

**COMPARATIVA DEL MODELO AUTORREGRESIVO Y MEDIA MÓVIL
PARA EL PRONÓSTICO DE LA DEMANDA ELÉCTRICA DEL ECUADOR
CONSIDERANDO EL CRITERIO AKAIKE**

**UNIVERSIDAD POLITÉCNICA SALESIANA
SEDE QUITO**

**CARRERA:
INGENIERÍA ELÉCTRICA**

**Trabajo de titulación previo a la obtención del título de
INGENIERO ELÉCTRICO**

**TEMA:
COMPARATIVA DEL MODELO AUTORREGRESIVO Y MEDIA MÓVIL
PARA EL PRÓNOSTICO DE LA DEMANDA ELÉCTRICA DEL ECUADOR
CONSIDERANDO EL CRITERIO AKAIKE**

**AUTOR:
STALIN XAVIER LLAMUCA GUALOTO**

**DIRECTOR:
MANUEL DARIO JARAMILLO MONGE**

Quito, mayo 2021

Stalin Xavier Llamuca Gualoto

**COMPARATIVA DEL MODELO AUTORREGRESIVO Y MEDIA MÓVIL
PARA EL PRÓNOSTICO DE LA DEMANDA ELÉCTRICA DEL ECUADOR
CONSIDERANDO EL CRITERIO DE AKAIKE**

Universidad Politécnica Salesiana, Quito – Ecuador 2021
Ingeniería Eléctrica

Breve reseña histórica e información de contacto.



Stalin Xavier Llamuca Gualoto (Y'1996-M'03). Realizó sus estudios secundarios en la Unidad Educativa Municipal “Eugenio Espejo”, se graduó de bachiller en la especialidad de “Físico Matemático”. Egresado de la carrera de Ingeniería Eléctrica de la Universidad Politécnica Salesiana. Su trabajo se fundamenta en la comparativa del modelo autorregresivo y media móvil para el pronóstico de la demanda eléctrica del Ecuador considerando el criterio de Akaike.

sllamuca@est.ups.edu.ec

Dirigido por:



Manuel Dario Jaramillo Monge (Y'1990). Realizó sus estudios superiores en la Universidad de las Fuerzas Armadas ESPE de Quito, donde se graduó de Ingeniero Electrónico en Automatización y Control en el 2014. Además, cursó estudios de posgrado en la Universidad de Newcastle, Reino Unido, donde obtuvo el título en Máster en Electrical Power. Actualmente es profesor ocasional a tiempo completo de la Universidad Politécnica Salesiana.

mjaramillo@ups.edu.ec

Todos los derechos reservados:

Queda prohibida, salvo excepción prevista en la ley, cualquier forma de reproducción, distribución, comunicación pública y transformación de esta obra para fines comerciales, sin contar con la autorización de los titulares de propiedad intelectual. La infracción de los derechos mencionados puede ser constitutiva de delito contra la propiedad intelectual. Se permite la libre difusión de este texto con fines académicos o investigativos por cualquier medio, con la debida notificación a los autores.

DERECHOS RESERVADOS

©2021 Universidad Politécnica Salesiana
QUITO - ECUADOR

DECLARATORIA DE COAUTORÍA DEL DOCENTE TUTOR

Yo, Manuel Dario Jaramillo Monge declaro que bajo mi dirección y asesoría fue desarrollado el trabajo de titulación *COMPARATIVA DEL MODELO AUTORREGRESIVO Y MEDIA MÓVIL PARA EL PRÓNOSTICO DE LA DEMANDA ELÉCTRICA DEL ECUADOR CONSIDERANDO EL CRITERIO AKAIKE* realizado por Stalin Xavier Llamuca Gualoto, obteniendo un producto que cumple con todos los requisitos estipulados por la Universidad Politécnica Salesiana para ser considerado como trabajo final de titulación.

Quito D.M., mayo de 2021



.....
Manuel Dario Jaramillo Monge

C.C.: 1714298005

CESIÓN DE DERECHOS DE AUTOR

Yo, Stalin Xavier Llamuca Gualoto, con documento de identificación N° 1722508643, manifiesto mi voluntad y cedo a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que soy autor del trabajo de grado/titulación intitulado: *COMPARATIVA DEL MODELO AUTORREGRESIVO Y MEDIA MÓVIL PARA EL PRÓNOSTICO DE LA DEMANDA ELÉCTRICA DEL ECUADOR CONSIDERANDO EL CRITERIO AKAIKE*, mismo que ha sido desarrollado para optar por el título de: Ingeniero Eléctrico, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En aplicación a lo determinado en la Ley de Propiedad Intelectual, en mi condición de autor me reservo los derechos morales de la obra antes citada. En concordancia, suscribo este documento en el momento que hago entrega del trabajo final en formato digital a la Biblioteca de la Universidad Politécnica Salesiana.



.....
Stalin Xavier Llamuca Gualoto

C.C.: 1722508643

Quito, D.M., mayo de 2021

ÍNDICE GENERAL

Resumen.....	1
Abstract	1
1 Introducción	2
2 Marco teórico.....	3
2.1 Demanda eléctrica.....	3
2.1.1 Consumo de energía eléctrica.....	3
2.1.2 Carga eléctrica de un sistema	3
2.2 Autocorrelación	3
2.2.1 Función de Autocorrelación (ACF)	4
2.2.2 Función de Autocorrelación Parcial (PACF)	4
2.3 Modelo autorregresivo (AR).....	4
2.4 Modelo media móvil (MA).....	4
2.5 Modelo autorregresivo integral de media móvil (ARIMA)	4
2.6 Seasonal ARIMA (SARIMA)	5
2.6.1 Operador de Retroceso (B).....	5
2.6.2 Método Box Jenkins	6
2.7 Criterios de Evaluación de modelos de predicción	6
2.7.1 Criterio Akaike (AIC)	6
2.7.2 Suma de cuadrados del error (SSE)	7
2.7.3 Criterio del p-value	7
2.8 Forecast	7
3 Planteamiento del Problema.....	7
3.1 Demanda eléctrica del Ecuador	7
3.2 La Agencia de Regulación y Control de Electricidad (ARCONEL).....	8
3.3 Formulación del problema.....	9
3.3.1 Caso de estudio 1: Demanda eléctrica máxima anual	9
3.3.2 Caso de estudio 2: Demanda eléctrica máxima mensual.....	11
4 Análisis de resultados	12
4.1 Caso 1	12
4.2 Caso 2	13
Conclusiones.....	15
Trabajos futuros.....	15
Referencias	15

4.3	Matriz de Estado del Arte	19
4.4	Resumen de Indicadores	23

ÍNDICE DE FIGURAS

Figura 1. Demanda eléctrica máxima anual del Ecuador con datos históricos desde el año 1990 al 2019.	8
Figura 2. Demanda eléctrica máxima mensual del Ecuador desde el año 2007 al 2019.....	8
Figura 3. Serie diferenciada de la demanda máxima anual.....	9
Figura 4. ACF de la serie diferenciada de la Figura 3.....	9
Figura 5. PACF de la serie diferenciada de la Figura 3.	10
Figura 6. Gráfica normal Q Q de residuos estándar anual.....	10
Figura 7. Pronóstico de demanda máxima anual de los 5 futuros años.	10
Figura 8. Serie diferenciada de la demanda máxima mensual.....	11
Figura 9. ACF de la serie diferenciada de la Figura 8.....	11
Figura 10. PACF de la serie diferenciada de la Figura 8.	12
Figura 11. Gráfica normal Q Q de residuos estándar mensual.	12
Figura 12. Predicción para 24 meses futuros.....	12
Figura 13. Comparativa de demanda máxima anual en R.	13
Figura 14. Comparativa de demanda máxima anual en Matlab.	13
Figura 15. Comparativa de demanda máxima mensual en R.....	13
Figura 16. Comparativa de demanda máxima mensual en Matlab.	14
Figura 17. Resumen e indicador de la temática - Estado del arte	23
Figura 18. Indicador de formulación del problema - Estado del arte	24
Figura 19. Indicador de solución - Estado del arte	24

ÍNDICE DE TABLAS

Tabla 1. Datos históricos de la demanda máxima anual del Ecuador desde el año 1990 al 2019.	9
Tabla 2. Modelos SARIMA anuales, con sus respectivos criterios de evaluación.	10
Tabla 3. Resultado de la Predicción de demanda para los 5 futuros años.	11
Tabla 4. Datos históricos de la demanda máxima mensual del Ecuador desde el año 2007 al 2019.....	11
Tabla 5. Modelos SARIMA con datos mensuales.....	12
Tabla 6. Resultado de la Predicción de demanda mensual para los 2 años futuros.	12
Tabla 7. Error de los valores reales con los valores estimados en R.....	13
Tabla 8. Error de los valores reales con los valores estimados en Matlab.....	13
Tabla 9. Error de los valores reales con los valores estimados en R.....	14
Tabla 10. Error de los valores reales con los valores estimados en Matlab.	14
Tabla 11. Matriz de estado del arte.....	19

COMPARATIVA DEL MODELO AUTORREGRESIVO Y MEDIA MÓVIL PARA EL PRONÓSTICO DE LA DEMANDA ELÉCTRICA DEL ECUADOR CONSIDERANDO EL CRITERIO AKAIKE

Resumen

El objetivo de la previsión de cargas eléctricas se centra en predecir de manera satisfactoria y precisa la demanda que podría aumentar o disminuir en el futuro. Una gran cantidad de aplicaciones de ingeniería cuentan con modelos de predicción precisos y confiables para la demanda eléctrica. Una previsión precisa de la carga ayuda a la planificación de la capacidad y la operación de las diferentes compañías eléctricas para suministrar energía de forma confiable a los consumidores.

