



Universidad de Cienfuegos “Carlos Rafael Rodríguez”  
Facultad de Ingeniería  
Departamento de Informática

**Predicción mensual del consumo de energía eléctrica en la Universidad de Cienfuegos usando Redes Neuronales.**

**Trabajo de diploma para optar por el título de Ingeniería en Informática**

**Autor:**

**María Karla Ruiz Chamizo.**

**Tutores:**

**Ing Gretter Torres Vázquez.**

**Ing Richard Darian Sánchez Rivero.**

**Consultante:**

**Dr. Eduardo Concepción Morales: jefe del departamento de ingeniería informática en la UCf.**

**Cienfuegos, Cuba**

**Curso 2022**

## **AGRADECIMIENTOS**

A mis padres, por ser el motor impulsor de mi vida, por guiarme y aconsejarme en cada paso y decisión que tomo, porque sin ellos mi trayectoria no hubiese sido la misma, son el alma de mi ser y mi motivo a seguir. A mi hermano, por obligarme a ser mejor cada día, por no permitirme caerme cuando creía que perdía la batalla, por ser mi mejor amigo y ser mi ejemplo de superación. Agradezco a mis profesores por todos los conocimientos que heredo gracias a sus clases. A mis compañeros, porque entre todos supimos crear un fuerte equipo, este recorrido juntos nunca se olvidará. A mis amigos, por darme ánimos en todo momento y estar al pendiente de mis resultados. Por último, agradecer a mis tutores que han sabido tenerme paciencia, ayudarme, aconsejarme, guiarme durante todo el proceso y no dejarme desamparada en ningún momento. ¡Muchas Gracias!

## **DEDICATORIA**

A mis padres, esos que pelean pero que te aman como solo un padre sabe, que sufre contigo cada momento de preocupación y que celebra a tu lado semestre tras semestre culminado. Padre, madre, gracias por las peleas, por las obligaciones, por no permitirme abandonar, por darme fuerzas aún sin saber de dónde ustedes la sacaban, por siempre saber qué decir, cómo decirlo y cuándo decirlo, no hubiese sido la misma sin ustedes a mi lado. Por todo su esfuerzo y amor es a ustedes a quienes va dedicado mi trabajo.

## **RESUMEN**

La presente investigación se realizó en la Universidad de Cienfuegos: Carlos Rafael Rodríguez (UCf), como alternativa de solución a las deficiencias en la gestión de la energía eléctrica. Debido a los problemas que enfrenta hoy día nuestro país en relación con la energía eléctrica, se hace entonces de vital importancia gestionarla y administrarla de la mejor manera posible. Este proceso de gestión y administración en la UCf se lleva a cabo de la siguiente manera: luego de recibir la asignación por la Empresa eléctrica, se procede entonces a distribuirla por los servicios que tiene la Universidad según la cantidad que requiera cada uno, en ocasiones algunos de estos servicios demandan más o menos energía de la planificada, lo cual causa inestabilidad. Es por ello entonces que surge la idea de llevar a cabo una investigación para la predicción del consumo.

La investigación por desarrollar lleva a cabo una serie de pasos para lograr la predicción del consumo energético mensual en la Universidad de Cienfuegos.

A través del documento de la investigación se describieron los elementos que conforman el análisis, diseño e implementación del modelo propuesto, para ello se utilizó el lenguaje de programación Python con las librerías para Machine Learning. Para la implementación se utilizó Anaconda, y la teoría de las Redes Neuronales Artificiales (RNA) para el desarrollo de los modelos a implementar. Se entrenaron los datos y se ajustaron para cada modelo propuesto, logrando definir uno que se ajuste a nuestras necesidades para la predicción del consumo MWh en la UCf.

**Palabras claves:** Predicción, Universidad, implementación, modelo, Redes Neuronales Artificiales.

## **RESUMEN EN INGLES**

The present investigation was carried out at the University of Cienfuegos: Carlos Rafael Rodríguez (UCf), as an alternative solution to the deficiencies in the management of electrical energy. Due to the problems that our country faces today in relation to electrical energy, it is therefore of vital importance to manage and administer it in the best possible way. This management and administration process at the UCf is carried out in the following way: after receiving the allocation from the Electric Company, it is then distributed among the services that the University has according to the amount required by each one, sometimes some of these services demand more or less energy than planned, which causes instability. That is why the idea of carrying out research for the prediction of consumption arises.

The research to be developed carries out a series of steps to achieve the prediction of monthly energy consumption at the University of Cienfuegos.

Through the research document, the elements that make up the analysis, design and implementation of the proposed model were described, for this the Python programming language was used with the libraries for Machine Learning. For the implementation, Anaconda was used, and the theory of Artificial Neural Networks (RNA) for the development of the models to be implemented. The data was trained and adjusted for each proposed model, managing to define one that meets our needs for the prediction of MWh consumption in the UCf.

**Keywords:** Prediction, University, implementation, model, Artificial Neural Networks

## Índice

<b>INTRODUCCIÓN</b> .....	<b>1</b>
SITUACIÓN PROBLEMÁTICA .....	4
ACTUALIDAD Y NECESIDAD DEL TRABAJO.....	4
OBJETIVOS ESPECÍFICOS: .....	5
APORTE PRÁCTICO DE LA INVESTIGACIÓN: .....	5
TAREAS DESARROLLADAS: .....	6
DESCRIPCIÓN CADA CAPÍTULO:.....	6
<b>CAPITULO I – FUNDAMENTACIÓN TEÓRICA</b> .....	<b>8</b>
INTRODUCCIÓN:.....	8
1.1 SITUACIÓN DEL CONSUMO MUNDIAL DE ENERGÍA.....	9
1.1.1 <i>Consumo de energía en Cuba</i> .....	11
1.1.2 <i>Consumo de portadores energéticos en el MES</i> .....	12
1.1.3 <i>Consumo de portadores energéticos UCf</i> .....	12
1.1.4 <i>Consumo de energía eléctrica en la UCf</i> .....	13
1.2 MODELOS MATEMÁTICOS PARA LA PLANIFICACIÓN DE LA ENERGÍA. ....	17
1.2.1 <i>Bases matemáticas aplicadas a los modelos de energía</i> .....	17
1.2.2 <i>Modelos de oferta de energía</i> .....	19
1.2.3 <i>Modelos de demanda de energía</i> .....	23
1.2.4 <i>Modelos estadísticos de pronóstico de energía</i> .....	27
1.3 REDES NEURONALES EN LA GESTIÓN DE LA ENERGÍA. ....	30
1.4 TENDENCIAS, METODOLOGÍAS Y TECNOLOGÍAS ACTUALES:.....	32
CONCLUSIONES.....	34
<b>CAPÍTULO II – ANÁLISIS Y DISEÑO DE LA PROPUESTA</b> .....	<b>36</b>
CAPÍTULO II: DISEÑO DEL EXPERIMENTO: .....	36
2.1 BASE DE CASOS, DESCRIPCIÓN DE LAS VARIABLES Y PREPARACIÓN DE LOS DATOS.....	36
2.1.1 <i>Las variables son descritas en la siguiente tabla:</i> .....	36
2.1.2 <i>Graficar serie temporal:</i> .....	37
2.1.3 <i>Descomposición de la serie:</i> .....	37
2.1.4 <i>Paseo aleatorio (randon walk):</i> .....	39
2.2. DESARROLLO DE MODELOS DE REDES NEURONALES PARA SERIES DE TIEMPO: .....	41
2.2.1 <i>Fragmentación de datos:</i> .....	43
2.2.2 <i>Ventanas de datos:</i> .....	43
2.2.3 <i>Aplicación de modelos de referencia de varios pasos:</i> .....	44
2.3 REDES NEURONALES: .....	47
2.3.1 <i>Modelo Lineal de varios pasos:</i> .....	47
2.3.2 <i>Función para configurar un modelo de aprendizaje y configurarlo a los datos:</i> .....	47
2.3.3 <i>Modelo Red neuronal profunda:</i> .....	49
CONCLUSIONES:.....	52
<b>CAPÍTULO III – DESCRIPCIÓN DE LA SOLUCIÓN PROPUESTA</b> .....	<b>53</b>
INTRODUCCIÓN:.....	53
3.1 RED NEURONAL RECURRENTE: .....	53
3.2 SE IMPLEMENTA LA ARQUITECTURA DEL MODELO LSTM PARA MODELO DE VARIOS PASOS: .....	54
3.3 LSTM AUTORREGRESIVO (ARLSTM):.....	55
CONCLUSIONES:.....	58
<b>CONCLUSIONES</b> .....	<b>60</b>
<b>RECOMENDACIONES</b> .....	<b>61</b>
<b>BIBLIOGRAFÍA</b> .....	<b>I</b>

## ÍNDICE DE FIGURAS

---

<b>FIGURA 1.1 CONSUMO HISTÓRICO DE PORTADORES ENERGÉTICOS. FUENTE: STATISTICAL REVIEW OF WORLD ENERGY 2019.....</b>	<b>10</b>
<b>FIGURA 1.2 CONSUMO MUNDIAL DE ENERGÍA PRIMARIA POR FUENTE. FUENTE: STATISTICAL REVIEW OF WORLD ENERGY 2019.....</b>	<b>11</b>
<b>FIGURA 1.3 CONSUMO ENERGÉTICO DE AMBAS SEDES. FUENTE .....</b>	<b>13</b>
<b>FIGURA 2.1 DESCRIPCIÓN DE LA SERIE TEMPORAL .....</b>	<b>37</b>
<b>FIGURA 2.2 COMPORTAMIENTO DE LA SERIE DE TIEMPO .....</b>	<b>38</b>
<b>FIGURA 2.3 TENDENCIA DE LA SERIE TEMPORAL .....</b>	<b>38</b>
<b>FIGURA 2.4 ESTACIONALIDAD DE LA SERIE TEMPORAL.....</b>	<b>39</b>
<b>FIGURA 2.5 RESIDUOS DE LA SERIE TEMPORAL .....</b>	<b>39</b>
<b>FIGURA 2.6 FUNCIÓN DE AUTOCORRELACIÓN .....</b>	<b>41</b>
<b>FIGURA 2.7 EJEMPLO DE VENTANA DE DATOS .....</b>	<b>44</b>
<b>FIGURA 2.8 MODELO BASE .....</b>	<b>46</b>
<b>FIGURA 2.9 REPETIR MODELO BASE .....</b>	<b>46</b>
<b>FIGURA 2.10 MODELO LINEAL .....</b>	<b>49</b>
<b>FIGURA 2.11. MODELO LINEAL Y MODELO RED NEURONAL PROFUNDA.....</b>	<b>50</b>
<b>FIGURA 2.12 MODELO DE RED NEURONAL PROFUNDA .....</b>	<b>51</b>
<b>FIGURA 2.13 ÍNDICE DEL MAE DE LOS MODELOS DESARROLLADOS.....</b>	<b>52</b>
<b>FIGURA 3.1 SALIDA DEL MODELO LSTM. ....</b>	<b>55</b>
<b>FIGURA 3.2 SALIDA DEL MODELO LSTM AUTORREGRESIVO. ....</b>	<b>58</b>
<b>MUCHAS PREDICCIONES ESTÁN MUY CERCA DE LOS VALORES REALES, A VECES INCLUSO SUPERPONIÉNDOLOS. ESTO INDICA QUE SE TIENE UN MODELO BASTANTE PRECISO.....</b>	<b>58</b>
<b>FIGURA 3.3 ÍNDICE DEL MAE DE LOS MODELOS DESARROLLADOS.....</b>	<b>58</b>

## ÍNDICE DE TABLAS

---

<b>TABLA 1.1 PRODUCCIÓN NACIONAL DE ENERGÍA .....</b>	<b>12</b>
<b>TABLA 2.1 DESCRIPCIÓN DE LAS VARIABLES UTILIZADAS.....</b>	<b>36</b>
<b>TABLA 2.2 VENTANA DE DATOS .....</b>	<b>43</b>

## INTRODUCCIÓN

En la actualidad, cuando alguien actúa sobre uno de los interruptores de la casa o del trabajo, no pasa por su mente la posibilidad de que al tiempo que enciende o apaga una lámpara, indirectamente, está emitiendo una orden a varias centrales eléctricas, que están obligadas a incrementar o a reducir su generación para atender las necesidades del cliente. La consecuencia inmediata es que la generación producida, por el conjunto de generadores del sistema, debe ajustarse al consumo de energía demandada en cada uno de estos instantes. [1]

La disponibilidad de energía está fuertemente ligada al nivel de bienestar, a la salud y duración de vida de los seres humanos, actualmente en el mundo el 80% de la producción de energía se produce a través de los combustibles fósiles como el carbón, gas natural y el petróleo. La disponibilidad de energía eléctrica, uno de los más claros indicadores del desarrollo, se emplea como señal de crecimiento económico. La demanda mundial de electricidad está creciendo rápidamente en los últimos tiempos a un ritmo vertiginoso. [1]

La posibilidad de pronosticar la demanda de energía eléctrica es una de las alternativas que en las últimas décadas se ha venido proponiendo a partir de métodos tales como: Tendencias históricas simples, regresiones, paramétricos y la aplicación de inteligencia artificial. [2]

El incremento de la eficiencia energética en las Universidades es un tema ampliamente estudiado, no sólo por la importancia que reviste en el impacto socioambiental, como por la complejidad del análisis a partir de la dinámica de los procesos universitarios. [2]

Las estrategias de ahorro de energía pueden dividirse en dos grandes categorías: estrategias estructurales y estrategias informacionales. Las estrategias estructurales son aquellas que propician cambios que favorecen el entorno en función de la eficiencia energéticas, para lo cual son necesarias inversiones financieras, (por ejemplo: mejora de aislamientos, uso de equipos eficientes, etc.). Las estrategias informacionales se relacionan con la educación de los consumidores en función de lograr un cambio de su motivaciones y percepciones del problema del consumo de energía. Generalmente, el mayor impacto en la eficiencia energética se logra a partir de la combinación de ambas estrategias. [1]

Muchas han sido las investigaciones realizadas a lo largo de todo el mundo con el propósito de lograr predecir el consumo próximo de una institución dado los consumos anteriores. Para ello se ha utilizado la inteligencia artificial como base para su desarrollo. A continuación, se muestra un pequeño resumen de alguna de estas investigaciones.

En un estudio realizado en la Universidad de Oviedo se explora la aplicabilidad de los modelos neuronales en el terreno de la economía cuantitativa como instrumento de modelización y predicción no paramétrica con el objetivo de predecir la evolución de la demanda horaria de energía eléctrica. Para ello se implementó un sencillo modelo neuronal en Matlab. En el mismo se construyó un modelo multicapa en el cual. La capa de entrada estaría compuesta por seis unidades que identificarían cada uno de los factores explicativos seleccionados, la capa de salida contaría solo con una unidad que representaría el valor de la carga eléctrica asociado a cada vector input presentado a la red. Por último, la capa oculta contaría con un número variable de neuronas. Se utilizaron diferentes datos de entrada entre los que se encontraban: clima, día de la semana, carga eléctrica, etc., los cuales fueron de gran utilidad para la confección y desarrollo del modelo matemático. [3]

El entrenamiento se llevó a cabo con una muestra de 8760 observaciones y para determinar el valor óptimo de los parámetros que define la red se recurrió al método de ensayo y error, donde el modelo neural que se propuso fue capaz de predecir la evolución horaria de la demanda eléctrica, con una precisión del 98%. Además, se demostró la incidencia que presentan determinadas variables como la temperatura o día de la semana en la evolución de la curva de carga eléctrica. [3]

Se analizó además otra importante investigación realizada en La Universidad de Las Tunas donde su objetivo radicaba en predecir la demanda de energía eléctrica usando Redes Neuronales. En dicha investigación se estudiaron los principales factores influyentes en el consumo de energía eléctrica en el sector público del país. Se determinan las principales variables influyentes en el consumo de energía eléctrica. Se analizaron los métodos de pronóstico de consumo de energía eléctrica más usados escogiéndose las redes neuronales artificiales por ser el más preciso. Se creó, simuló y validó una red neuronal para el pronóstico del consumo de energía eléctrica obteniéndose un error de aproximación de 5,87 %, debido a la existencia de pocos datos en el

entrenamiento. Se comprobó la validez del método propuesto al comparar los resultados pronosticados, resultando una diferencia de 31,77 MWh. Con este valor obtenido se pudieron determinar las potencialidades técnicas de ahorro, así como los beneficios económicos. [2]

En la Universidad Marta Abreu de Las Villas hace algunos años se desarrolló un proyecto con el objetivo de: Predecir la demanda energética utilizando Redes Neuronales. En esta investigación se realizó análisis de todos los métodos y variantes posibles para realizar con éxito la predicción necesaria, llegando a la conclusión que la manera óptima fue usando Series Cronológicas de tiempo, estas efectúan la predicción de la demanda de energía eléctrica analizando la trayectoria de los datos históricos y proyectándola en el futuro. Utilizando entonces juegos de datos de miles y miles de variables en conjunto con los algoritmos más precisos utilizados para Redes Neuronales fue así como se logró implementar una solución óptima. El entrenamiento de la red fue el último paso decisivo, el cual fue desarrollado empleando un Software confeccionado sobre MatLab a partir del empleo con sus herramientas para el trabajo con las RNA. [1]

El modelo neuronal propuesto ha sido capaz de predecir la evolución horaria de la demanda eléctrica con una precisión del 98%.

Para implementar estrategias de eficiencia energética es imprescindible el estudio de los patrones de consumo en el tiempo. Los estudios realizados en la universidad de Cienfuegos en este sentido han estado dirigidos, fundamentalmente, a identificar la influencia en el consumo de energía eléctrica de los diferentes factores que definen el nivel de actividad del centro.

Tal es el caso de la investigación realizada por Ana Margarita Díaz Rodríguez, con el objetivo general de obtener un modelo matemático que permita predecir futuros consumos de la energía eléctrica en el centro. En este trabajo sólo se tuvo en cuenta las variables internas identificadas en estudios anteriores. Aunque el modelo obtenido describe adecuadamente el fenómeno estudiado, la precisión de las estimaciones que pueden realizarse con él, es baja. Por tanto, es necesario encontrar un método de análisis matemático de los datos que definen el comportamiento del consumo de energía eléctrica de la universidad, que permita mayor precisión en los pronósticos a mediano plazo.

Diferentes estudios refieren el uso de redes neuronales artificiales (RNA) en modelos para el pronóstico a mediano plazo del consumo de energía en función de diferentes factores endógenos y exógenos del sistema. Estos modelos de RNA, pueden realizar múltiples funciones como resultado de un entrenamiento (aprendizaje) y dentro de sus ventajas está la elevada velocidad de procesamiento, así como su fácil aplicación a tecnologías disímiles. Su implementación en las estrategias de eficiencia energética permite, además de pronosticar demandas y gastos futuros de portadores, sugerir estrategias de ahorro, mantenimiento e impacto ambiental, tomar decisiones de control o explotación y establecer la operación más económica del sistema de consumo de energía eléctrica de una institución.

