



**ESCUELA SUPERIOR POLITÉCNICA DE CHIMBORAZO**  
**FACULTAD DE CIENCIAS**  
**CARRERA ESTADÍSTICA**

**COMPARACIÓN ENTRE LOS MÉTODOS DE PROMEDIO MÓVIL  
INTEGRADO AUTORREGRESIVO (ARIMA) Y TYLOR KRIGING(TK)  
PARA LA PREDICCIÓN DE SERIES TEMPORALES DE VELOCIDAD  
DEL VIENTO, CASO DE ESTUDIO: ESTACIÓN METEOROLÓGICA  
CHIMBORAZO**

**Trabajo de Titulación**

Tipo: Proyecto de Investigación

Presentado para optar al grado académico de:

**INGENIERA ESTADÍSTICA**

**AUTORAS: KERLY NATASHA LEMA REMACHE**

**LUZ ANGELICA CATUCUAMBA MENDOZA**

**DIRECTORA: Ing. PAULINA FERNANDA BOLAÑOS LOGROÑO, Mgs.**

Riobamba Ecuador

2024

**©2024, Lema Remache Kerly Natasha y Catucuamba Mendoza Luz Angelica**

Autorizamos la reproducción total o parcial, con fines académicos, por cualquier medio o procedimiento, incluyendo la cita bibliográfica del documento, siempre y cuando se reconozca el Derecho de Autor.

Nosotras, Lema Remache Kerly Natasha y Catucuamba Mendoza Luz Angelica, declaramos que el presente Trabajo de Titulación es de nuestra autoría y los resultados del mismo son auténticos. Los textos en el documento que provienen de otras fuentes están debidamente citados y referenciados.

Como autores asumimos la responsabilidad legal y académica de los contenidos de este Trabajo de Titulación; el patrimonio intelectual pertenece a la Escuela Superior Politécnica de Chimborazo.

Riobamba, 27 de mayo de 2024

A handwritten signature in blue ink, consisting of stylized initials 'K.N.' enclosed within an oval shape.

**Lema Remache Kerly Natasha**

**060462706-7**

A handwritten signature in blue ink, appearing to read 'Catucuamba Mendoza' with a stylized flourish.

**Catucuamba Mendoza Luz Angelica**

**172772021-9**

**ESCUELA SUPERIOR POLITÉCNICA DE CHIMBORAZO**  
**FACULTAD DE CIENCIAS**  
**CARRERA ESTADÍSTICA**

El Tribunal del Trabajo de Titulación certifica que: el Trabajo de Titulación; Tipo: Proyecto de Investigación. **COMPARACIÓN ENTRE LOS MÉTODOS DE PROMEDIO MÓVIL INTEGRADO AUTORREGRESIVO (ARIMA) Y TYLOR KRIGING (TK) PARA LA PREDICCIÓN DE SERIES TEMPORALES DE VELOCIDAD DEL VIENTO, CASO DE ESTUDIO: ESTACIÓN METEOROLÓGICA CHIMBORAZO**, realizado por las señoritas: **LEMA REMACHE KERLY NATASHA Y CATUCUAMBA MENDOZA LUZ ANGELICA**, ha sido minuciosamente revisado por los Miembros del Tribunal del Trabajo de Titulación, el mismo que cumple con los requisitos científicos, técnicos, legales, en tal virtud el Tribunal autoriza su presentación.

	<b>FIRMA</b>	<b>FECHA</b>
Ing. Natalia Alexandra Pérez Londo, Mgs. <b>PRESIDENTE DEL TRIBUNAL</b>		2024-05-27
Ing. Paulina Fernanda Bolaños Logroño, Mgs. <b>DIRECTORA DEL TRABAJO DE TITULACIÓN</b>		2024-05-27
Ing. Johanna Enith Aguilar Reyes, Mgs. <b>ASESORA DEL TRABAJO DE TITULACIÓN</b>		2024-05-27

## **DEDICATORIA**

Dedico este trabajo a mis padres Miguel Lema y Josefa Remache, que siempre me apoyaron y creyeron en mí, mostrándome su amor y cariño incondicional, siendo el mejor ejemplo de perseverancia y dedicación, a todos mis hermanos Verónica, Oscar, Roberth, Alejandra, Isáías y Sarón esperando que cada uno cumpla sus metas propuestas, para mis abuelitos que han sido mi impulso para jamás rendirme ante algún problema, a mi familia por ser el pilar más importante en mi vida y mi formación como persona.

*Kerly*

Le dedico esta tesis a mi madre que siempre me apoya en cada momento y sobre todo a enfrentarme a las adversidades, enseñarme a ser una persona humilde, creer en los sueños y metas sobre todo a mi familia por el apoyo brindado en toda esta trayectoria además dedico al Equipo Sporting S.P.U , Aso. Gafacc del Cantón Cayambe cada uno de ellos me brindaron la oportunidad de seguir creciendo como profesional y ser humano a obtener experiencias y conocer lugares, me han enseñado a ser la persona que soy hoy, mis principios, mis valores, mi perseverancia y mi empeño. Todo esto con una enorme dosis de amor y sin pedir nada a cambio.

*Luz*

## AGRADECIMIENTO

En primer lugar, agradezco a Dios por otorgarme esta magnífica oportunidad, agradezco también a mi padre por ser mi ejemplo, mi apoyo por darme siempre las fuerzas para seguir adelante e impulsarme a la Ing. Johanna Aguilar y a la Ing. Paulina Bolaños quienes me guiaron y tutelaron en el desarrollo de este trabajo de investigación. A mis padres quienes me han ayudado tanto económica como sentimentalmente durante toda mi vida. A toda mi familia quienes me han apoyado y soportado en todas las facetas de mi vida. Mi corazón siempre estará agradecido con mis maestros y amigos con quienes compartí momentos de alegría, triunfos y derrotas, con todos aquellos que me apoyaron en este largo proceso, gracias.

*Kerly*

A mi madre Narcisa Mendoza por todo su amor; usted y sus virtudes, su paciencia y constancia este trabajo no lo hubiese logrado tan fácil. Sus consejos fueron siempre útiles cuando todo era confuso. Usted formó parte importante de esta etapa en la Universidad. Muchas gracias por sus múltiples palabras de aliento, cuando más las necesite. También me ha brindado el soporte material y económico para poder concentrarme en los estudios y nunca abandonarlos”. A mis Hermanas y hermanos que siempre estaban para escucharme e impulsar mis sueños y esperanzas, quienes estuvieron siempre a mi lado en los días y noches más difíciles durante mis horas de estudio. Siempre han sido mis mejores guías de vida. Sportin S.P.U y a la Aso. Gafacc del Cantón Cayambe por sus enseñanzas y siempre impulsarme a ser la mejor persona y destacarme en cada ámbito por siempre apoyarme con su comprensión y brindarme todo su apoyo; gracias por confiar y creer en mi en todo momento.

*Luz*

## ÍNDICE DE CONTENIDO

ÍNDICE DE TABLAS.....	ix
ÍNDICE DE ILUSTRACIONES.....	x
RESUMEN.....	xii
ABSTRACT .....	xiii
INTRODUCCIÓN .....	1

### CAPÍTULO I

2.	PROBLEMA DE INVESTIGACIÓN .....	4
1.1.	Planteamiento del Problema .....	4
1.2.	Limitaciones y delimitaciones .....	4
1.3.	Problema General de Investigación.....	4
1.4.	Problemas específicos de investigación .....	4
1.5.	Objetivos .....	5
1.5.1.	<i>Objetivo general</i> .....	5
1.5.2.	<i>Objetivos específicos</i> .....	5
1.6.	Justificación .....	5
1.6.1.	<i>Justificación Teórica</i> .....	5
1.6.2.	<i>Justificación Práctica</i> .....	5
1.7.	Hipotesis.....	6

### CAPÍTULO II

2	MARCO TEÓRICO .....	7
2.1.	Bases teóricas.....	7
2.1.1.	<i>Modelos ARIMA</i> .....	7
2.1.2.	<i>Modelo autorregresivo</i> .....	7
2.1.3.	<i>Modelo de promedio móvil</i> .....	8
2.1.4.	<i>Promedio móvil integrado autorregresivo (ARIMA)</i> .....	8
2.1.5.	<i>Descomposición de la serie de tiempo</i> .....	8
2.1.6.	<i>Prueba Dickey-Fuller</i> .....	9
2.1.7.	<i>Tylor Kriging (TK)</i> .....	9

2.1.8.	<i>Método de Tylor Krigin (TK)</i> .....	9
2.1.9.	<i>Método de interpolación Kriging</i> .....	11
2.1.10.	<i>Variograma</i> .....	11
2.1.11.	<i>Series de tiempo</i> .....	11
2.1.12.	<i>Predicción</i> .....	12
2.1.13.	<i>Autocorrelación serial</i> .....	12
2.1.14.	<i>Medidas RMSE/MAE</i> .....	12
2.1.15.	<i>Error cuadrático medio (RMSE)</i> .....	12
2.1.16.	<i>Error absoluto medio (MAE)</i> .....	13
2.1.17.	<i>Datos Perdidos o faltantes</i> .....	13
2.1.18.	<i>Imputación simple o múltiple</i> .....	13
2.1.19.	<i>Estación meteorológica</i> .....	14
2.1.20.	<i>Tipos de estaciones meteorológicas</i> .....	14
2.1.21.	<i>Origen del Viento</i> .....	14
2.1.22.	<i>Velocidad del viento</i> .....	14
2.1.23.	<i>Energía eólica</i> .....	15

### CAPÍTULO III

3.	<b>MARCO METODOLÓGICO</b> .....	16
3.1.	<b>Tipo de Investigación</b> .....	16
3.2.	<b>Diseño de la Investigación</b> .....	16
3.2.1.	<i>Localización del Estudio</i> .....	16
3.2.2.	<i>Población de estudio</i> .....	17
3.2.3.	<i>Tamaño de la muestra</i> .....	17
3.2.4.	<i>Método de muestra</i> .....	17
3.2.5.	<i>Técnicas de recolección de datos</i> .....	17
3.2.6.	<i>Modelo Estadístico</i> .....	17
3.2.7.	<i>Identificaciones de variables</i> .....	18
3.2.7.1.	<i>Variable Independiente</i> .....	18
3.2.7.2.	<i>Variable dependiente</i> .....	18
3.2.8.	<i>Operacionalización de las variables</i> .....	18



## CAPÍTULO IV

4.	MARCO DE ANÁLISIS E INTERPRETACIÓN DE RESULTADOS.....	19
4.1.	Análisis descriptivo .....	19
4.2.	Imputación de información faltante .....	20
4.3.	Datos atípicos.....	21
4.4.	Matriz de información resultante .....	21
4.5.	Supuestos de normalidad.....	22
4.6.	Modelo ARIMA.....	23
4.7.	Series de tiempo.....	23
4.8.	Descomposición de la serie de tiempo.....	24
4.9.	Autocorrelogramas .....	25
4.10.	Diferenciación para obtener estacionariedad .....	26
4.11.	Prueba de estacionariedad de la serie .....	26
4.12.	Autocorrelogramas de la serie estacionaria.....	27
4.13.	Elección del modelo ARIMA.....	28
4.14.	Supuestos del modelo .....	29
4.14.1.	<i>Normalidad de los residuos</i> .....	29
4.14.2.	<i>Prueba de aleatoriedad de los residuos</i> .....	30
4.15.	Pronósticos con el modelo ARIMA.....	30
4.15.1.	<i>Predicciones de velocidad del viento para los próximos 15 días</i> .....	31
4.15.2.	<i>Predicciones de velocidad del viento para los próximos 30 días</i> .....	33
4.15.3.	<i>Predicciones de velocidad del viento para los próximos 3 meses</i> .....	36
4.16.	Método Taylor Kriging (TK) .....	39
4.17.	Supuestos del modelo .....	40
4.17.1.	<i>Normalidad de los residuos</i> .....	40
4.17.2.	<i>Estacionariedad espacial</i> .....	40
4.17.3.	<i>Pronósticos con el Método Taylor Kriging (15 días)</i> .....	41
4.17.4.	<i>Comparación de los dos métodos basado en el Error absoluto medio (MAE) y el Error cuadrático medio (RMSE).</i> .....	49
	CONCLUSIONES.....	52
	RECOMENDACIONES.....	53
	BIBLIOGRAFÍA	
	ANEXOS	

## ÍNDICE DE TABLAS

<b>Tabla 3-1</b> : Ubicación Metereológica.....	17
<b>Tabla 3-2</b> : Variables de Estudio. ....	18
<b>Tabla 4-1</b> : Resumen Estadístico.....	19
<b>Tabla 4-2</b> : Matriz resultante.....	22
<b>Tabla 4-3</b> : Supuesto de normalidad.....	23
<b>Tabla 4-4</b> : Supuesto de normalidad.....	27
<b>Tabla 4-5</b> : Modelos ARIMA.....	28
<b>Tabla 4-6</b> : Normalidad de los residuos .....	30
<b>Tabla 4-7</b> : Prueba de aleatoriedad.....	30
<b>Tabla 4-8</b> : Pronósticos (15 días) .....	32
<b>Tabla 4-9</b> : Pronósticos (30 días) .....	35
<b>Tabla 4-10</b> : Pronósticos (3 meses) .....	38
<b>Tabla 4-11</b> : Beta test .....	40
<b>Tabla 4-12</b> : Pronósticos (15 días) .....	43
<b>Tabla 4-13</b> : Pronósticos (30 días) .....	45
<b>Tabla 4-14</b> : Pronósticos (3 meses) .....	48
<b>Tabla 4-15</b> : MAE Y RMSE.....	49

