



UNIVERSIDAD NACIONAL DEL ALTIPLANO
FACULTAD DE INGENIERÍA MECÁNICA ELÉCTRICA
ELECTRÓNICA Y SISTEMAS
ESCUELA PROFESIONAL DE INGENIERÍA MECÁNICA
ELÉCTRICA



**“PREDICCIÓN DE LA DEMANDA DE ENERGÍA EN LA BARRA
DE 60KV DEL SISTEMA ELÉCTRICO PUNO MEDIANTE REDES
NEURONALES DEL TIPO PERCEPTRON MULTICAPA”**

TESIS

PRESENTADA POR:

AXEL JEFFERSON QUISPE MACHACA

PARA OPTAR EL TÍTULO PROFESIONAL DE:

INGENIERO MECÁNICO ELECTRICISTA

PUNO – PERÚ

2022



DEDICATORIA

A mi familia, por su apoyo moral y emocional, por los consejos, acciones y recomendaciones brindados para ser una mejor persona.

Axel Jefferson Quispe Machaca



AGRADECIMIENTOS

A mi asesor de tesis y miembros del jurado evaluador, por guiar y encaminar la culminación de la presente tesis

A mi escuela profesional de Ingeniería Mecánica Eléctrica, alma mater “Universidad Nacional del Altiplano – Puno” y en especial a mis docentes por compartir su conocimiento y experiencias durante mi periodo estudiantil.

A la empresa Electro Puno S.A.A., a la Gerencia de Comercialización y en especial a los profesionales que laboran en dicha área, por permitirme poner en práctica, laborar y ampliar mis conocimientos y experiencia profesional.

Axel Jefferson Quispe Machaca



ÍNDICE GENERAL

DEDICATORIA

AGRADECIMIENTOS

ÍNDICE GENERAL

INDICE DE TABLAS

INDICE DE FIGURAS

ÍNDICE DE ACRÓNIMOS

RESUMEN 11

ABSTRACT..... 12

CAPITULO I

INTRODUCCIÓN

1.1. PLATEAMIENTO DEL PROBLEMA..... 14

1.2. FORMULACION DEL PROBLEMA..... 14

1.3. JUSTIFICACIÓN DE LA INVESTIGACIÓN..... 14

1.3.1. Documentación y fuentes de información..... 15

1.4. OBJETIVOS..... 15

1.4.1. Objetivo general 15

1.4.2. Objetivos específicos 15

1.5. HIPÓTESIS 15

1.5.1. Hipó tesis general 15

1.5.2. Variables e indicadores 15

CAPITULO II

REVISIÓN DE LITERATURA

2.1. ANTECEDENTES 17

2.1.1. A Nivel Internacional:..... 17

2.1.2. A Nivel Nacional..... 19



2.1.3. A Nivel Local	20
2.2. MARCO TEÓRICO	20
2.2.1. Demanda	20
2.2.2. Horizontes temporales.....	21
2.2.3. Elasticidad	21
2.2.4. Demanda de energía eléctrica	22
2.2.5. Definición de términos básicos	25
2.2.6. Breve descripción de la empresa electro PUNO S.A.A	26
2.2.7. Factores de influencia en la demanda de energía.....	28
2.2.8. Factores climatológicos en la demanda de energía	29
2.2.9. Factores económicos en la demanda de energía	29
2.2.10. Métodos de proyección de la demanda de energía.....	30
2.2.11. Redes neuronales artificiales para la proyección de la demanda de energía eléctrica	31
2.2.12. Topología de la RNA perceptrón	33
CAPITULO III	
MATERIALES Y MÉTODOS	
3.1. CLASIFICACIÓN DE LA INVESTIGACIÓN.....	41
3.1.1. Tipo de investigación	41
3.1.2. Nivel de investigación.....	41
3.1.3. Diseño de investigación	41
3.2. POBLACIÓN Y MUESTRA	42
3.2.1. Población.....	42
3.2.2. Muestra.....	43
3.3. TÉCNICAS E INSTRUMENTOS DE RECOLECCIÓN DE DATOS	43
3.3.1. Recolección de datos.....	43
3.3.2. Instrumentos	43



3.3.3. Técnicas de procesamiento y análisis de datos	44
3.4. METODOLOGIA PARA LA PROYECCION DE ENERGIA.....	45
3.4.1. Selección del objeto de estudio	45
3.4.2. Pre procesamiento de la base de datos	46
3.4.3. Variables de la Investigación	53
3.4.4. Operacionalización de variables	54
3.4.5. Software de simulación	54
3.4.6. Desarrollo de la Arquitectura de la RNAs tipo MLS	55
3.4.7. Función de activación de la red neuronal.....	58
3.4.8. Entrenamiento de la RNAs tipo MLS	59
3.4.9. Validación de las proyecciones	60
CAPITULO IV	
RESULTADOS Y DISCUSIÓN	
4.1. RESULTADOS DE LAS PROYECCIONES DE LA RNA TIPO MLS	62
4.2. RESULTADOS DE LAS PROYECCIONES CON METODO ESTADISTICO	64
4.3. COMPARACION DE RESULTADOS RNA TIPO MLS VS ESTADISTICO	66
4.4. DISCUSIÓN DE LOS RESULTADOS	66
V. CONCLUSIONES.....	68
VI. RECOMENDACIONES	69
VII. REFERENCIAS BIBLIOGRÁFICAS.....	70
ANEXOS.....	73

Área: Ciencias de la Ingeniería.

Línea: Control de Procesos.

FECHA DE SUSTENTACION: 30 de noviembre de 2022



INDICE DE TABLAS

Tabla 1:	Funcionarios de Electro Puno	27
Tabla 2:	Tipos de neuronas artificiales	32
Tabla 3:	Funciones de activación	38
Tabla 4:	Tipos de aprendizaje	39
Tabla 5:	Medidores en puntos de compra.	44
Tabla 6:	Selección del objeto de estudio.....	45
Tabla 7:	Base de datos de las barras del sistema eléctrico Puno periodo 00:15 horas 03:15 horas del 01/01/2020.....	46
Tabla 8:	Valores de demanda periodo 01/01/2018 logrado de la base de datos de la barra de 60kv.....	47
Tabla 9:	Identificación de variables	53
Tabla 10:	Operacionalización de variables de investigación	54
Tabla 11:	Valores de MAPE diario	63
Tabla 12:	Comparación del MAPE de RNA tipo MLS vs modelo estadístico	66



INDICE DE FIGURAS

Figura 1:	Tendencia inelástica & Tendencia elástica.....	21
Figura 2:	Exceso de oferta & demanda.....	23
Figura 3:	Diagrama de intervalo de tiempo vs proyección de la demanda	25
Figura 4:	Influencia de las estaciones climáticas sobre la demanda eléctrica	29
Figura 5:	Modelo de una red neuronal artificial	32
Figura 6:	Arquitectura del perceptrón multicapa	34
Figura 7:	Comportamiento de la carga según las estaciones del año 2020.....	35
Figura 8:	Comportamiento de la carga según días con mayor demanda.	36
Figura 9:	Perfil de demanda histórica de la barra 60 kv (enero 2018-agosto 2021)...	48
Figura 10:	Serie de tiempo y Valores inusuales o atípicos.	48
Figura 11:	Valores inusuales o atípicos en la serie de tiempo diaria.	49
Figura 12:	Incrementos y decremento de demanda en la serie de tiempo.	50
Figura 13:	Serie de tiempo diaria comprendida entre los parámetros 01 de enero 2018- 31 de agosto 2021.....	51
Figura 14:	Grafica de distribución normal (campana de Gauss).	52
Figura 15:	Corrección de datos atípicos en la serie de tiempo.....	52
Figura 16:	Arquitectura de la RNA tipo MLS propuesto.....	56
Figura 17:	Datos de entrada 48 valores de carga del día anterior.	56
Figura 18:	Datos de entrada 48 valores de carga de la semana pasada.....	57
Figura 19:	Datos de salida 48 valores de carga del día actual.	57
Figura 20:	Función de Activación Reluactivation.....	58
Figura 21:	Modelo Función de Entrenamiento de la RNA tipo MLS.....	59
Figura 22:	Proceso de aprendizaje la RNA tipo MLS.	60
Figura 23:	Predicción de la demanda en el año 2021.	62



Figura 24: Predicción de la demanda mensual – agosto 2021.	63
Figura 25: Predicción de la demanda con suavizado exponencial – Eviews 10	64
Figura 26: Proyección de la demanda de energía – eviews 10	65



ÍNDICE DE ACRÓNIMOS

KV:	Kilo Voltios
AT:	Alta Tensión
MT:	Media Tensión
BT:	Baja Tensión
KW:	Kilo Wattios
MW:	Mega Wattios
SED:	Sub estación de distribución
SET:	Sub estación de transformación
ELPU:	Electro Puno S.A.A.
LCE:	Ley de Concesiones Eléctricas
RLCE:	Reglamento de la Ley de Concesiones Eléctricas
CNE:	Código Nacional de Electricidad
DGE:	Dirección General de Electricidad
OSINERGMIN:	Organismo Supervisor de la Inversión en Energía y Minería



RESUMEN

El notable crecimiento poblacional en la ciudad de Puno se ve manifestado en el acrecentamiento del consumo per cápita de la energía eléctrica, por consecuencia se tiene que el comportamiento de los sistemas eléctricos de transmisión sea dinámico, interactivo y poco predecible con cierto grado de imprecisión, esto debido a la varianza de las demandas de energías eléctricas, varianza directamente relacionada con factores temporales, económicos y climáticos. La presente tesis se desarrolló con la intención de elaborar una metodología de proyección de la demanda de energía eléctrica, utilizando redes neuronales del tipo perceptrón multicapa aplicado a la barra de 60 KV del sistema eléctrico Puno. Esto con la finalidad de disminuir la desigualdad entre la demanda de energía eléctrica proyectada y la demanda real, finalmente se logró el propósito además de lograr de disminuir el error de predicción de la demanda de energía eléctrica mediante el modelo de RNA del tipo MLS, con un nivel de confianza de 94.8 %.

Palabras Clave:

Corto Plazo, Demanda Eléctrica, Energía Eléctrica, Python, Predicción, Perceptron multicapa, Redes Neuronales, Tensorflow.



ABSTRACT

The notable population growth in the city of Puno is manifested in the increase of the per capita consumption of electric energy, consequently, the behavior of the electric transmission systems is dynamic, interactive and not very predictable with a certain degree of imprecision, due to the variance of the electric energy demands, variance directly related to temporal, economic and climatic factors. This thesis was developed with the purpose of elaborating a methodology for the projection of electric energy demand, using neural networks of the multilayer perceptron type applied to the 60 KV bus of the Puno electric system. This was done with the purpose of reducing the inequality between the projected electric energy demand and the real demand. Finally, the purpose was also achieved by reducing the prediction error of the electric energy demand through the ANN model of the MLS type, with a confidence level of 94.8 %.

Keywords:

Short Term, Electricity Demand, Electric Power, Python, Prediction, Multilayer Perceptron, Neural Networks, Tensorflow.



CAPITULO I

INTRODUCCIÓN

Con el transcurso de los años los sistemas eléctricos han abarcado con mayor amplitud el País a su vez, esto también implica un incremento en el requerimiento de energía eléctrica en usuarios libres y regulados, para lo cual los clientes libres y con mayor importancia las empresas de comercialización y distribución de electricidad deben ser capaces de proyectar o pronosticar sus valores de demanda de energía eléctrica con la mayor precisión posible y así evitar desabastecimientos y sobreabastecimientos de energía por parte de la empresa generadora y posibles renegociaciones de contratos, firma de adendas que resultan muy resaltantes y denotan una mala toma de decisiones por parte de sus directivos, a raíz de trabajar con datos poco aproximados a los reales. Además de tener finalidades diversas, el tener a disposición datos casi reales de la demanda eléctrica nos permite realizar un análisis técnico de las instalaciones eléctricas que están en funcionamiento, esto serviría para evitar posibles cortes o interrupciones a causa de sobredemanda o sobrecarga de estas instalaciones.

Las empresas vinculadas al sector eléctrico utilizan modelos estadísticos para proyectar su demanda de energía eléctrica, cabe resaltar que estos modelos son complejos en su manejo y adaptación de nuevas variables, es por eso que el objetivo de esta tesis es diseñar una red neuronal en su tipología de perceptron multicapa para pronosticar la demanda de energía eléctrica a corto plazo en la barra de 60 KV del sistema eléctrico Puno.



1.1. PLATEAMIENTO DEL PROBLEMA

La barra de 60 KV del sistema eléctrico Puno administrada por la Empresa Regional de Servicio de Electricidad de Puno Sociedad Anónima Abierta - Electro Puno S.A.A., es la primordial fuente alimentadora de línea de mediana tensión que alimenta a la sub estación eléctrica de transformación Bellavista y la sub estación eléctrica de transformación Ilave - Pomata. En dicha barra se lleva un control de perfil de carga diario, posterior a ello se procede a realizar proyecciones estadísticas con datos históricos, obteniendo resultados con altos índices de error.

1.2. FORMULACION DEL PROBLEMA

¿Cuál será de la eficiencia del modelo de predicción de la demanda de energía proyectada a corto plazo en la barra de 60 KV del sistema eléctrico Puno?

1.3. JUSTIFICACIÓN DE LA INVESTIGACIÓN

Debido al incremento de la demanda de energía eléctrica a través de los años surge el problema de realizar un adecuado pronóstico de la demanda. Los clientes libres y las empresas de comercializaciones y distribuciones efectúan proyecciones de demanda de energía eléctrica mediante cálculos y modelos estadísticos que pueden llegar a ser complicados y que proporcionan datos poco próximos a los reales, además que no incluyen variables de gran importancia que influyen en la demanda de energía eléctrica como son las variables climatológicas (día del año, estación del año y otros) e incluso hábitos de consumo. Es por eso que la implementación de nuevas técnicas de predicción es de gran significancia en la actualidad, en este caso se plantea el estudio de la demanda de energía eléctrica en la barra de 60 kv del sistema eléctrico Puno perteneciente a la empresa Electro Puno S.A.A. el análisis de la data será de los periodos 2018-2021.



1.3.1. Documentación y fuentes de información

La data histórica, perfil de carga e información concerniente fue brindada por la gerencia de comercialización de la empresa ELECTROPUNO S.A.A.

1.4. OBJETIVOS

1.4.1. Objetivo general

Demostrar que mediante el desarrollo del modelo basado en redes neuronales artificiales en su tipología de perceptrón multicapa disminuye el error de predicción de la demanda de energía eléctrica a corto plazo.

1.4.2. Objetivos específicos

- Determinar las variables de entrada, realizar el tratamiento y valorización de la información histórica de la demanda de energía eléctrica en la barra de 60 KV del sistema eléctrico Puno de la empresa Electro Puno S.A.A.
- Programar e implementar el algoritmo en la topología de la red neuronal perceptrón multicapa utilizando el software Python para obtener un error porcentual absoluto medio mínimo.

1.5. HIPÓTESIS

1.5.1. Hipótesis general

El algoritmo de pronóstico basado en redes neuronales artificiales en su topología de perceptrón multicapa disminuye el error de predicción de la demanda de energía eléctrica a corto plazo.

1.5.2. Variables e indicadores

En la presente tesis la eficiencia del modelo de red neuronal artificial en su topología de perceptrón multicapa es la variable independiente ya que esta es cambiante



en el transcurso del experimento, cabe decir los resultados varían con cada entrenamiento todo ello para alcanzar el objetivo planteado y respectivamente la demanda de energía eléctrica diaria expresada en MW viene a ser la variable dependiente.

La validez de los resultados estará justificada con el error porcentual absoluto MAPE, según cambien los resultados para cada periodo de tiempo estimado.



CAPITULO II

REVISIÓN DE LITERATURA

2.1. ANTECEDENTES

2.1.1. A Nivel Internacional:

Lozada et al. (2022), “Predicción de demanda eléctrica utilizando redes neuronales artificiales para un sistema de distribución de energía eléctrica”, Este estudio tiene el propósito realizar la proyección de la demanda de energía eléctrica mediante un modelo de Redes Neuronales Artificiales (RNA). Para desarrollar este pronóstico se utilizaron datos históricos de consumo de las empresas eléctricas (demanda máxima mensual) para 2019-2021. Este trabajo probó el modelo de ARN, que se ha desarrollado cada vez más con el tiempo. El procesamiento de datos se realiza a través de 3 capas pertenecientes a ANN, estas capas incluyen: capa de entrada, capa oculta y capa de salida las cuales brindan valores continuos los cuales representan el resultado a través de un proceso matemático. Los resultados se desarrollaron en varios pasos, que incluyen: entrenar la ANN utilizando el 85 % de los datos históricos, probar la ANN con el número anterior de registros históricos de acuerdo con los criterios de evaluación del error porcentual absoluto medio (MAPE) del valor del 15 %. no se utiliza en entrenamiento, esta fase permite probar el nivel de confianza del modelo en base al porcentaje de errores, brindando pronósticos con horizontes de tiempo más largos.

Querol (2018), desarrollo su investigación con el propósito principal de este trabajo es mejorar el alcance de esta investigación, desarrollar alternativas para la implementación del modelo de pronóstico de precios de energía y reducir el nivel de errores de pronóstico durante el año. Los mandatos de mercado son válidos para su uso. Por ello, se introdujo un nuevo modelo de previsión basado en observaciones de cómo se ajustan la tensión y la frecuencia de la red para garantizar la eficacia de servicio. El control



a efectuar es similar al control de frecuencia primaria. Este sistema de control permite que el sistema eléctrico mantenga la frecuencia del sistema y cambie la potencia activa producida a voluntad. Para obtener un modelo similar se ha creado una red neuronal artificial que utiliza un proceso de retroalimentación en la etapa de entrenamiento.

Villada et al. (2006) en el estudio “Pronostico de la tarifa de la energía eléctrica usando redes neuronales artificiales”, Predecir los precios de la electricidad empleando (RNAs) para predecir los precios a corto, mediano y largo plazo es muy importante. Se plantea un modelo fundado en redes neuronales artificiales y se evaluará su desempeño en un pronóstico de un mes cumplido del mercado eléctrico en Colombia.” (p.02). Para el desarrollo del presente se “Utilizaron dos estructuras de red, incluido los precios diarios en la primera y la serie de precios en la segunda más el nivel medio del agua del embalse como entrada. Comparando los resultados obtenidos con las predicciones basadas en el modelo GARCH, se encuentra que este último tiene ventaja en el periodo de muestreo, pero la red neuronal se comporta mejor en el periodo fuera de muestra.” (p.03).

Salazar & Cabrera (2007) en el estudio titulado “Pronostico de demanda por medio de redes neuronales artificiales”, en el cual “Se describe el pronóstico de la demanda utilizando una red neuronal artificial (RNAs). También se propone y prueba en aplicaciones prácticas un método para definir los parámetros de una red neuronal artificial de forma integrada y repetible” (p.01). finalizado el estudio los autores precisan “Los resultados de este trabajo respaldan el uso de la red neuronal artificial como técnicas de pronóstico confiables y apuntan a su viabilidad para el establecimiento en la industria.” (p.07).

González (2015) en su tesis “Pronostico de la demanda a través de una red neuronal artificial perceptrón multicapa”, En su percepción predice la necesidad de



(RNAs). perceptrón multicapa desarrollado en software libre y tiene en cuenta las variables que tienen mayor impacto en la predicción” (p.05). Finalmente llega a la conclusión que la metodología propuesta es más confiable y certera en comparación a los métodos estadísticos tradicionales.