### **Situación Problemática**

En la Universidad de Cienfuegos Carlos Rafael Rodríguez se realiza mensualmente la asignación del consumo para cada una de las instalaciones en correspondencia con lo asignado por la Empresa Eléctrica a la institución, así como la demanda energética que contemple cada uno de estos servicios. Hoy en día se hace muy difícil realizar esta asignación puesto que todas las instalaciones de la universidad no consumen la misma cantidad de energía todos los meses y en ocasiones ocurre derroche o carencia de esta, es entonces que surge la necesidad de crear una herramienta que permita predecir el consumo necesario mensual.

Teniendo en cuenta lo anterior se identifica como **problema a resolver** ¿Cómo predecir el consumo de energía eléctrica en la Universidad de Cienfuegos?

### **Actualidad y necesidad del trabajo**

A través de la historia, el desarrollo del modelo económico del mundo ha sido polémica año tras año, ya que en dependencia del nivel de desarrollo con el que cuente un país, entonces se corresponderá su economía. Al hablar de economía no podemos obviar un factor decisivo para el desarrollo de cualquier región, hablamos entonces de la electricidad. El consumo y uso adecuado de la energía eléctrica juega un papel fundamental en la administración de un centro o institución. En Cuba, la energía eléctrica constituye una preocupante diaria, por lo que se exhorta a todos a contribuir con el ahorro energético.

En la Universidad de Cienfuegos se dispone de un plan de consumo mensual para la utilización energética necesaria en la correcta ejecución de los procesos docentes, educativos y administrativos. Con el propósito de gestionar de una mejor manera el consumo de la institución se hace necesario crear un programa, investigación o ejercicio, capaz de según los datos recibidos de los micro contadores del centro, lograr pronosticar el consumo del mes próximo distribuido entonces entre los diferentes edificios y los variados equipos dentro de la misma.

Se define como **objeto de estudio**: técnicas de aprendizaje para la predicción de series de tiempo.

El **campo de acción de la investigación** es: los modelos de aprendizaje para el pronóstico de series de tiempo del consumo de energía eléctrica en la Universidad de Cienfuegos.

Se plantea como **idea a defender** que: con la creación de un modelo, basado en técnicas de aprendizaje automático, posibilite predecir el consumo eléctrico en la Universidad de Cienfuegos, permitiendo una mejor gestión energética.

La labor científico-investigativa está encaminada a dar cumplimiento al siguiente **objetivo general**:

Diseñar e implementar un modelo utilizando redes neuronales capaz de predecir el consumo de energía mensualmente.

#### **Objetivos Específicos:**

1. Estudiar el comportamiento de los datos.
2. Preparar los datos.
3. Elegir un modelo de red neuronal para predicción.
4. Entrenar el modelo haciendo uso de varias arquitecturas neuronales.

**Aporte Práctico de la investigación:** la presente investigación será de gran ayuda para lograr la predicción mensual del consumo energético en la Universidad de Cienfuegos Carlos Rafael Rodríguez. Además, demostrará cual es el modelo de red neuronal que nos brinda las predicciones más acertadas haciendo uso de nuestros datos con el que luego se pueda desarrollar un entrenamiento a los datos obteniendo los valores posibles para el consumo de MWh para los próximos meses.

**Tareas desarrolladas:** la presente investigación se ha llevado a cabo con un orden lógico y realizando un conjunto de tareas, las cuales se encuentran asociadas a cada uno de los objetivos específicos.

- 1- Dentro del estudio del comportamiento de los datos se realiza:
  - a- Utilizar el método estadístico de series de tiempo y graficar los datos para observar el comportamiento del consumo analizando las variables asociadas al consumo.
  - b- Descomponer la serie en sus tres componentes: Estacionalidad, Tendencia y Residuos.
  - c- Analizar si nuestra serie es estacionaria y si estamos en presencia de un Paseo Aleatorio.
- 2- Como preparación de los datos se realizó:
  - a- División de los datos en tres esferas: 70% entrenamiento, 20% validación y 10% prueba.
  - b- Escalar los datos entre valores de 0 y 1 para mejorar el desempeño a la hora de entrenar el modelo.
- 3- Selección del modelo de red neuronal para la predicción:
  - a- Análisis entre los diferentes modelos de redes neuronales existentes.
  - b- Identificar el modelo de Varios Pasos, donde definiremos más de un paso del tiempo en el futuro.
- 4- Por último, se llevó a cabo el proceso de entrenamiento y selección del modelo final.

### **Descripción cada capítulo:**

#### **Capítulo 1:**

Dentro del capítulo uno, se exponen los principales aspectos asociados al dominio del problema. Se realiza un análisis de los sistemas existentes vinculados al consumo energético que son utilizados para predicción, así como las tecnologías y tendencias actuales a emplear en la construcción de los sistemas y al empleo de redes neuronales en la predicción de los consumos de energía. Por último, se especifican los métodos que serán usados para la solución del problema planteado y las razones por las cuales serán empleados.

**Capítulo 2:**

En este capítulo se presenta la base de casos en un documento Excel con el formato establecido por estas, describiendo las variables y explicando la preparación de los datos. Se abordan teóricamente los diferentes métodos de selección de atributos y clasificación supervisada utilizados durante la experimentación. Se implementan las clases para crear modelos de pasos múltiples. Finalmente, se comparan los modelos Base con el modelo Denso.

**Capítulo 3:**

En este capítulo se presentan dos modelos avanzados para la predicción, el modelo llamado memoria a corto plazo (LSTM) y LSTM autorregresivo, con los cuáles se obtendrá un índice de error (MAE) que luego se compara con el resto, lo que posibilita obtener finalmente el modelo con el que se puede obtener mejores predicciones si se desarrolla el entrenamiento de los datos.

# CAPITULO I – Fundamentación Teórica

## **Introducción:**

A mediados de la década de 1970 el pronóstico de la demanda de energía eléctrica había recibido escasa atención de la opinión pública, ya que el entorno económico anterior a la primera crisis del petróleo se podía considerar relativamente estable. El bajo precio de los combustibles utilizados en la generación de la energía eléctrica era bastante predecible, las tasas de interés eran moderadas y no existían demasiados problemas para que los mercados de capitales proporcionasen los fondos necesarios para la expansión del sector eléctrico. Razones por las cuales se consideraba un proceso relativamente simple y constituía un reflejo directo de los requerimientos instantáneos de potencia por parte de los consumidores sobre la base de los datos históricos. [1]

Es así como, bajo este contexto y considerando los dramáticos cambios estructurales que se están presentando en los mercados eléctricos con la introducción de la competencia donde entran en juego intereses económicos, se hace importante que el pronóstico de la demanda eléctrica minimice todas las incertidumbres, por lo que los operadores del sistema deben trabajar con el mayor nivel de eficiencia posible.

## **Importancia de la Predicción:**

Ante todo, se cree conveniente hacer un breve comentario sobre la utilización de varios términos. La planificación se refiere a las acciones llevadas a cabo para realizar planes y proyectos de diferente índole. El proceso de planeación sigue un conjunto de pasos que se establecen inicialmente, y quienes realizan la planificación hacen uso de las diferentes expresiones y herramientas con que cuenta la planeación. La planificación ejecuta los planes desde su concepción y, si es el caso, se encarga de la operación en los diferentes niveles y amplitudes de la planeación. La planificación de trabajos realiza acciones basándose en la planeación de cada uno de los proyectos y de manera inicial concibe el plan para que posteriormente sea llevado a cabo. La planificación es la parte que opera la ejecución directa de los planes, que serán realizados y vigilados de acuerdo con el planteamiento señalado durante el proceso de planeación. [1]

En sentido estricto, la verdadera predicción sería la realizada a partir de la última observación histórica. Sin embargo, puesto que suele ser muy útil comprobar cómo se habría comportado un modelo dentro del período histórico si se hubiera utilizado para

pronosticar observaciones históricas ya conocidas con certeza, es frecuente emplear también el término predicción para lo que, en realidad, podría ser considerado como bondad de ajuste a valores históricos, siendo numerosas las publicaciones que utilizan indistintamente el término predicción, tanto para el ajuste de los períodos históricos como para el cálculo correspondiente a períodos futuros. [1]

Una de las herramientas útiles en el planeamiento de un sistema eléctrico es la predicción de la demanda (carga) eléctrica, la cual permite conocer de antemano la necesidad de expansión del sistema, la finalidad de la predicción siempre será el mejoramiento del servicio, convirtiéndose en uno de los primeros pasos en cualquier proceso de planeamiento de un sistema eléctrico.

La importancia de la predicción de la demanda de energía eléctrica surge, de forma obvia, de la incertidumbre asociada a una magnitud que se refiere al futuro. La mencionada predicción puede ayudar a determinar si, previsiblemente, se va a producir una carencia de capacidad generadora (en consecuencia, pudiera ser conveniente la construcción de nuevas centrales de energía o simplemente impulsar la adopción de medidas de conservación de la energía) o, por el contrario, en el futuro existirá un exceso de capacidad (pudiera aconsejar la no utilización de parte del parque generador ya existente). [1]

La predicción de consumo de carga refleja las necesidades futuras de una población; esta predicción debe ser lo más ajustada a la realidad, ya que unos valores inferiores a los reales causarán deficiencias en la prestación del servicio en el futuro y un pronóstico de necesidades superior al real, motiva la inversión prematura en instalaciones que no tendrán un aprovechamiento inmediato. [1]

### **1.1 Situación del consumo mundial de energía**

El consumo mundial de energía se caracteriza por un aumento sostenido, el que se ha intensificado con la aparición de nuevas economías emergentes, sobre todo China, Rusia, Brasil, India y Sudáfrica (BRICS). En la Figura 1.1 se muestra el aumento del consumo de portadores energéticos.

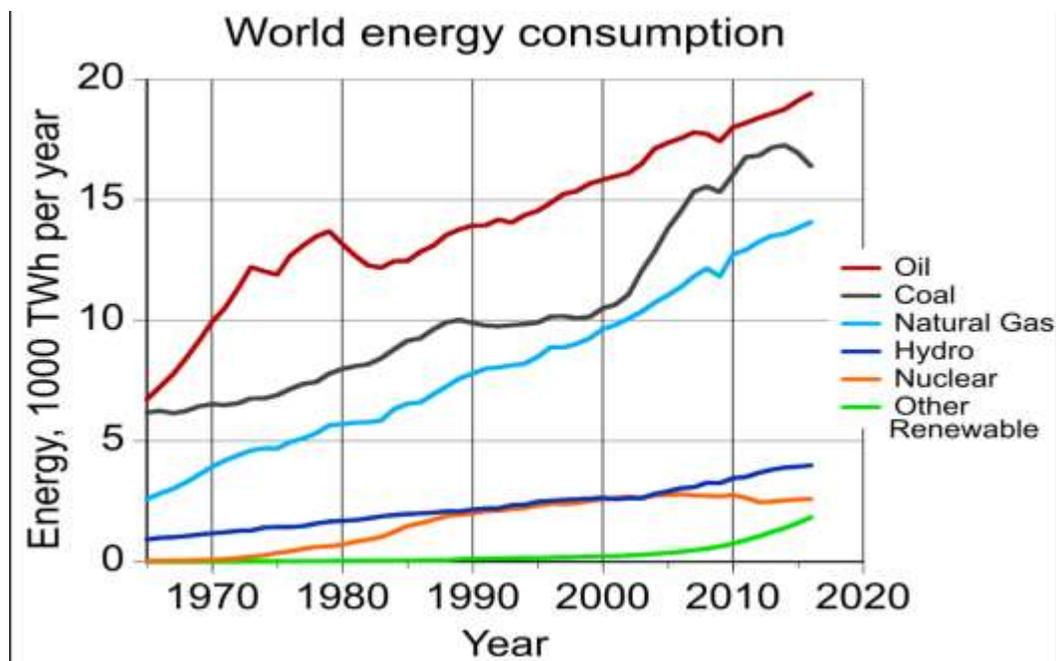


Figura 1.1 Consumo histórico de portadores energéticos. Fuente: Statistical Review of World Energy 2019.

El consumo de energía mundial se ha caracterizado por una enorme dependencia de los combustibles fósiles. A pesar de los enormes esfuerzos que se realizan para utilizar a gran escala las fuentes renovables, como la hidroeléctrica, las solares, las eólicas y otras similares, todavía se consume un 80 % de combustibles fósiles, como muestra la Figura 1.2. Esta situación se agrava por el temor del uso de la energía nuclear, por el peligro que entraña, sobre todo después de los accidentes de Chernobil, Three Island y Fukushima [4]

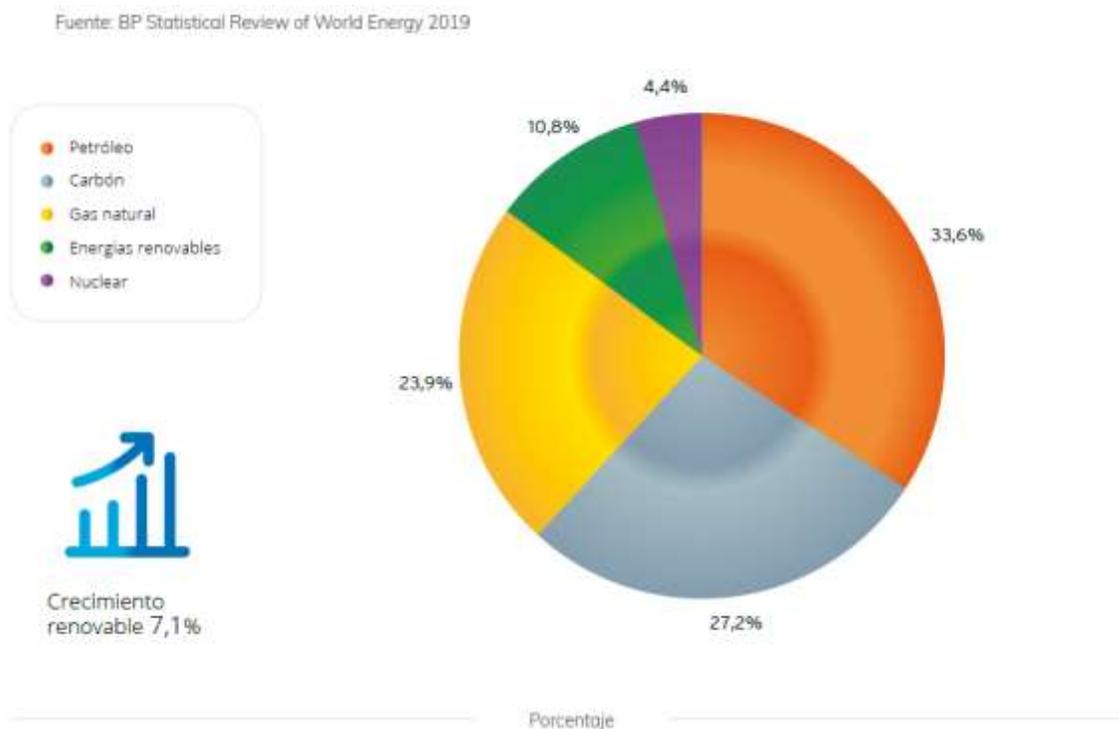


Figura 1.2 Consumo mundial de Energía Primaria por fuente. Fuente: Statistical Review of World Energy 2019.

### 1.1.1 Consumo de energía en Cuba

El consumo de energía en Cuba, a pesar de los grandes esfuerzos que realiza el Gobierno Revolucionario para diversificar las fuentes de energía y depender menos de la importación de petróleo, no se distingue mucho del resto del mundo en cuanto a su matriz energética, con una gran dependencia de los combustibles fósiles. El 95% de toda la electricidad que se consume en Cuba se produce con dichos combustibles lo cual se muestra en la tabla 1.1. Para cubrir la demanda de electricidad, la Unión Eléctrica (UNE) emplea, primero, los combustibles menos costosos, y va incorporando en el proceso de generación eléctrica todos los combustibles hasta llegar al diésel, el más caro.

Tabla 1.1 Producción nacional de energía

Años	Petróleo	Gas Natural	Hidroenergía (GW.h)	Leña	Productos de caña	Bagazo
2016	2619.2	1185.4	64.2	1106.8	4078.2	3793.6
2017	2522.2	1050.8	83	1055.1	5581.2	5233.4
2018	2462.5	970.1	145.5	963.9	6598.1	6275.9
2019	2371.5	951.1	124.5	923.9	5486.4	5195.3
2020	...	894.8	111.9	813.6	5863.5	4045.3

Fuente: Oficina Nacional de Estadística e Información, Ministerio de la Agricultura y Grupo Empresarial AZCUBA.

La generación de energía eléctrica se realiza fundamentalmente en termoeléctricas. Actualmente se realiza un gran esfuerzo por la generación con energía eólica y con paneles solares. Un ejemplo de ello es el parque eólico ubicado en Cantarrana, Cienfuegos, con seis estaciones y los parques eólicos ubicados en Palmira y Cruces. Asimismo, se encuentran los paneles de Yaguaramas, en Abreus, que es el de mayor capacidad de la provincia, y los más recientes situados en la localidad El Pino, en Rodas y en Aguada de Pasajeros. El territorio también posee siete mini hidroeléctricas ubicadas en el macizo montañoso de Guamuhaya las cuales se sincronizan con el Sistema Energético Nacional. [1]

### 1.1.2 Consumo de portadores energéticos en el MES

El consumo de energía en el MES se caracteriza por el predominio de la energía eléctrica, seguida por el diésel, la gasolina y el GLP, lo que es típico de los edificios públicos, en los que se llevan a cabo actividades administrativas, docentes y de servicios.