## ÍNDICE DE ILUSTRACIONES

<b>Ilustración 4-1</b> : Gráfica de datos imputados y originales.....	20
<b>Ilustración 4-2</b> : Código de R cálculo Error Cuadrático Medio .....	21
<b>Ilustración 4-3</b> : Identificación de atípicos con la función de R “boxplot.stats” .....	21
<b>Ilustración 4-4</b> : Gráfica de serie de tiempo - velocidad del viento (m/s) .....	23
<b>Ilustración 4-5</b> : Descomposición de la serie (Tendencia,estacionalidad y aleatoriedad) .....	24
<b>Ilustración 4-6</b> : Autocorrelograma ACF de la serie no estacionaria.....	25
<b>Ilustración 4-7</b> : Autocorrelograma PACF de la serie no estacionaria.....	25
<b>Ilustración 4-8</b> : Gráfica de serie tiempo(estacionaria) aplicada una diferencia) .....	26
<b>Ilustración 4-9</b> : Autocorrelograma ACF serie estacionaria .....	27
<b>Ilustración 4-10</b> : Autocorrelograma PACF serie estacionaria .....	28
<b>Ilustración 4-11</b> : Elección del mejor modelo ARIMA(1, 1, 3) .....	29
<b>Ilustración 4-12</b> : Gráfica de normalidad en los residuos.....	29
<b>Ilustración 4-13</b> : Serie de tiempo de los datos originales (15 días).....	31
<b>Ilustración 4-14</b> : Serie de tiempo de los datos predichos (15 días).....	31
<b>Ilustración 4-15</b> : Serie de tiempo de los datos originales y predichos .....	32
<b>Ilustración 4-16</b> : Serie de tiempo de los datos originales (30 días).....	33
<b>Ilustración 4-17</b> : Serie de tiempo de los datos predichos (30 días).....	34
<b>Ilustración 4-18</b> : Serie de tiempo de los datos originales y predichos .....	34
<b>Ilustración 4-19</b> : Serie de tiempo de los datos originales (3 meses) .....	36
<b>Ilustración 4-20</b> : Serie de tiempo de los datos predichos (3 meses) .....	37
<b>Ilustración 4-21</b> : Serie de tiempo de los datos originales y predichos .....	37
<b>Ilustración 4-22</b> : Modelo del variograma.....	39
<b>Ilustración 4-23</b> : Método Taylor Kriging (TK).....	39
<b>Ilustración 4-24</b> : Normalidad en los residuos .....	40
<b>Ilustración 4-25</b> : Estacionariedad espacial.....	41
<b>Ilustración 4-26</b> : Serie de tiempo de los datos originales (15 días).....	41
<b>Ilustración 4-27</b> : Serie de tiempo de los datos método TK (15 días) .....	42
<b>Ilustración 4-28</b> : Serie de tiempo de los datos originales y predichos .....	42
<b>Ilustración 4-29</b> : Serie de tiempo de los datos originales (30 días).....	44
<b>Ilustración 4-30</b> : Serie de tiempo de los datos, método TK (30 días) .....	44
<b>Ilustración 4-31</b> : Serie de tiempo de los datos originales y predichos .....	45

<b>Ilustración 4-32</b> : Serie de tiempo de los datos originales (3 meses) .....	47
<b>Ilustración 4-33</b> : Serie de tiempo de los datos, método TK (3 meses).....	47
<b>Ilustración 4-34</b> : Serie de tiempo de los datos originales y predichos .....	48
<b>Ilustración 4-35</b> : Resultados de la comparación del método ARIMA y Taylor Kriging .....	50

## RESUMEN

La estación meteorológica Chimborazo ubicada en la provincia de Chimborazo, cantón Riobamba, parroquia de Loma de Rasutambo, zona de Pinanquil, es un lugar donde se miden las distintas variables que afectan al estado de la atmósfera, es decir, nos permite la observación de los fenómenos atmosféricos, debido a la limitación de infraestructura esta estación meteorológica no cuenta con datos actuales para poder proyectar la posible instalación de un aerogenerador para la generación de energía eólica, por lo tanto, el objetivo de la presente investigación es comparar los métodos de promedio móvil integrado autorregresivo (ARIMA) y Tylor Kriging (TK) para la predicción de series temporales de velocidad del viento. La metodología implementada tuvo un diseño no experimental de tipo epistemológico, con un enfoque cuantitativo, obteniendo la matriz de datos de una fuente primaria, la población de estudio es la información de los años (2014, 2015, 2016) de la velocidad de viento medida en cada hora, con el uso de un anemómetro. Se comparó el rendimiento de los métodos de promedio móvil integrado autorregresivo (ARIMA) y Tylor Kriging (TK) con las medidas del error absoluto medio (MAE) y el error cuadrático medio (RMSE), dando como resultado en el modelo ARIMA un MAE de 26.42 % y un RMSE de 30.23 %. Por otro lado, el modelo Taylor Kriging tuvo un MAE de 50.09 % y un RMSE de 60.143 %, en base a estas métricas, cuanto más cercanos a cero sean estos valores, mejor será el rendimiento del modelo concluyendo que el modelo ARIMA (1, 1, 3) es el mejor en términos de precisión de las predicciones de la variable velocidad del viento, ya que presenta un valor menor MAE y RMSE en comparación con el modelo Taylor Kriging.

**Palabras clave:** <METEOROLOGIA>, <VELOCIDAD DEL VIENTO>, <PROMEDIO MÓVIL INTEGRADO AUTORREGRESIVO (ARIMA)>, <TYLOR KRIGING (TK)>, <ENERGIA EOLICA>.

0595-DBRA-UPT-2024



## SUMMARY

The meteorological station located in the province of Chimborazo, Riobamba canton , parish of Loma de Rasutambo, Pinanquil area, is a place where the different variables that affect the state of the atmosphere can be measured , in addition the observation of atmospheric phenomena, due to the limited infrastructure this meteorological station does not have current data to be able to project the possible installation of a wind turbine for wind power generation, therefore, the objective of this research is to compare the autoregressive integrated moving average (ARIMA) and Taylor Kriging(TK) methods for the prediction of wind speed time series. The methodology implemented had a non experimental design of epistemological type, with a quantitative approach , obtaining the data matrix from a secondary source, the study population is the information of the years (2014, 2015, 2016) of the wind speed measured in each hour, with the use of an anemometer. The performance of the autoregressive integrated moving average (ARIMA) and Taylor kriging (TK) methods were compared with the measures of mean absolute error (MAE) and root mean square error (RMSE), resulting in the ARIMA model an MAE of 26.42 % and RMSE of 30.23 % 30.23 %. On the other hand, the Taylor Kriging model had an MAE of 50.09% and an RMSE of 60.143% based on these metrics, the closer these values are to zero the better the performance of the model concluding that the ARIMA model (1, 1, 3) is the best in terms of accuracy of the predictions of the wind speed variable, since it presents a lower MAE and RMSE value compared to the TaylorKriging model.

**Keywords:** <METHEREOLOGY>,<WIND SPEED>,<AUTOREGRESSIVE INTEGRATED MOBILE AVERAGE (ARIMA)>, < TYLOR KRIGING (TK)>, <WIND ENERGY>.



Edgar Mesias Jaramillo Moyano

0603497397

## INTRODUCCIÓN

El estudio de la meteorología es de suma importancia ya que nos ayuda a estar preparados ante muchas adversidades climáticas y podemos estar alerta frente a acontecimientos que afectan al ser humano como: las inundaciones, lluvias torrenciales, heladas, etc., para ello se debe observar y medir las variables principales, teniendo la presión atmosférica, velocidad del viento, humedad y temperatura agregando una variable más siendo esta la calidad del aire.

Por consiguiente, una estación meteorológica es un lugar escogido adecuadamente para colocar los diferentes instrumentos, que permiten medir las distintas variables que afectan al estado de la atmósfera, es decir, es un lugar que nos permite la observación de los fenómenos atmosféricos y donde existen aparatos que miden las variables atmosféricas. Uno de los instrumentos de medición son los sensores, miden tanto la dirección y la velocidad del viento, siendo así unos de los dispositivos de alta precisión.

Las variables o elementos climatológicos en una estación meteorológica esenciales a medir son: temperatura, humedad del aire, viento, radiación solar, precipitación y evaporación, resulta necesario determinar el valor de la información recogida en relación con su utilidad y finalidad, por lo que los instrumentos deben estar homologados, ser robustos y estar bien calibrados. Los componentes de una estación meteorológica son: Terreno circundante, Parcela Meteorológica, Abrigo Meteorológico. Una de las variables escogidas para realizar el presente estudio es la variable velocidad del viento, ya que mucho más que aire en movimiento, es un recurso energético renovable y una de las formas de energía más antigua, el viento es causado por las diferencias de temperatura existentes al producirse un desigual calentamiento de las diversas zonas de la tierra y de la atmósfera. Las masas de aire más caliente tienden a ascender, y en su lugar es ocupado entonces por las masas de aire circundante, más frío y, por tanto, más denso. Se nombra propiamente “viento” a la corriente de aire que se desplaza en sentido horizontal, reservándose la denominación de “corriente de convección” para los movimientos de aire en sentido vertical. Por lo que velocidad del viento es la relación de la distancia recorrida por el aire con respecto al tiempo empleado en recorrerla. La velocidad instantánea corresponde al caso de un intervalo infinitamente pequeño. La velocidad media corresponde al caso de un intervalo de tiempo finito. En meteorología esta palabra se refiere, en general, a un movimiento de conjunto de aire cerca de la superficie terrestre o en altitud. El viento puede ser considerado como un vector con magnitud y dirección, es una variable la cual se puede estudiar como una serie de tiempo donde esta es un conjunto de observaciones sobre los valores que toma una variable (cuantitativa) a través del tiempo, por tanto, una serie de tiempo es una forma estructurada de representar datos. Los datos se pueden comportar de diferentes maneras a través del

tiempo: puede que se presente una tendencia, estacionalidad o simplemente no presenten una forma definida.

De esta manera se pueden realizar predicciones, donde la predicción de series de tiempo significa que se extienden los valores históricos de la serie al futuro, donde aún no se han hecho mediciones, para llevar a cabo el pronóstico donde se definen dos variables principales: cantidad de períodos y horizonte de predicción. La cantidad de períodos representa el nivel de agregación de los datos, por otra parte, el horizonte de planificación representa el número de períodos futuros o alcance a pronosticar, se han acogido o desarrollado varios métodos para el pronóstico de la velocidad del viento en general, esos métodos se pueden clasificar en tres categorías como son: modelos físicos, modelos estadísticos convencionales y modelos de series de tiempo no convencionales. Los modelos físicos a menudo se mencionan predicción meteorológica de la velocidad del viento, lo que implica la aproximación numérica de los modelos que describen el estado de la atmósfera.

La presente investigación se realizará con el fin de comparar dos métodos de predicción ARIMA (Promedio Móvil Integrado Autorregresivo) y Tylor Kriging (TK), que nos permitan ver cuál de los métodos es el mejor para predecir la velocidad del viento. Cabe recalcar que, en comparación con otros enfoques, las principales ventajas de los modelos estadísticos convencionales para el pronóstico de la velocidad del viento son la simplicidad de la construcción del modelo y la precisión de los resultados para la predicción a corto plazo, los modelos estadísticos supuestos incluyen el grupo general de modelos MA (Promedio Móvil), AR (Autorregresivo), ARMA (Promedio Móvil autorregresivo) y ARIMA (Promedio Móvil Integrado Autorregresivo), y se han aplicado ampliamente al pronóstico de la velocidad del viento.

En estadística y econometría, en particular en series temporales, un modelo Autorregresivo Integrado de Promedio Móvil o ARIMA (acrónimo del inglés Autoregressive Integrated Moving Average) es un modelo estadístico que utiliza variaciones y regresiones de datos estadísticos con el fin de encontrar patrones para una predicción hacia el futuro. Habla de un modelo dinámico de series temporales, es decir, las estimaciones futuras vienen explicadas por los datos del pasado y no por variables independientes.

El modelo ARIMA necesita identificar los coeficientes y número de regresiones que se utilizarán. Este modelo es muy sensible a la precisión con que se determinen sus coeficientes. Se suele expresar como  $ARIMA(p,d,q)$  donde los parámetros  $p$ ,  $d$  y  $q$  son números enteros no negativos que indican el orden de las distintas componentes del modelo respectivamente, las componentes autorregresiva, integrada y de media móvil. Cuando alguno de los tres parámetros es cero, es común omitir las letras correspondientes del acrónimo AR para la componente autorregresiva, I para la integrada y MA para la media móvil. Otro de los métodos a utilizar en la presente investigación es Kriging que



es una técnica estadística especial utilizada para estimar el valor de la función en una posición no observada. Fue creada por Danie G. Krige, un ingeniero de minas en Sudáfrica. Cressie proporcionó una introducción completa a Kriging. La aplicación temprana de Kriging es principalmente en entornos geológicos. Recientemente, Kriging se ha aplicado en muchos campos, como el diseño de ingeniería, la interpolación de simulación y la optimización. Curiosamente, aplicó un método Kriging neuronal a la estimación espacial de la velocidad del viento para la planificación energética en Sicilia, Italia. La literatura muestra que Kriging tiene amplias aplicaciones debido a su precisión de interpolación, y los modelos de Kriging ampliamente adoptados son OK (Kriging Ordinario). La función se deriva de OK es una constante y tiene dificultades para capturar la deriva media no constante de los datos. Liu y Maghsoodloo desarrollaron recientemente un nuevo modelo de Kriging basado en la expansión de Taylor, llamado TK (Taylor Kriging), donde la expansión de Taylor se usa para identificar las funciones base de Kriging. La expansión de Taylor tiene una excelente capacidad de aproximación no lineal, lo que mejora la precisión de la interpolación de Origina.

