using neural networks and hybrid neuro-fuzzy system: a comparative study. *Energy Building*, 2893-2899.
- Lin, J. K., Tso, S. K., Ho, H. K., Mak, C. M., Yung, K. M., & Ho, Y. K. (2006). Study of climatic effects on peak load and regional similarity of load profiles following disturbances based on data mining. *Electric Power Energy Systems*, 28, 177-185.
- Matsuda, K., Hiroshi, Y., Kurosaki, D., & Kado, Y. (2015). Area-wide energy saving program in a large industrial area. *Energy*(90), 89-94.
- McKane, A. (2012). Continual Improvement of Energy Performance with ISO 50001. *International Workshop - ISO 50001 Energy management system* . Tokio.
- Mirowski, P., Chen, S., Ho, T. K., & Yu, C. N. (2014). Demand forecasting in smart grids. *Bell Labs Technology Journal*, 18(4), 135-158.

- Motamedi, A., Zareipour, H., & Rosehart, W. D. (2012). Electricity price and demand forecasting in smart grids. *IEEE Transaction on Smart Grid*, 3(2), 664-674.
- Nagi, J., Yap, K. S., Nagi, F., Tiong, S. K., & Ahmed, S. K. (2011). A computational intelligent scheme for the prediction of the daily peak load. *Application of Soft Computing*, 11, 4773-4788.
- ONN. (2011). *Norma Cubana NC ISO 50001: 2011*. Norma Cubana, La Habana.
- Ortiz Beviá, M. J., Ruiz de Elvira, A., & Alvarez García, F. J. (2014). The influence of meteorological variability on the mid-term evolution of the electric load. *Energy*, 76, 850-856.
- Ortíz, H. J. (2016). *Realización de un Diagnóstico Energético de Nivel 1 en la "Universidad de Ciencias Pedagógicas" de Cienfuegos*. (Trabajo de diploma), Universidad de Cienfuegos, Facultad de Ingeniería, Cienfuegos.
- Peña Acción, J. A. (2012). *Modelo de gestión del desempeño energético y de sostenibilidad ambiental en universidades cubanas*. Cienfuegos, Cuba.
- Phimpachanh, S., Chammongthai, K., Kumhom, P., & Sangswang, A. (2004). Using neural network for long-term peak load forecasting in Vientiane municipality. *TENCON 2004, IEEE Region 10 Conference*, 3, págs. 319-322.
- Pusnik, M., Al-Mansour, F., Sucic, B., & Gubina, A. F. (2016). Gap analysis of industrial energy management systems in Slovenia. *Energy*(108), 41-49.
- Ramesh, S., Natarajan, B., & Bhagat, G. (1988). Peak load prediction using weather variables. *Energy*, 13(8), 671-679.
- Saravanan, S., Kannan, S., & Thangaraj, C. (2012). India's electricity demand forecast using regression analysis and artificial neural networks based on principal components. *ICTACT Journal of Soft Computing*, 02(04), 365-370.
- Sotolongo, G., & Guzman, M. (2001). *Aplicaciones de las redes neuronales. El caso de la Bibliometría*. La Habana, Cuba.
- Sucic, B., Al-Mansour, F., Pusnik, M., & Vuck, T. (2016). Context sensitive production planning and energy management approach in energy intensive industries. *Energy*(108), 63-73.
- Timilsina, G. R., Hochman, G., & Fedets, I. (2016). Understanding energy efficiency barriers in Ukraine: Insights from a survey of commercial and industrial firms. *Energy*(106), 203-211.
- US DOE EERE. (s.f.). *Superior Energy Performance*. Recuperado el 2016, de <http://energy.gov/eere/amo/superior-energy-performance>
- Walpole, R. E., Myers, R. H., & Myers, S. L. (2008). *Probabilidad y estadística para ingenieros* (Sexta ed., Vol. II). La Habana, Cuba: Félix Varela.
- WEC. (2016). *Defining measures to accelerate the energy transition*. World Energy Council.
- WEC. (2016). *World Energy/Trilemma 2016. Defining measures to accelerate the energy transition*.

Xiao, L., Wang, J., Hou, R., & Wu, J. (2015). A combined model based on data pre-analysis and weight coefficients optimization for electrical load forecasting. *Energy*, 82, 1-26.

Xiaoli, Z., Rui, Y., & Qian, M. (2014). China's total factor energy efficiency of provincial industrial sectors. *Energy*(65), 52-61.

Zhang, B.-L., & Dong, Z.-Y. (2001). An adaptive neural-wavelet model for short term load forecasting. *Electric Power System research*, 59, 121-129.

Zhang, G., Patuwo, B. E., & Hu, M. Y. (1998). Forecasting with artificial neural networks: the state of the art. *Int. J. Forecast.*, 14, 35-62.