Nojek et al. (1997) en el estudio “Pronostico de ventas: Comparaciones de predicciones basadas en redes neuronales versus método estadístico” realizaron el análisis de “la predicción de ventas mediante el uso de redes neuronales, comparar los resultados obtenidos con predicciones de métodos estadísticos clásicos y establecer el mejor entorno para su uso. Los resultados de esta encuesta nos permitieron concluir con un 82,29% de confianza que la red neuronal hizo predicciones más precisas que los métodos estadísticos utilizados. Resultado pertenece al promedio de los mejores pronósticos para cada serie de tiempo.” (p.02).

2.1.2. A Nivel Nacional

Cuadrado & Ramos (2010) en su tesis “Implementación de una Red Neuronal para mejorar el pronóstico de la demanda de energía en la empresa BlueStar Energy Services Inc.”, esta investigación tiene como objetivo “poder pronosticar la demanda de electricidad de BlueStar Energy Services Inc. con las mayores precisiones posibles para reducir las pérdidas por exceso o escasez de suministro” (p.10). Propusieron como método “Pronosticar la demanda de electricidad de la empresa. con las mayores precisiones posibles para reducir las pérdidas por exceso o escasez de suministro” (p.10). Al final de la experimentación obtuvieron que los resultados “muestran que la demanda futura se puede aproximar mejor mediante el uso de redes neuronales” (p.110).

Fernández (2014), en su tesis “Pronostico de la demanda eléctrica a corto plazo utilizando redes neuronales artificiales aplicado al sistema interconectado nacional”,



Realiza la proyección de la demanda de energía eléctrica con los datos del Comité de Operación Económica del Sistema Interconectado Nacional, en el cual refiere que, en el Perú, el COES ejecuta proyecciones diarias de la demanda de energía eléctrica del SEIN. se emplea datos históricos para los cálculos diarios de la curva de demanda de electricidad. Los programas de previsión de la demanda de electricidad a menudo proporcionan resultados que se desvían significativamente del valor real de la demanda. Como tal, utiliza redes neuronales para predecir la demanda de energías eléctricas aplicada al sistema eléctrico interconectados nacionales, restando la discrepancia entre la demanda de electricidad proyectadas y realizada. el propósito es conseguir un error medio porcentual absoluto mínimo. también estudiar el impacto de las diferentes variables que afectan la demanda.

2.1.3. A Nivel Local

No se hallaron antecedentes para el presente trabajo a nivel local.

2.2. MARCO TEÓRICO

2.2.1. Demanda

Según Cervantes et al. (2016), la cantidad demandada y la demanda son distintos, en donde la demanda es la acción de requerir un bien y/o servicio según los diferentes precios y periodos, cabe decir que existe una diferencia notable entre los valores de demanda actuales y anteriores, por otro lado, la cantidad demanda es la acción de requerir un bien y/o servicio a un determinado precio o periodo establecido. La función de demanda tiene la característica de poder ser representada como una función lineal, en el eje coordinado se representa la cantidad demandada del bien relacionado y el eje de las abscisas representa el precio o periodo del bien relacionado.

2.2.2. Horizontes temporales

Según Cervantes et al. (2016). Los bienes y/o servicios demandados, que son examinados en una dimensión temporal mayor (largo plazo) suelen tener una mayor elasticidad de la demanda, mientras que los que son analizados en el corto plazo suelen tener una demanda más inelástica. La elasticidad del precio y/o periodo de la demanda es útil para predecir cómo se va a ver afectado el producto y/o servicio demandado. En resumen, el estudio de la demanda de un referido bien y/o servicio presenta una clasificación temporal de la forma siguiente:

- Demanda a largo plazo
- Demanda a mediano plazo
- Demanda a corto plazo

2.2.3. Elasticidad

Cervantes et al. (2016). Menciona que la elasticidad mide el grado de varianza de la cantidad demandada del bien y/o servicio, dicha varianza es directamente proporcional a la varianza del precio o periodo

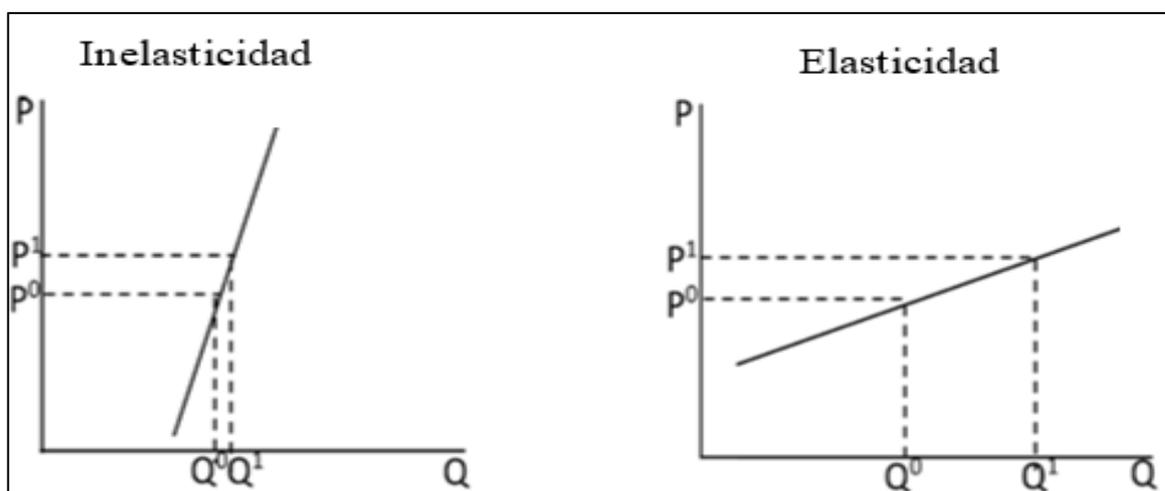


Figura 1: Tendencia inelástica & Tendencia elástica

Fuente: (Cervantes et al., 2016, p.61)



Donde:

D: Demanda de un bien y/o servicio.

Q: Cantidad del bien y/o servicio.

P: Precio y/o periodo.

De lo mencionado en los ítems 2.2.1, 2.2.2. y 2.2.3. podemos mencionar que, la economía en forma general al momento de realizar pronósticos utiliza una cantidad de variables limitadas (cantidad, precio, etc.) lo cual conllevaría a obtener diferencias considerables entre la demanda proyectada y demanda real.

2.2.4. Demanda de energía eléctrica

Desde un punto de vista técnico se ubica a la energía eléctrica como “fuente energética secundaria”, por motivos que se consigue a partir de fuentes primarias: térmicas, hidráulicas, nucleares y renovables. La energía eléctrica es dependiente de la fuente primaria en muchos casos no puede ser almacenada, o su almacenamiento es sumamente costoso (Cuadrado & Ramos,2010).

En un caso teórico en el cual los aparatos e instrumentos eléctricos puedan ser acondicionados para su funcionamiento con fuentes primarias de energía, estas adaptaciones no serían factibles en un horizonte temporal corto. Lo descrito líneas arriba hace que el mercado o sistemas eléctricos presenten particularidades tales como:

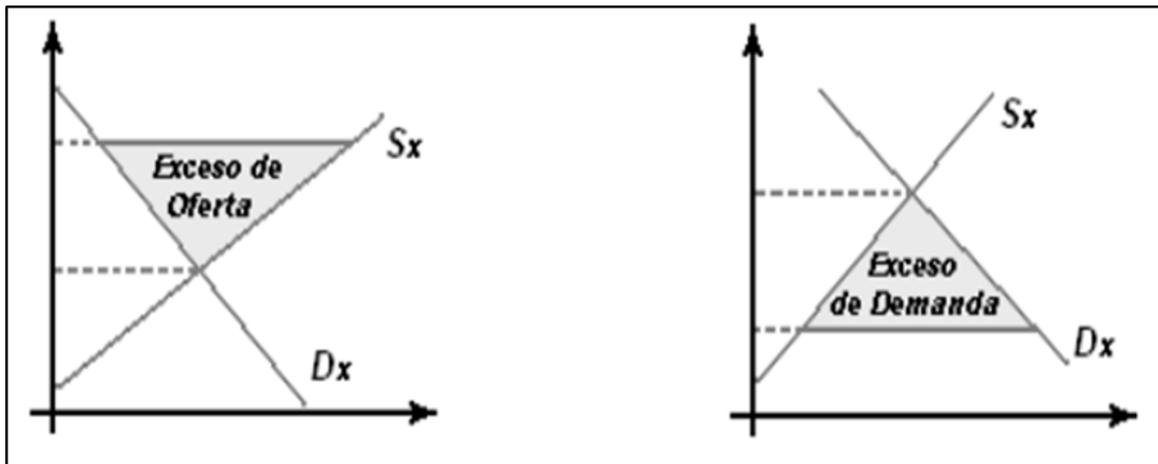


Figura 2: Exceso de oferta & demanda
Fuente: (Cuadrado & Ramos, 2010, p.19)

En la figura N° 2 se muestra un exceso de oferta y demanda en forma teórica, esto nos sirve para realizar el análisis del comportamiento del mercado eléctrico, en primer lugar, se tiene un exceso de oferta lo que representaría el mercado eléctrico habitual donde el valor del área sombreada representaría los stocks y reservas de energía de las empresas generadoras, cabe precisar la energía generada y no consumida inmediatamente, además de mencionar que la energía eléctrica actualmente no es acumulable o de lo contrario acumularla implica costos asociados muy elevados. Expresado de otra forma el área sombreada expresaría las pérdidas de la mala designación y usos de fuentes primarias. Así mismo, el exceso de demanda, en un mercado tradicional, el valor del área sombreada es la demanda insatisfecha. Posibles consumidores que carecen del servicio, que esperan ser atendidos o buscan un sustituto cercano del bien demandado. Lo último mencionado en el mercado eléctrico no existen las posibilidades de acudir a sustitutos cercanos, al menos en un periodo a corto plazo (Cuadrado & Ramos, 2010, p.20).

2.2.4.1. Proyección de energía a largo plazo

Da silva (1996) menciona que, la proyección de la demanda de energía a largo plazo reside en proyectarla en un horizonte de un año hacia adelante. Esta proyección es fundamental para determinar y evaluar la ubicación y dimensión de futuros centros de



transmisión y generación de los sistemas eléctricos, dicha proyección es utilizada como referente para inversiones futuras en el país.

En un ámbito regional, la proyección de la demanda a largo plazo, nos permitiría examinar los consumos de energía eléctrica de las diferentes barras pertenecientes a nuestro sistema eléctrico y planificar la operabilidad de los mismos.

2.2.4.2. Proyección de energía a mediano plazo

Fundamentalmente la proyección de la demanda de energía a mediano plazo es el pronóstico en un horizonte de un mes hasta un año. Esta proyección es fundamental para la elaboración de programas de mantenimiento en instalaciones eléctricas de generación y transmisión; además de ser primordial para la determinación y abastecimiento del suministro de energía entre empresas generadoras y comercializadoras con el fin de satisfacer la demanda prevista (Da Silva ,1996).

2.2.4.3. Proyección de energía a corto plazo

Reside en proyectar la demanda de energía eléctrica en un horizonte temporal desde un día hasta un mes. Este pronóstico en este horizonte temporal es de gran importancia para realizar un adecuado control de la variedad de procesos que desarrollan los operantes de centros de control de los sistemas eléctricos. Los errores en este pronóstico darían como resultado una programación desatinadamente conservadora o en una programación desatinadamente peligrosa originando efectos económicos negativos (Fernández,2014).

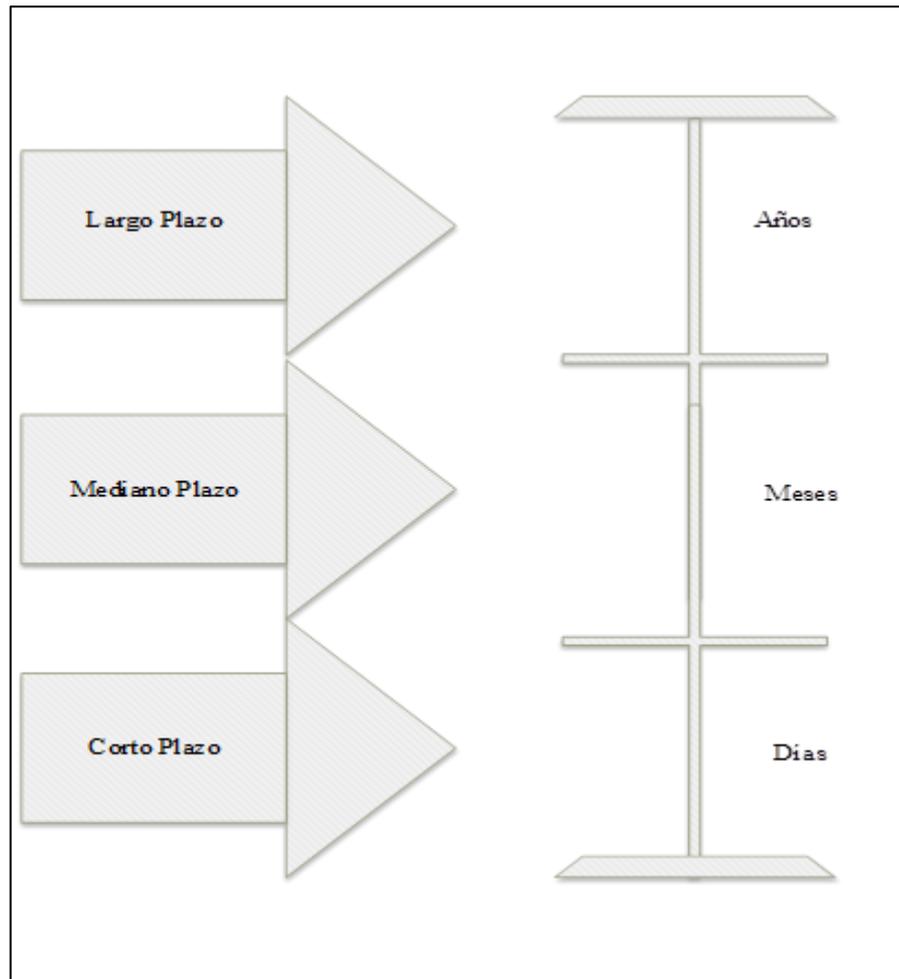


Figura 3:Diagrama de intervalo de tiempo vs proyección de la demanda
Elaboración propia

2.2.5. Definición de términos básicos

Redes Neuronales Artificiales (RNAs)

“Las RNAs intentan imitar el comportamiento del cerebro humano, diferenciado por aprender a través de las experiencias y extraer conocimiento general de un conjunto de datos” (Flores & Fernández, 2008, p.11).

Perceptron Multicapa

“Es una red neuronal con un modelo de propagación hacia adelante, compuesta de varias capas de neuronas entre la entrada y salida, esta característica en organización



en capas disjuntas evita que esta red realice conexiones hacia atrás” (Hilera & Martínez, 1995, p.113).

Energía Eléctrica

“Es la magnitud física relacionada con el flujo de partículas con carga negativa llamadas electrones, y se define como el producto de la potencia eléctrica por unidad de tiempo Kilowatt hora (Kw.h)” (CNE suministro, 2011, p.07).

Predicción

“Hecho o situación que se anuncia sucederá en el futuro” (Simpson, 2017).

Error Porcentual Absoluto Medio (MAPE)

“Es Vincular los errores de pronóstico a los niveles de demanda ayuda a poner el desempeño del pronóstico en perspectiva” (Krajewski, 2000, p.519).

2.2.6. Breve descripción de la empresa electro PUNO S.A.A

ELECTRO PUNO, es una franquicia de distribución de energía eléctrica en la región de Puno; se constituyó como parte del bloque común subregional de gestión de Electro Sur Este. Aprobado conforme a compromiso adoptado en la última Junta General de Accionistas de la Sociedad el 9 de julio de 1999, inscrito en el Registro Regional José Carlos Mariátegui-Autoridad de Puno, el 28 de octubre de 1999, tomo 74, local. 21742 y Hojas. n° 1467, iniciando su operación el 01 de noviembre de 1999.

El funcionamiento de la empresa se basa en la Ley de Concesión de Energía Eléctrica D.L. N° 25844 y su reglamento D.S. 009-93-EM, con actividad en la provincia de Puno Donde se sitúan sus infraestructuras electromecánicas de transmisión, distribución y generación de energía, implementa una estructura organizacional y cuenta con personal competente, con el objetivo de lograr un servicio eficiente, flexible y moderna y brindar a los clientes servicios de calidad.



Tabla 1:Funcionarios de Electro Puno

CARGO
Presidente del Directorio
Director
Director
Director
Gerente General
Gerente Administración
Gerente Comercial
Gerente de Planeamiento
Gerente Técnico
Gerente de Operaciones

Elaboración propia

2.2.6.1. Análisis de la metodología de proyección de la empresa

Realiza la proyección de la demanda mediante los servicios de consultoría externa, según información brindada por ELPU, el último estudio o consultoría realizada sobre la proyección de la demanda fue realizado en el año 2021.

En dicho estudio el consultor realizo proyecciones a largo y mediano plazo utilizando datos históricos de demanda, divididos en periodos mensuales, datos obtenidos de las diferentes barras del sistema eléctrico regional. El consultor para la realización de las proyecciones a largo y mediano plazo utilizo el software “MINITAB” en el cual realizo las series de tiempo de la demanda vs el periodo temporal (mensual), utilizando la función “Descomposición” de dicho software.

La función descomposición, realiza los pronósticos descomponiendo la serie de tiempo de los datos de demanda en índices estacionales, tendencia lineal y error,



utilizando el componente aditivo de los componentes estacionales procede a realizar los pronósticos de demanda. Proyecciones trabajadas con valores MAPE de 3.61958.

2.2.7. Factores de influencia en la demanda de energía

Según Cuadrado & Ramos (2010) la demanda de energía eléctrica es influenciada por varios factores tales como: factores climatológicos, temporales y económicos. El número de variables a utilizarse dependerá de la naturaleza o grado de precisión que requiera el pronóstico, dicho esto las variables a utilizarse deben ser seleccionadas y tratadas con atención. Anteriormente, la proyección de la demanda se sobrestimaba, lo que conllevaba la elaboración de pronósticos con un alto grado de error, dando como consecuencia inversión y crecimiento de infraestructura eléctrica que no es aprovechada íntegramente en la actualidad.

2.2.7.1. Factores temporales en la demanda de energía

Según Fernández (2014) los tres factores más influyentes en la demanda eléctrica son: días cíclicos de la semana, los días festivos o feriados y las estaciones del año.

La demanda eléctrica en la barra de 60kv del sistema eléctrico Puno varia directamente con cada estación del año; con mayor notabilidad en la estación de invierno.

Los días feriados tienen a tener mayor realce en las fiestas de febrero y fiestas de fin de año, los cuales presentan perfiles de demanda diferentes y con comportamientos difíciles de conocer.