Por otra parte, para el estudio de las series temporales de vientos se requiere de un análisis estadístico debido a que este se comporta como una variable aleatoria continua (Wilks, 2006, p.27-34), para ello existen numerosos softwares, entre los que destaca: Rstudio, que permite analizar simultáneamente datos de dirección y velocidad del viento de varias bases de datos en múltiples formatos, además, relaciona variables como la temperatura, presión, humedad relativa y altura con las series de vientos y permite el cálculo de los estadísticos principales tales como la media, los máximos y la desviación estándar (AWS Truepower, 2018).

Dicho todo lo anterior se puede ver que todo pronóstico tiene asociado un alcance, pudiendo ser de corto, mediano o largo plazo, por este motivo, es importante pronosticar la velocidad del viento y, en consecuencia, conocer la cantidad de energía limpia que se puede producir.

Aunque la energía eólica tiene muchas ventajas, la mayor dificultad es que la velocidad del viento no es constante a través del tiempo, pero es de suma importancia estudiarla ya que esta energía es renovable y ayudará en el futuro.

## **CAPÍTULO I**

### **1. PROBLEMA DE INVESTIGACIÓN**

#### **1.1. Planteamiento del Problema**

Se han instalado los anemómetros en la estación meteorológica Chimborazo desde el año 2014 al año 2016, donde se han obtenido datos de variables ambientales entre estas la velocidad del viento, dentro del objetivo de la estación meteorológica Chimborazo es proyectar la posible instalación de un aerogenerador para la generación de energía eólica, para lo cual se necesita conocer los datos actuales de la velocidad del viento para el año 2019, 2020, 2021, 2022, sin embargo debido a la limitación de infraestructura los datos solo se tiene de años anteriores, por lo cual se ve la necesidad de realizar pronósticos o estimaciones de la velocidad del viento, con la finalidad de proveer información fiable que permita la toma de decisiones en cuanto a la generación de energía eólica, por lo tanto, se propone predecir la velocidad del viento utilizando dos técnicas y con esto poder seleccionar la información más confiable en el proceso antes mencionado.

#### **1.2. Limitaciones y delimitaciones**

Una limitación en el manejo de la base de datos son los datos faltantes, esto debido a la infraestructura que se utiliza para la toma de datos en ciertos periodos de tiempo puede dejar de funcionar por problemas técnicos de calibración o falta de energía eléctrica. Se va a tomar todos los datos medidos de la velocidad del viento en la estación meteorológica Chimborazo desde el año 2014 al 2016, con una periodicidad de 60 minutos.

#### **1.3. Problema General de Investigación**

¿Cuál de los dos modelos predictivos será el mejor para el pronóstico de series temporales de velocidad del viento, caso de estudio: estación meteorológica Chimborazo?

#### **1.4. Problemas específicos de investigación**

- ¿Qué factores influyen en la velocidad del viento?
- ¿Qué factores influyen en la predicción de la variable de estudio?
- ¿Qué problema se genera en el preprocesamiento de datos?

- ¿Qué problemas se generan al utilizar el método de ARIMA?
- ¿Qué problemas se generan al utilizar el método de TK?
- ¿Qué problemas se generan al comparar estos métodos?

## **1.5. Objetivos**

### ***1.5.1. Objetivo general***

- Comparar los métodos de promedio móvil integrado autorregresivo (ARIMA) y Tylor Kriging (TK) para la predicción de series temporales de velocidad del viento, caso de estudio: estación meteorológica Chimborazo.

### ***1.5.2. Objetivos específicos***

- Realizar el preprocesamiento de los datos, utilizando software estadístico R, con la finalidad de obtener una base de datos óptima para su posterior estimación.
- Predecir la velocidad de viento mediante el método TK.
- Predecir la velocidad de viento mediante el método ARIMA.
- Comparar el rendimiento basado en el cálculo de errores absoluto medio y cuadrático medio y analizar los resultados obtenidos con cada método utilizado.

## **1.6. Justificación**

### ***1.6.1. Justificación Teórica***

Debido a los antecedentes antes mencionados, se propone la utilización de dos métodos predictivos para el pronóstico de series temporales de velocidad del viento, caso de estudio: estación meteorológica Chimborazo.

### ***1.6.2. Justificación Práctica***

El proceso de predicción se lo realizará comparando dos métodos predictivos como Promedio Móvil Integrado Autorregresivo (ARIMA) y Tylor Kriging (TK), además de realizar el preprocesamiento de los datos, utilizando el software estadístico R, con la finalidad de obtener una base de datos óptima para su posterior estimación.

### **1.7. Hipotesis**

El rendimiento basado en el cálculo de errores absoluto medio y cuadrático medio del método Taylor Kriging es mejor que el método ARIMA, para los datos de la estación meteorológica Chimborazo.

## CAPÍTULO II

### 2. MARCO TEÓRICO

#### 2.1. Bases teóricas

##### 2.1.1. Modelos ARIMA

Hay grandes progresos en el desarrollo y las aplicaciones de la predicción del clima a mediano plazo y su predicción estacional (Vitart et al. 2012). Los algoritmos de predicción automáticas más usados son en base al suavizado exponencial o modelos autorregresivos integrados de media móvil (ARIMA) (Hyndman y Khandakar, 2008). Box y Jenkins (1976) desarrollaron la metodología clásica que emplean las series de tiempo para generar modelos como el autorregresivo de media móvil (ARMA) o también el modelo ARIMA para obtener predicciones.

Los procesos ARIMA son los más populares para el modelado de procesos econométricos, financieros, meteorológicos e incluso biológicos. Son una generalización de procesos ARMA (Auto Regresivos y de Medias Móviles), usados cuando la serie de tiempo presenta una tendencia, que la vuelve un proceso no estacionario (Marco y Sonny, 2016: p.93).

##### 2.1.2. Modelo autorregresivo

Un modelo autorregresivo expresa al pronóstico como una función de valores previos de esa serie de tiempo.

Un modelo autorregresivo tiene la forma

$$Y_t = \varphi_0 + \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \dots + \varphi_p Y_{t-p} + \varepsilon_t \quad (2-1)$$

en donde

$Y_t$  = Variable dependiente

$Y_{t-1}, Y_{t-2}, Y_{t-p}$  = variables independientes que son variables dependientes desfasadas un número específico de periodos.

$\varphi_0, \varphi_1, \varphi_2, \varphi_p$  = coeficiente de regresión.

$\varepsilon_t$  = término de residuo que representa sucesos aleatorios no explicados por el modelo.

### 2.1.3. Modelo de promedio móvil

Un proceso de promedios móviles es tan sólo una combinación lineal de términos de error de ruido blanco.

Un modelo promedio móvil toma la forma

$$Y_t = W_0 + \varepsilon_t - W_1\varepsilon_{t-1} - W_2\varepsilon_{t-2} + \dots + W_q\varepsilon_{t-q} \quad (2-2)$$

en donde

$Y_t$  = variable dependiente.

$W_0, W_1, W_2, W_q$  = peso específico.

$\varepsilon_t$  = residuo o error.

$\varepsilon_{t-1}, \varepsilon_{t-2}, \varepsilon_{t-q}$  = valores previos de residuo.

### 2.1.4. Promedio móvil integrado autorregresivo (ARIMA)

Los modelos autorregresivos integrados de medias móviles, ARIMA por sus siglas en inglés, son los modelos de series de tiempo aditivas muy populares. Son una generalización de los modelos autorregresivos de medias móviles (ARMA), útiles cuando la serie de tiempo a modelar no es estacionaria a causa de la marcada tendencia (Marco y Sonny, 2016: pág. 89).

$$Y_t = \varphi_0 + \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \dots + \varphi_p Y_{t-p} + \varepsilon_t - W_1\varepsilon_{t-1} - W_2\varepsilon_{t-2} + \dots + W_q\varepsilon_{t-q} \quad (2-3)$$

Los modelos ARIMA (p, q) realizan combinaciones de errores anteriores y ofrecen un potencial para ajustar modelos que no pudieron ajustarse en forma adecuada mediante los modelos AR y MA por sí solos.

### 2.1.5. Descomposición de la serie de tiempo

- Tendencia: Es el patrón subyacente en los datos a lo largo del tiempo. No es necesariamente lineal.
- Estacionalidad: Cuando una serie está influenciada por factores estacionales de periodo fijo como el día, mes, trimestre.
- Ciclicidad: Cuando los datos muestran subidas y caídas que no son del período fijo. Las fluctuaciones suelen ser de al menos 2 años.

- Aleatoriedad: parte inexplicable de los datos

Otras definiciones incluyen el ruido blanco (White noise) referente a la suposición de que los valores en una serie de tiempo son aleatorios, independientes entre sí (no están correlacionados), tienen una media de cero y varianza constante. Cuando estos supuestos no se cumplen se deben aplicar modelos autorregresivos (AR) y de media móvil (MA) para corregir las infracciones de esta suposición.

#### **2.1.6. Prueba Dickey-Fuller**

En estadística, la prueba de Dickey-Fuller prueba la hipótesis nula de que una raíz unitaria está presente en un modelo de serie de tiempo autorregresivo. La hipótesis alternativa es diferente según la versión de la prueba que se utilice, pero suele ser de estacionariedad o tendencia-estacionariedad. La prueba lleva el nombre de los estadísticos David Dickey y Wayne Fuller, quienes la desarrollaron en 1979 (David y Wayne, 1979: pág 34).

#### **2.1.7. Tylor Kriging (TK)**

La técnica Kriging pertenece a la segunda familia de modelos basados en métodos geoestadísticos, que utilizan fundamentos matemáticos y estadísticos que incluyen auto correlaciones. Es decir, son modelos que no sólo predicen superficies de interpolación, sino que también indican el grado de exactitud y error de la predicción.

Es un método desarrollado por Krige (Krige 1951) en su teoría de las variables regionalizadas (1971) y aplicado después en prospección minera por Georges Matheron (Matheron 1962) como interpolador óptimo de la ley de un yacimiento.

Su objetivo, como técnica de interpolación geoestadística, es generar superficies que incorporan las propiedades estadísticas de los datos muestrales y que proporciona una medida del error de estas, siendo este último un indicador de una buena o mala predicción.

Kriging es un método de inferencia espacial, el cual nos permite estimar los valores de una variable en lugares no muestreados utilizando la información proporcionada por la muestra (Velázquez, 2019: p.4).

#### **2.1.8. Método de Tylor Kriging (TK)**

Supongamos que un proceso estocástico tiene la siguiente forma:

$$Z(X) = \mu(X) + \varepsilon(X) \quad (2-4)$$

donde  $X$  es un vector de posición,  $\mu(X)$  es un término medio y se llama función de deriva que muestra el comportamiento promedio de  $Z(X)$ , y  $\varepsilon(X)$  es un término de error estocástico con  $E[\varepsilon(X)] = 0$ . Kriging utiliza una combinación lineal de estos valores observados para estimar el valor de la función en un punto no observado.

$$X : \hat{Z}(X) = \sum_{i=1}^N \lambda_i Z(X_i) \quad (2-5)$$

Asumir que  $\mu(X)$  consta de  $M$  funciones

$$f_l(X) (l = 1, \dots, M) : \mu(X) = \sum_{l=1}^M \mu_l f_l(X) \quad (2-6)$$

Y la otra es que se debe minimizar la varianza de los errores de estimación. Estos dos requisitos conducen a la siguiente optimización problema con restricciones:

$$\text{Minimizar } \text{Var}[\hat{Z}(X) - Z(X)] = \sum_{i=1}^N \sum_{j=1}^N \lambda_i \lambda_j \text{Cov}[Z(X_i), Z(X_j)] \quad (2-7)$$

$$-2 \sum_{i=1}^N \lambda_i \text{Cov}[Z(X_i), Z(X)] + \text{Var}[Z(X)] \quad (2-8)$$

Sujeto en :

$$f_l(X) = \sum_{i=1}^N \lambda_i f_{li} = 1, \dots, M \quad (2-9)$$

Si  $\mu(X)$  es igual a una constante desconocida distinta de cero, las restricciones en el problema de optimización anterior se convierten en:

$$\lambda_1 + \dots + \lambda_N = 1 \quad (2-10)$$

la introducción de multiplicadores de Lagrange  $\mu_l (l = 1, \dots, M)$  puede cambiarlo para que sea un problema de optimización sin restricciones a continuación:

$$\text{Minimizar } \text{Var}[\hat{Z}(X) - Z(X)] = \sum_{i=1}^N \sum_{j=1}^N \lambda_i \lambda_j \text{Cov}[Z(X_i), Z(X_j)] \quad (2-11)$$

$$-2 \sum_{i=1}^N \lambda_i \text{Cov}[Z(X_i), Z(X)] \quad (2-12)$$



$$+ \text{Var}[Z(X) + 2 \sum_{i=1}^M \mu_i] \quad (2-13)$$

$$\ast [f_i(X) - \sum_{i=1}^N \lambda_i f_i(X_i)] \quad (2-14)$$

### 2.1.9. Método de interpolación Kriging

Tiene como objetivo estimar el valor de la variable  $Z$ , para un punto  $x_0$  que no ha sido considerado anteriormente, realiza una suma ponderada sobre todos los sectores que conforman la zona de estudio de interés, tomando los vecinos más cercanos al punto de interés  $X_0$ . El proceso del Kriging, es asignar pesos a los vecinos más cercanos, considerados para la estimación,

$$z^{\wedge}(x) = \sum_{i=1}^{n(x)} \lambda_i(x) [Z(x_i) - m(x)] + m(x) \quad (2-15)$$

donde:

$z^{\wedge}(x)$  = es el valor estimado para cada ubicación  $x$ .