ANEXOS

Anexo A. Información de campo. Lecturas del metro contador de la Universidad para

Fecha		Pico	Día	Madrugada	Total	Reactivo	FP
Viernes	ene-01	952186	3377965	1220563	5550714	1551381	0,89
Sábado	ene-02	952368	3378458	1220965	5551791	1551965	0,88
Domingo	ene-03	952515	3378897	1221311	5552723	1552451	0,89
Lunes	ene-04	952814	3379586	1221723	5554123	1553023	0,93
Martes	ene-05	953128	3380707	1222166	5556001	1553754	0,93
Miércoles	ene-06	953440	3381735	1222576	5557751	1554432	0,93
Jueves	ene-07	953735	3382655	1222984	5559374	1555077	0,93
Viernes	ene-08	953968	3383384	1223387	5560739	1555692	0,91
Sábado	ene-09	954168	3384032	1223744	5561944	1556244	0,91
Domingo	ene-10	954368	3384637	1224100	5563105	1556782	0,91
Lunes	ene-11	954698	3385882	1224521	5565101	1557496	0,94
Martes	ene-12	955035	3387022	1224990	5567047	1558269	0,93
Miércoles	ene-13	955352	3388122	1225394	5568868	1559049	0,92
Jueves	ene-14	955640	3388966	1225806	5570412	1559721	0,92
Viernes	ene-15	955882	3389823	1226292	5571997	1560391	0,92
Sábado	ene-16	956121	3390552	1226695	5573368	1561093	0,89
Domingo	ene-17	956329	3391132	1227048	5574509	1561663	0,89
Lunes	ene-18	956631	3392159	1227464	5576254	1562401	0,92
Martes	ene-19	956932	3393100	1227861	5577893	1563131	0,91
Miércoles	ene-20	957238	3394047	1228270	5579555	1563834	0,92
Jueves	ene-21	957530	3394818	1228671	5581019	1564511	0,91
Viernes	ene-22	957752	3395503	1229012	5582267	1565131	0,90
Sábado	ene-23	957932	3396034	1229345	5583311	1565651	0,90
Domingo	ene-24	958109	3396540	1229667	5584316	1566155	0,89
Lunes	ene-25	958394	3397516	1230032	5585942	1566946	0,90
Martes	ene-26	958678	3398218	1230437	5587333	1567587	0,91
Miércoles	ene-27	958970	3399101	1230860	5588931	1568300	0,91
Jueves	ene-28	959303	3399917	1231340	5590560	1568981	0,92
Viernes	ene-29	959525	3400526	1231706	5591757	1569514	0,91
Sábado	ene-30	959683	3400850	1232032	5592565	1569896	0,90
Domingo	ene-31	959892	3400850	1232179	5592921	1570076	0,89
Lunes	feb-01	960181	3402025	1232833	5595039	1570998	0,92
Martes	feb-02	960482	3403134	1233276	5596892	1571741	0,93
Miércoles	feb-03	960796	3404217	1233730	5598743	1572461	0,93
Jueves	feb-04	961103	3405236	1234168	5600507	1573231	0,92
Viernes	feb-05	961305	3406043	1234552	5601900	1573860	0,91

Sábado	feb-06	961492	3406627	1234862	5602981	1574381	0,90
Domingo	feb-07	961674	3407199	1235162	5604035	1574892	0,90
Lunes	feb-08	961963	3407999	1235529	5605491	1575496	0,92
Martes	feb-09	962261	3408824	1235914	5606999	1576145	0,92
Miércoles	feb-10	962552	3409639	1236287	5608478	1576828	0,91
Jueves	feb-11	962840	3410469	1236661	5609970	1577502	0,91
Viernes	feb-12	963065	3411123	1236995	5611183	1577965	0,93
Sábado	feb-13	963239	3411687	1237306	5612232	1578486	0,90
Domingo	feb-14	963407	3412165	1237619	5613191	1578948	0,90
Lunes	feb-15	963715	3413092	1238051	5614858	1579622	0,93
Martes	feb-16	964017	3413977	1238467	5616461	1580270	0,93
Miércoles	feb-17	964371	3414378	1238994	5617743	1580825	0,92
Jueves	feb-18	964676	3415406	1239397	5619479	1581578	0,92
Viernes	feb-19	964895	3416020	1239790	5620705	1582132	0,91
Sábado	feb-20	965089	3416550	1240125	5621764	1582651	0,90
Domingo	feb-21	965279	3417065	1240444	5622788	1583184	0,89
Lunes	feb-22	965621	3418120	1240934	5624675	1583955	0,93
Martes	feb-23	965936	3419146	1241414	5626496	1584698	0,93
Miércoles	feb-24	966303	3420278	1241963	5628544	1585555	0,92
Jueves	feb-25	966656	3420887	1242503	5630046	1586213	0,92
Viernes	feb-26	966882	3421554	1242886	5631322	1586751	0,92
Sábado	feb-27	967065	3422096	1243186	5632347	1587272	0,89
Domingo	feb-28	967249	3422623	1243476	5633348	1587790	0,89
Lunes	feb-29	967581	3423419	1243664	5634664	1588351	0,92
Martes	mar-01	967890	3424626	1244309	5636825	1589336	0,91
Miércoles	mar-02	968218	3425638	1244658	5638514	1590057	0,92
Jueves	mar-03	968528	3426849	1245108	5640485	1590910	0,92
Viernes	mar-04	968786	3427620	1245498	5641904	1591603	0,90
Sábado	mar-05	969002	3428188	1245882	5643072	1592190	0,89
Domingo	mar-06	969215	3428729	1246262	5644206	1592764	0,89
Lunes	mar-07	969543	3429741	1246682	5645966	1593520	0,92
Martes	mar-08	969861	3430736	1247085	5647682	1594280	0,91
Miércoles	mar-09	970154	3431772	1247524	5649450	1595013	0,92
Jueves	mar-10	970512	3432108	1248030	5650650	1595530	0,92
Viernes	mar-11	970787	3432851	1248485	5652123	1596210	0,91
Sábado	mar-12	970989	3433525	1248882	5653396	1596782	0,91
Domingo	mar-13	971193	3434187	1249187	5654567	1597353	0,90
Lunes	mar-14	971526	3435299	1249670	5656495	1598121	0,93
Martes	mar-15	971855	3436427	1250151	5658433	1598964	0,92
Miércoles	mar-16	972201	3437716	1250643	5660560	1599829	0,93
Jueves	mar-17	972479	3439003	1251155	5662637	1600663	0,93

