



UNIVERSIDAD POLITÉCNICA SALESIANA

SEDE QUITO

CARRERA DE INGENIERÍA INDUSTRIAL

**EVALUACIÓN DE PRODUCCIÓN DE ENERGÍA RENOVABLE UTILIZANDO
TRES MODELOS AUTORREGRESIVOS**

Trabajo de titulación previo a la obtención del
Título de Ingeniero Industrial

AUTORES: KAROL MISHELL ANDRADE FLORES

LENA VALERIA FLORES CARVAJAL

TUTOR: CRISTIAN CRISTOBAL CUJI CUJI

Quito -Ecuador

2023

**CERTIFICADO DE RESPONSABILIDAD Y AUTORÍA DEL TRABAJO DE
TITULACIÓN**

Nosotros, Karol Mishell Andrade Flores con documento de identificación N° 1750817817 y Lena Valeria Flores Carvajal con documento de identificación N° 1728212943; manifestamos que:

Somos los autores y responsables del presente trabajo; y, autorizamos a que sin fines de lucro la Universidad Politécnica Salesiana pueda usar, difundir, reproducir o publicar de manera total o parcial el presente trabajo de titulación.

Quito, 25 de agosto del año 2023

Atentamente,



Karol Mishell Andrade Flores

1750817817



Lena Valeria Flores Carvajal

1728212943

**CERTIFICADO DE CESIÓN DE DERECHOS DE AUTOR DEL TRABAJO DE
TITULACIÓN A LA UNIVERSIDAD POLITÉCNICA SALESIANA**

Nosotros, Karol Mishell Andrade Flores con documento de identificación No. 1750817817 y Lena Valeria Flores Carvajal con documento de identificación No.

1728212943, expresamos nuestra voluntad y por medio del presente documentocedemos a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que somos autores del Artículo Académico, EVALUACIÓN DE PRODUCCIÓN DE ENERGÍA RENOVABLE UTILIZANDO TRES MODELOS AUTORREGRESIVOS, el cual ha sido desarrollado para optar por el título de: Ingeniero Industrial, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En concordancia con lo manifestado, suscribimos este documento en el momento que hacemos la entrega del trabajo final en formato digital a la Biblioteca de la Universidad Politécnica Salesiana.

Quito, 25 de agosto del año 2023

Atentamente,



Karol Mishell Andrade Flores

1750817817



Lena Valeria Flores Carvajal

1728212943

CERTIFICADO DE DIRECCIÓN DEL TRABAJO DE TITULACIÓN

Yo, Cristian Cristóbal Cuji Cuji, con documento de identificación N° 1718002221 docente de la Universidad Politécnica Salesiana, declaro que bajo mi tutoría fue desarrollado el trabajo de titulación: EVALUACIÓN DE PRODUCCIÓN DE ENERGÍA RENOVABLE UTILIZANDO TRES MODELOS AUTORREGRESIVOS , realizado por Karol Mishell Andrade Flores con documento de identificación N° 1750817817 y por Lena Valeria Flores Carvajal con documento de identificación N° 1728212943, obteniendo como resultado final el trabajo de titulación bajo la opción Artículo Académico, que cumple con todos los requisitos determinados por la Universidad Politécnica Salesiana.

Quito, 25 de agosto del año 2023

Atentamente,



Cristian Cristóbal Cuji Cuji
1718002221

INDICE GENERAL

1. Introducción.....	18
2. Marco Teórico	19
2.1 Modelo matemático.....	20
2.1.1 Criterio F	20
2.1.2 Valor P.....	20
2.1.3 Criterio Bayesiano BIC	21
2.1.4 Criterio Akaike AIK	21
2.2 Modelo Autorregresivo	22
2.2.1 Definición.....	22
2.2.2 Características.....	22
2.2.3 Aplicación.....	22
2.3 Modelos autorregresivos (ARMA, ARIMA, SARIMA).....	23
2.3.1 ARMA	23
2.3.2 ARIMA.....	23
2.3.3 SARIMA.....	25
2.4 Pronóstico.....	25
2.5 Instrumentos meteorológicos	26
2.5.1 Anemómetro	26
2.5.2 Veleta.....	26
2.5.3. Sensores ultrasónicos	26
2.5.4 Piranómetro	26
2.5.5 Heliógrafo.....	26
2.5.6 Pirheliómetro	27
2.5.7 Radiómetro ultravioleta UV	27
2.5.8 Higrotermógrafo	27
2.5.9 Pantalla solar	27
2.5.10 Recurso energético	27
2.6 Energía	27
2.6.1 Eólica.....	27
2.6.2 Solar.....	28
2.6.3 Radiancia	28
2.6.4 Temperatura.....	28

2.6.5	Heurística.....	29
2.7	Estaciones meteorológicas	29
3.	Desarrollo	29
3.1	Solución del problema.....	29
3.2	Desarrollo del modelo matemático	30
3.2.1	Diagrama de flujo.....	31
3.2.2	Seudocódigo del diagrama de flujo	31
3.2.3	Criterios de información de Bayes (BIC) y de Akaike (AIC)	32
3.2.4	Parámetros de modelos autorregresivos: AR, MA, ARMA, ARIMA, SARIMA.....	32
3.3	Base de datos.....	33
3.3.1	Datos diarios de Temperatura, Radiancia y Velocidad de viento.....	33
3.3.2	Datos mensuales de Temperatura, Radiancia y Velocidad de viento.....	34
3.3.3	Datos anuales de Temperatura, Radiancia y Velocidad de viento.....	35
4.	Análisis de resultados	35
4.1	Temperatura.....	35
4.1.1	Temperatura diaria AR	35
4.1.2	Temperatura mensual AR	36
4.1.3	Temperatura anual AR.....	36
4.1.4	Temperatura diaria MA	36
4.1.5	Temperatura mensual MA	37
4.1.6	Temperatura anual MA.....	37
4.1.7	Temperatura diaria ARMA.....	38
4.1.8	Temperatura mensual ARMA.....	38
4.1.9	Temperatura anual ARMA	39
4.1.10	Temperatura diaria ARIMA	39
4.1.11	Temperatura mensual ARIMA.....	40
4.1.12	Temperatura anual ARIMA	40
4.1.13	Temperatura diaria SARIMA	41
4.1.14	Temperatura mensual SARIMA.....	41
4.1.15	Temperatura anual SARIMA.....	42
4.2	Radiancia.....	43
4.2.1	Radiancia diaria AR.....	44

4.2.2 Radiancia mensual AR	44
4.2.3 Radiancia anual AR	44
4.2.4 Radiancia diaria MA.....	45
4.2.5 Radiancia mensual MA	45
4.2.6 Radiancia anual MA	46
4.2.7 Radiancia diaria ARMA	46
4.2.8 Radiancia mensual ARMA.....	47
4.2.9 Radiancia anual ARMA.....	47
4.2.10 Radiancia diaria ARIMA	48
4.2.11 Radiancia mensual ARIMA.....	48
4.2.12 Radiancia anual ARIMA	49
4.2.13 Radiancia diaria SARIMA	49
4.2.14 Radiancia mensual SARIMA	50
4.2.15 Radiancia anual SARIMA	50
4.3 Velocidad de viento.....	51
4.3.1 Velocidad de viento diario AR.....	52
4.3.2 Velocidad de viento mensual AR	52
4.3.3 Velocidad de viento anual AR.....	52
4.3.4 Velocidad de viento diario MA	53
4.3.5 Velocidad de viento mensual MA	53
4.3.6 Velocidad de viento anual MA.....	54
4.3.7 Velocidad de viento diario ARMA.....	54
4.3.8 Velocidad de viento mensual ARMA.....	55
4.3.9 Velocidad de viento anual ARMA	55
4.3.10 Velocidad de viento diario ARIMA	56
4.3.11 Velocidad de viento mensual ARIMA.....	56
4.3.12 Velocidad de viento anual ARIMA	57
4.3.13 Velocidad de viento diaria SARIMA	57
4.3.14 Velocidad de viento mensual SARIMA	58
4.3.15 Velocidad de viento anual SARIMA.....	58
5. Conclusiones.....	62
6. Bibliografías	64

ÍNDICE DE FIGURAS

Figura 1. Proceso de recolección de datos meteorológicos para evaluación de modelos autorregresivos.....	18
Figura 2. Diagrama de Flujo	31
Figura 3 . Temperatura superficial diario AR.....	35
Figura 4. Temperatura superficial mensual AR.....	36
Figura 5. Temperatura superficial anual AR	36
Figura 6. Temperatura superficial diario MA	37
Figura 7. Temperatura superficial mensual MA.....	37
Figura 8. Temperatura superficial anual MA	38
Figura 9. Temperatura superficial diario ARMA	38
Figura 10. Temperatura superficial mensual ARMA	39
Figura 11. Temperatura superficial anual ARMA	39
Figura 12. Temperatura superficial diario ARIMA.....	40
Figura 13. Temperatura superficial mensual ARIMA	40
Figura 14. Temperatura superficial anual ARIMA.....	41
Figura 15. Temperatura superficial diario SARIMA	41
Figura 16. Temperatura superficial mensual SARIMA	42
Figura 17. Temperatura superficial anual SARIMA	42
Figura 18. Diagrama de Barras Temperatura Superficial AIC – BIC	43
Figura 19. Radiancia Global Ave diario AR.....	44
Figura 20. Radiancia Global Ave mensual AR.....	44
Figura 21. Radiancia Global Ave anual AR	45
Figura 22. Radiancia Global Ave diario MA.....	45
Figura 23. Radiancia Global Ave mensual MA.....	46
Figura 24. Radiancia Global Ave anual MA	46
Figura 25. Radiancia Global Ave diario ARMA	47
Figura 26. Radiancia Global Ave mensual ARMA	47
Figura 27. Radiancia Global Ave anual ARMA.....	48
Figura 28. Radiancia Global Ave diario ARIMA.....	48
Figura 29. Radiancia Global Ave mensual ARIMA.....	49
Figura 30. Radiancia Global Ave anual ARIMA.....	49
Figura 31. Radiancia Global Ave diario SARIMA	50
Figura 32. Radiancia Global Ave mensual SARIMA	50
Figura 33. Radiancia Global Ave anual SARIMA	50
Figura 34. Diagrama de Barras Radiancia Global Ave AIC – BIC	51
Figura 35. Velocidad de viento diario AR.....	52
Figura 36. Velocidad de viento mensual AR.....	52
Figura 37. Velocidad de viento anual AR.....	53
Figura 38. Velocidad de viento diario MA.....	53
Figura 39. Velocidad de viento mensual MA.....	54
Figura 40. Velocidad de viento anual MA	54

Figura 41. Velocidad de viento diario ARMA.....	55
Figura 42. Velocidad de viento mensual ARMA.....	55
Figura 43. Velocidad de viento anual ARMA	56
Figura 44. Velocidad de viento diario ARIMA	56
Figura 45. Velocidad de viento mensual ARIMA	57
Figura 46. Velocidad de viento anual ARIMA	57
Figura 47. Velocidad de viento diario SARIMA.....	58
Figura 48. Velocidad de viento mensual SARIMA.....	58
Figura 49. Velocidad de viento anual SARIMA.....	58
Figura 50. Diagrama de Barras Velocidad de viento AIC – BIC	59

ÍNDICE DE TABLAS

Tabla 1. Procesos del pseudocódigo del diagrama de flujo.....	31
Tabla 2. Datos diarios de Temperatura, Radiancia y Velocidad de viento.....	33
Tabla 3. Datos mensuales de Temperatura, Radiancia y Velocidad de viento	34
Tabla 4. Datos anuales de Temperatura, Radiancia y Velocidad de viento	35
Tabla 5. Temperatura Superficial en °C – AR	35
Tabla 6. Temperatura Superficial en °C – MA.....	36
Tabla 7. Temperatura Superficial en °C – ARMA	38
Tabla 8. Temperatura Superficial en °C – ARIMA.....	39
Tabla 9. Temperatura Superficial en °C – SARIMA.....	41
Tabla 10. Radiancia Global Ave en W/m ² – AR	43
Tabla 11. Radiancia Global Ave en W/m ² – MA	45
Tabla 12. Radiancia Global Ave en W/m ² – ARMA	46
Tabla 13. Radiancia Global Ave en W/m ² – ARIMA.....	48
Tabla 14. Radiancia Global Ave en W/m ² – SARIMA.....	49
Tabla 15. Velocidad de viento en m/s – AR.....	51
Tabla 16. Velocidad de viento en m/s – MA.....	53
Tabla 17. Velocidad de viento en m/s – ARMA	54
Tabla 18. Velocidad de viento en m/s – ARIMA	56
Tabla 19. Velocidad de viento en m/s – SARIMA.....	57
Tabla 20. Formulas obtenidas del modelo autorregresivo AR.....	59
Tabla 21. Formulas obtenidas del modelo autorregresivo MA.....	60
Tabla 22. Formulas obtenidas del modelo autorregresivo ARMA	60
Tabla 23. Formulas obtenidas del modelo autorregresivo ARIMA	61
Tabla 24. Formulas obtenidas del modelo autorregresivo SARIMA.....	61

EVALUACIÓN DE RECURSOS RENOVABLES UTILIZANDO UN MODELO AUTORREGRESIVO CON FINES DE PRODUCCIÓN DE ENERGÍA

Resumen

La predicción y análisis de fenómenos climáticos es de vital importancia en la meteorología para entender y anticipar cambios climáticos a lo largo del tiempo. En este contexto, los modelos autorregresivos AR, de media móvil MA, autorregresivos de media móvil ARMA, autorregresivos de media móvil con integración ARIMA y estacionales autorregresivos de media móvil SARIMA han demostrado ser herramientas eficaces y versátiles para el estudio de series temporales climáticas. Estos modelos se fundamentan en la relación entre una observación actual y sus observaciones pasadas, lo que permite capturar patrones temporales y realizar pronósticos precisos sobre variables climáticas como la temperatura, la precipitación y la velocidad del viento, entre otras. En el presente artículo, se investiga la aplicabilidad y eficiencia de los modelos autorregresivos AR, MA, ARMA, ARIMA y SARIMA en el ámbito de la meteorología. Al analizar estos conjuntos de datos, se busca evaluar cómo cada modelo se ajusta y pronostica con precisión los cambios climáticos, con un enfoque particular en el impacto de la temperatura, la radiancia y la velocidad del viento en los patrones climáticos.

