

PREDICCIÓN DE VARIABLES EN ESTACIONES METEOROLÓGICAS PARA
HALLAR EL FLUJO DEL AIRE EN LA UNIVERSIDAD INDUSTRIAL DE SANTANDER

INGRID TATIANA CARRILLO PICO

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERIAS FISICOMECAÑICAS
ESCUELA DE INGENIERIA MECANICA
INGENIERIA MECANICA
BUCARAMANGA
2023

PREDICCIÓN DE VARIABLES EN ESTACIONES METEOROLÓGICAS PARA HALLAR
EL FLUJO DEL AIRE EN LA UNIVERSIDAD INDUSTRIAL DE SANTANDER

INGRID TATIANA CARRILLO PICO

Trabajo de grado para optar el título de Ingeniero Mecánico

Director

Phd. David Alfredo Fuentes Diaz

Codirector

Ing. Carlos Daniel Barrera Diaz

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERIAS FISICOMECAÑICAS
ESCUELA DE INGENIERIA MECANICA
INGENIERIA MECANICA
BUCARAMANGA
2023

DEDICATORIA

El resultado de este trabajo se lo dedico principalmente a Dios, por brindarme la sabiduría y la fuerza necesaria para dar frente a todas las adversidades presentes en este camino de enseñanza.

A Emelina, mi madre por ser ese ejemplo de mujer y enseñarme a ser la mujer que soy; respetuosa, honesta y responsable.

A Brayan, mi hermano por estar en los buenos momentos y ser un apoyo en los no tan buenos.

A Jairo, mi tío por nunca dejar de creer en mí, y aunque hoy no esté con nosotros sé que nunca dudo que podría lograrlo.

A Adri, mi prima hermana por su comprensión y ser mi apoyo incondicional.

A Nubia, mi tía por escucharme y alentarme en mis momentos más difíciles y sobre todo por nunca dejar de creer en mí.

A todo el resto de mi familia, cada uno de ellos hicieron parte de este sueño que hoy es realidad.

A mis amigas, Danny, Aileen y Daniela por su paciencia y apoyo en mis momentos difíciles, gracias por ser parte de los buenos momentos.

A mí, por mi esfuerzo, perseverancia y fortaleza

AGRADECIMIENTOS

Primeramente, a Dios por permitir llegar hasta el final de este sueño y hoy ser una realidad.

A la Universidad por permitirme perseguir mis estudios y por proporcionarme los recursos necesarios y poder llegar a la recta final.

A mi director Alfredo David Fuentes Diaz, por su paciencia, comprensión y orientación en la ejecución de este proyecto.

A mi codirector Carlos Daniel Barrera Díaz por su ayuda y conocimientos brindados durante elaboración de esta investigación.

CONTENIDO

1. INTRODUCCIÓN.....	15
2. JUSTIFICACIÓN.....	17
3. OBJETIVOS.....	18
3.1 OBJETIVOS GENERALES	18
3.2 OBJETIVOS ESPECÍFICOS	18
4. ANTECEDENTES.....	19
4.1 MODELIZACIÓN Y PREDICCIÓN DE LA ENERGÍA ELÉCTRICA PRODUCIDA EN UN AEROGENERADOR UTILIZANDO MODELOS ESTOCÁSTICOS TEMPORALES A PARTIR DE SERIES DE VIENTO.....	19
4.2 EVALUACIÓN DEL POTENCIAL SOLAR Y EÓLICO DEL CAMPUS CENTRAL DE LA UNIVERSIDAD INDUSTRIAL DE SANTANDER Y LA CIUDAD DE BUCARAMANGA, COLOMBIA	20
4.3 PREDICCIÓN DE VARIABLES METEOROLÓGICAS POR MEDIO DE MODELOS ARIMA.....	20
5. MARCO TEORICO	22
5.1 MODELOS DE PREDICCIÓN	22
5.2 MODELO ARIMA	22
5.2.1 Estacionarias.....	23
5.2.2 No estacionarias.....	23
5.2.3 Procesos Lineales estacionarios	24
5.2.4 Procesos Lineales no Estacionarios.....	34
5.2.5 Modelo Sarima	34

5.3 REDES NEURONALES	35
5.3.1 Arquitectura de una RNA.....	35
5.3.2 Clasificación de las RNA	37
5.3.3 El Algoritmo Backpropagation	37
6. METODOLOGÍA	39
6.1 HERRAMIENTAS COMPUTACIONALES	39
6.2 DATOS A USAR.....	40
6.3 TRATAMIENTO DE LOS DATOS	40
6.3.1 Normalización.....	42
6.3.2 Promedio general	43
6.4 ANÁLISIS ENTRE LOS DATOS DE LAS DOS ESTACIONES METEOROLÓGICAS	45
6.5 MODELO ARIMA	48
6.5.4 Predicción.....	50
6.6 MODELO SARIMA	51
6.7 REDES NEURONALES	52
6.7.1 Preparación de los datos.....	52
6.7.2 Estructura de la red neuronal	52
6.8 ESCALA DE LAS GRAFICAS	53
6.9 ALCANCE DE LA INVESTIGACIÓN	53
7. resultados	54
7.1 MODELO ARIMA	54
7.1.1 Etapa de identificación	54
7.1.2 Etapa estimación del modelo	58

7.1.3 Etapa Predicción del modelo.....	58
7.2 PREDICCIÓN ARIMA (1,0,3)	61
7.3 MODELO SARIMA	62
7.4 PREDICCIÓN SARIMA (4,0,0)(0,1,1) ²⁴	67
7.4 REDES NEURONALES	70
7.4.2 Desarrollo del modelo.....	71
8. ANÁLISIS DE RESULTADOS	80
9. PROYECCIONES DEL FLUJO DE VIENTO ALREDEDOR DE LA EDIFICACIONES de LA UNIVERSIDAD INDUSTRIAL DE SANTANDER POR SIMULACIONES CFD	84
9.1 OBTENCIÓN DE PLANOS.....	84
9.2 CREACIÓN DEL MAPA DE RUGOSIDAD.....	84
9.3 ANÁLISIS DEL COMPORTAMIENTO DEL FLUJO DEL VIENTO	86
9.4 PROYECCION DE VELOCIDADES EN LA UNIVERSIDAD INDUSTRIAL DE SANTANDER	89
10. CONCLUSIONES	92
11. REFERENCIAS	96
12. ANEXOS.....	99

LISTA DE TABLAS

Tabla 1 . Base de datos de la Estación Meteorológica de la EIM.....	41
Tabla 2. Datos normalizados de la Estación Meteorológica de la EIM.....	42
Tabla 3. Promedio de la base de datos para la EIM.....	43
Tabla 4. Modelos de predicción con SARIMA	69
Tabla 5. Resultados de la velocidad del viento para la EIM.	74
Tabla 6. Resultados de la temperatura para la EIM.	75
Tabla 7. Resultados de la dirección del viento para la EIM.....	75
Tabla 8. Resultados de la velocidad del viento para la E3T.....	76
Tabla 9. Resultados de la temperatura para la E3T.....	76
Tabla 10. Resultados de la dirección del viento para la E3T.....	77
Tabla 11. Base de datos de las variables de predicción	78
Tabla 12. Valores de longitud de Rugosidad.....	86
Tabla 13. Resultados de la velocidad de flujo en la Universidad Industrial de Santander	91

LISTA DE FIGURAS

Figura 1. Serie de tiempo estacionaria.....	23
Figura 2. Serie de tiempo no estacionaria.....	24
Figura 3. Función de coeficientes de autocorrelación AR (1).....	26
Figura 4. Función de coeficientes de autocorrelación AR (2).....	27
Figura 5. Función de coeficientes de autocorrelación MA (1).	29
Figura 6. Función de coeficientes de autocorrelación MA (2).	30
Figura 7. Función de Coeficientes de autocorrelación de un modelo mixto ARMA (1,1).	33
Figura 8. Arquitectura de una RNA.	36
Figura 9. Datos normalizados-promediados de la Estación Meteorológica de la EIM....	44
Figura 10. Datos normalizados-promediados de la Estación Meteorológica de la Esc. Ingeniera Eléctrica, Electrónica y Telecomunicaciones.....	45
Figura 11. Velocidad del viento registradas por la EIM Y E3T.	46
Figura 12. Temperatura ambiente registradas por la EIM Y E3T.	47
Figura 13. Dirección del viento registradas por la EIM y la E3T.....	48
Figura 14. Comportamiento de los datos originales	56
Figura 15. Función de Autocorrelación simple	57
Figura 16. Función de Autocorrelación Parcial.....	57
Figura 17. Análisis de los residuales	60
Figura 18. Grafica de Normalidad.	61
Figura 19. Predicción del Modelo ARIMA.....	62
Figura 20. Análisis de los residuales	64
Figura 21. Histograma de densidad	65
Figura 22. Grafica de Normalidad.	66
Figura 23. Predicción del modelo (4,0,0)(0,1,1) ²⁴	67
Figura 24. Modelo SARIMA (4,0,0)(0,1,1) ²⁴ vs Serie Original.	68
Figura 25. Pasos para hacer una Red Neuronal Artificial.....	70

Figura 26. Entrenamiento de Backpropagation.	71
Figura 27. Estructura de una red neuronal de tipo Backpropagation.	72
Figura 28. Datos de entrada de la Red Neural.	73
Figura 29. Predicción de la Velocidad de viento para el año 2019.	79
Figura 30. Predicción de la velocidad del viento	81
Figura 31. Predicción de la Temperatura ambiente.	82
Figura 32. Predicción de la Dirección del viento.	83
Figura 33. Creación del mapa de la UIS por medio del Software AUTOCAD.	85
Figura 34. Análisis de 2 dimensiones y cada edificación con sus propiedades topográficas.	89
Figura 35. Flujo de viento de la UIS.	91

LISTA DE ANEXOS

ANEXO A. MODELOS ARIMA	99
ANEXO B. MODELOS SARIMA.....	112
ANEXO C. MODELOS REDES NEURONALES	125

RESUMEN

TÍTULO: PREDICCIÓN DE CONDICIONES LOCALES Y TEMPORALES DEL VIENTO MEDIANTE EL MODELO ARIMA EN LA UNIVERSIDAD INDUSTRIAL DE SANTANDER.

AUTOR: INGRID TATIANA CARRILLO PICO**

PALABRAS CLAVE: PREDICCIÓN, ESTACIÓN METEOROLÓGICA, VELOCIDAD, TEMPERATURA, DIRECCIÓN.

DESCRIPCIÓN : Este proyecto de investigación tiene como objetivo determinar los perfiles de velocidad y dirección del viento en la Universidad Industrial De Santander, para lograrlo, se analizaron las variables de velocidad de viento, temperatura y dirección del viento registradas por las estaciones meteorológicas de la EIM Y E3T durante los periodos 2016,2017 y 2018. Se emplearon diversas técnicas, como de Box-Jenkis (ARIMA), SARIMA, redes neuronales backpropagation y el método de Rugosidad, con apoyo de softwares como R Studio, Simbrain y Matlab.

¹Se identificó que las series de tiempo presentaban patrones de estacionalidad cada 24 rezagos, por lo tanto, se empleó el modelo Sarima, los modelos de predicción se evaluaron utilizando el coeficiente de determinación R^2 presentando el mejor ajuste de predicción para la variable de la temperatura, sin embargo, en cuanto a la velocidad del viento, se observaron discrepancias en los pronósticos respecto a los datos reales, lo que indica que ningún modelo logró capturar de manera precisa las variaciones de la velocidad del viento y para la dirección del viento se determinó que no se puede predecirse debido a su comportamiento aleatorio. Como resultado, se determinaron los

*Tesis grado

**Facultad de Ingenieras Físico-Mecánicas.

Escuela de Ingeniería Mecánica. Dr. Alfredo David Fuentes Díaz, Ingeniero Mecánico. Co-director : Carlos Daniel Barrera Díaz.

perfiles de velocidad del viento en la zona de estudio los cuales oscilaron entre 1 m/s y 1,6 m/s.

ABSTRACT

TÍTULO: FORECASTING OF LOCAL AND SEASONAL WIND CONDITIONS USING THE ARIMA MODEL AT THE INDUSTRIAL UNIVERSITY OF SANTANDER.

AUTOR: INGRID TATIANA CARRILLO PICO**

PALABRAS CLAVE : PREDICTION, WEATHER STATION, SPEED, TEMPERATURE, DIRECTION.

DESCRIPTION: This research project aims to determine the wind speed and direction profiles at the Industrial University of Santander. To achieve this, the variables of wind speed, temperature, and wind direction recorded by the meteorological stations EIM and E3T during the periods of 2016, 2017, and 2018 were analyzed. Various techniques were employed, such as Box-Jenkins (ARIMA), SARIMA, backpropagation neural networks, and the Roughness method, with the support of software tools like R Studio, Simbrain, and Matlab.

It was identified that the time series exhibited seasonal patterns every 24 lags, therefore the Sarima model was employed. The prediction models were evaluated using the coefficient of determination R^2 , which presented the best fit for temperature prediction. However, discrepancies were observed in wind speed forecasts compared to the actual data, indicating that no model was able to accurately capture the variations in wind speed. Regarding wind direction, it was determined that it cannot be predicted due to its random behavior. As a result, wind speed profiles in the study area were determined to range between 1 m/s and 1.6 m/s.²

² *Degree work

**Faculty of Physical-Mechanical Engineering. School of Mechanical Engineering. Director: Dr. Alfredo David Fuentes Díaz, Mechanical Engineering. Co-director : Ing Carlos Daniel Barrera Díaz

1. INTRODUCCIÓN

La ejecución de este proyecto se encuentra enmarcado dentro del desarrollo de la tesis doctoral titulada “Predicción de las condiciones hidráulicas ambientales locales en la simulación del flujo de edificaciones naturalmente ventiladas”, aprobada por el programa de Doctorado en Ingeniería Mecánica, llevada a cabo por el Ing. Carlos Barrera el cual busca desarrollar algoritmos propios para la Universidad Industrial de Santander (UIS), y así poder simular los problemas de flujo del viento en edificaciones naturalmente ventiladas, mediante la simulación numérica del fenómeno de turbulencia; de esta manera, se hace imperativo conocer las condiciones locales y temporales del viento como son su temperatura, dirección y velocidad.

El viento es un factor a tener en cuenta en el momento de visualizar la ubicación y orientación de una edificación. En la (UIS), debido a la ubicación privilegiada que tiene, el aprovechamiento del viento para la ventilación natural de las edificaciones puede mitigar los efectos de uso excesivo de energía a través de sistemas de ventilación artificial.

En base a los datos históricos obtenidos por las dos estaciones meteorológicas, ubicadas en la Escuela de Ingeniería Mecánica (EIM) y la Escuela de Ingeniería Eléctrica, Electrónica y Telecomunicaciones(E3T), se busca desarrollar una metodología que permita extrapolar los datos de una ubicación a otra en un plano horizontal con el objetivo de verificar el potencial del viento para su utilización en sistemas de ventilación natural.

Después de obtener la base de datos históricos se realiza la extrapolación de las variables del viento. Este proceso se lleva a cabo mediante diversas metodologías como, Box – Jenkins (MODELO ARIMA), los cuales se resumen en cuatro fases para encontrar el modelo con mejor ajuste de predicción de una serie temporal de tiempo. Se implementa el modelo SARIMA (SEASONAL ARIMA) que es una extensión del modelo ARIMA que incorpora la componente de estacionalidad en las series temporales.

Posteriormente por medio de correlaciones y extrapolaciones se determina el valor de estas variables en cualquier punto de la zona de estudio. El traslado en el espacio de la velocidad de viento y dirección se realiza por medio del método de Roughness length con ayuda de la topografía del terreno.

2. JUSTIFICACIÓN

La información acerca del flujo de viento alrededor de un edificio presenta barreras para su estudio a causa de la variabilidad del medio ambiente siendo esto difícil de modelar y predecir. La finalidad de este proyecto es crear un algoritmo para las variables meteorológicas velocidad de viento, temperatura y dirección del viento que permita obtener predicciones dentro de la universidad Industrial de Santander para posteriormente extrapolar y trasladarlos en el espacio.

Por medio del software R Studio y Simbrain se desarrollarán algoritmos que permiten analizar los datos de estaciones meteorológicas logrando predecir las variables requeridas para obtener el flujo de aire, además dará paso a herramientas como el software Matlab que permitirán predecir condiciones locales y temporales del viento que luego serán incorporadas a modelos computacionales de dinámica de fluidos (CFD) con el fin de determinar las condiciones de ventilación en edificaciones.

Los estudios realizados en Colombia que aborden las predicciones del flujo de viento en conjunto con el traslado de variables han sido pocos, por eso, esta investigación es un aporte importante para el desarrollo de la tesis Doctoral del Ing. Carlos Barrera titulada “Predicción de las condiciones hidráulicas ambientales locales en la simulación del flujo de edificaciones naturalmente ventiladas” y para la sociedad investigativa en la parte de energía renovables como lo es la Energía Eólica que hoy en día está teniendo grandes avances a nivel mundial y en nuestro país.

3. OBJETIVOS

3.1 OBJETIVOS GENERALES

Determinar los perfiles de velocidad y dirección del viento en la Universidad Industrial De Santander.

3.2 OBJETIVOS ESPECÍFICOS

- Predecir en el tiempo la velocidad y dirección del viento a partir de datos de campo de estaciones meteorológicas mediante el modelo autorregresivo integrado de media móvil (ARIMA).
- Trasladar en el espacio la velocidad y dirección del viento aplicando correlaciones y extrapolaciones descritas en la literatura utilizando la topografía del terreno y los datos meteorológicas disponibles.
- Predecir en el tiempo la velocidad y dirección del viento con redes neuronales a partir de datos de campo de estaciones meteorológicas y comparar el error por medio de modelos estadísticos.

4. ANTECEDENTES

4.1 MODELIZACIÓN Y PREDICCIÓN DE LA ENERGÍA ELÉCTRICA PRODUCIDA EN UN AEROGENERADOR UTILIZANDO MODELOS ESTOCÁSTICOS TEMPORALES A PARTIR DE SERIES DE VIENTO

Se realiza un estudio enfocado en analizar y predecir la velocidad de viento, la temperatura y la potencia eléctrica en un parque de España. Cabe destacar que para el año 2016 el 40,8% de la demandada de energía eléctrica en España fue cubierta por energías renovables en efecto, resulto necesario estudiar diferentes series temporales y proponer diferentes modelos estocásticos temporales, como Box - Jenkins (ARIMA), utilizando el software libre R.

Para el desarrollo de este trabajo se analizaron tres métodos para obtener predicciones de la energía eléctrica, con el objetivo de compararlos y evaluar la efectividad del modelo que presentara el menor error. Para realizar esta evaluación, se aplicaron diferentes métodos estadísticos, como RMSE (raíz del error cuadrado medio), MAE (error absoluto medio), MAPE (porcentaje de error absoluto medio), ME (error medio) y MPE (porcentaje de error medio).

Con los resultados obtenidos se evidencio que la energía eléctrica presenta variabilidad a lo largo del tiempo. Además, se realizó una comparación entre los modelos directos e indirectos, es decir, los modelos directos son aquellos que se basan únicamente en los datos históricos de la variable estudiada, mientras que los modelos indirectos utilizan variables relacionadas y análisis adicionales para obtener el resultado de la predicción.

[2]

4.2 EVALUACIÓN DEL POTENCIAL SOLAR Y EÓLICO DEL CAMPUS CENTRAL DE LA UNIVERSIDAD INDUSTRIAL DE SANTANDER Y LA CIUDAD DE BUCARAMANGA, COLOMBIA

En la ciudad de Bucaramanga se han realizado diversos estudios relacionados con variables meteorológicas, como la velocidad y dirección del viento, la temperatura y la radiación solar. Estos estudios se llevaron a cabo en tres lugares estratégicos de la ciudad, utilizando mediciones a lo largo de los años 2010, 2011 y 2012. Estos datos fueron suministrados por la Corporación de la Defensa para la Meseta de Bucaramanga, CDMB. En el análisis de estas variables meteorológicas, se empleó la función de distribución de Weibull que depende de dos parámetros importantes: k , que representa el parámetro de forma y C , que representan el parámetro de escala. Para estimar estos parámetros, se utilizó el método de estimación estadísticas (SEM) este método se eligió debido a su tiempo reducido de computo en comparación con otros métodos de estimación de parámetros, como el LSM (Least Square Method) o el MEAM (Minimum Error Approximation Method). Esto resulta útil cuando se trabajan con grandes cantidades de datos, como las recopilaciones históricas de años anteriores. Posteriormente, se procede a determinar el nivel de correlación entre la función de distribución de Weibull y las variables medidas, utilizando el factor de correlación R^2 el cual permite tener una mayor precisión de los datos. Los resultados obtenidos revelaron que las velocidades del viento en la ciudad no alcanzan la velocidad mínima para el arranque de un aerogenerador que es de 2m/s a una altura de 50m, por lo tanto, no se identificó el potencial energético suficiente para la generación eléctrica mediante aerogeneradores [4].