Con lo mencionado anteriormente, este estudio se centra en la comparación de modelos autorregresivos y media móvil, principalmente en el modelo de regresión SARIMA que considera la estacionalidad de los datos de carga, proporcionando una evaluación del modelo basándonos en el criterio de información Akaike. Los datos de entrada se han dividido en dos grupos de datos uno anual y otro mensual, para construir el modelo de pronóstico. La exactitud de los modelos de predicción se ha evaluado utilizando las diferentes matrices de error. Para el análisis de predicción se utilizó el software de RStudio y Matlab, en donde los resultados finales en la comparación de datos entre los reales y los estimados fueron con un valor mínimo de error, menor al 5%.

Palabras Clave: Métodos de Predicción, Econometría, Regresión, Autocorrelación, Estadística.

Abstract

The objective of electrical load forecasting is to satisfactorily and accurately predict the demand that could increase or decrease in the future. Many engineering applications have accurate and reliable prediction models for electricity demand. Accurate load forecasting assists in planning the capacity and operation of different utilities to reliably supply power to consumers.

With the above mentioned, this study focuses on the comparison of autoregressive and moving average models, mainly in the SARIMA regression model that considers the seasonality of load data, providing an evaluation of the model based on the Akaike information criterion. The input data has been divided into two data sets, one annual and one monthly, to build the forecast model. A comparison is made between the estimated and actual data on an annual and monthly basis to check the margin of error.

The accuracy of the prediction models has been evaluated using the different error matrices. For the prediction analysis, RStudio and Matlab, software was used, where the final results in the data comparison between actual and estimated data were with a minimum error value of less than 5%.

Keywords: Prediction methods, Econometrics, Regression, Autocorrelation, Statistics.

1 Introducción

En general, la predicción del uso de energía es actualmente muy relevante con respecto a la mejora del rendimiento energético en el país, así como también para reducir el impacto ambiental potencial. Aunque los horizontes de pronóstico cortos pueden ser muy relevantes en ciertas áreas de aplicación como por ejemplo la energía eléctrica, el consumo de energía diaria, mensual o anual. Las condiciones de una aplicación particular generalmente determinan la idoneidad de un modelo de pronóstico. Se han utilizado con éxito varios enfoques para la predicción del uso de energía [1].

Con la privatización del sector eléctrico y la creación de un mercado eléctrico, es importante la predicción de la demanda de energía eléctrica a corto y largo plazo, por parte de las empresas encargadas de la distribución de energía.

La previsión de la demanda a largo plazo se utiliza es necesaria para evitar comprar energía excesiva o insuficiente a los generadores, mientras que la previsión a corto plazo se utiliza para evitar distribuir más energía de la compra. Este tipo de pronóstico requiere que el error este por debajo de las tolerancias de los contratos, que suele rondar entre el 5% [2].

Se necesita una predicción precisa de la demanda para evitar que los consumidores compren demasiada electricidad o se queden sin electricidad, y para controlar la proporción entre la demanda y oferta, a través del sistema de energía eléctrica [3].

En la actualidad la previsión de carga se ha multiplicado por múltiples para la red futura con márgenes de seguridad limitados y niveles de riesgo crecientes, debido a los avances tecnológicos que están cambiando la

forma de la red al convertir una energía impulsado por la demanda en un sistema de generación impulsado por energía.

Esto se debe esencialmente a una multitud de factores, incluido el aumento de la penetración de los recursos de energía renovable y las nuevas tecnologías del lado del consumidor (vehículos eléctricos, almacenamiento de energía). El aumento de la demanda mundial de electricidad es constante y aun se espera que crezca más del doble del ritmo de la demanda mundial de energía [3].

La previsión de carga o demanda eléctrica es un proceso vital en la planificación de la industria eléctrica y desempeña un papel fundamental para el funcionamiento de un sistema eléctrico [4].

La predicción de carga eléctrica está altamente relacionado con el desarrollo económico, también está relacionado con la seguridad nacional y el funcionamiento diario de la sociedad [5].

Por lo tanto, la precisión del pronóstico de carga eléctrica tiene gran importancia para la programación de la capacidad de generación de energía y la gestión del sistema de energía [6], ya que estos pronósticos precisos conducen a ahorros sustanciales en el coste para la operación, mantenimiento y decisiones correctas para el desarrollo futuro [4].

Además, la previsión de carga de energía eléctrica presenta el paso inicial en el desarrollo de instalaciones futuras dentro de la generación, transmisión y distribución, sin embargo, la precisión del pronóstico de carga, a menudo no puede cumplir con nuestro resultado deseado porque está influenciada por varios factores inciertos e incontrolables como el desarrollo económico, las actividades sociales humana, las políticas del país y el cambio climático [7].

Para el estudio de la predicción, existen varios métodos que utilizan el análisis de regresión múltiple, inteligencia artificial como por ejemplo redes neuronales y el análisis de series de tiempo como el método autorregresivo (AR), media móvil (MA), autorregresivo integral de media móvil (ARIMA) [8],[9]. Los modelos de predicción que utilizan redes neuronales es demasiado complejo para decir que es fácil de usar [8].

El criterio Akaike, es usado dentro la materia de biología y la econometría, es un criterio fundamental que ayuda a determinar la conveniencia de un modelo particular dentro de un grupo finito de modelos [10].

Los algoritmos de regresión como es el caso del modelo SARIMA, están diseñados para capturar patrones estacionales, son perfectos para modelar series de tiempo de carga [11], utilizando un enfoque del mismo mes como es el caso de los datos mensuales.

El trabajo se distribuye así:

En la Sección 1: Introducción y antecedentes.

Sección 2: Abarca el marco teórico con la recopilación de los modelos autorregresivos, media móvil, autorregresiva integral media móvil, estacional ARIMA y los criterios de evaluación.

Sección 3: Planteamiento del problema en donde contiene la información de la demanda eléctrica del Ecuador, su regulador y el proceso de obtención del mejor modelo.

Sección 4: Análisis de resultados, conclusiones y trabajos futuros.

2 Marco teórico

2.1 Demanda eléctrica

Una de las realidades e incertidumbres más importantes en el mercado eléctrico es la demanda de electricidad [12].

A continuación, se presentan varios conceptos teóricos.

2.1.1 Consumo de energía eléctrica

El consumo de energía está representado por la siguiente ecuación

$$E = \sum_{i=1}^n P_i * T_i \quad (1)$$

Donde:

E Es la energía consumida
 P_i Es la potencia
 T_i Es el intervalo de tiempo

En otras palabras se la define como la energía, que el usuario utiliza para hacer una actividad determinada en un tiempo establecido [13].

2.1.2 Carga eléctrica de un sistema

La carga de energía dentro de un sistema se define como no estacionaria por su tendencia a incrementarse o a disminuir en ciertos tiempos del transcurso del día. Asimismo, sus valores no están alrededor de una media, por lo cual las variaciones se deben a parámetros como: la hora, día, clima, etc., y pueden estar relacionados por factores sociales y económicos [14]. Además, existen ciertos patrones que se comparan y que se repiten en ciclos diarios, en otras palabras, tienen estacionalidad definidas [15].

La generación eléctrica debe ser capaz de cubrir tanto la demanda eléctrica como las pérdidas que se producen por todos los elementos del sistema [16].

2.2 Autocorrelación

A veces en una serie de tiempo sucede que los valores toma una variable en el tiempo, no son independientes entre sí, caso contrario un valor determinado depende de los valores anteriores, por lo cual existe dos maneras de medir esta dependencia de las variables [17].

2.2.1 Función de Autocorrelación (ACF)

La función de autocorrelación simple calcula la fuerza de la correlación entre sucesos de un fenómeno en un intervalo de tiempo, mostrando así la agrupación entre valores de la misma variable en diferentes intervalos de tiempo [18].

$$\rho_k = \frac{y_k}{y_0} \quad (2)$$

Donde:

- ρ_k Función de autocorrelación.
- y_k Covarianza al rezago k
- y_0 Varianza.