Palabras clave: Modelo autorregresivo, Cima, AR, MA, ARMA, ARIMA, SARIMA

Abstract:

The prediction and analysis of weather phenomena is of vital importance in meteorology to understand and anticipate climatic changes over time. In this context, autoregressive AR, moving average MA, autoregressive moving average ARMA, autoregressive integrated moving average ARIMA, and seasonal autoregressive integrated moving average SARIMA models have proven to be effective and versatile tools for studying climatic time series. These models are based on the relationship between current observations and their past observations, allowing them to capture temporal patterns and make accurate forecasts regarding climatic variables such as temperature, precipitation, and wind speed, among others. In this article, we investigate the applicability and efficiency of AR, MA, ARMA, ARIMA, and SARIMA autoregressive models in the field of meteorology. By analyzing these datasets, we aim to evaluate how each model fits and accurately predicts climatic changes, with a particular focus on the impact of temperature, radiation, and wind speed on weather patterns.

Keywords: Autoregressive model, Weather, AR, MA, ARMA, ARIMA, SARIMA.

1. Introducción

El proyecto que se ha realizado, se exploraron los datos para identificar tendencias y patrones estacionales, de manera que se realizó un análisis de datos meteorológicos como: temperatura, radiancia y velocidad de viento, para determinar la estructura de los procesos autorregresivos más adecuados para cada conjunto de datos. Luego, se ajustaron modelos AR, MA, ARMA, ARIMA y SARIMA a los datos climáticos, utilizando técnicas de estimación de parámetros y validación cruzada para obtener modelos óptimos.

El objetivo principal fue comprender y evaluar el comportamiento de las variables de temperatura, radiancia y velocidad del viento a lo largo del tiempo, así como identificar y predecir posibles patrones y tendencias. Para lograr esto, se utilizó una combinación de técnicas de análisis de series temporales y modelos autorregresivos. Se implementaron modelos AR autorregresivos, MA medias móviles, ARMA autorregresivos de media móvil, ARIMA autorregresivos integrados de media móvil y SARIMA autorregresivos integrados de media móvil estacional utilizando las funciones y librerías disponibles en MATLAB.

Cada modelo se ajustó a los datos y se evaluó su rendimiento mediante métricas de ajuste y pronóstico. Se realizaron comparaciones entre los diferentes modelos para determinar cuál de ellos proporcionaba las mejores predicciones y se ajustaba de manera más adecuada a los datos de temperatura, radiancia y velocidad del viento. Los resultados obtenidos permitieron identificar patrones estacionales, tendencias a largo plazo y comportamientos cíclicos en las variables estudiadas. Además, los modelos autorregresivos proporcionaron pronósticos precisos y confiables para las variables de interés.

La presente investigación demostró que los modelos autorregresivos, como AR, MA, ARMA, ARIMA y SARIMA, son herramientas efectivas para el análisis y la predicción de datos de temperatura, radiancia y velocidad del viento. Estos modelos pueden ser útiles en diversas aplicaciones, como la meteorología, el monitoreo ambiental y la toma de decisiones en sectores relacionados con la energía renovable y la planificación urbana [1].



Figura 1. Proceso de recolección de datos meteorológicos para evaluación de modelos autorregresivos

En la **Figura 1** Se observa el proceso para recolectar datos de una estación meteorológica ubicada en la ciudad de Quito con el objetivo de evaluar los recursos energéticos: eólico, temperatura y radiancia, mismos que serán analizados posteriormente por medio de modelos autorregresivos.

2. Marco Teórico

El diseño de este sistema implica una serie de tareas de minería de datos, incluida la recopilación, limpieza y transformación de datos al formato deseado. Se aplica reducción de dimensionalidad para seleccionar solo las características relevantes antes de usar algoritmos de pronóstico para construir, AR, MA, ARMA, ARIMA, SARIMA.

La creciente preocupación por el cambio climático y la necesidad de reducir la dependencia de fuentes de energía no renovables han impulsado el desarrollo de tecnologías más limpias y sostenibles. En este contexto, las fuentes de energía renovables, como la solar y la eólica, han cobrado una relevancia significativa en la búsqueda de soluciones energéticas sostenibles. Sin embargo, la variabilidad y la incertidumbre asociadas a estas fuentes de energía plantean desafíos en su integración eficiente en la red eléctrica.

Se tiene como objetivo desarrollar y aplicar modelos autorregresivos para la evaluación de recursos renovables, específicamente la energía solar y eólica, con el fin de predecir su disponibilidad y variabilidad. Se pretende utilizar datos de temperatura y radiación como variables clave para identificar el potencial de los recursos renovables y determinar su contribución específica al suministro de energía renovable, así como evaluar la viabilidad de su implementación en el sistema energético.

Modelos autorregresivos aplicados a recursos renovables: Los modelos autorregresivos han demostrado ser herramientas efectivas en el análisis y predicción de series temporales, siendo ampliamente utilizados en diversas áreas, como la economía, la meteorología y la ingeniería. En este contexto, se plantea su aplicación para evaluar las características temporales y la variabilidad de los recursos renovables.

- Modelo ARMA Auto-Regresión Media Móvil:

El modelo ARMA combina componentes autorregresivos AR y de media móvil MA para capturar tanto la dependencia de valores pasados como el ruido presente en la serie temporal. Este enfoque permitirá analizar la variación de la generación de energía renovable en función de la temperatura y la radiación solar y eólica.

- Modelo ARIMA Auto-Regresión Integrada Media Móvil:

El modelo ARIMA extiende el ARMA al incorporar la integración (I) de la serie temporal. Esto permite abordar posibles tendencias presentes en los datos, como la estacionalidad, que podrían influir en la disponibilidad de energía renovable.

- Modelo SARIMA Seasonal Auto-Regresión Integrada Media Móvil:

El modelo SARIMA amplía el ARIMA al considerar componentes de estacionalidad. Dado que las fuentes de energía renovable, especialmente la solar y la eólica, exhiben patrones estacionales, este enfoque será crucial para evaluar su producción y variabilidad a lo largo del tiempo [2], [3].

2.1 Modelo matemático

Los modelos matemáticos se utilizan para describir, analizar y predecir el comportamiento de sistemas complejos, proporcionando una estructura y un marco para comprender su funcionamiento utilizando ecuaciones matemáticas y relaciones lógicas. La relación entre un modelo autorregresivo y un modelo matemático es que el modelo matemático se aplica a series de tiempo. Es una representación matemática que describe como los valores pasados de una serie de tiempo afectan al valor actual y futuro de esa serie [4].

2.1.1 Criterio F

Basado en el análisis de varianza ANOVA, se utiliza para comparar dos modelos: uno que incluye ciertas variables predictoras y otro que no las incluye. El criterio F permite determinar si la inclusión de esas variables predictoras mejora significativamente el ajuste del modelo, es decir que compara la varianza explicada por el modelo con la varianza no explicada o residual. Cuanto mayor sea el valor estadístico F, mayor será la evidencia de que el modelo con las variables predictoras incluidas es significativamente mejor que el modelo sin ellas.

El criterio F se calcula dividiendo la diferencia entre los RSS de los dos modelos por la diferencia de grados de libertad. Si el valor calculado del estadístico F es mayor que un valor crítico determinado a partir de las tablas de distribución F o mediante pruebas de hipótesis, se puede concluir que las variables predictoras incluidas en el modelo mejoran significativamente el ajuste. Un valor alto del estadístico F indica que el modelo con las variables predictoras incluidas es preferible al modelo sin ellas [5].

2.1.2 Valor P

Es una medida de probabilidad que indica la evidencia en contra de una hipótesis nula. En el contexto de los modelos matemáticos, el valor p se utiliza para evaluar la significancia de los coeficientes de regresión o de otras estimaciones obtenidas a partir de modelo, en el análisis de regresión lineal, se calculan los coeficientes de regresión que representan la relación entre las variables predictoras y la variable de respuesta. El valor p asociado a cada coeficiente indica la probabilidad de que el coeficiente sea igual a cero en la población subyacente.

Si el valor p asociado a un coeficiente es menor que un umbral de significancia predefinido como 0.05 o 0.01, se considera que el coeficiente es estadísticamente significativo y que hay evidencia suficiente para rechazar la hipótesis nula de que el coeficiente sea igual a cero. En este caso, se puede concluir que el coeficiente tiene un efecto significativo en el modelo.

Es importante tener en cuenta que el valor p no indica la magnitud o relevancia práctica del efecto es estadísticamente significativo o no. Un coeficiente puede tener un valor p significativo pero un efecto práctico pequeño o viceversa [6].

2.1.3 Criterio Bayesiano BIC

El criterio Bayesiano permite tomar decisiones y calcular la distribución marginal a posteriori para cada parámetro del modelo y utilizarla para estimar los valores posteriores para cada parámetro del modelo y utilizarla para estimar los valores posteriores más probables, por ejemplo, la media o la mediana de la distribución y sus intervalos de credibilidad.

Una ventaja del enfoque Bayesiano es que proporciona una forma natural de incorporar información previa y conocimiento experto en el modelo. Las distribuciones a priori pueden basarse en estudios previos, datos históricos o suposiciones fundamentales sobre los parámetros. A medida que se acumulan más datos, la influencia de las distribuciones a priori disminuye y la influencia de los datos observados aumenta. Esta distribución tiene en cuenta la incertidumbre en los parámetros del modelo y proporciona intervalos de predicción que reflejan esta incertidumbre y la incorporación de información previa [7].

Cuando el criterio BIC es mayor:

Indica que el modelo no es adecuado para los datos en comparación con otro modelo con un BIC más bajo. Además, el criterio BIC penaliza la complejidad del modelo más que el AIC, por lo que un BIC más grande indica un modelo más complejo que puede sobre ajustar los datos.

Cuando el criterio BIC es menor:

Indica que el modelo se ajusta mejor a los datos que otro modelo con un BIC más alto. Además, el criterio BIC penaliza aún más la complejidad del modelo, lo que sugiere que los BIC más bajos indican modelos más simples y posiblemente mejores.

2.1.4 Criterio Akaike AIC

El criterio de Akaike es una herramienta estadística utilizada para la selección de modelos, que permite determinar cuál es el modelo más adecuado para un conjunto de datos. En este artículo académico, se explora su aplicación en modelos autorregresivos AR, modelos de media móvil MA, modelos ARMA, modelos ARIMA y modelos estacionales ARIMA, SARIMA. Se analizan los fundamentos del criterio de Akaike y su interpretación, junto con su relación con estos modelos autorregresivos y su importancia en la toma de decisiones estadísticas [8], [9].

Cuando el criterio AIC es mayor:

Indica que el modelo no es adecuado para los datos en comparación con otro modelo con un AIC más bajo, puede indicar que el modelo es más complejo o se ajusta mal a los datos y en general, un AIC alto indica un equilibrio deficiente entre el ajuste y la complejidad de los datos del modelo, lo que puede conducir a un ajuste excesivo.

Cuando el criterio AIC es menor:

Indica que el modelo se ajusta mejor a los datos que otro modelo con un AIC más alto, sugiere que el modelo es adecuado para describir patrones y tendencias en datos con complejidad reducida y en general, un AIC más bajo indica un mejor equilibrio entre el ajuste del modelo y la simplicidad de los datos, y más confianza en el modelo.

2.2 Modelo Autorregresivo

2.2.1 Definición

Los modelos de autorregresión también conocidos como modelos AR, se utiliza para realizar pronósticos sobre varias ex-post observaciones que conocemos completamente su valor en determinados momentos del tiempo normalmente ordenados cronológicamente.

Son modelos que se regresan en sí mismos. Es decir, la variable dependiente y la variable explicativa son la misma con la diferencia que la variable dependiente está en un momento del tiempo posterior t al de la variable independiente $t-1$. Ordenados cronológicamente porque actualmente se encuentran en el momento t del tiempo. Si avanzamos un período nos trasladamos a $t+1$ y si se retrocede un período se va a $t-1$.

Los procesos autorregresivos presentan función de autocorrelación parcial ACFP con un número finito de valores distintos de cero y los demás son nulos. Esta afirmación es muy fuerte, y en la práctica se considera que una muestra dada proviene de un proceso autorregresivo de orden p si los términos de la función de autocorrelación parcial son casi cero a partir del que ocupa lugar p . Un valor se considera casi cero cuando su módulo es inferior a $2/T$. Los programas de ordenador constituyen la franja $-2/T; 2/T$ y detectan los valores de la ACFP que caen fuera de ella.

Los procesos de medias móviles presentan función de autocorrelación con un número finito de valores distintos de cero. Un proceso MA q tiene los primeros q términos de la función de autocorrelación distintos de cero y los demás son nulos, Las dos propiedades descritas son muy importantes con vistas a la identificación de un proceso mediante el análisis de las funciones de autocorrelación y autocorrelación parcial [10], [11], [12].

2.2.2 Características

Los modelos autorregresivos, se caracterizan por ser: modelos que regresan en sí mismos; basan sus predicciones únicamente en información pasada así mismo poseen una variable dependiente y una variable explicativa. Se catalogan como AR p , donde p recibe la etiqueta de "orden" y equivale al número de períodos los cuales va a retroceder para llevar a cabo el pronóstico de la variable. Los modelos autorregresivos también se caracterizan porque son considerados "ateóricos", ya que su especificación se basa en datos más que en teoría. Son capaces de reflejar los mecanismos generados del proceso. La utilidad de los modelos autorregresivos está sujeta a las condiciones de estacionariedad [13].

2.2.3 Aplicación

En cuanto a la aplicación de los modelos autorregresivos es importante conocer que estos predicen valores futuros basados en valores pasados y se emplean ampliamente en el análisis técnico para predecir los precios futuros de las acciones. Los modelos autorregresivos asumen implícitamente que el futuro se parecerá al pasado; por tanto, se operan bajo la premisa de que los valores pasados tienen un efecto sobre los valores presentes, lo que populariza la técnica estadística para analizar la naturaleza, la economía y otros procesos que varían en el tiempo [14].