$n(x)$  = número de muestras.

$\lambda_i$  = peso o ponderación de cada muestra  $Z(x_i)$  toma  $m(x_i)$ , y  $m(x)$  = medias aritméticas de las muestras y de la elevación en el área cubierta.

### 2.1.10. Variograma

La interpolación espacial es un problema clásico de estimación de una función  $F(x)$  en un punto  $X_p$  de un plano a partir de valores conocidos de  $F$  en un cierto número  $m$  de puntos regionales  $X_i$ . El problema consiste en determinar la ponderación de los valores  $W_i$  de cada punto regional, tal como se propone en la ecuación.

$$F(x_p) = \sum_{i=1}^m W_i \ast F(x_i) \quad (2-16)$$

### 2.1.11. Series de tiempo

Una serie temporal (o simplemente una serie) es una secuencia de  $N$  observaciones (datos) ordenadas y equidistantes cronológicamente sobre una característica (serie univariante o escalar) o sobre varias características (serie multivariante o vectorial) de una unidad observable en diferentes momentos (Mauricio, 2007:p.30).

### **2.1.12. Predicción**

La predicción en estadística es el anuncio de lo que se espera que pueda suceder. Es un elemento importante de las ciencias, en general, pues permiten iniciar experimentos y contrastar el hecho esperado con la realidad (Westreicher, 2018)

### **2.1.13. Autocorrelación serial**

La autocorrelación es un caso particular del modelo de regresión generalizado que se produce cuando las perturbaciones del modelo presentan correlaciones entre ellas. La autocorrelación supone que la matriz de varianzas y covarianzas de las perturbaciones presentan valores distintos de cero en los elementos que están fuera de la diagonal principal (Gujarati et al.,1993:p.57).

### **2.1.14. Medidas RMSE/MAE**

Existen dos medidas comunes de exactitud que miden la distancia promedio entre las predicciones y las correspondientes observaciones, son el error cuadrático medio (mean square error - MSE) y el error absoluto medio (mean absolute error - MAE). Ambas medidas tienen valor cero para pronósticos perfectos. Frecuentemente se utiliza la raíz del error cuadrático medio (root mean square error, RMSE) en vez del MSE porque tiene las mismas dimensiones que la variable original (Stauffer y Seaman,1990: pág 189).

### **2.1.15. Error cuadrático medio (RMSE)**

La diferencia entre la predicción y el valor real es el error. Se utilizan principalmente para ajuste de modelos (selección de parámetros óptimos de un modelo dado), validación de modelos, selección de modelos, comparaciones de modelos (entre varios modelos en competencia) y evaluaciones de pronóstico (Karunasingha, 2022:p.206).

$$RMSE = \left[ \frac{1}{N} \sum_{n=1}^N (f_n - o_n)^2 \right]^{1/2} \quad (2-17)$$

donde:

$N$  = número total de comparaciones pronosticadas

$f_n$  = pronóstico

$o_n$  = observaciones

### 2.1.16. *Error absoluto medio (MAE)*

MAE se utiliza para evaluar la magnitud del error en un pronóstico de temperatura, vientos y alturas geopotenciales.

$$MAE = \frac{1}{N} \sum_{n=1}^N |f_n - o_n| \quad (2-18)$$

donde:

$N$  = número total de comparaciones pronosticadas

$f_n$  = pronóstico

$o_n$  = observaciones

### 2.1.17. *Datos Perdidos o faltantes*

La presencia de valores perdidos (información ausente o faltante) es un problema común en cualquier investigación, no puede ser ignorado en el análisis de datos, pues puede ser de grave repercusión en la pérdida de potencia del análisis, hasta en la aparición de sesgos inaceptables. La eliminación de estos con este problema limita la representatividad o validez externa de los resultados del estudio, a pesar de que es algo prácticamente inevitable en las investigaciones (Abellana Sangra y Farran Codina, 2015).

Según (Viada, y otros, 2016). los datos perdidos se clasifican en tres tipos y son:

- Datos perdidos completamente al azar (MCAR): Cuando la probabilidad de que un sujeto presente un valor ausente en una variable no depende de la propia variable ni de ninguna otra variable recogida.
- Datos perdidos al azar (MAR): Cuando la probabilidad de no observar un dato depende de otras variables, pero no de los valores de la variable con valores perdidos.
- Datos perdidos no debidos al azar (NMAR): Cuando la probabilidad de un sujeto presenta un valor faltante depende de dicha variable con valores perdidos.

### 2.1.18. *Imputación simple o múltiple*

Según (Abellana, et al, 2015) menciona que, la imputación es un proceso de reemplazar los datos perdidos por estimaciones e indica varios métodos para proceder: imputación mediante la media, imputación mediante regresión, imputación mediante el algoritmo de esperanza- maximización e

imputación múltiple. El método a utilizar consiste en reemplazar los datos perdidos por la media de los datos no perdidos, el inconveniente es que puede atenuar cualquier correlación entre las variables que se han imputado valores.

#### **2.1.19. Estación meteorológica**

(Malvé, 2014) manifiesta que, una estación meteorológica es una instalación destinada a medir y registrar regularmente diversas variables meteorológicas mediante los instrumentos meteorológicos.

#### **2.1.20. Tipos de estaciones meteorológicas**

Pueden ser convencionales o automáticas:

Estaciones convencionales.- necesitan de un observador meteorológico, que es una persona calificada para recopilar y transmitir información meteorológica.

Estaciones automáticas.- son configuradas para que registren datos en lugares remotos y lo transmitan de manera automatizada. Una estación meteorológica automática (EMA) es una versión autónoma de la tradicional estación meteorológica, preparada tanto para ahorrar en personal, o realizar mediciones en áreas remotas o de difícil acceso. El sistema puede reportar en tiempo real vía sistema Argos, o el Global Telecommunications System, tener enlace de microondas, o salvar los datos para posteriores trabajos de investigación o calibración de la misma, un ejemplo de la misma se puede observar en la figura la misma que claramente indica la tecnología instalada para la obtención y monitoreo de datos de varias variables meteorológicas.

#### **2.1.21. Origen del Viento**

El viento se produce por el movimiento de las masas de aire en la troposfera, la capa más baja de la atmósfera. Dentro de ella, los vientos que tendrán interés desde el punto de vista energético son los que se producen a nivel de la superficie terrestre.

Los movimientos de masa de aire hay que buscarlos en los gradientes de presión existente, que en último término son debidos a los gradientes térmicos originados por la radiación solar recibida sobre la tierra. Es decir, las capas de aire caliente ascienden dejando hueco libre para las capas de aire frío, generando así el movimiento de las capas de aire (Mur, 2016).

#### **2.1.22. Velocidad del viento**

La velocidad del viento aumenta con la altura en forma exponencial debido a la disminución de la rugosidad de la superficie y la menor fricción. El patrón de la velocidad del viento sobre la

superficie se denomina Perfil de la velocidad del viento y permite conocer la velocidad del viento con la altura. La velocidad del viento en el interior del cultivo también decrece exponencialmente (Herrera, 2015).

### **2.1.23. *Energía eólica***

Es la energía cinética generada por efecto de las corrientes de aire, y que es transmutada en otras formas útiles para las actividades humanas. Principalmente se utiliza para producir energía eléctrica mediante aerogeneradores. Es un recurso abundante, renovable, limpio y ayuda a disminuir las emisiones de gases de efecto invernadero al reemplazar termoeléctricas a base de combustibles fósiles, lo que la convierte en un tipo de energía verde. Su principal inconveniente es la intermitencia del viento (Welch y Venkateswaran,2009).

## CAPÍTULO III

### 3. MARCO METODOLÓGICO

#### 3.1. Tipo de Investigación

Este trabajo es cuantitativo ya que las variables en estudio son mutables estadísticas, según el objetivo de estudio será aplicado ya que se pretende modelizar y comparar mediante dos técnicas como Promedio Móvil Integrado Autorregresivo (ARIMA) y Tylor Kriging (TK), según el nivel de profundización en el objeto de estudio exploratorio ya que se busca la predicción de series temporales de velocidad del viento con la unidad de media en horas, en el estudio de estación meteorológica Chimborazo con el uso de un cronómetro, según la manipulación de variables no experimental ya que la matriz de datos proviene de una fuente secundaria, según el tipo de inferencia inductiva ya que se busca hacer una proyección o estimación de la velocidad del viento con la finalidad de proveer de información fiable que permita la toma de decisiones en cuanto a la generación de la energía eólica mediante la predicción de la velocidad del viento a corto plazo utilizando dos técnicas y deductiva para ver cuales el mejor modelo al comprar, según el periodo temporal longitudinal ya que se obtiene datos de la estación meteorológica Chimborazo desde el año 2014 al año 2016.

#### 3.2. Diseño de la Investigación

Se utiliza un método de investigación cuantitativa y según la manipulación de variables es un diseño no experimental (Berger et al. 2018).

##### 3.2.1. *Localización del Estudio*

La estación meteorológica Chimborazo, está ubicada en la provincia de Chimborazo, cantón Riobamba, parroquia de Loma de Rasutambo, zona de Pinanquil, con un área de 1000 km aproximadamente, temperatura media de 7.1°C, cuyas coordenadas se resumen en la tabla.

**Tabla 3–1:** Ubicación Meteorológica.

Estación meteorológica	Altitud (m.s.n.m)	Latitud (deg)	Longitud(deg)
Loma de Rasutambo - zona Pinanquil. Chimborazo	4302	1° 32' 0.43"S	78° 52' 40.27" O

**Fuente:** Google Maps

**Realizado por:** Luz, Kerly, 2023.

### **3.2.2. Población de estudio**

Se realiza el análisis con información de los años (2014, 2015, 2016) de la velocidad de viento de la estación meteorológica Chimborazo.

### **3.2.3. Tamaño de la muestra**

Se tomo en cuenta todos los datos obtenidos durante el periodo 2014 a 2016 monitoreadas en la estación meteorológica Chimborazo

### **3.2.4. Método de muestra**

La información es recopilada directamente desde los anemómetros instalados en la estación meteorológica Chimborazo.

### **3.2.5. Técnicas de recolección de datos**

La técnica de recolección de datos se basa en la medición de la velocidad de viento cada hora desde el año 2014 al 2016, datos que se descargan al servidor de la estación meteorológica como un archivo de texto plano.

### **3.2.6. Modelo Estadístico**

Como primera instancia se realiza un procesamiento de datos con la finalidad tener una base de datos óptima, por consiguiente, efectuar las predicciones con los modelos Promedio Móvil Integrado Autorregresivo (ARIMA) y Tylor Kriging (TK), logrando así comparar los métodos antes mencionados para ello se aplica el cálculo de errores absoluto medio y cuadrático medio de los métodos en análisis.

### 3.2.7. Identificación de variables

#### 3.2.7.1. Variable Independiente

- Tiempo de medición

#### 3.2.7.2. Variable dependiente

- Velocidad del viento

### 3.2.8. Operacionalización de las variables

**Tabla 3–2:** Variables de Estudio.

VARIABLES	CONCEPTO	INDICADOR
VARIABLE INDEPENDIENTE: Velocidad del viento	Es una fuente de energía porque siempre está en movimiento, el contenido de la energía que puede generar depende de su velocidad.	Velocidad máxima Velocidad mínima.
VARIABLE DEPENDIENTE: Tiempo de medición	Consiste en el cálculo de la duración que tiene la velocidad del viento.	Periodo de tiempo Unidades de tiempo.

**Fuente:** Base de datos octubre 2014 hasta diciembre 2016

**Realizado por:** Luz, Kerly, 2023.



## CAPÍTULO IV

### 4. MARCO DE ANÁLISIS E INTERPRETACIÓN DE RESULTADOS

Se realizó el estudio de la velocidad del viento de la Estación Meteorológica de Chimborazo Loma de Rasutambo - zona Pinanquil, mediante el Modelo ARIMA y el Método Taylor-Kriging en R. Ambas metodologías son seleccionadas con el fin de realizar una comparativa, y elegir la más adecuada en función de su capacidad de predicción medida por sus errores, así como su habilidad para identificar patrones y cambios en el tiempo. En el proceso se realizan varias etapas, como la limpieza y preparación de los datos, para elegir los parámetros adecuados para cada método.

#### 4.1. Análisis descriptivo

**Tabla 4–1:** Resumen Estadístico.

<b>Velocidad del Viento</b>	
Media	11,130
Error típico	0,262
Mediana	10,638
Moda	3,417
Desviación estándar	5,953
Varianza de la muestra	35,434
Curtosis	-0,926
Coficiente de asimetría	0,351
Rango	25,116
Mínimo	2,226
Máximo	27,342
Total	518
NA's (faltantes)	26

**Fuente:** Base de datos octubre 2014 hasta diciembre 2016


**Realizado por:** Luz, Kerly, 2023.

Dentro del análisis descriptivo se observó un total de 518 mediciones, con 26 observaciones faltantes (NA's). En promedio la velocidad del viento es de 11,130 m/s, con un error típico de 0,262

m/s, mientras que la mediana tiene un valor de 10,638 m/s y la moda de 3,417 m/s, en cuanto a las medidas de dispersión, la desviación estándar tiene un valor de 5,953 m/s indicando la variabilidad de los valores individuales, la varianza de la muestra es de 35,434 m/s, la curtosis tiene un valor de -0,926 lo que sugiere una distribución ligeramente menos puntiaguda dado que los datos tienen muy poca concentración con respecto a la media, mientras que el coeficiente de asimetría es de 0,351, lo que indica una cola más larga en el lado derecho hace referencia que tiene más valores diferentes a la derecha de la media, por otro lado el rango de velocidad del viento es de 25,116 m/s, con un mínimo de 2,226 m/s y un máximo de 27,342 m/s.