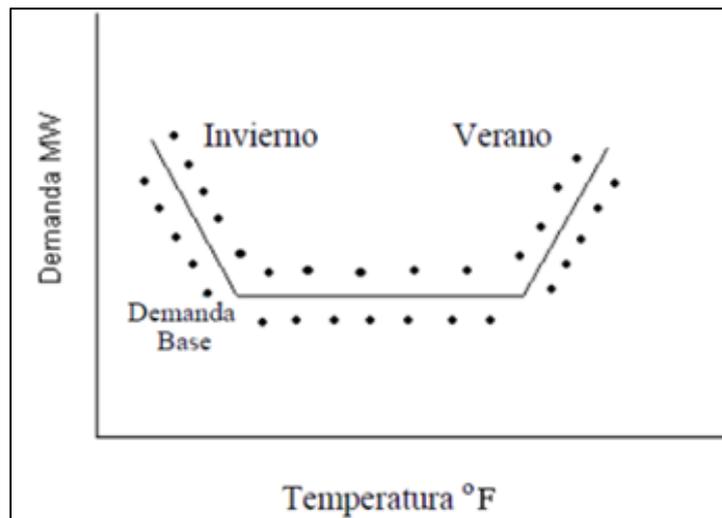


Figura 4: Influencia de las estaciones climáticas sobre la demanda eléctrica

Fuente: (Cuadrado & Ramos, 2010, p.27)

2.2.8. Factores climatológicos en la demanda de energía

Según Cuadrado & Ramos (2010) la demanda de energía eléctrica se analiza en periodos. Se observa que la demanda durante el día es diferente a la demanda durante la noche, de igual manera se observa una gran diferencia de la demanda de energía entre días extremadamente calurosos y días extremadamente fríos.

De lo mencionado anteriormente, se recalca que los factores climatológicos influyen notablemente en el pronóstico de la demanda, en el presente estudio es un factor muy importante, ya que el objeto de estudio de la presente tesis se encuentra ubicado en una región con comportamientos climáticos que varían desde periodos semi-secos y bastante fríos.

2.2.9. Factores económicos en la demanda de energía

El factor económico es importante en la conducta de la demanda de energía. Es claramente perceptible que la actividad comercial e industrial (agricultura, minería, pesquería y otros) influye en el consumo de la energía eléctrica; de igual manera al existir incrementos o decrementos en los ingresos económicos per cápita desencadena una mayor utilización o inutilidad de aparatos eléctricos (Da Silva, 1996).

2.2.10. Métodos de proyección de la demanda de energía

2.2.10.1 Método de regresión lineal múltiple

Se recurre a este método para analizar la conducta de una variable, Y, a través de un conjunto de variables X, dicho modelo crea una relación con más variables y son agrupadas en forma lineal (Grimaldo,2012). Se formula en términos de variables exógenas que pueden ser climáticas y no climáticas (Da silva, 1996). La expresión utiliza para representar el método es:

$$Y(t) = a_0 + a_1X_1(t) + a_2X_2(t)+\dots\dots\dots a_nX_n(t) + \varepsilon(t)$$

Donde:

Y(t) = Carga eléctrica en el instante “t”.

X_i (t)= Variables exógenas.

$\varepsilon(t)$ = Variables aleatorias con promedio cero y varianza constante.

La variable explicativa X_i se especifica mediante el análisis de relación entre la variable y la carga. Si el número de variables candidatas es muy grande, se utiliza una técnica estadística denominada Stepwise para escoger la más significativa de todas las variables. Los coeficientes generalmente se estiman mediante el método de mínimos cuadrados o el método de prueba estadística. (Fernández ,2014, p.22).

2.2.10.2 Método econométrico

El método econométrico es utilizado con mayor frecuencia en pronósticos temporales largos y medios, en este modelo se combinan las técnicas econométricas y técnicas estadísticas, valorando las relaciones entre el consumo de energía y los factores que influyen sobre incremento o decremento (Acevedo & Pimentel, 2014).

La funcionalidad del método inicia tomando en consideración que la variable socioeconómica explicativa de las ventas vegetativas puede ser: El producto bruto

interno, la tarifa eléctrica y población. Dichas variables tienden a ser analizadas por los efectos de estacionalidad de poseen (Fernández, 2014).

Según Fernández (2014, p.25) “La teoría de los mínimos cuadrados, o también conocida como teoría de la regresión lineal, es uno de los métodos más utilizados. Comienza representando la relación entre las variables económicas endógenas y las variables exógenas de forma lineal, de la siguiente manera:

$$Y = a_1 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \dots \dots \dots \beta_n X_n$$

Donde:

Y = Variable endógena, cuyo valor depende de las variables exógenas X₁, hasta X_n.

El objetivo es lograr los valores de los parámetros desde a₁ hasta β_n.

2.2.11. Redes neuronales artificiales para la proyección de la demanda de energía eléctrica

2.2.11.1. Introducción

A continuación, se describe el funcionamiento, comportamiento, estructura, arquitectura y factores los cuales intervienen directamente en el pronóstico de la demanda de energía eléctrica realizado con las RNAs.

Según (Flores & Fernández, 2008, p.17) “Las redes neuronales artificiales se pueden considerar como modelos computacionales caracterizados por algoritmos eficientes que se pueden ejecutar en paralelo a gran escala y permiten el desarrollo de tareas cognitivas como el aprendizaje de patrones.”.

2.2.11.2 Estructura y Modelado de una red neuronal artificial

La RNAs está dada por una serie de procesadores básicos denominados neuronas artificiales que constituyen un dispositivo de cómputo que proporciona una única

respuesta, partiendo de vectores de entrada (señales) de fuentes externas u otros estímulos recibidos de otras neuronas (salida), la representación de las tres neuronas artificiales es útil (Flores & Fernández, 2008, p.21).

Las RNAs son modelos matemáticos que pretenden reproducir la conducta del cerebro humano, cuyo primordial objetivo es la elaboración de sistemas capaces de aprender a realizar determinadas tareas (Fernández, 2014).

Tabla 2: Tipos de Neuronas Artificiales

NEURONA ARTIFICIAL	CARACTERISTICA
ENTRADA	RECIBEN SEÑALES EXTERNAS (DATA HISTORICA, ARCHIVOS DE PATRONES Y OTROS).
SALIDA	ENVIAN SEÑALES FUERA DEL SISTEMA UNA VEZ FINALIZADO EL TRATAMIENTO DE DATOS.
OCULTA	RECIBEN SEÑALES O ESTIMULOS Y EMITEN SEÑALES DE SALIDA DENTRO DEL SISTEMA SIN TENER CONTACTO CON EL EXTERIOR

Elaboración propia basado en (Flores y Fernández, 2008, p.21)

Gráficamente podría visualizarse como:

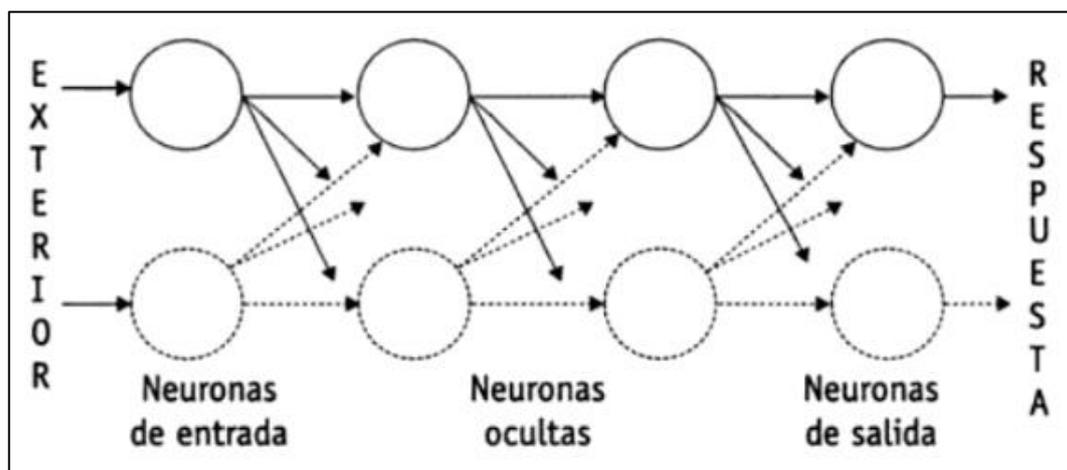


Figura 5: Modelo de una red neuronal artificial

Fuente: (Flores y Fernández, 2008, p.21)

2.2.12. Topología de la RNA perceptrón

Se componen topológicamente como lo que denominaremos capas de neuronas, las cuales establecen o se organizan entre una o varias capas según sea el caso.

2.2.12.1. El perceptrón monocapa (simple)

El perceptrón monocapa, tal y como su denominación afirma esta, compuesto por una única capa de neuronas, las cuales constituyen conexiones laterales y, en ocasiones autorrecurrentes con un modelo neuronal “feedback” (con propagación hacia atrás), este tipo de perceptrón suele utilizarse en la resolución de problemas de auto asociación y clusterización (Flores & Fernández, 2008, p.29).

El perceptrón realiza la función de clasificación, Asigna un valor binario a un vector de N valores mediante una transformación no lineal. Por tanto, cada vector pertenece a una de las particiones creadas por el perceptrón. Además de tener la funcionalidad de un interruptor genérico y el poder expresivo equivalente a la lógica binaria, porque logramos crear un perceptrón que se comporte igual que una función booleana NAND (Cuadrado & Ramos, 2010, p.47).

2.2.12.2. El perceptrón multicapa

El perceptrón multicapa presenta un modelo neuronal “feedforward” (con propagación hacia adelante), con su notable característica organizacional de capas de celdas disjuntas, lo que implica que ninguna salida neuronal sea una entrada para las neuronas de la misma capa o de capas previas, lo que impide las conexiones feedback (Flores & Fernández, 2008, p.60).

Históricamente esta topología de RNAs, tuvo un periodo de limitación algorítmica, lo que en la actualidad no permitiría la utilización de capas ocultas el cual

fue resuelto con otro algoritmo conocido como “backpropagation” (retro propagación de errores), dicho algoritmo será descrito con mayor énfasis en el ítem 2.8.4.10.

Sus características capas ocultas que realizan una transformación sobre variables de entrada, convierte la función lineal no independiente en lineal independiente todo esto realizado por la capa oculta. Cabe mencionar que, al admitir valores reales, hace que el perceptrón sea un modelador de funciones universal (Cuadrado & Ramos, 2010, p.50).

2.2.12.3. Arquitectura del perceptrón multicapa

Es una capa de entrada, una capa de salida y una o más capas ocultas, además de presentar un modelo neuronal con propagación hacia adelante, la sinapsis o conexión neuronal presentan el siguiente orden: la capa de entrada de une con la primera capa oculta y está con las demás capas ocultas; la última capa oculta se une con la capa de salida. Se representa gráficamente de la siguiente manera:

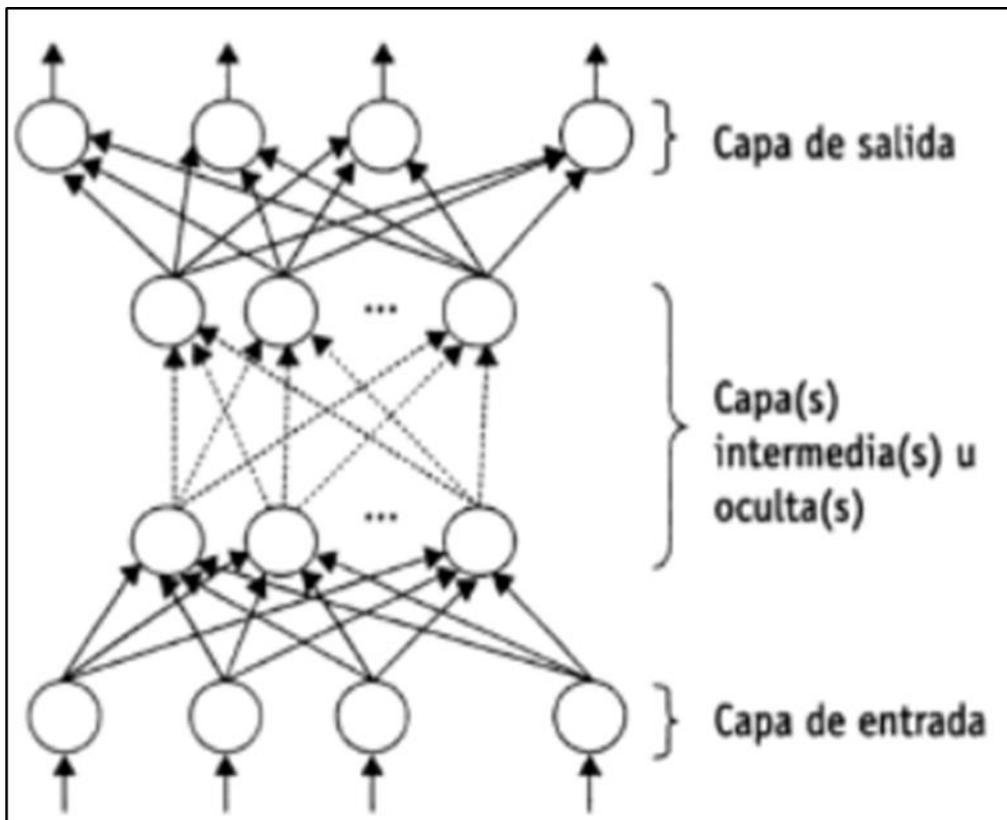


Figura 6: Arquitectura del perceptrón multicapa

Fuente: (Flores y Fernández, 2008, p.61)

2.2.12.4. Factores en el pronóstico de la demanda de energía

Los factores que se toman en cuenta, son directamente influyentes en el comportamiento del pronóstico de la demanda de energía eléctrica por medio de RNAs, son los causales en la varianza y determinan la forma del comportamiento de la misma.

2.2.12.5. Factor estacional

Como se mencionó en el ítem 2.6. de la presente tesis, el comportamiento de la demanda de energía eléctrica presenta una varianza en cada estación del año, para el presente objeto de estudio, es notable el aumento de la demanda de energía en estaciones de invierno.

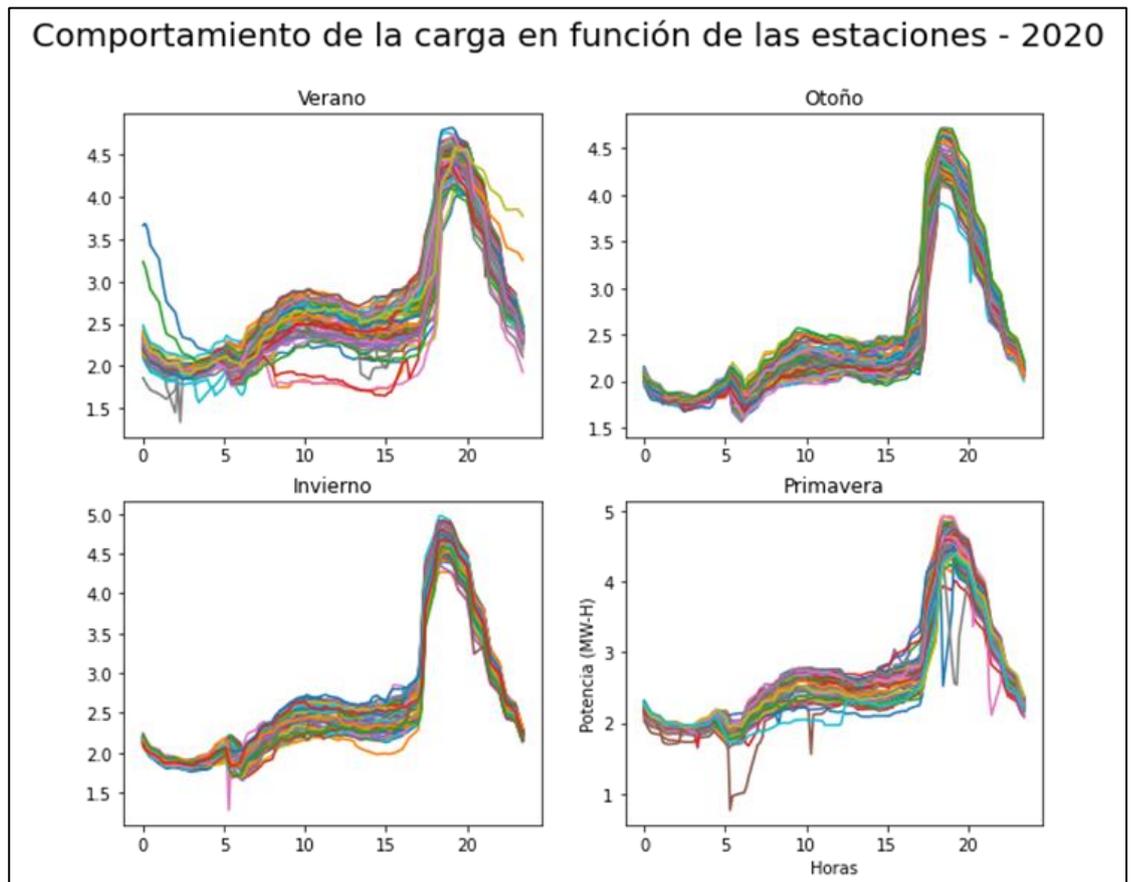


Figura 7: Comportamiento de la carga según las estaciones del año 2020
Elaboración propia

2.2.12.6. Factor climático

Las condiciones meteorológicas generan una varianza significativa en el comportamiento de la demanda de energía, se indicó en el ítem 2.6. de la presente tesis, los días extremadamente calurosos y los días extremadamente fríos generan efectos de gran significancia al momento de la ejecución del pronóstico o proyección de la demanda de energía eléctrica.

2.2.12.7. Factor temporal

El factor temporal en el pronóstico de la demanda de energía también es de suma importancia puesto que el comportamiento diario suele ser semejante entre días de semana laborables y fines de semana, presentándose similitudes entre días pertenecientes al mismo mes o incluso a meses distintos.

Un claro ejemplo de lo mencionado es la similitud de los días finales de cada año (31 de diciembre y 01 de enero) de cada año, en la gráfica se muestra que dichos días son los de mayor demanda a comparación del resto de los días, además de presentar un comportamiento cíclico estacional.

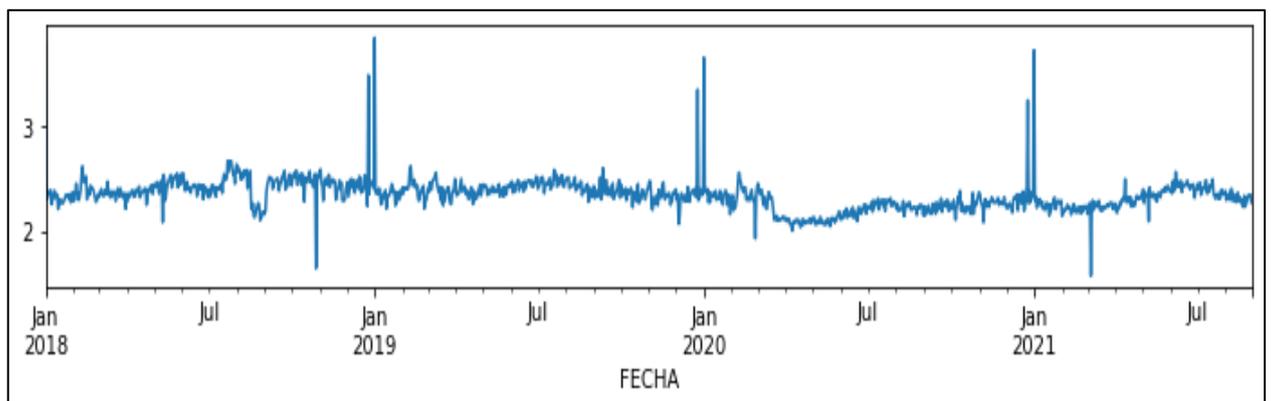


Figura 8: Comportamiento de la carga según días con mayor demanda.
Elaboración propia

El pronóstico de la demanda también, toma en cuenta el comportamiento de la demanda de energía en los días pasados, como se mencionó líneas arriba, existen



similitudes del comportamiento de la demanda, entre días de la semana anterior y día anterior al día el cual se realizará el pronóstico.

2.2.12.8. Datos de entrada y salida

Los datos de entrada y salida de una neurona logran ser clasificados en 2 conjuntos, continuas y binarias.