### 1.1.3 Consumo de portadores energéticos UCf

En la actualidad resulta de vital importancia hacer una caracterización de la situación de la energía eléctrica en la UCF, además de realizar un diagnóstico de los principales problemas que la afectan y determinar así indicadores energéticos para el centro. En la figura se puede observar el consumo energético de la sede Carlos Rafael Rodríguez (CRR) y la sede Conrado Benítez (CB). [5]

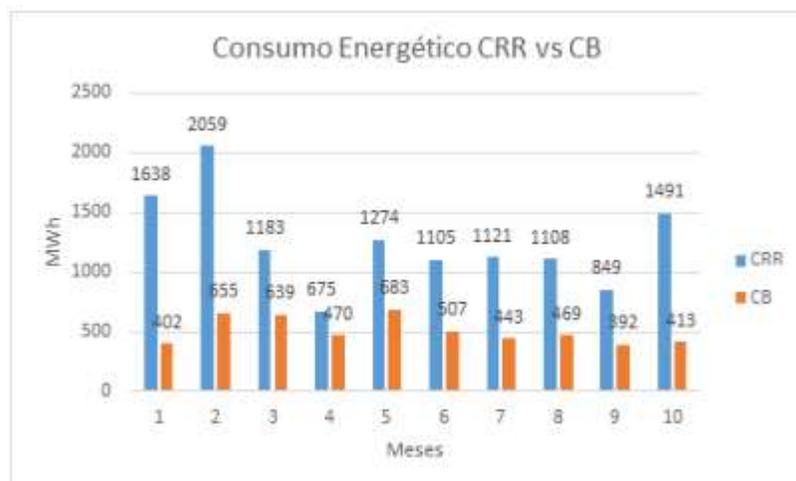


Figura 1.3 Consumo energético de ambas sedes. Fuente

#### 1.1.4 Consumo de energía eléctrica en la UCf

El consumo histórico de energía eléctrica se ha comportado según el propio crecimiento que ha tenido la universidad de acuerdo con su infraestructura. La introducción de computadoras en primer lugar, en cada una de las facultades, laboratorios, departamentos, así como equipos de climatización de distintas capacidades, por citar algunos, representan un crecimiento en la demanda de electricidad. Sin embargo, desde el año 2007 el consumo anual de energía eléctrica ha disminuido levemente, debido a los siguientes factores: [5]

1. Mayor control en el uso de la energía en las áreas.
2. Menor presencia en horario de la tarde de alumnos diurnos externos y profesores.
3. Menor frecuencia de uso de consolas del Salón Multipropósito.
4. Instalación de equipos de refrigeración y monitores más eficientes.

Para conocer la distribución del consumo de energía eléctrica por áreas y edificios en la UCF se encuentran las siguientes áreas:

- Facultad de Ciencias Sociales
- Facultad de Agronomía
- Facultad de Ingeniería
- Facultad de Ciencias Económicas
- Facultad de Ciencias de la Cultura Física y el Deporte
- Residencias estudiantiles y de postgrado
- CRAI, nodo y laboratorios de informática

- Departamentos de Química y sus laboratorios
- Edificios docentes, salas de conferencia
- Rectorado
- Edificio transporte
- Bombeo de agua
- Neveras
- Salas de generación de vapor

A pesar de que la Universidad de Cienfuegos cumple con todos los requisitos energéticos y se encuentra en una posición favorable respecto a otras empresas de la provincia, mantiene como una prioridad reducir el consumo de los portadores energéticos, para lo cual se trazan diversas oportunidades.

### **Flujo Actual de los Procesos:**

En la Universidad de Cienfuegos Carlos Rafael Rodríguez la demanda del consumo energético está condicionada según la cantidad de MWh asignados mensualmente por la Empresa Eléctrica a la institución. Este proceso se lleva a cabo de la siguiente manera: luego de ser asignada la energía eléctrica a la institución se procede a realizar una distribución por los servicios que tiene la Universidad. La UCf tiene tres servicios fundamentales de mayor consumo energético: Sede Central, Cámaras Frías y Bombas de Agua y por último la sede pedagógica Conrado Benítez, consumiendo estos servicios un total máximo de 3000KWh. Además, cuenta entre sus servicios los ocho Centros Universitarios quienes entre todos consumen un máximo de 1500 KWh.

No existe en estos momentos ningún software o programa informático que controle o prediga el consumo energético en la Universidad de Cienfuegos, todas las operaciones que se realizan para recoger el consumo diario o mensual se hacen de forma manual, por lo que resulta muy engorroso este proceso.

Es por ello que se hace necesario contar con un programa que prediga el consumo energético mensual de la institución para facilitar la administración de la energía eléctrica que se le es otorgada cada mes a la UCf.

### **1.2 Sistemas existentes vinculados al campo de acción:**

Algunos sistemas de predicciones de energía eléctrica a nivel internacional:

#### **Modelo Holt- Winters:**

Este modelo se implementó con el objetivo de predecir el consumo de energía eléctrica residencial de la Región Cajamarca mediante modelos Holt-Winters. Este procedimiento de modelización predictiva es útil para la predicción a corto y mediano plazo de ventas de energía eléctrica. La previsión del consumo de energía eléctrica tiene importancia en la planificación energética regional y nacional; a partir de sus resultados los agentes del mercado de energía eléctrica toman decisiones más adecuadas para su labor. El método Holt-Winters se estimó para diferentes constantes de suavización, que incluye métodos para patrones estacionales aditivos y multiplicativos. [6]

De acuerdo con los modelos de predicción, el modelo que presentó mejor ajuste para la serie de datos, es el modelo Holt-Winters aditivo, este modelo presentó menor error de ajuste entre el modelo y la serie de datos, cuyas constantes de suavización estimada  $\alpha, \gamma, \delta\alpha, \gamma, \delta$  igual a 0,4. Se comparó la función de ajuste con los datos reales, mediante los indicadores o estadísticos de error, resultando un MAPE de 1,70, MAD de 132,80 y MSD de 41280,00. La predicción se realizó a corto y mediano plazo para un horizonte predictivo de 3,3 años. De acuerdo con resultados de ajuste el modelo Holt-Winters aditivo, se predice un consumo de energía eléctrica residencial para marzo del año 2021 de 18976,70 MWh con un incremento de 6010,52 MWh, respecto a diciembre del año 2017 cuyo consumo de energía eléctrica residencial fue de 12966,18 MWh. [6]

Algunos sistemas de predicciones de energía eléctrica implementados a nivel nacional:

#### **ASPELFAC:**

El programa se denomina ASPELFAC, consiste en un software capaz de controlar el consumo de electricidad y, examina a cada instante los valores de las mediciones de voltaje, corriente y frecuencia, constituyendo una importante herramienta para el control del ahorro de electricidad y la supervisión del consumo energético.

El control en tiempo real del comportamiento del consumo eléctrico puede garantizarse mediante el programa de Adquisición Automática de Parámetros Eléctricos, Supervisión y Facturación (ASPELFAC), creado en 2009 por la Empresa de Ingeniería y Proyectos para la Electricidad (INEL). [7]

Este software cubano de supervisión eléctrica y facturación obtiene su mejor aprovechamiento cuando el establecimiento cuenta con metros contadores de la serie

CIRWATT (CIRCUTOR), debido a que el programa se comunica de forma automática con el metro e inspecciona los principales parámetros eléctricos.

ASPELFAC examina a cada instante los valores de las mediciones de voltaje, corriente y frecuencia, constituyendo una importante herramienta para el control del ahorro de electricidad y la supervisión del consumo energético del centro. [7]

### **Módulo de planificación para el sistema de supervisión energética:**

Con la implantación del Programa de Ahorro de la Electricidad en Cuba (PAEC), la Unión Nacional Eléctrica (UNE), ha trazado entre sus objetivos optimizar el proceso de planificación del consumo de energía eléctrica, para lo cual se hace necesaria la utilización de herramientas informáticas. [8]

Se desarrolló una aplicación web para integrarla al sistema de Supervisión Energética el cual se llevó a cabo en la Facultad 5 de la Universidad de las Ciencias Informáticas (UCI) con vistas a informatizar todo el proceso que de una forma u otra tiene que ver con la energía eléctrica, lo que influye directamente de forma positiva a elevar la eficiencia energética y lograr un ahorro considerable de dinero al país en la producción de electricidad. [8]

La modelación, diseño e implementación de este sistema se logró sobre la base de la elección y utilización de las herramientas escogidas por el proyecto supervisión energética, que por sus características particulares se ajustaban a los propósitos deseados. Quedan cumplidos los objetivos planteados, obteniendo la implementación de un producto informático que facilita la gestión de los planes operativos de consumo eléctrico de todo el sector estatal cubano. [8]

### **Sistema SCADA:**

No existe en Cuba una forma efectiva de supervisar en tiempo real el consumo eléctrico. Si esto fuera posible, permitiría detectar el gasto innecesario de la electricidad y por consiguiente ahorrar divisas por concepto de no generar más energía de la necesitada. Es por ello por lo que en la Universidad Marta Abreu de Las Villas se diseñó un sistema SCADA (Supervisory Control And Data Acquisition) para la supervisión del consumo eléctrico de los centros estatales de la provincia de Villa Clara que tienen el mayor consumo de energía eléctrica. Este sistema, permitió detectar a tiempo el sobreconsumo

de electricidad y ahorrar divisas al país al tiempo que se daña menos el medio ambiente. [9]

**1.3 Comparación entre los sistemas de predicción existentes y el sistema a desarrollar:**

A pesar que tanto nacional como internacionalmente se han llevado a cabo diferentes investigaciones relacionadas con la predicción del consumo de energía eléctrica, ninguno de estos modelos se ajusta a las necesidades que contempla hoy la Universidad de Cienfuegos Carlos Rafael Rodríguez, no existe en nuestro país un sistema que nos muestre un modelo adecuado para predecir mensualmente el consumo energético en las instituciones universitarias, es por ello que se hace necesario desarrollar esta investigación.

**1.2 Modelos matemáticos para la planificación de la energía.**

El modelo energético de una región es el flujo de las distintas energías; desde donde se extraen o compran, hasta el punto donde se consumen, indicando todas y cada una de las transformaciones sufridas; su transporte y distribución, señalando rendimientos y pérdidas, así como los residuos provocados en el proceso. [10]

Pages (1981) por su parte considera que modelo matemático no es más que un instrumento, una representación manejable de la realidad, construida a partir de un cuerpo de hipótesis bien definidas, y procurando que los resultados tengan significación en relación con dichas hipótesis y con los datos y parámetros utilizados. El modelo según su entorno es una herramienta o un instrumento y lo que importa es la visión de la realidad que se pueda obtener de él. [11]

**1.2.1 Bases matemáticas aplicadas a los modelos de energía.**

Los modelos matemáticos más utilizados aplicados a la energía son los siguientes:

- **Optimización Clásica:** La teoría de optimización clásica utiliza el cálculo diferencial en la determinación de los puntos de máximos y mínimos (extremos), para funciones con y sin restricciones. La teoría que lo fundamenta proporciona las bases para diseñar la mayor parte de los algoritmos de programación lineal. [12]
- **Programación Lineal:** Esta técnica está diseñada para optimizar el empleo de recursos limitados. La característica fundamental que define este caso es la linealidad de sus expresiones. Tanto la función objetivo a optimizar como el conjunto de restricciones asociadas al problema son lineales. Estas restricciones, según citando

a López de la Manzanara suelen clasificarse en dos grupos, según afecten a relaciones entre las variables independientes (llamadas "instrumentos") de la función objetivo (restricciones "circunstanciales") o al signo de dichas variables (restricciones "laterales"). En algunos casos una restricción, implícita y esencial, para desarrollar el algoritmo de solución del modelo es la "restricción de no negatividad" para las variables de la función objetivo. [12]

El teorema fundamental de la programación lineal permite limitar la búsqueda de óptimos para la función objetivo al conjunto de vértices del poliedro convexo. La solución correspondiente se conoce con el nombre de "óptima", calificándose como "degenerada" cuando alguno de las variables se anula. Cualquier solución que satisfaga todas las restricciones del modelo es una "solución factible". Como afirma Taha (1998) y Ramos et al. (2010), lo que interesa es encontrar la "solución factible óptima", que produce la máxima utilidad total.

El problema planteado suele recibir el nombre de "primal" si consiste en minimizar la función objetivo, denominándose "dual" al problema de maximización. Las soluciones óptimas de los problemas primal y dual coinciden, por lo que en ocasiones la transformación de uno de los programas en el otro permite lograr la solución de forma más cómoda.

- **Método Simplex:** Es un método de resolución de la forma estándar de programación lineal, todas las variables son no negativas. Para la conversión de una "variable no restringida" (puede ser negativa) en una "variable no negativa" se utiliza el siguiente sistema: Sea  $x_j$  una "variable no restringida", entonces se descompone en dos variables no negativas.

Con el fin de describir el algoritmo simplex se pueden determinar la programación lineal óptima enumerando de forma exhaustiva todas las soluciones básicas (factibles) de la forma estándar. Sin embargo, este procedimiento es ineficiente desde el punto de vista de cálculo; por ello el algoritmo simplex está diseñado para localizar la óptima, concentrándose en un número seleccionado de las soluciones básicas. [13]

El método Simplex empieza en una solución básica factible. Partiendo de esta solución, trata de encontrar otra solución básica factible que mejore el valor objetivo del problema; para ello convierte una variable no básica (que por tanto toma el valor cero en el

problema) en una variable positiva. A su vez elimina una de las variables básicas actuales (para mantener el número de variables en relación con las ecuaciones del problema) convirtiéndola en una "variable no básica". La variable no básica seleccionada se denomina "variable de entrada" y la variable básica eliminada "variable de salida". Repitiendo este proceso a lo largo de los límites del conjunto convexo se obtiene la deseada solución factible óptima. [13]

- **Programación lineal entera:** En esta programación algunas o todas las variables están restringidas a valores enteros (o discretos), Taha (1998) y Vitoriano (2010) llama "problema entero puro", a aquel en que todas las variables deben ser valores enteros; en contraposición, llama "problema entero mixto", a aquel en que solo algunas variables son deben tomar valores enteros.

Esta programación puede tener un interés especial si se pretende optimizar la construcción de instalaciones (centrales de producción eléctrica o de producción de biocarburantes), con una capacidad de producción concreta [13]

### 1.2.2 Modelos de oferta de energía.

La planificación de la generación de energía a largo plazo conlleva múltiples conflictos, objetivos, incertidumbres y riesgos. García (2004) citando a Evans, Morin y Moskowitz (1982) define el problema de planificación de la generación a largo plazo en su aceptación en idioma inglés "Long-range generation planning problem" (LRGPP) para una empresa eléctrica pública, como el problema de determinar, las cantidades de unidades de generación que se deben construir y cuando deben entrar en la red en un horizonte de planificación a largo plazo. El criterio utilizado en planificación puede englobar varios objetivos, por ejemplo: minimización del coste y maximización de la confianza, considerados de forma simultánea. [14]

Para la formulación de un modelo general de generación energética a largo plazo hay que contar con la diversidad de métodos para generar energía. Estos métodos darán lugar a varias unidades de generación que deben considerarse en el sistema energético. Para lograr una proyección fiable debe dividirse el horizonte de proyección en períodos más pequeños que den lugar a resultados parciales. La decisión básica es la elección del número de unidades de generación de cada tipo que se deben incluir en cada período

del horizonte de planificación (sumar una unidad a un período significa que entrará a funcionar al principio del periodo). [14]

### **Modelo MARAL**

En 1976 la Agencia Internacional de la Energía (AIE) constituye un grupo de trabajo, con la misión de analizar los sistemas energéticos de los países que la integran; este hecho supuso el desarrollo del modelo de oferta energética MARKAL (Market Allocation). Las bases de este modelo se desarrollaron dentro del programa ETSAP (Energy Technology Systems Analysis Program) de la AIE entre 1980 y 1981 el Brookhaven National Laboratory (BNL) de Nueva York de Estados Unidos y el Kernforschungsanlage (KFA) de Jülich de Alemania, diseñaron un modelo multiperiodico temporal de programación lineal flexible para un sistema generalizado de energía. Su construcción se realizó apoyándose en el concepto de Sistema Energético de Referencia (Reference Energy System) que representa un sistema energético cuyo nivel de detalle varía según la red de trabajo elegida. A este modelo lo denominaron MARKAL (Market Allocation).

Los conceptos de energía que utiliza el modelo MARKAL tanto para el establecimiento de la función objetivo como para las restricciones son tres, energía primaria, final y útil. La energía útil no puede ser exportada o importada. Las transformaciones de un tipo a otro son la conversión de energía primaria a final y la conversión de energía final a útil (considerando las correspondientes pérdidas en estas transformaciones). Las variables utilizadas en las hipótesis para la elaboración de escenarios son los ratios de crecimiento de población, los precios de la energía y los ratios de crecimiento de la demanda energética final en los sectores industrial, residencial y transporte.

Una configuración del sistema energético viene caracterizada por una combinación de portadores de energía (vectores energéticos) que se representan por líneas que forman la red. Estos portadores de energía se pueden transformar en otros a través de conversiones y procesos tecnológicos que se representan por cajas. Así el sistema energético queda representado por una red formada por líneas que se conectan a través de cajas. Cada hipótesis (escenario) viene definido por una configuración de estos portadores energéticos de forma que el modelo busca la óptima configuración (la que tiene los costes mínimos). A esto se le puede unir las restricciones en las emisiones de

los contaminantes, de forma que, la configuración óptima tiene que cumplir a su vez las condiciones ambientales deseadas por el decisor. [14]

### **Energy Flow Optimization Model, EFOM**

Según Marcos (1985), los trabajos realizados por el Brookhaven National Laboratory en Estados Unidos y el Institute Economique y Juridique de L'Energie de Francia son la base de Energy Flow Optimization Model o Modelo de Optimización del Flujo de Energía (EFOM), se desarrolló con la capacidad de tomar los datos de salida del modelo MEDEE de demanda de energía que se describe posteriormente en la investigación y realizar la optimización de la oferta energética de una región determinada. El EFOM es un modelo de programación lineal donde la optimización se realiza mediante la elaboración de una función objetivo que se optimiza, junto a un conjunto de restricciones, siendo tanto la función objetivo como las restricciones ecuaciones lineales. EFOM es utilizado por varios equipos de trabajo con objetivos muy distintos, analizando un gran número de materias. Esto supone que el uso del modelo debe ser fácil, flexible y tiene que dar resultados en los que se pueda confiar; este modelo de programación lineal multiperíodico que busca la minimización del total de costes descontados del sistema energético da el suministro (oferta) óptimo de energía para una demanda de energía útil determinada. Se puede incluir un conjunto de restricciones adicionales como son las derivadas del agotamiento de recursos, grado de penetración de ciertas tecnologías y niveles de emisión permitidos. El modelo contiene procesos (tecnologías) de extracción, transporte y conversión de la energía (como por ejemplo la generación de electricidad, la cogeneración de electricidad y calor, los procesos de refino y las tecnologías de uso final de la energía). Otra posibilidad que se incluye dentro de este modelo es la reducción de tecnologías con el fin de minimizar las emisiones atmosféricas contaminantes (SO<sub>2</sub> y NO<sub>x</sub>). [14]

### **Modelo ARIES**

El modelo ARIES se crea con el objetivo de resolver los problemas de incertidumbre de la planificación tradicional, basada en modelos deterministas que buscan soluciones de mínimo costo en escenarios prefijados; como consecuencia de estos problemas no se establece plan óptimo para todos los escenarios posibles. Este modelo se basa en la simulación, este tipo de planificación no busca el óptimo para ningún escenario previsible, pero posee una gran flexibilidad de adaptación al entorno cambiante. [14]

El programa ARIES (Análisis de Riesgo) es una herramienta de gestión de la metodología Trade-off/Risk, utilizada frecuentemente en la industria eléctrica (Schweppe y Merrill, 1987). Este programa desarrollado por el Electric Power Research Institute (EPRI) en el año 1988, ayuda a la resolución de problemas conduciendo a la elección de las alternativas que se comportan adecuadas para cualquier suceso futuro que se pueda anticipar. La metodología Trade-off/Risk es aplicada sobre todo en problemas donde la incertidumbre sea un factor importante, se basa en el concepto de dominancia significativa que consiste en seleccionar sólo las soluciones que sean significativamente mejores que las demás; las fases de esta metodología son principalmente dos: [14]

1. Se realiza un análisis de Trade-off donde se eligen los planes que representan un buen compromiso entre todos los atributos para cada futuro; en esta fase es necesario establecer las reglas de selección de planes, básicamente se utilizan reglas de dominancia condicional estricta y dominancia condicional significativa. La aplicación repetida de estas reglas entre los posibles planes da lugar a "conjuntos de selección" en función de cada criterio.
2. Se realiza un análisis de riesgo donde se estudia el conjunto completo de futuros y se comprueba la robustez (flexibilidad) de los planes elegidos. Un plan es robusto cuando está incluido en el conjunto condicional de decisión de todos los futuros. Este caso puede obtenerse información adicional sobre la robustez de las opciones, factor crítico de los atributos y las incertidumbres, valor de la información, exposición al riesgo y optimización.