#### 4.2. Imputación de información faltante

Se identificó un total de 544 observaciones, de las cuales 26 registros son NA, lo que representa aproximadamente el 5 de toda la información. Para abordar esta falta de datos, se aplicó la técnica de imputación por la media, el objetivo de esta técnica es reemplazar los valores faltantes con el valor promedio de los valores no faltantes presentes en la misma variable.



**Ilustración 4-1:** Gráfica de datos imputados y originales

**Realizado por:** Luz, Kerly, 2023.

Mediante la ilustración 4-1 la gráfica de color rojo representa los registros con la información faltante, mientras que la gráfica de color verde muestra los registros faltantes imputados con la técnica de imputación por la media, la cual tiene una buena aproximación en relación con la distribución original, con un Error Cuadrático Medio de 5.92107.

```
> squared_diff <- (datos_tesis$`Por día` - da$x)^2
> mse <- mean(squared_diff, na.rm = TRUE)
> mse
[1] 5.92107
```

**Ilustración 4–2:** Código de R cálculo Error Cuadrático Medio

**Realizado por:** Luz,Kerly, 2023.

La imputación por la media es una técnica práctica y rápida para manejar los registros faltantes de velocidad de viento, la cual nos da un valor mínimo en el error MSE.

### 4.3. Datos atípicos

Según (Francisco M. Ocaña Peinado, 2018), se denominan casos atípicos u outliers a aquellas observaciones con características diferentes de las demás. Sin embargo, en nuestro caso, no se observan datos atípicos en la variable objeto de estudio.

```
> boxplot.stats(da$x)
$stats
[1] 2.226314 5.750513 11.064172 15.854465 27.342373

$n
[1] 544

$conf
[1] 10.37971 11.74863

$out
numeric(0)
```

**Ilustración 4–3:** Identificación de atípicos con la función de R “boxplot.stats”

**Fuente:** Base de datos octubre 2014 hasta diciembre 2015.

**Realizado por:** Luz,Kerly, 2023.

Se contrasta mediante la función "boxplot.stats", la cual identifica los valores atípicos con el comando "Sout". Sin embargo, no se encuentra ningún dato atípico en la variable de estudio.

### 4.4. Matriz de información resultante

La tabla 4-2, muestra el registro completo de información, enumerando en primer lugar el número de registro, las mediciones por día de la variable velocidad del viento y la fecha correspondiente a cada medición.

**Tabla 4–2:** Matriz resultante.

Registro	Velocidad de viento	Fecha
1	6.135360518	17/10/2014
2	5.672823944	18/10/2014
3	4.897869911	19/10/2014
4	4.120062283	20/10/2014
5	6.643110971	21/10/2014
6	8.93550888	22/10/2014
7	7.166368603	23/10/2014
8	4.158180566	24/10/2014
...	...	...
...	...	...
537	7.551847222	05/04/2016
538	10.53973611	06/04/2016
539	16.51504167	07/04/2016
540	18.90809722	08/04/2016
541	17.1459375	09/04/2016
542	10.47342361	10/04/2016
543	4.749826389	11/04/2016
544	4.959280702	12/04/2016

**Fuente:** Base de datos octubre 2014 hasta diciembre 2016

**Realizado por:** Luz, Kerly, 2023.

Dando así una base datos óptima, y se procede a realizar el supuesto de normalidad donde veremos que los datos siguen una distribución normal.

#### 4.5. Supuestos de normalidad

##### **Hipótesis de la prueba:**

$H_0$  : Los datos proceden de una distribución normal

$H_1$  : Los datos no proceden de una distribución normal

## Nivel de significancia

$$\alpha = 0,05$$

**Tabla 4-3:** Supuesto de normalidad

Shapiro-Wilk Test	
W= 0.98057	p-value = 0.6973

**Fuente:** Shapiro Wilk-Test

**Realizado por:** Luz,Kerly, 2023.

Dado que el p-value  $> 0.05$  se concluye que los datos proceden de una distribución normal.

## 4.6. Modelo ARIMA

## 4.7. Series de tiempo

Primero se ha creado una serie de tiempo sobre lo cual se estudió si es estacionaria o no, con los datos de la velocidad del viento tomados desde el 17 de octubre del 2014 al 12 de abril del 2016.




**Ilustración 4-4:** Gráfica de serie de tiempo - velocidad del viento (m/s)

**Realizado por:** Luz,Kerly, 2023.

La ilustración 4-4 muestra que, en la serie de tiempo de la velocidad del viento, se puede apreciar que no sigue patrones ni tendencias claras a lo largo del tiempo, en el mes de octubre del año 2014 la serie tiende a ser estacionaria, mediante va transcurriendo el tiempo por el mes de junio hasta julio del año 2015 se puede ver que la velocidad del viento aumenta gradualmente, pero la serie aun no es estacionaria. Esto se interpreta como un patrón aleatorio, ya que no se observan ciclos o comportamientos recurrentes en los datos.

#### 4.8. Descomposición de la serie de tiempo

Se realizó la descomposición de la serie temporal, obteniéndose una visión más detallada del comportamiento de los datos a lo largo del tiempo, permitiendo entender mejor las componentes principales las cuales son: tendencia, estacionalidad y aleatoriedad.



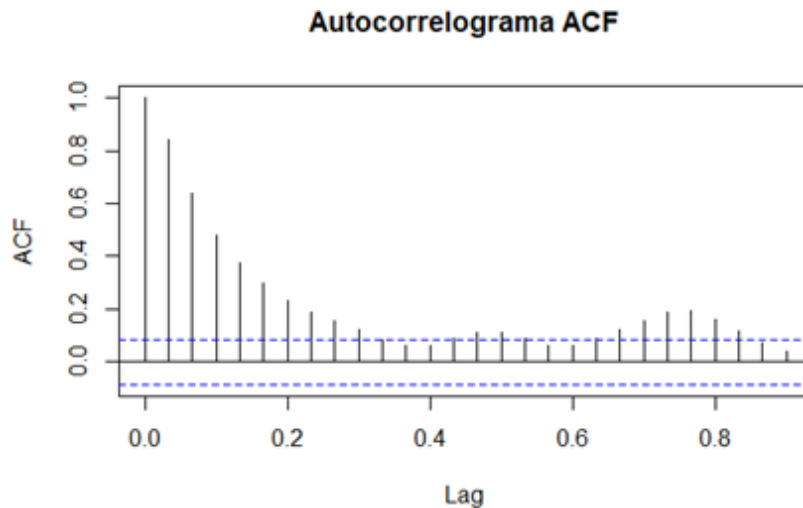
**Ilustración 4–5:** Descomposición de la serie (Tendencia, estacionalidad y aleatoriedad)

**Realizado por:** Luz, Kerly, 2023.

- **Tendencia:** Al observar la dirección general y el patrón a lo largo del tiempo en la serie de velocidad del viento, se notan fluctuaciones ascendentes y descendentes. Por lo que su comportamiento va en crecimiento y disminución a largo plazo de los valores, pero no se identifica un patrón claro de tendencia constante en una sola dirección.
- **Componente estacional:** Se observa patrones repetitivos en intervalos regulares, indicando una estacionalidad diaria en la serie de velocidad del viento. Esta estacionalidad está relacionada con factores climáticos y se repite en ciclos diarios.
- **Componente aleatorio:** En los residuos, anomalías o errores de medición no muestra un patrón específico. Estos componentes parecen ser aleatorios y no siguen una tendencia o patrón discernible.

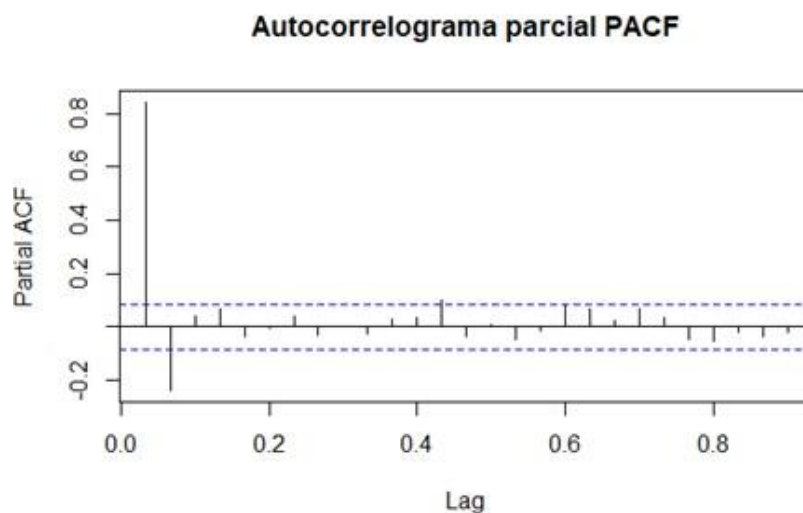
#### 4.9. Autocorrelogramas

Se realizan las gráficas de autocorrelograma (ACF) con el fin de identificar la correlación entre la serie de tiempo y sus valores rezagados en diferentes intervalos de tiempo. Por otro lado, en el caso del autocorrelogramas parcial (PACF), se muestra la correlación entre la serie de tiempo y sus valores rezagados, controlando las correlaciones intermedias.



**Ilustración 4-6:** Autocorrelograma ACF de la serie no estacionaria

Realizado por: Luz, Kerly, 2023.



**Ilustración 4-7:** Autocorrelograma PACF de la serie no estacionaria

Realizado por: Luz, Kerly, 2023.

En la ilustración 4-6, que representa el primer autocorrelograma, se puede observar que la serie no exhibe estacionariedad, por lo que no se aprecia una disminución exponencial de los rezagos en el autocorrelograma. Por otro lado, en la siguiente ilustración el autocorrelograma parcial muestra un rezago en el intervalo de confianza superior indicando una correlación positiva significativa. Por consecuente también se parecía un rezago, pero en la parte inferior del intervalo de confianza indicando una correlación negativa significativa, señalando una posible influencia inversa o compensatoria entre el valor actual y el rezago en cuestión.

#### 4.10. Diferenciación para obtener estacionariedad

En base a los resultados obtenidos, se procede a aplicar las diferencias necesarias para lograr que la serie sea estacionaria. Al aplicar una diferencia a la serie de tiempo esta presenta cambios en su comportamiento, es decir, la media y varianza son constantes en el tiempo como se muestra en la siguiente Ilustración 4-8.



**Ilustración 4-8:** Gráfica de serie tiempo(estacionaria) aplicada una diferencia)

**Realizado por:** Luz,Kerly, 2023.

#### 4.11. Prueba de estacionariedad de la serie

Con el test Dickey-Fuller, se evalúo si existe la presencia de raíces unitarias en la serie de tiempo. Una raíz unitaria sugiere que la serie presenta una tendencia no estacionaria, mientras que la ausencia de raíces unitarias indica que la serie es estacionaria.



## Dickey-Fuller

Hipótesis de la prueba:

$H_0: \gamma = 0$  La serie tiene raíces unitarias (no estacionaria)

$H_1: \gamma < 0$  La serie no tiene raíces unitarias (estacionaria)

**Tabla 4-4:** Supuesto de normalidad

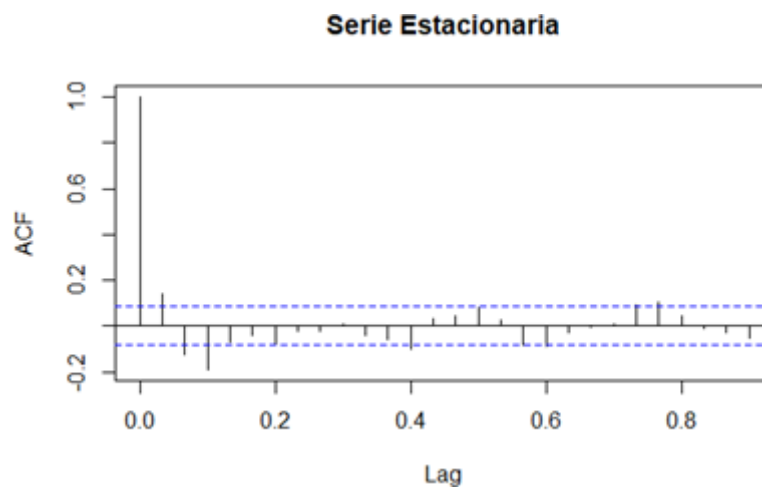
Prueba Dickey-Fuller	
Valor critico: -5.7587	P-value : 0.01

**Fuente:** Shapiro Wilk-Test

**Realizado por:** Luz,Kerly, 2023.


Dado que el p-value  $< 0.05$  se rechaza la hipótesis nula y se concluye que la serie es estacionaria.

### 4.12. Autocorrelogramas de la serie estacionaria



**Ilustración 4-9:** Autocorrelograma ACF serie estacionaria

**Realizado por:** Luz,Kerly, 2023.



**Ilustración 4-10:** Autocorrelograma PACF serie estacionaria  
**Realizado por:** Luz,Kerly, 2023.

Analizadas las ilustraciones de **acf** y **pacf** de la serie estacionaria se plantea varios modelos tentativos para el modelo ARIMA (Modelo autorregresivo integrado de media móvil).