Las neuronas binarias (digitales) aceptan solo 2 valor posible. Normalmente, en este tipo de neuronas se emplean las 2 letras $\{0,1\}$ o $\{-1,1\}$.

Sin embargo, las neuronas continuas (analógicas) aceptan un rango de valores, definido como $[-1,1]$. La elección del tipo de neurona a emplear depende de las aplicaciones y de los modelos a construir. (Bertona, 2005) (Fernández, 2014) (Steinherz et al., 2001).

2.2.12.9. Pesos sinápticos

Según los autores Bertona (2005), Fernández (2014) y Steinherz et al. (2001), el peso sináptico define la fuerza de la conexión sináptica entre un par de neuronas, y el peso sináptico toma un valor negativo, positivo o cero. En el caso de entradas positivas, los pesos positivos actúan como excitadores, mientras que los pesos negativos actúan como inhibidores. Si el peso es 0, no hay comunicación entre el par de neuronas. Dependiendo del ajuste de los pesos sinápticos, la red puede adaptarse a cualquier entorno y ejecutar tareas específicas.

2.2.12.10. Función de activación y salida

Según Bertona (2005) La función de activación establece el estado de activación de la neurona basándose en el potencial resultante h_i y el estado de activación previo de la neurona $h_i(t-1)$. El estado de activación de una neurona en un tiempo dado t se puede expresar como:



$$a_i(t) = f_i(a_i(t - 1), h_i(t))$$

Donde:

$a_i(t)$ = Estado de activación en un periodo de tiempo “t”.

$f_i(a_i(t - 1))$ = Estado de activación anterior en un periodo de tiempo “t-1”.

$h_i(t)$ = Potencial resultante en un periodo de tiempo “t”.

En la tabla 3, se muestra las funciones de activación más frecuentes en los distintos modelos de RNAs.

Tabla 3: Funciones de activación

FUNCION	FORMULA	RANGO
IDENTIDAD	$y = x$	$[-\infty, \infty]$
ESCALON	$y = +1$ si $x \geq 0$	$[0, 1]$
	$y = 0$ si $x < 0$	
LINEAL A TRAMOS	$y = +1$ si $x \geq 0$	$[-1, 1]$
	$y = -1$ si $x < 0$	
SIGMOIDEA	$y = x$ si $-1 \leq x \leq 1$	$[0, 1]$
	$y = +1$ si $x > 1$	
	$y = -1$ si $x < -1$	
SINUSOIDAL	$y = \text{sen}(wx + \emptyset)$	$[-1, 1]$

Fuente: (Bertona, 2005, p.9)

La función de salida proporciona el valor de salida de la neurona en función del estado de activación de la neurona. Generalmente usa la función de identidad. (Bertona, 2005).

$$y_i(t) = F_i(a_i(t)) = a_i(t)$$

2.2.12.11. Fase de entrenamiento y aprendizaje

Según Bertona (2005), menciona que teniendo en cuenta el tipo de neurona artificial que se empleara, además de determinar su topología, el siguiente paso es entrenarla para que pueda cumplir el trabajo o función asignada. Los pesos sinápticos iniciales son aleatorios, los cuales se determinan con exactitud en el proceso de aprendizaje. Hasta alcanzar un nivel de refinamiento y lograr una operacionalidad bastante buena. El aprendizaje se subdivide en:

Tabla 4:Tipos de aprendizaje

Aprendizaje	Característica
Supervisado	“Se presenta un conjunto de patrones de entrada a la red junto con la salida esperada. Los pesos se modifican proporcionalmente al error que se produce entre las salidas reales y esperadas de la red”.
No supervisado	“No hay información sobre los resultados esperados. El proceso de entrenamiento en este caso debe ajustar sus pesos en función de las correlaciones existentes entre los datos de entrada”.
Por esfuerzo	“Se ubica en medio de los tipos de aprendizaje descritos anteriormente. Se presenta a la red con un conjunto de patrones de entrada, y se presenta a la red con un conjunto de patrones de entrada, indicando a la red si la salida lograda es correcta o no.”.

Elaboración propia basado en Bertona (2005)

2.2.12.12. Fase de operación

Al culminar de las fases de entrenamiento y aprendizaje, la RNAs tipo MLP esta apta para realizar las funciones o tareas para las cuales fue entrenada. Bertona (2005, p.11) menciona que una de las ventajas principales es que la red adquiere las capacidades de generalizar definiciones. De esta manera la red neuronal puede tratar con datos que no le fueron presentados en el entrenamiento.



2.2.12.13. El algoritmo de backpropagation

Según Fritsch (1996) es el método de entrenamiento empleado con mayor frecuencia en redes con conexión feedforward. Es una sistemática de instrucción supervisado, en el que aprecian notablemente dos fases: Primero, se aplican un patrón de entrada, que se propaga a través de las diferentes capas que componen la red neuronal hasta que se produce una salida. Compare esta salida con la salida deseada y calcule el error resultante para cada neurona de salida. Cada neurona recibe un error proporcional a su parte del error total de la red. En función del error recibido, se ajusta el error del peso sináptico de cada neurona.



CAPITULO III

MATERIALES Y MÉTODOS

3.1. CLASIFICACIÓN DE LA INVESTIGACIÓN

3.1.1. Tipo de investigación

Es de tipo NO EXPERIMENTAL de enfoque CUANTITATIVO, Debido a la necesidad de medir y estimar la magnitud del fenómeno o problema de la presente investigación, además de no manipular, ni modificar los elementos estudiados, ya que la presente investigación está diseñada para determinar el impacto probable de la causa no manipulada, la recopilación de datos históricos es principalmente basado en medidas, además de ser de corte transversal y longitudinal (Hernández, 2014).

3.1.2. Nivel de investigación

El presente trabajo corresponde a un estudio PROYECTIVO ya que se pretende especificar, describir y explicar las propiedades, características y funciones del comportamiento y los fenómenos que puedan producir las RNAs del tipo perceptron multicapa, Estas variables se utilizan en su operación para predecir la demanda de energía eléctrica y cabe mencionar que solo tiene como finalidad medir o recopilar información de las variables de forma individual o conjunta. (Hernández, 2014).

3.1.3. Diseño de investigación

En el presente estudio se realizó el siguiente diseño de investigación, para así poder llevar un adecuado grado de evaluación y determinación en el pronóstico de la demanda de energía eléctrica en la barra de 60kv del sistema eléctrico Puno.



Primero: Se realiza la selección del objeto de estudio, tomando en cuenta el grado de importancia de cada una de las barras del sistema eléctrico Puno, según la evaluación previa se elige la barra de 60kv.

Segundo: Se realiza la recopilación y procesamiento de la base de datos de la demanda de energía eléctrica expresada en MW, datos históricos obtenidos de la barra de 60kv del sistema eléctrico Puno. Información correspondiente a los años 2018, 2019, 2020 y agosto del 2021. Se estudia, explica y las validaciones de las informaciones recolectadas.

Tercero: Se procesa la información en el software de simulación utilizado en la presente investigación. Además de hacer uso de las librerías del mismo.

Cuarto: Se modela la RNAs según la arquitectura y topología elegida para la presente tesis.

Quinto: Entrenamiento de la RNAs en la función encomendada, validación de los valores del pronóstico de la demanda de energía.

Sexto: Se ejecuta la validación de la hipótesis planteada.

3.2. POBLACIÓN Y MUESTRA

3.2.1. Población

En la presente investigación para objeto del presente estudio, se considera como población el conjunto de datos de demanda de energía pertenecientes al sistema eléctrico Puno, administrado por la empresa de comercialización y distribución Electro Puno S.A.A.



3.2.2. Muestra

La muestra es representada por la base de datos de demanda de la barra de 60kv asociada al sistema eléctrico Puno. Instalado en la SET totorani el cual está ubicado geográficamente en el centro poblado de alto Puno, distrito de Puno, provincia y departamento de Puno.

3.3. TÉCNICAS E INSTRUMENTOS DE RECOLECCIÓN DE DATOS

Es la técnica documentaria y los instrumentos empleados en la recopilación de datos para la realización de la presente investigación son los siguientes:

3.3.1. Recolección de datos

Se basa en procesos dependientes de la información disponible y brindada por ELPU, siendo estos:

- Solicitud de información a la gerencia de comercialización de la empresa distribuidora concerniente a la compra de energía en las barras asociadas al sistema eléctrico Puno y a elementos que conforman los sistemas eléctricos.
- Búsqueda de información en la web, artículos científicos y libros.

3.3.2. Instrumentos

Por parte de la empresa la cual compartió los datos históricos de la compra de energía eléctrica, utilizaron equipos de medición electrónicos, dichos aparatos son medidores registradores, los cuales poseen una memoria interna que recoge los registros de los parámetros eléctricos cada 15 minutos.

Tabla 5: Medidores en puntos de compra.

Barra de compra	Serie del medidor	Marca	Modelo	Clase	Año	Propiedad
Puno 60 kV	PJ-0903A225-15 PJ-0903A224-01	Schneider Electric	ION	0.2	2014	San Gabán
Puno 22.9 kV	PJ-0809A146-14	Schneider Electric	ION	0.2	2014	San Gabán
Juliaca 22.9 kV	PJ-0809A148-01	Schneider Electric	ION	0.2	2014	San Gabán
Juliaca 10 kV	PJ-0809A147-01	Schneider Electric	ION	0.2	2014	San Gabán
Azángaro 22.9 Kv	PJ-0903A222-01	Schneider Electric	ION	0.2	2014	San Gabán
Azángaro 60 Kv	PJ-0903A223-01	Schneider Electric	ION	0.2	2014	San Gabán
Ayaviri 22.9 Kv	PJ-0903A225-01	Schneider Electric	ION	0.2	2014	San Gabán
Ayaviri 10 Kv	PJ-09036A221-01	Schneider Electric	ION	0.2	2014	San Gabán
San Gabán 22.9 Kv	PJ-09036A220-01	Schneider Electric	ION	0.2	2014	San Gabán

Fuente: (Gerencia de comercialización - ELPU)

Por parte del autor del presente estudio:

- Computador tipo laptop; para el análisis de datos, tratamiento de datos y para la construcción, diseño y entrenamiento de la red neuronal.
- Plataforma web Google Colaboratory (Colab), para el entrenamiento de la red neuronal.
- Software libre Python y librerías.
- Software Eviews.

3.3.3. Técnicas de procesamiento y análisis de datos

Para analizar y procesar los datos se emplearán los siguientes softwares:

- Microsoft Office (Excel, Word y Vicio).
- Python y librerías.
- Eviews.

3.4. METODOLOGIA PARA LA PROYECCION DE ENERGIA

3.4.1. Selección del objeto de estudio

En las instalaciones de la SET Totorani se encuentran las instalaciones de una de las barras de compra de energía eléctrica pertenecientes al sistema eléctrico Puno, los mismos que se disgregan en: Sistema eléctrico rural Puno, Sistema eléctrico Puno de baja densidad y sistema eléctrico Ilave-Pomata. Para el presente estudio se tomó como referencia la clasificación por barras de compra de energía que posee ELPU las cuales son: Puno 60kV y Puno 22.9 kV.

Se toma como objeto de estudio la barra Puno 60kV por ser la de mayor tensión de transmisión, además de englobar los sub sistemas Sistema eléctrico Puno de baja densidad y sistema eléctrico ilave-pomata, ya que los valores de la base de datos de esta barra, reflejan el consumo de toda la ciudad de Puno y las localidades cercanas más pobladas de la zona sur de la región.

Tabla 6: Selección del objeto de estudio.

Barra de compra	Salida LT	Sub sistema	Salida MT	Condición
Puno 60 kV	SET PUNO	Puno Puno baja densidad	salida 0101 (Av. Circunvalación) salida 0102 (Centro Puno) salida 0103 (Av. El Sol) salida 0104 (Alto Puno) salida 0105 (Av. Simón Bolívar) salida 0106 (UNA-Antenas)	Seleccionado como objeto de estudio
	SET ILAVE-POMATA	Ilave - pomata	salida 1001 (Pilcuyo) salida 1002 (Ilave - Acora) salida 1003 (Ilave Zona Alta) salida 2001 (Juli) salida 2002 (Yunguyo) salida 2003 (Desaguadero) salida 2004 (Pomata)	
Puno 22.9 kV	SALIDA VILQUE - MAÑASO	Puno rural	Vilque Mañaso	-

Fuente: (Gerencia de Operaciones - ELPU)

3.4.2. Pre procesamiento de la base de datos

En la presente investigación se empleó una base de datos de demanda de los años 2018, 2019, 2020 y agosto del 2021. Valores de demanda de energía expresada en MWh perteneciente a la barra de 60kv del sistema eléctrico Puno.

Los valores de demanda son tomados en parámetros de tiempo de cuarto de hora (cada 15 minutos) por lo que se obtiene 96 valores diarios para la elaboración de la serie de tiempo. Tomados desde el 1 de enero del 2018 hasta el 31 de agosto del 2021

Tabla 7: Base de datos de las barras del sistema eléctrico Puno periodo 00:15 horas 03:15 horas del 01/01/2020

Empresa:	Electro Puno S.A.A.	PUNO 60 kV	PUNO 22.9 kV	JULIACA 22.9 kV	JULIACA 10 kV	AZANGARO 22.9 kV	AZANGARO 60 kV	AYAVIRI 22.9 kV	AYAVIRI 10 kV	SAN GABAN 13.8 kV
Barra de Retiro Físico:		ENERGIA	ENERGIA	ENERGIA	ENERGIA	ENERGIA	ENERGIA	ENERGIA	ENERGIA	ENERGIA
Unidad:		MWh	MWh	MWh	MWh	MWh	MWh	MWh	MWh	MWh
Ejecutado	01/01/2018 00:00
.
.
Ejecutado	01/01/2021 00:15	3.75	0.72	1.27	4.98	0.92	0.90	0.30	0.29	0.15
Ejecutado	01/01/2021 00:30	3.68	0.70	1.25	4.91	0.93	0.94	0.30	0.29	0.15
Ejecutado	01/01/2021 00:45	3.55	0.68	1.20	4.79	0.90	0.96	0.29	0.28	0.14
Ejecutado	01/01/2021 01:00	3.34	0.64	1.15	4.59	0.86	0.87	0.28	0.27	0.14
Ejecutado	01/01/2021 01:15	3.15	0.61	1.09	4.35	0.81	0.81	0.27	0.25	0.14
Ejecutado	01/01/2021 01:30	2.99	0.57	1.06	4.08	0.75	0.78	0.25	0.23	0.13
Ejecutado	01/01/2021 01:45	2.83	0.54	1.03	3.82	0.70	0.72	0.23	0.21	0.12
Ejecutado	01/01/2021 02:00	2.71	0.52	1.02	3.58	0.66	0.67	0.22	0.20	0.12
Ejecutado	01/01/2021 02:15	2.59	0.49	1.00	3.37	0.62	0.62	0.21	0.19	0.12
Ejecutado	01/01/2021 02:30	2.49	0.47	1.02	3.18	0.60	0.66	0.20	0.17	0.12
Ejecutado	01/01/2021 02:45	2.42	0.45	1.01	3.06	0.57	0.54	0.19	0.17	0.11
Ejecutado	01/01/2021 03:00	2.36	0.44	1.00	2.94	0.55	0.52	0.19	0.16	0.10
Ejecutado	01/01/2021 03:15	2.31	0.43	1.01	2.86	0.54	0.55	0.18	0.16	0.10
.
.
Ejecutado	31/08/2021 00:00

Fuente: (Gerencia de Comercialización, ELPU)

Los datos de demanda tomados como valores de entrada para la red neuronal artificial son tomados en parámetros de tiempo de media de hora (cada 30 minutos) por lo que se obtiene 48 valores diarios para la realización de los pronósticos. Tomados desde el 1 de enero del 2018 hasta el 31 de agosto del 2021

Tabla 8: Valores de demanda periodo 01/01/2018 logrado de la base de datos de la barra de 60kv.

Nº	FECHA	DEMANDA
1	2018-01-01 00:00:00	3.806495
2	2018-01-01 00:30:00	3.75722
3	2018-01-01 01:00:00	3.457277
4	2018-01-01 01:30:00	2.972107
5	2018-01-01 02:00:00	2.619474
6	2018-01-01 02:30:00	2.420526
7	2018-01-01 03:00:00	3.806495
.	.	.
.	.	.
.	.	.
.	.	.
48	2018-01-01 23:30:00	2.47321

Elaboración propia

Análisis de datos históricos

Se presenta la siguiente serie de tiempo, la cual fue elaborada a partir de la base de datos históricos, conformada por un total de 128544 valores de demanda, comprendida en los periodos de tiempo de 01 de enero del 2018 al 31 de agosto de 2021, en dicha serie de tiempo se puede evidenciar el comportamiento anómalo que presenta la demanda de energía eléctrica a través del periodo temporal mencionado.

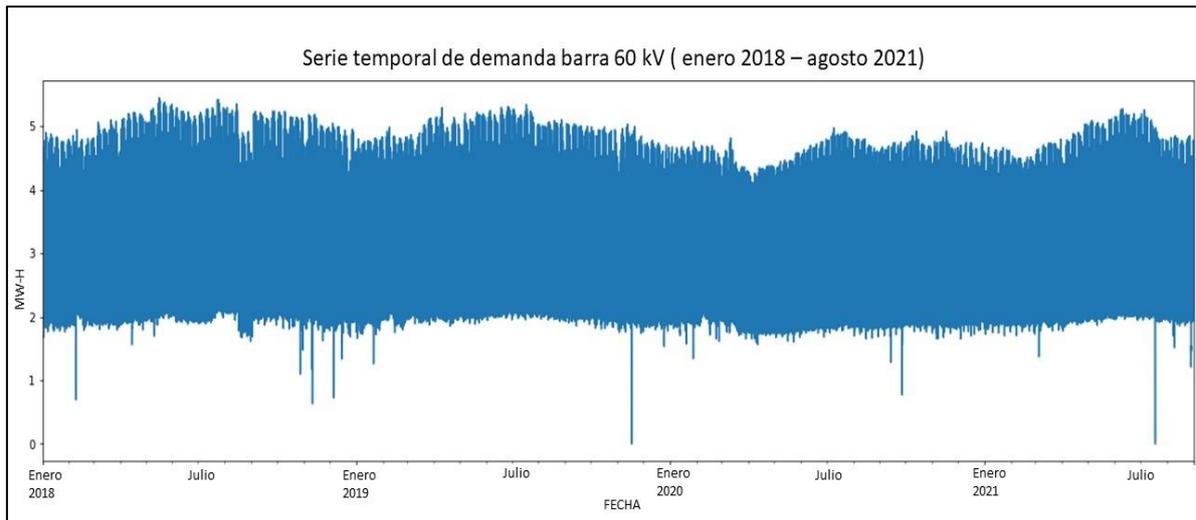


Figura 9: Perfil de demanda histórica de la barra 60 kv (enero 2018-agosto 2021).
Elaboración propia

Figura N° 9, se aprecia la existencia valores de demanda extremadamente atípicos e inusuales, que no siguen ningún patrón o comportamiento similar a valores de días de la semana pasada o un día anterior, para dicho caso se realizará el análisis correspondiente, además del suavizado o corrección necesaria para seguidamente realizar las proyecciones de demanda.