2.3 Modelos autorregresivos ARMA, ARIMA, SARIMA

2.3.1 ARMA

Responde al concepto en inglés AutoRegressive Moving Average cuyas siglas son ‘‘ARMA’’. Es definido por ser un modelo estacionario donde las variables independientes siguen tendencias estocásticas y el término de error estacionario. Esto se traduce a que incorpora en su regresión la autocorrelación y el modelo de media móvil.

En este sentido, los modelos ARMA, se construyen a partir de la información que aportan estas funciones, y se utilizan para explicar la estructura teórica temporal de la serie y predecir su comportamiento futuro a corto plazo. Matemáticamente se parte del modelo autorregresivo ARMA p, q :

$$Y(t) = c + \varphi_1 Y(t - 1) + \varphi_2 Y(t - 2) + \dots + \varphi_p Y(t - p) + \varepsilon(t) \quad (1)$$

Donde:

- $Y(t)$ es el valor de la serie de tiempo en el momento t .
- $Y(t-1), Y(t-2), \dots, Y(t-p)$ son los valores anteriores de la serie de tiempo hasta p períodos atrás.
- c es una constante o intercepto en el modelo.
- $\varphi_1, \varphi_2, \dots, \varphi_p$ son los coeficientes autorregresivos del modelo, controlan la influencia de los valores pasados de la serie de tiempo en el valor actual.
- $\varepsilon(t)$ es el término de error en el momento t .

Para los modelos que describen procesos estocásticos estacionarios, la representación matemática consiste en dos partes: una que permite recoger la regularidad del proceso llamada a veces parte sistemática, y otra puramente aleatoria, denominada innovación, conformada por una secuencia de valores que no tienen ninguna relación o dependencia entre sí

2.3.2 ARIMA

Conocido como Autorregressive Integrated Average en inglés cuyas siglas responde a ‘‘ARIMA’’. Un proceso estocástico homogéneamente no estacionario puede ser reducido a un proceso estacionario tomando un grado adecuado de diferenciación. Se da así inicio al estudio de

los modelos. Permite describir un valor como una función lineal de datos anteriores y errores debidos al azar, además, puede incluir un componente cíclico o estacional.

La metodología de Box y Jenkins se resume en cuatro fases:

- La primera fase consiste en identificar el posible modelo ARIMA que sigue la serie, lo que requiere: Decidir qué transformaciones aplicar para convertir la serie observada en una serie estacionaria y determinar un modelo ARMA para la serie estacionaria, es decir, los órdenes p y q de su estructura autorregresiva y de media móvil.
- La segunda fase: Seleccionando provisionalmente un modelo para la serie estacionaria, se pasa a la segunda etapa de estimación donde los parámetros AR y MA del modelo que se estiman por máxima verosimilitud y se obtienen sus errores estándar y los residuos del modelo.
- La tercera fase: es el diagnóstico, donde se comprueba que los residuos no tienen estructura de dependencia y siguen un proceso de ruido blanco. Si los residuos muestran estructura se modifica el modelo para incorporarla y se repiten las etapas anteriores hasta obtener un modelo adecuado.
- La cuarta fase: es la predicción, una vez que se ha obtenido un modelo adecuado se realizan predicciones con el mismo.

Matemáticamente este modelo descompone valores p, d, q que se consideran más apropiados y se deben encontrar en la operación; si la serie temporal presenta una tendencia, lo primero que debe de hacerse es convertirla en estacionaria mediante una diferenciación de orden [15], [16], [17], [18].

- ARIMA p, d, q:

$$Y(t) = c + \varphi_1 Y(t-1) + \varphi_2 Y(t-2) + \dots + \varphi_p Y(t-p) + \Phi_1 \varepsilon(t-1) + \Phi_2 \varepsilon(t-2) + \dots + \Phi_q \varepsilon(t-q) + \varepsilon(t) \quad (2)$$

Donde:

- Y(t) es el valor de la serie de tiempo en el momento t.
- Y(t-1), Y(t-2), ..., Y(p) son los valores anteriores de la serie de tiempo hasta p períodos atrás.
- $\varepsilon(t-1)$, $\varepsilon(t-2)$, ..., $\varepsilon(t-q)$ son los errores anteriores del modelo, hasta q períodos atrás.
- c es una constante o intercepción del modelo
- $\varphi_1, \varphi_2, \dots, \varphi_p$ son los coeficientes de la parte autorregresiva del modelo. Controlan la influencia de los valores pasados de la serie de tiempo en el valor actual.
- $\varepsilon(t)$ es el término de error en el momento t.

2.3.3 SARIMA

Basado en el nombre Seasonal Autorregresive Integrated Moving Average cuyas siglas son SARIMA, es uno de los modelos autorregresivos que captan el comportamiento puramente estacional d una serie, en forma similar, como hemos visto, se realiza para la componente regular o no estacional. Una serie con influencia solamente por la componente estacional puede ser descrito por un modelo SARIMA P, D, Q, el cual se lo representa de la siguiente manera:

$$\begin{aligned} \cdot \text{ SARIMA } (p, d, q) \times (P, D, Q)Y(t) = c + \varphi_1 Y(t-1) + \varphi_2 Y(t-2) + \dots + \varphi_p Y(t-p) - \theta_1 \varepsilon(t-1) - \theta_2 \varepsilon(t-2) - \dots - \theta_q \varepsilon(t-q) + \\ (\varphi_1 h_p Y(t-s) + \varphi_2 h_p Y(t-2s) + \dots + \varphi_p h_p Y(t-ps)) - (\theta_1 h_p \varepsilon(t-s) + \theta_2 h_p \varepsilon(t-2s) + \dots + \theta_p h_p \varepsilon(t-ps)) + \varepsilon(t) \end{aligned} \quad (3)$$

$$(1 - \phi_1 L - \phi_2 L^2) y_t = c + \varepsilon_t \quad (4)$$

Donde:

- Y(t) es el valor de la serie de tiempo en el momento t.
- Y (T-1), Y (t-2), Y (t-p) son los valores anteriores de la serie de tiempo hasta p períodos atrás.
- c es una constante o intercepto en el modelo.
- $\varepsilon(t)$ es el término de error en el momento t.
- s es el período de estacionalidad de la serie de tiempo.

2.4 Pronóstico

Los pronósticos se elaboran utilizando datos históricos, modelos matemáticos, análisis estadístico y otras herramientas para integrar predecir cómo se desarrollará una situación en el futuro. Si bien los pronósticos no pueden predecir el futuro con certeza absoluta, se utilizan para tomar decisiones informadas y planificar estrategias en función de las tendencias y patrones identificados.

El pronóstico por medio de modelos autorregresivos es un enfoque utilizado en el análisis de series de tiempo para predecir valores futuros en función de valores pasados de la misma serie. Estos modelos se basan en la suposición de que los valores futuros de la serie dependen linealmente de los valores anteriores, es decir, que cada valor se explica por una combinación lineal de los valores previos.

Los modelos autorregresivos se representan comúnmente como Ar p, donde ‘‘AR’’ significa autorregresivo y ‘p’ indica el orden del modelo, es decir, la cantidad de valores pasados que se utilizan para predecir valor futuro. Para construir un pronóstico utilizando un modelo AR

p, se realiza utilizando técnicas estadísticas, como el método de mínimos cuadrados o el método de máxima verosimilitud. Una vez que se han estimado los coeficientes, se pueden realizar pronósticos para un número determinado de períodos futuros.

La estimación de los coeficientes del modelo AR p, se realizan utilizando técnicas estadísticas, como el método de mínimos cuadrados o el método de máxima verosimilitud. Una vez que se han estimado los coeficientes, se pueden realizar pronósticos para un número determinado de períodos futuros.

Es importante destacar que los modelos autorregresivos asumen que la serie de tiempo es estacionaria, lo que significa que la media y la varianza de la serie no cambian con el tiempo. Además, la validez y precisión de los pronósticos obtenidos a través de modelos autorregresivos dependen de la calidad de los datos utilizando y de la adecuación del modelo elegido para representar la estructura subyacente de la serie de tiempo [19], [20], [21].

2.5 Instrumentos meteorológicos

2.5.1 Anemómetro

Instrumento para medir la velocidad o rapidez de los gases ya sea en un flujo contenido, como el flujo de aire en conducto, o en flujos no confinados, como un viento atmosférico. La dirección del viento se define como la dirección de donde sopla el viento y se mide en grados sexagesimales $0^\circ - 360^\circ$, a partir del norte geográfico ver rosa de los vientos. En meteorología la velocidad del viento se reporta en metros por segundo m/s o en nudos kn, en donde 1 kn es igual a 1.94384 m/s [22], [23], [24].

2.5.2 Veleta

Determina la dirección horizontal de donde proviene el viento.

2.5.3. Sensores ultrasónicos

Los aquí mostrados miden la velocidad y dirección del viento en m/s.

2.5.4 Piranómetro

Mide la radiación solar global componentes directa y difusa proviene de la bóveda celeste w/m^2 . También es usado para determinar cada una de dichas componentes por separado y para medir el albedo de superficies.

2.5.5 Heliógrafo

Registra el tiempo horas durante el cual se presenta radiación directa del sol, mayor a 120 vatios por metro cuadrado W/m^2 , lo que se denomina brillo solar.

2.5.6 Pirheliómetro

Mide la componente directa de la radiación solar, perpendicular a los rayos del sol.

2.5.7 Radiómetro ultravioleta UV

Mide la radiación solar de longitud de onda menor a 0.4 μm .

2.5.8 Higrotermógrafo

Instrumento mecánico que mide y gráfica en forma continua, valores de temperatura y humedad relativa del aire [25].

2.5.9 Pantalla solar

Es una cubierta para sensores que miden temperatura y humedad. Esta pantalla protege los sensores del efecto del sol, para que no altere las mediciones.

2.5.10 Recurso energético

Comprenden el conjunto de sustancias que pueden ser empleadas como fuente de energía a través de distintos procesos de índole física o química descubiertos por el ser humano, Se trata de un tipo de sustancias que tienen generalmente un origen natural, pero que a través de la industria permiten obtener energía, especialmente energía eléctrica y calórica [26].

2.6 Energía

Es la capacidad de los cuerpos para realizar un trabajo y producir cambios en ellos mismos o en otros cuerpos. Es decir, el concepto de energía se define como la capacidad de hacer funcionar las cosas.

La energía se crea en centrales capaces de obtener energía eléctrica a partir de energías primarias. Las llamadas energías primarias renovables son el viento, la radiación solar, las mareas y las no-renovables son el carbón, el gas natural, el petróleo [27], [28], [29], [30].

2.6.1 Eólica

Constituye la energía obtenida del viento. Es uno de los recursos energéticos más antiguos explotados por el ser humano y es hoy en día la energía más madura y eficiente de todas las energías renovables. La energía eólica no emite sustancias tóxicas ni contaminantes del aire, que pueden ser muy perjudiciales para el medio ambiente y el ser humano.

La disponibilidad del viento es variable y depende de la ubicación geográfica, lo que puede limitar la viabilidad de la energía eólica en ciertas regiones. Se requiere una infraestructura adecuada, como líneas de transmisión, para llevar la electricidad generada por la energía eólica a los lugares donde necesita [31].

2.6.2 Solar

La energía solar es la producida por la luz o el calor del sol para la generación de electricidad o la producción de calor. Inagotable y renovable, pues procese del sol, se obtiene por medio de paneles y espejos.

Las células solares fotovoltaicas convierten la luz del sol directamente en electricidad por el llamado efecto fotoeléctrico, por el cual determinados materiales son capaces de absorber fotones partículas lumínicas y liberar electrones, generando una corriente eléctrica. Por otro lado, los colectores solares térmicos usan paneles o espejos para absorber y concentrar el calor solar, transferirlo a un fluido y conducirlo por tuberías para su aprovechamiento en edificios e instalaciones o también para la producción de electricidad solar termoeléctrico [32].

2.6.3 Radiancia

Denotada comúnmente como L , la radiancia describe la cantidad de energía radiante que emite, refleja o transmite una superficie en una determinada dirección. Es una medida de la potencia radiante por unidad de ángulo sólido lo que significa que su valor puede variar según la dirección en la que se mida.

La radiancia se expresa en vatios por metro cuadrado por estereorradián $\frac{W}{m^2}/sr$, es una medida fundamental en radiometría y se utiliza en una variedad de aplicaciones, como la medición de la radiación solar, la caracterización de la emisión y reflexión de superficies, y el diseño de sensores hoy detectores de luz [33], [34].

2.6.4 Temperatura

La temperatura es una medida de la intensidad de calor o del frío en un cuerpo, objeto o ambiente. Es una propiedad física que está relacionada con el nivel de energía cinética de las partículas que componen una sustancia. Cuanto mayor es la energía cinética promedio de las partículas, más alta es la temperatura.

La medición de la temperatura en modelos autorregresivos generalmente se realiza mediante la recolección de datos de temperatura en intervalos regulares, como horas, días o meses. La temperatura se puede representar como una variable dependiente en un modelo autorregresivo, donde se utiliza el valor futuro. En este caso, la temperatura se considera una serie temporal y se aplica el concepto de autocorrelación, que es la relación entre los valores de la serie en diferentes modelos.

Al aplicar un modelo autorregresivo, se busca encontrar una relación matemáticamente que describa cómo los valores pasados de la temperatura afectan al valor actual y a los valores futuros. La formulación matemáticamente exacta del modelo autorregresivo depende del orden del modelo denotado por p , que indica cuántos valores pasados se utilizan en la predicción. [35], [36], [37].

2.6.5 Heurística

La heurística es un método de resolución de problemas que utiliza atajos mentales o reglas generales para encontrar soluciones, aunque no garantice la solución óptima. En el contexto de un modelo autorregresivo, las heurísticas pueden ser utilizadas en varias etapas del proceso de análisis y predicción de series de tiempo.

Las heurísticas son muy útiles para identificar patrones o características importantes en los datos de la serie de tiempo, como por ejemplo para detectar estacionalidad, tendencias o cambios estructurales en los datos, lo que puede influir en la elección del modelo autorregresivo o en la selección de variables adicionales a considerar.