#### 4.13. Elección del modelo ARIMA

Para la obtención del modelo ARIMA se procede a variar los parámetros ARIMA (p, d, q) y (P, D, Q). Destacando que (p, d, q) se refiere a la tendencia regular o parte regular de la serie, mientras que el segundo paréntesis (P, D, Q) se refiere a las variaciones estacionales o parte cíclica de la serie temporal. Se selecciona el mejor modelo teniendo en cuenta el valor menor en los criterios AIC (Criterio de Información de Akaike) y BIC (Criterio de Información Bayesiano), los cuales actúan como medida de su ajuste como se observa en la siguiente tabla:

**Tabla 4-5:** Modelos ARIMA

Modelo ARIMA		Criterio	
		AIC	BIC
1	(0, 1, 0)	2823.755	2828.052
2	(0, 1, 1)	2812.396	2820.990
3	(0, 1, 2)	2810.876	2823.767
4	(0, 1, 3)	2787.26	2804.449
5	<b>(1, 1, 3)</b>	<b>2755.079</b>	<b>2776.564</b>
6	(0, 1, 2) (0, 0, 1)	2811.222	2828.410
7	(0, 1, 3) (1, 0, 1)	2784.445	2810.228
8	(1, 1, 2) (0, 1, 0)	2997.122	3014.083

9	(1, 1, 1) (1, 0, 0)	2813.955	2831.144
10	(1, 1, 3) (1, 1, 0)	2817.728	2843.170

**Fuente:** Base de datos octubre 2014 hasta diciembre 2015.

**Realizado por:** Luz, Kerly, 2023.

Para la predicción de la velocidad del viento, se evalúa un total de 10 modelos ARIMA (ver tabla 4-5) con diferentes combinaciones de parámetros (p, d, q) y (P, D, Q). Después de verificar los criterios que actúan como medida de ajuste, se encuentra que el modelo ARIMA(1, 1, 3) obtiene el menor valor en los criterios AIC y BIC, lo que sugiere que este modelo tiene un mejor ajuste a los datos en comparación con los otros nueve modelos evaluados.

```
Series: ARIMA
ARIMA(1,1,3)

Coefficients:
      ar1      ma1      ma2      ma3
      0.6628  -0.6072  -0.2332  -0.1310
s.e.  0.0607   0.0741   0.0475   0.0624


sigma^2 = 9.225: log likelihood = -1372.54
AIC=2755.08  AICC=2755.19  BIC=2776.56
```

**Ilustración 4-11:** Elección del mejor modelo ARIMA(1, 1, 3)

**Realizado por:** Luz, Kerly, 2023.

#### 4.14. Supuestos del modelo

##### 4.14.1. Normalidad de los residuos



**Ilustración 4-12:** Gráfica de normalidad en los residuos

**Realizado por:** Luz, Kerly, 2023.

**Tabla 4-6:** Normalidad de los residuos

<b>Jarque Bera Test</b>	
Valor critico: 2	P-value: 0.068

**Fuente:** Base de datos 2014-2016

**Realizado por:** Luz, Kerly, 2023.

Se aplicó la prueba de normalidad de Jarque Bera y se obtiene un valor p de 0.068, el cual es mayor que el nivel de significancia de 0.05. Por lo tanto, se concluye que los residuos del modelo siguen una distribución normal. Esta evidencia estadística respalda la hipótesis nula de que los residuos se distribuyen normalmente.

#### 4.14.2. Prueba de aleatoriedad de los residuos

**Tabla 4-7:** Prueba de aleatoriedad

<b>Ljung-Box Test</b>	
Valor critico: 71.791	P-value: 0.0541

**Fuente:** Base de datos 2014-2016

**Realizado por:** Luz, Kerly, 2023.

Al realizar el test, se obtuvo un valor p de 0.0541, el cual es mayor que el nivel de significancia de 0.05. Esto indica que no hay suficiente evidencia para rechazar la hipótesis nula de aleatoriedad en los residuos. En otras palabras, los residuos del modelo se comportan de manera aleatoria y no muestran patrones sistemáticos o tendencias significativas.

#### 4.15. Pronósticos con el modelo ARIMA


Para realizar los pronósticos, se implementa cuatro pasos fundamentales:

1. **División de la matriz 70-30:** Se procede a dividir la matriz de datos en dos partes, utilizando el 70 % de las filas para probar el modelo y el 30 % restante para realizar los pronósticos.
2. **Pronósticos a corto plazo:** A partir del 70 % de los datos, se realiza pronósticos para los primeros 15 días. Estos pronósticos proporcionan información sobre los eventos más cercanos en el futuro.
3. **Pronósticos para 30 días:** Después de los primeros 15 días, se extiende los pronósticos para los siguientes 30 días, utilizando la información disponible en la matriz de datos.

4. **Pronósticos a mediano plazo:** Como último paso se realiza pronósticos para los siguientes 3 meses, basado en la información histórica y los datos pronosticados previamente.

#### 4.15.1. *Predicciones de velocidad del viento para los próximos 15 días*

La ilustración 4-13, muestra los 15 días de la serie de tiempo de datos originales, mientras que la ilustración 4-14, muestra los primeros 15 días de la segunda serie de tiempo con los datos predichos desde el mes de diciembre del 2015 al mes de enero del 2016.



**Ilustración 4–13:** Serie de tiempo de los datos originales (15 días)

Realizado por: Luz,Kerly, 2023.




**Ilustración 4–14:** Serie de tiempo de los datos predichos (15 días)

Realizado por: Luz,Kerly, 2023.

En la ilustración 4-15 se analizó el comportamiento de la serie de tiempo original y la serie generada por el modelo ARIMA. Durante los primeros 15 días, se puede observar que el modelo ARIMA no

logra capturar de manera precisa el comportamiento de la serie de tiempo original. Sin embargo, a medida que avanzan los días, la serie predicha sigue el mismo patrón general de la serie de tiempo original.



**Ilustración 4–15:** Serie de tiempo de los datos originales y predichos

Realizado por: Luz, Kerly, 2023.

La tabla 4-8, presenta los pronósticos de la velocidad de viento para los próximos 15 días, junto con sus respectivos intervalos de confianza, que permiten estimar la incertidumbre en las predicciones. Estos pronósticos se basaron en el análisis de la serie de tiempo y el modelo ARIMA(1, 1, 3).

**Tabla 4–8:** Pronósticos (15 días)

	Fecha	Datos originales	Predicciones	Intervalo de confianza al 95	
				Li	Ls
1	31/12/2015	10.590583	25.631303	13.452779	37.80983
2	01/01/2016	20.235275	6.841741	-5.336784	19.02027
3	02/01/2016	9.419104	21.076742	8.898218	33.25527
4	03/01/2016	6.849264	8.176759	-4.001765	20.35528

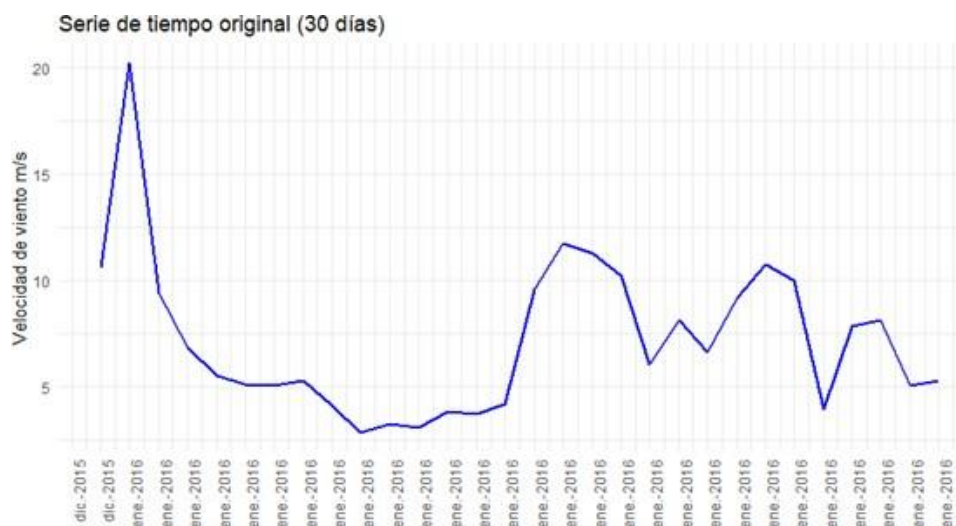
5	04/01/2016	5.508111	6.916051	-5.262474	19.09458
6	05/01/2016	5.113632	7.311208	-4.867316	19.48973
7	06/01/2016	5.041319	6.688942	-5.489583	18.86747
8	07/01/2016	5.282424	6.690883	-5.487641	18.86941
9	08/01/2016	4.129125	6.969681	-5.208844	19.14821
10	09/01/2016	2.854556	5.634031	-6.544494	17.81256
11	10/01/2016	3.258757	4.544644	-7.633881	16.72317
12	11/01/2016	3.116757	5.327883	-6.850642	17.50641
13	12/01/2016	3.856826	5.029405	-7.149119	17.20793
14	13/01/2016	3.729167	5.743506	-6.435019	17.92203
15	14/01/2016	4.187104	5.430929	-6.747595	17.60945

**Fuente:** Base de datos octubre 2014 hasta diciembre 2015.

**Realizado por:** Luz, Kerly, 2023.


#### 4.15.2. Predicciones de velocidad del viento para los próximos 30 días

En la ilustración 4-16, se presentan los primeros 30 días de la serie de tiempo de datos originales, brindando información sobre el comportamiento de la velocidad del viento en esos días. Por otro lado, en la ilustración 4-17, se muestran los primeros 30 días de la segunda serie de tiempo con los datos predichos, lo cual permite observar cómo se proyecta su evolución casi similar a la original.



**Ilustración 4–16:** Serie de tiempo de los datos originales (30 días)


**Realizado por:** Luz, Kerly, 2023.



**Ilustración 4–17:** Serie de tiempo de los datos predichos (30 días)

**Realizado por:** Luz,Kerly, 2023.

La ilustración 4-18 muestra una comparación entre la serie de tiempo original y la serie generada por el modelo ARIMA. En los primeros 30 días del mes de enero del año 2016, se observa que el modelo ARIMA logra capturar parcialmente el comportamiento de la serie de tiempo original. Aunque no es una réplica exacta, la serie predicha sigue en cierta medida el patrón general de la serie de tiempo original a medida que avanzan los días.



**Ilustración 4–18:** Serie de tiempo de los datos originales y predichos

**Realizado por:** Luz,Kerly, 2023.



La tabla 4-9 contiene las proyecciones de la velocidad del viento para los próximos 30 días, junto con sus intervalos de confianza correspondientes, los cuales brindan una estimación de la incertidumbre en las predicciones. Estos pronósticos se obtienen mediante el estudio de la serie temporal y el modelo.

**Tabla 4-9:** Pronósticos (30 días)

	Fecha	Datos originales	Predicciones	Intervalo de confianza al 95	
				Li	Ls
1	31/12/2015	10.590583	25.631303	16.4203455	34.84226
2	01/01/2016	20.235275	6.841741	-2.3692171	16.0527
3	02/01/2016	9.419104	21.076742	11.8657846	30.2877
4	03/01/2016	6.849264	8.176759	-1.0341986	17.38772
5	04/01/2016	5.508111	6.916051	-2.294907	16.12701
6	05/01/2016	5.113632	7.311208	-1.8997492	16.52217
7	06/01/2016	5.041319	6.688942	-2.5220161	15.8999
8	07/01/2016	5.282424	6.690883	-2.5200744	15.90184
9	08/01/2016	4.129125	6.969681	-2.241277	16.18064
10	09/01/2016	2.854556	5.634031	-3.576927	14.84499
11	10/01/2016	3.258757	4.544644	-4.6663142	13.7556
12	11/01/2016	3.116757	5.327883	-3.8830747	14.53884
13	12/01/2016	3.856826	5.029405	-4.1815525	14.24036
14	13/01/2016	3.729167	5.743506	-3.4674522	14.95446
15	14/01/2016	4.187104	5.430929	-3.7800283	14.64189
16	15/01/2016	9.589729167	25.631303	-3.3416357	15.08028
17	16/01/2016	11.73990972	6.841741	2.2542155	20.67613
18	17/01/2016	11.27390972	21.076742	3.0825011	21.50442
19	18/01/2016	10.22040972	8.176759	1.8216979	20.24361
20	19/01/2016	6.031513889	6.916051	1.0062419	19.42816
21	20/01/2016	8.173569444	7.311208	-3.0909263	15.33099
22	21/01/2016	6.662381944	6.688942	0.2178542	18.63977
23	22/01/2016	9.186645833	6.690883	-1.8007177	16.6212
24	23/01/2016	10.73425694	6.969681	0.9460637	19.36798
25	24/01/2016	9.990902778	5.634031	2.1466555	20.56857
26	25/01/2016	3.935243056	4.544644	0.7498443	19.17176
27	26/01/2016	7.834243056	5.327883	-5.3870635	13.03485


28	27/01/2016	8.165354167	5.029405	0.3564226	18.77834
29	28/01/2016	5.075493056	5.743506	-0.1205603	18.30136
30	29/01/2016	5.317256944	5.430929	-3.943737	14.47818

**Fuente:** Base de datos octubre 2014 hasta diciembre 2016.

**Realizado por:** Luz, Kerly, 2023.

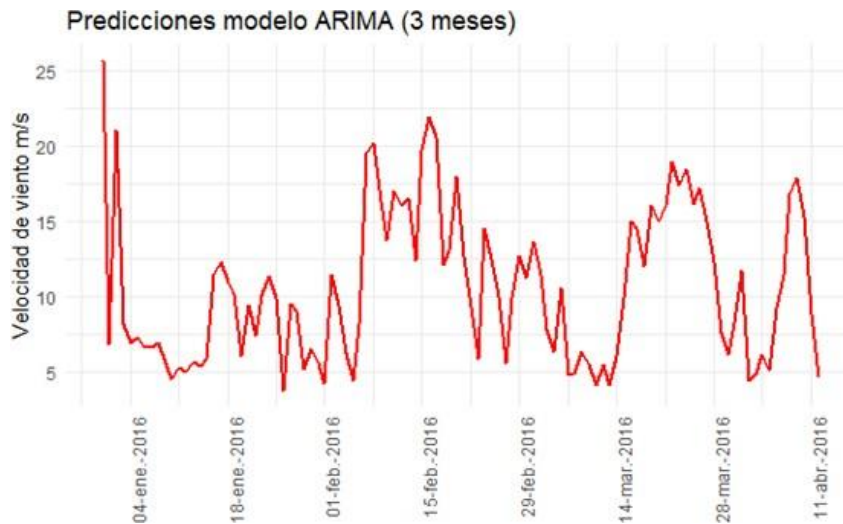
#### 4.15.3. Predicciones de velocidad del viento para los próximos 3 meses

En la ilustración 4-19, se muestran los datos originales de la serie de tiempo durante un periodo de 3 meses del año 2016, proporcionando información sobre su comportamiento. En consecuencia, la ilustración 4-20 muestra los datos pronosticados de la segunda serie de tiempo durante el período de 3 meses, lo que permite observar cómo su evolución se asemeja de manera notable a la serie de tiempo original.