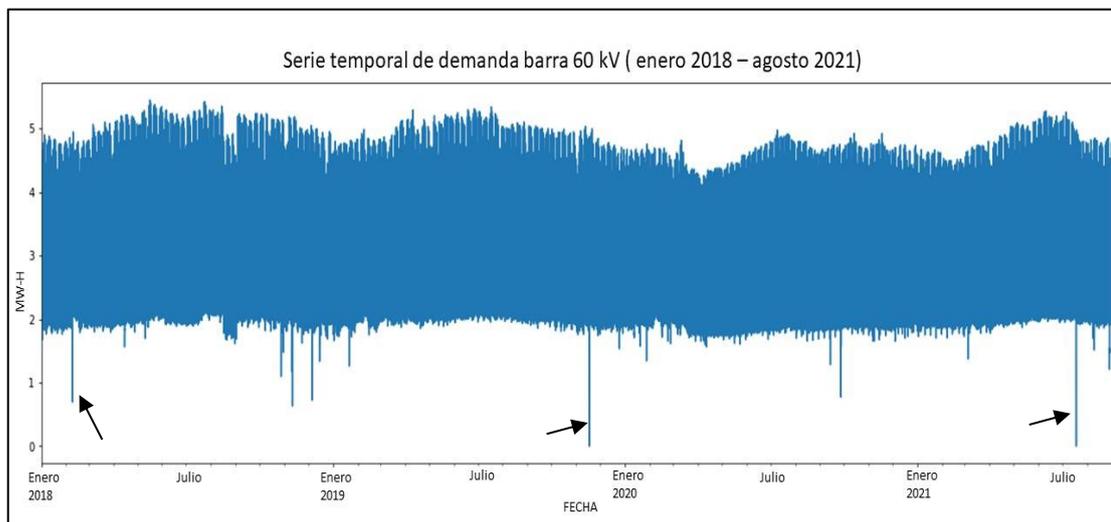


Figura 10: Serie de tiempo y Valores inusuales o atípicos.
Elaboración propia

Los valores atípicos son aquellos que no tienden a seguir el comportamiento de la carga, ya sea el comportamiento general, mensual o diario tal y como se muestra en la figura N° 10, en la serie de tiempo general es apreciable la existencia de estos valores.

La corrección o suavizado de estos datos es de gran importancia en el pronóstico de la demanda, ya que al realizar la serie de tiempo en un día estos valores son más notorios y más influyentes en la predicción, al ser datos que no siguen la tendencia tienen a generar mayor error al realizar las proyecciones. Por eso es que se desarrollaron los métodos de corrección o suavizado.

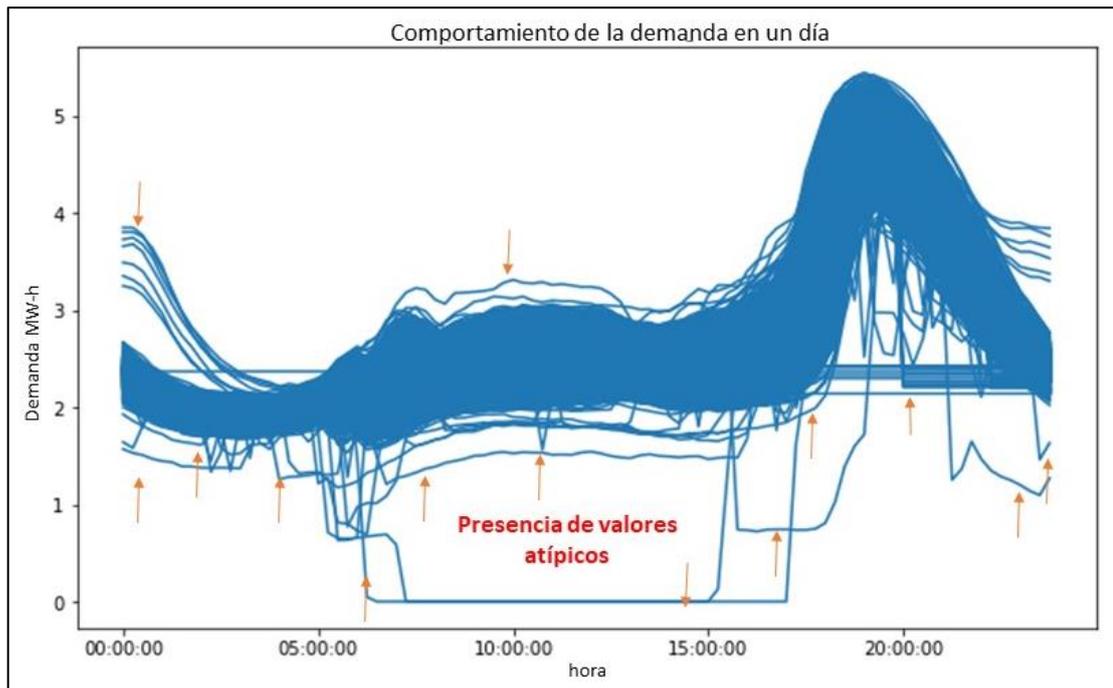


Figura 11: Valores inusuales o atípicos en la serie de tiempo diaria.
Elaboración propia

Figura N° 11 podemos apreciar una ligera caída de la demanda en los periodos comprendidos en los meses de abril, mayo y junio del año 2020, podemos mencionar que este hecho se suscitó a raíz de la medida de cuarentena tomada por el gobierno nacional a raíz del desarrollo de la pandemia provocada por el virus denominado COVID 19, en dicho periodo de cuarentena muchos negocios e industria local cerraron y paralizaron su producción todo esto conllevó a las disminuciones en el consumo de energía eléctrica.

Podemos también mencionar que la conducta de la demanda de energía suele presentar picos elevados en los meses de mayo, junio y julio; esto debido a la estación de invierno en la región de Puno, así como la presencia de friaje y heladas, lo que conlleva

que muchas de las personas y empresas utilicen calefactores eléctricos, por ende, la demanda de energía tiende a incrementarse.

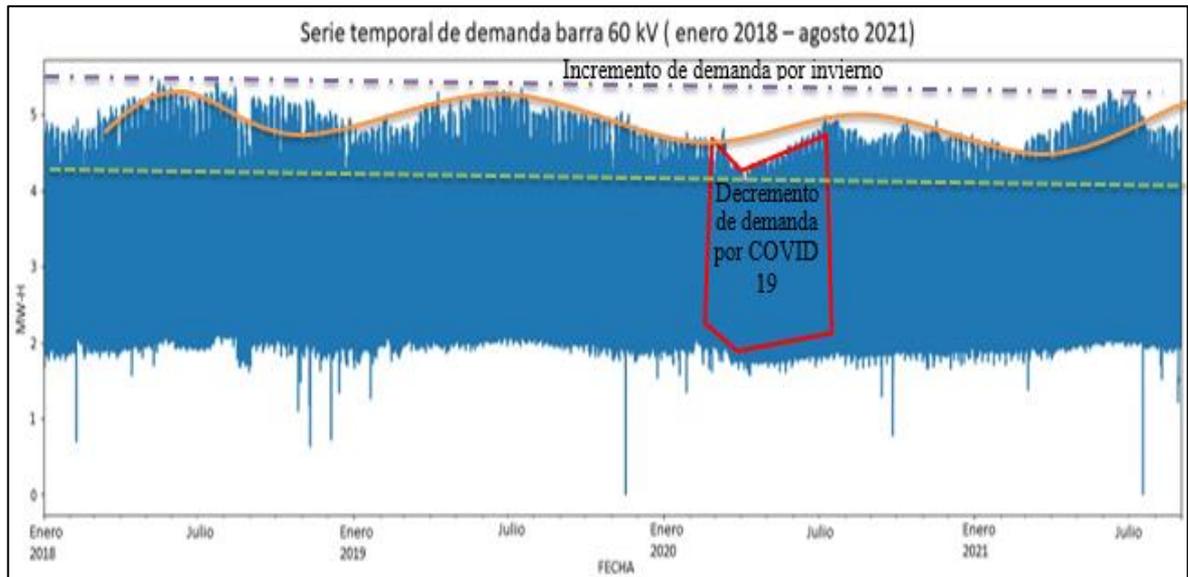


Figura 12: Incrementos y decremento de demanda en la serie de tiempo.
Elaboración propia

Para mayor análisis temporal, se realiza un gráfico del comportamiento de la carga de forma semanal para realizar un análisis diario. Podemos detallar que los días con mayor consumo de energía eléctrica en la ciudad de Puno y las ciudades del sur son los días lunes, martes, miércoles, jueves y viernes. Se concluye que este comportamiento se debe a que los días en donde las empresas, entidades e industria realizan mayor actividad son los días laborables y por ende el consumo de energía se incrementa, a comparación de los fines de semana, es de conocimiento que los días sábados solo se labora hasta el medio día o no se labora al igual que los días domingos, lo que conllevaría a afirmar que el consumo doméstico de los fines de semana es relativamente menor que los días laborables.

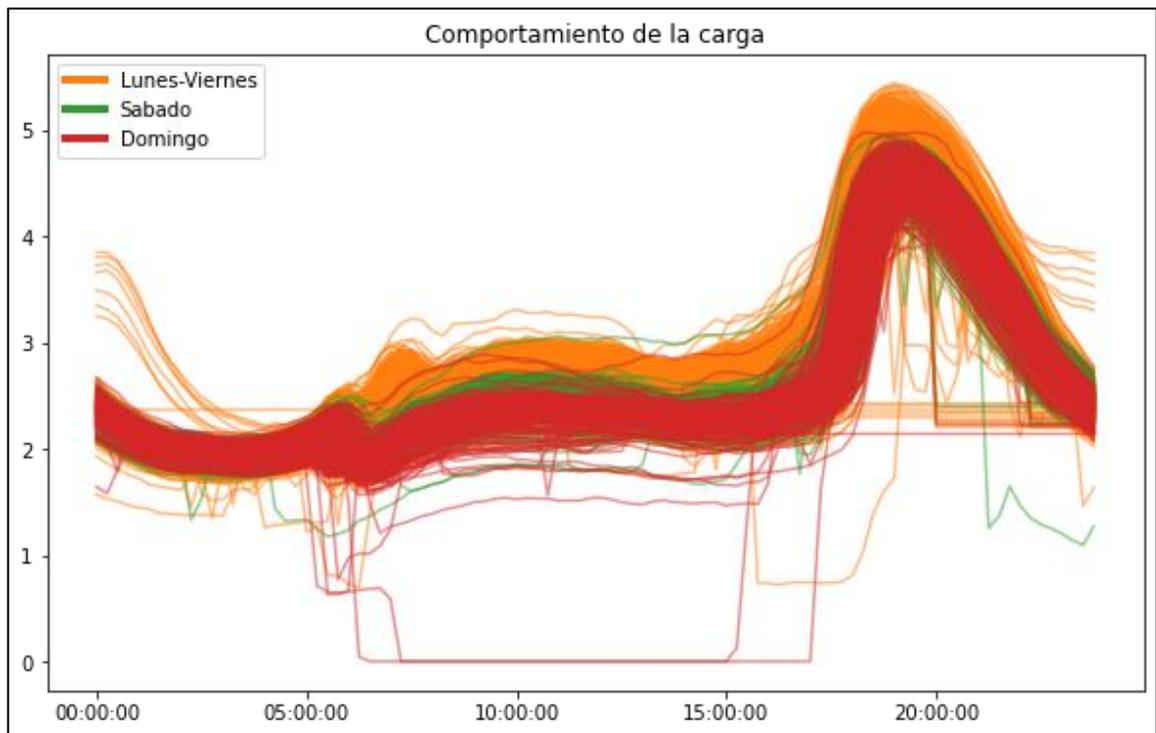


Figura 13: Serie de tiempo diaria comprendida entre los parámetros 01 de enero 2018-31 de agosto 2021.

Elaboración propia

En la figura N° 13 también es apreciable el comportamiento de la carga según la hora del día, llámese horas punta y horas fuera de punta. Es claramente apreciable que las horas punta en la ciudad de Puno comienzan a partir de las 16:00 horas hasta llegar a su pico máximo de las 20:00 horas y empezar con el descenso correspondiente. Esto debido a mayor utilización de iluminación en las calles y domicilios, así como de la utilización de aparatos eléctricos.

Análisis y corrección de datos atípicos

Al realizar los análisis de las gráficas de las series de tiempo, se logró identificar la existencia de datos atípicos o inusuales, para un mayor análisis de procedió a realizar una gráfica de normalidad (campana de Gauss) de los datos de la variable.

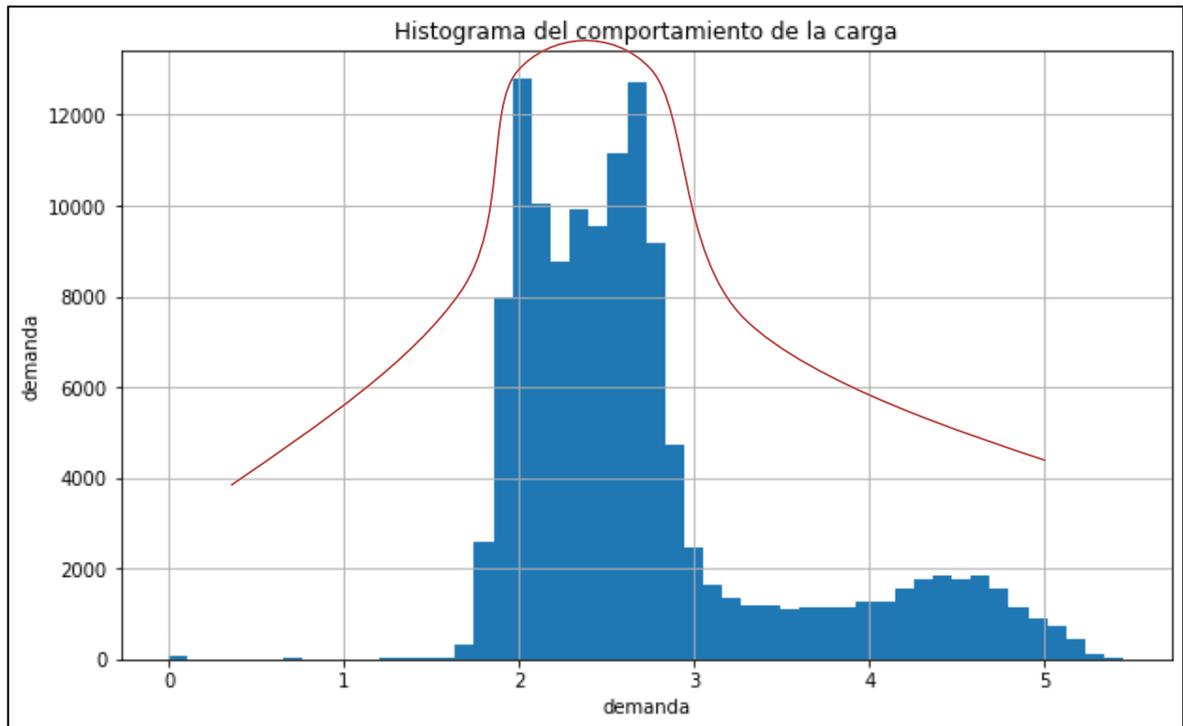


Figura 14: Grafica de distribución normal (campana de Gauss).
Elaboración propia

De la figura N° 14, podemos verificar de la gráfica que la serie temporal no sigue una distribución normal, esto quiere decir que los parámetros estadísticos y métodos de suavizados tradicionales son de poco uso para la corrección de los datos atípicos.

Para la corrección de datos atípicos se utiliza la estacionalidad de datos, cabe decir que al identificar los datos atípicos dentro de la serie de tiempo estos serán reemplazados por valores del mismo día de la semana o mes pasado.

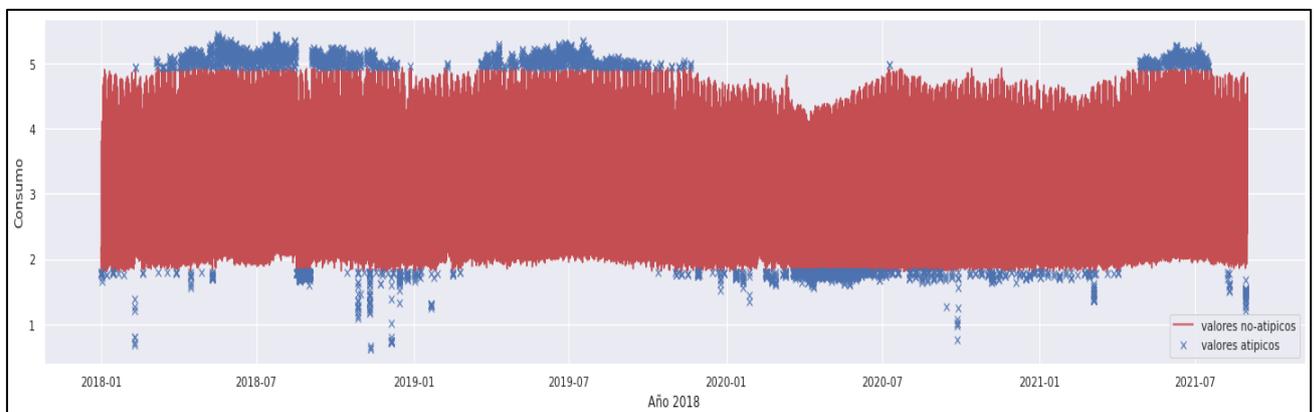


Figura 15: Corrección de datos atípicos en la serie de tiempo.
Elaboración propia

Estandarización y acondicionamiento de datos

Una vez ejecutado el tratamiento de los datos perdidos y atípicos de la serie de tiempo, se procedió a estandarizar los datos, esta acción implica re escalar la distribución de valores, también se le denomina “blanqueo”, este tratamiento nos permite trabajar con la media con un valor de 0 la desviación estándar con 1, a valores que no se apeguen a una distribución normal (campana de gauss), para la estandarización solo es necesario tener conocimiento de los valores de entrada y así proceder con el entrenamiento.

$$Y = \frac{(x - media)}{desviacion - estandar}$$

Donde:

X = Dato escalado

Y = Dato original

Media = 0

Desviación - estándar = 1

3.4.3. Variables de la Investigación

Identificación de variables

Tabla 9: Identificación de variables

Variable	Tipo	Concepto
Error de predicción de la demanda de energía eléctrica	Cuantitativa. Dependiente	Son procedimientos sistemáticos que define cuantitativamente los requerimientos futuros, y dado que es crítico, es imperativo asegurar que dichas informaciones sea lo más precisa posible sin olvidar que existe incertidumbre.
Eficiencia del Modelo de predicción	Cualitativa Independiente	Se refiere a las técnicas, procesos, operaciones y algoritmos diseñadas para mejorar la calidad de los resultados de los pronósticos.

Elaboración propia

3.4.4. Operacionalización de variables

Tabla 10: Operacionalización de Variables de Investigación

Variable	Indicador	Técnica	Instrumento
Error de predicción de la demanda de energía eléctrica	Error absoluto porcentual promedio (MAPE)	Estadística	Python, TensorFlow, Keras
Eficiencia del Modelo de predicción	Eficiencia del modelo de predicción	Predicción	Python, TensorFlow, Keras

Elaboración propia

3.4.5. Software de simulación

Python, es un lenguaje de programación e interpretación multiparadigma, cabe de decir que desarrolla programación orientada a objetos, imperativa y funcional. El cual es capaz de trabajar con librerías pre programadas o bases de trabajo como Tensorflow y keras las cuales son esquemas con una estructura base para el desarrollo de redes neuronales en Python. En dicho software se realizará el desarrollo e implementación de la RNA perceptrón multicapa.