4.3 PREDICCIÓN DE VARIABLES METEOROLÓGICAS POR MEDIO DE MODELOS ARIMA

Existen grandes avances en la predicción del clima a determinado tiempo y en la predicción estacional. Los modelos autorregresivos integrados de media móvil son ampliamente utilizados para obtener predicciones. Se investigaron dos proyectos de

predicciones; el primero proyecto se centró en la predicción de la radiación solar en intervalos de tiempo que iban desde 5 minutos hasta varias horas, estos datos presentaron variabilidad y no linealidad debido a la presencia de nubosidad, las pruebas realizadas revelaron que los mejores resultados son usando los modelos ARIMA. La segunda investigación se enfocó en predecir las lluvias del monzón de la India, y más específicamente, en estimar la demanda de agua para las siguientes 24 h utilizando el modelo ARIMA. En este caso se evidencio que el modelo ARIMA era el mas adecuado para desarrollar este tipo de estudios, aunque las redes neuronales proporcionan mejores predicciones

Teniendo en cuenta que el modelo ARIMA es una herramienta efectiva para desarrollar predicciones en series de tiempo univariadas, se propuso la creación de un algoritmo de predicción de variables meteorológicas usando los modelos ARIMA.

Para llevar a cabo este desarrollo, se recopiló información de tres estaciones meteorológicas del Servicio Meteorológico Nacional, México, para el 2013, específicamente para los meses; marzo y junio. La base de datos fue analizada por medio del software R, y se evaluaron las condiciones de alta y baja precipitación utilizando el modelo ARIMA. Los resultados revelaron que el modelo presentaba un bajo porcentaje de error en las mediciones y en el error cuadrado medio del error. El análisis de los resultados indicó que el modelo ARIMA es el modelo con el mejor ajuste de predicción de las variables meteorológicas en condiciones de baja precipitación. [8]

5. MARCO TEORICO

5.1 MODELOS DE PREDICCIÓN

Los modelos de predicción son aquellos que me permiten predecir a futuro una variable a partir de los datos históricos que se tienen mediante técnicas regresivas y se clasifican en función del horizonte de tiempo de pronóstico. En corto plazo; se efectúa cada mes o menos, mediano plazo; abarca un periodo más amplio, que va desde seis meses hasta tres años, largo plazo; de 3 años en adelante.

5.2 MODELO ARIMA

El modelo ARIMA (Autoregressive Integrated Moving Average) es empleado para analizar y predecir serie de datos históricos. La idea principal del modelo Arima es identificar patrones y relaciones en los datos históricos con el objetivo de realizar predicciones futuras que a su vez es modelado en función de los valores anteriores.

A diferencia de otros modelos, los modelos Arima no incluyen variables independientes. Se basan en la propia información de la serie temporal para generar las predicciones, esto implica que el modelo se basa en los patrones de autorrelación presentes en las series. Para el desarrollo de un modelo ARIMA se emplea una serie de procedimientos para identificar, ajustar y validar el modelo utilizando los datos de la serie temporal en cuestión.

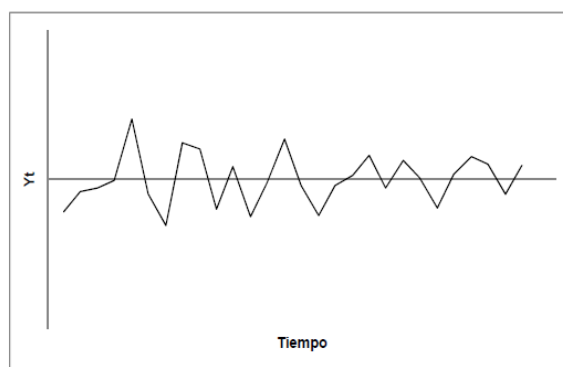
Para evaluar la calidad del modelo, se comparan los datos estimados con los datos históricos. Se analizan los residuos del modelo, teniendo en cuenta si se distribuyen de manera aleatoria, es decir, si presentan ruido. Si el modelo se ajusta de manera precisa a la serie temporal no es necesario realizar más diferenciaciones y mucho menos combinaciones de los posibles parámetros. [14]

En el análisis de series de tiempo se clasifican en dos categorías principales: estacionarias y no estacionarias, a continuación, se describen cada una de ellas.

5.2.1 Estacionarias

En la Figura 1 muestra una serie de tiempo estacionaria con características de estabilidad de la serie a lo largo del tiempo, lo cual indica que la varianza y la media se mantienen constantes. Esto indica que no muestra tendencia clara de la serie hacia un incremento o disminución, sino que los valores se mantienen en proximidad de un nivel central.

Figura 1. Serie de tiempo estacionaria.

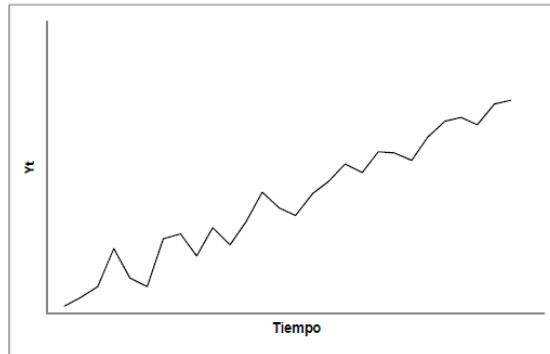


Fuente: PILCO SANCHEZ, Victoria Karina y ACURIO MARTINEZ, Washington David. Técnicas estadísticas para la modelación y predicción de la temperatura y velocidad de viento en la provincia de Chimborazo. Ecuador. Escuela Politécnica Superior de Chimborazo.

5.2.2 No estacionarias

En la Figura 2 se observa una serie tiempo con presencia de una tendencia en aumento y positiva, Además, la falta de oscilaciones constantes alrededor de un valor son indicativos de que la serie no presentan un comportamiento estacionario.

Figura 2. Serie de tiempo no estacionaria.



Fuente: PILCO SANCHEZ, Victoria Karina y ACURIO MARTINEZ, Washington David. Técnicas estadísticas para la modelación y predicción de la temperatura y velocidad de viento en la provincia de Chimborazo. Ecuador. Escuela Politécnica Superior de Chimborazo.

En algunos casos es difícil determinar visualmente si la serie es estacionaria o no estacionario, sobre todo cuando la presencia de tendencia es poco marcada, Por consiguiente, se recurre al análisis de la función de autocorrelación.

5.2.3 Procesos Lineales estacionarios

Los siguientes modelos deben ser trabajados como estacionarios, en caso tal que los datos sean no estacionarios, se debe realizar el debido procesos para convertirlo en estacionario.

5.2.3.1 Modelo auto regresivo AR(p)

Busca predecir observaciones futuras el modelo autorregresivo de primer orden conocido como AR(1) se centra en la observación inmediatamente anterior y el modelo de autorregresivo de segundo orden AR (2) se centra en las dos observaciones previas .

La ejecución de estos modelos se trabaja con el valor actual de la serie X_t y se explica en función de p valores pasados $X_{t-1}, X_{t-2}, \dots X_{t-p}$, donde p indica el número de rezagos necesarios para predecir un valor actual.

Un modelo autorregresivo de orden p tiene la forma

$$Y_t = \phi_0 + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t \quad \text{Ec. 1}$$

Donde:

Y_t : Variable respuesta en el tiempo t .

$\phi_0, \phi_1, \phi_2, \dots, \phi_p$: Coeficiente a ser estimados .

$Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$: Variable respuesta(independiente).

$t - 1, -2, \dots, t - p$: Periodos anteriores .

ε_t : Es el error de las variables

Modelo autorregresivo

$$Y = a + b_1 X_1 + b_2 X_2 + b_3 X_3 + \dots + b_p X_p + e \quad \text{Ec. 2}$$

Las variables independientes son simplemente valores rezagados de la variable dependiente con rezagos de tiempo $1, 2, 3, \dots, p$ periodos.

- **Proceso Autorregresivo de Orden 1: AR (p)**

En un modelo Autorregresivo AR (1) la variable X_t se determina por el valor pasado, es decir X_{t-1} .

$$X_t = \phi X_{t-1} + \varepsilon_t \quad \text{Ec. 3}$$

Donde:

ε_t es un procedimiento de ruido blanco con media 0 y varianza σ^2 , ϕ es el parámetro

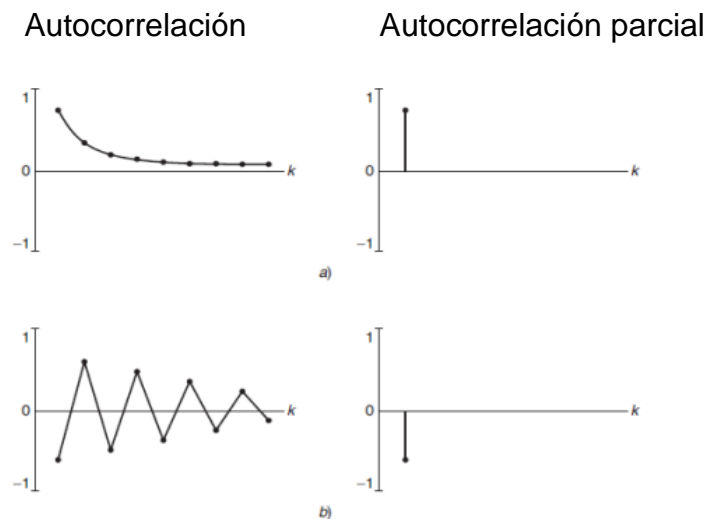
- **Características de un modelo AR (1)**

Las siguientes características son fundamentales para comprender y analizar el modelo de orden 1 :

- 1) Invertible
- 2) Estacionariedad
- 3) Función de autocorrelación
- 4) Función de autocorrelación parcial

La Figura 3(a) ilustra una disminución gradual hacia cero en la función de los coeficientes de autocorrelación a medida que aumenta el retraso de tiempo y en la Figura 3(b) ilustra una caída a cero después del primer retraso de tiempo.

Figura 3. Función de coeficientes de autocorrelación AR (1).



Fuente: PILCO SANCHEZ, Victoria Karina y ACURIO MARTINEZ, Washington David. Técnicas estadísticas para la modelación y predicción de la temperatura y velocidad de viento en la provincia de Chimborazo. Ecuador. Escuela Politécnica Superior de Chimborazo.

- **Proceso Autorregresivo de Orden 2: AR (p)**

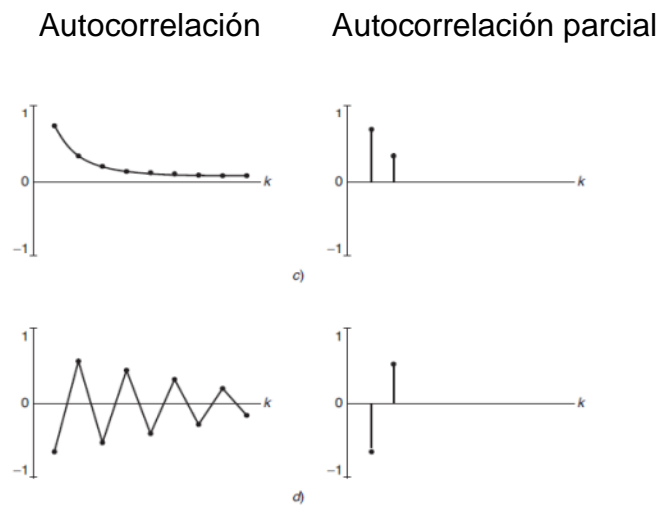
En el proceso AR (2) la variable X_t está determinado por el valor pasado y el anterior a este.

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \varepsilon_t \quad \text{Ec. 4}$$

Donde ε_t es un ruido blanco

La Figura 4(c) ilustra una disminución gradual hacia cero en la función de los coeficientes de autocorrelación a medida que aumenta el retraso de tiempo y en la Figura 4(d) ilustra una caída a cero después del segundo retraso de tiempo.

Figura 4. Función de coeficientes de autocorrelación AR (2).



Fuente: PILCO SANCHEZ, Victoria Karina y ACURIO MARTINEZ, Washington David. Técnicas estadísticas para la modelación y predicción de la temperatura y velocidad de viento en la provincia de Chimborazo. Ecuador. Escuela Politécnica Superior de Chimborazo.

5.2.3.2 Modelo de Medias Móviles MA(q)

En este modelo a diferencia del modelo autorregresivo en el modelo de medias móviles la observación actual se basa en los “impulsos aleatorios” de las observaciones

anteriores. Estos impulsos aleatorios representan las perturbaciones o errores que ocurren en la serie de tiempo que no se pueden predecir o explicar mediante observaciones pasadas.

El modelo de medias móviles tiene la siguiente forma:

$$X_t = \theta_0 - \theta_1 \varepsilon_{t-1} - \theta_2 \theta_1 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} + \varepsilon_t \dots \quad \text{Ec. 5}$$

Si se expresa en términos del operador de retardos:

$$X_t = (1 - \theta_1 L - \theta_2 L^2 - \dots - \theta_q L^q) \varepsilon_t \quad \text{Ec. 6}$$

$$X_t = \theta_q(L) \varepsilon_t \quad \text{Ec. 7}$$

Donde:

ε_t es un ruido blanco y $\mu, \theta_1, \theta_2, \dots, \theta_q$ son los parámetros del modelo.

- **Proceso de Media Móvil de orden 1: MA (1)**

Los modelos de medias móviles se basan en el valor X_t en función de la innovación actual y su primer retardo, esto es:

$$X_t = \varepsilon_t - \theta \varepsilon_{t-1} \quad \text{Ec. 8}$$

Expresado en función del polinomio operador de retardo es:

$$X_t = (1 - \theta) \varepsilon_t \quad X_t = \theta_1(L) \varepsilon_t \quad \text{Ec. 9}$$

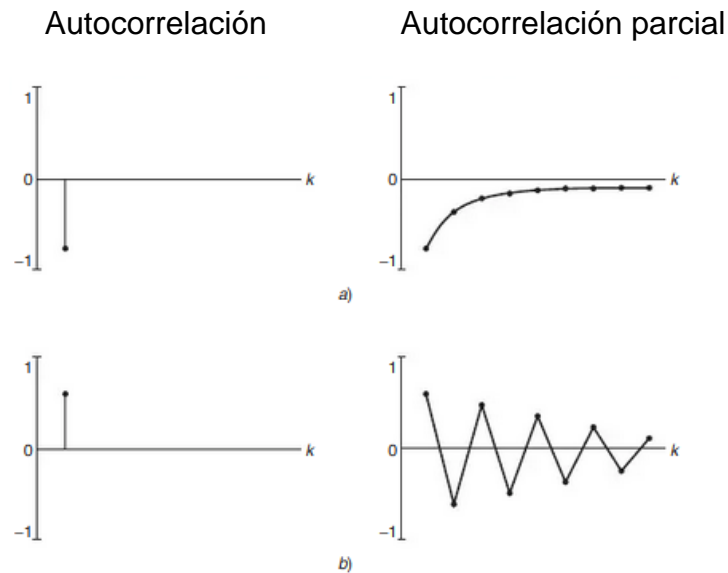
Donde ε_t es un proceso de ruido blanco y es el parámetro

Para realizar un modelo de promedio de media móvil debe cumplir los siguientes requerimientos:

- Estacionario en media, para todo valor del parámetro
- Estacionario en covarianza

La Figura 5(a) ilustra una disminución gradual hacia cero en la función de los coeficientes de autocorrelación después del primer retraso y en la Figura 5(b) ilustra un comportamiento de caída a cero gradualmente.

Figura 5. Función de coeficientes de autocorrelación MA (1).



Fuente: PILCO SANCHEZ, Victoria Karina y ACURIO MARTINEZ, Washington David. Técnicas estadísticas para la modelación y predicción de la temperatura y velocidad de viento en la provincia de Chimborazo. Ecuador. Escuela Politécnica Superior de Chimborazo.

- **Proceso de Media Móvil de orden 2: MA (2)**

Modelo de medias móviles de orden 2:

$$X_t = \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} \quad \text{Ec. 10}$$


Donde los parámetros son θ_1 y θ_2 , además ε_t es un proceso de ruido blanco. Este proceso es estacionario para cualquier valor de θ_1 y θ_2

- **Las características más importantes son:**

- 1) Estacionario en media
- 2) Función de autocovarianza

La Figura 6 (c) ilustra un comportamiento de disminución gradual hacia cero en la función de los coeficientes de autocorrelación después del segundo retraso de tiempo en la Figura 6(d) ilustra que la función de autocorrelación parcial tienden gradualmente a cero a medida que aumenta el retraso de tiempo.

Figura 6. Función de coeficientes de autocorrelación MA (2).



Fuente: PILCO SANCHEZ, Victoria Karina y ACURIO MARTINEZ, Washington David. Técnicas estadísticas para la modelación y predicción de la temperatura y velocidad de viento en la provincia de Chimborazo. Ecuador. Escuela Politécnica Superior de Chimborazo.

5.2.3.3 Procesos Autorregresivos de Medias Móviles ARMA (p,q)

El modelo ARMA (Autorregresivo de Medias Móviles) es una combinación de las estructuras (AR) y (MA). En este modelo, cada observación se determina por las observaciones anteriores como por los impulsos aleatorios o errores de las observaciones pasadas.

Un modelo ARMA (p, q) se representa de la siguiente manera:

$$X_t = c + \phi_1 x_{t-1} + \dots + \phi_p X_{t-p} + \theta_1 \varepsilon_{t-1} + \theta_1 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t \quad \text{Ec. 11}$$

Donde:

ε_t es ruido blanco y $c, \phi_1, \dots, \phi_p, \dots, \theta_1, \dots, \theta_q$ parametros del modelo

- **Características de un modelo ARMA (p,q) estacionario:**

En la construcción y análisis de modelos ARMA, se consideran ciertos criterios importantes como; media igual a cero, varianza constante y la función de autocorrelación decreciente hacia cero.

- Media

$$E(X_t) = E(\phi X_{t-1} + \varepsilon_t - 0\varepsilon_{t-1}) = \phi E(X_{t-1}) \quad \text{Ec. 12}$$

$$E(X_t) = 0$$

- Función de Autocovarianza

$$\gamma_k = \begin{cases} \gamma_0 = \frac{(1+\theta^2-2\phi\theta)\sigma^2}{1-\phi^2} & k=0 \\ \gamma_1 = \phi\gamma_0 - \theta\sigma^2 & k=1 \\ \gamma_k = \phi\gamma_{k-1} & k < 1 \end{cases} \quad \text{Ec. 13}$$

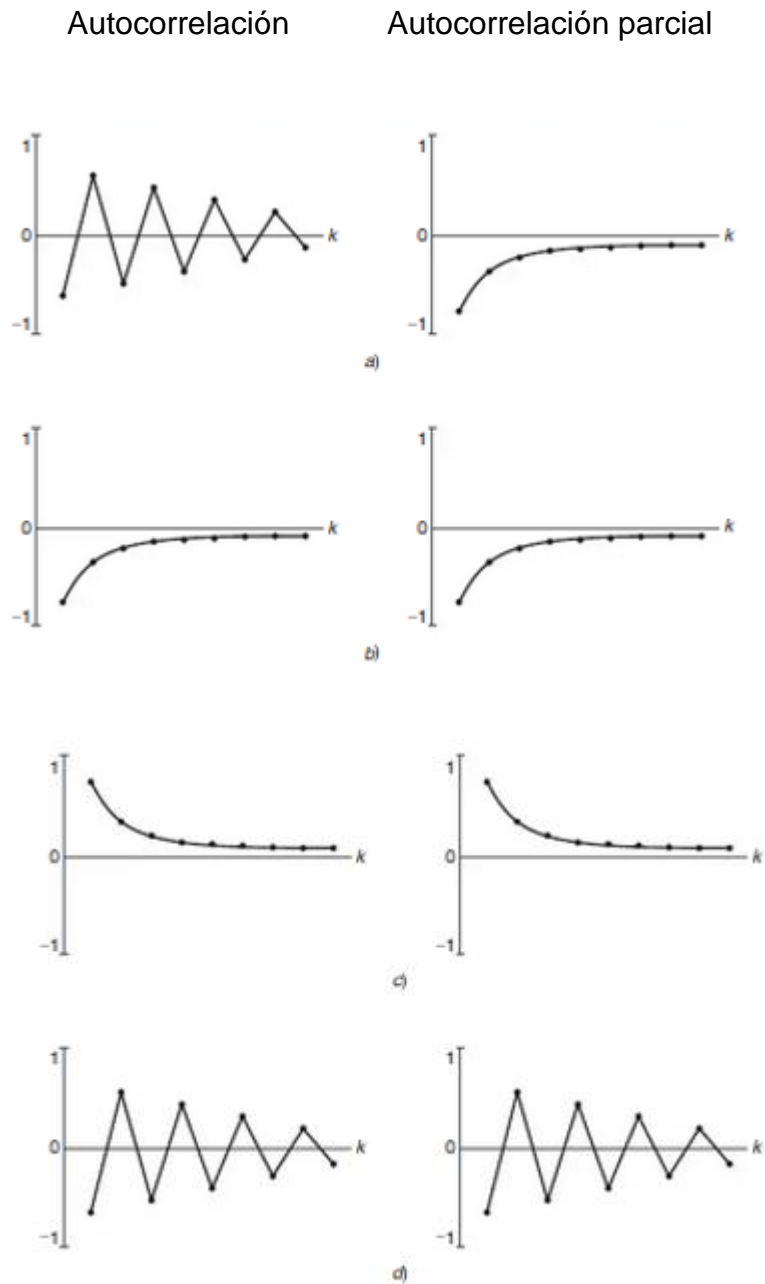
- Función de autocorrelación

$$\rho_k = \begin{cases} \rho_1 = \phi - \frac{\theta\sigma^2}{\gamma_0} & k=0 \\ \rho_k = \phi\rho_{k-1} & k > 0 \end{cases} \quad \text{Ec. 14}$$

En la determinación del número de términos autorregresivos y de promedio móvil en un modelo ARMA (orden p y orden q) es necesario analizar los patrones de las autocorrelaciones y autocorrelaciones parciales de la muestra, así como utilizar criterios de selección de modelo.