Viernes	mar-18	972729	3440008	1251652	5664389	1601402	0,92
Sábado	mar-19	972972	3440605	1252039	5665616	1601943	0,92
Domingo	mar-20	973203	3441211	1252427	5666841	1602479	0,92
Lunes	mar-21	973523	3442381	1252857	5668761	1603272	0,92
Martes	mar-22	973850	3443401	1253259	5670510	1603985	0,93
Miércoles	mar-23	974166	3444518	1253703	5672387	1604811	0,92
Jueves	mar-24	974392	3445356	1254128	5673876	1605495	0,91
Viernes	mar-25	974627	3446158	1254532	5675317	1606150	0,91
Sábado	mar-26	974848	3446884	1254934	5676666	1606780	0,91
Domingo	mar-27	975072	3447539	1255288	5677899	1607396	0,89
Lunes	mar-28	975438	3448952	1255856	5680246	1608230	0,94
Martes	mar-29	975784	3450348	1256404	5682536	1609139	0,93
Miércoles	mar-30	976132	3451506	1256957	5684595	1609958	0,93
Jueves	mar-31	976504	3452596	1257195	5686295	1610556	0,94
Viernes	abr-01	976744	3453813	1258182	5688739	1611351	0,95
Sábado	abr-02	976986	3454673	1258580	5690239	1612052	0,91
Domingo	abr-03	977228	3455537	1258988	5691753	1612786	0,90
Lunes	abr-04	977633	3457020	1259656	5694309	1613759	0,93
Martes	abr-05	977983	3458402	1260175	5696560	1614563	0,94
Miércoles	abr-06	978338	3459576	1260691	5698605	1615388	0,93
Jueves	abr-07	978682	3460822	1261182	5700686	1616249	0,92
Viernes	abr-08	978912	3461596	1261596	5702104	1616865	0,92
Sábado	abr-09	979125	3462320	1261989	5703434	1617496	0,90
Domingo	abr-10	979306	3462949	1262344	5704599	1618047	0,90
Lunes	abr-11	979507	3463598	1262769	5705874	1618682	0,90
Martes	abr-12	979701	3464235	1263179	5707115	1619292	0,90
Miércoles	abr-13	979887	3464820	1263572	5708279	1619879	0,89
Jueves	abr-14	980081	3465448	1263982	5709511	1620490	0,90
Viernes	abr-15	980338	3466204	1264440	5710982	1621101	0,92
Sábado	abr-16	980574	3466789	1264862	5712225	1621664	0,91
Domingo	abr-17	980790	3467304	1265248	5713342	1622210	0,90
Lunes	abr-18	981109	3468472	1265817	5715398	1622937	0,94
Martes	abr-19	981462	3469711	1266318	5717491	1623785	0,93
Miércoles	abr-20	981792	3470407	1266825	5719024	1624502	0,91
Jueves	abr-21	982126	3471537	1267347	5721010	1625265	0,93
Viernes	abr-22	982363	3472441	1267827	5722631	1625933	0,92
Sábado	abr-23	982587	3473274	1268280	5724141	1626564	0,92
Domingo	abr-24	982805	3473917	1268720	5725442	1627176	0,90
Lunes	abr-25	983169	3475268	1269311	5727748	1628079	0,93
Martes	abr-26	983553	3476542	1269892	5729987	1628832	0,95
Miércoles	abr-27	983896	3477901	1270437	5732234	1629771	0,92