Eviews, es una herramienta tecnológica de gran capacidad y facilidad de utilización para realizar trabajos eficientes relacionados a los análisis econométricos y estadísticos, que tiene la capacidad de realizar series de tiempo, regresiones múltiples, pronósticos y demás relacionados a la estadística tradicional. Se utilizará dicho software para realizar las mismas proyecciones que la RNA tipo MLS programada en python, y así poder comparar dichos resultados y ver cuál de ellos tiene menor porcentaje de error y así validar nuestra hipótesis.

3.4.6. Desarrollo de la Arquitectura de la RNAs tipo MLS

La RNA tipo MLS utilizada está compuesta por 3 capas, las cuales son:

La capa de entrada (constituida por neuronas de entrada) conformada por 98 neuronas de entrada, las cuales dividen en:

- 48 neuronas correspondientes a los valores de la demanda eléctrica, valores representados en un periodo temporal de cada 30 minutos, de la semana anterior que corresponden al día típico a pronosticar.
- 48 neuronas correspondientes a los valores de demanda eléctrica del día anterior al día a proyectar.
- 1 neurona de la estación de año.
- 1 neurona que corresponde al día típico de la semana a proyectar.

Las capas ocultas (compuesta por neuronas ocultas interconectadas), la red neuronal artificial utilizada está conformada por 02 capas ocultas, las cuales se interrelacionan con las capas de entrada y salida respectivamente.

La capa de salida (compuestas por neuronas de salida), conformada por 48 neuronas que pertenecen a los valores de demanda de energía eléctrica que han sido pronosticados en valores representados en un periodo temporal de cada 30 minutos para un día.

A continuación, se muestran la arquitectura del modelo de red neuronal propuesto.

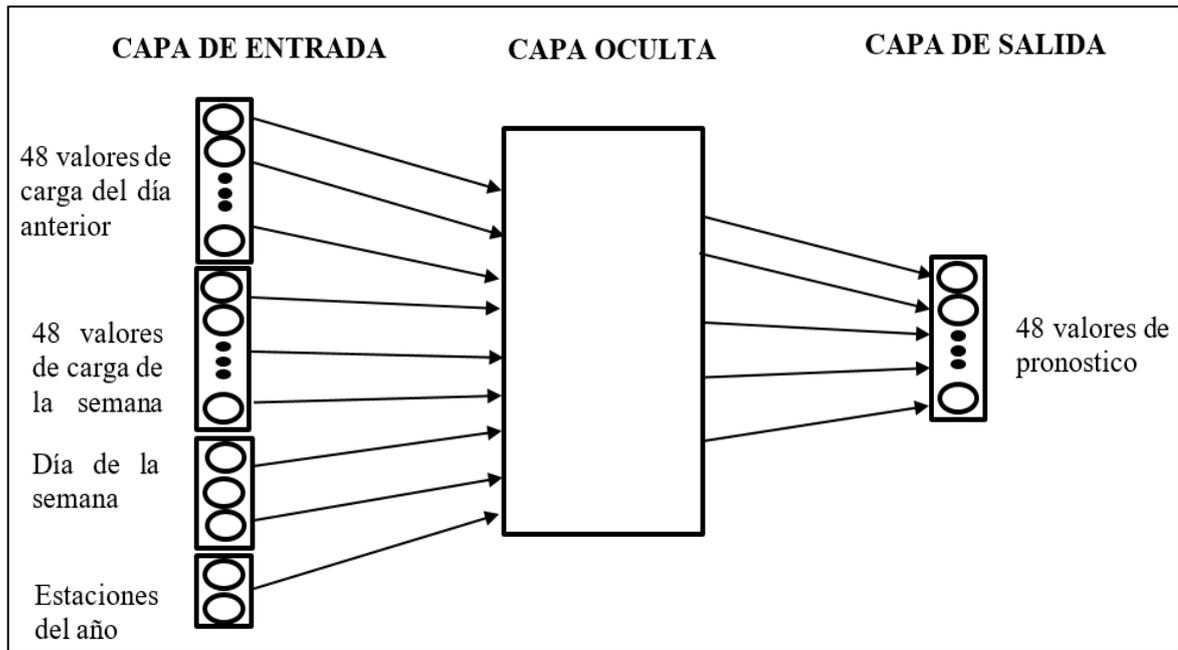


Figura 16: Arquitectura de la RNA tipo MLS propuesto.
Elaboración propia basado en Fernández 2014

En la figura N° 17 se aprecian en el software los valores de ingreso del día anterior, en un total de 48 valores de carga por día en parámetros temporales de cada 30 minutos:

```
df_semanaActual = df_semanaActual.drop(["2018-01-01", "2018-01-02", "2018-01-03", "2018-01-04", "2018-01-05", "2018-01-06", "2018-01-07", "2021-08-31"])
df_semanaActual.head()
```

hora	00:00:00	00:30:00	01:00:00	01:30:00	02:00:00	02:30:00	03:00:00	03:30:00	04:00:00	04:30:00	...	19:00:00	19:30:00	20:00:00	
fecha	dia														
2018-01-08	Monday	2.255422	2.118422	2.013014	1.916983	1.915596	1.919337	1.870714	1.890034	1.904158	2.000270	...	4.570029	4.752322	4.590838
2018-01-09	Tuesday	2.331807	2.171008	2.036886	1.966961	1.940963	1.889964	1.873399	1.914909	1.900971	1.967280	...	4.665177	4.796478	4.746421
2018-01-10	Wednesday	2.311075	2.138633	2.031769	2.008956	1.949631	1.964212	1.917286	1.947335	1.952080	2.009601	...	4.638885	4.880087	4.810955
2018-01-11	Thursday	2.384005	2.205027	2.097458	1.994480	1.983286	1.915694	1.901747	1.946695	1.960999	2.000147	...	4.750297	4.821373	4.682732
2018-01-12	Friday	2.339800	2.173865	2.046821	1.963579	1.952152	1.927200	1.911393	1.916468	1.972693	1.997147	...	4.736800	4.803333	4.658659

5 rows x 48 columns

Figura 17: Datos de entrada 48 valores de carga del día anterior.
Elaboración propia

Figura N° 18 se aprecian en el software los valores de ingreso de la semana pasada, en un total de 48 valores de carga por día en parámetros temporales de cada 30 minutos:

```
#Transformando del Dataframe
df_pivot= df_2.pivot(index=['fecha','dia'], columns='hora', values='consumo')
#Copia
df_semanaPasada= df_pivot.copy()
# Eliminar datos
df_semanaPasada = df_semanaPasada.drop(["2021-08-25", "2021-08-26", "2021-08-27", "2021-08-28", "2021-08-29", "2021-08-30", "2021-08-31", "2021-08-24"])
df_semanaPasada.head()
```

hora	00:00:00	00:30:00	01:00:00	01:30:00	02:00:00	02:30:00	03:00:00	03:30:00	04:00:00	04:30:00	...	19:00:00	19:30:00	20:00:00	
fecha	dia														
2018-01-01	Monday	3.806495	3.757220	3.457277	2.972107	2.619474	2.420526	2.265926	2.167135	2.120294	2.141302	...	3.882836	4.092023	4.074759
2018-01-02	Tuesday	2.311954	2.142135	2.037293	1.971618	1.966999	1.901741	1.893686	1.910216	1.918776	1.936571	...	4.489323	4.638003	4.631736
2018-01-03	Wednesday	2.308899	2.161110	2.073152	1.975605	1.963590	1.902332	1.884832	1.897034	1.954657	1.994692	...	4.534983	4.768905	4.720042
2018-01-04	Thursday	2.339694	2.151907	2.038640	1.974856	1.896870	1.891731	1.888588	1.848422	1.912317	1.963574	...	4.625531	4.888726	4.903282
2018-01-05	Friday	2.376024	2.197770	2.055888	1.990392	1.967032	1.902162	1.893244	1.911412	1.961349	2.033576	...	4.669488	4.838292	4.779548

5 rows x 48 columns

Figura 18: Datos de entrada 48 valores de carga de la semana pasada.
Elaboración propia

La figura N° 19 se aprecian en el software los valores de salida del pronóstico, en un total de 48 valores de carga por día en parámetros temporales de cada 30 minutos:

```
df_diaApronosticar = df_diaApronosticar.drop(["2018-01-01", "2018-01-02", "2018-01-03", "2018-01-04", "2018-01-05", "2018-01-06", "2018-01-07", "2018-01-08"])
df_diaApronosticar.head()
```

hora	00:00:00	00:30:00	01:00:00	01:30:00	02:00:00	02:30:00	03:00:00	03:30:00	04:00:00	04:30:00	...	19:00:00	19:30:00	20:00:00	20:30:00	
fecha	dia															
2018-01-09	Tuesday	2.331807	2.171008	2.036886	1.966961	1.940963	1.889964	1.873399	1.914909	1.900971	1.967280	...	4.665177	4.796478	4.746421	4.488145
2018-01-10	Wednesday	2.311075	2.138633	2.031769	2.008956	1.949631	1.964212	1.917286	1.947335	1.952080	2.009601	...	4.638885	4.880087	4.810955	4.593394
2018-01-11	Thursday	2.384005	2.205027	2.097458	1.994480	1.983286	1.915694	1.901747	1.946695	1.960999	2.000147	...	4.750297	4.821373	4.682732	4.430076
2018-01-12	Friday	2.339800	2.173865	2.046821	1.963579	1.952152	1.927200	1.911393	1.916468	1.972693	1.997147	...	4.736800	4.803333	4.658659	4.438990
2018-01-13	Saturday	2.324390	2.183835	2.065366	1.989065	1.979599	1.915899	1.895047	1.910258	1.927004	1.968931	...	4.367794	4.562541	4.477814	4.299726

5 rows x 48 columns

Figura 19: Datos de salida 48 valores de carga del día actual.
Elaboración propia

3.4.7. Función de activación de la red neuronal

Es utilizada en la RNA tipo MLS es Reluactivation, la función rectificadora que tiene una función similar a la función de activación lineal.

Reluactivation ayuda a las RNA a formar modelos de aprendizaje profundo, esto permite que el modelo MLS tenga un funcionamiento más óptimo y un aprendizaje con mayor rapidez. Debido a la presencia de problemas de gradiente de fuga en diferentes capas, la utilización de la activación sigmoide no es utilizable en este caso.

El gradiente de fuga se origina en el proceso de entrenamiento de la RNA, el cual en cada entrenamiento origina que algunas neuronas sean más lentas que otras, esto a raíz de, que en cada entrenamiento los pesos varían, muchos de estos tienden a descender a ir en dirección negativa, lo que conlleva a provocar lentitud en proceso de aprendizaje de algunas neuronas.

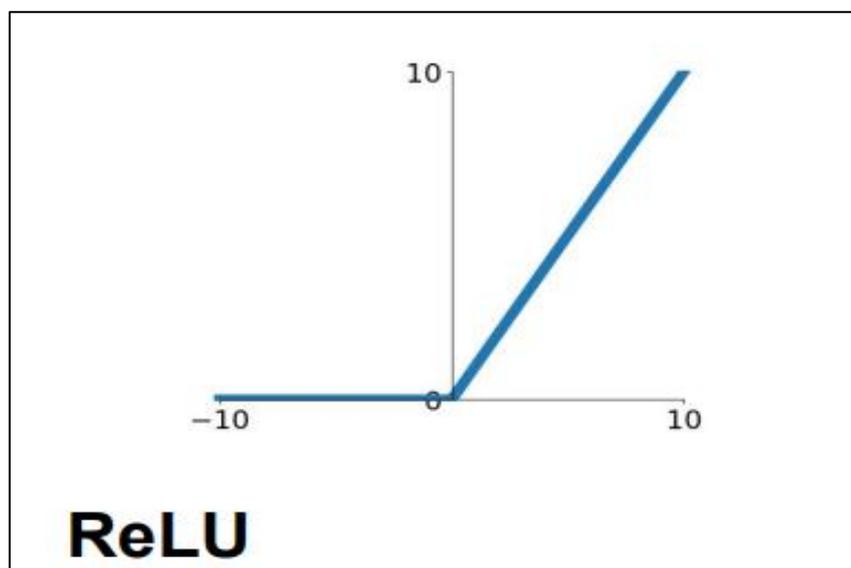


Figura 20: Función de Activación Reluactivation.

Fuente: Fei-Fei LI et al 2019

3.4.8. Entrenamiento de la RNAs tipo MLS

El método de entrenamiento utilizado en la RNA tipo MLS es el método de algoritmo de Backpropagation, es un método de aprendizaje supervisado. En la programación en Python se usa la función “K – Fold Validation”, dicha función realizara la evaluación de funcionalidad del modelo, mientras que el algoritmo backpropagation realizara la actualización de los pesos, y de este modo se llevara el entrenamiento respectivo.

El entrenamiento se realizará con datos de la semana pasada y de un día anterior para así poder obtener los datos de salida del día actual, el mismo que representará el modelo de predicción.

```
[ ] # K-Fold Validation : Iterar sobre el conjunto de entrenamiento el conjunto de validacion, la validacion ira cambiando
k = 4
num_val_samples = len(X_train) // k
num_epoch = 500
all_history = []

# 4 distintos entrenamientos con el set de validacion en una posicion distinta
for i in range(k):
    print("Fold " , i)
    # 0:1*271 ; 271:2*271 ; 2*271:3*271; .....
    val_data = X_train[i*num_val_samples: (i+1) * num_val_samples]
    val_targets = y_train[i*num_val_samples: (i+1) * num_val_samples]
    # El data set se divide en 4 partes para el entramiento utiliza los 4 y para la validacion solo 1
    partial_train_data = np.concatenate(
        [X_train[:i * num_val_samples],# 0; 1*271; ....
         X_train[(i+1) * num_val_samples:]], # 271;2*271;....
        axis= 0
    )

    partial_train_targets = np.concatenate(
        [y_train[:i * num_val_samples],
         y_train[(i+1) * num_val_samples:]],
        axis= 0
    )

    # modelo
    model = build_model_regression(96)
    history = model.fit(partial_train_data.astype('float32') , partial_train_targets.astype('float32') , epochs=num_epoch, batch_size =16,
                       validation_data = (val_data, val_targets),
                       verbose=0)
```

Figura 21: Modelo Función de Entrenamiento de la RNA tipo MLS.

Elaboración propia

El entrenamiento se realizará sobre la base de datos de demanda de energía pre procesada de los periodos 2018,2019,2020 y agosto 2021. La base de prueba de los entrenamientos serán los datos del enero a agosto del 2021 los cuales hacen un total de 11664, en el que se realizarán 4 iteraciones en 500 épocas.

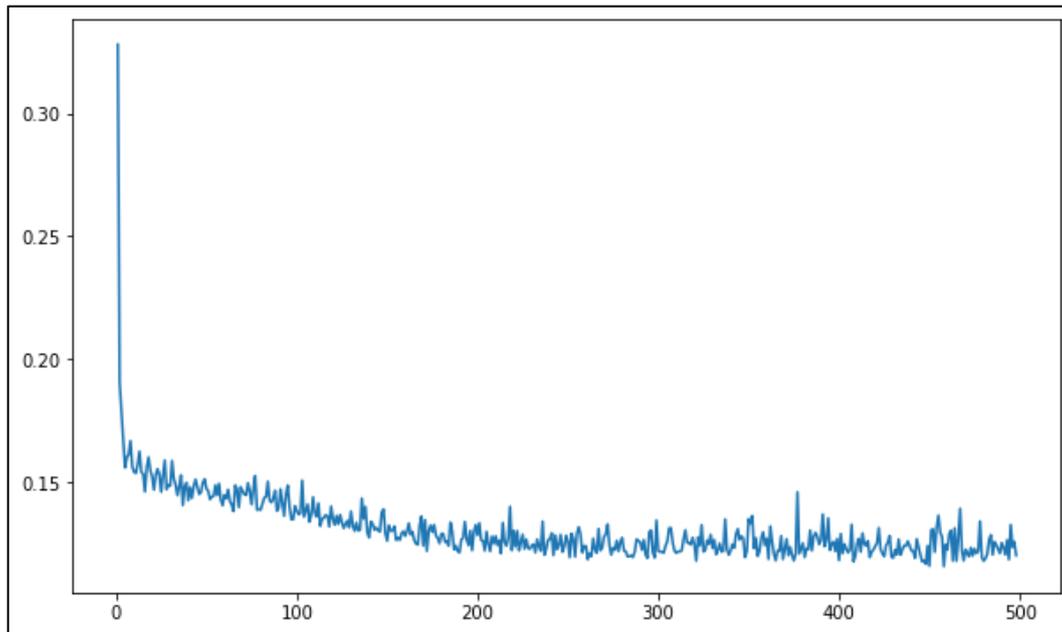


Figura 22: Proceso de aprendizaje la RNA tipo MLS.
Elaboración propia

De la figura N° 22 podemos concluir que el error de predicción tiende a descender con el transcurso de las épocas, se nota un notable descenso a partir de la época 100 y también apreciamos como va tomando estabilidad a partir de la época 400. Para concluir la simulación podemos afirmar que en la época 500 se tiene un entrenamiento óptimo del modelo.

3.4.9. Validación de las proyecciones

La validación de las proyecciones de la demanda de energía eléctrica realizadas por la RNA tipo MLS, será realizado mediante el indicador de error medio porcentual absoluto (MAPE) para cada día de pronóstico.

MAPE busca obtener una medida que muestre qué tan lejos está el valor predicho del valor real.



El MAPE está dado por:

$$MAPE = \frac{\sum_{i=1}^{48} \left[\left| \frac{x_i - y_i}{y_i} \right| \times 100 \% \right]}{48}$$

Donde:

x_i ; es el valor de la demanda de energía real (realizado)

y_i ; es el valor de la demanda de energía proyectado (pronosticados)

i ; 1,248; son los valores de intervalos del día en periodos temporales de cada 30 minutos.

CAPITULO IV

RESULTADOS Y DISCUSIÓN

En este capítulo se examinarán los diferentes resultados logrados del modelo de predicción de la demanda de energía eléctrica basado en redes neuronales del tipo perceptrón multicapa, así mismo se realizará una comparación con los resultados de los pronósticos realizados con métodos tradicionales, correspondientes a los periodos temporales 2018,2019,2020 y agosto del 2021.

4.1. RESULTADOS DE LAS PROYECCIONES DE LA RNA TIPO MLS

Realizado la carga de los datos a la capa de entrada, se procedió a realizar las proyecciones, del día actual suministrándole datos de la demanda de energía de la semana anterior, como se mencionó en ítem anteriores los valores de demanda presentan similitud entre días pasados y días anteriores.

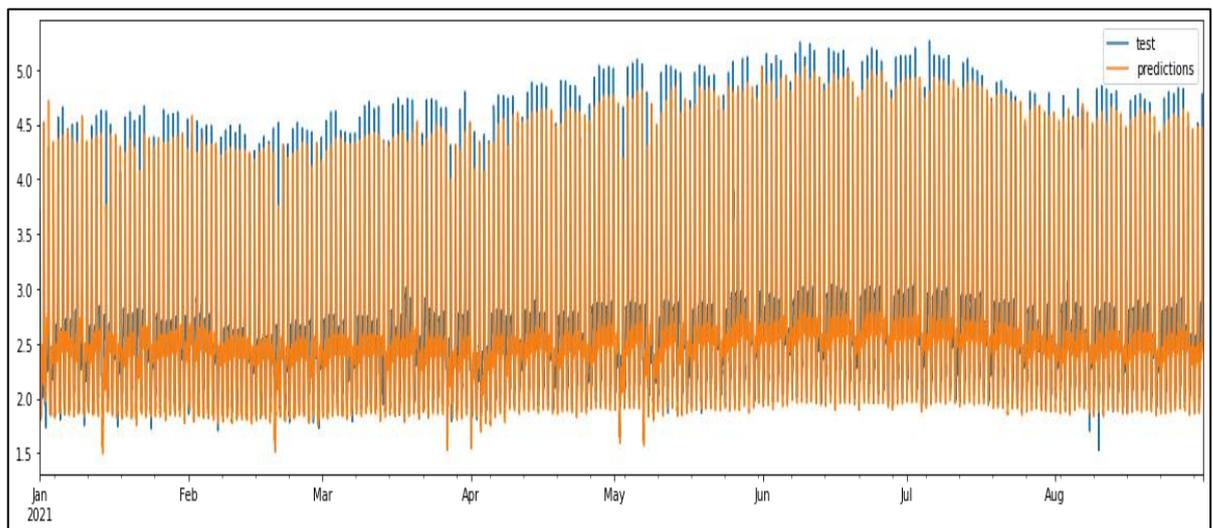


Figura 23: Predicción de la demanda en el año 2021.