2.2.2 Función de Autocorrelación Parcial (PACF)

La autocorrelación parcial calcula el grado de correlación entre dos variables que se dividen en n periodos, cuando se neutraliza la dependencia línea que se crea por los retrasos intermedios entre ambas [18].

$$r_k = \frac{\sum_{t=1}^{n-k} (y_t - \bar{y})(y_{t+k} - \bar{y})}{\sum_{t=1}^n (y_t - \bar{y})^2} \quad (3)$$

Donde:

- \bar{y} Es la media muestral.
- n Es el tamaño de la muestra
- r_k Es el estimador de ρ_k

En conclusión, la autocorrelación parcial detecta la correlación de los valores actuales y los valores rezagados de la serie cronológica original [19].

2.3 Modelo autorregresivo (AR)

La metodología del modelamiento univariante es simple, ya que es aclarar el valor que se designa en un momento t, una variable económica que presenta dependencia temporal, un método de trabajar es recopilar información sobre el pasado de la variable, observar su trayectoria en el tiempo y explora el

patrón de regularidad que muestran los datos [20].

El modelo autorregresivo se ha usado desde el año 1996, se relaciona con una suma ponderada de datos, basada en la variable escogida. El indicador p es el que representa el orden del modelo autorregresivo [21],[22].

El modelo autorregresivo se expresa de la siguiente manera [23]:

$$(Y_t - \delta) = a_1(Y_{t-1} - \delta) + a_2(Y_{t-2} - \delta) + \dots + a_p(Y_{t-p} - \delta) + u_t \quad (4)$$

Donde:

- Y_t Demanda de energía eléctrica.
- δ Media de la demanda.
- u_t Error aleatorio.
- a_p Parámetro que define el modelo (valor a estimar).

2.4 Modelo media móvil (MA)

El modelo de media móvil es una agrupación lineal de términos de errores presentes y rezagados [24].

El modelo MA es representada por la ecuación (5) [23],[25]:

$$Y_t = \mu + \beta_0 u_t + \beta_1 u_{t-1} + \beta_2 u_{t-2} + \dots + \beta_q u_{t-q} \quad (5)$$

Donde:

- μ Es el valor constante.
- u Es el termino de error.
- q Es el orden de media móvil.

2.5 Modelo autorregresivo integral de media móvil (ARIMA)

El modelo ARIMA es una agrupación de un término AR y un término MA con un elemento diferenciador representado por la letra I.

El modelo ARIMA debe usarse siempre y cuando el procedimiento sea no estacionario, el cual será modificado a estacionario para así poder diferenciar si es un modelo ARMA, AR o MA. Teniendo en cuenta que el modelo

ARIMA es univariado, por lo cual se correlacionan los valores presentes con los valores pasados para así realizar la predicción [21],[24].

Es importante saber que el modelo ARIMA se encuentra entre los métodos estadísticos más simples pero populares que se han aplicado al modelo de series de tiempo. La popularidad de ARIMA se puede atribuir al esfuerzo de Box y Jenkins [26].

El modelo ARIMA se representa por la ecuación (6) [23].

$$Y_t = \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (6)$$

Donde:

- ϕ Es el indicador autorregresivo
- θ Es el indicador de media móvil
- ε Es el error
- Y_{t-p} Es el registro normalizado de la serie a modelar

En la ecuación (6)

- p representa el autorregresivo
- q representa los términos de la media móvil.
- p se refiere al número de observaciones de los datos históricos que se utilizan en predecir los valores futuros
- q se refiere a los valores rezagados de los términos de error [26].

Para este modelo, el requisito principal es hacer que los datos de la serie de tiempo sean estadísticamente estacionarios en términos de media, varianza y autocorrelación. En caso de que los datos se muestren no estacionarios, los datos deben diferenciarse. Esto ayuda a convertir los datos en una serie de tiempo estacionaria donde se la representa en la ecuación (7) [26].

$$ARIMA = (p, d, q) \quad (7)$$

Donde:

- p Es el coeficiente autorregresivo
- d Es el grado de diferenciación
- q Es el coeficiente de media móvil

2.6 Seasonal ARIMA (SARIMA)

El modelo SARIMA se utiliza cuando la serie de tiempo muestra una variación estacional y se la representa con la ecuación (8) [27].

$$SARIMA = (p, d, q)(P, D, Q)_s \quad (8)$$

Donde:

- P Es una notación autorregresiva
- Q Es una notación de media móvil
- s Es el periodo estacional

Un ejemplo del periodo estacional, en una serie temporal de datos trimestral $s = 4$ y en un dato mensual $s = 12$.

2.6.1 Operador de Retroceso (B)

Para formalizar el modelo se utiliza el operador de retroceso (B) representada por la ecuación (9).

$$B^k Y_t = Y_{t-k} \quad (9)$$

Donde:

- B^k Es la observación de la serie de tiempo hacia atrás en el tiempo por k periodo

Anteriormente el operador de retroceso se usaba para presentar una transformación de estacionariedad general, donde la serie de tiempo es estacionaria si las propiedades estadísticas (media y varianza) son constantes en el tiempo [27].

La transformación seasonality general se presenta a continuación:

$$z_t = \nabla_s^D \nabla^d y_t = (1 - B^s)^D (1 - B)^d y_t \quad (10)$$

Donde:

- z Es la diferenciación de series de tiempo
- d Es el grado de diferenciación no estacional utilizado
- D Es el grado de diferenciación estacional utilizado

Luego, la forma general SARIMA del modelo SARIMA (p, P, q, Q) es:

$$\phi_p(B)\phi_p(B^S)z_t = \delta + \theta_q(B)\theta_q(B^S)a_t \quad (11)$$

2.6.2 Método Box Jenkins

George Box y Gwilym Jenkins estudiaron la simplificación paso a paso para obtener la información completa de entender el modelo ARIMA y usar el univariante modelo ARIMA. La metodología Box-Jenkins (BJ) consta de cuatro pasos iterativos [26],[27].

Paso 1: Identificación

Este paso se centra en la selección del orden de regular diferenciación (d), diferenciación estacional (D), el no estacional de autorregresivo (p), el orden estacional de Autorregresivo (P), el orden no estacional de la media móvil (q) y el orden no estacional del autorregresivo (Q). El número de orden se puede identificar observando función de autocorrelación (ACF) y autocorrelación parcial (PACF)

Paso 2: Estimación

Los datos históricos se utilizan para estimar los parámetros del modelo provisional del Paso 1.

Paso 3: Comprobación de diagnóstico

La prueba de diagnóstico, es decir el ACF y PACF, se utiliza para comprobar la idoneidad del modelo provisional.

Paso 4: Predicción

El modelo final del paso 3 se utiliza para pronosticar los valores de pronóstico.

Este enfoque se usa ampliamente para examinar el modelo SARIMA debido a la capacidad de capturar la tendencia apropiada al examinar el patrón histórico seguido de la metodología del Box-Jenkins que tiene varias ventajas.

— Extraer una gran cantidad de información de la serie de tiempo

utilizando un número mínimo de parámetros.

— Esta metodología tiene la capacidad de manejar series de tiempo estacionarias y no estacionarias en elementos no estacionales y estacionales [27].

2.7 Criterios de Evaluación de modelos de predicción

2.7.1 Criterio Akaike (AIC)

El criterio de información de Akaike (AIC) es muy útil para la selección de modelos. La selección del modelo ARIMA estacional se realiza con frecuencia utilizando AIC para seleccionar un modelo que ofrezca una buena estimación y tenga un mínimo de parámetros [10].

Agregar parámetros adicionales conduce a la penalización del modelo por parte del AIC. Al comparar un conjunto de modelos para un dato dado, el AIC estima un criterio que es el valor mínimo del modelo de referencia. Este valor se calcula utilizando el valor maximizado de la función de verosimilitud de la siguiente manera:

$$AIC = -2l + 2k \quad (12)$$

$$(l = \log(L)) \quad (13)$$

Donde:

- k Es el número de parámetros del modelo
- l Es la estimación de probabilidad logarítmica del modelo seleccionado
- L Función de probabilidad

Por tanto, el mejor modelo se selecciona en función del valor mínimo de AIC obtenido [23].

Para modelos que tienen valores casi idénticos, se puede usar la siguiente fórmula para una comparación adicional:

$$\Delta AIC = \Delta i = -AIC_{min} + AIC_i \quad (14)$$

Donde:

AIC_{min} Es el valor de AIC más bajo del modelo

AIC_i Es el valor i –ésimo modelo (modelo de interés)

Se muestra evidencia significativa del interés del modelo cuando $\Delta i < 2$. Sin embargo, el modelo de interés tiene menos apoyo cuando $3 \leq \Delta i \leq 7$, mientras que $\Delta i > 10$ muestra un apoyo importante contra el modelo de interés [23].