Jueves	abr-28	984246	3479171	1271010	5734427	1630632	0,93
Viernes	abr-29	984467	3479885	1271402	5735754	1631152	0,93
Sábado	abr-30	984702	3480579	1271610	5736891	1631630	0,92
Domingo	may-01	984952	3481292	1272535	5738779	1632355	0,93
Lunes	may-02	985196	3481984	1272880	5740060	1632941	0,91
Martes	may-03	985551	3483351	1273515	5742417	1633857	0,93
Miércoles	may-04	985937	3484735	1274144	5744816	1634760	0,94
Jueves	may-05	986235	3485982	1274669	5746886	1635624	0,92
Viernes	may-06	986468	3486759	1275125	5748352	1636314	0,90
Sábado	may-07	986683	3487474	1275545	5749702	1636951	0,90
Domingo	may-08	986850	3488027	1275870	5750747	1637442	0,91
Lunes	may-09	987162	3489169	1276416	5752747	1638300	0,92
Martes	may-10	987490	3490452	1276955	5754897	1639135	0,93
Miércoles	may-11	987793	3491593	1277497	5756883	1639998	0,92
Jueves	may-12	988082	3492682	1278016	5758780	1640670	0,94
Viernes	may-13	988358	3493719	1278509	5760586	1641354	0,94
Sábado	may-14	988606	3494653	1278954	5762213	1641957	0,94
Domingo	may-15	988869	3495639	1279423	5763931	1642706	0,92
Lunes	may-16	989219	3497045	1280016	5766280	1643519	0,95
Martes	may-17	989598	3498603	1280666	5768867	1644395	0,95
Miércoles	may-18	989969	3500136	1281267	5771372	1645288	0,94
Jueves	may-19	990312	3501577	1281834	5773723	1646196	0,93
Viernes	may-20	990595	3502636	1282367	5775598	1646939	0,93
Sábado	may-21	990842	3503556	1282831	5777229	1647584	0,93
Domingo	may-22	991059	3504365	1283239	5778663	1648152	0,93
Lunes	may-23	991398	3505782	1283766	5780946	1648962	0,94
Martes	may-24	991719	3507179	1284288	5783186	1649769	0,94
Miércoles	may-25	992031	3508467	1284800	5785298	1650527	0,94
Jueves	may-26	992334	3509578	1285267	5787179	1651298	0,93
Viernes	may-27	992640	3510703	1285739	5789082	1651997	0,94
Sábado	may-28	992924	3511740	1286175	5790839	1652689	0,93
Domingo	may-29	993159	3512605	1286538	5792302	1653269	0,93
Lunes	may-30	993451	3513674	1286987	5794112	1653952	0,94
Martes	may-31	993716	3514644	1287395	5795755	1654590	0,93
Miércoles	jun-01	994019	3516470	1288172	5798661	1655693	0,93
Jueves	jun-02	994305	3517411	1288696	5800412	1656410	0,93
Viernes	jun-03	994572	3518288	1289185	5802045	1657078	0,93
Sábado	jun-04	994790	3519035	1289583	5803408	1657672	0,92
Domingo	jun-05	995008	3519717	1289982	5804707	1658167	0,93
Lunes	jun-06	995331	3521073	1290577	5806981	1659029	0,94
Martes	jun-07	995663	3522465	1291178	5809306	1659899	0,94

Miércoles	jun-08	995973	3523842	1291778	5811593	1660768	0,93
Jueves	jun-09	996282	3525208	1292339	5813829	1661580	0,94
Viernes	jun-10	996571	3526574	1292925	5816070	1662430	0,94
Sábado	jun-11	996860	3527804	1293486	5818150	1663241	0,93
Domingo	jun-12	997122	3528188	1293814	5819124	1663716	0,90
Lunes	jun-13	997438	3529714	1294345	5821497	1664562	0,94
Martes	jun-14	997767	3531208	1294879	5823854	1665460	0,93
Miércoles	jun-15	998040	3532293	1295366	5825699	1666208	0,93
Jueves	jun-16	998331	3533450	1295886	5827667	1667006	0,93
Viernes	jun-17	998618	3534591	1296398	5829607	1667792	0,93
Sábado	jun-18	998875	3535613	1296857	5831345	1668497	0,93
Domingo	jun-19	999090	3536467	1297241	5832798	1669086	0,93
Lunes	jun-20	999487	3538002	1297856	5835345	1669892	0,95
Martes	jun-21	999863	3539517	1298484	5837864	1670772	0,94
Miércoles	jun-22	1000295	3541102	1298945	5840342	1671685	0,94
Jueves	jun-23	1000572	3542270	1299533	5842375	1672420	0,94
Viernes	jun-24	1000830	3543355	1300079	5844264	1673155	0,93
Sábado	jun-25	1001068	3544356	1300584	5846008	1673890	0,92
Domingo	jun-26	1001287	3545278	1301048	5847613	1674312	0,97
Lunes	jun-27	1001598	3546719	1301562	5849879	1675123	0,94
Martes	jun-28	1001918	3548059	1302075	5852052	1675926	0,94
Miércoles	jun-29	1002241	3549321	1302511	5854073	1676625	0,95
Jueves	jun-30	1002561	3550534	1302804	5855899	1677316	0,94
Viernes	jul-01	1002820	3551503	1303356	5857679	1678021	0,93
Sábado	jul-02	1003017	3552314	1303852	5859183	1678601	0,93
Domingo	jul-03	1003208	3552929	1304338	5860475	1679133	0,92
Lunes	jul-04	1003345	3553609	1304923	5861877	1679713	0,92
Martes	jul-05	1003489	3554318	1305586	5863393	1680321	0,93
Miércoles	jul-06	1003623	3555275	1306200	5865098	1681032	0,92
Jueves	jul-07	1003754	3555940	1306859	5866553	1681652	0,92
Viernes	jul-08	1003872	3556537	1307450	5867859	1682209	0,92
Sábado	jul-09	1003985	3557111	1308019	5869115	1682744	0,92
Domingo	jul-10	1004076	3557570	1308474	5870120	1683173	0,92
Lunes	jul-11	1004221	3558223	1309102	5871546	1683721	0,93
Martes	jul-12	1004358	3558787	1309712	5872857	1684265	0,92
Miércoles	jul-13	1004532	3559354	1310348	5874234	1684718	0,95
Jueves	jul-14	1004672	3559787	1310919	5875378	1685246	0,91
Viernes	jul-15	1004803	3560190	1311450	5876443	1685737	0,91
Sábado	jul-16	1004929	3560577	1311961	5877467	1686209	0,91
Domingo	jul-17	1005035	3560903	1312390	5878328	1686606	0,91
Lunes	jul-18	1005130	3561373	1312803	5879306	1687134	0,88