Elaboración propia

En la figura N° 23 podemos apreciar que los valores de demanda de asemejan y siguen la trayectoria de los valores reales de demanda.

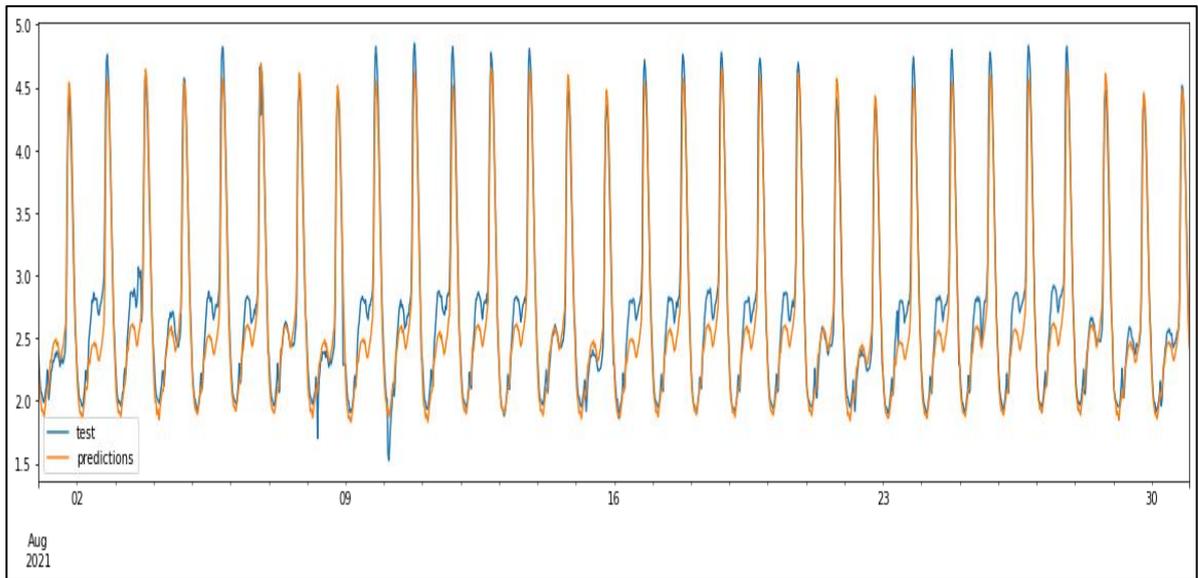


Figura 24: Predicción de la demanda mensual – agosto 2021.
Elaboración propia

En la figura N° 24 es más apreciable lo mencionado líneas arriba, se logra apreciar con más nitidez, como los valores de demanda proyectada con las RNA tipo MLS son capaces de seguir el comportamiento en el trayecto de la curva construida con valores de demanda reales.

Tabla 11: valores de MAPE diario

Día de la semana	MAPE diario
Lunes	5.94
Martes	4.85
Miércoles	5.00
Jueves	5.68
Viernes	5.90
Sábado	4.90
Domingo	4.71
Global	5.28

Elaboración propia

4.2. RESULTADOS DE LAS PROYECCIONES CON METODO ESTADISTICO

Para realizar la comparación de los valores del MAPE hallados con el método de RNA tipo MLS a la par, se realizó la proyección de la demanda de energía con un modelo tradicional estadístico en el software Eviews 10, en dicho software se trabajó con los mismos valores de demanda de energía los cuales son 48 valores de demanda por día, separados en parámetros de 30 minutos de dato a dato.

En el software se utilizó la herramienta de “Exponential smoothing” o suavizado exponencial, el cual es un método de pronóstico aplicado a las series temporales que siguen una tendencia, dentro de los suavizados exponenciales se utilizó el método de Holt-Winters – Aditivo, con un factor cíclico de 48 (48 valores de demanda diarios) en el rango temporal de 01/01/2018 00:00 – 31/12/2021 23:30, con valores de pesos aleatorios que van de 0 a 1.

La justificación para que el rango de la serie de la demanda sea 01/01/2018 00:00 – 12/31/2021 23:30 y no 01/01/2018 00:00 – 31/08/2021 23:30 es que los valores de demanda faltantes son los que serán pronosticados por el software cabe decir que los valores de 01/09/2021 00:00 al 31/12/2021 23:30 son los valores a pronosticar.

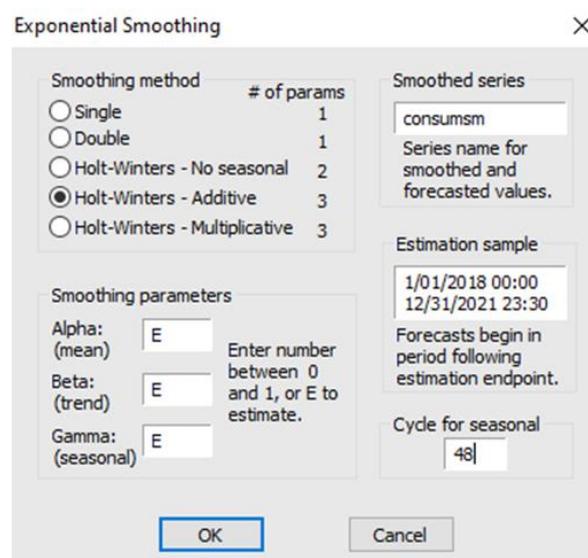


Figura 25: Predicción de la demanda con suavizado exponencial – Eviews 10
Elaboración propia

Una vez cargados los datos y simulados en el modelo de suavizado exponencial Holt-winters aditivo, podemos verificar que los pronósticos fueron realizados en el rango de 01/09/2021 00:00 al 31/12/2021 23:30.

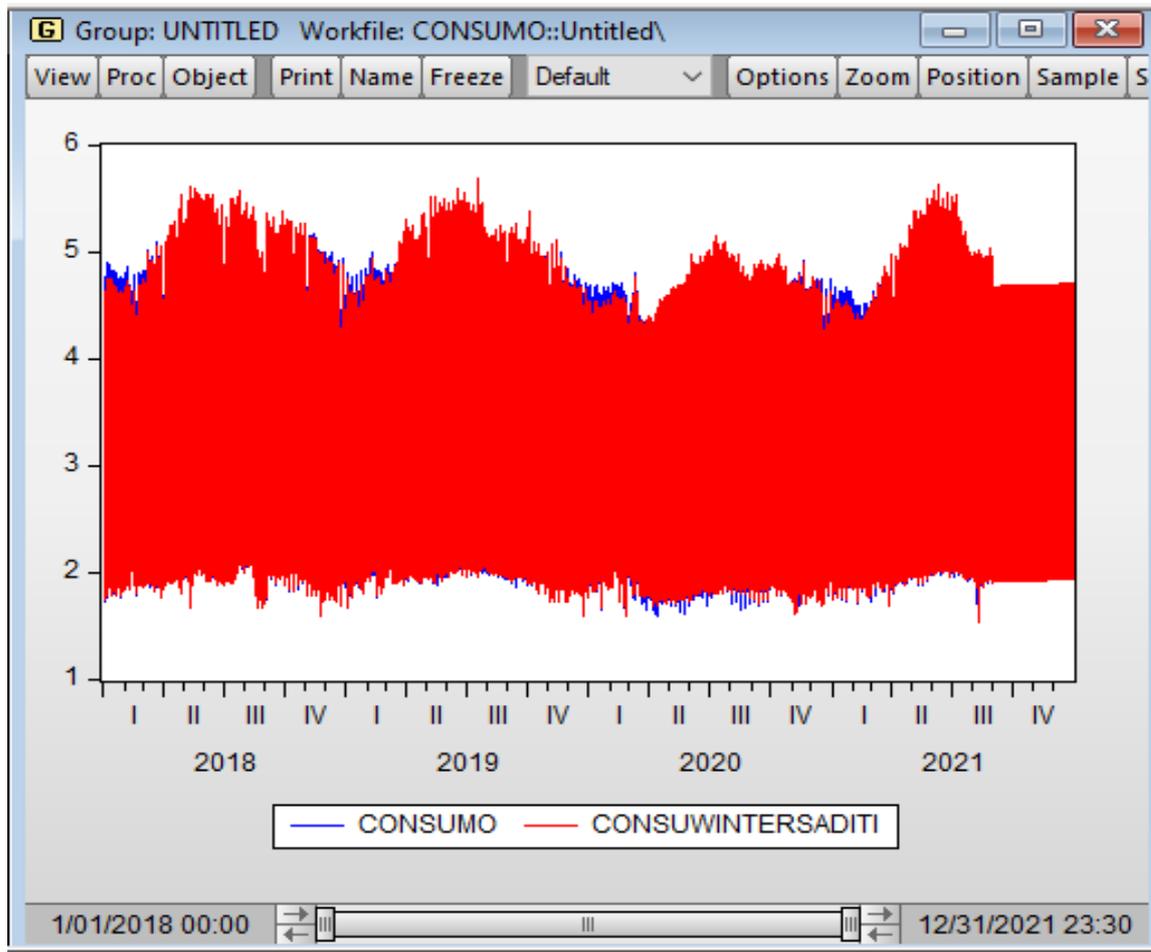


Figura 26: Proyección de la demanda de energía – eviews 10
Elaboración propia

Figura N° 26 podemos apreciar que los valores de demanda pronosticados tratan de seguir con gran dificultad la trayectoria de los valores de demanda reales. En la serie de temporal también podemos verificar que el software y el modelo tradicional no son tan robustos y eficientes a comparación del modelo RNA tipo MLS desarrollado en Python, obteniendo un valor MAPE global de 6.32.

4.3. COMPARACION DE RESULTADOS RNA TIPO MLS VS ESTADISTICO

Una vez obtenidos los resultados de los modelos anteriores se procede a comparar los resultados del MAPE con menor valor, el modelo de RNA tipo MLS con el modelo tradicional estadístico.

Tabla 12: Comparación del MAPE de RNA tipo MLS vs modelo estadístico

Día de la semana	MAPE RNA tipo MLS	MAPE modelo estadístico
Lunes	5.94 %	-
Martes	4.85 %	-
Miércoles	5.00 %	-
Jueves	5.68 %	-
Viernes	5.90 %	-
Sábado	4.90 %	-
Domingo	4.71 %	-
Global	5.28 %	6.32 %

Elaboración propia

De la tabla N° 12, podemos concluir que el modelo de RNA tipo MLS para el pronóstico de la demanda de energía eléctrica nos proporciona un MAPE menor que el modelo estadístico tradicional obteniendo una diferencia de 1.04%, además de mencionar que ambos modelos fueron trabajados con los mismos valores y en los mismos parámetros temporales.

4.4. DISCUSIÓN DE LOS RESULTADOS

De la conclusión sobre el modelo de predicción de demanda de energía basado en redes neuronales del tipo perceptrón multicapa, que reduce el error de predicción con un nivel de confianza de 94.8 %, a comparación de la metodología estadística tradicional que brinda un 93.7% de confianza. Realizar el tratamiento de datos atípicos y la valorización respectiva de los valores de entrada minimiza el MAPE, lo cual fue probado en ambos



modelos de proyección, de manera concordante Querol (2018), logro determinar, que su sistema de control que permite también que el sistema eléctrico, obtener un modelo similar que se ha creado una red neuronal artificial que utiliza un proceso de retroalimentación en la etapa de entrenamiento, ha sido placentero con la predicción de todos los productos eléctricos evaluados salvo con el futuro a un mes.



V. CONCLUSIONES

PRIMERO. Se logró disminuir el porcentaje de error de predicción de la demanda de energía eléctrica mediante el modelo de RNA del tipo MLS, con un nivel de confianza de 94.8 %.

SEGUNDO. Se logró determinar la importancia del pre procesamiento de datos, así como de la valorización de las variables de entrada para cada método desarrollado.

TERCERO. Es posible afirmar que, para lograr pronósticos más certeros y con bajos niveles de error en la predicción se requiere una gran cantidad de datos, así como del tratamiento y procesamiento de los mismos.



VI. RECOMENDACIONES

PRIMERO. Se recomienda realizar más estudios y simulaciones con las distintas topologías de las redes neuronales artificiales, para así poder demostrar cuál de estas topologías es más eficiente para este tipo de trabajos.

SEGUNDO. Para mejorar la comprensión del comportamiento de la demanda de energía eléctrica en la predicción se recomienda incrementar mayor cantidad de variables tales como los ingresos per cápita, inflación, PBI y otros, al modelo de redes neuronales perceptrón multicapa.

TERCERO. Para pretender reducir el error en la predicción se recomienda evaluar si las técnicas de suavizado estadístico colaborarían en la disminución de error en los pronósticos.



VII. REFERENCIAS BIBLIOGRÁFICAS

- Acevedo Rueda Ruben & Pimentel Jose A. (1995). Modelo econométrico para el pronóstico de demanda eléctrica máxima diaria (tesis de posgrado). Universidad centro Occidental Lisandro Alvarado. Barquisimeto.
- Bertona Luis Federico (2005). Entrenamientos de redes neuronales basados en algoritmos evolutivos (tesis de grado). Universidad de buenos aires.
- Cervantes Liñan Luis, Perez Baca Grinaldo, Caro Anchay Augusto, Vela Zavala Saul, Alzamora Noreña Freddy. (2016). Fundamentos de microeconomía (libro). Universidad inca Garcilaso de la vega, 1ra edición, lima.
- Cuadrado Moltalvo Ronny Ronald & Ramos Valdez Judith Carolina (2010). Implementación de una red neuronal para mejorar el pronóstico de demanda de energía para la empresa Bluestar Energy Services. (Tesis de pregrado). Universidad mayor de santos marcos, lima.
- Da Silva, W.L. (1996). Previsão de carga de pico de demanda usando rede neural artificial (tesis de posgrado). Universidad estatal de campinas.
- Fei-Fei Li ; Justin Johnson ; Serena Yeung (2005). Training neural networks part I (lectura).
- Fernández Quiñones Ever Ronald (2014). Se aplica al sistema interconectado nacional el pronóstico de demanda de energía a corto plazo basado en redes neuronales artificiales. (tesis de grado magister). Universidad nacional de ingeniería, lima.
- Flores López Raquel & Fernandez Fernandez Jose Miguel (2008). Las redes neuronales (libro). NETBIBLO s.l., España.
- Fritsch Jurgen (1996). Modular Neural Networks (Tesis de pogrado) for speech recognition. Karlsruhe University. Pittsburgh.



- Gomes, R. Bernardon, D. Garcia V. (2000). Metodologías para previsao de carga em curtissimo prazo considerando variaveis climatical (tesis de posgrado). Universidad de federal de pampa, bage.
- Gonzalez Garcia Jorge Yasmanis (2015). Pronóstico de demanda a través de redes neuronales artificiales de perceptrón multicapa (tesis de grado). Universidad de Holguin, holguin.
- Grimaldo Guerrero John William (2012). Modelo de Pronóstico de Regresión Múltiple para la Demanda Eléctrica en Colombia (tesis de posgrado). Universidad del norte. barranquilla.
- Hilera Gonzales Jose Ramon & Martinez Hernando Victor Jose (1995). Red neuronal artificial fundamento, modelo y aplicación (libro). RA-MA editorial, 1ra edicion. madrid.
- Krajewski Lee - J. Ritman & Larry P. (2000). Administración de operaciones estrategia y análisis (libro). Ed Pearson education, boston.
- Lozada Cabrera, C. H., Acosta Apolo, N. P., Paredes Moran, D. V., & Vique Salazar, G. I. (2022). Predicción de demanda eléctrica utilizando redes neuronales artificiales para un sistema de distribución de energía eléctrica. Ciencia Latina Revista Científica Multidisciplinar, 6(3), 3871-3894. https://doi.org/10.37811/cl_rcm.v6i3.2502
- Nojek, S. ; Britos, P. ; Rossi, b. y Garcia Martinez R. (1997). Previsión de ventas: una comparación de métodos estadísticos y de previsión basados en redes neuronales Buenos aires.
- Querol Herrá Javier (2018), Desarrollo de un modelo de predicción del precio de la energía eléctrica para el mercado a plazo mediante redes neuronales, Tesis de maestría, Escuela Técnica Superior de Ingeniería Industrial, Universidad



Politécnica de Madrid,

<https://ciencialatina.org/index.php/cienciala/article/view/2502>.

R.M. N° 2014-2011-MEM/DM. (29 de 04 de 2011). Código Nacional de Electricidad.

Lima, Perú: Diario Oficial El Peruano.

Salazar Aguilar Maria Angelica & Cabrera Ríos Mauricio (2007). Pronósticos de demandas por medio de redes neuronales artificiales (tesis de posgrado).

Universidad autónoma de nuevo leon, monterrey.

Simpson J. (2017). Oxford english dictionary 3ra ed.: Oxford univerity press. oxford

Steinherz Hipper, H. Pedreira, C.E. Castro Souza, r. (2001). Neural Networks for Short-

Term Load Forecasting: A Review and Evaluation (artículo científico). IEEE

Transactions on Energy Systems, Vol. 16.

Villada Fernando, Cadavid Diego Raul, Molina Juan David (2016). Pronostico del precio de la energía eléctrica usando redes neuronales artificiales (Tesis de pregrado). Universidad de Antioquia, Medellín.