La Figura 7 se ilustra los comportamientos de las autocorrelaciones y autocorrelaciones parciales teóricas en un análisis de serie de tiempo. En este caso particular, se observa que tanto las autocorrelaciones como las autocorrelaciones parciales disminuyen gradualmente y no terminan de manera abrupta.

Figura 7. Función de Coeficientes de autocorrelación de un modelo mixto ARMA (1,1).



Fuente: PILCO SANCHEZ, Victoria Karina y ACURIO MARTINEZ, Washington David. Técnicas estadísticas para la modelación y predicción de la temperatura y velocidad de viento en la provincia de Chimborazo. Ecuador. Escuela Politécnica Superior de Chimborazo.

5.2.4 Procesos Lineales no Estacionarios

5.2.4.1 Proceso Autorregresivo Integrado y de Media Móvil ARIMA (p,d,q)

Esta clase de modelo se emplea en series de tiempo que no presentan estacionariedad, lo que significa que su media y varianza ya no son constantes. Generalmente, este fenómeno es común en serie económicas debido a los cambios de nivel a lo largo del tiempo o a la variabilidad no constante de la serie. Estos tipos de procesos se conocen como procesos integrados. Por consiguiente, se aplican diferencias a la serie de tiempo original. Estas diferencias se realizan d veces según sea necesario, hasta que la serie transformada presente sea estacionariedad, a esta serie diferenciada se le aplica un modelo $ARMA(p,q)$, y como resultado final se analiza la serie de tiempo transformada $ARIMA(p,d,q)$.

Dónde: p representa el orden de los elementos de autorregresivos, d es el número de diferencias para que la serie sea estacionaria y q representa el orden de los elementos de la media móvil.

Su expresión algebraica es:

$$(X_t)^d = c + \underbrace{\phi_1 X_{t-1}^d + \dots + \phi_p (X_{t-p})^d}_{AR(q)} + \quad Ec. 15$$

$$\underbrace{\theta_1 (\varepsilon_{t-1})^d + \theta_2 (\varepsilon_{t-2})^d + \dots + \theta_q (\varepsilon_{t-q})^d + \varepsilon_t^d}_{MA(q)}$$

5.2.5 Modelo Sarima

Seasonal Autoregressive Integrated Moving Average, denominado SARIMA por sus siglas en ingles. Es un modelo que se aplica cuando la serie de tiempo presenta patrones estacionales, es decir, variaciones regulares que se repiten a lo largo del tiempo.

ARIMA (p,d,q)x(P,D,Q)s.

Donde,

P: parámetro auto-regresivo (AR) estacional.

D: Diferenciación estacional o grado de integración

Q: Parámetro media móvil (MA) estacional

S: periodo de tiempo de repetición


5.3 REDES NEURONALES

Una Red Neuronal Artificial (RNA) se caracteriza por ser una herramienta computacional diseñada para simular el funcionamiento de un sistema nervioso como el presente en los organismos vivos. Se basa en la interconexión de neuronas artificiales para procesar información y producir resultados. Cada neurona artificial recibe entradas ponderadas las procesa a través de una función de activación y genera una salida.

5.3 1 Arquitectura de una RNA

En la Figura 8 presenta la arquitectura de una red neural en la cual se observa la interconexión entre las distintas neuronas que la componen. Estas neuronas se organizan en capas, donde cada capa está compuesta por un conjunto de neuronas de número variable y comportamiento similar.

Figura 8. Arquitectura de una RNA.



Fuente: PERÉZ RODRIGUEZ, Daniel. Predicción de la velocidad del viento para la generación eólica mediante redes neuronales artificiales. Universidad Central “Marta Abreu” de Las Villas.

- **Capa de entrada:** Se encarga recibir las señales de entrada o los datos y distribuirlos a las neuronas de la capa oculta. Su principal función es la recepción de datos y su estructura se determina según la caracterización y los datos del fenómeno en estudio
- **Capas ocultas:** Son responsables de extraer características y generalidades de los patrones de ingreso a través de los pesos y umbrales establecidos. Estas capas realizan cálculos y procesamientos permitiendo a la red neuronal realizar tareas complejas.
- **Capa de salida:** es la encargada de proporcionar respuestas o predicciones a partir de estímulos recibidos por la capa oculta. El número de neuronas en la capa de salida puede variar dependiendo del diseño y los objetivos de la red neuronal.

5.3.2 Clasificación de las RNA

Las Redes neuronales artificiales pueden clasificarse en dos categorías según el método de supervisión del aprendizaje. Esas categorías se identifican por la forma en que se realiza la supervisión y el ajuste de los pesos sinápticos durante el proceso de entrenamiento de la red.

- **Supervisadas:** Se caracteriza por aprender la interacción entre los datos de entrada y las salidas correspondientes. La red neuronal ajusta los pesos sinápticos iterativamente para disminuir la diferencia entre las salidas predichas por la red y las salidas esperadas esto se obtiene mediante el uso de algoritmos de optimización como el descenso del gradiente que actualiza los pesos en función del error cometido. La red de aprendizaje supervisado más utilizada es backpropagation (retropropagación)
- **No supervisadas:** Se basa solo en datos de entrada y la actualización de los pesos se lleva cabo internamente. La red neuronal busca descubrir patrones o estructuras útiles en los datos de entrada sin una guía explícita. [16]

5.3.3 El Algoritmo Backpropagation

Es una técnica utilizada en el entrenamiento de redes neuronales artificiales supervisadas. El proceso de retropropagación se basa en el gradiente descendente el cual busca encontrar el mínimo error global de una función de error, el algoritmo se divide en dos fases principales: propagación hacia adelante (forward propagation) y propagación hacia atrás (backward propagation).

Durante la propagación hacia adelante las entradas son introducidas en la red neuronal y se propagan a través de las capas ocultas hasta llegar a la capa de salida. En cada capa se calcula la salida de las neuronas utilizando los pesos sinápticos actuales y una función de activación. Una vez obtenida la salida de la red se compara con la salida esperada y se calcula el error.

En la fase de propagación hacia atrás, el error calculado se propaga desde la capa de salida hacia las capas ocultas utilizando el gradiente descendente. El gradiente se calcula aplicando la regla de la cadena y representa la tasa de cambio del error con respecto a los pesos sináptico de cada neurona. Estos procesos se repiten iterativamente hasta que se alcance un error aceptable [17]

6. METODOLOGÍA

A continuación, se expondrá detalladamente el procedimiento de cada modelo utilizado, se inicia por la preparación de los datos, seguido por la implementación de los modelos ARIMA, SARIMA Y REDES NEURONALES.

ARIMA, es una técnica estadística ampliamente utilizada, este modelo se basa en tres componentes: la parte autorregresiva (AR), la parte de promedio móvil (MA) y la parte de integración (I). Cada componente desempeña un papel fundamental en la predicción de series temporales, permitiendo capturar la tendencia, la estacionalidad y a la aleatoriedad presentes en los datos. SARIMA es una extensión del ARIMA que considera la estacionalidad en las series temporales. A través de la inclusión de los componentes de estacionalidad y diferenciación estacional, SARIMA es una modelo que pronostica patrones recurrentes en los datos a lo largo del tiempo. Estos dos modelos se emplearon mediante el software R y para las REDES NEURONALES se implementa el software SIMBRAIN es una técnica de aprendizaje automático basada en la estructura y funcionamiento del cerebro humano, utilizan capas de neuronas interconectadas para procesar y analizar datos permitiendo capturar relaciones no lineales complejas en las series temporales.

Asimismo, para el análisis y proyecciones de flujo de aire en las edificaciones del campus Universitario, se implementará el método de Longitud de Rugosidad en el software MATLAB. Este modelo permitirá hallar las velocidades del viento en base a las alturas de las edificaciones que serán tomadas como puntos de referencia para estimar la velocidad del viento en diferentes ubicaciones y alturas dentro del área analizada.

6.1 HERRAMIENTAS COMPUTACIONALES

En el desarrollo de los modelos de predicción y análisis predictivo, se emplearon herramientas computacionales, tales como Microsoft Excel, R STUDIO y SIMBRAIN cada uno desempeña un proceso de construcción para los modelos de predicción.

Microsoft Excel es una herramienta que se emplea para el tratamiento de los datos tal como completar las series de tiempo sin datos faltantes, este proceso es crucial para aplicar los respectivos modelos.

R STUDIO es un software libre y de código abierto disponible bajo una Licencia Pública General (GNU). Es decir, que puede ser instalado y utilizado de manera gratuita, está diseñado para trabajar en el lenguaje de programación R y cuenta con una gran cantidad de paquetes y algoritmos de aprendizaje automático que permiten construir y ajustar modelos predictivos.

SIMBRAIN es un software libre y de código abierto desarrollado en Java que está en constante evolución, permite construir, ejecutar y analizar redes neuronales utilizando el algoritmo de retropropagación (Backpropagation) para realizar predicciones.

6.2 DATOS A USAR

Se utilizó una serie de datos históricos obtenidos de dos Estaciones Meteorológicas ubicadas en la UIS. Específicamente, se recolectaron datos de los periodos comprendidos entre 2016, 2017 y 2018. Estas estaciones están situadas en la EIM y E3T.

La serie de datos correspondiente a la Estación Meteorológica de la EIM consistió en un total de 69,452 registros. Por otro lado, de la Estación Meteorológica de la E3T proporcionó una serie de datos con un total de 80,337 registros.

Estos datos históricos representan mediciones y observaciones realizadas en diferentes variables climáticas y meteorológicas. Para este proyecto las variables de interés son velocidad del viento, la temperatura y dirección del viento.

6.3 TRATAMIENTO DE LOS DATOS

Los datos en bruto consisten en un registro diario de cada 15 minutos de las variables velocidad, temperatura y dirección, como se muestra en la Tabla 1 El conjunto de datos correspondientes a las estaciones meteorológicas corresponde a 69,452 en la estación de la EIM, y 80,452 de la estación de la E3T.

Tabla 1 . Base de datos de la Estación Meteorológica de la EIM.

Hora	Temperatura (°C)	Velocidad (m/s)	Dirección (Grados)	Mes	Año
5:00:00 p. m.	26,30	1,8	135	6	2016
5:15:00 p. m.	25,90	1,8	90	6	2016
5:30:00 p. m.	25,50	1,3	67,5	6	2016
5:45:00 p. m.	25,10	1,3	90	6	2016
6:00:00 p. m.	24,80	1,3	90	6	2016
6:15:00 p. m.	24,60	0,9	67,5	6	2016
6:30:00 p. m.	24,40	1,3	67,5	6	2016
6:45:00 p. m.	24,20	1,3	67,5	6	2016
7:00:00 p. m.	24,10	0,9	90	6	2016
7:15:00 p. m.	24,00	0,9	45	6	2016
7:30:00 p. m.	23,90	0,4	45	6	2016
7:45:00 p. m.	23,90	0,9	90	6	2016
8:00:00 p. m.	23,40	0,9	90	6	2016
8:15:00 p. m.	23,40	0,9	90	6	2016

Fuente: Elaboración propia.

Con el objetivo de tener los datos ajustados a las necesidades de los programas utilizados se hizo un tratamiento de los datos que consiste en:

- Transformación de datos (Normalización)
- Promedio general

Tabla 2. Datos normalizados de la Estación Meteorológica de la EIM

Hora	Normalizado				
	Hora	Temperatura (°C)	Velocidad (m/s)	Dirección (Grados)	Mes
5:00:00 p. m.	0,69565217	0,827044025	0,36734694	0,4	0,45454545
5:15:00 p. m.	0,73913043	0,814465409	0,36734694	0,26666667	0,45454545
5:30:00 p. m.	0,73913043	0,801886792	0,26530612	0,2	0,45454545
5:45:00 p. m.	0,73913043	0,789308176	0,26530612	0,26666667	0,45454545
6:00:00 p. m.	0,7826087	0,779874214	0,26530612	0,26666667	0,45454545
6:15:00 p. m.	0,7826087	0,773584906	0,18367347	0,2	0,45454545
6:30:00 p. m.	0,7826087	0,767295597	0,26530612	0,2	0,45454545
6:45:00 p. m.	0,7826087	0,761006289	0,26530612	0,2	0,45454545
7:00:00 p. m.	0,82608696	0,757861635	0,18367347	0,26666667	0,45454545
7:15:00 p. m.	0,82608696	0,754716981	0,18367347	0,13333333	0,45454545
7:30:00 p. m.	0,82608696	0,751572327	0,08163265	0,13333333	0,45454545
7:45:00 p. m.	0,82608696	0,751572327	0,18367347	0,26666667	0,45454545
8:00:00 p. m.	0,82608696	0,735849057	0,18367347	0,26666667	0,45454545
8:15:00 p. m.	0,86956522	0,735849057	0,18367347	0,26666667	0,45454545

Fuente: Elaboración propia.

6.3.1 Normalización

Para el proceso de normalización los datos de las variables velocidad del viento, la temperatura y dirección del viento; hora, día y mes de la toma del registro se llevaron a una escala comprendida entre 0 y 1. Este proceso consistió en encontrar el valor máximo, el valor mínimo y calcular la relación del dato respecto de la diferencia entre los valores máximos y mínimos, como se muestra en la Ec. 16. En la Tabla 2 se muestra una pequeña porción del proceso de normalización.

$$X^* = \frac{X - X_{min}}{X_{max} - X_{min}} \quad Ec. 16$$

6.3.2 Promedio general

Una vez normalizado los datos se procede a completar los datos faltantes. En este caso, se promediaron los datos correspondientes a una misma hora y día por cada mes. El resultado se muestra en la Tabla 3, y en la Figura 9 se observan los datos tratados de la estación meteorológica de la EIM, y en Figura 10 los datos de la estación meteorológica de la E3T. En las columnas de velocidad promedio, temperatura promedio y dirección promedio, se encuentran los datos procesados y preparados para la implementación de los modelos de predicción. Estas columnas contienen la información requerida para llevar a cabo el análisis predictivo y generar pronósticos basados en las variables de velocidad de viento, la temperatura y dirección del viento. Los datos presentes en estas columnas han sido sometidos a un proceso de tratamiento y transformación con la finalidad de asegurar la calidad de los modelos de predicción.


Tabla 3. Promedio de la base de datos para la EIM

	Promedio general			
Hora	Velocidad (m/s)	Temperatura (°C)	Dirección (Grados)	Mes
0	0,02984213	0,693589059	0,159433962	0
0,043478261	0,03311513	0,682211938	0,13509434	0,09090909
0,086956522	0,02541394	0,672619754	0,129559748	0,18181818
0,130434783	0,0238737	0,664530675	0,179874214	0,27272727
0,173913043	0,01732769	0,653233654	0,163522013	0,36363636
0,217391304	0,01617251	0,644772754	0,201677149	0,45454545
0,260869565	0,02368117	0,64090127	0,258805031	0,54545455
0,304347826	0,0477474	0,666631067	0,353962264	0,63636364
0,347826087	0,09061738	0,707784502	0,376939203	0,72727273
0,391304348	0,16633132	0,749697345	0,354929577	0,81818182
0,434782609	0,25419501	0,799301188	0,34345679	0,90909091
0,47826087	0,36974049	0,825452287	0,353497942	1
0,52173913	0,44595616	0,828718262	0,327777778	0
0,565217391	0,48480726	0,82947822	0,322469136	0,09090909

Fuente: Elaboración propia.

En la Figura 9 se visualiza que la serie de tiempo original de la velocidad del viento para la estación meteorológica de la EIM no tiene una tendencia por ende podemos asumir que presenta un comportamiento estacionario, también se observa que la velocidad máxima alcanza durante los años 2016, 2017 y 2018 fue en el mes de febrero.


Figura 9. Datos normalizados-promediados de la Estación Meteorológica de la EIM.



Fuente: Elaboración propia.

En la Figura 10 se analiza que la serie de tiempo de la Estación Meteorológica de la E3T podría ser una serie estacionaria, para ello se debe verificar por medio de la prueba de Dicker Fuller. Además, se observa que la máxima velocidad registrada para los años 2016, 2017 y 2018 se produjo en el mes de febrero al igual que en la estación meteorológica de la EIM.

Figura 10. Datos normalizados-promediados de la Estación Meteorológica de la Esc. Ingeniera Eléctrica, Electrónica y Telecomunicaciones.

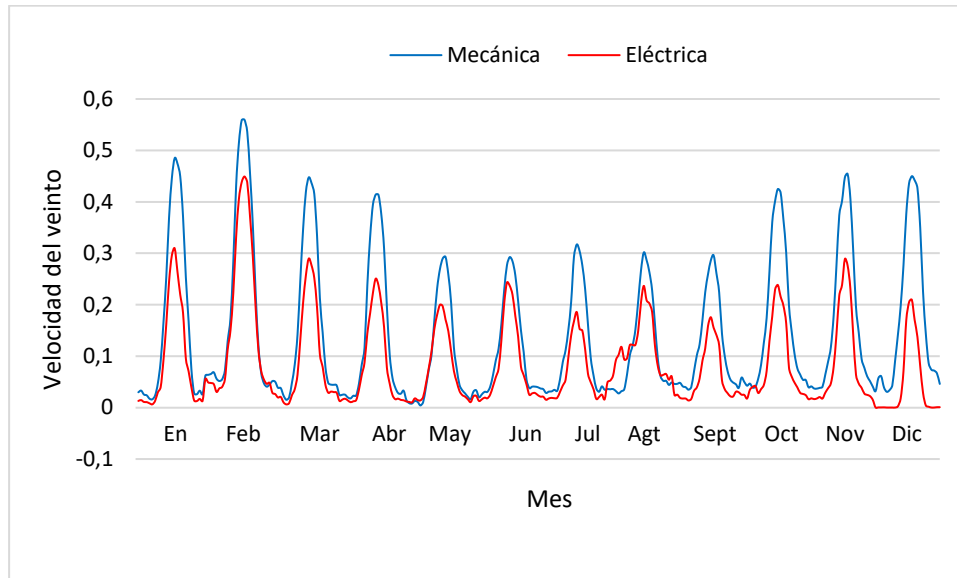


Fuente: Elaboración propia.

6.4 ANÁLISIS ENTRE LOS DATOS DE LAS DOS ESTACIONES METEOROLÓGICAS

En la Figura 11 se presenta las velocidades del viento registradas en las dos estaciones Meteorológicas situadas en la Universidad. Se observa que la estación de la EIM muestra una velocidad de viento mayor en comparación con la estación de la E3T. Esto podría ser por diversos factores, como la posible descalibración de los instrumentos de medición utilizados en cada estación, la presencia de obstáculos, las diferencias entre las ubicaciones topográficas de las estaciones y la influencia de corrientes de aire pueden afectar las mediciones. Se esperaba que existiera una mayor similitud en los datos registrados por ambas estaciones, dado que se encuentran relativamente cercanas entre sí.