La heurística puede desempeñar un papel en diferentes aspectos de un modelo autorregresivo, como la selección del orden del modelo, la identificación de patrones en los datos y las interpretaciones de los resultados y todo esto con el fin de combinar métodos estadísticos para obtener resultados más sólidos [38], [39].

2.7 Estaciones meteorológicas

Constituyen un conjunto de dispositivos o instrumentos que recoge los datos de distintas variables atmosféricas que son de interés para la meteorología y la climatología. Pueden estar instaladas en cualquier terreno y parte del mundo y como veremos posteriormente existen varios tipos. En lo que respecta a la utilidad principal de una estación meteorológica es recoger y registrar datos meteorológicos.

La función de las estaciones meteorológicas es conocer de forma exacta las condiciones meteorológicas de ese lugar en un momento dado, con el fin de comparar esa información con otras estaciones de lugares cercanos para conocer las diferencias climáticas, Así mismo aportar información para realizar los pronósticos de modelos meteorológicos.

Por otra parte, las estaciones meteorológicas proporcionan datos a los modelos meteorológicos, tales como el ECWMF o el GFS, para que realicen los cálculos de los pronósticos, crean información climática representativa del lugar en donde se toman los datos; crean alertas específicas ante fenómenos meteorológicos que pudieran ser de interés y correlacionar fenómenos meteorológicos con situaciones de riesgo, accidentes, destrucción de infraestructura, etc. La medición continua de los datos atmosféricos permite a lo largo del tiempo medir los posibles cambios por el cambio climático u otros fenómenos [40].

3. Desarrollo

3.1 Solución del problema

El estudio de los procesos autorregresivos es esencial para comprender y modelar variables climáticas. Estos modelos se basan en la idea de que los valores pasados de una variable son predictores relevantes de los valores futuros. El uso de MATLAB ofrece una plataforma flexible y

poderosa para la implementación y análisis de estos modelos. En este trabajo, se investigará la teoría detrás de los modelos autorregresivos y se desarrollarán implementaciones prácticas utilizando datos de temperatura, radiancia y velocidad de viento [41].

3.2 Desarrollo del modelo matemático

1. Se recopilarán conjuntos de datos históricos de temperatura, radiancia y velocidad de viento de fuentes confiables y relevantes para la ubicación geográfica de interés.
2. Se realizará un análisis exploratorio de los datos para comprender sus características y detectar posibles problemas, como valores atípicos o datos faltantes.
3. Se implementarán los modelos AR, MA, ARMA, ARIMA y SARIMA utilizando las funciones y herramientas proporcionadas por MATLAB.
4. Se ajustarán los parámetros de los modelos utilizando técnicas de estimación, como el método de mínimos cuadrados o máxima verosimilitud.
5. Se evaluará el rendimiento de los modelos utilizando métricas adecuadas, como el error cuadrático medio MSE o el coeficiente de determinación R^2 .
6. Se realizarán comparaciones entre los diferentes modelos y se seleccionará el más adecuado para la predicción de cada variable climática.
7. Se realizarán pronósticos a corto y largo plazo utilizando los modelos seleccionados y se evaluará su precisión mediante técnicas de validación cruzada u otros métodos apropiados.
8. Se espera que este estudio proporcione una comprensión profunda de los modelos autorregresivos y su aplicabilidad en la predicción de variables climáticas. Además, se espera obtener modelos precisos y confiables para la predicción de temperatura, radiancia y velocidad de viento utilizando los datos recopilados. Los resultados obtenidos podrían tener aplicaciones prácticas en la planificación y toma de decisiones en diversos campos, como la agricultura, la energía renovable y la gestión de desastres naturales [42].

3.2.1 Diagrama de flujo

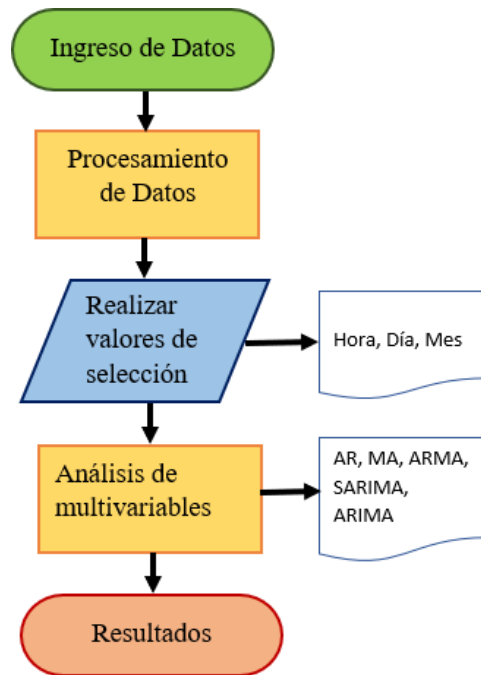


Figura 2. Diagrama de Flujo

En la **Figura 2** para modelos autorregresivos AR, de media móvil MA, ARMA, ARIMA y SARIMA en series temporales. Comienza con el análisis exploratorio para entender patrones. Luego, verifica la estacionariedad y aplica diferenciación si es necesario. Identifica patrones AR, MA y ARMA mediante gráficos ACF y PACF. Finalmente, elige el modelo más adecuado para el análisis.

3.2.2 Seudocódigo del diagrama de flujo

Tabla 1. Procesos del pseudocódigo del diagrama de flujo

1	Ingreso de datos	-Recopilación de datos de la estación meteorológica -Organización de datos
2	Procesamiento de datos	-Eliminar datos y símbolos arbitrarios erróneos -Verificación de datos
3	Realizar valores de selección	-24 horas -12 meses -5 años
4	Análisis de multivariantes	En el econometrix se utilizó los modelos autorregresivo AR, MA ARMA, ARIMA y SARIMA
5	Resultados	-Grafica de los pronósticos diarios de Temperatura, Radiancia y Velocidad de viento - Grafica de los pronósticos mensuales de Temperatura, Radiancia y Velocidad de viento - Grafica de los pronósticos anuales de Temperatura, Radiancia y Velocidad de viento

En la **Error! Reference source not found.**, se ha creado el pseudocódigo del diagrama de flujo donde nos indica los 5 procesos que se realizan con cada una de las descripciones respectivas.

3.2.3 Criterios de información de Bayes BIC y de Akaike AIC

La presente investigación se centra en la comparación de dos importantes criterios de información utilizados en el análisis de series temporales para seleccionar modelos autorregresivos AR. El objetivo principal de este estudio es analizar y contrastar el rendimiento del Criterio de Información de Akaike AIC con el Criterio de Información de Bayes BIC en la selección de modelos AR que mejor se ajusten a los datos observados.

En la primera parte del trabajo, se realiza una exhaustiva revisión de la literatura existente en torno a los criterios de información, los modelos autorregresivos y el análisis de series temporales. Se explora en detalle la fundamentación teórica de cada criterio y se examinan estudios previos que han abordado la comparación de ambos criterios en diversos contextos.

Posteriormente, se lleva a cabo un estudio empírico utilizando datos reales de una serie temporal de naturaleza económica. Se implementan varios modelos autorregresivos con distintos órdenes y se calcula tanto el AIC como el BIC para cada modelo. A través de un análisis comparativo de los resultados obtenidos, se evalúa la calidad del ajuste y la complejidad del modelo seleccionado por cada criterio.

Los hallazgos revelan que tanto el AIC como el BIC son capaces de seleccionar modelos AR apropiados para representar los datos observados. No obstante, se observa una tendencia del BIC a favorecer modelos más sencillos en comparación con el AIC. Esto sugiere que el BIC podría ser una alternativa más conservadora y efectiva en situaciones donde se dispone de datos limitados, evitando así el sobreajuste.

Además, se presentan las ventajas y limitaciones inherentes a cada criterio y se ofrecen recomendaciones para la elección adecuada del criterio de información, considerando las características específicas de los datos y los objetivos del análisis.

Esta investigación profundiza en el conocimiento de los criterios de información AIC y BIC en el contexto de modelos autorregresivos. Los resultados obtenidos pueden ser de gran utilidad para investigadores y profesionales que trabajen con análisis de series temporales, brindándoles una base informada para la selección de modelos apropiados acorde a sus datos específicos [43], [44].

3.2.4 Parámetros de modelos autorregresivos: AR, MA, ARMA, ARIMA, SARIMA

Los resultados obtenidos revelaron que los modelos AR, MA, ARMA, ARIMA y SARIMA fueron capaces de capturar patrones y tendencias presentes en los datos de temperatura, radiancia y velocidad de viento. Sin embargo, cada modelo presentó características distintas en términos de complejidad y precisión en la predicción:

- El modelo AR mostró un buen rendimiento al considerar la relación entre una observación actual y sus observaciones previas. Este modelo fue útil para identificar dependencias temporales en las variables climáticas estudiadas.
- El modelo MA, por otro lado, demostró su eficacia en el manejo de componentes aleatorios o ruido en los datos. Este modelo se destacó al capturar las fluctuaciones estacionales y eliminar tendencias a largo plazo.
- El modelo ARMA, que combina las características del AR y MA, permitió una mayor flexibilidad en la representación de la variabilidad de las variables climáticas y se mostró efectivo para series temporales con patrones de dependencia temporal y componentes aleatorios.
- Con respecto al modelo ARIMA, se observó que la incorporación del componente de integración permitió tratar eficazmente las tendencias no estacionarias en los datos de temperatura, radiancia y velocidad de viento. Esto condujo a una mejor estacionalidad y estacionariedad en los residuos del modelo.
- Finalmente, el modelo SARIMA, que incluye la componente estacional, demostró una alta capacidad para capturar las variaciones recurrentes y patrones estacionales presentes en los datos climáticos analizados. Esto resultó en una mejora significativa en la precisión de las predicciones a corto plazo [45], [46], [47], [48].

3.3 Base de datos

En esta investigación, se utilizó una base de datos robusta y confiable para abordar un problema de modelos autorregresivos, incluyendo AR, MA, ARMA, ARIMA y SARIMA. Los resultados obtenidos demostraron que estos modelos son herramientas poderosas para analizar y predecir series temporales complejas, proporcionando una comprensión profunda de los patrones y tendencias presentes en los datos. La selección adecuada de cada modelo permitió una mejor aproximación a la realidad y una mejora significativa en la precisión de las predicciones. Estos hallazgos destacan la importancia de utilizar enfoques adecuados para el análisis de series temporales y su potencial aplicación en diversas áreas como meteorología, economía, salud y más. Sin embargo, se destaca la necesidad de validar y ajustar los modelos cuidadosamente para garantizar la confiabilidad y utilidad de las conclusiones obtenidas.

3.3.1 Datos diarios de Temperatura, Radiancia y Velocidad de viento

Tabla 2. Datos diarios de Temperatura, Radiancia y Velocidad de viento

Temperatura Superficial (°C)	Radiancia Global Ave (W/m ²)	Velocidad de viento (m/s)
10,426667	0,007117	2,157100
10,144726	0,007543	3,644700
9,828260	0,006381	0,888999

9,494069	0,006758	1,244444
9,276344	1,279605	0,735200
10,131922	31,103808	3,982800
12,766582	160,948850	1,388400
17,556168	407,256685	1,008300
21,158236	631,434818	2,226600
24,124672	771,566819	1,862100
25,854495	783,068619	1,458600
25,136703	690,032620	1,134200
23,430037	590,287418	1,029500
21,576547	501,403350	0,578900
19,454939	358,053797	3,353700
17,204567	215,926618	2,053200
15,408193	91,224103	2,701100
13,723767	15,088919	1,888100
12,829225	0,063852	1,248600
12,337906	0,014151	0,420300
11,957068	0,009970	0,868100
11,532220	0,008090	2,650900
11,130341	0,009970	2,242600
10,770286	0,008808	2,164700

En la **Tabla 2**, se presenta los valores diarios de tres importantes parámetros climáticos: Temperatura, Radiancia y Velocidad de viento. Estos datos son cruciales para analizar el comportamiento climático y comprender las condiciones atmosféricas en una ubicación específica.

3.3.2 Datos mensuales de Temperatura, Radiancia y Velocidad de viento

Tabla 3. Datos mensuales de Temperatura, Radiancia y Velocidad de viento

MESES	Temperatura Superficial (°C)	Radiancia Global Ave (W/m ²)	Velocidad de viento (m/s)
ENERO	13,948627	204,973571	2,76111111
FEBREO	14,105895	199,619035	3,25648148
MARZO	13,545688	154,121154	2,94953704
ABRIL	14,713900	202,865023	3,03425926
MAYO	14,070000	155,479278	2,68981482
JUNIO	14,810000	167,198500	2,8037037
JULIO	15,100200	177,430900	3,04814815
AGOSTO	20,545849	270,230395	3,42407407
SEPTIEMBRE	17,180625	241,587285	3,14611111
OCTUBRE	16,337542	246,348862	2,97583333
NOVIEMBRE	14,754407	257,439315	3,16574074
DICIEMBRE	14,422657	227,717491	2,95472222

En la **Tabla 3**, se presenta los valores mensuales de tres importantes parámetros climáticos: Temperatura, Radiancia y Velocidad de viento. Estos datos son cruciales para analizar el comportamiento climático y comprender las condiciones atmosféricas en una ubicación específica.

3.3.3 Datos anuales de Temperatura, Radiancia y Velocidad de viento

Tabla 4. Datos anuales de Temperatura, Radiancia y Velocidad de viento

AÑO	Temperatura Superficial (°C)	Radiancia Global Ave (W/m2)	Velocidad de viento (m/s)
2018	15,23	240,58	1,62037037
2019	15,07	234,12	2,31401531
2020	14,97	243,05	2,91123451
2021	15,13	237,19	3,01746142
2022	15,09	242,36	2,70398245

En la **Tabla 4**, se presenta los valores diarios de tres importantes parámetros climáticos: Temperatura, Radiancia y Velocidad de viento. Estos datos son cruciales para analizar el comportamiento climático y comprender las condiciones atmosféricas en una ubicación específica.