### **Model Electric Generation Expansion Analysis System, EGEAS**

El modelo Electric Generation Expansión Analysis System (EGEAS) perteneciente al Electric Power Research Institute (EPRI) es una alternativa a las simulaciones cronológicas. Es un método probabilístico para modelar las tecnologías no despachables en las que se consideran tecnologías de energías renovables, respecto a los costes de producción y a la planificación a largo plazo, este modelo se utiliza para la expansión de unidades de generación eléctrica.

Para alcanzar los objetivos el modelo trata las salidas de energía de las fuentes energéticas dependientes y de los distribuidores de energía como variables random y representa su interdependencia estadística como una distribución de probabilidades. Esto

representa un algoritmo de operación equivalente a la curva de carga del sistema energético convencional.

El modelo EGEAS consiste en una serie de cinco programas informáticos diseñados para determinar el plan óptimo de expansión de la generación. Este modelo permite optimizar a la vez energías convencionales y energías renovables. Se designa un año concreto como punto de referencia para los datos económicos. Todos los costes se refieren a la unidad monetaria corriente de ese año. El horizonte de planificación se denomina periodo de estudio, pudiendo variar entre 1 y 30 años. Durante este periodo las unidades de generación se van eligiendo con el fin de atender al crecimiento de la demanda. Para poder estudiar los efectos finales del plan elegido se utiliza una extensión del periodo de estudio. Durante esta extensión se supone constante la demanda energética y no se instalan nuevas unidades de generación. [14]

### **1.2.3 Modelos de demanda de energía.**

Los consumos eficaces de energía (consumo por unidad monetaria) durante el período de las crisis del petróleo 1973-1979 tuvieron un crecimiento muy pequeño (debido a la subida de precios de la energía), esto hizo que se desestimase los métodos econométricos clásicos para hacer estimaciones de consumo energético. No podían considerarse los distintos productos energéticos por separado, ya que todo el sector energético estaba y está relacionado. Lo expuesto significaba que la variación de uno de los productos energéticos influía en todos los demás de forma importante. A partir de 1973 los nuevos modelos de demanda adquieren su importancia, pues el ratio consumo futuro/consumo actual debía de ser pequeño, el mantenimiento este ratio a niveles aceptables fue conseguido por países como Estados Unidos o Alemania. [15]

Los modelos de previsión de demanda energética se construyen considerando, tanto las nuevas tecnologías energéticas que se van desarrollando o se desarrollarán, como la demanda final debida a los consumidores. Por tanto, deben considerarse características sociales como variaciones en el estilo de vida, preferencias de los usuarios, situaciones políticas nacionales e internacionales, etc.

Con los estudios de los flujos energéticos se puede desarrollar el modelo deseado, que se clasifican de la siguiente forma: [15]

1. Históricos: Se basa en realizar un estudio histórico (bibliográfico o encuestas) que relaciona parámetros macroeconómicos como el Producto Interno Bruto (PIB) y Valor Añadido Neto (VAN) con energéticos. A continuación, se estudia la previsión del parámetro macroeconómico y de él se induce la demanda energética.
2. Inductivos: Realiza un proceso inductivo puro. Se utiliza cuando existen lagunas en las series de datos consultados. En el proceso inductivo se consideran parámetros como el PIB, los ingresos y gastos de los particulares, etc. Con ellos se determina la demanda energética.
3. Prospectivos: Son proyecciones de demanda a muy largo plazo que dependen de los escenarios que se construyan, tienen carácter especulativo y admiten cambios de mentalidad, políticos, de hábitos y de innovación tecnológica notable.
4. Directos: En análisis sectoriales a muy corto plazo, los métodos directos de encuesta al consumidor y vendedor se consideran los más útiles.

### **Modelo INGA**

El modelo INGA fue presentado en 1979 en el Simposium de Modelos Energéticos de Washington, este modelo se basa en una hipótesis que relaciona la demanda de energía de un país como consecuencia del gasto privado generado en el mismo.

Según la demanda de energía no se basa solamente en las variaciones del PIB, sino que la estructura de ingresos familiares influye de forma importante en esta demanda. Esto se debe a la incorporación de las familias de bajo nivel de ingresos a niveles de ingresos superiores, incrementando en términos relativos la cantidad de energía consumida por unidad de gasto, a esto hay que añadir que el aumento de gasto implica aumento de consumo de producto y por tanto de PIB. [15]

Las unidades finales de demanda adquieren bienes y/o servicios en ellos está incluida la energía requerida para su producción y venta. Las entidades finales de demanda adquieren energía útil directamente. Para poder determinar la demanda final de energía a partir de la demanda final de bienes y servicios (gasto) el modelo utiliza dos módulos. Un módulo económico que relaciona el gasto (demanda de bienes y servicios) con la producción de los bienes y servicios más la importación, y un módulo energético que relaciona esta producción de bienes y servicios más la importación, con el consumo energético necesario para estas actividades. [15]

Una vez que los resultados de módulo económico se han adaptado y definido los consumos específicos energéticos de los sectores, la aplicación de los consumos específicos a los niveles se convierte en una multiplicación matricial. Se considera como energía primaria al carbón, petróleo, gas natural, electricidad hidráulica y nuclear, estos vectores energéticos son los inputs de los sectores energéticos. La energía eléctrica primaria es únicamente de origen hidráulico o nuclear, energía eléctrica obtenida en centrales térmicas es energía secundaria. Para el cálculo de los factores de corrección se utilizan grupos de productos energéticos suministrados por cada subsector energético al no calcularse de forma individual puede existir una desviación de la realidad, pero supone un cálculo más homogéneo para todos los productos, se evitan posibles errores comparativos entre los distintos sectores energéticos. Con estos coeficientes se realiza el cálculo final de energía para los productos de los distintos sectores del país. [15]

### **Modelo PROCER**

El modelo Proyección de los Consumos Energéticos Representativos (PROCER) fue desarrollado por Ortega (1983) surge de la necesidad de acomodar los modelos de planificación energética al nivel estadístico español. La idea se basaba en proyectar la demanda de energía e introducir los resultados en un modelo de optimización de la oferta como modelo EFOM descrito en los modelos de oferta. El modelo destaca el uso de tec (tonelada equivalente de carbón) en lugar de tep (tonelada equivalente de petróleo) a la hora de manejar los datos. La elección de esta unidad se debe a los antiguos balances, que utilizaban principalmente tec, con los cuáles se quería identificar el modelo. [16]

Pero como apunta Marcos (1984) el modelo PROCER se basa en la íntima relación existente entre los consumos energéticos y el PIB por lo que se proyectan tanto los consumos energéticos como los valores del PIB al coste de los factores. En el caso regional se utiliza el valor añadido bruto (VAB) al coste de los factores, el consumo de un sector se considera representativo en la medida que representa la interacción existente entre consumo energético y PIB dividido en los distintos sectores del país. La relación entre el consumo de energía y el VAB o el PIB no es uniforme, hay sectores con un gran consumo energético por unidad de valor añadido, mientras que en otros es pequeño. [16]

### **Modelo MEDEE**

El primer modelo MEDEE surgió en el Instituto Económico y Jurídico de la Energía de la Universidad de Ciencias Sociales de Grenoble en Francia; este modelo se enmarcaba en el estudio de los países de la Comunidad Económica Europea (CEE) denominado Análisis de Sistemas / Modelos Energéticos. El modelo MEDEE es un modelo de simulación que utiliza la teoría de análisis de sistemas a los problemas energéticos, permite calcular la demanda energética a nivel desagregado (por sectores y por usos energéticos) su técnica de modelización se sitúa entre el análisis energético y la econometría. [16]

Este modelo ha estado en continua evolución mejorando los instrumentos de análisis, simplificando los sectores cuando se hace necesario y adaptando su estructura a distintos objetivos finales. Así después del primer modelo MEDEE, surgieron el MEDEE-2, el MEDEE-3, el MEDEE región, el MEDEE de utilización racional de la energía, el MEDEE-SUD y el MEDEEEUR; esta última versión fue desarrollada en la Dirección General de la Ciencia, de la Investigación y del Desarrollo de la Comisión de las Comunidades Europeas, dentro de los programas de Investigación Energética y en concreto de los de Análisis de Sistemas Energéticos. La construcción del modelo MEDEE-EUR tenía como finalidad su implantación en todos los países comunitarios. Sin embargo, algunas no lo han utilizado, otros sólo han usado parte de sus componentes, otros han copiado su estructura para desarrollar sus propios modelos y otros han desarrollado modelos distintos. [16]

### **Modelo ENCA**

El modelo ENCA se desarrolló para el cálculo de la demanda de energía según las inversiones necesarias a medio plazo por sectores está compuesto por tres elementos básicos:

1. Matriz de entradas y salidas de la economía.
2. Matriz de coeficientes capital - producto, correspondiente al mismo año que la matriz entrada y salida
3. Modelo de simulación que utiliza las dos matrices para realizar un análisis de la evolución de la economía según varios escenarios.

Este modelo está basado en varias hipótesis de comportamiento: (1) la Administración Pública no tiene una política monetaria que conlleve modificaciones del tipo de interés,

(2) la tecnología de todos los sectores productivos permanece constante y (3) los precios de los bienes producidos para los distintos sectores económicos permanecen constantes durante el intervalo al que hace referencia la simulación. [14]

### **Modelo MULTIMOD**

El modelo MULTIMOD está desarrollado según las teorías neoclásicas de crecimiento siendo un modelo macroeconómico a nivel mundial, este modelo no es apropiado para una planificación a largo plazo, pero si el horizonte de planificación no supera los 15 años, puede tener grandes ventajas.

El modelo utiliza diez bloques relacionados entre sí para la realización de los cálculos, se establecen aproximadamente 65 ecuaciones repetidas en cada uno de los bloques, cada miembro del grupo G7 forma un bloque, el resto de los países de la Organización de Cooperación y Desarrollo Económico (OCDE) forman otro bloque y los países en vías de desarrollo forman los dos últimos bloques (uno para exportadores netos de capital, y otro para los demás), no se consideraran economías en esa etapa en transición como China o Rusia, ni los países del sudeste asiático de forma general. [14]

Los sectores considerados por el modelo son industria, servicios, doméstico, construcción y transporte; estos sectores se relacionan con las inversiones en cada uno, el consumo público o privado y con las exportaciones netas. Un aspecto de importancia dentro del modelo MULTIMOD es la ecuación relacionada con la demanda eléctrica que forma su propio modelo de corrección de errores debido a la importancia que tiene mantener la red eléctrica sin grandes descompensaciones, esta ecuación se calcula aparte del resto de los productos energéticos. [14]

#### **1.2.4 Modelos estadísticos de pronóstico de energía.**

##### **Series de tiempo**

Se llama Series de Tiempo a un conjunto de observaciones sobre valores que toma una variable (cuantitativa) en diferentes momentos del tiempo. Los datos se pueden comportar de diferentes formas a través del tiempo, puede que se presente una tendencia, un ciclo; no tener una forma definida o aleatoria, variaciones estacionales (anual, semestral, etc.). Las observaciones de una serie de tiempo serán denotadas por  $Y_1; Y_2, \dots, Y_T$ , donde  $Y_t$  es el valor tomado por el proceso en el instante  $t$ . [17]

Los modelos de series de tiempo tienen un enfoque netamente predictivo y en ellos los pronósticos se elaborarán sólo con base al comportamiento pasado de la variable de interés. [17]

El conjunto de datos constituye una serie de tiempo, pues es una secuencia de observaciones, medido en determinados momentos del tiempo, ordenado cronológicamente y, espaciado entre sí de manera uniforme, así los datos usualmente son dependientes entre sí. Existen diferentes formas de trabajar con series de tiempo, con el objetivo principal de realizar pronósticos, normalmente para analizarlas se utilizan los modelos

- AR (Autoregresivos),
- MA (Medias Móviles),
- ARMA (Autoregresivo de Medias Móviles) y
- ARIMA (Autoregresivo Integrado y de Media Móvil).

Otra forma de trabajar con series temporales es haciendo uso de Redes Neuronales Recurrentes, también a través de los modelos KNN (K-Nearest Neighbor), entre otras vías. [17]

Hoy en día diversas organizaciones requieren conocer el comportamiento futuro de ciertos fenómenos con el fin de planificar, prevenir, es decir, se utilizan para predecir lo que ocurrirá con una variable en el futuro a partir del comportamiento de esa variable en el pasado. En las organizaciones es de mucha utilidad en predicciones a corto y mediano plazo, por ejemplo, ver qué ocurriría con la demanda de un cierto producto, las ventas a futuro, decisiones sobre inventario, insumos, etc. [17]

### **Modelos econométricos**

Un modelo econométrico es un modelo estadístico, una representación simplificada de la relación entre dos o más variables que permite estimaciones empíricas. Su utilización permite hacer estimaciones acerca del efecto de una variable sobre otra y/o hacer predicciones acerca del valor futuro de las variables.

Un modelo econométrico tiene la siguiente estructura: una variable endógena y una o más variables exógenas o explicativas y, un error.

- **Variable endógena:** una variable o factor que es causada o explicada por otro conjunto de variables independientes (que son determinadas por otros factores fuera del modelo).
- **Variables exógenas:** variables que determinan o explican a la variable endógena y que son independientes entre sí.
- **Error:** captura el efecto de otros parámetros desconocidos.

Para construir un modelo econométrico, se parte de un modelo económico que explica el comportamiento de una variable en función de otras. Así, por ejemplo, el modelo económico puede plantear que el salario de un trabajador depende de sus años de estudio, la educación de sus padres y la experiencia principalmente. De esta forma, se puede construir un modelo econométrico donde la variable endógena es **salario**, mientras que la educación, la educación de los padres y la experiencia son las variables exógenas. Considerando esto tendríamos:

**Modelo económico:** W (educación, educación de los padres, experiencia)

**Modelo econométrico:** se podría representar así:

$$W = B_0 + B_1Ed + B_2Edp + B_3Exp + U$$

Donde:

- W – salario por hora
- Ed – años de educación
- Edp – años de educación de los padres
- Exp – experiencia
- B<sub>0</sub>, B<sub>1</sub>, B<sub>2</sub>, B<sub>3</sub> – estimadores, indican el efecto de un cambio en la variable
- U – error, recoge efectos no observables como capacidad, habilidades, etc.

De esta forma, en este modelo lineal simple, si el valor obtenido de B<sub>1</sub> es 0.60 por ejemplo, podemos decir que, si se aumenta un año más de educación, el salario por hora se verá aumentado en 60 céntimos.

Estos modelos tienen múltiples usos en la práctica. Son herramientas importantes en la formulación de políticas económicas, estrategias de ventas, definición de la política monetaria, entre muchos. Algunos ejemplos conocidos de uso de modelos econométricos son: predecir la tasa de crecimiento de PIB, determinar el efecto del gasto público, evaluar el impacto de un subsidio, proyectar la demanda de un producto, etc.

Los modelos pueden ser simples con una variable endógena y varias explicativas (una ecuación) o más complejos con la utilización simultánea de varias ecuaciones. Dependiendo del tipo de información utilizada los modelos pueden ser:

- **Datos de corte transversal:** datos de un individuo o agente que se recogen en un momento en el tiempo, por ejemplo, un censo.
- **Series de tiempo:** datos de una misma variable que se recogen a lo largo del tiempo, por ejemplo, el PIB de un país durante 10 años.
- **Paneles:** se recoge la información a lo largo del tiempo para cada unidad de información. Son datos de corte transversal que se siguen en el tiempo. [18]

Acevedo Rueda, Rubén, & Pimentel, José A. (2014). Modelo econométrico para el pronóstico de demanda eléctrica máxima diaria. *Universidad, Ciencia y Tecnología*, 18(70), 4-11.

### 1.3 Redes neuronales en la gestión de la energía.

Las redes neuronales, también denominadas sistemas neuronales artificiales o Artificial Neural Systems (ANS) son redes interconectadas masivamente en paralelo de elementos simples (usualmente adaptativos) y con organización jerárquica, las cuales intentan interactuar con los objetos del mundo real del mismo modo que lo hace el sistema nervioso biológico. [19]

Un sistema neuronal artificial tiene la estructura jerárquica donde el elemento esencial de partida será la neurona artificial, que se organizará en capas; varias capas construirán una red neuronal. Una red neuronal (o un conjunto de ellas), junto con las interfaces de entrada y salida, más los módulos convencionales adicionales necesarios, constituirán el sistema global de proceso. [19]

Surgen por la citada dificultad para resolver con la eficiencia deseada problemas como los de visión o aprendizaje, y debido a los altos requerimientos computacionales de este tipo de tareas. Los sistemas neuronales artificiales constituyen en la actualidad un activo campo multidisciplinar, en el que confluyen investigadores procedentes de muy diferentes áreas, como la electrónica, física, matemáticas, ingeniería, biología o psicología.