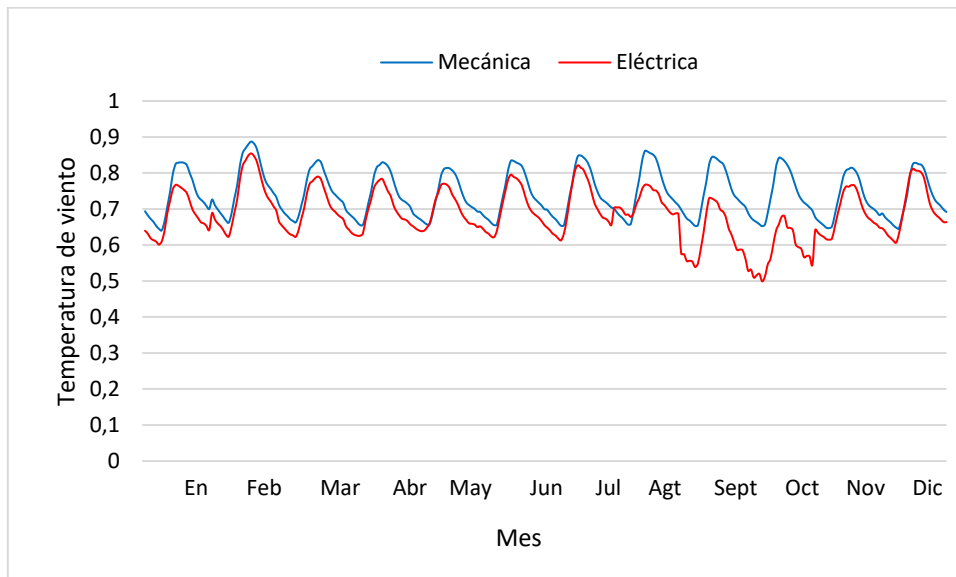
Figura 11. Velocidad del viento registradas por la EIM Y E3T.



Fuente: Elaboración propia.

En la Figura 12 ilustra un análisis comparativo de las temperaturas registradas en ambas Estaciones Meteorológicas. Se observa una notable similitud entre las mediciones, aunque no son idénticas. Para los meses; agosto, septiembre y octubre presentan una discrepancia que puede atribuirse a la influencia de la ubicación de cada estación, la cual está condicionada por la topografía del terreno. Las diferencias en la ubicación de las estaciones pueden generar variaciones locales en la temperatura registrada. Esto podría ser por varios factores como la presencia de obstáculos, la descalibración de los instrumentos de medición y la influencia de corrientes de aire pueden afectar las mediciones y generar diferencias entre las estaciones. A pesar de estas discrepancias, se observa una tendencia general de similitud en los datos de temperatura entre las dos estaciones meteorológicas.


Figura 12. Temperatura ambiente registradas por la EIM Y E3T.



Fuente: Elaboración propia.

En la Figura 13 se analizó la dirección del viento registrada en ambas Estaciones Meteorológicas. Es importante tener en cuenta que en la estación de la EIM y la E3T se encuentra relativamente cercanas entre sí, con una cierta inclinación relativa entre ellas. Se observa una notable variabilidad en la dirección del viento entre las dos estaciones. No se evidencia una similitud clara en las direcciones del viento registradas por las estaciones. Esto puede estar influenciado por factores topográficos, como para presencia de obstáculos o la conformación del terreno en las proximidades de la estación.

Figura 13. Dirección del viento registradas por la EIM y la E3T.



Fuente: Elaboración propia.

6.5 MODELO ARIMA

El ARIMA se compone de tres parámetros fundamentales: dos de ellos provienen de los modelos ARMA, mientras que el tercer parámetro corresponde al orden de diferenciación. El modelo se describe como ARIMA (p,d,q) donde p y q indican el número de datos pasados que se utilizan para estimar el modelo, y d se refiere al grado de integración.

El desarrollo del modelo ARIMA requiere la ejecución de tres etapas fundamentales a través del software R Studio: identificación, estimación, verificación diagnóstica, y predicción. Estas etapas se llevan a cabo mediante el código y permiten el desarrollo de un modelo que se ajuste adecuadamente a los datos de la serie de tiempo.

6.5.1 Etapa de identificación

Esta etapa consta de la verificación de la serie estacionaria y los posibles parámetros del modelo como se describe a continuación:

Verificación del carácter estacionario de la serie

En el proceso de desarrollo del código para el modelo ARIMA en R Studio, fue necesario instalar varios paquetes para llevar a cabo todas las etapas del proceso de predicción. Posteriormente, se inició la etapa de identificación de los datos y verificación de la estacionariedad. Si la serie de tiempo no es estacionaria, se utilizó la técnica de diferenciación la cual consiste en calcular la diferencia entre los valores sucesivos de la serie. La diferenciación permite eliminar la tendencia y obtener una serie de tiempo estacionaria que pueda ser utilizada para continuar con el desarrollo del código.

Revisar alcance de la correlación

Para la obtención de los parámetros p y q se realiza mediante la visualización y análisis de los correlogramas, Es proceso se realiza en R Studio mediante la ejecución del código, lo que permite obtener la mejor estimación de los parámetros (p y q) para la serie de tiempo.

6.5.2 Estimación

La estimación del modelo ARIMA implica ajustar los parámetros del modelo utilizando los datos observados de la serie de tiempo. Esta etapa se basa en que los parámetros deben tener significancia y capturar de manera adecuada los valores de los parámetros del modelo.

Esto se realiza por medio de los valores de error estándar y el valor t asociado a cada uno de los coeficientes del modelo.

El valor de t se define como:

$$t = \frac{\text{coeficiente calculado}}{\text{error estándar asociado al coeficiente calculado}} \quad \text{Ec. 17}$$

6.5.3 Verificación

En el proceso de validación de un modelo, se debe verificar la presencia de ruido blanco en los residuos, con el fin de asegurar que el modelo no se encuentre sobreajustado. Para ello, se realiza el test Ljung-Box, el cual evalúa si los residuos del modelo presentan una distribución normal y si son independientes.

6.5.4 Predicción

Para el análisis de los modelos predictivos, es necesario evaluar el rendimiento del modelo en el pronóstico de los periodos estimados. Esto se realiza comparando las predicciones del modelo con los valores reales, y evaluando el coeficiente de determinación R^2 .

Por medio del coeficiente de determinación R^2 se evalúa la bondad de ajuste del modelo, permitiendo cuantificar la precisión del mismo y se calcula de la siguiente manera:

$$R^2 = \frac{\sum_{t=1}^t (\hat{Y}_t - \bar{Y})^2}{\sum_{t=1}^t (Y_t - \bar{Y})^2} \quad \text{Ec. 18}$$

Donde;

t = Cantidad de datos

\hat{Y}_t = Serie original

Y_t = Promedio de la serie original

\bar{Y} = Pronostico

El coeficiente de determinación evalúa la precisión del ajuste de un modelo de regresión a los datos observados. Este coeficiente puede tomar valores en el rango de 0 a 1, donde los valores más aproximados a 1 indican un mejor ajuste del modelo a la variable que se

está analizando. Por el contrario, los valores cercanos a 0 indican un ajuste deficiente del modelo.

Una vez seleccionado el de mejor ajuste, se puede realizar una predicción precisa de los valores futuros con una cierta confianza.

6.6 MODELO SARIMA

El modelo SEASONAL ARIMA (SARIMA) es una extensión del modelo ARIMA que permite incorporar componentes estacionales a las series de tiempo. La estimación de los parámetros del modelo SARIMA sigue la misma metodología del modelo ARIMA, tal y como se explicó en la sección anterior.

$$\text{ARIMA}(p,d,q) \times (P,D,Q)_S.$$

Donde,

P: parámetro auto-regresivo (AR) estacional.

D: Diferenciación estacional o grado de integración

Q: Parámetro media móvil (MA) estacional

S: periodo de tiempo de repetición

Como se verá más adelante, el modelo ARIMA evaluado previamente no cumple con los criterios mínimos de predicción como es la no estacionalidad para considerarlo un modelo adecuado, se prueba el modelo SARIMA. Este modelo se utiliza para modelamiento de series de tiempo que presentan patrones estacionales, como se observa que ocurre en las Figura 9 y Figura 10.

En los modelos SARIMA se estima la presencia de los coeficientes autorregresivos (AR) y de media móvil (MA). Teniendo en cuenta el número de diferencias necesaria para eliminar la tendencia y la estacionalidad. Por tanto, se corre el código arrojando una lista de posibles modelos y junto con ellos el mejor Modelo SARIMA.

6.7 REDES NEURONALES

Las Redes Neuronales de Retropropagación (Backpropagation) se caracteriza por ser un tipo de arquitectura de redes artificiales que utilizan un algoritmo de aprendizaje supervisado para ajustar los pesos sinápticos entre las neuronas y realizar predicciones. A continuación, se nombran los pasos para llevar a cabo este modelo.

6.7.1 Preparación de los datos

Es necesario preparar los datos de entrenamiento, es decir la normalización de los datos y así poder implementar el entrenamiento y obtener resultados de calidad.

6.7.2 Estructura de la red neuronal

Define la estructura de la red neuronal, incluyendo el número de capas ocultas y neuronas en cada capa, así como el tipo de algoritmo de aprendizaje supervisado Backpropagation.

- **Importar datos**

Para llevar a cabo el proceso de entrenamiento de la red neuronal, es necesario importar los datos de entrada y salida desde una fuente externa.

- **Proceso de entrenamiento**

Se inicia con propagación hacia delante, los datos de entrada se introducen en la red neuronal y se propagan a través de las capas ocultas hasta la capa de salida, se compara

la capa de salida generada por la red neuronal con la capa de salida conocida para el conjunto de entrenamiento. Se calcula el error, que representa la diferencia entre la salida predicha y la salida real. Con este error se realiza la retropropagación hacia atrás, esto implica calcular el gradiente del error con respecto a los pesos de las conexiones en cada capa. Luego viene la actualización de los pesos y la iteración.

- **Iteración del proceso**

Este proceso de iteración depende del menor porcentaje de error presente, donde a medida que se incrementa el número de iteraciones, se observa una disminución proporcional del error medio.

- **Evaluación de la predicción**

Una vez terminado el entrenamiento, la red neuronal se evalúa utilizando métricas de error que permiten cuantificar la diferencia entre las predicciones y los valores reales.

6.8 ESCALA DE LAS GRAFICAS

Una vez obtenidos todos los resultados de los modelos predicción que presentaron el mejor ajuste, se procede a realizar la desnormalizan de los datos para hacer el correspondiente análisis grafico a escala real.

6.9 ALCANCE DE LA INVESTIGACIÓN

Este proyecto busca predecir la velocidad de viento, la temperatura y dirección del viento dentro de un área delimitada en la Universidad Industrial de Santander con el apoyo de datos históricos de dos estaciones meteorológicas las cuales están ubicadas dentro del campus Universitario; en la EIM y E3T. El registro de datos será para los años 2016, 2017 y 2018. Esto se logrará implementando el modelo ARIMA, SARIMA y REDES NEURONALES posteriormente se realiza el traslado de estas variables por medio de extrapolaciones y correlaciones usando el software MATLAB.

7. RESULTADOS

En esta sección se mostrará los resultados obtenido por los modelos de mejor ajuste de predicción, siendo evaluados por el análisis de coeficiente de determinación R^2 .

7.1 MODELO ARIMA

El proceso de este modelo está compuesto por tres etapas; identificación, estimación y predicción. Las cuales se describirán a continuación.

7.1.1 Etapa de identificación

Se utilizó el Software R para el desarrollo del modelo, se cargaron los datos denominados VELOCIDAD_MECANICA y se desarrolla la predicción. Inicialmente, se lleva a cabo la transformación de los datos en una serie de tiempo para poder desarrollar el modelo, como se observa en Figura 9. Posteriormente, se realiza un análisis de la serie por medio del método de descomposición STL(SEASONAL TREND DESCOMPOSITION USING LOESS) este método consiste en el suavizado por regresión local y la descomposición de la serie en tres componentes; estacionariedad, estacionalidad y tendencia.

En la Figura 14 (a) se visualiza en la serie de tiempo original y el análisis estadístico que se explicará a continuación. En la Figura 14 (b) se observa que la serie de tiempo no presenta tendencia dado que no se visualiza ninguna pendiente o curva que así lo indique, pero muestra evidencia de la existencia de estacionalidad (c). Adicionalmente, en la Figura 14(d) se observa un comportamiento donde no existe aleatoriedad, esto se comprueba mediante la prueba de Ljung-Box (Ruido blanco), como se muestra en el Código 1. Se verifica con un p-value de 2.2×10^{-16} y se confirma la no existencia de ruido blanco que a su vez demuestra que los datos no son independientes y tampoco son aleatorios, por lo tanto, los datos se pueden predecir. En consecuencia, se procede a realizar una evaluación estadística para determinar si los datos de la serie presentan un comportamiento estacionario. A continuación, se emplea la Prueba de Dickey Fuller para verificar la estacionariedad en la serie de tiempo. Los resultados se muestran en el

Código 2 y arrojó un valor de 0.01 lo cual confirma que la serie de tiempo tiene un comportamiento estacionario.

Código 1. Resultados de la prueba de Ljung-Box en la serie de tiempo original.

```
> TEST_RD=Box.test(Datos_EST,type = "Ljung-Box")  
> TEST_RD
```

Box-Ljung test

```
data: Datos_EST  
X-squared = 259.66, df = 1, p-value < 2.2e-16
```


Código 2. Resultados de la Prueba de Dickey Fuller.

```
> Test
```

Augmented Dickey-Fuller Test

```
data: Datos_EST  
Dickey-Fuller = -6.1927, Lag order = 6, p-value = 0.01  
alternative hypothesis: stationary
```

Figura 14. Comportamiento de los datos originales




Fuente: Elaboración propia del desarrollo del modelo en el programa R.

Luego de identificar que la serie de tiempo se comporta como una serie estacionaria, es decir con un valor medio sin tendencia y datos distribuidos alrededor del medio, se concluye que la serie es modelable y se procede a identificar los parametros(p,q,d) de los posibles modelos para realizar el pronóstico.

En la Figura 15 se puede comprobar nuevamente que la serie de tiempo es estacionaria ya que los rezagos (Barras) no presentan una tendencia, y adicionalmente los datos presentan un carácter cíclico. Esto se identifica como patrón estacional mediante el comportamiento de los rezagos, se observa que algunos de ellos superan las bandas de limite. Estos rezagos indican una correlación entre el dato anterior y el actual. También son posibles valores que representaran MA en el modelo final. En la función de autocorrelación simple se identifica una combinación máxima de MA (1) hasta un MA (22).


Figura 15. Función de Autocorrelación simple



Fuente: Elaboración propia del desarrollo del modelo en el programa R.

En la Figura 16 presenta el análisis de autocorrelación parcial de la serie. El primer rezago no está correlacionado con el dato anterior debido a su posición de inicio en la serie de tiempo. Se identifica que algunos de ellos sobrepasan las bandas de límite. Estos rezagos que exceden los límites indican la presencia de una correlación significativa entre los datos actuales y los datos anteriores, lo que sugiere una inclusión de términos autorregresivos (AR) en el modelo final. Estos valores que superan los límites son posibles candidatos para representar los términos AR en el modelo. Según lo observado, en la función de Autocorrelación Parcial se identifica una combinación máxima de AR (1) hasta un AR (9).

Figura 16. Función de Autocorrelación Parcial



Fuente: Elaboración propia del desarrollo del modelo en el programa R.

7.1.2 Etapa estimación del modelo

Una vez que se han identificado el número de rezagos p y q en la etapa anterior del proceso de modelado, se procede a estimar los coeficientes de los términos autorregresivos (AR) y de media móvil (MA) incluidos en el modelo. Para hacerlo se realiza el análisis de los parámetros más significativos, el código se desarrolló para que arrojará el modelo de mejor ajuste, como se muestra en el Código 3. Según se observa, el modelo que presenta mejor ajuste es de (p,d,q) es el $(1,0,3)$ que indica que el AR es orden 1, MA es de orden 3, y no presenta diferencia.

Código 3. Ajuste ARIMA

```
> MOD_ARI
Series: Datos_TS
ARIMA(1,0,3) with non-zero mean

Coefficients:
      ar1      ma1      ma2      ma3  intercept
 0.8646  1.1061  0.8084  0.3783    0.1375
s.e.  0.0314  0.0619  0.0674  0.0474    0.0321

sigma^2 estimated as 0.000527:  log likelihood = 675.86,  aic = -1339.72

Training set error measures:
              ME      RMSE      MAE      MPE      MAPE      MASE
ACF1
Training set 0.0002072033 0.022956 0.01636137 -4.984184 20.66949 0.5131017 0.0
9230056
```

7.1.3 Etapa Predicción del modelo

Se realizan las pruebas pertinentes para verificar que efectivamente este sea el mejor modelo. La verificación se realiza mediante un análisis de los residuos del pronóstico. En la Figura 17 (a) muestra que los residuales se distribuyen alrededor de 0, lo cual indica que no existe un sesgo sistemático en el modelo. En la Figura 17 (b) muestra que la

mayoría de los coeficientes de autocorrelación de los residuos se encuentran dentro de los límites de confianza, sin embargo, se observa que algunos coeficientes están fuera de los mismos, esto indica la presencia de patrones sistemáticos no capturados por el modelo. Dado que algunos rezagos sobrepasan las bandas de los límites, se debe realizar una prueba adicional con el fin de comprobar si hay ruido blanco a través de la prueba estadística de Ljung-Box.

Resultado de test de Ruido Blanco

La prueba de ruido blanco consiste en formular dos hipótesis:

H0= Los residuales se distribuyen de forma independiente. (Ruido blanco)

H1= Los residuales no se distribuyen de forma independiente (No es ruido blanco)

Se verifica la independencia mediante el test de Ljung-Box como se muestra en el Código 4 encontrando un P-Valor de 0.1107 (c) y por lo tanto no se rechaza H0, indicando que los residuales son independientes, no son significativos y con un comportamiento aleatorio, revelando un buen ajuste del modelo.

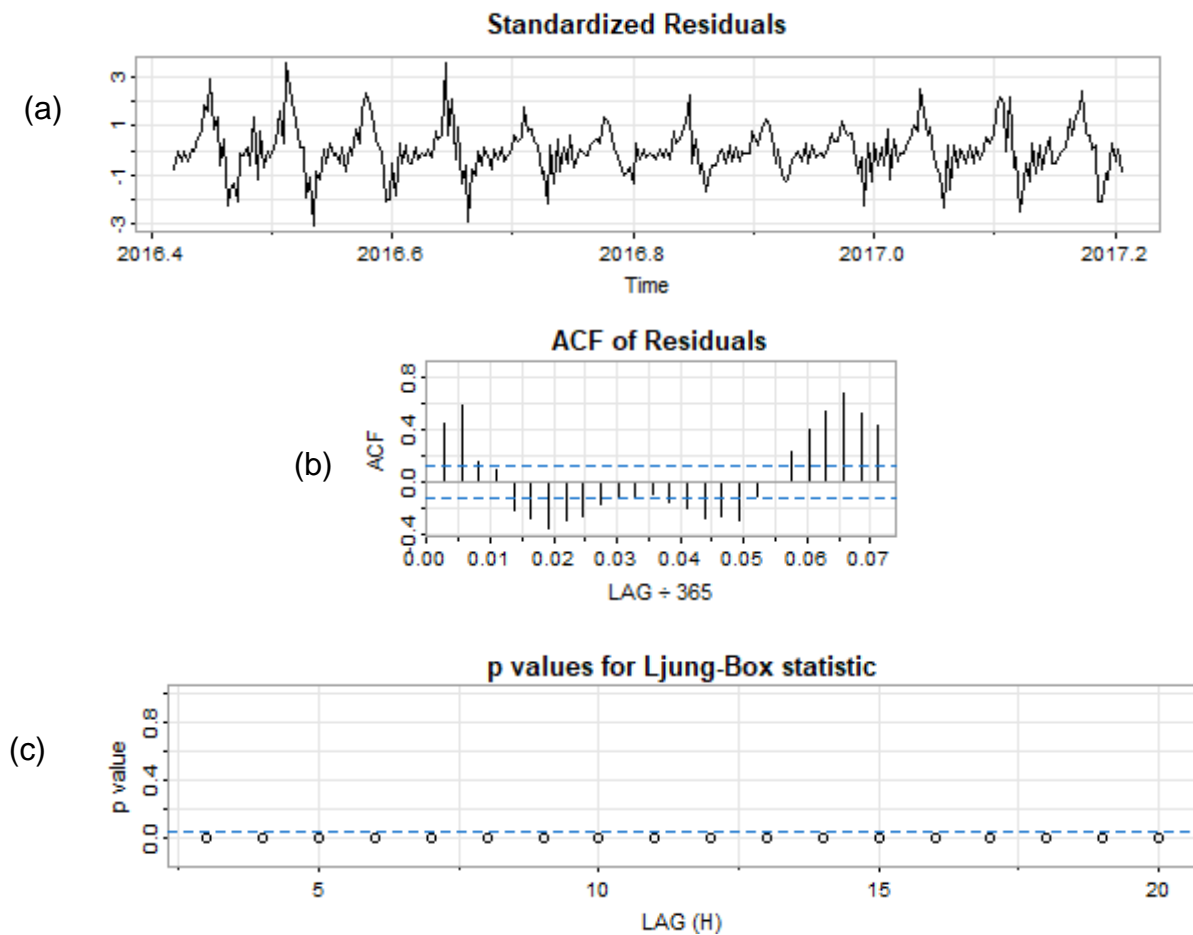
Código 4. Resultados de la prueba de Ljung-Box en el modelo Arima

```
> TEST_A=Box.test(residuals(MOD_ARI),type = "Ljung-Box")  
> TEST_A
```

```
Box-Ljung test
```

```
data: residuals(MOD_ARI)  
x-squared = 2.4792, df = 1, p-value = 0.1154
```

Figura 17. Análisis de los residuales



Fuente: Elaboración propia del desarrollo del modelo en el programa R.