**Ilustración 4-19:** Serie de tiempo de los datos originales (3 meses)

**Realizado por:** Luz, Kerly, 2023.




**Ilustración 4–20:** Serie de tiempo de los datos predichos (3 meses)

**Realizado por:** Luz,Kerly, 2023.

En la ilustración 4-21, se presenta una comparativa entre la serie de tiempo original y la serie generada por el modelo ARIMA. Durante el periodo de 3 meses del año 2016, se puede apreciar que el modelo ARIMA logra capturar parcialmente el comportamiento de la serie de tiempo original. Aunque la serie predicha no replica exactamente, refleja de manera consistente el patrón general de la serie de tiempo original a medida que los meses avanzan.

**Serie de tiempo Original vs. ARIMA (3 Meses)**



**Ilustración 4–21:** Serie de tiempo de los datos originales y predichos

**Realizado por:** Luz,Kerly, 2023.

En la tabla 4-10 se presentan las proyecciones de la velocidad del viento para los próximos 3 meses, acompañadas de sus intervalos de confianza correspondientes, los cuales ayudan a estimar la incertidumbre asociada a las predicciones. Estos pronósticos fueron generados mediante el estudio de la serie temporal utilizando un modelo específico. Los resultados muestran una similitud notoria entre las predicciones y el comportamiento real de la serie, lo que sugiere una buena capacidad del modelo para capturar las tendencias y patrones subyacentes.

**Tabla 4-10: Pronósticos (3 meses)**

	Fecha	Datos originales	Predicciones	Intervalo de confianza al 95	
				Li	Ls
1	31/12/2015	10.590583	25.631303	16.4203455	34.84226
2	01/01/2016	20.235275	6.841741	-2.3692171	16.0527
3	02/01/2016	9.419104	21.076742	11.8657846	30.2877
4	03/01/2016	6.849264	8.176759	-1.0341986	17.38772
5	04/01/2016	5.508111	6.916051	-2.294907	16.12701
6	05/01/2016	5.113632	7.311208	-1.8997492	16.52217
7	06/01/2016	5.041319	6.688942	-2.5220161	15.8999
8	07/01/2016	5.282424	6.690883	-2.5200744	15.90184
9	08/01/2016	4.129125	6.969681	-2.241277	16.18064
10	09/01/2016	2.854556	5.634031	-3.576927	14.84499
11	10/01/2016	3.258757	4.544644	-4.6663142	13.7556
12	11/01/2016	3.116757	5.327883	-3.8830747	14.53884
13	12/01/2016	3.856826	5.029405	-4.1815525	14.24036
14	13/01/2016	3.729167	5.743506	-3.4674522	14.95446
15	14/01/2016	4.187104	5.430929	-3.7800283	14.64189
16	15/01/2016	9.589729167	25.631303	-3.3416357	15.08028
17	16/01/2016	11.73990972	6.841741	2.2542155	20.67613
18	17/01/2016	11.27390972	21.076742	3.0825011	21.50442
...	...	...	...	...	...
...	...	...	...	...	...
97	20/01/2016	8.173569444	7.311208	-3.0909263	15.33099
98	21/01/2016	6.662381944	6.688942	0.2178542	18.63977
99	22/01/2016	9.186645833	6.690883	-1.8007177	16.6212
100	23/01/2016	10.73425694	6.969681	0.9460637	19.36798
101	24/01/2016	9.990902778	5.634031	2.1466555	20.56857

102	25/01/2016	3.935243056	4.544644	0.7498443	19.17176
103	26/01/2016	7.834243056	5.327883	-5.3870635	13.03485
104	27/01/2016	8.165354167	5.029405	0.3564226	18.77834

**Fuente:** Base de datos octubre 2014 hasta diciembre 2016

**Realizado por:** Luz,Kerly, 2023.

#### 4.16. Método Taylor Kriging (TK)

En primera instancia se crea un objeto "data" se establece coordenadas, luego una malla regular para predecir los valores de velocidad del viento. Se especifica el número de puntos de predicción ( $n_{pred}$ ) y se generan secuencias de coordenadas ( $x_{pred}, y_{pred}$ ) dentro de un rango definido.

Por consecuente se define el modelo de variograma, especificando los parámetros como el rango, el sill y el nugget, que determinan la forma y la variabilidad.

Se calcula las predicciones usando Kriging modificado: Se realiza el proceso de Kriging utilizando la función «krige». Se especifica el modelo de velocidad del viento, los datos de entrada y la malla de predicción. El resultado es un objeto «tk» que contiene las predicciones de velocidad del viento en la malla de predicción. A continuación, se muestra el modelo resultante del método TK.

model	psill	range
Nug	0.00000	0
sph	33.73733	5

**Ilustración 4–22:** Modelo del variograma

**Realizado por:** Luz,Kerly, 2023.

```
Object of class spatialPointsDataFrame
Coordinates:
  min max
x -10 10
y -10 10
Is projected: NA
proj4string : [NA]
Number of points: 1600
Data attributes:
  var1.pred      var1.var
Min.   : 2.76    Min.   : 0.2665
1st Qu.: 8.63    1st Qu.: 3.5399
Median :11.11    Median : 4.9735
Mean   :11.28    Mean   : 5.2301
3rd Qu.:13.84    3rd Qu.: 6.4264
Max.   :24.60    Max.   :23.3778
```


**Ilustración 4–23:** Método Taylor Kriging (TK)

**Realizado por:** Luz,Kerly, 2023.

El modelo del variograma es parte esencial del método de Kriging. El modelo de esfera ("Sph") es uno de los modelos de variograma más comunes y se utiliza para describir la estructura de dependencia espacial de los datos.

#### 4.17. Supuestos del modelo

##### 4.17.1. Normalidad de los residuos



**Ilustración 4–24:** Normalidad en los residuos

**Realizado por:** Luz, Kerly, 2023.

**Tabla 4–11:** Beta test

Jarque Bera Test	
Valor crítico: 10.569	P-value: 0.0507


**Fuente:** Base de datos octubre 2014 hasta diciembre 2015.

**Realizado por:** Luz, Kerly, 2023.

Se realiza el test, en lo cual se obtiene un valor p de 0.0507, el cual supera el nivel de significancia establecido de 0.05. En consecuencia, se concluye que los residuos del modelo siguen una distribución normal.

##### 4.17.2. Estacionariedad espacial

El método TK debe cumplir con el supuesto de estacionariedad lo cual se observa que el variograma muestra un comportamiento estable, que indica estacionariedad espacial.




**Ilustración 4–25:** Estacionariedad espacial

Realizado por: Luz,Kerly, 2023.

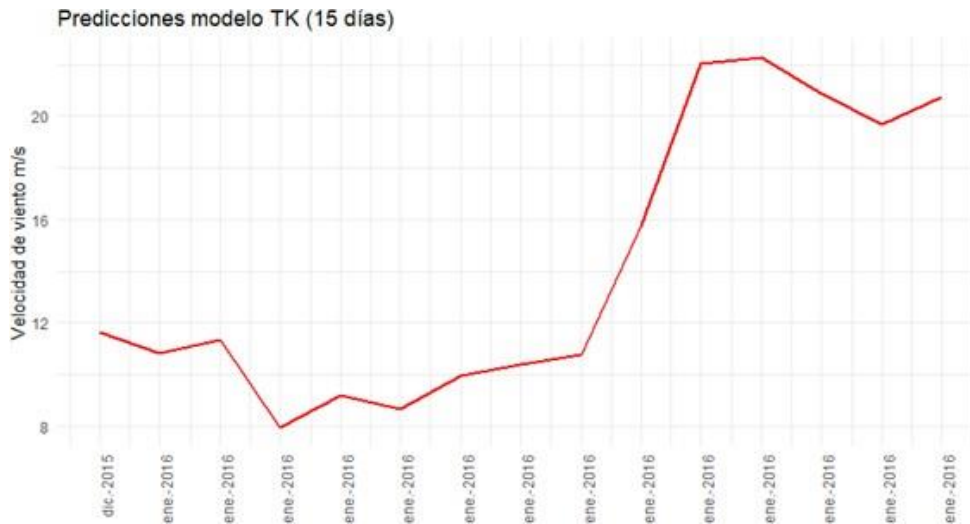
#### 4.17.3. Pronósticos con el Método Taylor Kriging (15 días)

La ilustración 4-26 exhibe los primeros 15 días de la serie de tiempo de datos originales, brindando información sobre su comportamiento. Por otro lado, en la ilustración 4-27 se presenta también los primeros 15 días de acuerdo a los datos predichos utilizando el método TK.



**Ilustración 4–26:** Serie de tiempo de los datos originales (15 días)

Realizado por: Luz,Kerly, 2023.



**Ilustración 4–27:** Serie de tiempo de los datos método TK (15 días)

**Realizado por:** Luz,Kerly, 2023.

En la ilustración 4-28, se pudo apreciar que el método TK no logra una buena aproximación con los datos originales. Existe una marcada discrepancia entre las predicciones realizadas mediante este método y el comportamiento real de la serie de tiempo en los primeros 15 días.



**Ilustración 4–28:** Serie de tiempo de los datos originales y predichos

**Realizado por:** Luz,Kerly, 2023.



Se presenta los pronósticos de la velocidad del viento para los próximos 15 días, acompañados de sus respectivos intervalos de confianza. Sin embargo, es importante destacar que los intervalos de confianza están notablemente amplios, lo que sugiere que existe una considerable incertidumbre en las predicciones realizadas con el modelo de TK.

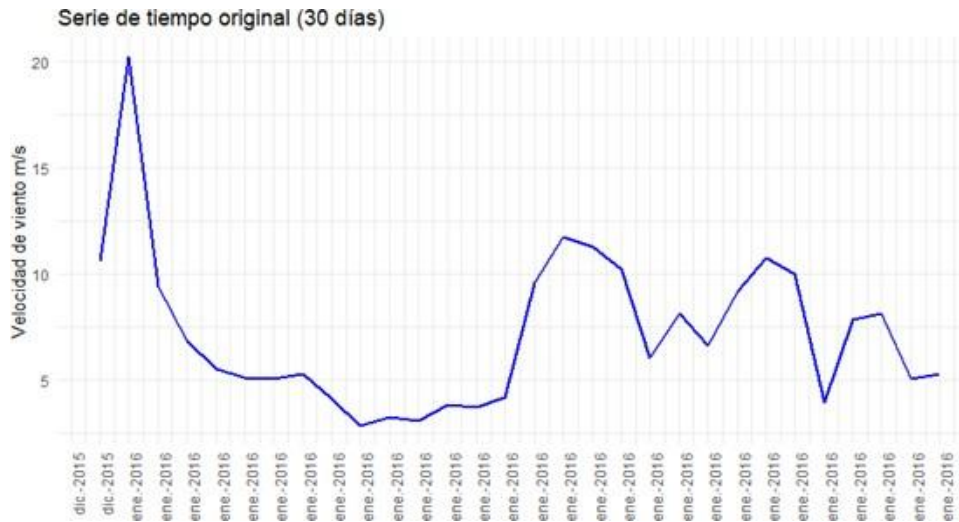
**Tabla 4–12:** Pronósticos (15 días)

	Fecha	Pronósticos (15 días)	Predicciones	Intervalo de confianza al 95	
				Li	Ls
1	31/12/2015	10.590583	11.662039	-4.6954733	28.01955
2	01/01/2016	20.235275	10.809562	-5.5479502	27.16707
3	02/01/2016	9.419104	11.354194	-5.0033177	27.71171
4	03/01/2016	6.849264	7.950418	-8.4070941	24.30793
5	04/01/2016	5.508111	9.203357	-7.1541553	25.56087
6	05/01/2016	5.113632	8.648608	-7.7089037	25.00612
7	06/01/2016	5.041319	9.972819	-6.3846931	26.33033
8	07/01/2016	5.282424	10.401941	-5.955571	26.75945
9	08/01/2016	4.129125	10.771802	-5.5857096	27.12931
10	09/01/2016	2.854556	15.747713	-0.6097985	32.10523
11	10/01/2016	3.258757	22.006701	5.6491893	38.36421
12	11/01/2016	3.116757	22.265401	5.9078894	38.62291
13	12/01/2016	3.856826	20.86953	4.512018	37.22704
14	13/01/2016	3.729167	19.691644	3.3341319	36.04916
15	14/01/2016	4.187104	20.717966	4.3604541	37.07548

**Fuente:** Base de datos octubre 2014 hasta diciembre 2015.

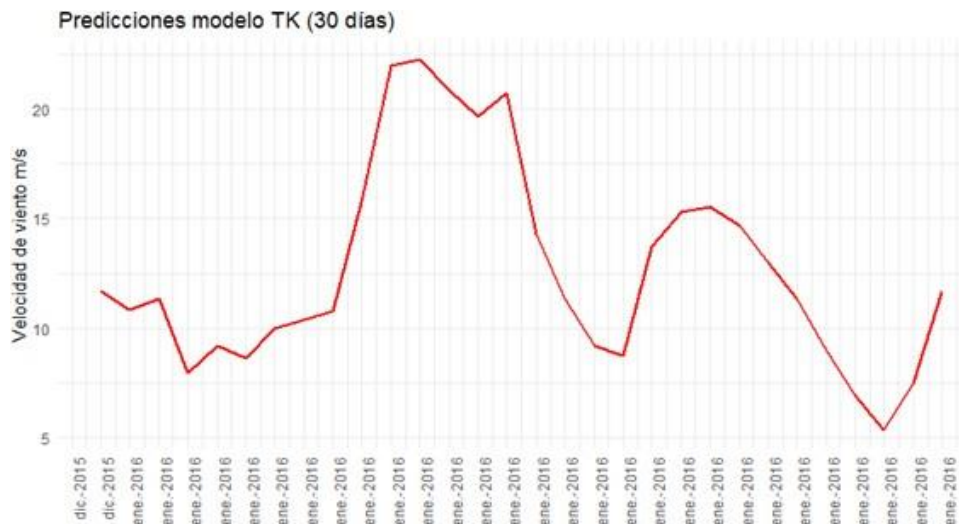
**Realizado por:** Luz, Kerly, 2023.