El estudio de los ANS puede orientarse en dos direcciones, bien como modelos del sistema nervioso y los fenómenos cognitivos, bien como herramientas para la resolución de problemas prácticos; en este último caso se considera que las redes neuronales

artificiales son sistemas, hardware o software, de procesamiento, que copian esquemáticamente la estructura neuronal del cerebro para tratar de reproducir sus capacidades. Los ANS son capaces así de aprender de la experiencia a partir de las señales o datos provenientes del exterior, dentro de un marco de computación paralela y distribuida, fácilmente implementable en dispositivos hardware específicos. [19]

### **Aplicaciones de las redes neuronales**

Las redes neuronales pueden utilizarse en un gran número y variedad de aplicaciones, tanto comerciales como en la previsión del consumo eléctrico. Los más habituales son los relacionados con clasificación, estimación funcional y optimización; en general, el del reconocimiento de patrones suele considerarse como un denominador común. Se pueden señalar las siguientes áreas de aplicación de los sistemas neuronales: reconocimiento del habla, reconocimiento de caracteres, visión, robótica, control, procesamiento de señal, predicción, economía, defensa, bioingeniería, etc. Asimismo, se están aplicando ANS para incorporar aprendizaje en los sistemas borrosos y a la confección de sistemas expertos conexionistas. [19]

1. **Telecomunicaciones:** es en este campo donde los ANS han conseguido la aplicación industrial más significativa en la actualidad; se han utilizado para construir ecualizadores lineales y canceladores de ecos, que son empleados en los módems que trabajan con transmisión de alta velocidad. En ambos casos se emplea una red neuronal de una sola neurona. Así, millones de módems en todo el mundo contienen una adalina.
2. **Fallos en motores eléctricos:** la empresa de constitución alemana Siemens, dirigida a la electrónica e ingeniería eléctrica; ha desarrollado un sistema neuronal capaz de predecir, con mucha fiabilidad y bajo coste, los fallos de grandes motores de inducción. El porcentaje de aciertos en dicha predicción resulta ser de un 80% a un 90%, frente al 30% obtenido anteriormente con otras técnicas.
3. **Aplicaciones biomédicas:** se aplica ANS al estudio de secuencias de aminoácidos en proteínas, nucleótidos en ADN y ARN, clasificación de señales electrocardiográficas y electroencefalográficas, predicción de la reacción de paciente ante determinados tratamientos, predicción de accidentes relacionados con anestesia, detección de arritmias, predicción de mortandad de pacientes,

identificación de cáncer de pecho a partir de mamografías, modelización de la esquizofrenia, clasificación de imágenes médicas, etc.

4. **Predicción:** es un campo en el que las redes neuronales proporcionan excelentes resultados, ejemplo de ello es en la predicción de la demanda del consumo eléctrico. El interés de esta previsión radica en que las empresas eléctricas deben conocer con antelación las necesidades de su mercado para poder planear la generación y distribución futura de la energía eléctrica (por una parte, la electricidad producida en exceso se pierde o puede ocasionar inestabilidades en la red; por otra, no producir la electricidad suficiente para cubrir las necesidades contribuye a un déficit de planificación).

#### **Análisis crítico de los modelos:**

Se han analizado un sinnúmero de modelos, sin embargo, de ellos pocos son aplicables para nuestra problemática. Se busca un modelo capaz de brindar un enfoque predictivo utilizando los datos almacenados mensualmente desde el año 2001 hasta el año 2019. Las series temporales permiten analizar secuencias de datos cronológicamente dispuestos, por lo que se adaptan a nuestras necesidades pudiendo ser implementadas en nuestro programa. Además, se combinan con redes neuronales para brindar mejores resultados, justamente lo que se necesita.

#### **1.4 Tendencias, metodologías y tecnologías actuales:**

##### **Lenguaje de programación utilizado: Python**

Python es un lenguaje de programación ampliamente utilizado en las aplicaciones web, el desarrollo de software, la ciencia de datos y el machine learning (ML). Los desarrolladores utilizan Python porque es eficiente y fácil de aprender, además de que se puede ejecutar en muchas plataformas diferentes. El software Python se puede descargar gratis, se integra bien a todos los tipos de sistemas y aumenta la velocidad del desarrollo.  
[20]

##### **Beneficios que ofrece:**

- Los desarrolladores pueden leer y comprender fácilmente los programas de Python debido a su sintaxis básica similar a la del inglés.

- Python permite que los desarrolladores sean más productivos, ya que pueden escribir un programa de Python con menos líneas de código en comparación con muchos otros lenguajes.
- Python cuenta con una gran biblioteca estándar que contiene códigos reutilizables para casi cualquier tarea. De esta manera, los desarrolladores no tienen que escribir el código desde cero.
- Los desarrolladores pueden utilizar Python fácilmente con otros lenguajes de programación conocidos, como Java, C y C++.
- La comunidad activa de Python incluye millones de desarrolladores alrededor del mundo que prestan su apoyo. Si se presenta un problema, puede obtener soporte rápido de la comunidad.
- Hay muchos recursos útiles disponibles en Internet si desea aprender Python. Por ejemplo, puede encontrar con facilidad videos, tutoriales, documentación y guías para desarrolladores.
- Python se puede trasladar a través de diferentes sistemas operativos de computadora, como Windows, macOS, Linux y Unix. [20]

### **Se utiliza como interfaz gráfica Anaconda:**

#### **Anaconda:**

Anaconda es una distribución de los lenguajes de programación Python y R para computación científica (ciencia de datos, aplicaciones de Machine Learning, procesamiento de datos a gran escala, análisis predictivo, etc.).

Tiene como ventaja simplificar la gestión e implementación de paquetes. La distribución incluye paquetes de “data science” adecuados para Windows, Linux y macOS.

#### **Anaconda Navigator:**

Anaconda Navigator es una interfaz gráfica de usuario (GUI) de escritorio incluida en la distribución Anaconda que le permite iniciar aplicaciones y administrar fácilmente paquetes, entornos y canales conda sin usar comandos. [21]

#### **Jupyter Notebooks:**

Son una aplicación web, también de código abierto que nos va a permitir crear y compartir documentos con código en vivo, ecuaciones, visualizaciones y texto explicativo. Estos documentos registran todo el proceso de desarrollo y, lo más interesante, pueden ser

compartidos fácilmente con otras personas a través de correo electrónico, Dropbox, sistemas de control de versiones como git/GitHub y **nbviewer**. [22]

Entre sus usos están:

- la limpieza y transformación de datos
- la simulación numérica
- el modelado estadístico
- el aprendizaje automático

### **Librerías de Python para Machine Learning:**

#### **Tensor Flow:**

Es una librería de python, desarrollada por Google, para realizar cálculos numéricos mediante diagramas de flujo de datos. Con esta computación basada en grafos, TensorFlow puede usarse para deep learning y otras aplicaciones de cálculo científico.

#### **Keras:**

Es un interfaz de alto nivel para trabajar con **redes neuronales**. El interfaz de Keras es mucho más fácil de usar que el de TensorFlow. Esta facilidad de uso es su principal característica.

Con Keras es muy fácil comprobar si nuestras ideas tendrán buenos resultados rápidamente. Keras utiliza otras librerías de deep learning (TensorFlow, CNTK o Theano) de forma transparente para hacer el trabajo que le digamos. [23]

#### **Pandas:**

Una de las más utilizadas para el tratamiento de datos en Python. Una de las principales virtudes que tiene la librería es la carga de datos, la cual permite realizar la carga desde distintos orígenes. Entre los orígenes que acepta encontramos archivos de texto plano como CSV, ficheros en el extendido formato Excel y cargas directas desde bases de datos SQL, entre otros orígenes de datos. Todas estas fuentes de datos contienen la información en formato tabular y pandas permite representar este tipo de datos a la perfección mediante el uso de su estructura principal, el DataFrame. [23]

### **Conclusiones**

La utilización combinada de redes neuronales junto con análisis matemático y estadístico permitirá una mejora en la gestión y toma de decisiones del consumo energético. El análisis de las investigaciones homólogas analizadas en el capítulo brinda claridad en

cuanto a los pasos a seguir y metodologías a implementar, pudiendo entonces proseguir a la búsqueda y desarrollo de un modelo que brinde resultados certeros.

## CAPÍTULO II – ANÁLISIS Y DISEÑO DE LA PROPUESTA

### Capítulo II: Diseño del experimento:

En este capítulo se presenta la base de casos en un documento Excel con el formato establecido por estas, describiendo las variables y explicando la preparación de los datos. Se presentan las herramientas a emplear en la experimentación: Python con Machine Learning, así como la conversión de los datos a los formatos establecidos por esta. Se abordan teóricamente los diferentes métodos de selección de atributos y clasificación supervisada utilizados durante la experimentación. Por último, se presenta la configuración de parámetros de cada una de las técnicas.

#### 2.1 Base de casos, descripción de las variables y preparación de los datos.

Para la realización de este trabajo se ha llevado a cabo la recopilación de información que conforma la base de casos, tomada de las mediciones realizadas a los micro-contadores de la Universidad de Cienfuegos Carlos Rafael Rodríguez (UCf) en el período de enero del año 2001 hasta el año 2019.

La base de casos tiene un total de 12 variables que constituyen todos aquellos factores importantes para pronosticar el consumo de energía eléctrica en la Universidad. Estas variables fueron elegidas según el criterio tanto de especialistas eléctricos como personas interesadas en la resolución de este problema, todos trabajadores de la UCf.

##### 2.1.1 Las variables son descritas en la siguiente tabla:

<b>Variabes</b>	<b>Descripción</b>
year	año
Mes	mes
MesCod	Mes codificado 1:12
MWh	Consumo de energía eléctrica mensual en la sede CRR(MWh).
Bec	Cantidad de becados
CantComp	Cantidad de computadoras
AA	Cantidad de equipos de aire acondicionado
MT	Matrícula Total
MD	Estudiantes de curso diurno
Trab	Cantidad de trabajadores
H2O	Consumo de agua mensual (m3)
tmed	Temperatura ambiente media mensual (oC)

Tabla 2.1 Descripción de las variables utilizadas

### 2.1.2 Graficar serie temporal:

Para el desarrollo del trabajo se utilizaron series de tiempo ya que nos permiten desarrollarnos en diferentes campos utilizando un conjunto de datos igualmente espaciados en el tiempo. Como es nuestro caso al contar con una serie de datos de consumo MWh desde el año 2001 hasta diciembre del año 2019 con un total de 228 datos de consumo.

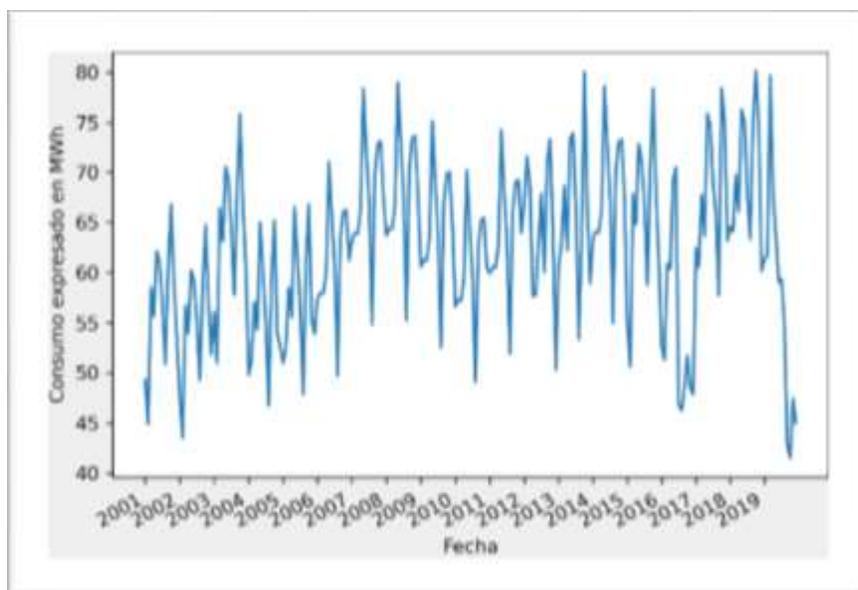


Figura 2.1 Descripción de la serie temporal

La figura anterior representa una serie de tiempo. Los datos están indexados por tiempo como se ilustra en el eje horizontal. Estos datos representan el consumo en MWh de la Universidad de Cienfuegos Carlos Rafael Rodríguez durante los años desde el 2001 hasta diciembre del año 2019.

Podemos ver que los valores tienen un comportamiento cíclico durante todo el año, manteniéndose este comportamiento de una manera similar durante toda la serie, alcanzando los valores más bajos a finales del año 2019.

### 2.1.3 Descomposición de la serie:

Es importante analizar el comportamiento de la serie analizando sus tres componentes: una tendencia, un componente estacional y los residuos.

La visualización de los componentes de una serie temporal se conoce como descomposición. La descomposición se define como una tarea estadística que separa una serie de tiempo en sus diferentes componentes. Podemos visualizar cada

componente individual que nos ayuda a identificar la tendencia y el patrón estacional en nuestros datos, lo que no siempre es sencillo con solo mirar nuestro conjunto de datos.

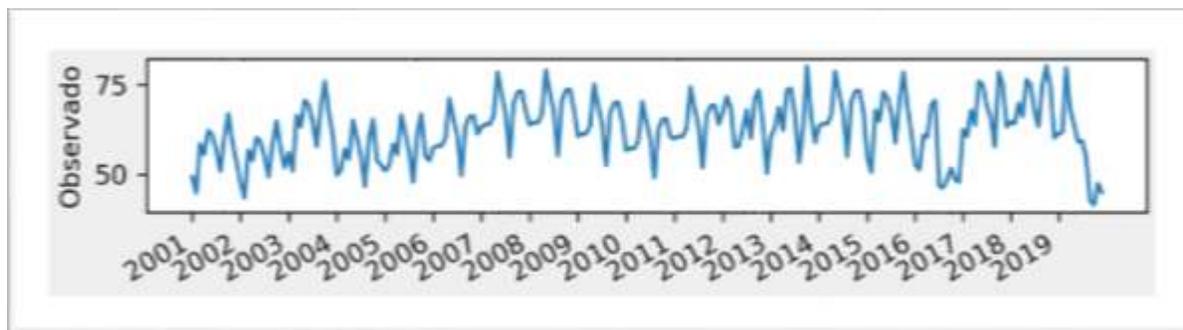


Figura 2.2 Comportamiento de la serie de tiempo

Primero el gráfico superior etiquetado como Observado, muestra la serie temporal tal como se registró. El eje Y muestra el valor de los MWh consumidos durante cada año en la Universidad de Cienfuegos, mientras que el eje X representa el tiempo.

El siguiente gráfico para analizar es el etiquetado como Tendencia. Se observa que nuestra serie no tiene una tendencia fija, esta aumenta o disminuye por intervalos de tiempo.

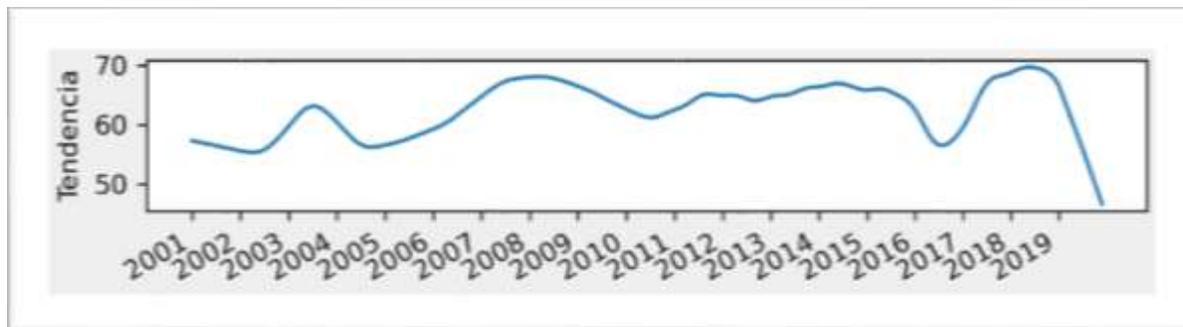


Figura 2.3 Tendencia de la serie temporal

El componente estacional. El mismo captura la variación estacional, que es un ciclo que ocurre durante un período fijo de tiempo. Se hace notar que el consumo se mantiene aumentando y disminuyendo de manera casi idéntica año tras año.

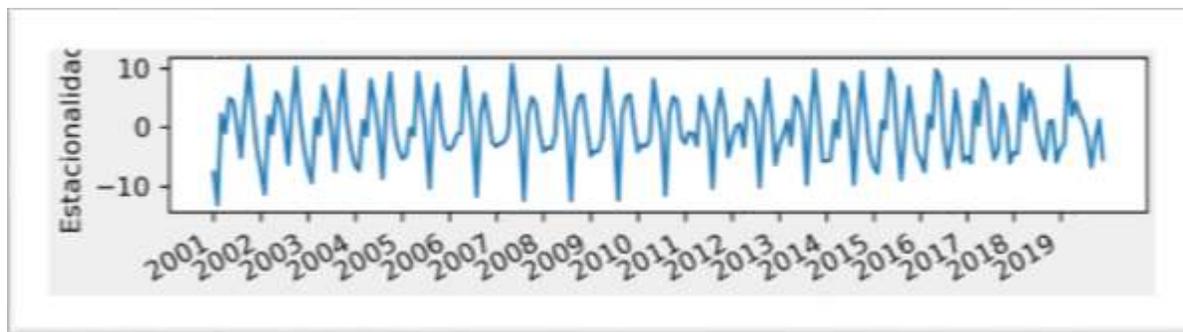


Figura 2.4 Estacionalidad de la serie temporal

Por último, se muestran los residuos, que es lo que no se puede explicar ni por la tendencia ni por el componente estacional. Podemos pensar en los residuos como sumando Tendencia y Estacional juntos y comparando el valor en cada punto en el tiempo para Observado. Para ciertos puntos, podríamos obtener exactamente el mismo valor que en Observado, en cuyo caso el residuo será cero.

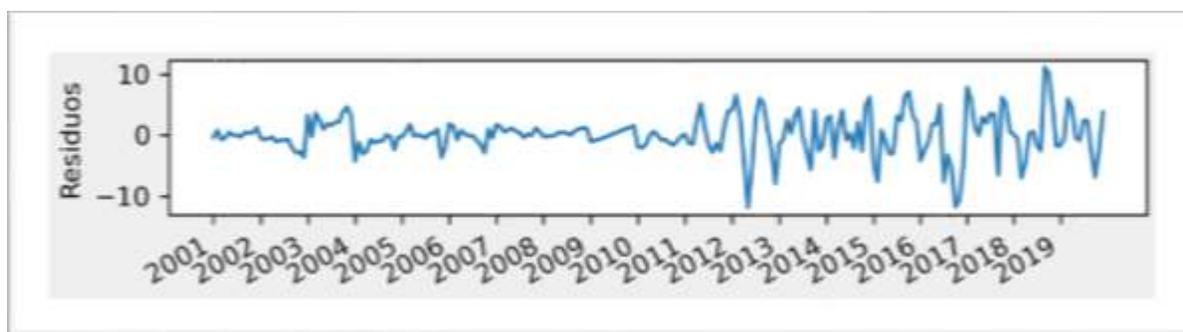


Figura 2.5 Residuos de la serie temporal

#### 2.1.4 Paseo aleatorio (random walk):

Un paseo aleatorio es un proceso en el que existe la misma probabilidad de subir o bajar un número aleatorio. Esto suele observarse en datos financieros y económicos. A menudo se acompaña de cambios repentinos de dirección.