Martes	jul-19	1005330	3561818	1313421	5880569	1687648	0,93
Miércoles	jul-20	1005533	3562328	1313977	5881838	1688184	0,92
Jueves	jul-21	1005729	3562793	1314552	5883074	1688661	0,93
Viernes	jul-22	1005890	3563190	1315138	5884218	1689114	0,93
Sábado	jul-23	1006043	3563546	1315693	5885282	1689543	0,93
Domingo	jul-24	1006178	3563870	1316182	5886230	1689922	0,93
Lunes	jul-25	1006365	3564279	1316693	5887337	1690396	0,92
Martes	jul-26	1006547	3564676	1317189	5888412	1690857	0,92
Miércoles	jul-27	1006746	3565111	1317732	5889589	1691361	0,92
Jueves	jul-28	1006895	3565535	1318271	5890701	1691805	0,93
Viernes	jul-29	1007042	3565905	1318782	5891729	1692253	0,92
Sábado	jul-30	1007229	3566098	1319210	5892537	1692591	0,92
Domingo	jul-31	1007406	3566298	1319499	5893203	1692895	0,91
Lunes	ago-01	1007668	3567079	1320388	5895135	1693824	0,90
Martes	ago-02	1007870	3567587	1320873	5896330	1694366	0,91
Miércoles	ago-03	1008034	3568081	1321366	5897481	1694923	0,90
Jueves	ago-04	1008243	3568497	1321889	5898629	1695451	0,91
Viernes	ago-05	1008491	3568962	1322434	5899887	1696032	0,91
Sábado	ago-06	1008725	3569400	1322947	5901072	1696578	0,91
Domingo	ago-07	1008974	3569866	1323493	5902333	1697160	0,91
Lunes	ago-08	1009214	3570324	1323982	5903520	1697705	0,91
Martes	ago-09	1009436	3570866	1324439	5904741	1698236	0,92
Miércoles	ago-10	1009654	3571309	1324952	5905915	1698755	0,91
Jueves	ago-11	1009900	3571786	1325463	5907149	1699279	0,92
Viernes	ago-12	1010128	3572282	1325930	5908340	1699790	0,92
Sábado	ago-13	1010343	3572750	1326377	5909470	1700301	0,91
Domingo	ago-14	1010552	3573230	1326884	5910666	1700783	0,93
Lunes	ago-15	1010809	3573771	1327419	5911999	1701333	0,92
Martes	ago-16	1011011	3574205	1327855	5913071	1701801	0,92
Miércoles	ago-17	1011208	3574611	1328314	5914133	1702254	0,92
Cambio de Metro		1011208	3574633	1328314	5914155	1702266	0,88
Jueves	ago-18	208	339	507	1054	432	0,93
Viernes	ago-19	439	954	985	2378	1058	0,90
Sábado	ago-20	685	1454	1496	3635	1556	0,93
Domingo	ago-21	927	1894	2013	4834	2063	0,92
Lunes	ago-22	1172	2480	2507	6159	2616	0,92
Martes	ago-23	1361	2986	2898	7245	3126	0,91
Miércoles	ago-24	1590	3427	3314	8331	3597	0,92
Jueves	ago-25	1822	3931	3758	9511	4113	0,92
Viernes	ago-26	2071	4481	4223	10775	4671	0,91
Sábado	ago-27	2264	4935	4671	11870	5175	0,91

Domingo	ago-28	2452	5424	5074	12950	5675	0,91
Lunes	ago-29	2683	6181	5495	14359	6394	0,89
Martes	ago-30	2665	6800	5857	15322	6943	0,87
Miércoles	ago-31	3074	7202	6008	16284	7383	0,91
Jueves	sep-01	3251	8110	6556	17917	8273	0,88
Viernes	sep-02	3421	8666	6899	18986	8786	0,90
Sábado	sep-03	3574	9162	7205	19941	9243	0,90
Domingo	sep-04	3713	9613	7484	20810	9660	0,90
Lunes	sep-05	3928	10433	7874	22235	10329	0,91
Martes	sep-06	4152	11375	8297	23824	11022	0,92
Miércoles	sep-07	4392	12344	8732	25468	11721	0,92
Jueves	sep-08	4629	13251	9159	27039	12367	0,92
Viernes	sep-09	4812	13914	9530	28256	12929	0,91
Sábado	sep-10	4980	14525	9871	29376	13446	0,91
Domingo	sep-11	5124	14997	10162	30283	13887	0,90
Lunes	sep-12	5368	15802	10576	31746	14486	0,93
Martes	sep-13	5565	16676	10978	33219	15051	0,93
Miércoles	sep-14	5784	17497	11445	34726	15664	0,93
Jueves	sep-15	5977	18370	11852	36199	16265	0,93
Viernes	sep-16	6152	18972	12212	37336	16802	0,90
Sábado	sep-17	6295	19466	12508	38269	17242	0,90
Domingo	sep-18	6426	19914	12777	39117	17670	0,89
Lunes	sep-19	6675	20642	13243	40560	18303	0,92
Martes	sep-20	6904	21408	13703	42015	18955	0,91
Miércoles	sep-21	7133	22400	14121	43654	19603	0,93
Jueves	sep-22	7354	23192	14534	45080	20180	0,93
Viernes	sep-23	7541	23853	14910	46304	20752	0,91
Sábado	sep-24	7690	24430	15239	47359	21250	0,90
Domingo	sep-25	7834	24888	15500	48222	21647	0,91
Lunes	sep-26	8095	25849	15919	49863	22263	0,94
Martes	sep-27	8316	26619	16314	51249	22940	0,90
Miércoles	sep-28	8559	27427	16760	52746	23569	0,92
Jueves	sep-29	8802	28334	17185	54321	24207	0,93
Viernes	sep-30	8921	28744	17331	54996	24510	0,91
Sábado	oct-01	9117	29287	17961	56365	25251	0,88
Domingo	oct-02	9310	29818	18327	57455	25810	0,89
Lunes	oct-03	9595	30690	18761	59046	26479	0,92
Martes	oct-04	9867	31589	19212	60668	27180	0,92
Miércoles	oct-05	10132	32553	19691	62376	27874	0,93
Jueves	oct-06	10408	33571	20169	64148	28616	0,92
Viernes	oct-07	10622	34237	20605	65464	29242	0,90