En la Figura 18 se verifica que los residuos del modelo representan una adecuada distribución normal, sin mostrar sesgo. A través de la función de obtención de los percentiles de los valores del modelo se observa que los residuos se ajustan a los cuantiles teóricos de una distribución normal con algunas desviaciones en las puntas. Para verificar se realiza el test de Shapiro_Wilk, arrojando un P-value de 2.2×10^{-16} indicando una distribución no normal, (como se observa en el Código 5). Este valor es menor que 0.01 por tanto se rechaza la hipótesis H_0 .

H_0 : La variable presenta una distribución normal

H1: La variable presente una distribución no normal

Código 5. Prueba de normalidad Shapiro-Wilk.


```
> shapiro.test(MOD_ARI)
```

Shapiro-wilk normality test

data: MOD_ARI

W = 0.20471, p-value < 2.2e-16

Figura 18. Grafica de Normalidad.



Fuente: Elaboración propia del desarrollo del modelo en el programa R.


7.2 PREDICCIÓN ARIMA (1,0,3)

Finalmente, se realiza la predicción extendiendo los datos de base hasta un (1) año. En la Figura 19 se muestra la serie temporal de la variable velocidad de viento registrada en la estación meteorológica de la EIM. En el eje de ordenadas se representa el periodo de tiempo y en el eje de las abscisas se muestra la velocidad del viento. Se visualiza una línea constante en color azul oscuro que representa el valor de la predicción. Además, se presentan dos bandas de confianza que brindan información sobre la incertidumbre asociada a la predicción. La de banda de confianza representada en azul oscuro indica el rango dentro del cual existe un 80% de probabilidad de que se encuentre el valor real de la velocidad del viento. Por otro lado, la banda de confianza en color azul más claro

muestra un rango más amplio en el cual es posible que se encuentre la velocidad real, con un nivel de confianza del 95%.

Este mismo análisis se realizó para las variables de velocidad, temperatura y dirección de las estaciones meteorológicas de la Universidad Industrial de Santander. (ANEXOS)

Figura 19. Predicción del Modelo ARIMA.



Fuente: Elaboración propia del desarrollo del modelo en el programa R.

Según se observa en la Figura 19, la predicción representa un comportamiento estacionario, sin estacionalidad, con valores mínimos por debajo de los valores mínimos de los datos originales. La predicción indica que los valores originales presentan un comportamiento cíclico con un valor medio estacionario y desviaciones normalizadas alrededor de la media. En consecuencia, el modelo ARIMA estudiado no representa un modelo de estimación conveniente.

7.3 MODELO SARIMA

Siguiendo el procedimiento indicado en el modelo ARIMA, se procedió agregar el componente estacional al modelo, como se muestra en el Código 6, agregando los parámetros (P, Q, D) y el periodo al modelo ARIMA. El mejor ajuste a los datos está representado por los parámetros que se indican en el modelo ARIMA.

Código 6. Ajuste SARIMA.

```
> print(summary(fit_arima))
Series: Datos_TS
ARIMA(4,0,0)(0,1,1)[24]

Coefficients:
      ar1      ar2      ar3      ar4      sma1
  1.1943 -0.3060  0.175  -0.1659 -0.3621
s.e.  0.0661  0.0971  0.095   0.0607  0.0827

sigma^2 = 0.000203:  log likelihood = 744.52
AIC=-1477.03  AICC=-1476.7  BIC=-1455.6

Training set error measures:
              ME          RMSE          MAE          MPE          MAPE
Training set 8.971443e-06 0.01351011 0.009420245 -1.628184 13.06075
              MASE          ACF1
Training set 0.3830641 -0.004266947
```

En la Figura 20 se realizan las pruebas pertinentes para verificar que este modelo sea el de mejor ajuste. La verificación se realiza mediante un análisis de los residuos del pronóstico. En la Figura 20 (a) los residuos estandarizados se distribuyen alrededor del promedio, quiere decir que la media de los residuos obtenido se mantiene alrededor de cero, no presenta tendencia y tiene estacionariedad (a). En la Figura 20 (b) muestra que la mayoría de los coeficientes de autocorrelación de los residuos se encuentran dentro de los límites de confianza, sin embargo, se observa que algunos coeficientes están fuera de los mismos, esto indica la presencia de patrones sistemáticos no capturados por el modelo. Dado que algunos rezagos sobrepasan las bandas de los límites, se debe realizar una prueba adicional con el fin de comprobar si hay ruido blanco a través de la prueba estadística de Ljung-Box.

Código 7. Resultados prueba de Ljung-Box test del modelo SARIMA.

```
> checkresiduals(fit_arima)
```

Ljung-Box test

data: Residuals from ARIMA(4,0,0)(0,1,1)[24]
Q* = 44.721, df = 43, p-value = 0.3994

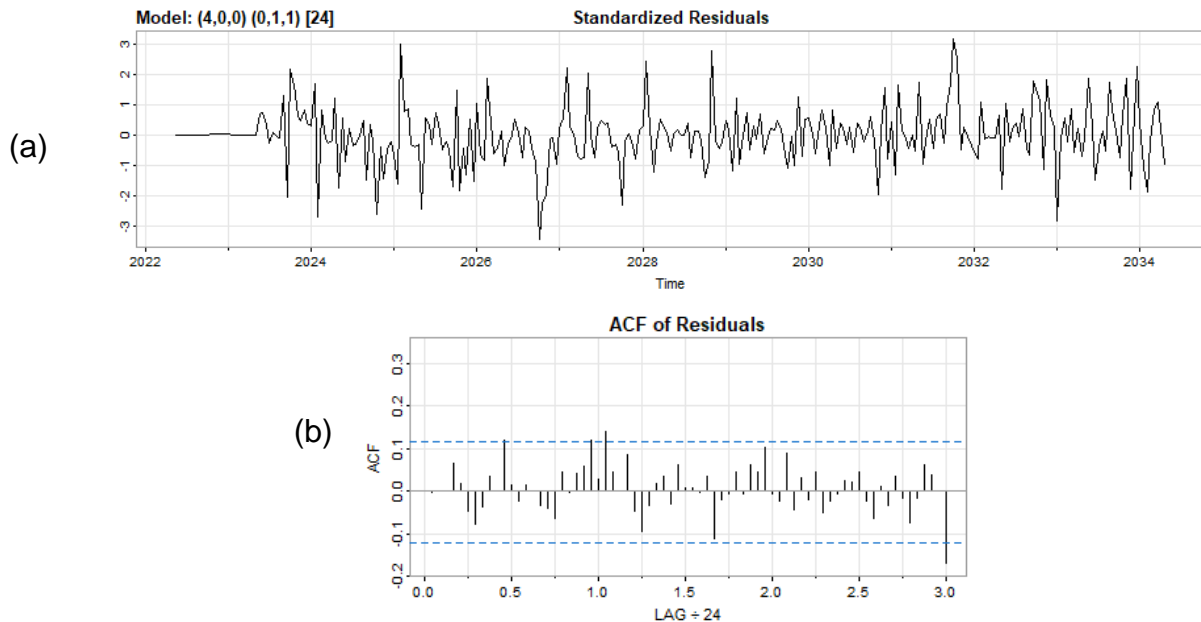
Test de Ruido Blanco


H0= Los residuales se distribuyen de forma independiente. (Ruido blanco)

H1= Los residuales no se distribuyen de forma independiente (No es ruido blanco)

Se verifica la independencia mediante el test de Ljung-Box como se muestra en el Código 7 encontrando un P-Valor de 0.3994 (c) y por lo tanto no se rechaza H0, indicando que los residuales son independientes, no son significativos y con un comportamiento aleatorio, revelando un buen ajuste del modelo.

Figura 20. Análisis de los residuales






Fuente: Elaboración propia del desarrollo del modelo en el programa R.

En la Figura 21 se evidencia una distribución normal de los residuales, se observa que existen valores que sobresalen la curva de ajuste normal. Para verificar este comportamiento se observa la gráfica de normalidad y se realiza el test de Shapiro-Wilk.

Figura 21. Histograma de densidad



Fuente: Elaboración propia del desarrollo del modelo en el programa R.

En la Figura 22 se verifica que los residuos del modelo representan una adecuada distribución normal, sin sesgo. Esto por medio de la función de obtención de percentiles de los valores del modelo, mostrando que los residuos se ajustan a los cuantiles teóricos de una distribución normal con algunas desviaciones en las extremos; para verificar se

realiza el test de Shapiro_Wilk, arrojando un P-value de 2.2 e-16, indicando una distribución no normal (como se observa en el Código 8). Este valor es menor que 0.01 por lo tanto, se rechaza la hipótesis H0, lo cual indica que los residuos no mantienen una distribución normal.

H0: La variable presenta una distribución normal

H1 : La variable presente una distribución no normal


Código 8. Prueba de Normalidad Shapiro-Wilk

```
> shapiro.test(fit_arma)

      shapiro-wilk normality test

data:  fit_arma
w = 0.79585, p-value < 2.2e-16
```

Figura 22. Grafica de Normalidad.




Fuente: Elaboración propia del desarrollo del modelo en el programa R.

7.4 PREDICCIÓN SARIMA (4,0,0)(0,1,1)₂₄

En la Figura 23 se muestra la predicción extendiendo los datos de base hasta un (1) año. Se puede observar que presenta una estacionalidad y la media es constante. Adicionalmente, presenta un rango de variaciones de los posibles valores de velocidad de viento. Se observa un color azul oscuro que son las bandas de confianza del 80% y un color azul claro con bandas del 95%. También Se observa que las variaciones en cada periodo van aumentando con el tiempo.


Figura 23. Predicción del modelo (4,0,0)(0,1,1)₂₄



En la Figura 24 se realiza un análisis de los datos reales con los predichos por el modelo y se evidencia una similitud entre los datos como la periodicidad, sin embargo, en los dos primeros meses del año los valores predichos son inferiores a los rangos de variaciones donde oscilan los posibles valores de velocidad. En el tercer mes del año se observa que la predicción se encuentra dentro de los rangos establecidos por el modelo; En los

siguiente cuatro meses del año los valores predichos se encuentran por debajo de los valores reales, y en los últimos cuatro meses se observa una similitud entre los datos reales y predichos. Las diferencias se pueden explicar teniendo en cuenta la climatología global en los diferentes periodos del año. Adicionalmente, existe la percepción que en los meses de mitad de año hay menos viento que en el resto del año, y esto explicaría las discrepancias con los valores predichos.

Figura 24. Modelo SARIMA (4,0,0)(0,1,1)₂₄ vs Serie Original.



Fuente: Elaboración propia.

En la Tabla 4 se presentan los resultados de los modelos SARIMA de mejor ajuste obtenidos mediante el código aplicado a las variables de interés de este proyecto, específicamente la velocidad del viento, temperatura y dirección del viento registradas en las dos bases meteorológicas. Es importante destacar que durante el desarrollo del código se estableció como condición que el modelo seleccionado fuera aquel que

presentara el mejor ajuste y el menor error numérico con respecto a otros posibles modelos. Los resultados registrados en la Tabla 4 corresponden a los modelos finales.

En la columna de las estaciones meteorológicas se encuentran las variables de las series de tiempo a predecir, en la siguiente columna (Modelo) se presentan los resultados finales de los mejores pronósticos obtenidos con el mismo periodo para cada modelo, en la columna de coeficiente de determinación R^2 se observa que el modelo de predicción de la temperatura para la estación meteorológica de la EIM tiene un valor de 0,955 este valor es muy cercano a 1, por lo tanto, este modelo tiene el mejor ajuste y es el más preciso.

Para el caso donde los coeficientes de determinación se acercan a cero, menos ajuste presenta el modelo y será menos fiable, esto se puede corroborar con el análisis cuantitativo de cada predicción. Respecto al valor de 1,144 de la velocidad del viento para la estación de EIM, hace referencia a que el R^2 excede la media, es decir, se encuentra por encima del promedio. Todo el desarrollo de los modelos se presentará en los anexos adjuntos. Los cuales proporcionaran una visión exhaustiva de las técnicas y metodologías aplicadas en el proceso del modelo y pronostico.

En el análisis de resultados que se presentará más adelante se podrá observar el desempeño final de cada modelo en relación a los datos reales. Estos resultados serán fundamentales para evaluar el comportamiento y la precisión de los modelos SARIMA.

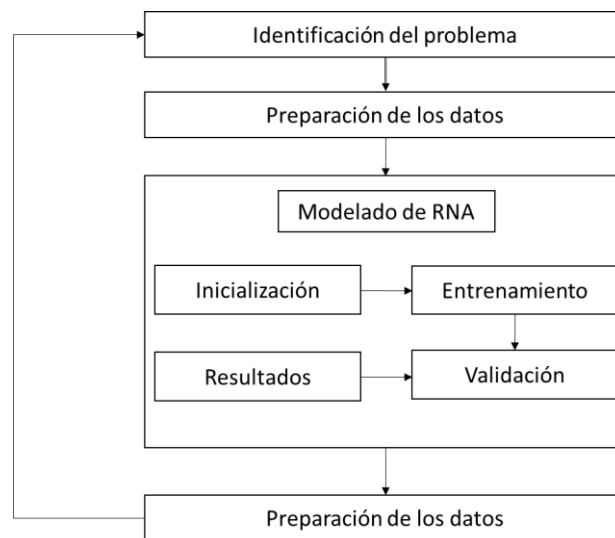
Tabla 4. Modelos de predicción con SARIMA

Estaciones meteorológicas y variables	Modelo	Coeficiente de determinación R^2
Mecánica Velocidad	(4,0,0)(0,1,2)(24)	1,144
Mecánica Temperatura	(1,0,1)(0,1,1)(24)	0,955
Mecánica Dirección	(2,0,0)(2,1,1)(24)	0,082
Eléctrica Velocidad	(1,0,1)(0,1,1)(24)	0,698
Eléctrica Temperatura	(2,0,1)(2,1,0)(24)	0,678
Eléctrica Dirección	(2,0,1)(2,1,0)(24)	-2,580

7.4 REDES NEURONALES

El objetivo de esta sección es encontrar el modelo que presente el menor porcentaje de error en la predicción de los datos meteorológicos modificando el número de capas ocultas y el número de neuronas de las capas ocultas. En la Figura 25 se muestra la estructura del proceso para modelar una Red Neuronal. Inicialmente, se identifica el problema, luego se preparan los datos para poder implementar las redes neuronales, y finalmente se lleva a cabo el modelamiento por el medio del software y se obtiene los resultados.

Figura 25. Pasos para hacer una Red Neuronal Artificial



Fuente: Elaboración propia construido a partir de la tesis de grado del ING Miguel Jiménez Calderón. pronóstico de la velocidad del viento utilizando modelos Arima y redes neuronales artificiales. Mexico. Universidad Michoacana de San Nicolás de Hidalgo

7.4.1 Preparación de los datos

Para modelar series de tiempo con Redes Neuronales Artificiales (RNA) es fundamental realizar una preparación exhaustiva de los datos. Por lo tanto, el primer paso en la preparación de los datos es la inspección detallada de la serie de tiempo para detectar cualquier problema como datos faltantes, una vez realizada la inspección se procede con

la normalización de los datos y el cálculo del promedio. Este proceso es esencial para garantizar que los datos estén en una escala adecuada.

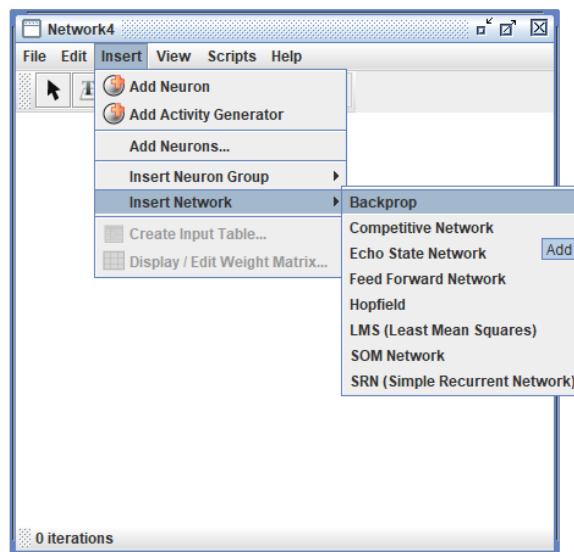
En la sección 6.1 se describe detalladamente el proceso de preparación de los datos para el modelado de series de tiempo con redes neuronales.

7.4.2 Desarrollo del modelo

Para la predicción de las variables velocidad de viento, temperatura y dirección del viento se empleó un software libre llamado SIMBRAIN 3.05, este se pudo descargar de una forma rápida y fácil por medio de la página <https://simbrain.net/> esto con el fin de desarrollar el modelo de Red Neuronal.

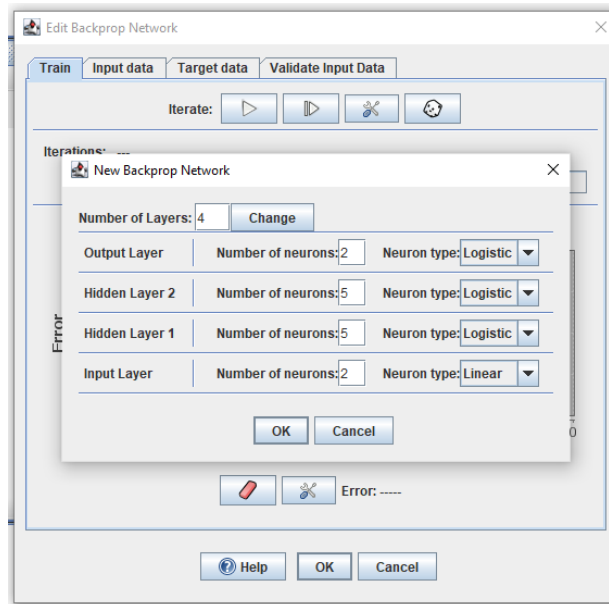
El proceso inicia seleccionando la red neuronal de tipo BACKPROPAGATION, como se muestra en la Figura 26. Seguidamente, se indican el número de capas, el número de neuronas por capa, las variables de entrada y las de salida como se observa en la Figura 27.

Figura 26. Entrenamiento de Backpropagation.



Fuente: Programa SIMBRAIN 3.05

Figura 27. Estructura de una red neuronal de tipo Backpropagation.



Fuente: Programa SIMBRAIN 3.05

Una vez se define la estructura se procede a cargar los datos donde un porcentaje de los datos se deja para el aprendizaje de la red y otro para la verificación como se visualiza en la Figura 28. En este caso los vectores de entrada corresponden a la hora y el mes; en el vector de salida, se consignan la velocidad, temperatura y dirección de viento.

Figura 28. Datos de entrada de la Red Neural.