En el contexto de las series temporales, un paseo aleatorio se define como una serie cuya primera diferencia es estacionaria y no correlacionada. [24]

##### 2.1.4.1 Pasos para saber si es un paseo aleatorio:

El primer paso natural es tener datos, como es nuestro caso. Luego, probamos la estacionalidad. En el caso de que nuestros datos no sean estacionarios, aplicaremos una transformación, como la diferenciación, y probaremos la estacionalidad nuevamente. Si

es así, podemos trazar la función de autocorrelación (ACF). Si la gráfica no muestra coeficientes de autocorrelación significativos, podemos modelar nuestra serie temporal como un paseo aleatorio. [24]

#### **2.1.4.2 Probar Estacionalidad:**

Una serie de tiempo estacionaria es aquella cuyas propiedades estadísticas no cambian con el tiempo. En otras palabras, tiene una media constante, varianza y autocorrelación, y estas propiedades son independientes del tiempo.

Para saber si nuestra serie es estacionaria se llevó a cabo la prueba de Dickey-Fuller aumentada (ADF). [24]

La prueba ADF verifica la siguiente hipótesis nula: hay una raíz unitaria presente en una serie de tiempo. La hipótesis alternativa es que no existe raíz unitaria y, por lo tanto, la serie temporal es estacionaria. El resultado de esta prueba es la estadística ADF que es un número negativo. Cuanto más negativa es, más fuerte es el rechazo de la hipótesis nula. En su implementación en Python, también se devuelve el valor p. Si su valor es inferior a 0,05, también podemos rechazar la hipótesis nula. [24]

Luego de aplicarle a la serie de tiempo la prueba ADF imprime una estadística de -3,36 y un valor de p de 0,012. Claramente la estadística ADF es un número negativo grande y con un valor de p menor que 0,05 podemos rechazar la hipótesis nula que establece que nuestra serie de tiempo no es estacionaria.

Una vez que un proceso es estacionario, trazar la función de autocorrelación es una excelente manera de comprender qué tipo de proceso se está analizando.

#### **2.1.4.3 Función de Autocorrelación:**

La función de autocorrelación (ACF) mide la relación lineal entre los valores retrasados de una serie de tiempo. En otras palabras, mide la correlación de la serie temporal consigo misma.

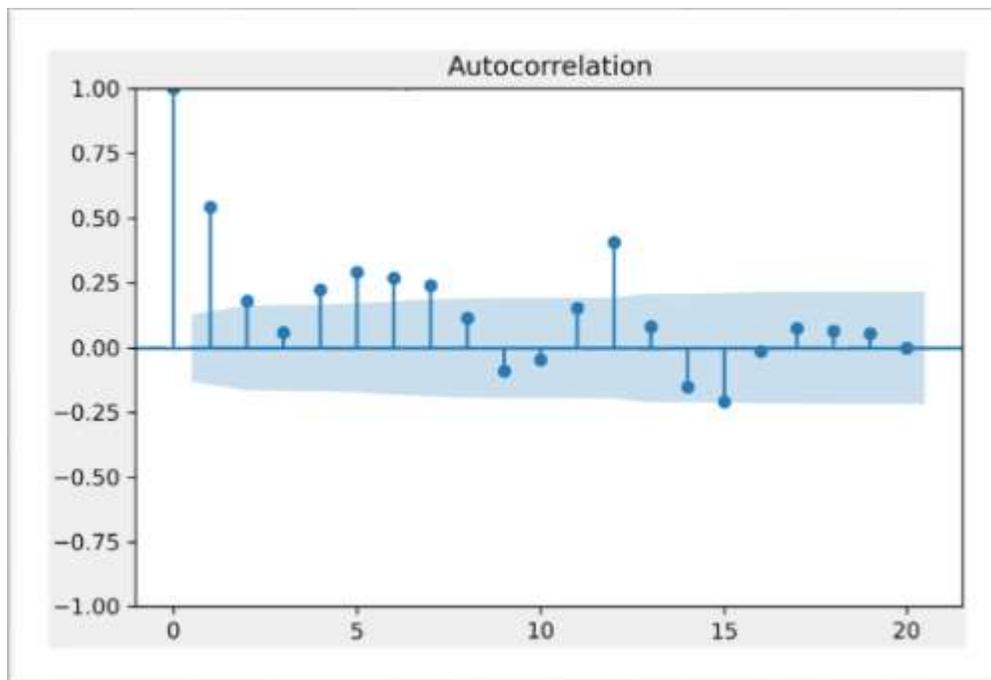


Figura 2.6 Función de autocorrelación

Observando la figura, notamos cómo los coeficientes de autocorrelación aumentan y disminuyen a medida que aumenta el retraso, podemos notar cómo se muestran valores significativos después del paso 0 que disminuyen lentamente, al no tener una caída abrupta entonces no se vuelven no significativos. Podemos concluir entonces que no nos encontramos en presencia de un paseo aleatorio.

Luego de concluir que no presenta paseo aleatorio se puede aplicar entonces métodos estadísticos y de aprendizaje profundo.

## 2.2. Desarrollo de modelos de Redes neuronales para series de tiempo:

Las series de tiempo se pueden desarrollar usando modelos estadísticos como se ha visto anteriormente, pero existen modelos de más alto rendimiento que responden de una mejor manera a nuestras necesidades, son aquellos relacionados con las redes neuronales. [24]

Por lo tanto, se recurre al Aprendizaje Profundo. Es un subconjunto del aprendizaje automático que se enfoca en construir modelos en la arquitectura de la red neuronal. El aprendizaje profundo tiene la ventaja de que tiende a funcionar mejor a medida que hay más datos disponibles, lo que lo convierte en una excelente opción para pronosticar series temporales de gran dimensión.

Hay tres tipos principales de modelos de aprendizaje profundo que se pueden construir para el pronóstico de series de tiempo: modelos de un solo paso, modelos de varios pasos y modelos de salida múltiple.

**Modelo de un solo paso:**

El modelo de un solo paso genera un valor único que representa la predicción para el siguiente paso de tiempo. La entrada puede tener cualquier longitud, pero la salida sigue siendo una única predicción para el siguiente paso de tiempo.

**Modelo de varios pasos:**

En un modelo de varios pasos, la salida del modelo es una secuencia de valores que representan predicciones para muchos pasos de tiempo en el futuro. Por ejemplo, si el modelo predice las próximas 6 horas, 24 horas o 12 meses, es un modelo de varios pasos.

**Modelo de salida múltiple:**

Un modelo de salida múltiple genera predicciones para más de un objetivo. Por ejemplo, si pronosticamos la temperatura y la velocidad del viento, es un modelo de múltiples salidas.

En este trabajo se emplea el modelo de varios pasos ya que la salida del modelo es una secuencia de valores que representan predicciones para muchos pasos de tiempo en el futuro. Para el presente caso se predicen los próximos 12 pasos.

**Para aplicar este modelo se siguen una serie de pasos:**

- 1- Obtener los datos necesarios
- 2- Realizar el análisis de los datos
- 3- Dividir los datos en tres esferas: 70% entrenamiento, 20% validación y 10% prueba

Para comenzar a aplicar el aprendizaje profundo, primeramente, realizamos la exploración de los datos:

Se inicia el proceso cargando los datos usando la librería de Pandas. Estos datos se encuentran en archivo tipo csv que contempla las variables asociadas al consumo y el valor mensual para cada una de ellas. El conjunto de datos comienza en el año 2001 y finaliza en diciembre del año 2019.

Se encuentran como características esenciales la temperatura, la fecha y el consumo total mensual de MWh. En la realización del análisis anterior de la descomposición de la

serie de tiempo se pudo apreciar que contaba con estacionalidad al analizar año tras año, los meses pico y los de consumo normal.

### 2.2.1 Fragmentación de datos:

Luego de culminada el proceso de la exploración de los datos se procede a la división de datos. Se divide el modelo en: tren de datos, validación y conjuntos de prueba. El conjunto de trenes es la muestra de datos utilizada para ajustar el modelo. El conjunto de validación es un poco como un conjunto de prueba al que el modelo puede echar un vistazo para ajustar sus hiperparámetros y mejorar su rendimiento durante el entrenamiento del modelo. El conjunto de prueba está completamente separado del procedimiento de entrenamiento del modelo y se utiliza para una evaluación imparcial del rendimiento del modelo. Se usa una división de 70:20:10 para los conjuntos de entrenamiento, validación y prueba.

Antes de guardar los datos se escalan para que todos los valores estén entre 0 y 1. Esto disminuye el tiempo requerido para entrenar modelos de aprendizaje y mejorar su rendimiento. Se utiliza MinMaxScaler para aprender a escalar los datos. Este procedimiento se realiza para evitar la fuga de datos. De esta manera estamos simulando el hecho de que solo tenemos los datos de entrenamiento disponibles cuando estamos usando el modelo, y el modelo no conoce información futura.

### 2.2.2 Ventanas de datos:

Para los modelos de aprendizaje profundo, no tenemos un conjunto de funciones para probar. En su lugar, dejamos que la red neuronal derive su propia función de modo que cuando tome las entradas, genere las mejores predicciones posibles. Para lograrlo, realizamos lo que se denomina ventanas de datos. Este es un proceso en el que definimos una secuencia de puntos de datos en nuestra serie temporal y definimos cuáles son entradas y cuáles etiquetas. De esa forma, el modelo de aprendizaje profundo puede adaptarse a las entradas, generar predicciones, compararlas con las etiquetas y repetir este proceso hasta que no pueda mejorar la precisión de sus predicciones. [24]

Entrada					Etiqueta				
T=0	T= 1	T=...	T= 10	T=11	T= 12	T=13	T=...	T=22	T=23

Tabla 2.2 Ventana de Datos

Se presenta un ejemplo de ventana de datos. Nuestra ventana de datos tiene 12 pasos de tiempo como entrada y 12 pasos de tiempo como salida. Luego, el modelo utilizará 12 horas de entrada para generar 12 meses de predicciones. La longitud total de la ventana de datos es la suma de la longitud de las entradas y las etiquetas. En este caso, tenemos una longitud total de 24 pasos de tiempo.

### Ejemplo:

Visualización de las ventanas de datos en el conjunto de entrenamiento. Las entradas se muestran con marcadores cuadrados y las etiquetas se muestran con cruces. Cada ventana de datos consta de 24 intervalos de tiempo con marcadores cuadrados seguidos de 24 etiquetas con cruces.

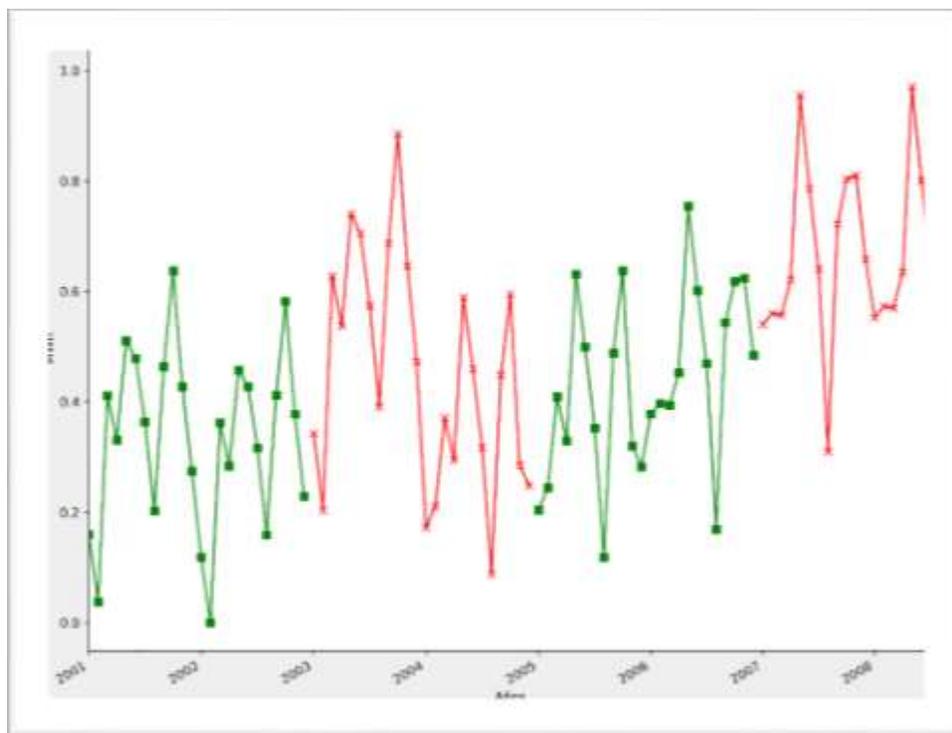


Figura 2.7 Ejemplo de Ventana de Datos

### 2.2.3 Aplicación de modelos de referencia de varios pasos:

Para los modelos de varios pasos, se predice más de un paso de tiempo en el futuro. En este caso, se pronostica el consumo energético para los próximos 12 meses de datos con una entrada. Con eso en mente, implementemos la primera línea de base, donde simplemente repetiremos el último valor conocido durante los próximos 24 intervalos de tiempo de 12 meses.

El primer paso es generar la ventana de datos adecuada. Debido a que se desea predecir 12 pasos de tiempo en el futuro con una entrada de 12 meses, el ancho de entrada es 12, el ancho de la etiqueta es 12 y el cambio también es 12.

Con la ventana de datos generada, ahora se implementan los modelos de referencia. En esta situación, hay dos líneas de base razonables:

- 1- Prediga el último valor conocido para los próximos 12 intervalos de tiempo.
- 2- Prediga los últimos 12 pasos de tiempo para los próximos 12 pasos de tiempo.

Con eso en mente, implementemos la primera línea de base, donde simplemente repetiremos el último valor conocido durante los próximos 12 intervalos de tiempo.

Para predecir el último valor conocido, se implementa una clase toma la entrada y repite el último valor de la secuencia de entrada en 12 pasos de tiempo. Esto actúa como la predicción del modelo.

A continuación, se inicializa la clase y especificaremos la columna de destino. Luego se repiten los mismos pasos que en la sección anterior, compilando el modelo y evaluándolo en el conjunto de validación y el conjunto de prueba.

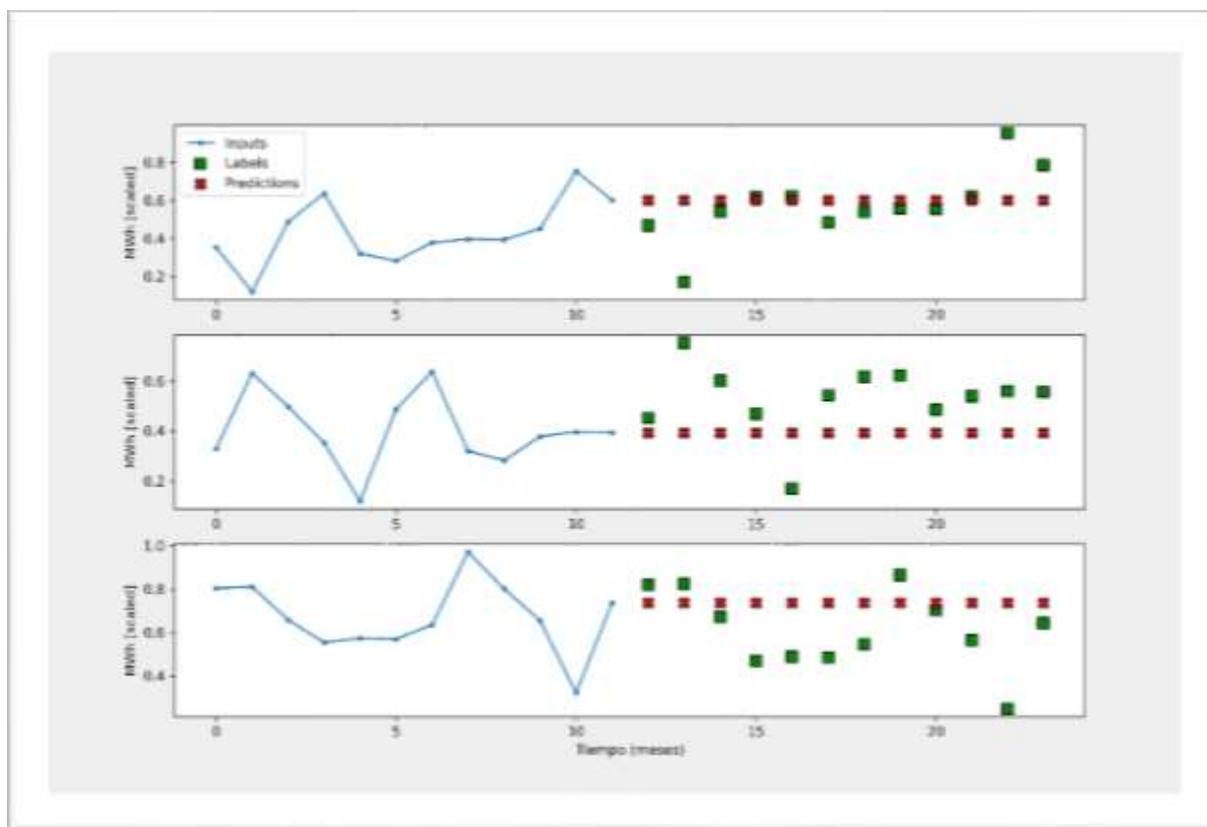


Figura 2.8 Modelo Base

Predicción del último valor conocido para los siguientes 12 intervalos de tiempo. Se observa que las predicciones, que se muestran como cruces, corresponden al último valor de la secuencia de entrada, por lo que nuestra línea de base se comporta como se esperaba.

### 2.2.7 Se repite la secuencia de entrada:

Se implementa una segunda línea de base para modelos de varios pasos, que simplemente devuelve la secuencia de entrada. Esto significa que la predicción para los próximos 12 meses será simplemente los últimos 12 meses conocidos de datos. Esto se implementa a través de la otra clase.

A continuación, se visualizan las predicciones. El resultado se muestra en la figura siguiente. Esta línea de base funciona bien. Esta línea de base es el equivalente a predecir la última temporada conocida.