Haciendo un resumen de lo comentado anteriormente, el modelo que se debe seleccionar es con el valor de AIC más bajo ya que describe mejor los datos analizados.

Agregar más parámetros aumentaría la incertidumbre de la estimación de parámetros, por lo tanto, el número de parámetros y el ajuste mejorado deben equilibrarse entre sí para minimizar el valor AIC [28].

2.7.2 Suma de cuadrados del error (SSE)

El cálculo SSE con la formula definitoria implica mucha aritmética, donde se debe calcular los valores pronosticados y residuos, por lo que a continuación tenemos la siguiente ecuación [29]:

$$SSE = \sum (y_i - \hat{y}_i)^2 \quad (15)$$

2.7.3 Criterio del p-value

Si el p-value es menor o igual al tamaño de la región crítica, quiere decir que este p-value se encuentra en la región de rechazo, con lo cual el factor x_i se considera significativamente mayor que cero, y deberá ser incluido en el modelo ajustado. En caso en que el p-value sea mayor que el tamaño de la región crítica no habrá evidencia estadística suficiente para decir que el termino evaluado sea

significativo y por tanto no deberá ser incluido dentro del modelo ajustado [30].

2.8 Forecast

Para el Forecast o pronóstico de un periodo de la señal en análisis y para su verificación del resultado existen características que se deben tomar en cuenta [31].

- Para cualquier modelo estadístico, los datos mínimos necesarios para el ajuste dependen del número de parámetros a estimar y el número de variaciones aleatorias en los datos.
- Desde una perspectiva estadística, es importante tener un número mayor de observaciones que de parámetros.
- Es importante enfatizar que el uso de esta cantidad mínima de datos requeridos no garantiza estimaciones adecuadas de estacionalidad.
- Al pronosticar utilizando modelos estacionales, el número de datos necesarios depende del tipo del modelo y el número de aleatoriedad en los datos.
- No existe reglas estrictas sobre la dimensión de la muestra que se debe usar, y la dimensión mínima requerido solo se usa cuando el número de variaciones aleatorias en los datos es pequeño.
- En la práctica, los datos suelen contener un elevado número de aleatoriedad, lo que hace que el tamaño de los requisitos de la muestra aumente en consecuencia.

3 Planteamiento del Problema

3.1 Demanda eléctrica del Ecuador

El mercado eléctrico mayorista, funciona contrarrestando la demanda y la oferta, con la finalidad de afianzar el suministro

de la demanda con excelentes inversiones por el lado de la oferta [32]. Con esta introducción, dentro de la planificación del sector eléctrico es importante realizar un estudio de análisis demanda eléctrica, que permita al planificador del sector procurar los posibles acontecimientos a enfrentarse en un futuro, con la finalidad de garantizar el abastecimiento de energía mediante inversiones en generación, transmisión y distribución [33].

Para la planificación de la ampliación de un sistema eléctrico en un proceso de la transformación futura del mercado donde se permita efectuar un plan indicativo de inversiones. El manejo de la ampliación resulta el desarrollo a futuro de la demanda, si la demanda no crece no sería necesario realizar ampliaciones en el sistema eléctrico, se supone que en la situación de partida del procedimiento de planificación se abastece toda la demanda [33]. En el caso de existir un error en la proyección de demanda, esto puede resultar un problema de generación, como la evacuación de energía o donde no se pueda vender los excedentes producidos, lo que causaría grandes problemas financieros debido a la gran inversión en generación que no está completamente usada [34].

Una proyección de demanda futura de energía esta analizada en el procedimiento de decisión con las posibles opciones de inversión sectorial y de crecimiento a nivel del país, además nos ayuda para la preparación de inversiones, presupuestos, estudios de pérdidas y de cálculos tarifarios [34].

3.2 La Agencia de Regulación y Control de Electricidad (ARCONEL)

La ARCONEL, como dispone la Ley Orgánica de Servicio Público de Energía Eléctrica (LOSPEE), mantiene sus

resoluciones en el trabajo permanente para la implementación, operación y mantener el sistema único de información estadística del sector eléctrico [35].

Para esto el ARCONEL gestionara, actualizara, validara y procesara la información estadística y geográfica de los participantes del sector eléctrico, orientando al libre acceso de información completa, oportuna y de calidad de las actividades de generación, transmisión, distribución y alumbrado público general. por lo tanto el ARCONEL publica en su página web www.regulacionelectrica.gob.ec de libre acceso, información estadística y geográfica detallada de infraestructura, transacciones e indicadores como Balance Nacional de Energía, entre otros [36].

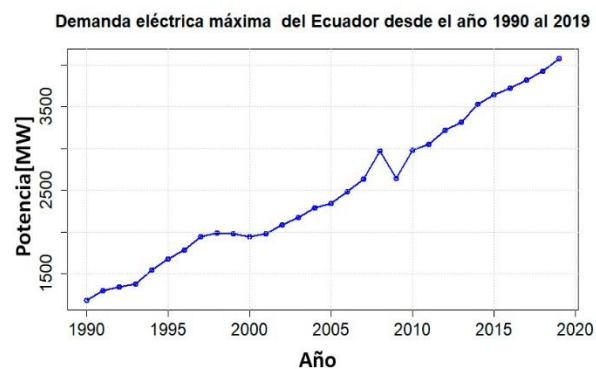


Figura 1. Demanda eléctrica máxima anual del Ecuador con datos históricos desde el año 1990 al 2019.

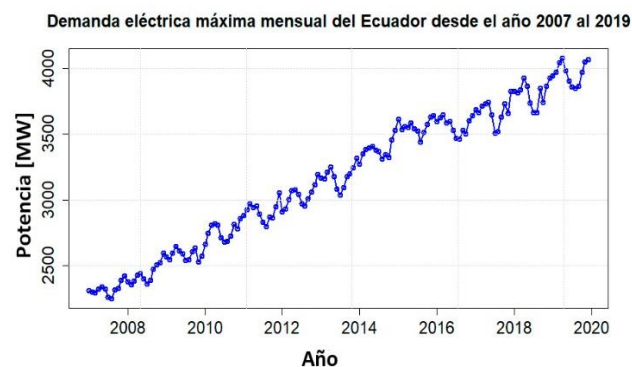


Figura 2. Demanda eléctrica máxima mensual del Ecuador desde el año 2007 al 2019.

3.3 Formulación del problema

Para el presente trabajo de estudio, se realizará ciertos modelos autorregresivos (AR), media móvil (MA), autorregresivo integral de media móvil (ARIMA) y Seasonal ARIMA (SARIMA), con el fin de predecir la demanda máxima del sector eléctrico ecuatoriano para futuros años.

El propósito de predecir la demanda eléctrica ecuatoriana, se utiliza el software RStudio, en el cual se ingresa los datos obtenidos por los documentos de la Estadística del Sector Eléctrico Ecuatoriano, encontrados en la página del ARCONEL y mediante programación encontrar los valores futuros de demanda máxima.

3.3.1 Caso de estudio 1: Demanda eléctrica máxima anual

En la Tabla 1, se indica los valores de potencia máxima obtenidos en dichos documentos.

Tabla 1. Datos históricos de la demanda máxima anual del Ecuador desde el año 1990 al 2019.

	Año	Potencia Máxima [MW]
1	1990	1185,8
2	1991	1296,4
3	1992	1339,5
4	1993	1378,6
5	1994	1544,4
6	1995	1674,9
7	1996	1787,8
8	1997	1947,8
9	1998	1986,7
10	1999	1977,01
11	2000	1940,57
12	2001	1979,94
13	2002	2087,11
14	2003	2173,97
15	2004	2293,75
16	2005	2344,20
17	2006	2481,01
18	2007	2635,19
19	2008	2973,88
20	2009	2644,58
21	2010	2983,51
22	2011	3052,64
23	2012	3221,98
24	2013	3315,37

25	2014	3530,67
26	2015	3643,36
27	2016	3723,95
28	2017	3825,82
29	2018	3928,93
30	2019	4077,03

Con estos datos se crea un algoritmo donde muestre la demanda máxima como lo podemos visualizar en la Figura 1, en donde se observa que tiene tendencia lineal, lo cual se determina que es factible modelar un modelo SARIMA. Seguido se diferencia los datos.

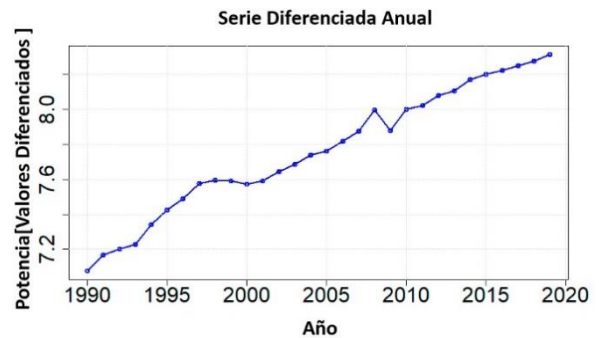


Figura 3. Serie diferenciada de la demanda máxima anual.