#	Neuron_1	Neuron_2
1	0.0	0.0
2	0.090909091	0.043478261
3	0.181818182	0.086956522
4	0.272727273	0.130434783
5	0.363636364	0.173913043
6	0.454545455	0.217391304
7	0.545454545	0.260869565
8	0.636363636	0.304347826
9	0.727272727	0.347826087
10	0.818181818	0.391304348
11	0.909090909	0.434782609
12	1.0	0.47826087
13	0.0	0.52173913
14	0.090909091	0.565217391
15	0.181818182	0.608695652
16	0.272727273	0.652173913
17	0.363636364	0.695652174
18	0.454545455	0.739130435
19	0.545454545	0.782608696
20	0.636363636	0.826086957
21	0.727272727	0.869565217
22	0.818181818	0.913043478
23	0.909090909	0.956521739
24	1.0	1.0
25	0.0	0.0

#	Neuron_42	Neuron_43	Neuron_44
1	0.0	0.693589059	0.159433962
2	0.033115133	0.682211938	0.13509434
3	0.025413939	0.672619754	0.129559748
4	0.0238737	0.664530675	0.179874214
5	0.017327686	0.653233654	0.163522013
6	0.016172507	0.644772754	0.201677149
7	0.023681171	0.64090127	0.258805031
8	0.047747401	0.666631067	0.353962264
9	0.090617379	0.707784502	0.376939203
10	0.166331321	0.749697345	0.354929577
11	0.254195011	0.799301188	0.34345679
12	0.369740489	0.825452287	0.353497942
13	0.44595616	0.828718262	0.327777778
14	0.484807256	0.82947822	0.322469136
15	0.474552784	0.828111655	0.301234568
16	0.449452003	0.821366177	0.213888889
17	0.371050642	0.799604007	0.124938272
18	0.253897832	0.780264854	0.09068323
19	0.167705971	0.754003611	0.086728395
20	0.07414966	0.734742604	0.160246914
21	0.027210884	0.725968631	0.131687243
22	0.02617158	0.718873748	0.158024691
23	0.033002048	0.708470693	0.177942999
24	0.026203074	0.700073763	0.185596708
25	0.062135569	0.726330863	0.191964286

Fuente: Programa SIMBRAIN 3.05

Una vez que se han cargado los datos de los vectores de entrada, salida y validación, se inicia la ejecución del programa. En este proceso, se realizan varias iteraciones hasta que la red encuentra los pesos con el fin de minimizar el error de predicción de las variables.

En las siguientes tablas se muestran los resultados de diferentes configuraciones de redes neuronales utilizadas, estas incluyen el uso de dos capas de entrada y diferentes distribuciones de neuronas por capas ocultas. La nomenclatura X-Y indica que para la capa "X" se especificaron "Y" neuronas. En la columna de ERROR, se muestra el error arrojado por el programa, entre más se aproxime a cero el modelo es más preciso. Este se alcanza después de 5000 iteraciones, al presentar el menor error se selecciona la estructura de red neuronal (Capas ocultas).

En la Tabla 5 se visualiza que los valores del ERROR tienen pequeñas variaciones en comparación con los otros modelos de redes neuronales. Esto indica que cualquier configuración es aceptable para la predicción de la velocidad del viento, no obstante, se selecciona la configuración del modelo 3, que presenta el menor ERROR de 0,0012. Dicha configuración consta de dos capas ocultas, con cinco neuronas en la primera capa oculta y cinco neuronas en la última capa oculta.

Tabla 5. Resultados de la velocidad del viento para la EIM.

Modelo	Capas ocultas	Numero de capas (X-Y)	ERROR(%)	Iteraciones
1	2	1--4 2--6	0,0013	5000
2	2	1--8 2--5	0,0018	5000
3	2	1--5 1--5	0,0012	5000
4	3	1--4 1--6 1--8	0,0016	5000
5	3	1--8 2--5 3--3	0,002	5000
6	3	1--6 2--6 3--6	0,0017	5000
7	4	1--5 2--5 3--5 4--5	0,0016	5000
8	4	1--8 2--10 3--6 4--6	0,0018	5000

Fuente: Elaboración propia.

En la Tabla 6 se puede apreciar que los valores del ERROR son muy pequeños, adicionalmente, es el mismo valor para diferentes configuraciones de la estructura de la red, esto implica que cualquier configuración que se elija será adecuada para la predicción de la temperatura del viento basada en los datos proporcionados a la red neuronal. Entre los distintos modelos disponibles, se opta por el modelo 1 con ERROR de 0,0002. El cual consta de dos capas ocultas, con cuatro neuronas en la primera capa oculta y seis neuronas en la última capa oculta.

Tabla 6. Resultados de la temperatura para la EIM.

Modelo	Capas ocultas	Numero de capas	ERROR (%)	Iteraciones
1	2	1--4 2--6	0,0002	5000
2	2	1--8 2--5	0,0002	5000
3	2	1--5 1--5	0,0002	5000
4	3	1--4 1--6 1--8	0,0002	5000
5	3	1--8 2--5 3--3	0,0002	5000
6	3	1--6 2--6 3--6	0,0002	5000
7	4	1--5 2--5 3--5 4--5	0,0002	5000
8	4	1--8 2--10 3--6 4--6	0,0002	5000

Fuente: Elaboración propia.

En la Tabla 7 se visualiza que el valor del ERROR es el mismo para todas las configuraciones de la estructura de la red neural utilizadas para la predicción de la dirección de la velocidad de viento, esto indica que cualquier modelo puede ser seleccionado, ya todos ellos presentan un ERROR equivalente. Sin embargo, se opta por el modelo 3, el cual consta de dos capas ocultas, con cinco neuronas en la primera capa oculta y cinco neuronas en la última capa oculta.

Tabla 7. Resultados de la dirección del viento para la EIM.

Modelo	Capas ocultas	Numero de capas	ERROR (%)	Iteraciones
1	2	1--4 2--6	0,0047	5000
2	2	1--8 2--5	0,0047	5000
3	2	1--5 1--5	0,0047	5000
4	3	1--4 1--6 1--8	0,0047	5000
5	3	1--8 2--5 3--3	0,0047	5000
6	3	1--6 2--6 3--6	0,0047	5000
7	4	1--5 2--5 3--5 4--5	0,0047	5000
8	4	1--8 2--10 3--6 4--6	0,0047	5000

Fuente: Elaboración propia.

En la Tabla 8 se visualiza algunas diferencias en los valores del ERROR entre los distintos modelos utilizados para la predicción de la velocidad del viento en la estación

meteorológica E3T. Entre estos modelos, se selecciona el modelo 5, el cual presenta el menor ERROR 0,0019, con una configuración de tres capas ocultas, con ocho neuronas en la primera capa oculta, con cinco neuronas en la segunda capa oculta y cinco neuronas en la última capa oculta.

Tabla 8. Resultados de la velocidad del viento para la E3T.

Modelo	Capas ocultas	Numero de capas	ERROR (%)	Iteraciones
1	2	1--4 2--6	0,002	5000
2	2	1--8 2--5	0,002	5000
3	2	1--5 1--5	0,002	5000
4	3	1--4 1--6 1--8	0,0034	5000
5	3	1--8 2--5 3--3	0,0019	5000
6	3	1--6 2--6 3--6	0,0034	5000
7	4	1--5 2--5 3--5 4--5	0,002	5000
8	4	1--8 2--10 3--6 4--6	0,0034	5000

Fuente: Elaboración propia.

En la Tabla 9 se visualiza variaciones en los valores del ERROR entre los diferentes modelos analizados, aunque en algunos modelos el ERROR es el mismo. La predicción con mejor precisión para la temperatura del viento es el modelo 2 con un valor de ERROR de 0,0028, con una configuración de dos capas ocultas, con ocho neuronas en la primera capa oculta, y seis neuronas en la última capa oculta.

Tabla 9. Resultados de la temperatura para la E3T.

Modelo	Capas ocultas	Numero de capas	ERROR (%)	Iteraciones
1	2	1--4 2--6	0,004	5000
2	2	1--8 2--5	0,0028	5000
3	2	1--5 1--5	0,0031	5000
4	3	1--4 1--6 1--8	0,0075	5000
5	3	1--8 2--5 3--3	0,0031	5000
6	3	1--6 2--6 3--6	0,0031	5000
7	4	1--5 2--5 3--5 4--5	0,0031	5000
8	4	1--8 2--10 3--6 4--6	0,0064	5000

Fuente: Elaboración propia.

En la Tabla 10 se visualiza mucha similitud del ERROR entre los diferentes modelos, la mayoría de los modelos presentan un ERROR prácticamente idéntico, por consiguiente, se opta por el modelo 6 con un valor de ERROR de 0,0075. Con una configuración de tres capas ocultas, con seis neuronas en la primera capa oculta, con seis neuronas en la segunda capa oculta y seis neuronas en la última capa oculta.

Tabla 10. Resultados de la dirección del viento para la E3T.

Modelo	Capas ocultas	Numero de capas	ERROR (%)	Iteraciones
1	2	1--4 2--6	0,0075	5000
2	2	1--8 2--5	0,0075	5000
3	2	1--5 1--5	0,0075	5000
4	3	1--4 1--6 1--8	0,0075	5000
5	3	1--8 2--5 3--3	0,0075	5000
6	3	1--6 2--6 3--6	0,0075	5000
7	4	1--5 2--5 3--5 4--5	0,0076	5000
8	4	1--8 2--10 3--6 4--6	0,0076	5000

Fuente: Elaboración propia.

En la Tabla 11 se muestra una fracción del resultado de la predicción que se realizó por medio de redes neuronales para la velocidad, temperatura y dirección del viento. En la Figura 29 se grafican los resultados de la velocidad del viento para la estación meteorológica de la EIM.


Tabla 11. Base de datos de las variables de predicción

Día	Velocidad (m/s)	Temperatura (°C)	Dirección (Grados)
1	0,260323568	21,95713285	93,08001851
2	0,174753041	21,56362775	93,14268948
3	0,126735266	21,21190493	93,20329571
4	0,112757869	20,92383567	93,26189777
5	0,124845637	20,72326922	93,31855509
6	0,165408222	20,66238123	93,37332594
7	0,247967556	20,84783029	93,42626743
8	0,394580972	21,43893039	93,47743546
9	0,62536304	22,53562854	93,52688472
10	0,93899135	23,9543829	93,57466869
11	1,301541287	25,26600355	93,62083962
12	1,661926273	26,19966906	93,66544854
13	1,958292981	26,22179078	91,16953917
14	2,095954474	26,32501156	91,29110048
15	2,108368561	26,19131883	91,40915377

Fuente: Elaboración propia.

En la Figura 29 se realiza un análisis comparativo entre los datos reales y los pronosticados por el modelo. Se observa una similitud entre los datos en cuanto a la periodicidad del modelo. El coeficiente de determinación R^2 tiene un valor de 1,144 lo que confirma la precisión del modelo en ciertos meses; como marzo, noviembre y diciembre, donde la diferencia entre los datos reales y los pronosticados es mínima. Para los meses de abril y octubre, el pronóstico es casi idéntico a los datos reales. En cuanto a los meses de enero y febrero, se observa que se presentan los vientos más intensos en comparación a los otros meses. Sin embargo, el pronóstico del modelo es inferior a los datos reales. Por otro lado, los meses de mayo, junio, julio, agosto y septiembre, el pronóstico del modelo supera a los datos reales. Estas discrepancias podrían atribuirse a la falta de inclusión de variables de condiciones climáticas locales en el conjunto de datos de entrada el modelo de la red neuronal.

Figura 29. Predicción de la Velocidad de viento para el año 2019.




Fuente: Elaboración propia.

8. ANÁLISIS DE RESULTADOS

En la Figura 30 se muestra el análisis de los pronósticos de las velocidades del viento. Se puede observar que las velocidades registradas de la E3T son inferiores a las velocidades de la estación EIM. Estas diferencias pueden ser debido a su ubicación geográfica y las condiciones climáticas locales de cada zona, todos los pronósticos tienen algo en común y en este caso es la periodicidad, es decir cada 24 datos se presenta un ciclo repetitivo como se observa. Para la estación meteorológica de E3T el modelo de redes neuronales tiene un coeficiente de determinación R^2 de 0,832 y el modelo Sarima de 1,144 y para la estación meteorológica de la EIM el modelo de redes neuronales tiene un R^2 0,730 y el modelo Sarima de 0,697.


Figura 30. Predicción de la velocidad del viento



Fuente: Elaboración propia.

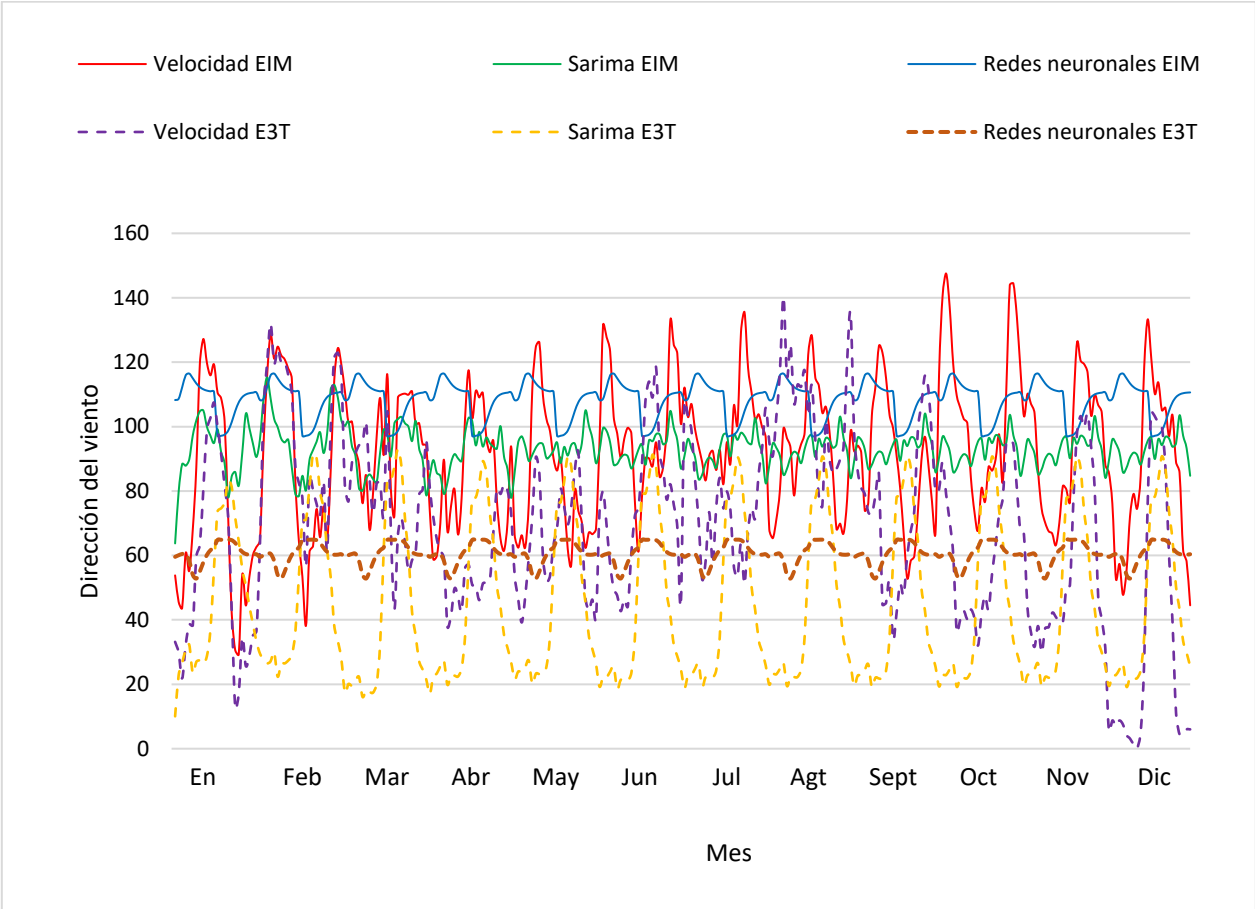
En la Figura 31 se observa el análisis de los pronósticos de las temperatura. Se puede observar que los pronósticos realizados para la estación meteorológica de EIM son prácticamente idénticos a los datos reales registrados, esto se corrobora con el valor de R^2 de 0,95 para el modelo Sarima y para redes neuronales el valor es de 1. Es decir, presentan la mayor precisión de ajuste para el modelo. Para la estación E3T el modelo de redes neuronales presenta un R^2 de 0,735, mientras que el modelo Sarima muestra un R^2 de 0,677. Estos resultados confirman las discrepancias en los pronósticos.

Figura 31. Predicción de la Temperatura ambiente



En la Figura 32 se evidencia que ninguno de los pronósticos se ajuste a los datos reales, lo cual se confirma mediante los valores obtenidos del R^2 para cada modelo. En el caso de la estación meteorológica EIM, el modelo de redes neuronales presenta un R^2 de 0,081, mientras que el modelo Sarima de 0,61. Por otro lado, para la estación meteorológica E3T, el modelo de redes neuronales muestra un R^2 de 0,1 y el modelo Sarima de 1,426. Estos errores están cerca de 0. En consecuencia, se concluye que la dirección del viento no es posible predecirla utilizando los modelos aplicados en este estudio.

Figura 32. Predicción de la Dirección del viento



Fuente: Elaboración propia.

9. PROYECCIONES DEL FLUJO DE VIENTO ALREDEDOR DE LA EDIFICACIONES DE LA UNIVERSIDAD INDUSTRIAL DE SANTANDER POR SIMULACIONES CFD

Se realiza un estudio topográfico del terreno de la Universidad Industrial de Santander, Para adquirir información detallada sobre las características geométricas del terreno y sus edificaciones. Esta información fue utilizada para la creación de un mapa de la Universidad en el software AUTOCAD, en el cual se representaron las dimensiones de altura y curvas de nivel de cada edificación presente en la Universidad. Una vez obtenido el mapa, se procedió a realizar un análisis del comportamiento del flujo de viento en la zona de estudio. Para ello, se aplicó una correlación matemática basada en un perfil de velocidad logarítmico y la longitud de rugosidad del terreno, Para llevar a cabo este análisis, se empleó el software MATLAB para analizar el comportamiento de flujo de viento en la zona de estudio. La finalidad de este estudio fue evaluar cómo la rugosidad del terreno influía en el comportamiento del flujo de viento en la zona.

9.1 OBTENCIÓN DE PLANOS

Se solicitaron ante planta física los planos del terreno y de cada edificación del área de estudio. Estos planos contienen información detallada de la altura y ancho de los edificios, adicionalmente la topografía del terreno.

Una vez obtenidos los planos en formato AUTOCAD, se procedió a extraer las alturas de cada edificio utilizando las curvas de nivel presentes en el terreno. Con esta información, se pudo obtener una mejor aproximación de las alturas de cada edificio.


9.2 CREACIÓN DEL MAPA DE RUGOSIDAD

El análisis de la carga del viento es importante para el establecimiento de las variaciones del flujo con la altura. Este comportamiento se conoce como perfil vertical del viento y está fuertemente influenciado por las características del terreno, la correcta

determinación del parámetro que refleja esas condiciones topográficas, es denominado longitud de rugosidad y se define como la altura donde la velocidad de viento es uniforme.

En la Figura 33 presenta el mapa que se construyó mediante el software AUTOCAD con base en a los datos extraídos por los planos, este mapa representa las características topográficas del terreno, incluyendo las alturas de las edificaciones. Adicionalmente, se dividió en zonas dependiendo de la cantidad de edificios y naturaleza, es decir, se seccionó por los valores de longitud de rugosidad. En la Tabla 12 se encuentran los códigos de colores según la Longitud de Rugosidad de cada edificio y el terreno usados en la construcción del mapa.

Figura 33. Creación del mapa de la UIS por medio del Software AUTOCAD.



Fuente: Elaboración propia

Tabla 12. Valores de longitud de Rugosidad.

CLASE DE RUGOSIDAD	LONGITUD DE RUGOSIDAD	RANGO	COLOR
0	0,0002		
3,5	0,8	1 a 15	
4	1,6	16 <	

9.3 ANÁLISIS DEL COMPORTAMIENTO DEL FLUJO DEL VIENTO

A partir del mapa creado, se desarrolló en MATLAB un modelo numérico que simula la velocidad del viento en toda el área de estudio. Este modelo permitió analizar el comportamiento del flujo del viento aplicando una correlación matemática a partir de un perfil logarítmico y la longitud de rugosidad, permite identificar las áreas de alto flujo, puntos críticos de acumulación de flujo y zonas con baja circulación de aire.

Para el análisis del terreno de toda la UIS, como se muestra en la Figura 34, se implementó una malla rectangular compuesta por 200x200 particiones. Cada uno de los elementos de esta malla fue asignado con valores de altura y rugosidad que corresponden a las características del terreno. Asimismo, se tuvo en consideración la inclinación y declinación del terreno con el fin de obtener una representación más precisa de su topografía.

Modelo matemático

$$V_Z = V_{ref} \left(\frac{\ln\left(\frac{Z}{Z_0}\right)}{\ln\left(\frac{Z_{ref}}{Z_0}\right)} \right) \quad Ec. 19$$

V_Z = Velocidad a calcular

V_{ref} = Velocidad de la estación meteorológica (E3T)

Z = Altura a la cual se va calcular la velocidad (Altura del edificio)

Z_0 = Parámetro de rugosidad

Z_{ref} = Altura de la velocidad de referencia (altura del edificio donde se encuentra ubicada la estación meteorológica de referencia)

Con este modelo matemático se realiza el estudio de la influencia del flujo de viento en conjunto con longitud de rugosidad; para el desarrollo del código se empleó una serie de pasos, como se indica a continuación.

Primer paso

El objetivo principal fue determinar una velocidad uniforme en toda la zona de interés, para lograr esto se asumió una altura de 80 metros sobre el nivel de la Universidad Industrial de Santander aplicando el método de longitud de rugosidad.