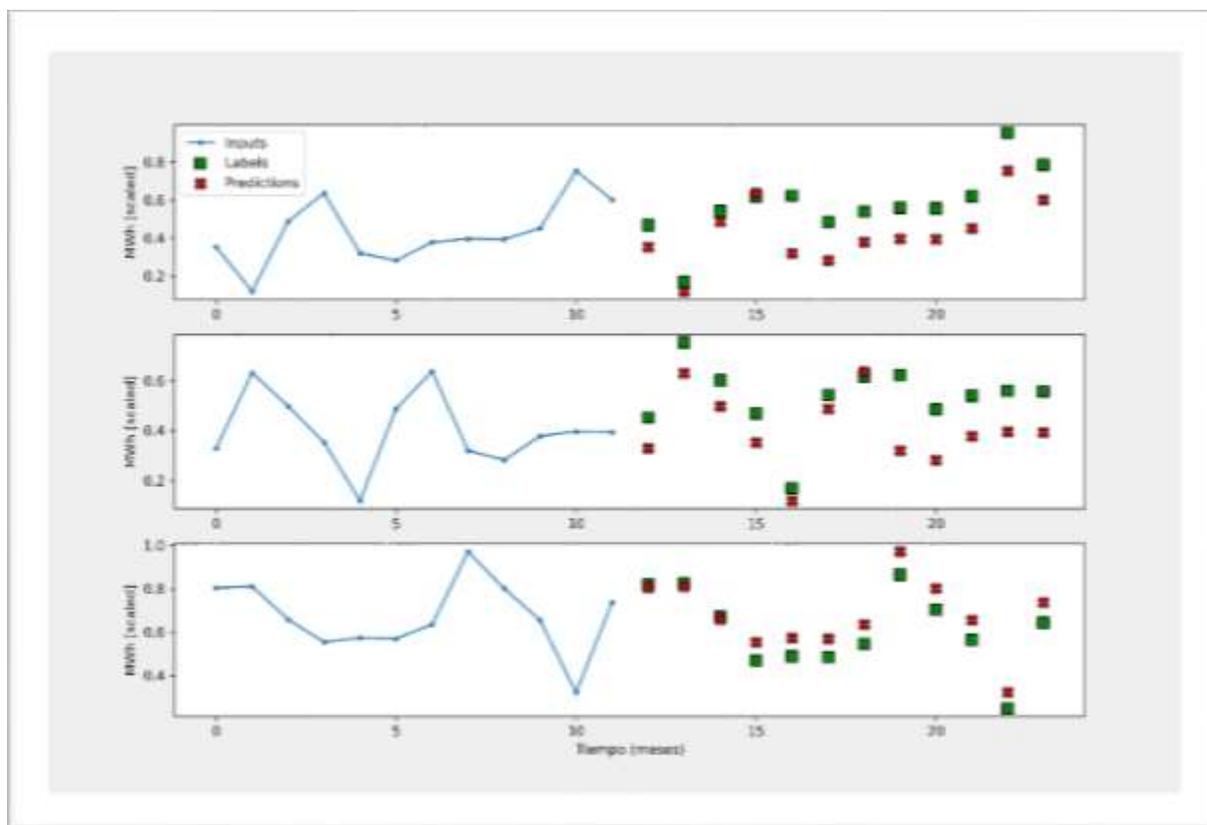


Figura 2.9 Repetir modelo Base

Repetición de la secuencia de entrada como predicciones. Las predicciones (representadas como cruces) coinciden exactamente con la secuencia de entrada. También se nota que algunas predicciones superponen las etiquetas, lo que indica que esta línea de base funciona bastante bien.

Una vez hecho el análisis de ambos modelos base, se concluye que el segundo presenta mejores resultados que el primero, acercándose aún más a los valores reales de entrada de nuestros datos. Además, el segundo modelo presenta una relación casi exacta entre los valores reales y los valores resultados de las predicciones.

### **2.3 Redes Neuronales:**

Luego de desarrollar los modelos de referencia para varios pasos, se procede al análisis ya que servirán como punto de referencia para modelos más complejos. Implementaremos modelos lineales y redes neuronales profundas. Un Modelo lineal es un caso especial de una red neuronal, donde no hay una capa oculta. Este modelo simplemente calcula pesos para cada variable de entrada para generar una predicción para el objetivo. Por el contrario, una red neuronal profunda tiene al menos una capa oculta, lo que nos permite comenzar a modelar relaciones no lineales entre las características y el objetivo, lo que generalmente da como resultado mejores pronósticos.

#### **2.3.1 Modelo Lineal de varios pasos:**

Un Modelo lineal es la arquitectura más simple que podemos implementar en el aprendizaje profundo. De hecho, podríamos argumentar que no es un aprendizaje profundo en absoluto, ya que el modelo no tiene una capa oculta. Cada característica de entrada simplemente recibe un peso y se combinan para generar una predicción para el objetivo, al igual que en una regresión lineal tradicional. [24]

A diferencia de un modelo de referencia, un modelo lineal en realidad requiere entrenamiento. Así, se define un compilar y ajustar función que configura el modelo para el entrenamiento y luego ajusta el modelo a los datos.

#### **2.3.2 Función para configurar un modelo de aprendizaje y configurarlo a los datos:**

**Para el ajuste de los datos se tiene en cuenta lo siguiente:**

- 1- La función toma un modelo y una ventana de datos de la clase DataWindow. La paciencia es el número de épocas después de las cuales el modelo debe dejar de entrenarse si la pérdida de validación no mejora; max\_epochs establece un

número máximo de épocas para entrenar el modelo. (def compile\_and\_fit(modelo, ventana, paciencia=?, max\_epochs=?))

- 2- La pérdida de validación se rastrea para determinar si debemos aplicar la parada temprana o no. Parada temprana ocurre si el valor de la paciencia para épocas consecutivas no disminuya la pérdida de validación, ya que establecido por el parámetro de paciencia.
- 3- El Error Absoluto Medio (MAE) se utiliza como una métrica de error. Así es como se compara el rendimiento de nuestros modelos. Un MAE más bajo significa un mejor modelo.
- 4- **early\_stopping**: se pasa como un callback. Si la pérdida de validación no disminuye después de 3 épocas consecutivas, el modelo deja de entrenar. Este evita el sobreajuste.
- 5- El parámetro max\_epochs establece el número máximo de veces que puede entrenar el modelo.

Luego se compila el modelo. En Keras, esto simplemente configura el modelo para especificar la función de pérdida a utilizar, el optimizador y las métricas de evaluación. En nuestro caso, usaremos el Error Cuadrático Medio (MSE) como la función de pérdida, lo que significa que el modelo se penaliza en gran medida por las grandes diferencias entre los valores predichos y reales. Se emplea el optimizador Adam por ser un optimizador rápido y eficiente. Finalmente, se emplea el MAE como una métrica de evaluación para comparar el rendimiento de los modelos.

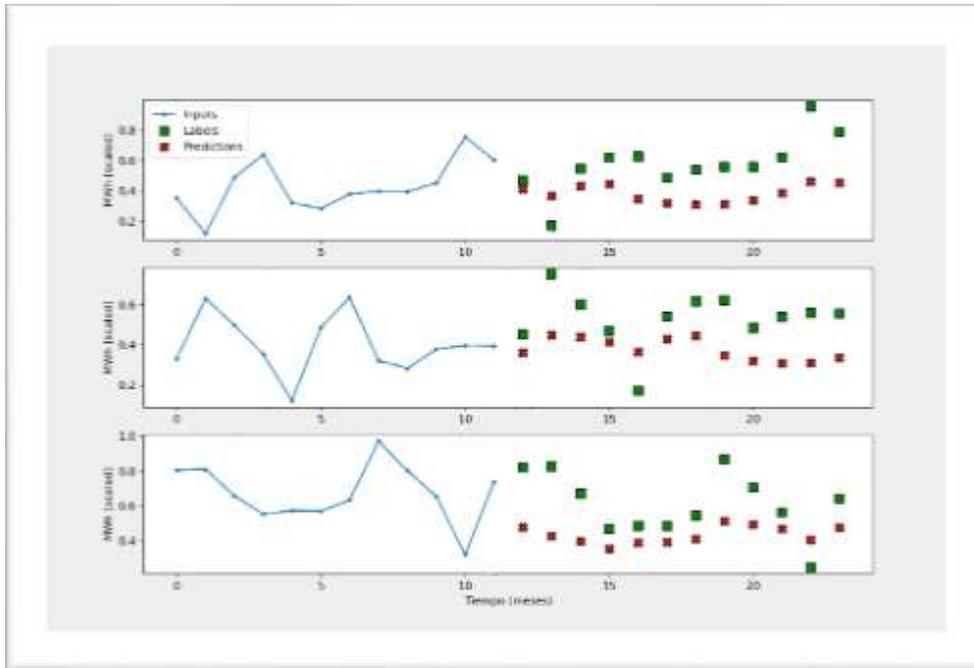


Figura 2.10 Modelo Lineal

El modelo lineal presentado anteriormente usa la misma estructura de datos de los modelos base: mismo tamaño de entrada: 12, la misma cantidad de etiquetas:12, así como la misma cantidad de objetos a predecir.

### 2.3.3 Modelo Red neuronal profunda:

Se ha demostrado empíricamente que agregar capas ocultas en las redes neuronales ayuda a lograr mejores resultados. [24]

Los modelos lineales no tienen capas ocultas; el modelo tiene una capa de entrada y una capa de salida. En una red neuronal profunda (DNN), agregaremos más capas entre las capas de entrada y salida, llamadas capas ocultas. Esta diferencia en la arquitectura se destaca a continuación:

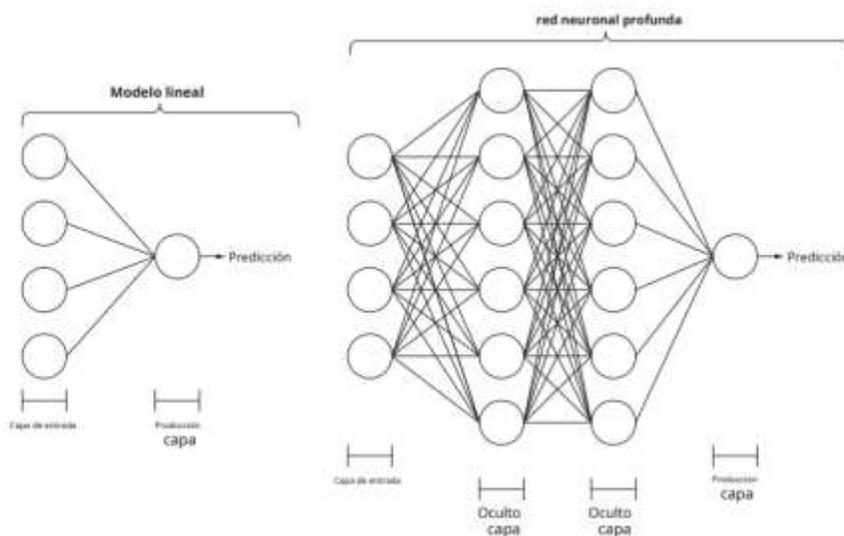


Figura 2.11. Modelo lineal y modelo red neuronal profunda

La idea detrás de agregar capas a la red es que le da al modelo más oportunidades de aprender, lo que generalmente da como resultado que el modelo generalice mejor los datos no vistos, mejorando así su rendimiento. Por supuesto, con capas adicionales, el modelo necesariamente entrena durante más tiempo y, por lo tanto, se supone que aprende mejor.

Cada círculo en una capa oculta representa una neurona y cada neurona tiene una función de activación. El número de neuronas es igual al número de unidades que se pasa como argumento en el modelo Denso usando Keras. Por lo general, se establece la cantidad de unidades, o neuronas, como una potencia de 2, ya que es más eficiente desde el punto de vista computacional: los cálculos en la CPU y la GPU se realizan en tamaños de lote que también son potencias de 2.

Antes de implementar una DNN, se debe abordar la función de activación en cada neurona de las capas ocultas. La función de activación define la salida de cada neurona en función de la entrada. Por lo tanto, si se desea modelar relaciones no lineales, para ello se usa una función de activación no lineal.

Se utiliza la función de activación de la Unidad Lineal Rectificada (ReLU). Esta función de activación no lineal básicamente devuelve la parte positiva de su entrada o 0, como se define en la ecuación.

$$F(X) = X + \max(0, X)$$

Esta función de activación tiene muchas ventajas, como una mejor propagación de gradientes, un cálculo más eficiente y una invariancia de escala. Por todas esas razones, ahora es la función de activación más utilizada en el aprendizaje profundo, y la usaremos siempre que tengamos una Denso capa que es una capa oculta. [24]

### 2.3.4 Implementación de una red neuronal Profunda con modelo de varios pasos:

Se implementó una red neuronal profunda como un modelo de varios pasos. Con 3 neuronas de entrada que representan el tiempo, el consumo MWh y la fecha. La red cuenta con 3 capas ocultas, la primera con 64 neuronas, la segunda con 32 y la tercera con 64 neuronas. La capa de salida representa el valor del consumo MWh.

Luego, se entrena el modelo y se guarda su rendimiento para compararlo con los modelos lineales y de referencia.

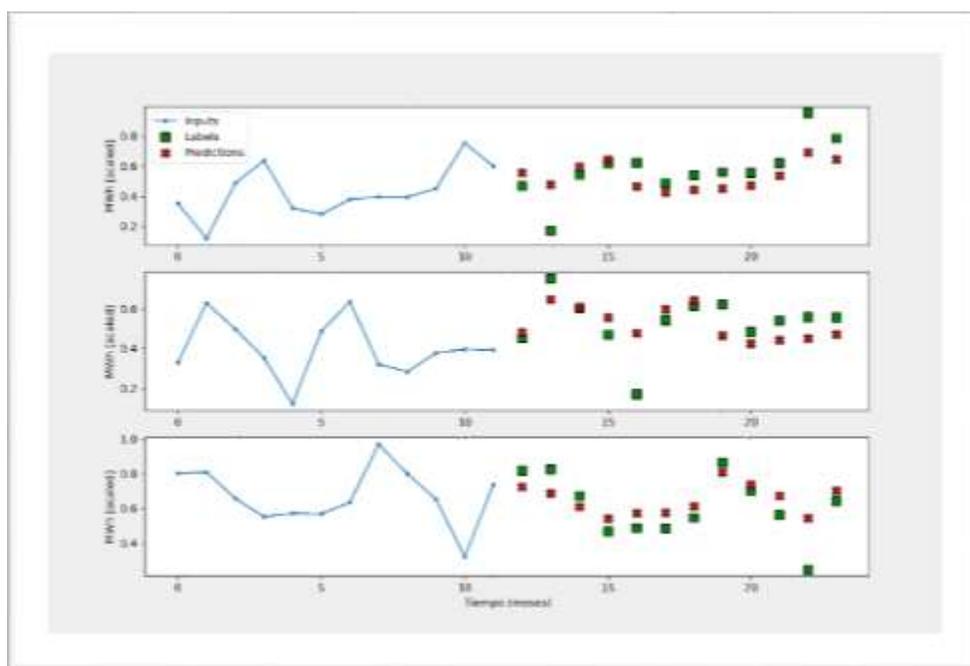


Figura 2.12 Modelo de Red neuronal profunda

Se compara el MAE de la DNN con el modelo lineal y la línea base que se construyó anteriormente. Los resultados se muestran de la siguiente manera:

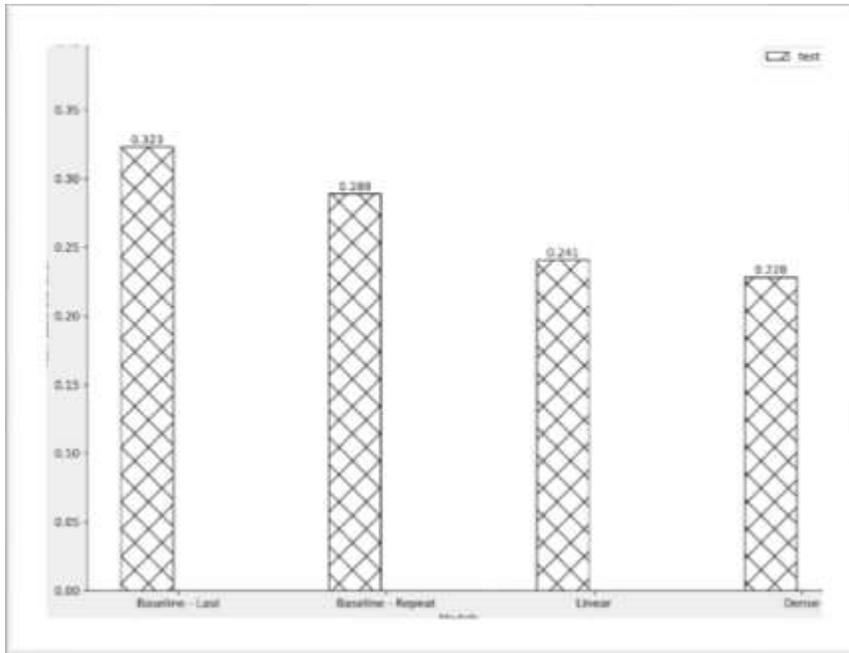


Figura 2.13 índice del MAE de los modelos desarrollados.

A través de este gráfico de barras que el modelo que presenta mejores resultados es el modelo de red neuronal profunda aportando un índice de error de 0,228, siendo este el más bajo de todos y por ende mientras más bajo menor porcentaje de error y mayor será la correspondencia entre los valores de entrada y las predicciones.

### Conclusiones:

Se analizaron y trataron los datos descomponiéndolos en Observado, Tendencia, Estacionalidad y Residuos. Se comprobó si constituía un paseo aleatorio para lo cual se concluyó que no lo es, en este paso se comprobó la estacionalidad y se trazó la función de autocorrelación. Se desarrollaron los modelos de redes neuronales para series de tiempo utilizando la arquitectura de varios pasos en el tiempo, para lo cual se fragmentaron los datos y se crearon las ventanas de los mismos. Se desarrollaron dos modelos base, un modelo lineal y un modelo Denso que brindó el menor índice de error, por lo que se ajusta de una mejor manera a nuestras necesidades.

## Capítulo III – Descripción de la solución propuesta

### **Introducción:**

En el capítulo anterior, se construyeron los primeros modelos en aprendizaje profundo, implementando modelos de redes neuronales lineales y profundas. En el caso de nuestro conjunto de datos, se pudo apreciar que ambos modelos superaron las líneas base que se construyen en el capítulo 2, siendo la red neuronal profunda el mejor modelo para tareas de varios pasos.

A continuación, se analiza una arquitectura más avanzada llamada memoria a corto plazo (LSTM), que es un caso particular de una red neuronal recurrente (RNN). Este tipo de red neuronal se utiliza para procesar secuencias de datos, donde el orden importa. Una aplicación común de RNN y LSTM es el procesamiento del lenguaje natural. Las palabras en una oración tienen un orden, y cambiar ese orden puede cambiar completamente el significado de una oración. Por lo tanto, a menudo encontramos esta arquitectura detrás de los algoritmos de clasificación y generación de texto.

### **3.1 Red Neuronal Recurrente:**

Una red neuronal recurrente (RNN) es una arquitectura de aprendizaje profundo especialmente adaptada para procesar secuencias de datos. Denota un conjunto de redes que comparten una arquitectura similar: la memoria a corto plazo (LSTM) y la unidad recurrente cerrada (GRU) son subtipos de RNN.