Se utiliza la función de autocorrelación (ACF) y autocorrelación parcial (PACF) dando como resultado las siguientes Figuras 4 y 5.

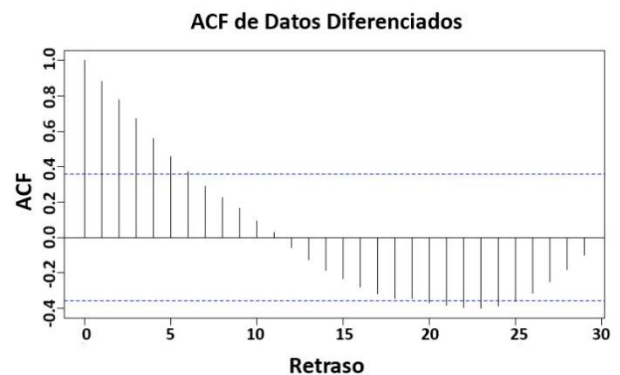


Figura 4. ACF de la serie diferenciada de la Figura 3.




Figura 5. PACF de la serie diferenciada de la Figura 3.

Para el algoritmo se considera que para (d, D) se toma el valor de 1, es decir, los coeficientes de diferenciación no estacional y estacional es 1, esto es debido a que no es necesario diferenciar los datos más de una vez.

Mediante el algoritmo se obtiene los valores (p, q) (P, Q) . que representan a

los coeficientes autorregresivos y media móvil no estacionario y estacionarios. El periodo estacional en este caso es 1, ya que estamos trabajando con un dato por año.

Finalmente se tiene que encontrar el mejor modelo SARIMA para tener la mejor predicción anual.

A continuación, en la Tabla 2 muestra los valores AIC, SSE y p-value de 5 modelos encontrados y basándonos mediante el criterio de evaluación se determina el mejor modelo SARIMA.

- AIC debe ser el menor valor.
- SSE debe ser el menor valor
- P-value debe ser cercano a 1.

Tabla 2. Modelos SARIMA anuales, con sus respectivos criterios de evaluación.

Modelo	p	d	q	P	D	Q	s	AIC	SSE	p-value
1	0	1	0	1	1	1	1	-85.6806	0.05622203	0.9205082
2	0	1	0	0	1	1	1	-85.45176	0.05966706	0.2249689
3	0	1	1	0	1	1	1	-83.76094	0.06300745	0.7833637
4	1	1	0	1	1	1	1	-83.54841	0.0565212	0.8839251
5	0	1	1	1	1	1	1	-82.40829	0.05854784	0.4971028

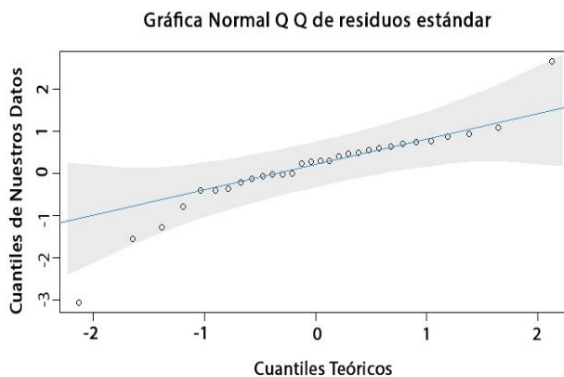


Figura 6. Gráfica normal Q Q de residuos estándar anual.

Existe la restricción de que un modelo no debe sobrepasar cierto nivel de complejidad, es decir que la suma de los coeficientes sea menor que 10.

Seguido con la función Forecast del Software se predice los valores de demanda eléctrica para los 5 años futuros. Los resultados se encuentran en la Figura 7 y la Tabla 3.




Figura 7. Pronóstico de demanda máxima anual de los 5 futuros años.

Tabla 3. Resultado de la Predicción de demanda para los 5 futuros años.

Promedio de Potencia [MW]	
1	4164.88
2	4279.21
3	4381.90
4	4489.70
5	4595.26

3.3.2 Caso de estudio 2: Demanda eléctrica máxima mensual

Se realiza el mismo análisis que el caso de estudio 1, pero ahora con los datos mensualmente que se detallan en la Tabla 4.

Tabla 4. Datos históricos de la demanda máxima mensual del Ecuador desde el año 2007 al 2019.

Mes/Año	2007	2008	2009	2010	2011	2012
Enero	2307,7	2379,38	2569,70	2662,85	2883,40	2910,59
Febrero	2300,73	2355,97	2542,55	2743,88	2928,27	2931,56
Marzo	2291,72	2380,75	2597,99	2809,92	2970,11	3004,65
Abril	2322,24	2430,36	2644,58	2819,50	2944,71	3068,45
Mayo	2337,13	2440,65	2614,54	2806,79	2953,50	3076,06
Junio	2322,24	2401,44	2590,77	2715,09	2892,97	3042,87
Julio	2260,79	2358,75	2538,75	2680,54	2828,05	2968,68
Agosto	2251,11	2386,41	2544,49	2685,93	2795,43	2951,82
Septiembre	2317,88	2475,13	2605,17	2723,39	2870,67	3010,05
Octubre	2327,66	2505,11	2634,93	2811,26	2863,03	3060,13
Noviembre	2389,09	2521,17	2526,06	2778,94	2950,02	3113,28
Diciembre	2420,62	2593,52	2575,28	2861,25	3052,64	3193,72
2013	2014	2015	2016	2017	2018	2019
3165,25	3274,73	3616,23	3594,45	3687,42	3825,86	3944,00
3162,37	3351,29	3533,62	3624,77	3662,01	3813,75	3974,04
3213,33	3382,85	3555,87	3647,81	3714,24	3838,64	4045,88
3247,90	3393,40	3553,11	3585,19	3732,31	3928,93	4077,03
3178,22	3405,63	3583,41	3598,16	3743,52	3863,12	3984,73
3081,06	3377,81	3543,11	3531,21	3649,19	3738,52	3905,52
3039,43	3366,00	3521,92	3469,87	3505,36	3664,15	3862,35
3091,90	3313,49	3440,73	3464,23	3521,49	3662,60	3851,71
3178,46	3342,73	3515,91	3528,85	3630,98	3847,37	3863,33
3197,41	3324,94	3575,03	3503,90	3733,15	3741,78	3971,20
3242,98	3455,01	3630,81	3605,47	3656,37	3867,57	4050,62
3315,37	3530,67	3643,36	3639,93	3825,82	3927,30	4068,13

El algoritmo realizado anteriormente es el mismo, en el que de igual manera se diferencia los datos como se muestra en la Figura 8.




Figura 8. Serie diferenciada de la demanda máxima mensual.

Se encuentra las funciones de autocorrelación (ACF) y autocorrelación parcial (PACF), con los datos mensuales.




Figura 9. ACF de la serie diferenciada de la Figura 8.




Figura 10. PACF de la serie diferenciada de la Figura 8.

Tabla 5. Modelos SARIMA con datos mensuales.

Modelo	p	d	q	P	D	Q	s	AIC	SSE	p-value
1	2	1	1	0	1	1	12	-792.1848	0.02545203	0.6738887
2	1	1	1	0	1	1	12	-792.1415	0.02579888	0.4475178
3	0	1	2	0	1	1	12	-791.6785	0.02589336	0.3713313
4	1	1	2	0	1	1	12	-791.3815	0.02558976	0.6126908
5	1	1	1	0	1	2	12	-790.2299	0.02588931	0.4732326




Figura 11. Gráfica normal Q Q de residuos estándar mensual.

Seguido de encontrar el mejor modelo se continua con la predicción de los valores de demanda máxima mensual por 2 años (24 meses).

Pronóstico mensual de los 2 años futuros




Figura 12. Predicción para 24 meses futuros.
Tabla 6. Resultado de la Predicción de demanda mensual para los 2 años futuros.

	Promedio de Potencia [MW]
1	4061.52
2	4072.01
3	4114.09

Los resultados de los mejores modelos se muestran a continuación en la Tabla (5), donde se determina el mejor modelo SARIMA mediante los criterios de evaluación donde:

- AIC debe ser el menor valor.
- SSE debe ser el menor valor
- P-value debe ser cercano a 1.

4	4137.22
5	4124.90
6	4063.90
7	4007.98
8	4000.04
9	4073.02
10	4099.20
11	4140.75
12	4207.36
13	4202.55
14	4210.67
15	4251.46
16	4274.11
17	4261.64
18	4200.60
19	4144.66
20	4136.72
21	4209.70
22	4235.88
23	4277.43
24	4344.04

4 Análisis de resultados

Mediante los casos mencionados anteriormente se tiene los siguientes resultados

4.1 Caso 1

Se realiza un análisis a los resultados de la predicción anual mediante una comparación entre el modelo real (30

datos) y otro modelo quitado 5 datos (25 datos).