4. Análisis de resultados

4.1 Temperatura

Tabla 5. Temperatura Superficial en °C – AR

AR	AIC	BIC	P-Value	T Statistic
Días	56,325	60,689	0,0007	3,388
Meses	52,832	52,453	0,376	0,884
Años	150,053	143,518	0,993	-0,008

En la **Tabla 5**, se proporciona los valores obtenidos a través del modelo autorregresivo AR para cuatro métricas importantes: AIC Akaike Information Criterion, BIC Bayesian Information Criterion, P-Value y t Statistics, en diferentes períodos de tiempo, a saber: días, meses y años.

4.1.1 Temperatura diaria AR

$$(1 - \phi_1 L - \phi_2 L^2)y_t = c + \varepsilon_t \quad (5)$$




Figura 3 . Temperatura superficial diario AR

En la **Figura 3** . Temperatura superficial diario AR, proporciona un análisis de la temperatura superficial diaria, este modelo muestra una notable precisión al pronosticar la temperatura en cada día, con valores que se acercan significativamente a los valores reales observados.

4.1.2 Temperatura mensual AR

$$(1 - \phi_1 L - \dots - \phi_5 L^5) y_t = c + \varepsilon_t \quad (6)$$




Figura 4. Temperatura superficial mensual AR

En la **Figura 4**. Temperatura superficial mensual AR, presenta un análisis de la temperatura en meses, en general, el modelo muestra valores pronosticados que se acercan significativamente a los valores reales observados, lo que indica una buena precisión en la predicción.

4.1.3 Temperatura anual AR

$$(1 - \phi_1 L - \phi_2 L^2 - \phi_3 L^3) y_t = c + \varepsilon_t \quad (7)$$




Figura 5. Temperatura superficial anual AR

En la **Figura 5**. Temperatura superficial anual AR, proporciona un análisis de la temperatura en años, en general, el modelo muestra valores pronosticados que se acercan significativamente a los valores reales observados, lo que indica una alta precisión en la predicción

4.1.4 Temperatura diaria MA

Tabla 6. Temperatura Superficial en °C – MA

MA	AIC	BIC	P-Value	T Statistic
Días	96,376	102,266	0,016	12,474
Meses	53,849	55,789	1,444e-09	7,563
Años	-2,465	-4,808	0,000001	223,711

En la **Tabla 6**, se proporciona los valores obtenidos a través del modelo autorregresivo MA para cuatro métricas importantes: AIC Akaike Information Criterion, BIC Bayesian Information Criterion, P-Value y t Statistics, en diferentes períodos de tiempo, a saber: días, meses y años.

$$y_t = c + (1 + \theta_1 L + \theta_2 L^2 + \theta_3 L^3) \varepsilon_t \quad (8)$$




Figura 6. Temperatura superficial diario MA

En la **Figura 6**. Temperatura superficial diario MA, muestra un análisis de la temperatura en días, en general, el modelo exhibe valores pronosticados que están muy cercanos a los valores reales observados, lo que indica una alta precisión en las predicciones.

4.1.5 Temperatura mensual MA

$$y_t = c + (1 + \theta_1 L + \theta_2 L^2) \varepsilon_t \quad (9)$$




Figura 7. Temperatura superficial mensual MA

En la **Figura 7**. Temperatura superficial mensual MA, se observa la temperatura en meses del modelo autorregresivo MA, teniendo valores muy acercados del pronóstico al real, exceptuando el pico que tuvo a los 8 meses.

4.1.6 Temperatura anual MA

$$y_t = c + (1 + \theta_1 L + \dots + \theta_4 L^4) \varepsilon_t \quad (10)$$




Figura 8. Temperatura superficial anual MA

En la **Figura 8**. Temperatura superficial anual MA, muestra un análisis de la temperatura en años, en general, el modelo presenta valores pronosticados que están muy cercanos a los valores reales observados, lo que indica una alta precisión en las predicciones.

4.1.7 Temperatura diaria ARMA

Tabla 7. Temperatura Superficial en °C – ARMA

ARMA	AIC	BIC	P-Value	T Statistic
Días	55,6400	61,0952	0,0139	2,4588
Meses	54,2446	55,7575	0,3322	0,9697
Años	150,0530	143,5188	0,9932	-0,0085

En la **Tabla 7**, se proporciona los valores obtenidos a través del modelo autorregresivo ARMA para cuatro métricas importantes: AIC Akaike Information Criterion, BIC Bayesian Information Criterion, P-Value y t Statistics, en diferentes períodos de tiempo, a saber: días, meses y años.

$$(1 - \phi_1 L - \phi_2 L^2)y_t = c + (1 + \theta_1 L)\varepsilon_t \quad (11)$$




Figura 9. Temperatura superficial diario ARMA

En la **Figura 9**. Temperatura superficial diario ARMA, muestra un análisis de la temperatura en días, en general, el modelo presenta valores pronosticados que están muy cercanos a los valores reales observados, lo que indica una alta precisión en las predicciones.

4.1.8 Temperatura mensual ARMA

$$(1 - \phi_1 L - \phi_2 L^2)y_t = c + (1 + \theta_1 L)\varepsilon_t \quad (7)$$




Figura 10. Temperatura superficial mensual ARMA

En la **Figura 10.** Temperatura superficial mensual ARMA, se observa la temperatura en meses del modelo autorregresivo ARMA, teniendo valores muy acercados del pronóstico al real, exceptuando el pico que tuvo a los 8 meses.

4.1.9 Temperatura anual ARMA

$$(1 - \phi_1 L - \phi_2 L^2 - \phi_3 L^3)y_t = c + \varepsilon_t \quad (3)$$




Figura 11. Temperatura superficial anual ARMA

En la **Figura 11.** Temperatura superficial anual ARMA, se observa la temperatura en años del modelo autorregresivo ARMA, teniendo valores muy acercados del pronóstico al real, exceptuando el valor a los 3 años.

4.1.10 Temperatura diaria ARIMA

Tabla 8. Temperatura Superficial en °C – ARIMA

ARIMA	AIC	BIC	P-Value	T Statistic
Días	59,960	66,506	0,112	-1,590
Meses	56,999	58,815	0,520	0,642
Años	150,053	143,518	0,993	-0,008

En la **Tabla 8,** se proporciona los valores obtenidos a través del modelo autorregresivo ARIMA para cuatro métricas importantes: AIC Akaike Information Criterion, BIC Bayesian

Information Criterion, P-Value y t Statistics, en diferentes períodos de tiempo, a saber: días, meses y años.

$$(1 - \phi_1 L)(1 - L)y_t = c + (1 + \theta_1 L + \theta_2 L^2 + \theta_3 L^3)\varepsilon_t \quad (12)$$




Figura 12. Temperatura superficial diario ARIMA

En la **Figura 12.** Temperatura superficial diario ARIMA, muestra un análisis de la temperatura en días, en general, el modelo presenta valores pronosticados que están muy cercanos a los valores reales observados, lo que indica una alta precisión en las predicciones.

4.1.11 Temperatura mensual ARIMA

$$(1 - \phi_1 L)(1 - L)y_t = c + (1 + \theta_1 L + \theta_2 L^2 + \theta_3 L^3)\varepsilon_t \quad (8)$$




Figura 13. Temperatura superficial mensual ARIMA

En la **Figura 13.** Temperatura superficial mensual ARIMA, se observa la temperatura en meses del modelo autorregresivo ARIMA, teniendo valores muy acercados del pronóstico al real, exceptuando el pico que tuvo a los 8 meses.

4.1.12 Temperatura anual ARIMA

$$(1 - \phi_1 L - \phi_2 L^2 - \phi_3 L^3)y_t = c + \varepsilon_t \quad (3)$$




Figura 14. Temperatura superficial anual ARIMA

En la **Figura 14**. Temperatura superficial anual ARIMA, se observa la temperatura en años del modelo autorregresivo AR, teniendo valores muy acercados del pronóstico al real, exceptuando el valor a los 3 años.

4.1.13 Temperatura diaria SARIMA

Tabla 9. Temperatura Superficial en °C – SARIMA

SARIMA	AIC	BIC	P-Value	T Statistic
Días	61,833	69,144	0,096	-1,662
Meses	58,982	60,363	0,480	0,704
Años	150,053	143,518	0,993	-0,008

En la **Tabla 9**, se proporciona los valores obtenidos a través del modelo autorregresivo SARIMA para cuatro métricas importantes: AIC Akaike Information Criterion, BIC Bayesian Information Criterion, P-Value y t Statistics, en diferentes períodos de tiempo, a saber: días, meses y años.

$$(1 - \phi_1 L)(1 - \Phi_1 L)(1 - L)y_t = c + (1 + \theta_1 L + \theta_2 L^2 + \theta_3 L^3)\varepsilon_t \quad (13)$$




Figura 15. Temperatura superficial diario SARIMA

En la **Figura 15**. Temperatura superficial diario SARIMA, muestra un análisis de la temperatura en días, en general, el modelo presenta valores pronosticados que están muy cercanos a los valores reales observados, lo que indica una alta precisión en las predicciones.

4.1.14 Temperatura mensual SARIMA

$$(1 - \phi_1 L)(1 - \Phi_1 L)(1 - L)y_t = c + (1 + \theta_1 L + \theta_2 L^2 + \theta_3 L^3)\varepsilon_t \quad (9)$$




Figura 16. Temperatura superficial mensual SARIMA

En la **Figura 16.** Temperatura superficial mensual SARIMA, se observa la temperatura en meses del modelo autorregresivo SARIMA, teniendo valores muy acercados del pronóstico al real, exceptuando el pico que tuvo a los 8 meses.

4.1.15 Temperatura anual SARIMA

$$(1 - \Phi_1 L - \Phi_2 L^2 - \Phi_3 L^3) y_t = c + \varepsilon_t \quad (14)$$




Figura 17. Temperatura superficial anual SARIMA

En la **Figura 17.** Temperatura superficial anual SARIMA, se observa la temperatura en años del modelo autorregresivo SARIMA, teniendo valores muy acercados del pronóstico al real, exceptuando el valor a los 3 años.




Figura 18. Diagrama de Barras Temperatura Superficial AIC – BIC

En la **Figura 18**. Diagrama de Barras Temperatura Superficial AIC – BIC, se observa los valores de AIC y BIC para cada tiempo día, mes y año, representado por las barras en cada modelo autorregresivo, siendo el de año con los valores más altos y en mes el de los valores más parecidos

4.2 Radiancia

Tabla 10. Radiancia Global Ave en W/m² – AR

AR	AIC	BIC	P-Value	T Stadistic
Días	251,949	256,314	0,065	1,840
Meses	113,474	113,096	1,444e-09	5,426
Años	1,317e+03	1,305e+03	0,016	9,638e+05

En la **Tabla 10**, se proporciona los valores obtenidos a través del modelo autorregresivo AR para cuatro métricas importantes: AIC Akaike Information Criterion, BIC Bayesian Information Criterion, P-Value y t Statistics, en diferentes períodos de tiempo, a saber: días, meses y años.

4.2.1 Radiancia diaria AR

$$(1 - \phi_1 L - \phi_2 L^2) y_t = c + \varepsilon_t \quad (1)$$




Figura 19. Radiancia Global Ave diario AR

En la **Figura 19**. Radiancia Global Ave diario AR, muestra un análisis de la radiancia en días, en general, el modelo presenta valores pronosticados que están muy cercanos a los valores reales observados, lo que indica una alta precisión en las predicciones.

4.2.2 Radiancia mensual AR

$$(1 - \phi_1 L - \dots - \phi_5 L^5) y_t = c + \varepsilon_t \quad (2)$$




Figura 20. Radiancia Global Ave mensual AR

En la **Figura 20**. Radiancia Global Ave mensual AR, muestra un análisis de la radiancia en meses, en general, el modelo presenta valores pronosticados que están muy cercanos a los valores reales observados, lo que indica una alta precisión en las predicciones.

4.2.3 Radiancia anual AR

$$(1 - \phi_1 L - \dots - \phi_4 L^4) y_t = c + \varepsilon_t \quad (15)$$




Figura 21. Radiancia Global Ave anual AR

En la **Figura 21**. Radiancia Global Ave anual AR, muestra un análisis de la radiancia en años, en general, el modelo presenta valores pronosticados que están muy cercanos a los valores reales observados, lo que indica una alta precisión en las predicciones.

4.2.4 Radiancia diaria MA

Tabla 11. Radiancia Global Ave en W/m2 – MA

MA	AIC	BIC	P-Value	T Statistic
Días	283,996	289,886	0,223	1,217
Meses	127,539	129,963	1,444e-09	6,050
Años	27,029	25,076	0,016	676,976

En la **Tabla 11**, se proporciona los valores obtenidos a través del modelo autorregresivo MA para cuatro métricas importantes: AIC Akaike Information Criterion, BIC Bayesian Information Criterion, P-Value y t Statistics, en diferentes períodos de tiempo, a saber: días, meses y años.

$$y_t = c + (1 + \theta_1 L + \theta_2 L^2 + \theta_3 L^3) \varepsilon_t \quad (4)$$




Figura 22. Radiancia Global Ave diario MA

En la **Figura 22**. Radiancia Global Ave diario MA, se observa la radiancia en días del modelo autorregresivo MA, teniendo valores muy acercados del pronóstico al real, exceptuando el desfase entre las 8 y 14 horas

4.2.5 Radiancia mensual MA

$$y_t = c + (1 + \theta_1 L + \theta_2 L^2 + \theta_3 L^3) \varepsilon_t \quad (4)$$




Figura 23. Radiancia Global Ave mensual MA

En la **Figura 23.** Radiancia Global Ave mensual MA, muestra un análisis de la radiancia en meses, en este caso, el modelo no presenta valores pronosticados muy cercanos a los valores reales observados, lo que indica que no ha logrado una alta precisión en las predicciones.

4.2.6 Radiancia anual MA

$$y_t = c + (1 + \theta_1 L + \theta_2 L^2 + \theta_3 L^3) \varepsilon_t \quad (4)$$




Figura 24. Radiancia Global Ave anual MA

En la **Figura 24.** Radiancia Global Ave anual MA, muestra un análisis de la radiancia en años, en este caso, el modelo presenta valores pronosticados que están muy cercanos a los valores reales observados, lo que indica una alta precisión en las predicciones.