La velocidad V_Z calculada por el modelo corresponde a una altura Z de 80 metros. Como velocidad de referencia V_{ref} , se utilizó la proporcionada por la Estación Meteorológica

ubicada en la E3T, Z_{ref} donde se encuentra dicha Estación Meteorológica y el parámetro de rugosidad Z_0 .

Este análisis se centró en determinar la velocidad de flujo en función de la altura y establecer una relación con la velocidad de referencia y los parámetros de rugosidad. Para poder comprender el comportamiento del flujo del aire en la zona de estudio.

Segundo paso

$$\frac{V_z}{\left(\frac{\ln\left(\frac{z}{Z_0}\right)}{\ln\left(\frac{Z_{ref}}{Z_0}\right)}\right)} = V_{ref} \quad Ec. 20$$

V_z = Velocidad hallada en el caso 1

V_{ref} = Velocidad a calcular

Z = 80 metros

Z_0 = Parámetro de rugosidad

Z_{ref} = Altura del edificio


Después de hallar la velocidad del flujo de aire en toda la zona de estudio a 80 m, se procede a calcular las velocidades V_{ref} de cada edificio en base a la respectiva altura de la edificación, adicionalmente, se suma la inclinación presente del terreno donde se encuentra ubicado el edificio.

En la Figura 34 se presenta un ejemplo a escala reducida de una malla compuesta de 20x20 particiones. Cabe resaltar que esta malla no fue utilizada para el desarrollo del código en MATLAB; en su lugar, se empleó una malla de 200x200 particiones. Cada

elemento de esta malla se asignó con valores correspondiente a la altura de las edificaciones y la rugosidad que es característica del terreno, esta malla permite una representación más precisa y realista del terreno de estudio.

El propósito de este ejemplo a pequeña escala es ilustrar de manera visual cómo se organiza la malla compuesta y cómo se distribuyen los valores de altura y rugosidad de cada elemento.

Figura 34. Análisis de 2 dimensiones y cada edificación con sus propiedades topográficas.



9.4 PROYECCION DE VELOCIDADES EN LA UNIVERSIDAD INDUSTRIAL DE SANTANDER

En la Figura 35 se ilustra la velocidad del viento a diferentes alturas de los edificios, cada color se representa una aproximación de la velocidad del viento correspondiente a la altura. En otras palabras, se presenta el perfil de velocidad del viento para cada edificio en función de su altura, con el objetivo de obtener información cuantitativa acerca del flujo de aire a diferentes alturas dentro de las instalaciones de la Universidad Industrial de

Santander. Estas velocidades se hallaron por utilizando el método de Rugosidad indicado en la Ec. 19 para este estudio en particular, se ha asignado un valor de rugosidad de 0,8 a las edificaciones cuyas alturas oscilan entre 1m y 15m, y 1,6 para los edificios con alturas superiores a 15 m. Esta clasificación de rugosidad se estableció con el propósito de categorizar cada edificio en términos de su influencia en el flujo del viento.

La máxima velocidad del viento registrada es del edificio 38 (Gestión Logística) el cual tiene una altura de 30m más la elevación respecto al nivel de referencia. En dicho edificio, la velocidad del viento alcanza aproximadamente los 1,6 m/s, lo cual se representa mediante el color café oscuro. Teniendo en cuenta que la dirección del viento predomina de norte a sur.

Para la zona del terreno sin edificaciones el flujo de la velocidad del viento se representa de la siguiente manera; en la parte de donde se toma el punto referencia que para este caso sería la parte más baja y representa la menor velocidad de 1m/s con el color azul, por toda la zona se presenta una elevación hasta llegar a la máxima elevación de 30 m con una velocidad de 1,56 m/s representado por el color café. En la Tabla 13 se presenta el nombre del edificio, la altura del mismo y el aproximado de la velocidad del viento a dicha altura.

Figura 35. Flujo de viento de la UIS.

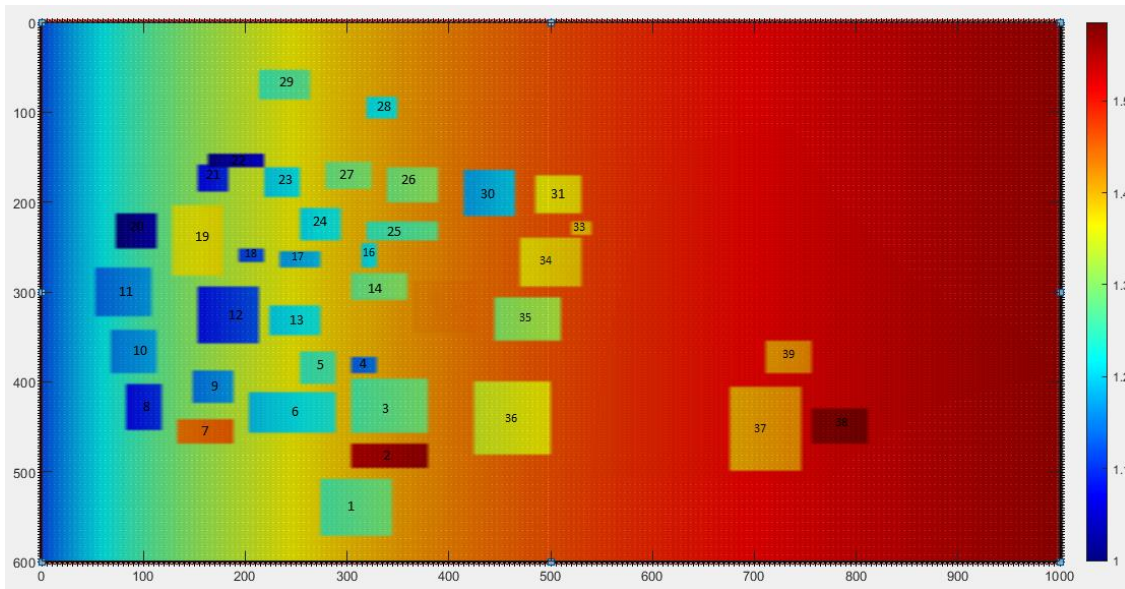


Tabla 13. Resultados de la velocidad de flujo en la Universidad Industrial de Santander

Edificio	Nombre	Altura	Velocidad(m/s)	Edificio	Nombre	Altura	Velocidad (m/s)
1	Ciencias Humanas	18	1,25	21	Laboratorio de Alta Tensión	7,6	1,15
2	Ciencias Humanas II	43,55	1,54	22	Taller de Diseño Industrial	5	1,05
3	Ingeniería Mecánica	12,3	1,27	23	Laboratorio de Hidráulica	16	1,22
4	Aula máxima Ingeniería Mecánica	5,44	1,15	24	Federico Mamitza Bayer	10,74	1,22
5	Camilo Torres	17,7	1,25	25	Instituto de Lenguas	11	1,28
6	Laboratorio Livianos	16	1,2	26	Ingeniería Industrial	12,96	1,27
7	Edic	36,25	1,45	27	Ingeniería E3T	19,16	1,26
8	Planta de Aceros	9,8	1,16	28	Laboratorio de Biología Vegetal	9	1,22
9	Laboratorio de Postgrado	10,7	1,18	29	Laboratorio Estructuras y Materiales	14,6	1,27
10	Jorge Bautista Vesga	18	1,19	30	La Perla	4	1,17
11	Físico Mecánica	13,2	1,19	31	Bienestar Estudiantil	14,16	1,38
12	Ingeniería Química	7,83	1,08	32	Parqueadero		
13	Centic	16	1,22	33	Administración II	20	1,39
14	Biblioteca	13,6	1,27	34	Administración III	20	1,4
15	Lago			35	Administración	10,78	1,27
16	Planta Telefónica	9	1,22	36	Auditorio Luis A. Calvo	14,43	1,34
17	Uis Salud	9,27	1,19	37	Coliseo	12	1,42
18	Aula máxima de Ciencias	7,79	1,15	38	Gestión Logísticas	30	1,58
19	Bienestar Profesoral	30	1,36	39	Residencias estudiantiles	12,5	1,43
20	Daniel Casas	7,34	1,04				

10. CONCLUSIONES

En este trabajo se desarrolló una metodología para la predicción de los parámetros del viento a partir del modelo ARIMA (SARIMA) y RNA. De acuerdo con los resultados encontrados se puede concluir que el modelo ARIMA no predice las variables del tiempo utilizados, debido al carácter estacional de los datos. Las predicciones obtenidas por este modelo revelaron una pendiente constante con un comportamiento estacionario y sin presencia de estacionalidad. Por lo tanto, resulta evidente que el modelo Arima no es capaz de predecir adecuadamente series de tiempo con ciclos repetitivos. Los errores obtenidos en la predicción de la magnitud de la velocidad del viento en la estación de EIM fueron de $R^2 = 0,018$. En el caso de la estación de E3T se obtuvo el $R^2 = 0,302$. En cuanto a la predicción de la temperatura ambiente, se obtuvieron los siguientes errores: en la estación EIM el $R^2 = 0,013$ y para la estación E3T el $R^2 = 0,004$. En el caso de la dirección del viento los errores en la estación EIM fueron de $R^2 = 0,015$, y para la estación de E3T fueron de $R^2 = 0,024$.

Por otra parte, se implementó el modelo SARIMA; del cual se puede concluir que predice con un margen de error razonable la variabilidad estacional de los datos. Sin embargo, la dirección del viento, aunque tiene una dirección predominante norte-sur, no es posible predecirla con el modelo. Algunos valores de R^2 exceden el valor de oscilación de 0 a 1, es decir, cuando son mayores que 1 exceden la media de la serie de tiempo pronosticado. Los errores obtenidos en la predicción de la magnitud de la velocidad del viento en la estación de EIM fue de $R^2 = 1,144$. En el caso de la estación de E3T se obtuvo el R^2 de 0,697. En cuanto a la predicción de la temperatura del viento, se obtuvieron los siguientes R^2 : en la estación EIM 0,954 para la estación E3T de 0,677. En el caso de la dirección del viento los R^2 fueron: en la estación EIM 0,081, y para la estación de E3T 1,426. Se asume que la mayor diferencia en el pronóstico de la dirección del viento se debe a cambios aleatorios e instantáneos en la dirección del viento.

Según los resultados obtenidos mediante el uso de redes neuronales, se concluye que es posible predecir los datos magnitud de la velocidad del viento y temperatura ambiente con un margen de error razonable. Para la velocidad del viento en la estación de EIM, se obtuvo un R^2 de 0,832 mientras que para la estación E3T se obtuvo un valor de 0,73. Con respecto a la temperatura ambiente, se obtuvo R^2 de 1 en la estación EIM y de 0,735 para la estación E3T. Para la dirección del viento, se obtuvieron valores para la estación de EIM de 0,617, mientras que para la estación de E3T fue 0,1.

Al comparar los resultados obtenido utilizando los modelos Sarima y Redes Neuronales Artificiales, se observó una similitud en las predicciones realizadas para la velocidad y temperatura del viento, como se evidencia en los errores reportados en los pronósticos. Sin embargo, cuando se analizó la dirección del viento, su evidencia una predicción incierta con un alto componente de aleatoriedad, consecuentemente, ninguna de las dos metodologías empleadas predice con un margen de error aceptable la variable de dirección del viento.

Las proyecciones de las velocidades del viento en relación con la altura de cada edificio en la Universidad oscilan en el rango de 1m/s a 1,6 m/s. Estas variaciones en la velocidad del viento se atribuyen a la influencia directa de la altura de los edificios y las características de rugosidad presentes en cada uno de ellos. Estos valores representan estimaciones basadas en el análisis de datos y el empleo del método de rugosidad. Dichas proyecciones son información importante acerca de las condiciones del flujo de aire en el entorno de la universidad.

Los resultados obtenidos por los perfiles de velocidad del viento proporcionaron aproximaciones cercanas a la velocidad real presente dentro de la Universidad. Estos resultados se basaron en los promedios de cada estación meteorológica, aunque los valores promedio brindan una idea general de la velocidad del viento en la zona, es importante tener en cuenta que los perfiles de velocidad se ven influenciados por diversos factores locales, como la topografía y la presencia de obstáculos. Para el caso de la EIM se utilizó el promedio de la velocidad de 1,27 m/s y para la E3T de 1,2 m/s. Finalmente

el perfil de velocidad de la dirección del viento no se pudo determinar por sus variaciones, su comportamiento es aleatorio.

RECOMENDACIONES

En vista de los resultados obtenidos en el uso de redes neuronales en el presente estudio, se recomienda considerar la inclusión de variables adicionales relacionadas a las condiciones climáticas locales, la consideración de más variables climáticas locales puede proporcionar información adicional que ayude a identificar patrones y tendencias más sólidas en el comportamiento de los datos lo que resulta fundamental para obtener pronósticos más precisos. Adicionalmente obtener la mayor cantidad de datos, ya que en cuanto más datos hallan mejor será la predicción.

11. REFERENCIAS

[1] Asociación Colombiana de Generadores de Energía Eléctrica. [Sitio web]. Bogotá: ACOGEN. Sala de prensa [Consulta: 17 de marzo 2021]. Disponible en: <https://acolgen.org.co/portfolio/acolgen-la-buena-energia>

[2] MARÍA MARGARITA GONZÁLEZ GUERRERO. Análisis de los procesos de gestión de las grandes centradles hidroeléctricas en Colombia en el marco de los requerimientos de la normatividad y los retos de sostenibilidad. Trabajo de grado en la Maestría en Gestión Ambiental. Bogotá D.C. Universidad Pontificia Javeriana. Facultad de estudios Ambientales y Rurales, 2021. 120p.

[3] VERGARA, Pedro. Evaluación del potencia solar y eólico del campus central de la Universidad Industrial de Santander y la ciudad de Bucaramanga. En : *Revista UIS Ingenierías*. 2014, vol 13, nro 2, pp 49-57.

[4] VERGARA, Pedro. Evaluación del potencia solar y eólico del campus central de la Universidad Industrial de Santander y la ciudad de Bucaramanga, En : *Revista UIS Ingenierías*. 2014, vol 13, nro 2, pp 49-57.

[6] Ades Tempero Group. [Sitio web]. España : EMPRESA ADES. Disponible en: <http://www.ades.tv/es/servicios/id/202>

[7] Ventajas económicas y medioambientales de la energía eólica. [Sitio web]. Argentina: BBVA. Energía eólica [Consulta: 17 de octubre 2019] . Disponible en : <https://www.bbva.com/es/sostenibilidad/ventajas-economicas-y-medioambientales-de-la-energia-eolica/>

[8] Aguado Rodríguez, Javier, *et al.* Predicción de Variables meteorológicas por Medio de Modelos Arima. En : *Agrociencia*. 2015, vol 50, nro.

[9] Palomino Parra, Jhon Ademir, *et al.* Dispositivo basado en modelo arima para predicción de variables ambientales (temperatura, humedad, velocidad de aire) en el área agrícola del departamento del meta. En: *Revista GEON (Gestión, Organizaciones y Negocios)*. 2020, vol 7(2), pp 1-12. Disponible en: <https://doi.org/10.22579/23463910.193>

[10] Pinzón Pineda, Sara Edith, *et al.* Aplicación de modelos auto regresivos para la predicción de generación de energía eléctrica a partir de datos eólicos. En: *research in computing science*. 2017, pp 59-70. ISSN 1870-4069.

[11] Ramírez Stalin, *et al.* Plataforma Web de predicción de viento basado en técnicas de inteligencia artificial con el uso del método ARIMA: caso de estudio. En: *Reviste Ibérica de sistemas y tecnologías de información*. 2019, pp 404-416.

[12] PILCO SANCHEZ, Victoria Karina y ACURIO MARTINEZ, Washington David. Técnicas estadísticas para la modelación y predicción de la temperatura y velocidad de viento en la provincia de Chimborazo. Trabajo de grado Ingeniero en Estadística Informática. Ecuador. Escuela Politécnica Superior de Chimborazo. Facultad de ciencias, 2019. 145p.

[13] FUENTE FERNANDE, Santiago. Series temporales: Modelo Arima. Universidad autónoma de Madrid. Facultad Ciencias Económicas y Empresariales. Disponibles en: <https://www.estadistica.net/ECONOMETRIA/SERIES-TEMPORALES/modelo-arima.pdf>

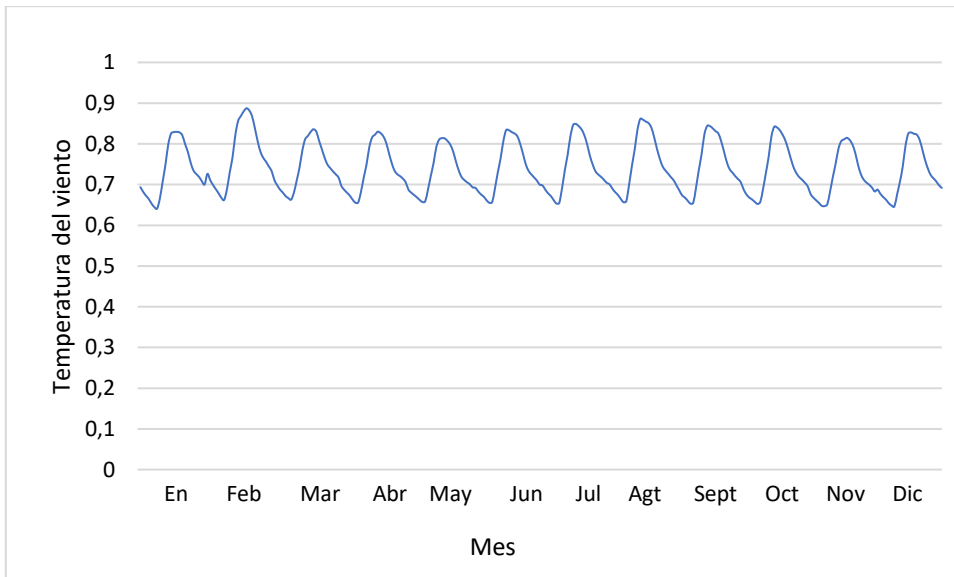
[14] PERÉZ RODRIGUEZ, Daniel. Predicción de la velocidad del viento para la generación eólica mediante redes neuronales artificiales. Trabajo de diploma. Universidad Central "Marta Abreu" de Las Villas. Facultad de Ingeniería Eléctrica, 2019. 75p.

[15] JIMÉNEZ MEJÍA, Miguel. Pronóstico de la velocidad del viento utilizando modelos arima y redes neuronales artificiales. Trabajo de grado maestro en ciencias. Universidad Michoacana de San Nicolás de Hidalgo. División de Estudios de Posgrados de la Facultad de Ingeniería Mecánica. 2011. 85p.