Figura N° 1.2: Programación de la RNA tipo MLS en Python

Importando librerías

```
In [1]: import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import xlrd #Leer archivos excel
import datetime

from sklearn.impute import SimpleImputer

import keras
from keras.models import Sequential
from keras.layers import Dense # crea capas e inicializa pesos con pequeños
from keras import models, layers, optimizers
from sklearn.model_selection import train_test_split
```

Data Set

```
In [2]: dataset = pd.read_excel('./puno_60kv_pre_proc.xlsx', index_col=0, parse_dates=True)
dataset.shape
```

Out[2]: (128544, 1)

```
In [3]: dataset=dataset[0:-1:2]
dataset.shape
```

Out[3]: (64272, 1)

```
In [4]: dataset.head()
```

Out[4]:

	consumo
FECHA	
2018-01-01 00:00:00	3.806495
2018-01-01 00:30:00	3.757220
2018-01-01 01:00:00	3.457277
2018-01-01 01:30:00	2.972107
2018-01-01 02:00:00	2.619474

Estructura de los datos de entrada

```
In [5]: # Frame 2
# copia de df_1
df_2= dataset.copy()

# Separar día y hora
df_2['fecha'] = df_2.index.normalize()
df_2['hora'] = df_2.index.time.astype(str)
df_2['dia']=df_2.index.day_name()

df_2.head()
```

Out[5]:

	consumo	fecha	hora	dia
	FECHA			
2018-01-01 00:00:00	3.806495	2018-01-01	00:00:00	Monday
2018-01-01 00:30:00	3.757220	2018-01-01	00:30:00	Monday
2018-01-01 01:00:00	3.457277	2018-01-01	01:00:00	Monday
2018-01-01 01:30:00	2.972107	2018-01-01	01:30:00	Monday
2018-01-01 02:00:00	2.619474	2018-01-01	02:00:00	Monday

```
In [6]: #Transformando del Dataframe
df_pivot= df_2.pivot(index=['fecha','dia'], columns='hora', values='consumo')
#copia
df_semanaPasada= df_pivot.copy()
# Eliminar datos
df_semanaPasada = df_semanaPasada.drop(["2021-08-25", "2021-08-26", "2021-08-27", "2021-08-28", "2021-08-29", "2021-08-30", "2021-08-31", "2021-08-24"])
df_semanaPasada.head()
```

Out[6]:

	hora	00:00:00	00:30:00	01:00:00	01:30:00	02:00:00	02:30:00	03:00:00	03:30:00	04:00:00	04:30:00	...	19:00:00	19:30:00	20:00:00	20:30:00	21:00:00	2'
fecha	dia																	
2018-01-01	Monday	3.806495	3.757220	3.457277	2.972107	2.619474	2.420526	2.265926	2.167135	2.120294	2.141302	...	3.882836	4.092023	4.074759	3.941521	3.742466	3.
2018-01-02	Tuesday	2.311954	2.142135	2.037293	1.971618	1.966999	1.901741	1.893686	1.910216	1.918776	1.936571	...	4.489323	4.638003	4.631736	4.405867	4.161745	3.
2018-01-03	Wednesday	2.308899	2.161110	2.073152	1.975605	1.963590	1.902332	1.884832	1.897034	1.954657	1.994692	...	4.534983	4.768905	4.720042	4.491115	4.218134	3.
2018-01-04	Thursday	2.339694	2.151907	2.038640	1.974856	1.896870	1.891731	1.888588	1.848422	1.912317	1.963574	...	4.625531	4.888726	4.903282	4.674095	4.424584	4.
2018-01-05	Friday	2.376024	2.197770	2.055888	1.990392	1.967032	1.902162	1.893244	1.911412	1.961349	2.033576	...	4.669488	4.838292	4.779548	4.537767	4.305984	3.

```
In [7]: #df de Los días anteriores al pronostico
df_diaAPronosticar= df_pivot.copy()
# df a pronosticar
df_semanaActual = df_pivot.copy()
```

```
In [8]: df_semanaActual = df_semanaActual.drop(["2018-01-01", "2018-01-02", "2018-01-03", "2018-01-04", "2018-01-05", "2018-01-06", "2018-01-07", "2021-08-31"])
df_semanaActual.head()
```

Out[8]:

	hora	00:00:00	00:30:00	01:00:00	01:30:00	02:00:00	02:30:00	03:00:00	03:30:00	04:00:00	04:30:00	...	19:00:00	19:30:00	20:00:00	20:30:00	21:00:00	2'
fecha	dia																	
2018-01-08	Monday	2.255422	2.118422	2.013014	1.916983	1.915596	1.919337	1.870714	1.890034	1.904158	2.000270	...	4.570029	4.752322	4.590838	4.453324	4.194480	3.
2018-01-09	Tuesday	2.331807	2.171008	2.036886	1.966961	1.940963	1.889964	1.873399	1.914909	1.900971	1.967280	...	4.665177	4.796478	4.746421	4.488145	4.164240	3.
2018-01-10	Wednesday	2.311075	2.138633	2.031769	2.008956	1.949631	1.964212	1.917286	1.947335	1.952080	2.009601	...	4.638885	4.880087	4.810955	4.593394	4.299870	3.
2018-01-11	Thursday	2.384005	2.205027	2.097458	1.994480	1.983286	1.915694	1.901747	1.946695	1.960999	2.000147	...	4.750297	4.821373	4.682732	4.430076	4.124015	3.
2018-01-12	Friday	2.339800	2.173865	2.046821	1.963579	1.952152	1.927200	1.911393	1.916468	1.972693	1.997147	...	4.736800	4.803333	4.658659	4.438990	4.100753	3.

5 rows × 48 columns

```
In [9]: df_diaAPronosticar = df_diaAPronosticar.drop(["2018-01-01", "2018-01-02", "2018-01-03", "2018-01-04", "2018-01-05", "2018-01-06", "2018-01-07", "2018-01-08"])
df_diaAPronosticar.head()
```

Out[9]:

	hora	00:00:00	00:30:00	01:00:00	01:30:00	02:00:00	02:30:00	03:00:00	03:30:00	04:00:00	04:30:00	...	19:00:00	19:30:00	20:00:00	20:30:00	21:00:00	2'
fecha	dia																	
2018-01-09	Tuesday	2.331807	2.171008	2.036886	1.966961	1.940963	1.889964	1.873399	1.914909	1.900971	1.967280	...	4.665177	4.796478	4.746421	4.488145	4.164240	3.
2018-01-10	Wednesday	2.311075	2.138633	2.031769	2.008956	1.949631	1.964212	1.917286	1.947335	1.952080	2.009601	...	4.638885	4.880087	4.810955	4.593394	4.299870	3.
2018-01-11	Thursday	2.384005	2.205027	2.097458	1.994480	1.983286	1.915694	1.901747	1.946695	1.960999	2.000147	...	4.750297	4.821373	4.682732	4.430076	4.124015	3.
2018-01-12	Friday	2.339800	2.173865	2.046821	1.963579	1.952152	1.927200	1.911393	1.916468	1.972693	1.997147	...	4.736800	4.803333	4.658659	4.438990	4.100753	3.
2018-01-13	Saturday	2.324390	2.183835	2.065366	1.989065	1.979599	1.915899	1.895047	1.910258	1.927004	1.968931	...	4.367794	4.562541	4.477814	4.299726	3.990014	3.

5 rows × 48 columns

```
In [10]: # Dimensiones
df_semanaActual.values.shape, df_semanaPasada.values.shape
```

```
Out[10]: ((1331, 48), (1331, 48))
```

```
In [11]: # Concatenar array df_semanaActual con df_semanaPasada
X = np.concatenate((df_semanaActual,df_semanaPasada),axis=1 )
y = df_diaAPronosticar.values
X.shape, y.shape
```

```
Out[11]: ((1331, 96), (1331, 48))
```

```
In [12]: # Dividir el conjunto en entrenamiento y prueba
X_train = X[0:1087,:]
y_train = y[0:1087,:]

X_test = X[1088:,:]
y_test = y[1088:,:]

X_train.shape, y_train.shape, X_test.shape, y_test.shape
```

```
Out[12]: ((1087, 96), (1087, 48), (243, 96), (243, 48))
```

Red Neuronal

```
In [13]: # Construir el modelo
def build_model_regression(input_data):
    model = models.Sequential()
    model.add(layers.Dense(10,activation='relu',input_shape=(input_data,)))
    model.add(layers.Dense(10,activation='relu'))
    model.add(layers.Dense(48))
    model.compile(optimizer='rmsprop', loss='mse',metrics=['mae'])

    return model
```

```
In [14]: # K-Fold Validation : Iterar sobre el conjunto de entrenamiento el conjunto de validacion, La validacion ira cambiando
k = 4
num_val_samples = len(X_train) // k
num_epoch = 500
all_history = []
```

```
In [15]: # 4 distintos entrenamientos con el set de validacion en una posicion distinta
for i in range(k):
    print("Fold ", i)
    # 0:1*271 ; 271:2*271 ; 2*271:3*271; .....
    val_data = X_train[i*num_val_samples: (i+1) * num_val_samples]
    val_targets = y_train[i*num_val_samples: (i+1) * num_val_samples]
    # El data set se divide en 4 partes para el entramiento utiliza las 4 y para la validacion solo 1
    partial_train_data = np.concatenate(
        [X_train[:i * num_val_samples],# 0; 1*271; ....
        X_train[(i+1) * num_val_samples:]], # 271;2*271;....
        axis= 0
    )

    partial_train_targets = np.concatenate(
        [y_train[:i * num_val_samples],
        y_train[(i+1) * num_val_samples:]],
        axis= 0
    )
    # modelo
    model = build_model_regression(96)
    history = model.fit(partial_train_data.astype('float32') , partial_train_targets.astype('float32') , epochs=num_epoch, batch_size =16,
        validation_data = (val_data, val_targets),
        verbose=0)

    all_history.append(history.history['val_mae'])
```

```
Fold 0
Fold 1
Fold 2
Fold 3
```

```
In [16]: # Resultado de las 4 iteraciones en las 500 epocas
pd.DataFrame(all_history)
```

```
Out[16]:
```

	0	1	2	3	4	5	6	7	8	9	...	490	491	492	493	494	495	496
0	1.813083	0.892428	0.285868	0.161307	0.191811	0.185540	0.156452	0.160151	0.173783	0.175613	...	0.125553	0.120908	0.120522	0.121008	0.154127	0.119258	0.126095
1	1.914591	1.068727	0.522009	0.263934	0.189247	0.151555	0.166388	0.146523	0.144576	0.144759	...	0.119088	0.131379	0.120468	0.122369	0.121094	0.121204	0.124031
2	1.645944	0.763140	0.356099	0.180883	0.155738	0.159201	0.170619	0.167492	0.174429	0.160592	...	0.117911	0.117266	0.123616	0.121608	0.119611	0.117243	0.122610
3	1.445354	0.568108	0.148002	0.156052	0.177182	0.172413	0.129815	0.165540	0.152288	0.185855	...	0.121297	0.131350	0.128486	0.116582	0.110725	0.116068	0.157478

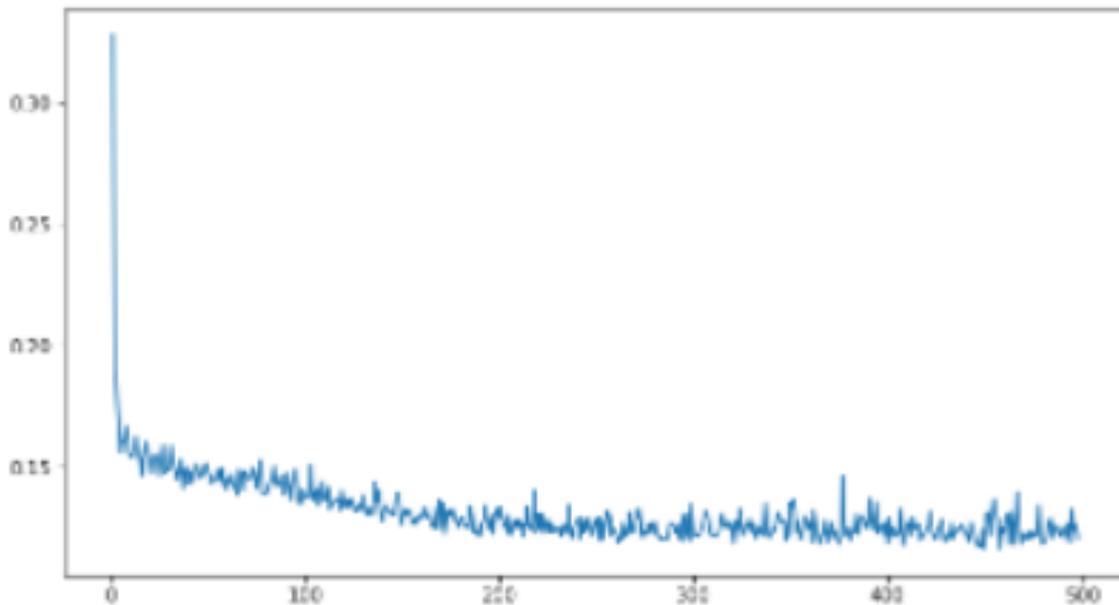
4 rows × 500 columns

```
In [17]: # promedio del error absoluto medio
all_mae_avg = pd.DataFrame(all_history).mean(axis=0)
all_mae_avg
```

```
Out[17]: 0      1.784743
1      0.823101
2      0.327994
3      0.190544
4      0.178494
...
495    0.118443
496    0.132554
497    0.123465
498    0.125668
499    0.120135
Length: 500, dtype: float64
```

```
In [18]: # Grafica epocas vs mean absolute error
import matplotlib.pyplot as plt

fig = plt.figure(figsize=(10,6))
plt.plot(range(1,len(all_mae_avg[2:])+1), all_mae_avg[2:])
plt.show()
```



```
In [19]: #model.evaluate(test_data, test_targets)
model.evaluate(X_train, y_train) #desviacion de 0.11
```

```
34/34 [=====] - 0s 2ms/step - loss: 0.0248 - mae: 0.1165
Out[19]: [0.024776721373200417, 0.1164923757314682]
```

```
In [21]: #Predicciones
def predict(X_test,y_test,model):
    predictions = []
    for i in range(len(X_test)):
        predictions.append(model.predict(X_test[i:i+1]))
    return predictions
```

```
In [22]: #array de fechas de test
date = np.array([dataset["2021"].index])
date=date.reshape(date.shape[1])
def newData(predict,test):
    #reshape predictions y test
    predict = predict.reshape(243*48,1)
    test = test.reshape(243*48,1)

    # matriz de tests y predictions_two
    data = np.concatenate((test,predict),axis=1)

    # dataframe con test y predictions
    df = pd.DataFrame(data=data, index=date,columns=["test","predictions"])

    return df
```

/usr/local/lib/python3.7/dist-packages/ipykernel_launcher.py:2: FutureWarning: Indexing a DataFrame with a datetimelike index using a single string to slice the rows, like 'frame[string]', is deprecated and will be removed in a future version. Use 'frame.loc[string]' instead.

```
In [23]: #mape
def mape(test,predict):
    #reshape test
    #test = test.reshape(test.shape[0],test.shape[1]*test.shape[2] )
    #mape
    mape = np.mean(np.abs((test-predict)/test))*100
    return mape
```

```
In [24]: # calculo del MAPE por días
def mapePerDays(df,MAPE_GLOBAL):
    # agregar días al df
    df["day"] = df.index.day_name()
    #df por días
    df_monday = df[df["day"] == "Monday"]
    df_tuesday = df[df["day"] == "Tuesday"]
    df_wednesday = df[df["day"] == "Wednesday"]
    df_thursday = df[df["day"]=="Thursday"]
    df_friday = df[df["day"] == "Friday"]
    df_saturday = df[df["day"] == "Saturday"]
    df_sunday = df[df["day"] == "Sunday"]

    #calculo del mape por días
    monday_mape = mape(df_monday["test"].values,df_monday["predictions"].values)
    tuesday_mape = mape(df_tuesday["test"].values,df_tuesday["predictions"].values)
    wednesday_mape = mape(df_wednesday["test"].values,df_wednesday["predictions"].values)
    thursday_mape = mape(df_thursday["test"].values,df_thursday["predictions"].values)
    friday_mape = mape(df_friday["test"].values,df_friday["predictions"].values)
    saturday_mape = mape(df_saturday["test"].values,df_saturday["predictions"].values)
    sunday_mape = mape(df_sunday["test"].values,df_sunday["predictions"].values)

    return [monday_mape, tuesday_mape,wednesday_mape,thursday_mape,friday_mape,saturday_mape,sunday_mape,MAPE_GLOBAL]
```

```
In [25]: #Predicciones desde enero hasta agosto del 2021
predictions = predict(X_test, y_test,model)
```

```
In [26]: df_resultados = newData(np.array(predictions),y_test)
```

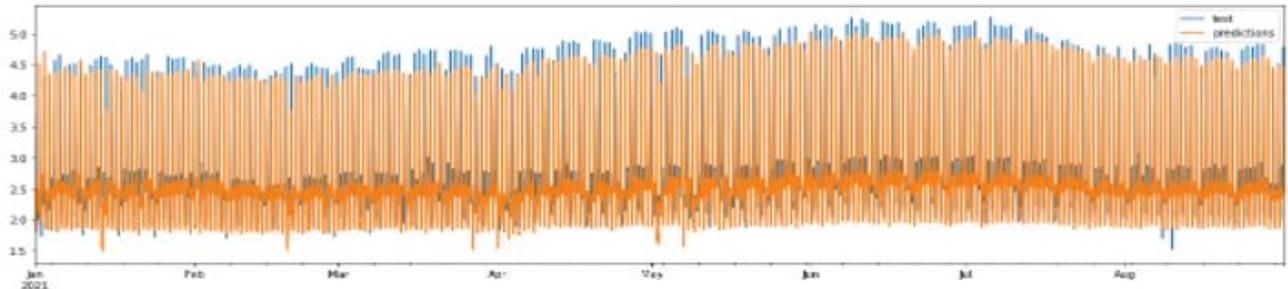
```
In [27]: #dataframe de test vs predicciones
df_resultados.head()
```

```
Out[27]:
```

	test	predictions
2021-01-01 00:00:00	3.730907	2.665803
2021-01-01 00:30:00	3.679624	2.488494
2021-01-01 01:00:00	3.336446	2.345039
2021-01-01 01:30:00	2.985824	2.265343
2021-01-01 02:00:00	2.712038	2.145049

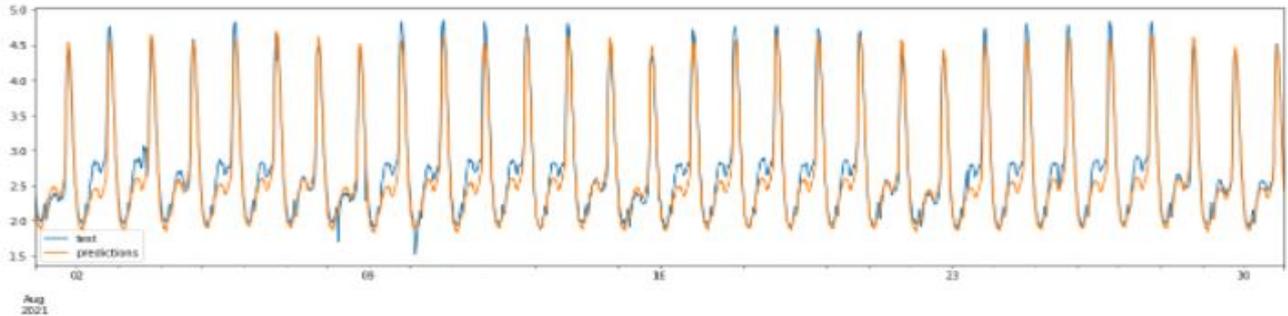
```
In [32]: #Resultado de Las predicciones
df_resultados.plot(figsize=(20,5))
```

```
Out[32]: <matplotlib.axes._subplots.AxesSubplot at 0x7f1a915d6490>
```



```
In [33]: #Predicciones para una mes
df_resultados.loc["2021-08-01":"2021-08-30"].plot(figsize=(20,5))
```

```
Out[33]: <matplotlib.axes._subplots.AxesSubplot at 0x7f1a90ee2490>
```



MAPE

Cálculo del mape general

```
In [29]: mapeGeneral = mape(df_resultados["test"].values, df_resultados["predictions"].values)
print(f'{mapeGeneral.round(2)} %')
```

5.28 %

```
In [30]: dias = ["Lunes", "Martes", "Miercoles", "Jueves", "Viernes", "Sabado", "Domingo", "Global"]
```

```
In [31]: #calcula el MAPE por días
listMape = mapePerDays(df_resultados, mapeGeneral)
#df
df_mape = pd.DataFrame(data=listMape, columns=["MAPE"], index=dias)
df_mape.round(2)
```

```
Out[31]:
```

	MAPE
Lunes	5.94
Martes	4.85
Miercoles	5.00
Jueves	5.68
Viernes	5.90
Sabado	4.90
Domingo	4.71
Global	5.28

Guardar el Modelo

```
In [37]: model.save('./models/RNA.h5')
```