4.2.7 Radiancia diaria ARMA

Tabla 12. Radiancia Global Ave en W/m2 – ARMA

ARMA	AIC	BIC	P-Value	T Statistic
Días	242,752	248,207	0,206	1,263
Meses	127,393	128,906	0,425	0,796
Años	49,229	45,547	1,452e-80	19,008

En la **Tabla 12,** se proporciona los valores obtenidos a través del modelo autorregresivo ARMA para cuatro métricas importantes: AIC Akaike Information Criterion, BIC Bayesian

Information Criterion, P-Value y t Statistics, en diferentes períodos de tiempo, a saber: días, meses y años.

$$(1 - \phi_1 L - \phi_2 L^2) y_t = c + (1 + \theta_1 L) \varepsilon_t \quad (7)$$




Figura 25. Radiancia Global Ave diario ARMA

En la **Figura 25.** Radiancia Global Ave diario ARMA, muestra la radiancia en días, en general, el modelo presenta valores pronosticados que están muy cercanos a los valores reales observados, lo que indica una alta precisión en las predicciones.

4.2.8 Radiancia mensual ARMA

$$(1 - \phi_1 L - \phi_2 L^2) y_t = c + (1 + \theta_1 L) \varepsilon_t \quad (7)$$




Figura 26. Radiancia Global Ave mensual ARMA

En la **Figura 26.** Radiancia Global Ave mensual ARMA, muestra la radiancia en meses, en este caso, el modelo no presenta valores pronosticados muy cercanos a los valores reales observados, lo que indica que no ha logrado una alta precisión en las predicciones.

4.2.9 Radiancia anual ARMA

$$(1 - \phi_1 L) y_t = c + (1 + \theta_1 L + \theta_2 L^2 + \theta_3 L^3) \varepsilon_t \quad (16)$$




Figura 27. Radiancia Global Ave anual ARMA

En la **Figura 27**. Radiancia Global Ave anual ARMA, muestra la radiancia en años, en este caso, el modelo presenta valores pronosticados que están acercados a los valores reales observados, lo que indica una buena precisión en las predicciones.

4.2.10 Radiancia diaria ARIMA

Tabla 13. Radiancia Global Ave en W/m2 – ARIMA

ARIMA	AIC	BIC	P-Value	T Statistic
Días	247,141	252,819	0,422	0,802
Meses	127,206	129,021	0,767	0,295
Años	49,229	45,547	1,452e-80	19,008

En la **Tabla 13**, se proporciona los valores obtenidos a través del modelo autorregresivo ARIMA para cuatro métricas importantes: AIC Akaike Information Criterion, BIC Bayesian Information Criterion, P-Value y t Statistics, en diferentes períodos de tiempo, a saber: días, meses y años.

$$(1 - \phi_1 L)y_t = c + (1 + \theta_1 L + \theta_2 L^2)\varepsilon_t \quad (17)$$




Figura 28. Radiancia Global Ave diario ARIMA

En la **Figura 28**. Radiancia Global Ave diario ARIMA, muestra la radiancia en días, en este caso, el modelo presenta valores pronosticados que están muy cercanos a los valores reales observados, lo que indica una alta precisión en las predicciones.

4.2.11 Radiancia mensual ARIMA

$$(1 - \phi_1 L)(1 - L)y_t = c + (1 + \theta_1 L + \theta_2 L^2 + \theta_3 L^3)\varepsilon_t \quad (8)$$




Figura 29. Radiancia Global Ave mensual ARIMA

En la **Figura 29**. Radiancia Global Ave mensual ARIMA, muestra la radiancia en meses, en este caso, el modelo no presenta valores pronosticados muy cercanos a los valores reales observados, lo que indica que no ha logrado una alta precisión en las predicciones.

4.2.12 Radiancia anual ARIMA

$$(1 - \phi_1 L)y_t = c + (1 + \theta_1 L + \theta_2 L^2 + \theta_3 L^3)\varepsilon_t \quad (12)$$




Figura 30. Radiancia Global Ave anual ARIMA

En la **Figura 30**. Radiancia Global Ave anual ARIMA, muestra la radiancia en años, en este caso, el modelo presenta valores pronosticados que están acercados a los valores reales observados, lo que indica una buena precisión en las predicciones.

4.2.13 Radiancia diaria SARIMA

Tabla 14. Radiancia Global Ave en W/m2 – SARIMA

SARIMA	AIC	BIC	P-Value	T Statistic
Días	237,212	245,940	0,437	0,776
Meses	127,545	129,966	0,122	1,545
Años	49,229	45,547	1,452e-80	19,008

En la **Tabla 14**, se proporciona los valores obtenidos a través del modelo autorregresivo SARIMA para cuatro métricas importantes: AIC Akaike Information Criterion, BIC Bayesian Information Criterion, P-Value y t Statistics, en diferentes períodos de tiempo, a saber: días, meses y años.

$$(1 - \phi_1 L)(1 - \Phi_1 L)y_t = c + (1 + \theta_1 L + \theta_2 L^2)(1 + \Theta_1 L + \Theta_2 L^2)\varepsilon_t \quad (18)$$




Figura 31. Radiancia Global Ave diario SARIMA

En la **Figura 31**. Radiancia Global Ave diario SARIMA, muestra la radiancia en días, en este caso, el modelo presenta valores pronosticados que están muy cercanos a los valores reales observados, lo que indica una alta precisión en las predicciones.

4.2.14 Radiancia mensual SARIMA

$$(1 - \phi_1 L)(1 - \Phi_1 L)y_t = c + (1 + \theta_1 L + \theta_2 L^2)(1 + \Theta_1 L + \Theta_2 L^2)\varepsilon_t \quad (14)$$




Figura 32. Radiancia Global Ave mensual SARIMA

En la **Figura 32**. Radiancia Global Ave mensual SARIMA, muestra la radiancia en meses, en este caso, el modelo no presenta valores pronosticados muy cercanos a los valores reales observados, lo que indica que no ha logrado una alta precisión en las predicciones.

4.2.15 Radiancia anual SARIMA

$$(1 - \phi_1 L)y_t = (1 + \Theta_1 L + \Theta_2 L^2 + \Theta_3 L^3)\varepsilon_t \quad (19)$$




Figura 33. Radiancia Global Ave anual SARIMA

En la **Figura 33**. Radiancia Global Ave anual SARIMA, muestra la radiancia en años, en este caso, el modelo presenta valores pronosticados que están acercados a los valores reales observados, lo que indica una buena precisión en las predicciones.




Figura 34. Diagrama de Barras Radiancia Global Ave AIC – BIC

En la **Figura 34**. Diagrama de Barras Radiancia Global Ave AIC – BIC, se observa los valores de AIC y BIC para cada tiempo día, mes y año, representado por las barras en cada modelo autorregresivo, siendo el de año con los valores más altos y en mes y día el de los valores más parecidos

4.3 Velocidad de viento

Tabla 15. Velocidad de viento en m/s – AR

AR	AIC	BIC	P-Value	T Statistic
Días	55,144	62,813	0,0006	3,454
Meses	2,212	3,198	0,069	1,818
Años	14,690	11,084	0,013	2,471

En la **Tabla 15**, se proporciona los valores obtenidos a través del modelo autorregresivo AR para cuatro métricas importantes: AIC Akaike Information Criterion, BIC Bayesian

Information Criterion, P-Value y t Statistics, en diferentes períodos de tiempo, a saber: días, meses y años.

4.3.1 Velocidad de viento diario AR

$$(1 - \phi_1 L - \dots - \phi_{10} L^{10}) y_t = c + \varepsilon_t \quad (20)$$




Figura 35. Velocidad de viento diario AR

En la **Figura 35**. Velocidad de viento diario AR, muestra la velocidad en días, en este caso, el modelo presenta valores pronosticados que están muy cercanos a los valores reales observados, lo que indica una alta precisión en las predicciones.

4.3.2 Velocidad de viento mensual AR

$$(1 - \phi_1 L - \phi_2 L^2 - \phi_3 L^3) y_t = c + \varepsilon_t \quad (3)$$




Figura 36. Velocidad de viento mensual AR

En la **Figura 36**. Velocidad de viento mensual AR, muestra la velocidad en meses, en este caso, el modelo no presenta valores pronosticados muy cercanos a los valores reales observados, lo que indica que no ha logrado una alta precisión en las predicciones. Sin embargo, se observa que los valores pronosticados siguen una tendencia similar a la de los valores reales.

4.3.3 Velocidad de viento anual AR

$$(1 - \phi_1 L - \phi_2 L^2) y_t = c + \varepsilon_t \quad (1)$$




Figura 37. Velocidad de viento anual AR

En la **Figura 37**. Velocidad de viento anual AR, se observa la velocidad en años del modelo autorregresivo AR, teniendo valores no muy cercanos del pronóstico al real, pero con una tendencia parecida.

4.3.4 Velocidad de viento diario MA

Tabla 16. Velocidad de viento en m/s – MA

MA	AIC	BIC	P-Value	T Statistic
Días	80,218	94,355	0,016	6,292
Meses	6,622	10,986	1,444e-09	34,368
Años	16,506	14,163	6,261e-04	3,420

En la **Tabla 16**, se proporciona los valores obtenidos a través del modelo autorregresivo MA para cuatro métricas importantes: AIC Akaike Information Criterion, BIC Bayesian Information Criterion, P-Value y t Statistics, en diferentes períodos de tiempo, a saber: días, meses y años.

$$y_t = c + (1 + \theta_1 L + \dots + \theta_{10} L^{10}) \varepsilon_t \quad (21)$$




Figura 38. Velocidad de viento diario MA

En la **Figura 38**. Velocidad de viento diario MA, se observa la velocidad en días del modelo autorregresivo MA, teniendo valores no muy cercanos del pronóstico al real, pero con una tendencia parecida.

4.3.5 Velocidad de viento mensual MA

$$y_t = c + (1 + \theta_1 L + \dots + \theta_7 L^7) \varepsilon_t \quad (22)$$




Figura 39. Velocidad de viento mensual MA

En la **Figura 39**. Velocidad de viento mensual MA, muestra la velocidad en meses, en este caso, el modelo presenta valores pronosticados que están cercanos a los valores reales observados, lo que indica una buena precisión en las predicciones.

4.3.6 Velocidad de viento anual MA

$$y_t = c + (1 + \theta_1 L + \dots + \theta_4 L^4) \varepsilon_t \quad (6)$$




Figura 40. Velocidad de viento anual MA

En la **Figura 40**. Velocidad de viento anual MA, muestra la velocidad en años, en este caso, el modelo presenta valores pronosticados que están cercanos a los valores reales observados, lo que indica una buena precisión en las predicciones..

4.3.7 Velocidad de viento diario ARMA

Tabla 17. Velocidad de viento en m/s – ARMA

ARMA	AIC	BIC	P-Value	t Statistic
Días	64,852	74,253	0,016	4,510
Meses	91,256	90,877	90,877	1,219e-04
Años	16,506	14,163	6,261e-04	3,420

En la **Tabla 17**, se proporciona los valores obtenidos a través del modelo autorregresivo AR para cuatro métricas importantes: AIC Akaike Information Criterion, BIC Bayesian Information Criterion, P-Value y t Statistics, en diferentes períodos de tiempo, a saber: días, meses y años.

$$(1 - \phi_1 L - \phi_2 L^2 - \phi_3 L^3) y_t = c + (1 + \theta_1 L + \dots + \theta_4 L^4) \varepsilon_t \quad (23)$$




Figura 41. Velocidad de viento diario ARMA

En la **Figura 41**. Velocidad de viento diario ARMA, se observa la velocidad en días del modelo autorregresivo ARMA, teniendo valores no muy cercanos del pronóstico al real, pero con una tendencia parecida.

4.3.8 Velocidad de viento mensual ARMA

$$(1 - \phi_1 L - \phi_2 L^2 - \phi_3 L^3) y_t = c + \varepsilon_t \quad (3)$$




Figura 42. Velocidad de viento mensual ARMA

En la **Figura 42**. Velocidad de viento mensual ARMA, muestra la velocidad en meses, en este caso, el modelo no presenta valores pronosticados muy cercanos a los valores reales observados, lo que indica que no ha logrado una alta precisión en las predicciones.

4.3.9 Velocidad de viento anual ARMA

$$y_t = c + (1 + \theta_1 L + \dots + \theta_4 L^4) \varepsilon_t \quad (6)$$




Figura 43. Velocidad de viento anual ARMA

En la **Figura 43**. Velocidad de viento anual ARMA, muestra la velocidad en años, en este caso, el modelo presenta valores pronosticados que están cercanos a los valores reales observados, lo que indica una buena precisión en las predicciones.

4.3.10 Velocidad de viento diario ARIMA

Tabla 18. Velocidad de viento en m/s – ARIMA

ARIMA	AIC	BIC	P-Value	T Statistic
Días	68,959545	76,2661	0,2770	1,0870
Meses	23,4759	26,8043	0,8782	-0,1533
Años	16,5067	14,1634	6,2614e-04	3,4200

En la **Tabla 18**, se proporciona los valores obtenidos a través del modelo autorregresivo ARIMA para cuatro métricas importantes: AIC Akaike Information Criterion, BIC Bayesian Information Criterion, P-Value y t Statistics, en diferentes períodos de tiempo, a saber: días, meses y años.

$$(1 - \phi_1 L - \phi_2 L^2)(1 - L)y_t = c + (1 + \theta_1 L + \theta_2 L^2 + \theta_3 L^3)\varepsilon_t \quad (24)$$




Figura 44. Velocidad de viento diario ARIMA

En la **Figura 44**. Velocidad de viento diario ARIMA, se observa la velocidad en días del modelo autorregresivo ARIMA, teniendo valores no muy cercanos del pronóstico al real, pero con una tendencia parecida.

4.3.11 Velocidad de viento mensual ARIMA

$$(1 - L)^2 y_t = c + (1 + \theta_1 L + \dots + \theta_9 L^9)\varepsilon_t \quad (25)$$




Figura 45. Velocidad de viento mensual ARIMA

En la **Figura 45**. Velocidad de viento mensual ARIMA, se observa la velocidad en meses del modelo autorregresivo ARIMA, teniendo valores no muy cercanos del pronóstico al real, pero con una tendencia parecida.