Figura 13. Comparativa de demanda máxima anual en R.

Cálculo del error:

Tabla 7. Error de los valores reales con los valores estimados en R.

	Valor real	Valor estimado	Error Porcentual
1	3643,36	3628,37	0,41
2	3723,95	3726,08	0,06
3	3825,82	3823,78	0,05
4	3928,93	3921,48	0,19
5	4077,03	4019,19	1,42
RMSE=		26,9621302	

Comparativa con el software Matlab.




Figura 14. Comparativa de demanda máxima anual en Matlab.

Cálculo del error:

Tabla 8. Error de los valores reales con los valores estimados en Matlab.

	Valor real	Valor estimado	Error Porcentual
1	3643,36	3652,70	0,26
2	3723,95	3774,70	1,36
3	3825,82	3896,60	1,85
4	3928,93	4018,60	2,28
5	4077,03	4140,60	1,56

RMSE= 62.856122

En este caso 1 para la determinación del mejor modelo SARIMA (Tabla 2) se compara los valores de AIC y p-value de todos los modelos, donde se obtuvo un valor de AIC de -85.6806, siendo este el de menor valor y el p-value de 0.9205082, siendo este el más cercano a 1.

En la figura 13 y 14 se observa la comparación de la demanda anual real y la demanda anual pronosticada con los softwares RStudio y Matlab donde los resultados se reflejan en las tablas 7 y 8 respectivamente, obteniendo un error porcentual menor al 5% de la comparación de la demanda de los últimos 5 años en los 2 softwares, obteniendo de igual manera el error RMSE, siendo el valor de RStudio menor que el de Matlab por lo tanto los valores de RStudio son los que tienen menor error para la predicción de la demanda eléctrica del Ecuador.

4.2 Caso 2

Se realiza un análisis a los resultados de la predicción mensual tomando en cuenta los 12 meses de 13 años, mediante una comparación entre el modelo real (156 datos) y otro modelo quitado 24 datos equivalente a dos años (132 datos).

Comparativa de demanda eléctrica mensual del Ecuador

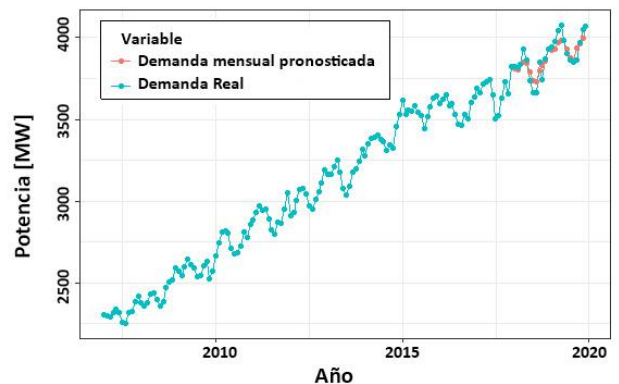


Figura 15. Comparativa de demanda máxima mensual en R.

Cálculo del error:

Tabla 9. Error de los valores reales con los valores estimados en R.

	Valor real [MW]	Valor estimado [MW]	Error Porcentual [%]
1	3825,86	3810,63	0,40
2	3813,75	3801,79	0,31
3	3838,64	3833,20	0,14
4	3928,93	3846,65	2,09
5	3863,12	3846,02	0,44
6	3738,52	3792,53	1,44
7	3664,15	3737,20	1,99
8	3662,6	3728,95	1,81
9	3847,37	3797,34	1,30
10	3741,78	3828,04	2,31
11	3867,57	3858,49	0,23
12	3927,3	3930,24	0,07
13	3943,997	3922,17	0,55
14	3974,038	3928,54	1,14
15	4045,88	3967,18	1,95
16	4077,03	3982,68	2,31
17	3984,73	3982,28	0,06
18	3905,52	3928,66	0,59
19	3862,35	3873,25	0,28
20	3851,71	3864,96	0,34
21	3863,33	3933,34	1,81
22	3971,2	3964,05	0,18
23	4050,62	3994,50	1,39
24	4077,3	4066,25	0,27
RMSE=		48,674633	

Comparativa con el software Matlab.




Figura 16. Comparativa de demanda máxima mensual en Matlab.

Cálculo del error:

Tabla 10. Error de los valores reales con los valores estimados en Matlab.

Valor real [MW]	Valor estimado [MW]	Error [%]
--------------------	---------------------------	--------------

1	3825,86	3823,6	0,06
2	3813,75	3804,9	0,23
3	3838,64	3840,2	0,04
4	3928,93	3850,8	1,99
5	3863,12	3853,9	0,24
6	3738,52	3800,0	1,64
7	3664,15	3745,4	2,22
8	3662,6	3730,8	1,86
9	3847,37	3799,1	1,25
10	3741,78	3823,7	2,19
11	3867,57	3872,2	0,12
12	3927,3	3935,8	0,22
13	3943,997	3931,1	0,33
14	3974,038	3930,9	1,09
15	4045,88	3966,4	1,96
16	4077,03	3974,2	2,52
17	3984,73	3978,9	0,15
18	3905,52	3921,7	0,41
19	3862,35	3858,3	0,10
20	3851,71	3846,6	0,13
21	3863,33	3918,8	1,44
22	3971,2	3950,9	0,51
23	4050,62	3987,4	1,56
24	4077,3	4061,1	0,40
RMSE=		48,9247576	

En este caso 2, para la determinación del mejor modelo SARIMA (Tabla 5) se compara los valores de AIC y p-value de todos los modelos, donde se obtuvo un valor de AIC de -792.1848, siendo este el de menor valor y el p-value de 0.6738887, siendo este el más cercano a 1.

En la figura 15 y 16 se observa la comparación de la demanda mensual real y la demanda mensual pronosticada con los softwares RStudio y Matlab donde los resultados se reflejan en las tablas 9 y 10 respectivamente, obteniendo un error porcentual menor al 5% de la comparación de la demanda de los últimos 2 años en los 2 softwares, obteniendo de igual manera el error RMSE, siendo el valor de RStudio menor que el de Matlab por lo tanto los valores de RStudio son los que tienen menor error para la predicción de la demanda eléctrica del Ecuador.

Conclusiones

Del análisis de resultados y lo descrito en el presente documento se concluye lo siguiente:

- El presente trabajo realiza, ejecuta y simula el mejor modelo SARIMA, considerando los valores de los criterios de evaluación AIC y p-value y en función del error de estimación obtenido.
- La comparativa que se hizo de la demanda real y la demanda estimada por el software de RStudio y Matlab, tienen un valor de error porcentual menor al 5%, por lo tanto, los valores pronosticados son muy buenos para estimar un estudio de expansión.
- En la Tabla 3, los resultados del pronóstico anual para los futuros 5 años es claro que se va incrementando, esto es debido al crecimiento de los distintos sectores residencial, industrial y comercial.
- En la Tabla 6, los resultados de pronóstico mensual se observan claramente que para el mes de diciembre (12 y 24) son los valores más altos de demanda máxima 4207.36 y 4344.04 respectivamente, comparando con los datos históricos mensuales estos valores tienen similitud al ser los valores más altos en el año.

Trabajos futuros

El trabajo realizado puede ser la base de nuevas investigaciones que pueden ser relacionadas con las siguientes temáticas:

- Incluir variables meteorológicas exógenas como la temperatura, humedad, nubosidad etc. A través de modelos promedios móviles integrados autorregresivos

estacionales exógenos (SARIMAX), el cual mejoraría el desempeño de las proyecciones.