Sábado	oct-08	10810	34826	20988	66624	29796	0,90
Domingo	oct-09	10934	35209	21239	67382	30157	0,90
Lunes	oct-10	11057	35560	21484	68101	30487	0,91
Martes	oct-11	11308	36539	21889	69736	31246	0,91
Miércoles	oct-12	11557	37458	22309	71324	31932	0,92
Jueves	oct-13	11806	38315	22723	72844	32568	0,92
Viernes	oct-14	11983	39106	23084	74173	33169	0,91
Sábado	oct-15	12152	39656	23455	75263	33658	0,91
Domingo	oct-16	12320	40048	23791	76159	34084	0,90
Lunes	oct-17	12574	40831	24229	77634	34678	0,93
Martes	oct-18	12839	41888	24674	79401	35404	0,92
Miércoles	oct-19	13091	42700	25111	80902	35985	0,93
Jueves	oct-20	13330	43570	25500	82400	36576	0,93
Viernes	oct-21	13539	44228	25902	83669	37183	0,90
Sábado	oct-22	13706	44755	26225	84686	37669	0,90
Domingo	oct-23	13853	45217	26507	85577	38095	0,90
Lunes	oct-24	14115	46008	26876	86999	38700	0,92
Martes	oct-25	14396	46880	27308	88584	39393	0,92
Miércoles	oct-26	14661	47747	27782	90190	40063	0,92
Jueves	oct-27	14944	48624	28233	91801	40737	0,92
Viernes	oct-28	15169	49323	28661	93153	41402	0,90
Sábado	oct-29	15329	49906	28968	94203	41956	0,88
Domingo	oct-30	15480	50290	29254	95024	42321	0,91
Lunes	oct-31	15754	51082	29410	96246	42852	0,92
Martes	nov-01	16014	52165	30002	98181	43749	0,91
Miércoles	nov-02	16325	53135	30449	99909	44562	0,90
Jueves	nov-03	16578	53912	30824	101314	45174	0,92
Viernes	nov-04	16798	54612	31213	102623	45848	0,89
Sábado	nov-05	16992	55226	31554	103772	46437	0,89
Domingo	nov-06	17130	55664	31798	104592	46859	0,89
Lunes	nov-07	17426	56408	32175	106009	47472	0,92
Martes	nov-08	17713	57341	32552	107606	48161	0,92
Miércoles	nov-09	18009	58076	32949	109034	48754	0,92
Jueves	nov-10	18267	58624	33279	110170	49275	0,91
Viernes	nov-11	18486	59275	33648	111409	49901	0,89
Sábado	nov-12	18636	59740	33911	112287	50348	0,89
Domingo	nov-13	18766	60174	34158	113098	50766	0,89
Lunes	nov-14	19060	61007	34561	114628	51427	0,92
Martes	nov-15	19342	61869	34943	116154	52116	0,91
Miércoles	nov-16	19610	62603	35287	117500	52750	0,90
Jueves	nov-17	19898	63351	35793	119042	53545	0,89

Viernes	nov-18	20095	63864	36140	120099	54090	0,89
Sábado	nov-19	20276	64334	36459	121069	54590	0,89
Domingo	nov-20	20433	64741	36734	121908	55022	0,89
Lunes	nov-21	20735	65546	37100	123381	55677	0,91
Martes	nov-22	21030	66434	37460	124924	56421	0,90
Miércoles	nov-23	21327	67250	37843	126420	57131	0,90
Jueves	nov-24	21606	68097	38233	127936	57800	0,91
Viernes	nov-25	21836	68789	38634	129259	58481	0,89
Sábado	nov-26	22007	69304	38932	130243	58988	0,89
Domingo	nov-27	22141	69707	39166	131014	59385	0,89
Lunes	nov-28	22432	70585	39543	132560	60046	0,92
Martes	nov-29	22715	71327	39911	133953	60711	0,90
Miércoles	nov-30	22935	72305	40159	135399	61387	0,91
Jueves	dic-01	23218	73196	40755	137169	62046	0,94
Viernes	dic-02	23451	74055	41163	138669	62825	0,89
Sábado	dic-03	23645	74771	41503	139919	63475	0,89
Domingo	dic-04	23773	75242	41727	140742	63903	0,89
Lunes	dic-05	24115	76301	42136	142552	64695	0,92
Martes	dic-06	24400	77385	42385	144170	65485	0,90
Miércoles	dic-07	24708	78416	42974	146098	66229	0,93
Jueves	dic-08	25001	79502	43355	147858	67054	0,91
Viernes	dic-09	25206	80148	43710	149064	67664	0,89
Sábado	dic-10	25363	80641	43981	149985	68129	0,89
Domingo	dic-11	25491	81042	44201	150734	68508	0,89
Lunes	dic-12	25775	81948	44597	152320	69202	0,92
Martes	dic-13	26048	82815	44992	153855	69869	0,92
Miércoles	dic-14	26325	83704	45396	155425	70587	0,91
Jueves	dic-15	26625	84646	45819	157090	71329	0,91
Viernes	dic-16	26855	85382	46243	158480	72012	0,90
Sábado	dic-17	27049	85999	46599	159647	72585	0,90
Domingo	dic-18	27162	86359	46807	160328	72919	0,90
Lunes	dic-19	27439	87255	47217	161911	73608	0,92
Martes	dic-20	27725	88153	47607	163485	74366	0,90
Miércoles	dic-21	27984	88895	47983	164862	75024	0,90
Jueves	dic-22	28196	89623	48309	166128	75654	0,90
Viernes	dic-23	28369	90168	48634	167171	76273	0,86
Sábado	dic-24	28494	90561	48868	167923	76719	0,86
Domingo	dic-25	28599	90891	49065	168555	77094	0,86
Lunes	dic-26	28742	91287	49327	169356	77560	0,86
Martes	dic-27	28884	91700	49589	170173	78075	0,85
Miércoles	dic-28	29018	92064	49857	170939	78510	0,87