4.3.12 Velocidad de viento anual ARIMA

$$y_t = c + (1 + \theta_1 L + \dots + \theta_4 L^4) \varepsilon_t \quad (6)$$




Figura 46. Velocidad de viento anual ARIMA

En la **Figura 46**. Velocidad de viento anual ARIMA, muestra la velocidad en años, en este caso, el modelo presenta valores pronosticados que están cercanos a los valores reales observados, lo que indica una buena precisión en las predicciones.

4.3.13 Velocidad de viento diaria SARIMA

Tabla 19. Velocidad de viento en m/s – SARIMA

SARIMA	AIC	BIC	P-Value	T Statistic
Días	63,584	74,029	0,359	0,916
Meses	4,711	5,505	0,840	0,201
Años	16,506	14,163	2,182e-05	4,245

En la **Tabla 19**, se proporciona los valores obtenidos a través del modelo autorregresivo SARIMA para cuatro métricas importantes: AIC Akaike Information Criterion, BIC Bayesian Information Criterion, P-Value y t Statistics, en diferentes períodos de tiempo, a saber: días, meses y años.

$$(1 - \phi_1 L)(1 - \Phi_1 L - \Phi_2 L^2) y_t = c + (1 + \theta_1 L + \theta_2 L^2)(1 + \Theta_1 L + \Theta_2 L^2 + \Theta_3 L^3) \varepsilon_t \quad (26)$$




Figura 47. Velocidad de viento diario SARIMA

En la **Figura 47.** Velocidad de viento diario SARIMA, se observa la velocidad en días del modelo autorregresivo SARIMA, teniendo valores no muy cercanos del pronóstico al real, pero con una tendencia parecida.

4.3.14 Velocidad de viento mensual SARIMA

$$(1 - \phi_1 L)(1 - \Phi_1 L - \Phi_2 L^2 - \Phi_3 L^3)y_t = c + (1 + \theta_1 L + \theta_2 L^2)(1 + \Theta_1 L + \Theta_2 L^2)\varepsilon_t \quad (27)$$




Figura 48. Velocidad de viento mensual SARIMA

En la **Figura 48.** Velocidad de viento mensual SARIMA, se observa la velocidad en meses del modelo autorregresivo SARIMA, teniendo valores no muy cercanos del pronóstico al real, pero con una tendencia parecida.

4.3.15 Velocidad de viento anual SARIMA

$$y_t = c + (1 + \theta_1 L)(1 + \Theta_1 L + \Theta_2 L^2 + \Theta_3 L^3)\varepsilon_t \quad (28)$$




Figura 49. Velocidad de viento anual SARIMA

En la **Figura 49**. Velocidad de viento anual SARIMA, muestra la velocidad en años, en este caso, el modelo presenta valores pronosticados que están cercanos a los valores reales observados, lo que indica una buena precisión en las predicciones.




Figura 50. Diagrama de Barras Velocidad de viento AIC – BIC

En la **Figura 50**. Diagrama de Barras Velocidad de viento AIC – BIC, se observa los valores de AIC y BIC para cada tiempo día, mes y año, representado por las barras en cada modelo autorregresivo, siendo el de día con los valores más altos y en años el de los valores más parecidos

1. AR

Tabla 20. Formulas obtenidas del modelo autorregresivo AR

Temperatura Superficial	
Días	$(1 - \phi_1 L - \phi_2 L^2) y_t = c + \varepsilon_t$
Meses	$(1 - \phi_1 L - \dots - \phi_5 L^5) y_t = c + \varepsilon_t$
Años	$(1 - \phi_1 L - \phi_2 L^2 - \phi_3 L^3) y_t = c + \varepsilon_t$
Radiancia Global Ave (W/m2)	
Días	$(1 - \phi_1 L - \phi_2 L^2) y_t = c + \varepsilon_t$
Meses	$(1 - \phi_1 L - \dots - \phi_5 L^5) y_t = c + \varepsilon_t$
Años	$(1 - \phi_1 L - \dots - \phi_4 L^4) y_t = c + \varepsilon_t$

Velocidad de viento (m/s)	
Días	$(1 - \phi_1L - \dots - \phi_{10}L^{10})y_t = c + \varepsilon_t$
Meses	$(1 - \phi_1L - \phi_2L^2 - \phi_3L^3)y_t = c + \varepsilon_t$
Años	$(1 - \phi_1L - \phi_2L^2)y_t = c + \varepsilon_t$

En la **Tabla 20**, se puede observar las fórmulas obtenidos con el modelo autorregresivo AR para la temperatura superficial, radiancia global Ave y la velocidad de viento en cada periodo de tiempo, días, meses y años.

2. MA

Tabla 21. Formulas obtenidas del modelo autorregresivo MA

Temperatura Superficial	
Días	$y_t = c + (1 + \theta_1L + \theta_2L^2 + \theta_3L^3)\varepsilon_t$
Meses	$y_t = c + (1 + \theta_1L + \theta_2L^2)\varepsilon_t$
Años	$y_t = c + (1 + \theta_1L + \dots + \theta_4L^4)\varepsilon_t$
Radiancia Global Ave (W/m2)	
Días	$y_t = c + (1 + \theta_1L + \theta_2L^2 + \theta_3L^3)\varepsilon_t$
Meses	$y_t = c + (1 + \theta_1L + \theta_2L^2 + \theta_3L^3)\varepsilon_t$
Años	$y_t = c + (1 + \theta_1L + \theta_2L^2 + \theta_3L^3)\varepsilon_t$
Velocidad de viento (m/s)	
Días	$y_t = c + (1 + \theta_1L + \dots + \theta_{10}L^{10})\varepsilon_t$
Meses	$y_t = c + (1 + \theta_1L + \dots + \theta_7L^7)\varepsilon_t$
Años	$y_t = c + (1 + \theta_1L + \dots + \theta_4L^4)\varepsilon_t$

En la **Tabla 21**, se puede observar las fórmulas obtenidos con el modelo autorregresivo MA para la temperatura superficial, radiancia global Ave y la velocidad de viento en cada periodo de tiempo, días, meses y años.

3. ARMA

Tabla 22. Formulas obtenidas del modelo autorregresivo ARMA

Temperatura Superficial	
Días	$(1 - \phi_1L - \phi_2L^2)y_t = c + (1 + \theta_1L)\varepsilon_t$
Meses	$(1 - \phi_1L - \phi_2L^2)y_t = c + (1 + \theta_1L)\varepsilon_t$
Años	$(1 - \phi_1L - \phi_2L^2 - \phi_3L^3)y_t = c + \varepsilon_t$
Radiancia Global Ave (W/m2)	
Días	$(1 - \phi_1L - \phi_2L^2)y_t = c + (1 + \theta_1L)\varepsilon_t$
Meses	$(1 - \phi_1L - \phi_2L^2)y_t = c + (1 + \theta_1L)\varepsilon_t$
Años	$(1 - \phi_1L)y_t = c + (1 + \theta_1L + \theta_2L^2 + \theta_3L^3)\varepsilon_t$

Velocidad de viento (m/s)	
Días	$(1 - \phi_1L - \phi_2L^2 - \phi_3L^3)y_t = c + (1 + \theta_1L + \dots + \theta_4L^4)\varepsilon_t$
Meses	$(1 - \phi_1L - \phi_2L^2 - \phi_3L^3)y_t = c + \varepsilon_t$
Años	$y_t = c + (1 + \theta_1L + \dots + \theta_4L^4)\varepsilon_t$

En la **Tabla 22**, se puede observar las fórmulas obtenidos con el modelo autorregresivo ARMA para la temperatura superficial, radiancia global Ave y la velocidad de viento en cada periodo de tiempo, días, meses y años.

4. ARIMA

Tabla 23. Formulas obtenidas del modelo autorregresivo ARIMA	
Temperatura Superficial	
Días	$(1 - \phi_1L)(1 - L)y_t = c + (1 + \theta_1L + \theta_2L^2 + \theta_3L^3)\varepsilon_t$
Meses	$(1 - \phi_1L)(1 - L)y_t = c + (1 + \theta_1L + \theta_2L^2 + \theta_3L^3)\varepsilon_t$
Años	$(1 - \phi_1L - \phi_2L^2 - \phi_3L^3)y_t = c + \varepsilon_t$
Radiancia Global Ave (W/m2)	
Días	$(1 - \phi_1L)y_t = c + (1 + \theta_1L + \theta_2L^2)\varepsilon_t$
Meses	$(1 - \phi_1L)(1 - L)y_t = c + (1 + \theta_1L + \theta_2L^2 + \theta_3L^3)\varepsilon_t$
Años	$(1 - \phi_1L)y_t = c + (1 + \theta_1L + \theta_2L^2 + \theta_3L^3)\varepsilon_t$
Velocidad de viento (m/s)	
Días	$(1 - \phi_1L - \phi_2L^2)(1 - L)y_t = c + (1 + \theta_1L + \theta_2L^2 + \theta_3L^3)\varepsilon_t$
Meses	$(1 - L)^2y_t = c + (1 + \theta_1L + \dots + \theta_9L^9)\varepsilon_t$
Años	$y_t = c + (1 + \theta_1L + \dots + \theta_4L^4)\varepsilon_t$

En la **Tabla 23**, se puede observar las fórmulas obtenidos con el modelo autorregresivo ARIMA para la temperatura superficial, radiancia global Ave y la velocidad de viento en cada periodo de tiempo, días, meses y años.

5. SARIMA

Tabla 24. Formulas obtenidas del modelo autorregresivo SARIMA	
Temperatura Superficial	
Días	$(1 - \phi_1L)(1 - \Phi_1L)(1 - L)y_t = c + (1 + \theta_1L + \theta_2L^2 + \theta_3L^3)\varepsilon_t$
Meses	$(1 - \phi_1L)(1 - \Phi_1L)(1 - L)y_t = c + (1 + \theta_1L + \theta_2L^2 + \theta_3L^3)\varepsilon_t$
Años	$(1 - \Phi_1L - \Phi_2L^2 - \Phi_3L^3)y_t = c + \varepsilon_t$
Radiancia Global Ave (W/m2)	
Días	$(1 - \phi_1L)(1 - \Phi_1L)y_t = c + (1 + \theta_1L + \theta_2L^2)(1 + \Theta_1L + \Theta_2L^2)\varepsilon_t$

Meses	$(1 - \phi_1L)(1 - \Phi_1L)y_t = c + (1 + \theta_1L + \theta_2L^2)(1 + \Theta_1L + \Theta_2L^2)\varepsilon_t$
Años	$(1 - \phi_1L)y_t = (1 + \Theta_1L + \Theta_2L^2 + \Theta_3L^3)\varepsilon_t$
Velocidad de viento (m/s)	
Días	$(1 - \phi_1L)(1 - \Phi_1L - \Phi_2L^2)y_t = c + (1 + \theta_1L + \theta_2L^2)(1 + \Theta_1L + \Theta_2L^2 + \Theta_3L^3)\varepsilon_t$
Meses	$(1 - \phi_1L)(1 - \Phi_1L - \Phi_2L^2 - \Phi_3L^3)y_t = c + (1 + \theta_1L + \theta_2L^2)(1 + \Theta_1L + \Theta_2L^2)\varepsilon_t$
Años	$y_t = c + (1 + \theta_1L)(1 + \Theta_1L + \Theta_2L^2 + \Theta_3L^3)\varepsilon_t$

En la **Tabla 24**, se puede observar las fórmulas obtenidos con el modelo autorregresivo SARIMA para la temperatura superficial, radiancia global Ave y la velocidad de viento en cada periodo de tiempo, días, meses y años.

5. Conclusiones

Este estudio analiza modelos autorregresivos AR, modelos de media móvil MA, modelos autorregresivos de media móvil ARMA, modelos autorregresivos integrados de media móvil ARIMA y modelos autorregresivos estacionales integrados de media móvil SARIMA, tres variables: temperatura de la superficie, radiación solar global promedio y velocidad del viento.

Para temperatura superficial variable, se analizaron los resultados de los modelos AR, MA, ARMA, ARIMA y SARIMA para diferentes periodos de tiempo días, meses, años. En general, observamos que los modelos AR y ARMA dan valores cercanos a los datos reales para todos los periodos de tiempo, salvo algunos picos atípicos en meses y años. Los modelos MA, ARIMA y SARIMA también dieron valores cercanos a las verdaderas predicciones en la mayoría de los casos, aunque también mostraron mayores desviaciones para algunos periodos de tiempo. En resumen, los modelos AR y ARMA demostraron ser los más efectivos para predecir la temperatura superficial. Para la variable radiación global media se aplicó el mismo modelo con resultados similares. Los modelos AR y ARMA estuvieron cerca de las predicciones reales para todos los períodos de tiempo, mientras que los modelos MA, ARIMA y SARIMA mostraron algunas desviaciones. Esto sugiere que el modelo autorregresivo es adecuado para predecir la dosis de radiación global media.

Finalmente, se analizaron las variables de velocidad del viento y se aplicaron los modelos AR, MA, ARMA, ARIMA y SARIMA. En este caso, los modelos AR y MA muestran discrepancia la mayor parte del tiempo, lo que indica que no son óptimos para predecir la velocidad del viento. Sin embargo, los modelos ARMA, ARIMA y SARIMA arrojaron valores cercanos a las predicciones reales en la mayoría de los casos, aunque con algunos errores. Esto sugiere que el modelo de promedio móvil autorregresivo es más efectivo para predecir la velocidad del viento.

Se realizó un análisis estadístico de los diferentes modelos considerados. Entre ellos, el modelo diario mostró la puntuación más alta en el criterio del P-value, alcanzando una puntuación significativa de 0,993. Este valor alto indica una fuerte correlación o asociación entre las variables analizadas en el contexto particular.

Además, se observaron valores de P-value de 0,789 y 0,465 al examinar los modelos diarios y mensuales, respectivamente. Estos resultados sugieren que, aunque todavía existe una correlación entre las variables, la fuerza de la correlación es menor en comparación con el modelo diario. Es importante señalar que estos resultados se basan en los datos proporcionados y el análisis estadístico realizado. Tenga en cuenta que la validez y aplicabilidad de estos resultados dependen de las circunstancias y la calidad de los datos utilizados en el estudio.