Una red neuronal recurrente (RNN) está especialmente adaptada para procesar secuencias de datos. Utiliza un estado oculto que se retroalimenta a la red para que pueda usar información pasada como entrada al procesar el siguiente elemento de una secuencia. Es así como replica el concepto de memoria. Sin embargo, los RNN sufren de memoria a corto plazo, lo que significa que la información de un elemento temprano en la secuencia dejará de tener un impacto más adelante en la secuencia.

Por lo tanto, debemos encontrar una manera de retener la importancia de la información pasada en nuestra red. Esto nos lleva a la arquitectura de memoria a largo plazo (LSTM), que utiliza el estado de la celda como una forma adicional de mantener información pasada en la memoria durante mucho tiempo. [24]

Memoria a corto plazo (LSTM): agrega un estado de celda a la arquitectura RNN para evitar el problema del gradiente de fuga, donde la información pasada deja de afectar el aprendizaje de la red. Esto permite que la red mantenga la información pasada en la memoria durante más tiempo. [24]

La memoria a corto plazo (LSTM) es una arquitectura de aprendizaje profundo que es un subtipo de RNN. LSTM aborda el problema de la memoria a corto plazo al agregar el estado de la celda. Esto permite que la información pasada fluya a través de la red durante un período de tiempo más largo, lo que significa que la red aún transporta información de los primeros valores de la secuencia. El LSTM se compone de tres puertas:

- **La puerta del olvido:** determina qué información de los pasos anteriores sigue siendo relevante.
- **La puerta de entrada:** determina qué información del paso actual es relevante.
- **La puerta de salida:** determina qué información se pasa al siguiente elemento de la secuencia o, como resultado, a la capa de salida. [24]

### **3.2 Se implementa la arquitectura del modelo LSTM para modelo de varios pasos:**

Ahora se implementa la arquitectura LSTM para el conjunto de datos de consumo de MWh con el que se ha estado trabajando anteriormente. El objetivo principal de nuestro escenario es el consumo MWh. Para el modelo de varios pasos, los objetivos son: el consumo mensual MWh y la temperatura juntamente con la fecha.

En este caso, se desea predecir el consumo MWh para los próximos 12 meses, utilizando una ventana de entrada de 12 meses.

Primero, se define la ventana de tiempo para alimentar nuestro modelo. Los anchos de entrada y ancho etiqueta son 12, ya que queremos ingresar 12 meses de datos y evaluar las predicciones en 12 meses de datos también. Esta vez el cambio también es 12, lo que especifica que el modelo debe generar predicciones para los próximos 12 meses en una sola toma. A continuación, se define el modelo en Keras y una vez que esté definido, se entrena el modelo y almacenaremos sus métricas de evaluación para comparar.

Se puede visualizar las predicciones del modelo en el siguiente gráfico:

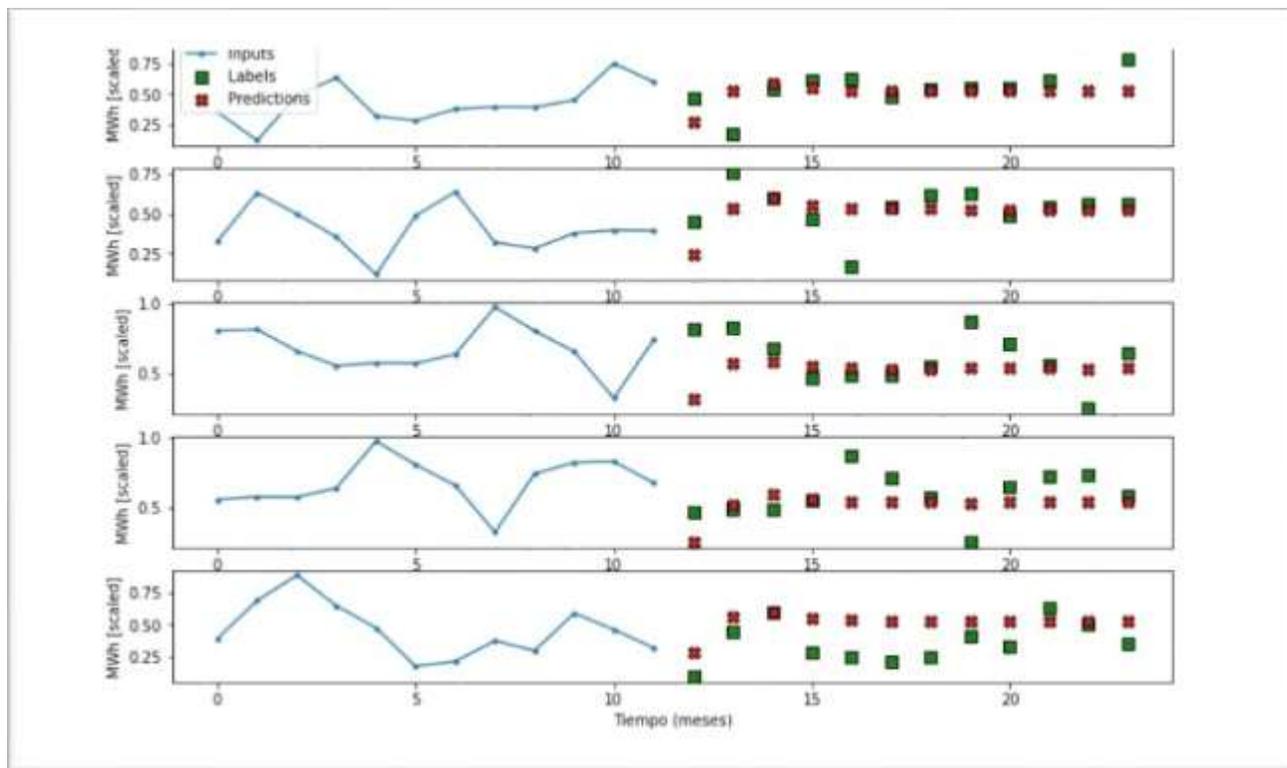


Figura 3.1 Salida del modelo LSTM.

### 3.3 LSTM Autorregresivo (ARLSTM):

Se centra por completo en los modelos de varios pasos, ya que todos generan la secuencia completa de predicciones en una sola toma. Se procede a modificar ese comportamiento y generar gradualmente la secuencia de predicción, usando predicciones pasadas para hacer nuevas predicciones. De esa forma, el modelo creará pronósticos continuos, pero usando sus propios pronósticos para informar la salida. Esta arquitectura se usa comúnmente con LSTM y se llama LSTM autorregresivo (ARLSTM). [24]

Se han creado muchos modelos de varios pasos que generan predicciones para el volumen de tráfico en los próximos 12 meses. Cada modelo ha generado la secuencia de predicción completa en una sola secuencia, lo que significa que obtenemos 12 valores del modelo de inmediato.

Se puede ver lo fácil que se vuelve generar cualquier longitud de secuencia utilizando una arquitectura de aprendizaje profundo autorregresivo. Este enfoque tiene la ventaja adicional de permitirnos pronosticar series de tiempo con diferentes escalas, como horas, días o meses, al tiempo que evita tener que volver a entrenar un nuevo modelo.

Sin embargo, los modelos de aprendizaje profundo autorregresivos vienen con una advertencia importante, que es la acumulación de errores. Se han pronosticado muchas series de tiempo y sabemos que siempre hay alguna discrepancia entre las predicciones y los valores reales. Ese error se acumula a medida que se retroalimenta al modelo, lo que significa que las predicciones posteriores tendrán un error mayor que las predicciones anteriores. Por lo tanto, si bien la arquitectura de aprendizaje profundo autorregresivo parece poderosa, podría no ser la mejor solución para un problema en particular. De ahí la importancia de utilizar un protocolo de prueba riguroso. [24]

### **Construcción del modelo:**

Es de esta manera que se procede para codificar nuestro propio modelo de aprendizaje profundo autorregresivo en Keras. Específicamente, codificaremos un modelo ARLSTM. Se define la ventana de datos. En este caso, se reutiliza la ventana de datos que se usó para el modelo LSTM. Las secuencias de entrada y etiqueta tendrán cada uno 12 pasos de tiempo.

Se especifica un cambio de 12 para que el modelo genere 12 predicciones. El objetivo sigue siendo el consumo MWh. Luego se envuelve el modelo en una clase llamada Autorregresivo, que hereda del Modelo clase en Keras. Esto es lo que nos permite acceder a entradas y salidas. De esa forma, podremos especificar que la salida debe convertirse en una entrada en cada paso de predicción.

### **Esta función toma tres parámetros:**

- self: Hace referencia a la instancia del Autoregresivoclase.
- Unidades: Representa el número de neuronas en una capa.
- shift: Representa la longitud de la secuencia de predicción. En este caso, son 12.

Luego se hace uso de tres capas diferentes de Keras: la Densocapa, la RNNcapa, y la LSTMCellcapa. Los LSTMCellcapa es una capa de nivel inferior a la LSTMcapa. Permite acceder a información más granular, como el estado y las predicciones, que luego se pueden manipular para enviar una salida al modelo como entrada. En cuanto a RNN capa, esto se utiliza para entrenar la capa LSTMCell en los datos de entrada. Luego, su salida se pasa a través de la capa Densa para generar una predicción.

Una vez realizada la inicialización, el siguiente paso es definir una función que genere la primera predicción. Dado que este es un modelo autorregresivo, esa predicción se



Figura 3.2 Salida del modelo LSTM autorregresivo.

Muchas predicciones están muy cerca de los valores reales, a veces incluso superponiéndolos. Esto indica que se tiene un modelo bastante preciso.

Esta inspección visual no es suficiente para determinar si tenemos un nuevo modelo de alto rendimiento, por lo que se muestra su MAE frente a todos los modelos anteriores de varios pasos. El resultado se muestra en la figura siguiente, que muestra que el modelo LSTM autorregresivo logra un MAE de 0.237.

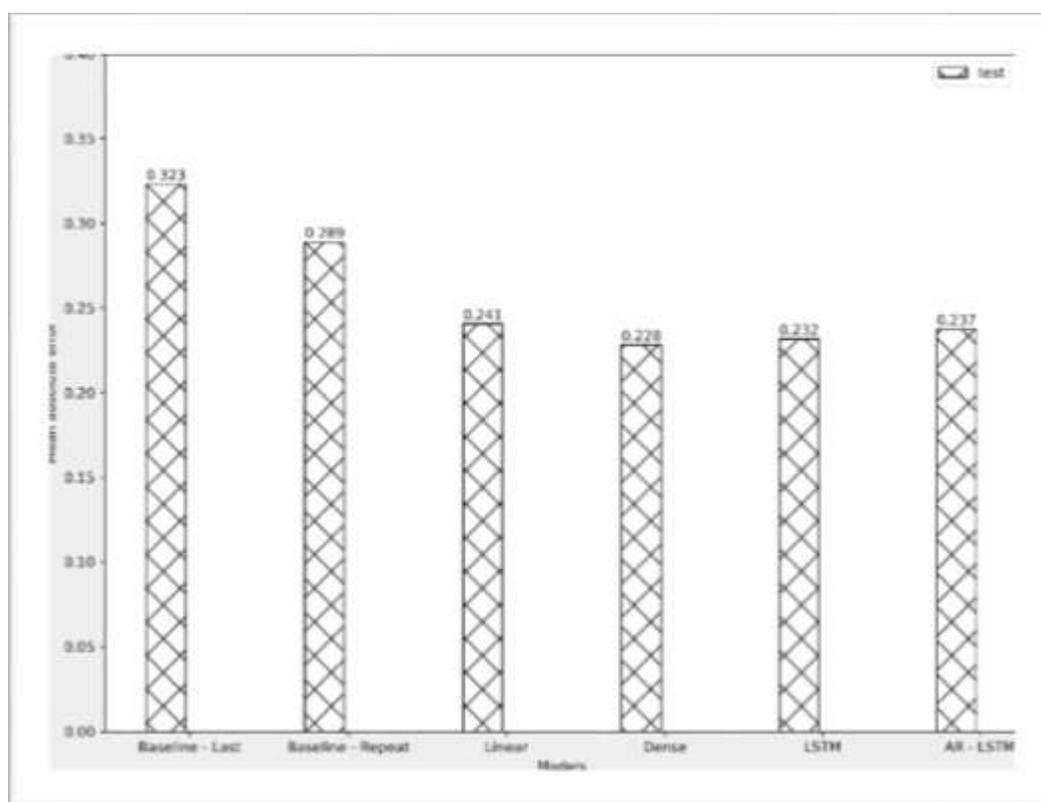


Figura 3.3 índice del MAE de los modelos desarrollados.

Se puede concluir una vez analizado y comparado todos los modelos propuestos que el modelo que presenta un menor MAE o error es el modelo Denso con un MAE de 0.028. Esto significa que los valores de predicción alcanzados por este modelo estarán muy cerca de los valores reales y por ende se ajustarán de una mejor manera a nuestras necesidades.

### Conclusiones:

Se analizó una arquitectura de red más avanzada llevando a cabo una secuencia de pasos para su correcta implementación, utilizando las redes neuronales recurrentes,

dentro de las cuales se encuentra la memoria a corto plazo (LSTM) implementado para el modelo de varios pasos como se ha trabajado desde el comienzo y se desarrolló dentro de las redes neuronales recurrentes también el modelo LSTM autorregresivo para generar pronósticos continuos. Mostrando finalmente entre ambos modelos mejores resultados por el modelo autorregresivo. Sin embargo, los resultados obtenidos por estos modelos no superan los alcanzados por el modelo Denso anteriormente desarrollado. Es por ello que luego de realizada la exploración e implementación de los modelos, se puede finalmente concluir que el modelo Denso aporta menor índice de error, por ende, aportará mejores predicciones con el entrenamiento de los datos.

## Conclusiones

Se analizaron los elementos de la base de dato de estudio seleccionando solo las variables fuertemente relacionadas con el consumo de energía eléctrica.

Se seleccionó un modelo de varios pasos en el tiempo para la predicción del consumo de MWh en la Universidad de Cienfuegos.

Se escalaron el setenta porciento de los datos y se dividieron en tren de entrenamiento, validación y prueba.

Se entrenó el modelo y se probaron dos arquitecturas de red neuronal obteniendo como resultado final el modelo denso para la predicción del consumo eléctrico.

## Recomendaciones

En la actualidad existe un sinnúmero de modelos tanto estadísticos, como matemáticos unidos además con las redes neuronales, se exhorta a comprobar la efectividad de estos modelos no implementados en el trabajo con los datos que se tienen. Además, se pudiese realizar el desarrollo de los modelos utilizando más variables con el objetivo de analizar qué tanto influyen estas en los resultados.

## Bibliografía

- [1] Y. G. López, «Predicción de la Demanda Eléctrica empleando,» Santa Clara, 2009.
- [2] A. S. Velázquez, «PRONOSTICO DE CONSUMO DE ENERGÍA ELÉCTRICA USANDO REDES NEURONALES ARTIFICIALES,» Las Tunas.
- [3] C. M. González, «Predicción de la demanda eléctrica horaria mediante redes neuronales artificiales.,» 2004.
- [4] A. J. Núñez, «Ambiente, consumo de energía y cambio climático,» 2013.
- [5] J. A. Peña, «Pronóstico del consumo pico para la gestión energética de la Universidad de Cienfuegos,» Cienfuegos, 2019.
- [6] E. J. M. Vásquez, «Predicción del consumo de energía eléctrica residencial de la Región Cajamarca mediante modelos Holt -Winters,» Cajamarca, 2019.
- [7] S. A. Rodríguez, «Diario de la Juventud Cubana,» 23 Enero 2010. [En línea]. Available: <file:///D:/Tesis/doc%20cap%201/Desarrollan%20software%20capaz%20de%20control%20el%20consumo%20de%20electricidad%20-%20Juventud%20Rebelde%20-%20Diario%20de%20la%20juventud%20cubana.html>.
- [8] Á. R. Torres, «Módulo de planificación para el sistema supervisión energética,» *TINO*, 2015.
- [9] J. O. P. Ramos, «Diseño de sistema SCADA para la supervisión de,» Santa Clara, 2011.
- [10] F. Marcos, «CEUTEC,» 1985. [En línea]. Available: <https://glifos.unitec.edu/library/index.php?title=29463&lang=en&query=@title=Special:GSMSearchPage@process=@field1=encabezamiento@value1=MODELO%20@mode=advanced&recnum=20>.
- [11] J. F. Roque, «DESARROLLO DE UN MODELO DE PLANIFICACIÓN,» Perú, 2018.
- [12] A. Ramos, «Modelos matemáticos de optimización,» Madrid, 2010.
- [13] H. Arshan, «Sitio Espejo para América Latín,» [En línea]. Available: <http://home.ubalt.edu/ntsbarsh/business-stat/opre/spanishd.htm#:~:text=Un%20modelo%20de%20Optimizaci%C3%B3n%20Matem%C3%A1tica,sistema%20de%20ecuaciones%20o%20inecuaciones..>
- [14] L. B. García, «Desarrollo de un modelo multicriterio-multiobjetivo de oferta de energías renovables : aplicación a la Comunidad de Madrid,» Madrid, 2004.
- [15] J. A. Espey, «Encendiendo las luces: un metanálisis de las elasticidades de la demanda de electricidad residencial,» *EconPapers*, vol. 36, nº 1, p. 17, 2004.
- [16] L. V. B. LEYVA, «PROCEDIMIENTO MULTICRITERIO-MULTIOBJETIVO DE,» Madrid, 2015.
- «Wikipedia,» 22 Marzo 2022. [En línea]. Available: [https://es.wikipedia.org/wiki/Serie\\_temporal](https://es.wikipedia.org/wiki/Serie_temporal).
- [18] P. N. Roldán, «Modelo econométrico,» *economipedia*, 2018.

- [19] C. A. Ruiz, «Redes Neuronales: Conceptos Básicos y».
- [20] «aws,» [En línea]. Available: <https://aws.amazon.com/es/what-is/python/#:~:text=Python%20es%20un%20lenguaje%20de,ejecutar%20en%20muchas%20plataformas%20diferentes..>
- [21] I. Rondón, «Escuela Internacional de Postgrados UCAM,» 4 Febrero 2022. [En línea]. Available: <https://eiposgrados.com/blog-python/que-es-anaconda/>.
- [22] P. R. d. I. Santos, «Telefónica Tech,» 28 Marzo 2018. [En línea]. Available: <https://empresas.blogthinkbig.com/python-para-todos-2-jupyternotebook/>.
- [23] «Solver,» 19 Junio 2021. [En línea]. Available: <https://iasolver.es/6-librerias-de-python-para-machine-learning/>.
- [24] M. Peixeiro, Time Series Forecasting, 2021.