Jueves	dic-29	29167	92373	50082	171622	78883	0,88
Viernes	dic-30	29305	92657	50288	172250	79225	0,88
Sábado	dic-31	29434	92924	50483	172841	79547	0,88
Domingo	ene-01	29622	93479	50959	174060	80248	0,87
Lunes	ene-02	29733	93806	51240	174779	80661	0,87

Anexo B. resultados del análisis de regresión lineal múltiple para los modelos de pronóstico de consumo pico y consumo total

MCP1 = Linear regression model:

$y \sim$ [Linear formula with 28 terms in 6 predictors]

Estimated Coefficients:

	Estimate	SE	tStat	pValue
(Intercept)	185.8	52.387	3.5467	0.00044544
x1	3.1459	4.5033	0.69859	0.48529
x2	22.152	7.5167	2.9471	0.003432
x3	0	0	NaN	NaN
x4	0	0	NaN	NaN
x5	-0.26122	0.36777	-0.71028	0.47802
x6	-0.10808	0.045535	-2.3736	0.018175
x1:x2	0.37888	0.28904	1.3108	0.19082
x1:x3	-1.2685	1.1936	-1.0627	0.28866
x1:x4	3.5503	2.0942	1.6953	0.090938
x1:x5	-0.03897	0.022545	-1.7286	0.084805
x1:x6	0.0019249	0.0027373	0.70322	0.4824
x2:x3	-5.755	2.5322	-2.2727	0.023675
x2:x4	2.3002	2.9388	0.78271	0.43435
x2:x5	-0.04384	0.031247	-1.403	0.16153
x2:x6	0.0020066	0.004316	0.46492	0.64229
x3:x4	-16.063	13.835	-1.161	0.24645
x3:x5	-0.43062	0.12312	-3.4975	0.00053277
x3:x6	0.03206	0.017766	1.8046	0.072031
x4:x5	-0.7823	0.27812	-2.8128	0.0051998
x4:x6	-0.069675	0.026925	-2.5877	0.010081
x5:x6	0.00064834	0.00015955	4.0637	6.0189e-05

x1^2	-0.18711	0.17475	-1.0707	0.28508
x2^2	-2.3968	0.56475	-4.2441	2.8428e-05
x3^2	181.06	26.916	6.7268	7.4819e-11
x4^2	265.47	68.67	3.8659	0.00013289
x5^2	0.001087	0.00085735	1.2679	0.20571
x6^2	-1.2973e-05	1.2485e-05	-1.0391	0.2995

Number of observations: 364, Error degrees of freedom: 338

Root Mean Squared Error: 28.5

R-squared: 0.842, Adjusted R-Squared 0.831

F-statistic vs. constant model: 72.3, p-value = 1.48e-119

MCP1simp= step(MCP1,'NSteps',10)

1. Removing x3^2, FStat = NaN, pValue = NaN
2. Removing x4^2, FStat = NaN, pValue = NaN
3. Removing x2:x6, FStat = 0.21615, pValue = 0.64229
4. Removing x1:x6, FStat = 0.47212, pValue = 0.49249
5. Removing x2:x4, FStat = 0.91463, pValue = 0.33957
6. Removing x2:x5, FStat = 0.84899, pValue = 0.35749
7. Removing x1:x3, FStat = 0.99788, pValue = 0.31853
8. Removing x6^2, FStat = 0.97851, pValue = 0.32326
9. Removing x1^2, FStat = 1.0919, pValue = 0.29678
10. Removing x1:x4, FStat = 1.9688, pValue = 0.16148

MCP1simp = Linear regression model:

$y \sim$ [Linear formula with 18 terms in 6 predictors]

Estimated Coefficients:

	Estimate	SE	tStat	pValue
(Intercept)	263.38	37.845	6.9593	1.722e-11
x1	-3.5594	2.1352	-1.667	0.096422
x2	16.68	4.863	3.4301	0.00067639
x3	156.04	19.219	8.1191	8.3392e-15
x4	354.72	58.725	6.0404	3.9709e-09
x5	-0.76766	0.25313	-3.0326	0.0026072
x6	-0.10165	0.027668	-3.6738	0.0002768
x1:x2	0.51859	0.24072	2.1544	0.0319
x1:x5	-0.0081811	0.0088671	-0.92264	0.35684
x2:x3	-6.5114	2.0726	-3.1416	0.001825
x3:x4	-23.493	12.156	-1.9326	0.054105
x3:x5	-0.30967	0.10774	-2.8742	0.0043014
x3:x6	0.028522	0.015456	1.8454	0.065838
x4:x5	-1.0049	0.25434	-3.9508	9.4415e-05
x4:x6	-0.068606	0.025025	-2.7415	0.0064345
x5:x6	0.00055212	0.00013554	4.0735	5.7455e-05
x2^2	-2.5886	0.54868	-4.7178	3.4655e-06
x5^2	0.0017129	0.00078296	2.1878	0.029355

Number of observations: 364, Error degrees of freedom: 346

Root Mean Squared Error: 28.5

R-squared: 0.839, Adjusted R-Squared 0.831

F-statistic vs. constant model: 106, p-value = 8.61e-126

MCT1 = Linear regression model:

$y \sim$ [Linear formula with 28 terms in 6 predictors]

Estimated Coefficients:

	Estimate	SE	tStat	pValue
(Intercept)	7.6303	405.94	0.018796	0.98501
x1	158.5	34.896	4.5422	7.7729e-06
x2	84.58	58.247	1.4521	0.14741
x3	0	0	NaN	NaN
x4	0	0	NaN	NaN
x5	5.5449	2.8498	1.9457	0.052525
x6	-0.31807	0.35285	-0.90142	0.36801
x1:x2	3.7569	2.2398	1.6774	0.094404
x1:x3	-3.3256	9.2493	-0.35955	0.71941
x1:x4	41.019	16.228	2.5277	0.011939
x1:x5	-0.47318	0.1747	-2.7085	0.0071048
x1:x6	0.026712	0.021211	1.2593	0.20878
x2:x3	-91.392	19.622	-4.6576	4.6156e-06
x2:x4	29.125	22.773	1.2789	0.20181
x2:x5	0.014349	0.2421	0.059261	0.95278
x2:x6	0.020495	0.033445	0.6128	0.54042
x3:x4	-215.5	107.21	-2.0101	0.045218
x3:x5	0.095897	0.95407	0.10051	0.92
x3:x6	0.10205	0.13767	0.74126	0.45905
x4:x5	0.73797	2.1552	0.34242	0.73225
x4:x6	-0.44078	0.20864	-2.1126	0.035372
x5:x6	0.00021959	0.0012363	0.17762	0.85913
x1^2	-9.6293	1.3542	-7.1109	6.9775e-12
x2^2	-17.721	4.3762	-4.0494	6.3802e-05
x3^2	738.69	208.57	3.5416	0.00045381
x4^2	60.987	532.13	0.11461	0.90882

x5^2	-0.0039527	0.0066436	-0.59496	0.55227
x6^2	0.00016251	9.6746e-05	1.6798	0.09393

Number of observations: 364, Error degrees of freedom: 338

Root Mean Squared Error: 221

R-squared: 0.764, Adjusted R-Squared 0.747

F-statistic vs. constant model: 43.8, p-value = 2.13e-90

MCT1simp= step(MCT1,'NSteps',10)

1. Removing x3^2, FStat = NaN, pValue = NaN
2. Removing x4^2, FStat = NaN, pValue = NaN
3. Removing x2:x5, FStat = 0.0035119, pValue = 0.95278
4. Removing x3:x5, FStat = 0.0080918, pValue = 0.92838
5. Removing x5:x6, FStat = 0.053612, pValue = 0.81703
6. Removing x1:x3, FStat = 0.15001, pValue = 0.69877
7. Removing x4:x5, FStat = 0.21133, pValue = 0.64602
8. Removing x5^2, FStat = 0.5166, pValue = 0.47278
9. Removing x2:x6, FStat = 0.83484, pValue = 0.36152
10. Removing x3:x6, FStat = 0.56704, pValue = 0.45195

MCT1simp = Linear regression model:

y ~ [Linear formula with 18 terms in 6 predictors]

Estimated Coefficients:

	Estimate	SE	tStat	pValue
(Intercept)	36.775	280.67	0.13103	0.89583
x1	149.4	31.726	4.7091	3.6066e-06
x2	107.21	36.441	2.9421	0.0034794
x3	838.62	62.929	13.326	5.4836e-33
x4	90.176	247.44	0.36444	0.71575
x5	4.0946	1.1247	3.6406	0.00031354
x6	-0.19663	0.27073	-0.7263	0.46815

x1:x2	3.7296	1.8735	1.9907	0.047298
x1:x4	36.507	14.662	2.4898	0.013249
x1:x5	-0.41491	0.15775	-2.6302	0.0089155
x1:x6	0.021939	0.019456	1.1276	0.26026
x2:x3	-87	17.687	-4.9189	1.348e-06
x2:x4	40.417	16.448	2.4572	0.014492
x3:x4	-149.84	68.44	-2.1894	0.029232
x4:x6	-0.37096	0.13476	-2.7528	0.0062198
x1^2	-9.4357	1.2692	-7.4343	8.3355e-13
x2^2	-17.148	4.1396	-4.1424	4.3239e-05
x6^2	0.00018216	8.1343e-05	2.2394	0.025768

Number of observations: 364, Error degrees of freedom: 346

Root Mean Squared Error: 219

R-squared: 0.762, Adjusted R-Squared 0.751

F-statistic vs. constant model: 65.3, p-value = 6.94e-97