El análisis de los modelos muestra que el modelo diario tiene una correlación más fuerte con un P-value de 0.993, mientras que los modelos diarios y mensual tienen valores de P-value más bajos y una correlación relativamente débil.

Para el criterio AIC, se encontró que el modelo mensual tiene los valores más bajos entre 2 y 6. Esto sugiere que este modelo tiene un mejor ajuste y capacidad predictiva para las variables de interés en comparación con los modelos diarios y anuales. Los valores de AIC para los modelos diarios son más altos con valor de 283,996, lo que sugiere que estos modelos tienen un ajuste relativamente pobre.

Para los criterios BIC, el modelo mensual volvió a mostrar el valor más bajo de 3,198, lo que confirma nuestra conclusión anterior de que este modelo es el que mejor se ajusta. Los modelos diarios muestran valores de BIC más altos tal como 289,886, lo que indica un ajuste relativamente pobre en comparación con el modelo diario.

En cuanto a las t Statistic, se realizaron pruebas para evaluar la significancia estadística de las variables de temperatura, radiación y velocidad para cada modelo. En el modelo diario, se encontró que todas las variables tenían valores significativos para el t Statistic, lo que sugiere una relación estadísticamente significativa entre estas variables. Sin embargo, algunas variables en los modelos diarios y mensuales mostraron t Statistic no significativas, lo que sugiere correlaciones débiles o inexistentes en estas situaciones temporales.

Los resultados del análisis muestran que el modelo diario muestra un mejor ajuste según los criterios AIC y BIC, mostrando correlaciones estadísticamente significativas entre las variables temperatura, radiación y velocidad. Los modelos diarios y mensuales, por otro lado, están relativamente menos ajustados y menos fuertemente correlacionados que los modelos diarios.

6. Bibliografías

- [1] H. O. Omoregbee, B. A. Edward, and M. U. Olanipekun, "Bearing failure diagnosis and prognostics modeling in plants for industrial purpose," *Journal of Engineering and Applied Science*, vol. 70, no. 1, Dec. 2023, doi: 10.1186/s44147-023-00183-y.
- [2] M. Karimi and M. Karimi, "Finite sample criteria for autoregressive model order selection Array signal processing, Sonar signal processing, Spectral estimation and signal modelling View Project Noisy AR estimation View project FINITE SAMPLE CRITERIA FOR AUTOREGRESSIVE MODEL ORDER SELECTION," 2007.
- [3] G. Schwarz, "Estimating the Dimension of a Model," *The Annals of Statistics*, vol. 6, no. 2, Dec. 2007, doi: 10.1214/aos/1176344136.
- [4] C. T. C. L. G. J. V. M. Serrano Sheila, "An Empirical Model for Rainfall Maximums Conditioned to Tropospheric Water Vapor Over the Eastern Pacific Ocean," <https://www.frontiersin.org/articles/10.3389/feart.2020.00198/full>, Jul. 09, 2020.
- [5] Hans-Holger Rogner and Anca Popescu, "An introduction to energy," *Part I energy and major global issues*, Germany, Romania, pp. 1–9, 2018.
- [6] A. H. Amshi and R. Prasad, "Time series analysis and forecasting of cholera disease using discrete wavelet transform and seasonal autoregressive integrated moving average model," *Sci Afr*, vol. 20, Jul. 2023, doi: 10.1016/j.sciaf.2023.e01652.
- [7] M. C. Van Der Linden, M. Van Loon-Van Gaalen, J. R. Richards, G. Van Woerden, and N. Van Der Linden, "Effects of process changes on emergency department crowding in a changing world: an interrupted time-series analysis," *Int J Emerg Med*, vol. 16, no. 1, Dec. 2023, doi: 10.1186/s12245-023-00479-z.
- [8] A. Vieira, I. Sousa, and S. Dória-Nóbrega, "Forecasting daily admissions to an emergency department considering single and multiple seasonal patterns," *Healthcare Analytics*, vol. 3, Nov. 2023, doi: 10.1016/j.health.2023.100146.
- [9] D. Rodriguez Martínez, J. C. Cabaleiro, T. F. Pena, and F. F. Rivera, "Big Data Security in Hadoop and IoT Ecosystem View project ClimatePrediction.net View project," 2009. [Online]. Available: <https://www.researchgate.net/publication/236279245>
- [10] M. Zhang, "Time Series: Autoregressive models AR, MA, ARMA, ARIMA Overview 1 Introduction of Time Series Categories and Terminologies White Noise and Random Walk Time Series Analysis," 2018.
- [11] Z. Cai, J. Li, and J. Zhang, Eds., *Theoretical Computer Science*, vol. 1494. in Communications in Computer and Information Science, vol. 1494. Singapore: Springer Singapore, 2021. doi: 10.1007/978-981-16-7443-3.
- [12] A. B. Alemu, U. J. Parakash Raju, A. M. Seid, and B. Damtie, "Comparative study of seasonal autoregressive integrated moving average and Holt-Winters modeling for forecasting monthly ground-level ozone," *AIP Adv*, vol. 13, no. 3, Mar. 2023, doi: 10.1063/5.0132812.

- [13] R. Graf and P. Aghelpour, "Daily river water temperature prediction: A comparison between neural network and stochastic techniques," *Atmosphere (Basel)*, vol. 12, no. 9, Sep. 2021, doi: 10.3390/atmos12091154.
- [14] J. Kaur, K. S. Parmar, and S. Singh, "Autoregressive models in environmental forecasting time series: a theoretical and application review," *Environmental Science and Pollution Research*, vol. 30, no. 8. Springer Science and Business Media Deutschland GmbH, pp. 19617–19641, Feb. 01, 2023. doi: 10.1007/s11356-023-25148-9.
- [15] J. Li, J. Cai, R. Li, Q. Li, and L. Zheng, "Wavelet transforms based ARIMA-XGBoost hybrid method for layer actions response time prediction of cloud GIS services," *Journal of Cloud Computing*, vol. 12, no. 1, Dec. 2023, doi: 10.1186/s13677-022-00360-z.
- [16] L. Bai *et al.*, "Predicting monthly hospital outpatient visits based on meteorological environmental factors using the ARIMA model," *Sci Rep*, vol. 13, no. 1, Dec. 2023, doi: 10.1038/s41598-023-29897-y.
- [17] M. Pilar, G. Casimiro, and P. G. Casimiro, *Análisis de series temporales: Modelos ARIMA*.
- [18] H. N. Mahendra *et al.*, "Assessment and Prediction of Air Quality Level Using ARIMA Model: A Case Study of Surat City, Gujarat State, India," *Nature Environment and Pollution Technology*, vol. 22, no. 1, pp. 199–210, Mar. 2023, doi: 10.46488/NEPT.2023.V22I01.018.
- [19] S. He, J. Liu, X. Zhu, Z. Dai, and D. Li, "Research on modeling and predicting of BDS-3 satellite clock bias using the LSTM neural network model," *GPS Solutions*, vol. 27, no. 3, Jul. 2023, doi: 10.1007/s10291-023-01451-3.
- [20] Dra. Fernanda Villarreal, "Introducción a los Modelos de Pronósticos," *Departamento de Matemática*, vol. I, Universidad Nacional del Sur, pp. 1–121, 2016.
- [21] K. Bellisario *et al.*, "Time-series forecasting offers novel quantitative measure to assess loud sound event in an urban park with restored prairie," *Ecol Inform*, vol. 75, Jul. 2023, doi: 10.1016/j.ecoinf.2023.102100.
- [22] H. Kim, S. Park, and S. Kim, "Time-series clustering and forecasting household electricity demand using smart meter data," *Energy Reports*, vol. 9, pp. 4111–4121, Dec. 2023, doi: 10.1016/j.egy.2023.03.042.
- [23] "www.wmo.int Guide to Meteorological Instruments and Methods of Observation." [Online]. Available: www.wmo.int
- [24] I. Brazil, "METROLOGIC INSTRUMENTS, INC. MS700i Series Laser Bar Code Projection Scanner Installation and User's Guide," 1998. [Online]. Available: www.metrologic.com
- [25] R. M. Ghazy, S. Al Awaidy, and S. H. N. Taha, "Trends of HIV indicators in Egypt from 1990 to 2021: time-series analysis and forecast toward UNAIDS 90–90–90 targets," *BMC Public Health*, vol. 23, no. 1, Dec. 2023, doi: 10.1186/s12889-023-15490-5.

- [26] H. D. S. Cristian Cuji, "Evaluación del consumo de energía eléctrica de acuerdo a la arquitectura bioclimático mediante el Modelo ASHRAE y Gauss T-Student," <https://revistas.utp.ac.pa/index.php/id-tecnologico/article/view/2926>, Jun. 17, 2020.
- [27] C. C. C. R. O. Galarza, "Gestión Óptima de la Energía En Un Proceso Paulatino y Controlado para Contribuir a la Des carbonización del Sector Eléctrico," <https://revistaenergia.cenace.gob.ec/index.php/cenace/article/view/518/749>, Jul. 19, 2022.
- [28] "The Study of Information Collection and Verification Survey for Renewable Energy Introduction and Grid Stabilization in the Republic of Cabo Verde Final Report."
- [29] W. Tong, "CHAPTER 1 Fundamentals of wind energy," *WIT Transactions on State of the Art in Science and Engineering*, vol. 44, pp. 1755–8336, 2010, doi: 10.2495/978-1-84564-/205-1.
- [30] Hans-Holger Rogner and Anca Popescu, "An introduction to energy," *Part I energy and major global issues*, Germany, Romania, pp. 1–9, 2018.
- [31] M. Emami Javanmard and S. F. Ghaderi, "Energy demand forecasting in seven sectors by an optimization model based on machine learning algorithms," *Sustain Cities Soc*, vol. 95, Aug. 2023, doi: 10.1016/j.scs.2023.104623.
- [32] DR ASIT KUMAR and EVS DEPARTMENT, "ENERGY RESOURCES-Non-Renewable Sources-Renewable Sources-Alternate Emerging Energy Sources," *UNIVERSITY OF DELHI.*, UNIVERSITY OF DELHI., pp. 1–14, 2011.
- [33] Y. Wu *et al.*, "Disease burden and attributable risk factors of neonatal disorders and their specific causes in China from 1990 to 2019 and its prediction to 2024," *BMC Public Health*, vol. 23, no. 1, Dec. 2023, doi: 10.1186/s12889-023-15050-x.
- [34] "IRRADIANCIA Y RADIANCIA COMPRENSIÓN DE LOS CONCEPTOS DE IRRADIANCIA Y RADIANCIA PARA LOS ESPACIOS ARQUITECTÓNICOS ASÍ CÓMO LAS UNIDADES RADIOMÉTRICAS Y FOTOMÉTRICAS PRÁCTICA 15."
- [35] E. M. Cristian Cuji, "Controlador Difuso Para Gestión De La Energía En Un Proceso De Transición De Central De Generación Térmica A Renovables," <https://revistaenergia.cenace.gob.ec/index.php/cenace/article/view/491>.
- [36] A. Beléndez Vázquez, "CALOR Y TEMPERATURA," 2017.
- [37] M. Azzam, Z. Bouida, and M. Ibnkahla, "Irradiance and Temperature Forecasting for Energy Harvesting Units in IoT Sensors using SARIMA-KF," in *IEEE Wireless Communications and Networking Conference, WCNC*, Institute of Electrical and Electronics Engineers Inc., 2022, pp.1701–1706. doi: 10.1109/WCNC51071.2022.9771763.
- [38] D. P. Cristian Cuji, "Estimación Del Tiempo De Recuperación De Energía Aplicado En Producción De Hidrogeno Con Fines De Generación Eléctrica," <https://revistaenergia.cenace.gob.ec/index.php/cenace/article/view/492>.
- [39] M. H. J Romanycia and F. Jeffry Pelletier, "What is a heuristic?," 1985.

- [40] T. A. Budiman, C. R. James, N. C. Howlett, and R. M. Wood, "Near real-time prediction of urgent care hospital performance metrics using scalable random forest algorithm: A multi-site development," *Healthcare Analytics*, vol. 3, Nov. 2023, doi: 10.1016/j.health.2023.100169.
- [41] Glenn Marion, Scotland Given, Daniel Lawson, and Glenn Marion, "Introduction to Mathematical Modelling," Scotland, 2008.
- [42] J. A. Mauricio, "Análisis de Series Temporales SERIES TEMPORALES PÁGINA II OBSERVACIONES PRELIMINARES."
- [43] M. Behzadi Goodari, H. Sharifi, P. Dehesh, M. A. Mosleh-Shirazi, and T. Dehesh, "Factors affecting the number of road traffic accidents in Kerman province, southeastern Iran (2015–2021)," *Sci Rep*, vol. 13, no. 1, Dec. 2023, doi: 10.1038/s41598-023-33571-8.
- [44] Madeleine Renom, "ESTACIONES METEOROLOGICAS," *Unidad de Cs. de la Atmósfera Fac. de Ciencias-UdelaR*, vol. I, pp. 1–26, 2011.
- [45] E. Yao, L. Zhang, X. Li, and X. Yun, "Traffic Forecasting of Back Servers Based on ARIMA-LSTM-CF Hybrid Model," *International Journal of Computational Intelligence Systems*, vol. 16, no. 1, Dec. 2023, doi: 10.1007/s44196-023-00232-7.
- [46] J. Sekban, M. O. M. Nabil, H. F. Alsan, and T. Arsan, "Istanbul Dam Water Levels Forecasting Using ARIMA Models," in *Proceedings - 2022 Innovations in Intelligent Systems and Applications Conference, ASYU 2022*, Institute of Electrical and Electronics Engineers Inc., 2022. doi: 10.1109/ASYU56188.2022.9925418.
- [47] M. Zhang, "Time Series: Autoregressive models AR, MA, ARMA, ARIMA Overview 1 Introduction of Time Series Categories and Terminologies White Noise and Random Walk Time Series Analysis," 2018.
- [48] "Decision-making model to predict auto-rejection: An implementation of ARIMA for accurate forecasting of stock price volatility during the Covid-19 Suropto a*," 2022, doi: 10.5267/dsl.2022.10.002.