12. ANEXOS

ANEXO A. MODELOS ARIMA

- **ESTACIÓN METEOROLÓGICA EIM TEMPERATURA AMBIENTE**



PRUEBA DE DICKEY FULLER

Augmented Dickey-Fuller Test

data: Datos_EST

Dickey-Fuller = -7.7756, Lag order = 6, p-value = 0.01

alternative hypothesis: stationar

MODELO

```
> MOD_ARI
```

Series: Datos_TS

ARIMA(1,0,4) with non-zero mean

Coefficients:

ar1	ma1	ma2	ma3	ma4	mean
-----	-----	-----	-----	-----	------

	0.8332	1.0835	0.8874	0.9091	0.4444	0.7383
s.e.	0.0352	0.0529	0.0654	0.0728	0.0508	0.0140

sigma^2 = 8.897e-05: log likelihood = 931.27
AIC=-1848.54 AICc=-1848.14 BIC=-1822.93




PRUEBA DE RUIDO BLANCO

Box-Ljung test


data: residuals(MOD_ARI)

X-squared = 2.4591, df = 1, p-value = 0.1168

ANÁLISIS DE LOS RESIDUALES DEL MODELO ARIMA (1,0,4)



GRAFICA DE NORMALIDAD




PRUEBA DE NORMALIDAD DE SHAPIRO-WILK :

shapiro-wilk normality test


data: Datos_TS

w = 0.93872, p-value = 1.551e-09

PREDICCIÓN MODELO ARIMA (1,0,4)



- ESTACIÓN METEOROLÓGICA EIM DIRECCIÓN DEL VIENTO



PRUEBA DE DICKEY FULLER

Augmented Dickey-Fuller Test

```
data: Datos_EST
Dickey-Fuller = -9.0172, Lag order = 6, p-value = 0.01
alternative hypothesis: stationary
```

MODELO

```
> MOD_ARI
```

```
Series: Datos_TS
ARIMA(1,0,1) with non-zero mean
```

Coefficients:

	ar1	ma1	mean
	0.7569	0.2698	0.2674
s.e.	0.0443	0.0558	0.0114


```
sigma^2 = 0.001402: log likelihood = 536.38
AIC=-1064.77 AICc=-1064.63 BIC=-1050.1
```

PRUEBA DE RUIDO BLANCO


Box-Ljung test

data: residuals(MOD_ARI)
X-squared = 0.35768, df = 1, p-value = 0.5498

ANÁLISIS DE LOS RESIDUALES DEL MODELO ARIMA (1,0,1)



GRAFICA DE NORMALIDAD




PRUEBA DE NORMALIDAD DE SHAPIRO-WILK :


shapiro-wilk normality test

data: Datos_TS
w = 0.99274, p-value = 0.1762

PREDICCIÓN MODELO ARIMA (1,0,1)



- **ESTACIÓN METEOROLÓGICA E3T VELOCIDAD DEL VIENTO**



PRUEBA DE DICKEY FULLER

Augmented Dickey-Fuller Test

data: Datos_EST

Dickey-Fuller = -6.3176, Lag order = 6, p-value = 0.01

alternative hypothesis: stationary

MODELO

> MOD_ARI

Series: Datos_TS

ARIMA(1,0,3) with non-zero mean

Coefficients:

	ar1	ma1	ma2	ma3	mean
	0.8388	0.7884	0.5482	0.3559	0.0836
s.e.	0.0353	0.0676	0.0625	0.0493	0.0195

sigma^2 = 0.000416: log likelihood = 710.53

AIC=-1409.05 AICc=-1408.75 BIC=-1387.09


PRUEBA DE RUIDO BLANCO

Box-Ljung test


data: residuals(MOD_ARI)

X-squared = 1.9638, df = 1, p-value = 0.1611

ANÁLISIS DE LOS RESIDUALES DEL MODELO ARIMA (1,0,3)



GRAFICA DE NORMALIDAD




PRUEBA DE NORMALIDAD DE SHAPIRO-WILK :

Shapiro-wilk normality test


data: Datos_TS

w = 0.81578, p-value < 2.2e-16

PREDICCIÓN MODELO ARIMA (1,0,1)



- ESTACIÓN METEOROLÓGICA E3T TEMPERATURA AMBIENTE



PRUEBA DE DICKEY FULLER

Augmented Dickey-Fuller Test

data: Datos_EST
 Dickey-Fuller = -5.9723, Lag order = 6, p-value = 0.01
 alternative hypothesis: stationary

MODELO

[MOD_ARI](#)

Series: Datos_TS
 ARIMA(1,0,3) with non-zero mean

Coefficients:

	ar1	ma1	ma2	ma3	mean
	0.8673	0.5269	0.4564	0.3791	0.6824
s.e.	0.0316	0.0598	0.0564	0.0504	0.0164

sigma² = 0.0002607: log likelihood = 777.68
 AIC=-1543.37 AICc=-1543.07 BIC=-1521.41


PRUEBA DE RUIDO BLANCO

Box-Ljung test


```
data: residuals(MOD_ARI)
```

```
X-squared = 0.71773, df = 1, p-value = 0.3969
```

ANÁLISIS DE LOS RESIDUALES DEL MODELO ARIMA (1,0,3)



GRAFICA DE NORMALIDAD




PRUEBA DE NORMALIDAD DE SHAPIRO-WILK :

shapiro-wilk normality test


data: Datos_TS

w = 0.99133, p-value = 0.08935

PREDICCIÓN MODELO ARIMA (1,0,3)



- **ESTACIÓN METEOROLÓGICA E3T DIRECCIÓN DEL VIENTO**



PRUEBA DE DICKEY FULLER

Augmented Dickey-Fuller Test

```
data: Datos_EST
Dickey-Fuller = -5.9723, Lag order = 6, p-value = 0.01
alternative hypothesis: stationar
```

MODELO

```
> MOD_ARI
Series: Datos_TS
ARIMA(1,0,1) with non-zero mean
```

Coefficients:

	ar1	ma1	mean
	0.8455	0.2246	0.2004
s.e.	0.0353	0.0596	0.0182

```
sigma^2 = 0.001587: log likelihood = 518.47
AIC=-1028.94 AICc=-1028.8 BIC=-1014.3
```


PRUEBA DE RUIDO BLANCO

Box-Ljung test


```
data: residuals(MOD_ARI)
X-squared = 0.10444, df = 1, p-value = 0.7466
```

ANÁLISIS DE LOS RESIDUALES DEL MODELO ARIMA (1,0,3)





GRAFICA DE NORMALIDAD




PRUEBA DE NORMALIDAD DE SHAPIRO-WILK :

shapiro-wilk normality test

data: Datos_TS

w = 0.98719, p-value = 0.01194

PREDICCIÓN MODELO ARIMA (1,0,1)



ANEXO B. MODELOS SARIMA

• ESTACIÓN METEOROLÓGICA EIM TEMPERATURA AMBIENTE

MODELO

Series: Datos_TS
ARIMA(1,0,1)(0,1,1)[24]

Coefficients:

	ar1	ma1	sma1
	0.9312	0.3061	-0.7866
s.e.	0.0232	0.0558	0.0770



sigma² = 2.124e-05: log likelihood = 1030.87
AIC=-2053.73 AICc=-2053.58 BIC=-2039.45


Training set error measures:

	ME	RMSE	MAE	MPE	MAPE	M
ASE						
Training set	-7.055688e-05	0.004386126	0.002818891	-0.004915964	0.3785665	0.2095701

ACF1
Training set 0.04030851

ANÁLISIS DE LOS RESIDUOS DEL MODELO SARIMA (1,0,1)(0,1,1)(24)







PRUEBA DE RUIDO BLANCO DEL MODELO

data: Residuals from ARIMA(1,0,1)(0,1,1)[24]
 $Q^* = 80.476$, $df = 45$, $p\text{-value} = 0.0009071$

HISTOGRAMA DE DENSIDAD DE LOS RESIDUALES DEL MODELO SARIMA (1,0,1)(0,1,1)(24)



GRAFICA DE NORMALIDAD




PRUEBA DE NORMALIDAD DE SHAPIRO-WILK :

Shapiro-wilk normality test

data: Datos_EST
 $w = 0.93872$, $p\text{-value} = 1.551e-09$

MODELO SARIMA (1,0,1)(0,1,1)(24) VS SERIE ORIGINAL ESTACIÓN METEOROLÓGICA EIM TEMPERATURA AMBIENTE



• ESTACIÓN METEOROLÓGICA EIM DIRECCIÓN DEL VIENTO

MODELO

Series: Datos_TS
ARIMA(2,0,0)(2,1,1)[24]

Coefficients:

	ar1	ar2	sar1	sar2	sma1
	0.9847	-0.2467	-0.1881	-0.4579	-0.6830
s.e.	0.0643	0.0619	0.0763	0.0717	0.0843

sigma² = 0.001382: log likelihood = 474.15
AIC=-936.29 AICc=-935.96 BIC=-914.86

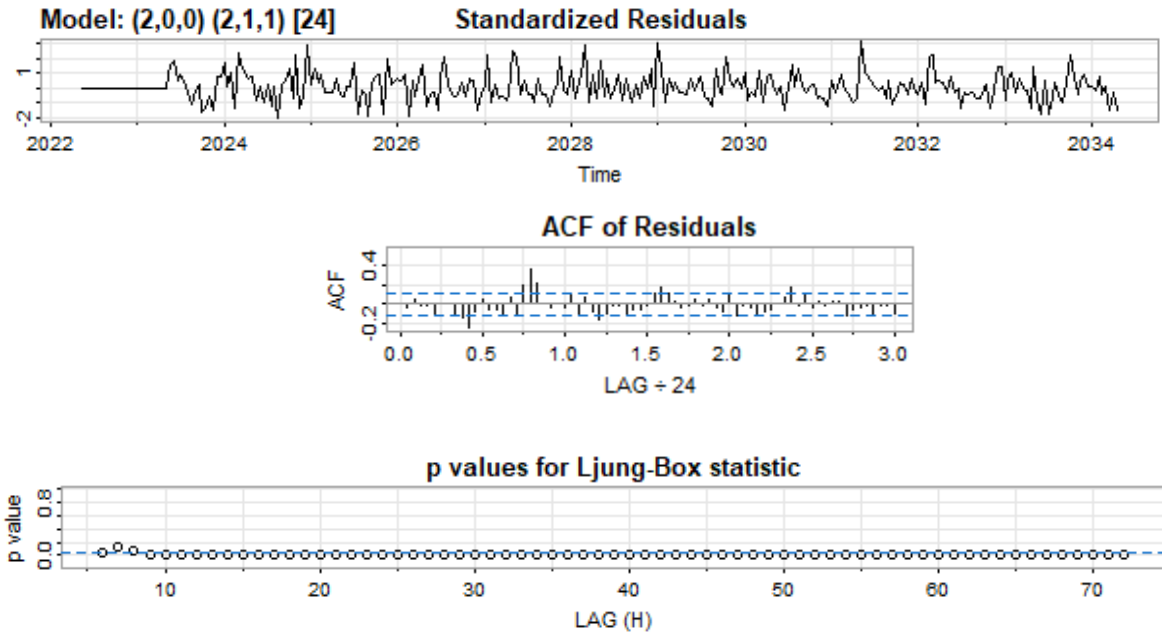
Training set error measures:

	ME	RMSE	MAE	MPE	MAPE	MASE
Training set	0.003192546	0.03525065	0.02646522	-0.2973767	10.17651	0.328168

ACF1

Training set -0.03802524

ANÁLISIS DE LOS RESIDUOS DEL MODELO SARIMA (2,0,0)(2,1,1)(24)




PRUEBA DE RUIDO BLANCO DEL MODELO


data: Residuals from ARIMA(2,0,0)(2,1,1)[24]

$Q^* = 154.54$, $df = 43$, $p\text{-value} = 1.71e-14$

HISTOGRAMA DE DENSIDAD DE LOS RESIDUALES DEL MODELO SARIMA (2,0,0)(2,1,1)(24)



GRAFICA DE NORMALIDAD




PRUEBA DE NORMALIDAD DE SHAPIRO-WILK :

Shapiro-wilk normality test

data: Datos_EST

w = 0.99274, p-value = 0.176

MODELO SARIMA (2,0,0)(2,1,1)(24) VS SERIE ORIGINAL -ESTACIÓN METEOROLÓGICA EIM DIRECCIÓN DEL VIENTO



- ESTACIÓN METEOROLÓGICA E3T VELOCIDAD DEL VIENTO

MODELO

Series: Datos_TS

ARIMA(1,0,1)(0,1,1)[24]

Coefficients:

	ar1	ma1	sma1
	0.9080	0.3185	-0.7613
s.e.	0.0268	0.0571	0.0780

sigma^2 = 0.0002176: log likelihood = 725.79

AIC=-1443.58 AICc=-1443.43 BIC=-1429.29


Training set error measures:


	ME	RMSE	MAE	MPE	MAPE	MASE	ACF
1							
Training set	-0.0007476273	0.01403897	0.009460348	NaN	Inf	0.2501424	0.0452871
9							
>	checkresiduals(fit_arma)						
	Ljung-Box test						

data: Residuals from ARIMA(1,0,1)(0,1,1)[24]

Q* = 65.87, df = 45, p-value = 0.02287

ANÁLISIS DE LOS RESIDUOS DEL MODELO SARIMA (1,0,1)(0,1,1)(24)







PRUEBA DE RUIDO BLANCO DEL MODELO

data: Residuals from ARIMA(1,0,1)(0,1,1)[24]
 $Q^* = 65.87$, $df = 45$, $p\text{-value} = 0.02287$

HISTOGRAMA DE DENSIDAD DE LOS RESIDUALES DEL MODELO SARIMA (1,0,1)(0,1,1)(24)



GRAFICA DE NORMALIDAD




PRUEBA DE NORMALIDAD DE SHAPIRO-WILK :

Shapiro-wilk normality test

data: Datos_EST
 $w = 0.81578$, $p\text{-value} < 2.2e-16$

MODELO SARIMA (1,0,1)(0,1,1)(24)VS SERIE ORIGINAL ESTACIÓN METEOROLÓGICA E3T VELOCIDAD DEL VIENTO



• ESTACIÓN METEOROLÓGICA E3T TEMPERATURA AMBIENTE

MODELO

ARIMA(2,0,1)(2,1,0)[24]

Coefficients:

	ar1	ar2	ma1	sar1	sar2
	1.5563	-0.5848	-0.4734	-0.5884	-0.5999
s.e.	0.1749	0.1673	0.1883	0.0539	0.0522

sigma^2 = 0.0001908: log likelihood = 741.93

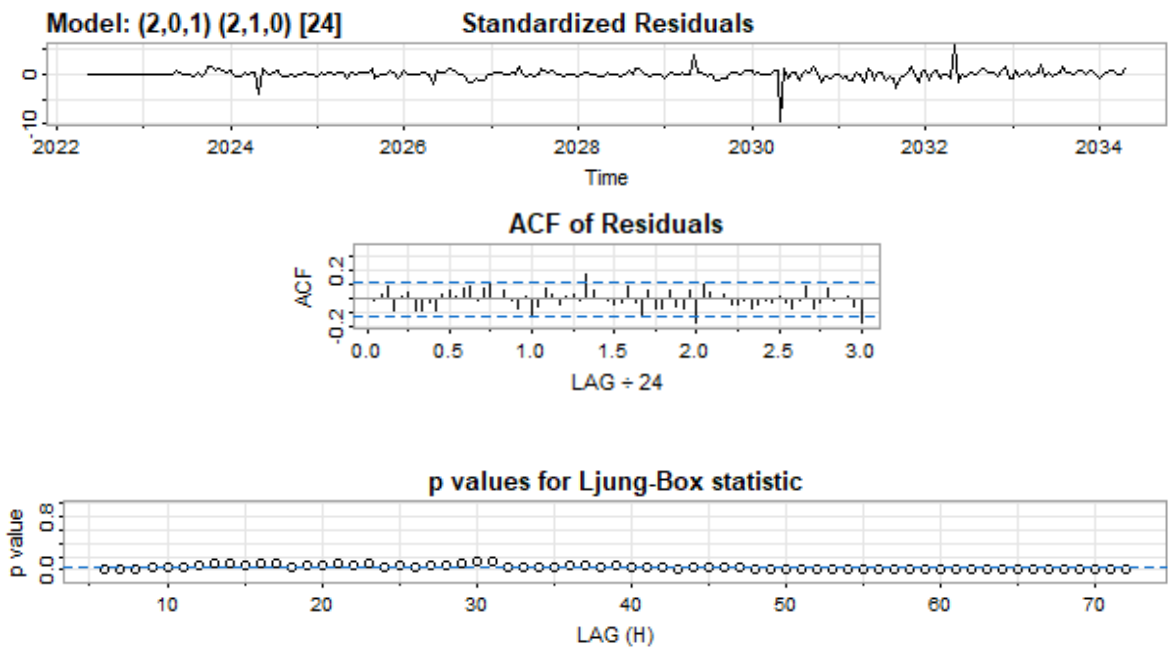
AIC=-1471.86 AICc=-1471.53 BIC=-1450.42

Training set error measures:

	ME	RMSE	MAE	MPE	MAPE	MAS
E	ACF1					

```
Training set -4.639523e-05 0.01309693 0.007053117 -0.03674558 1.06442 0.176946
5 -0.01691276
> checkresiduals(fit_arima)
```


ANÁLISIS DE LOS RESIDUOS DEL MODELO SARIMA (2,0,1)(2,1,0)(24)




PRUEBA DE RUIDO BLANCO DEL MODELO

```
data: Residuals from ARIMA(2,0,1)(2,1,0)[24]
Q* = 72.516, df = 43, p-value = 0.003239
```

HISTOGRAMA DE DENSIDAD DE LOS RESIDUALES DEL MODELO SARIMA (2,0,1)(2,1,0)(24)




GRAFICA DE NORMALIDAD



PRUEBA DE NORMALIDAD DE SHAPIRO-WILK :

data: Residuals from ARIMA(2,0,1)(2,1,0)[24]
Q* = 72.516, df = 43, p-value = 0.003239

MODELO SARIMA (2,0,1)(2,1,0)(24) VS SERIE ORIGINAL ESTACIÓN METEOROLÓGICA E3T TEMPERATURA DEL VIENTO



• ESTACIÓN METEOROLÓGICA E3T DIRECCIÓN DEL VIENTO

MODELO

Series: Datos_TS
ARIMA(2,0,1)(2,1,0)[24]

Coefficients:

	ar1	ar2	ma1	sar1	sar2
	1.4873	-0.5983	-0.3983	-0.5367	-0.3590
s.e.	0.1559	0.1357	0.1810	0.0634	0.0638

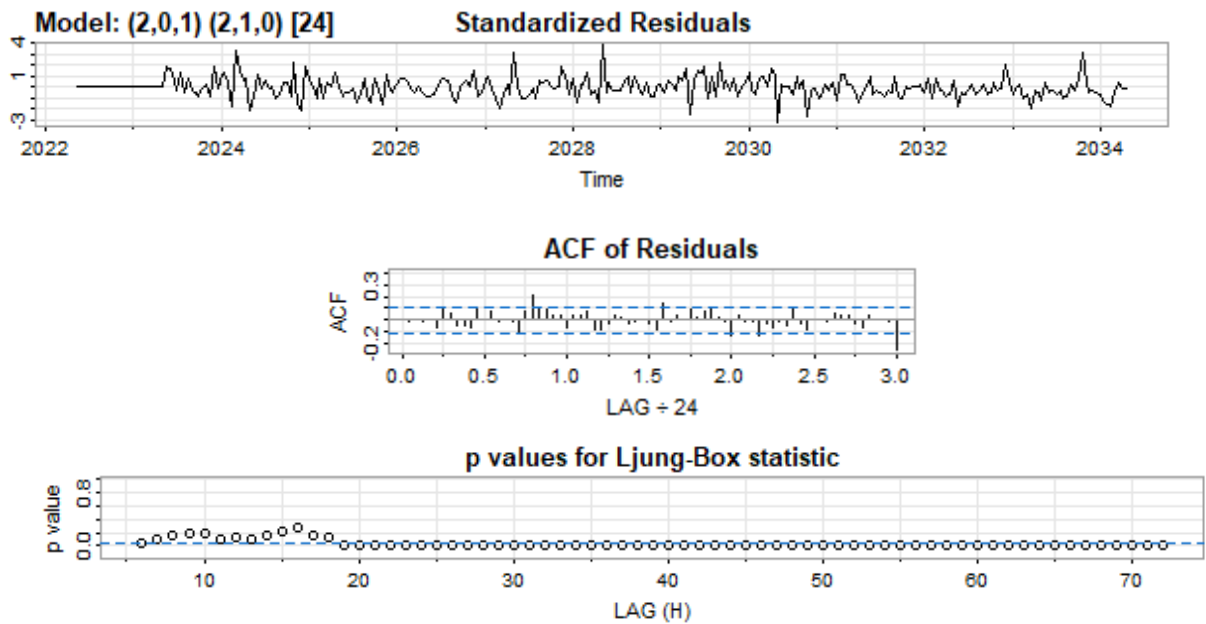
sigma² = 0.002143: log likelihood = 431.32
AIC=-850.64 AICc=-850.32 BIC=-829.21

Training set error measures:

	ME	RMSE	MAE	MPE	MAPE	MASE
Training set	-0.001488883	0.04388643	0.03216761	-3.364227	34.52691	0.3835214

ACF1
Training set -0.00507875


ANÁLISIS DE LOS RESIDUOS DEL MODELO SARIMA




PRUEBA DE RUIDO BLANCO DEL MODELO

data: Residuals from ARIMA(2,0,1)(2,1,0)[24]
 $Q^* = 72.865$, $df = 43$, $p\text{-value} = 0.002986$

HISTOGRAMA DE DENSIDAD DE LOS RESIDUALES DEL MODELO SARIMA (2,0,1)(2,1,0)(24)



GRAFICA DE NORMALIDAD




PRUEBA DE NORMALIDAD DE SHAPIRO-WILK :

Shapiro-wilk normality test

data: Datos_EST


w = 0.98719, p-value = 0.01194

MODELO SARIMA (2,0,1)(2,1,0)(24)VS SERIE ORIGINAL -ESTACIÓN METEOROLÓGICA E3T DIRECCIÓN DEL VIENTO.




ANEXO C. MODELOS REDES NEURONALES


- **ESTACIÓN METEOROLÓGICA EIM TEMPERATURA AMBIENTE**




- **ESTACIÓN METEOROLÓGICA EIM DIRECCIÓN DEL VIENTO**



ESTACIÓN METEOROLÓGICA E3T VELOCIDAD DEL VIENTO



ESTACIÓN METEOROLÓGICA E3T TEMPERATURA DEL VIENTO



ESTACIÓN METEOROLÓGICA E3T DIRECCIÓN DEL VIENTO