Referencias

- [1] A. Hošovský, J. Piteř, M. Adámek, J. Miřáková, and K. Židek, “Comparative study of week-ahead forecasting of daily gas consumption in buildings using regression ARMA/SARMA and genetic-algorithm-optimized regression wavelet neural network models,” *J. Build. Eng.*, no. April, 2020, doi: 10.1016/j.jobe.2020.101955.
- [2] I. S. Msiza, F. V. Nelwamondo, and T. Marwala, “Electrical Energy demand prediction using artificial neural networks and support vector regression,” *J. Comput.*, vol. 3, no. 11, pp. 1–8, 2008, doi: 10.4304/jcp.3.11.1-8.
- [3] A. A. Mir, M. Alghassab, K. Ullah, Z. A. Khan, Y. Lu, and M. Imran, “A review of electricity demand forecasting in low and middle income countries: The demand determinants and horizons,” *Sustain.*, vol. 12, no. 15, 2020, doi: 10.3390/SU12155931.
- [4] H. Son and C. Kim, “A deep learning approach to forecasting monthly demand for residential-sector electricity,” *Sustain.*, vol. 12, no. 8, p. 3103, 2020, doi: 10.3390/SU12083103.
- [5] J. Zhang, “Research on power load forecasting based on the improved elman neural network,” *Chem. Eng. Trans.*, vol. 51, pp. 589–594, 2016, doi: 10.3303/CET1651099.
- [6] Y. Lin, H. Luo, D. Wang, H. Guo, and K. Zhu, “An ensemble model

- based on machine learning methods and data preprocessing for short-term electric load forecasting,” *Energies*, vol. 10, no. 8, 2017, doi: 10.3390/en10081186.
- [7] M. A. Hammad, B. Jereb, B. Rosi, and D. Dragan, “Methods and Models for Electric Load Forecasting: A Comprehensive Review,” *Logist. Sustain. Transp.*, vol. 11, no. 1, pp. 51–76, 2020, doi: 10.2478/jlst-2020-0004.
- [8] Y. Kobayashi, R. Abe, and K. Tanaka, “The study of method of electric demand prediction for liberalized household electricity market,” *IET Conf. Publ.*, vol. 2014, no. CP651, pp. 2–7, 2014, doi: 10.1049/cp.2014.0937.
- [9] S. Fan and L. Chen, “Short-term load forecasting based on an adaptive hybrid method,” *IEEE Trans. Power Syst.*, vol. 21, no. 1, pp. 392–401, 2006, doi: 10.1109/TPWRS.2005.860944.
- [10] D. R. Martínez, J. L. Albín, J. C. Cabaleiro, T. F. Pena, F. F. Rivera, and V. Blanco., “El criterio de información de Akaike en la obtención de modelos estadísticos de Rendimiento,” *XX Jornadas Paralelismo*, pp. 439–444, 2009.
- [11] A. Zubair, “Short-Term Electric Demand Forecasting for Power,” pp. 122–126, 2019.
- [12] M. Tahmasebi and J. Pasupuleti, “Electricity demand uncertainty modeling using enhanced path-based scenario generation method,” *2017 6th Int. Youth Conf. Energy, IYCE 2017*, no. 2, pp. 1–5, 2017, doi: 10.1109/IYCE.2017.8003747.
- [13] J. Mendieta, Di., Escribano, *Electricidad, Desarrollo Rural Y Buen Vivir*. 2015.
- [14] S. R. Castaño, “Redes de Distribución de Energía,” vol. 3, 2014.
- [15] J. W. Taylor, “Short-term electricity demand forecasting using double seasonal exponential smoothing,” *J. Oper. Res. Soc.*, vol. 54, no. 8, pp. 799–805, 2003, doi: 10.1057/palgrave.jors.2601589.
- [16] M. Beccali, M. Cellura, V. Lo Brano, and A. Marvuglia, “Forecasting daily urban electric load profiles using artificial neural networks,” *Energy Convers. Manag.*, vol. 45, no. 18–19, pp. 2879–2900, 2004, doi: 10.1016/j.enconman.2004.01.006 .
- [17] J. Villavicencio, “Introducción a Series de Tiempo,” pp. 1–34, 2010
- [18] Plaza Sibaja Oscar, “Desarrollo de una metodología que permita determinar en forma previa la condicion ARIMA de una o múltiples series de tiempo, en un programa de case excel, para predicciones e inventarios en mantenimiento,” vol. 7, pp. 1–25, 2012.
- [19] B. Fanoodi, B. Malmir, and F. F. Jahantigh, “Reducing demand uncertainty in the platelet supply chain through artificial neural networks and ARIMA models,” *Comput. Biol. Med.*, vol. 113, no. August, p. 103415, 2019, doi: 10.1016/j.compbimed.2019.103415.
- [20] M. P. C. González, *Análisis de series temporales económicas: Modelos ARIMA*. 2009.
- [21] M. A. Mat Daut, M. Y. Hassan, H. Abdullah, H. A. Rahman, M. P. Abdullah, and F. Hussin, “Building electrical energy consumption forecasting analysis

- using conventional and artificial intelligence methods: A review,” *Renew. Sustain. Energy Rev.*, vol. 70, no. December, pp. 1108–1118, 2017, doi: 10.1016/j.rser.2016.12.015.
- [22] S. de la Fuente Fernández, “Series Temporales: Modelo Arima,” *Univ. Autónoma Madrid*, pp. 1–14, 2016.
- [23] P. E. Paucar Uyaguari and L. A. Yubi Quito, “Pronostico de perfiles de consumo de electricidad a través de modelos estadísticos y desarrollo de una metodología comparativa,” 2020.
- [24] L. F. Siavichay Cumbe and J. X. Serrano Guerrero, “Aplicacion de metodos estadisticos para el analisis y prediccionde perfiles de consumo de energia electrica,” p. 123, 2018.
- [25] D. Guajarati and P. Dawn, *Econometría*, Quinta edi. Mexico, 2010.
- [26] K. Goswami and A. B. Kandali, “Electricity Demand Prediction using Data Driven Forecasting Scheme: ARIMA and SARIMA for Real-Time Load Data of Assam,” *2020 Int. Conf. Comput. Perform. Eval. ComPE 2020*, pp. 570–574, 2020, doi: 10.1109/ComPE49325.2020.9200031.
- [27] A. E. Permanasari, I. Hidayah, and I. A. Bustoni, “SARIMA (Seasonal ARIMA) implementation on time series to forecast the number of Malaria incidence,” *Proc. - 2013 Int. Conf. Inf. Technol. Electr. Eng. "Intelligent Green Technol. Sustain. Dev. ICITEE 2013*, no. 2, pp. 203–207, 2013, doi: 10.1109/ICITEED.2013.667623.
- [28] A. Stitou, “SARIMA short to medium-term forecasting and stochastic simulation of streamflow , water levels and sediments time series from the HYDAT database,” p. 49, 2019.
- [29] R. E. Walpole, R. H. Myers, S. L. Myers, and K. Ye, *Probabilidad y estadística para ingeniería y ciencias*. 2012.
- [30] D. Jay, “Probability and Statistics for Engineering and the Sciences,” vol. Eighth Edi, p. 328, 2012.
- [31] A. R. Hoshmand, *Business forecasting: A practical approach: Second edition*. 2009.
- [32] B. Shan, D. Jia, L. Zhang, F. Cao, and Y. Sun, “Analysis of energy demand forecasting model in the context of electric power alteration,” *Proc. IEEE Int. Conf. Softw. Eng. Serv. Sci. ICSESS*, vol. 2017-Novem, pp. 798–801, 2018, doi: 10.1109/ICSESS.2017.8343032.
- [33] J. Suntaxi, Y. Salazar, and R. Loor, “Pronóstico de la demanda en energía y potencia del Sistema Eléctrico Quito,” *Rev. Técnica "Energía,"* vol. 15, no. 2, pp. 12–21, 2019, doi: 10.37116/revistaenergia.v15.n2.2019.371.
- [34] CONELEC (Consejo Nacional de Electricidad), “Estudio y Gestión de la Demanda Eléctrica,” *Plan Maest. Electríf. 2013-2022*, vol. 2, p. 206, 2013.
- [35] J. E. Macías Centeno, L. A. Valarezo Molina, and G. Loor Castillo, “Los Diferentes Costos que Tiene la Energía Eléctrica en el Ecuador Considerando los Cambios de la Estructura Actual,” *Rev. Investig. en Energía, Medio Ambient. y Tecnol. RIEMAT ISSN 2588-0721*, vol. 3, no. 2, p. 29,

- 2018, doi:
10.33936/riemat.v3i2.1628.
- [36] ARCONEL, “Estadísticas Anuales Y Multianual Del Sector Eléctrico Ecuatoriano 2018,” p. 214, 2019.

4.3 Matriz de Estado del Arte

Tabla 11. Matriz de estado del arte

ITEM	DATOS				TEMÁTICA				FORMULACIÓN DEL PROBLEMA FUNCIONES OBJETIVO				RESTRICCIONES DEL PROBLEMA				PROPUESTAS PARA RESOLVER EL PROBLEMA				SOLUCIÓN PROPUESTA						
	AÑO	TÍTULO DEL ARTÍCULO	PAÍS	CITAS	PREDICCIÓN	SERIES EN EL TIEMPO	CRITERIOS DE EVALUACIÓN	ESTADÍSTICA	IMPLEMENTACIÓN DE MODELOS DE OPTIMIZACIÓN PARA LA PREDICCIÓN	NECESIDAD DE LA PREDICCIÓN	DEMANDA ELECTRICA	EXACTITUD DEL PRONÓSTICO	CRITERIOS DE EVALUACION	REGRESION EN SERIES DE TIEMPO	BAJO ERROR PORCENTUAL	MEDIA Y VARIANZA	MINIMO VALOR DE AKAIKE	TÉCNICAS COMPUTACIONALES	MODELOS AUTORREGRESIVOS Y MEDIA MOVIL.	MODELOS ARIMA	MODELOS SARIMA	COMPARACIÓN CON LOS DATOS REALES Y ESTIMADOS	USO DE LOS SOFTWARE MATLAB Y RSTUDIO	DETERMINACION DE LOS MEJORES CRITERIOS DE EVALIACION	DETERMINACION DEL MEJOR MODELO	EVALUACIÓN DE LOS VALORES DE PREDICCIÓN	EVALUACION DEL MINIMO ERROR
1	2020	Comparative study of week-ahead forecasting of daily gas consumption in buildings using regression ARMA/SARMA	República Checa	48	☒	☒	☐	☒	☒	☐	☒	☐	☐	☒	☐	☐	☒	☒	☒	☐	☒	☒	☐	☒	☒	☒	☐
2	2008	Electrical Energy demand prediction using artificial neural networks and support vector regression	India	16	☒	☐	☒	☒	☐	☒	☒	☒	☒	☐	☒	☒	☐	☐	☐	☒	☐	☐	☐	☐	☐	☒	☒
3	2020	A review of electricity demand forecasting in low and middle income countries: The demand determinants and horizons	Pakistan	132	☒	☒	☐	☐	☐	☐	☒	☐	☐	☒	☐	☐	☐	☒	☐	☐	☐	☐	☒	☐	☐	☒	☐
4	2020	A deep learning approach to forecasting monthly demand for residential-sector electricity	Korea	51	☒	☒	☒	☐	☐	☒	☒	☐	☒	☐	☒	☐	☐	☐	☐	☐	☐	☐	☐	☐	☐	☒	☒
5	2016	Research on power load forecasting based on the improved elman neural network	China	12	☒	☐	☐	☒	☐	☐	☐	☐	☐	☒	☐	☐	☒	☐	☒	☐	☐	☐	☐	☒	☐	☒	☐
6	2017	An ensemble model based on machine learning methods and data preprocessing for short-term electric load forecasting	China	36	☒	☒	☐	☒	☒	☐	☐	☐	☐	☐	☐	☒	☐	☒	☐	☐	☐	☐	☒	☐	☐	☒	☐
7	2020	Methods and Models for Electric Load Forecasting: A Comprehensive Review	Slovenia	134	☒	☒	☐	☒	☒	☐	☒	☐	☐	☒	☐	☐	☐	☒	☐	☐	☒	☐	☐	☒	☒	☒	☐

8	2014	The study of method of electric demand prediction for liberalized household electricity market	Japón	8	✗	✗	□	✗	✗	✗	✗	□	□	✗	□	□	✗	□	□	□	✗	✗	□	✗	□	✗	□
9	2006	Short-term load forecasting based on an adaptive hybrid method	China	24	✗	□	✗	✗	✗	□	□	□	✗	□	□	□	□	□	□	✗	□	□	□	✗	□	✗	□
10	2009	El criterio de información de Akaike en la obtención de modelos estadísticos de Rendimiento	España	10	□	□	✗	✗	□	□	□	✗	✗	□	✗	✗	✗	□	□	□	□	□	□	□	✗	□	✗
11	2019	Short-Term Electric Demand Forecasting for Power	Dhaka	16	✗	□	✗	□	□	□	✗	□	✗	□	□	□	□	□	□	□	□	□	□	✗	□	✗	□
12	2017	Electricity demand uncertainty modeling using enhanced path-based scenario generation method	Iran	17	✗	✗	□	□	✗	✗	□	□	□	✗	□	□	□	✗	✗	□	✗	□	✗	□	□	□	□
13	2015	Electricidad, Desarrollo Rural Y Buen Vivir	México	28	□	□	□	□	✗	□	✗	□	✗	□	□	□	□	✗	□	✗	□	□	✗	□	□	✗	□
14	2014	Redes de Distribución de Energía.	Colombia	41	□	□	□	□	✗	✗	□	□	✗	□	□	□	✗	□	□	✗	□	□	□	□	✗	□	✗
15	2003	Short-term electricity demand forecasting using double seasonal exponential smoothing	Inglaterra	25	✗	✗	✗	□	✗	□	□	□	✗	□	□	□	□	□	✗	□	□	□	□	□	✗	□	□
16	2004	Forecasting daily urban electric load profiles using artificial neural networks	Italia	34	✗	□	✗	□	✗	□	□	□	✗	□	□	□	□	✗	□	□	□	□	□	□	□	✗	□
17	2010	Introducción a Series de Tiempo	Colombia	11	✗	✗	□	□	□	□	✗	□	□	□	□	□	□	□	□	□	□	□	□	□	□	□	□
18	2012	Desarrollo de una metodología que permita determinar en forma previa la condición ARIMA de una o múltiples series de tiempo, en un programa de case excel, para predicciones e inventarios en mantenimiento	Colombia	20	✗	✗	□	□	✗	□	□	✗	□	□	✗	□	□	□	□	✗	□	□	□	□	✗	□	✗
19	2019	Reducing demand uncertainty in the platelet supply chain through artificial neural networks and ARIMA models	Iran	41	✗	✗	✗	□	✗	□	□	□	✗	□	□	□	✗	□	□	✗	□	✗	□	□	✗	□	✗

33	2019	Pronóstico de la demanda en energía y potencia del Sistema Eléctrico Quito	Ecuador	17	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>			
34	2013	Estudio y Gestión de la Demanda Eléctrica	Ecuador	120	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>			
35	2018	Los Diferentes Costos que Tiene la Energía Eléctrica en el Ecuador Considerando los Cambios de la Estructura Actual	Ecuador	31	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>		
36	2018	Estadísticas Anuales Y Multianual Del Sector Eléctrico Ecuatoriano 2018	Ecuador	120	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>			
CANTIDAD:					27	21	14	17	16	15	16	5	14	10	8	9	13	12	6	9	9	11	12	10	9	21	11

4.4 Resumen de Indicadores

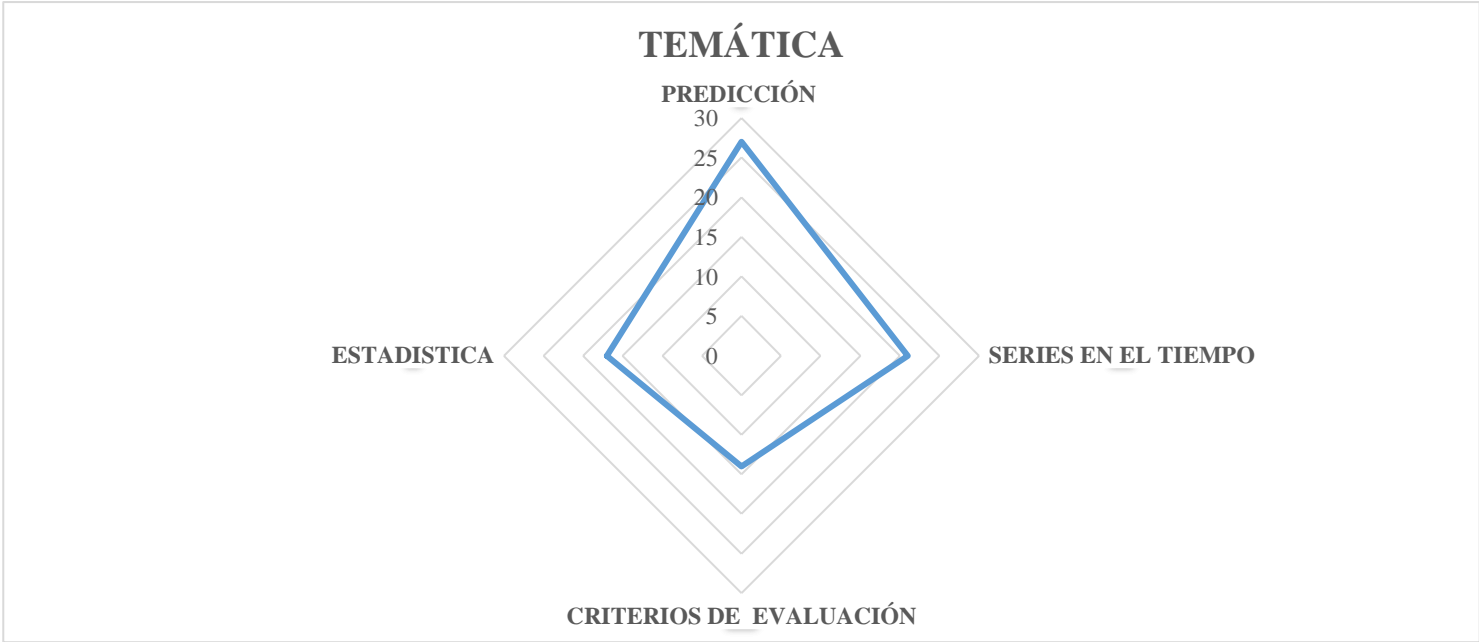


Figura 17. Resumen e indicador de la temática - Estado del arte




Figura 18. Indicador de formulación del problema - Estado del arte




Figura 19. Indicador de solución - Estado del arte