La primera ilustración muestra la serie original de 30 días, brindando una representación visual del comportamiento real de los datos. Mientras, la segunda ilustración presenta las estimaciones de 30 días generados mediante el método de TK.



**Ilustración 4–29:** Serie de tiempo de los datos originales (30 días)

**Realizado por:** Luz, Kerly, 2023.

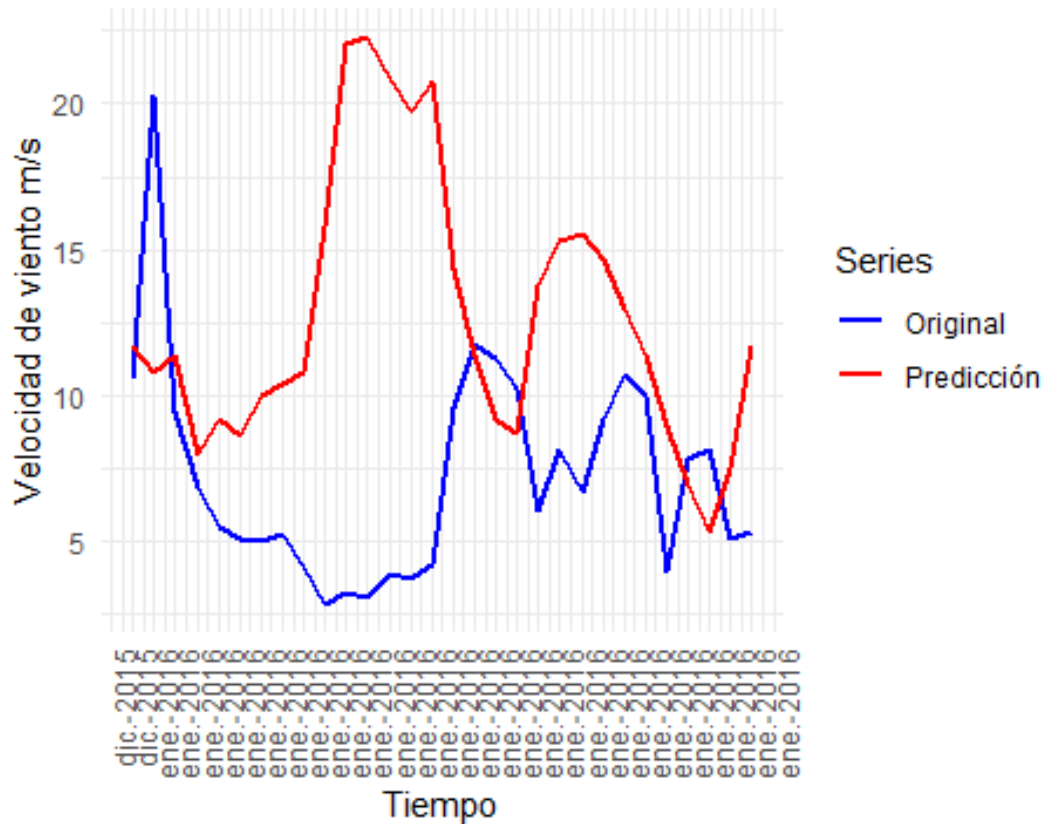


**Ilustración 4–30:** Serie de tiempo de los datos, método TK (30 días)

**Realizado por:** Luz, Kerly, 2023.

Al comparar visualmente ambas ilustraciones, se evidencia que las estimaciones del método TK no se aproximan de manera precisa o semejante a los datos reales de la serie de tiempo original.

**Serie de tiempo Original vs. TK (30 días)**



**Ilustración 4–31:** Serie de tiempo de los datos originaesl y predichos

**Realizado por:** Luz, Kerly, 2023.

En la tabla 4-13, se logra apreciar que los intervalos son considerablemente amplios, lo que indica una alta incertidumbre en las predicciones. Esta situación puede deberse a diversas razones, como la complejidad de los datos o la limitación del modelo TK para capturar adecuadamente las variaciones y tendencias presentes en la serie de tiempo.

**Tabla 4–13:** Pronósticos (30 días)

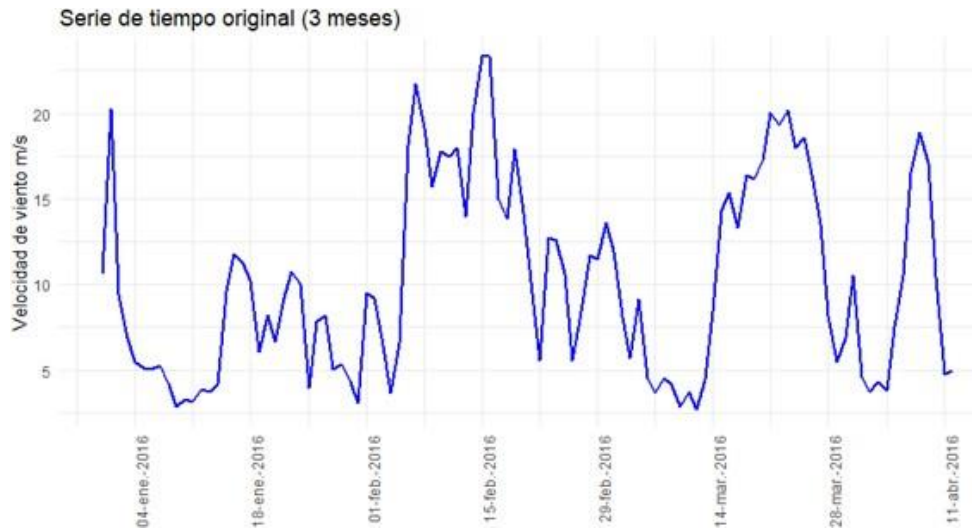
	Fecha	Datos originales	Predicciones	Intervalo de confianza al 95	
				Li	Ls
1	31/12/2015	10.590583	11.662039	-1.8280531	25.15213
2	01/01/2016	20.235275	10.809562	-2.68053	24.29965
3	02/01/2016	9.419104	11.354194	1-2.1358975	24.84429
4	03/01/2016	6.849264	7.950418	-5.5396739	21.44051
5	04/01/2016	5.508111	9.203357	-4.2867351	22.69345
6	05/01/2016	5.113632	8.648608	-4.8414835	22.1387
7	06/01/2016	5.041319	9.972819	-3.5172729	23.46291

8	07/01/2016	5.282424	10.401941	-3.0881508	23.89203
9	08/01/2016	4.129125	10.771802	-2.7182894	24.26189
10	09/01/2016	2.854556	15.747713	2.2576217	29.23781
11	10/01/2016	3.258757	22.006701	8.5166095	35.49679
12	11/01/2016	3.116757	22.265401	8.7753096	35.75549
13	12/01/2016	3.856826	20.86953	7.3794382	34.35962
14	13/01/2016	3.729167	19.691644	6.2015521	33.18174
15	14/01/2016	4.187104	20.717966	7.2278743	34.20806
16	15/01/2016	9.589729167	14.297111	0.8070197	27.7872
17	16/01/2016	11.73990972	11.325649	-2.1644427	24.81574
18	17/01/2016	11.27390972	9.160413	-4.3296787	22.6505
19	18/01/2016	10.22040972	8.708103	-4.7819882	22.1982
20	19/01/2016	6.031513889	13.732903	0.2428118	27.223
21	20/01/2016	8.173569444	15.326084	1.8359919	28.81618
22	21/01/2016	6.662381944	15.553615	2.063523	29.04371
23	22/01/2016	9.186645833	14.670333	-1.1802411	28.16042
24	23/01/2016	10.73425694	12.980512	-0.5095793	26.4706
25	24/01/2016	9.990902778	11.345969	-2.144123	24.83606
26	25/01/2016	3.935243056	8.970086	-4.5200057	22.46018
27	26/01/2016	7.834243056	6.930652	-6.5594401	20.42074
28	27/01/2016	8.165354167	5.337111	-8.1529807	18.8272
29	28/01/2016	5.075493056	7.469785	-6.0203063	20.95988
30	29/01/2016	5.317256944	11.681141	-1.808951	25.17123

**Fuente:** Base de datos octubre 2014 hasta diciembre 2015.


**Realizado por:** Luz, Kerly, 2023.

Consecuentemente, se presentan las siguientes dos ilustraciones: la primera muestra la gráfica original de 3 meses, representando el comportamiento real de los datos durante ese periodo. Mientras tanto, la segunda ilustración exhibe la gráfica generada con el método TK para el mismo periodo de 3 meses.



**Ilustración 4–32:** Serie de tiempo de los datos originales (3 meses)


Realizado por: Luz,Kerly, 2023.



**Ilustración 4–33:** Serie de tiempo de los datos, método TK (3 meses)

Realizado por: Luz,Kerly, 2023.

Es evidente que el método TK no se ajusta adecuadamente a la gráfica de la serie de tiempo original. La discrepancia entre las predicciones generadas por el método TK y los datos reales es claramente visible. Esto sugiere que el método TK no es el más adecuado para capturar con precisión las tendencias y patrones presentes en la serie de tiempo.



**Ilustración 4–34:** Serie de tiempo de los datos originales y predichos

**Realizado por:** Luz, Kerly, 2023.

La tabla 4-14, que muestra los intervalos de confianza de los pronósticos obtenidos mediante el método TK. Es importante destacar que los intervalos de confianza son notoriamente amplios, lo que refleja una alta incertidumbre en las predicciones. Esta situación puede tener implicaciones significativas, ya que los intervalos amplios indican una falta de precisión en las estimaciones y limitan la capacidad de confiar plenamente en las predicciones obtenidas.

**Tabla 4–14:** Pronósticos (3 meses)

	Fecha	Datos originales	Predicciones	Intervalo de confianza al 95	
				Li	Ls
1	31/12/2015	10.590583	11.662039	-1.79323465	25.11731
2	01/01/2016	20.235275	10.809562	-2.64571159	24.26483
3	02/01/2016	9.419104	11.354194	-2.10107904	24.80947
4	03/01/2016	6.849264	7.950418	-5.50485548	21.40569
5	04/01/2016	5.508111	9.203357	-4.25191665	22.65863
6	05/01/2016	5.113632	8.648608	-4.80666502	22.10388
7	06/01/2016	5.041319	9.972819	-3.48245444	23.42809
8	07/01/2016	5.282424	10.401941	-3.05333232	23.85721
9	08/01/2016	4.129125	10.771802	-2.68347097	24.22708

10	09/01/2016	2.854556	15.747713	2.29244012	29.20299
11	10/01/2016	3.258757	22.006701	8.55142798	35.46197
12	11/01/2016	3.116757	22.265401	8.81012805	35.72067
13	12/01/2016	3.856826	20.86953	7.41425668	34.3248
14	13/01/2016	3.729167	19.691644	6.23637055	33.14692
15	14/01/2016	4.187104	20.717966	7.26269271	34.17324
16	15/01/2016	9.589729167	14.297111	0.84183808	27.75238
17	16/01/2016	11.73990972	11.325649	-2.1296243	24.78092
18	17/01/2016	11.27390972	9.160413	-4.2948603	222.61569
...	...	...	...	...	...
...	...	...	...	...	...
97	05/04/2016	7.551847222	8.748763	-4.70651056	22.20404
98	06/04/2016	10.53973611	6.688942	-2.68239237	24.22815
99	07/04/2016	16.51504167	9.440298	-4.0149753	22.89557
100	08/04/2016	18.90809722	6.646561	-6.80871245	20.10183
101	09/04/2016	17.1459375	6.016116	-7.43915717	19.47139
102	10/04/2016	10.47342361	14.862758	1.40748511	28.31803
103	11/04/2016	4.749826389	10.592267	-2.86300644	24.04754
104	12/04/2016	4.959280702	7.076322	-6.37895153	20.53159

**Fuente:** Base de datos octubre 2014 hasta diciembre 2016

**Realizado por:** Luz, Kerly, 2023.

#### 4.17.4. Comparación de los dos métodos basado en el Error absoluto medio (MAE) y el Error cuadrático medio (RMSE).

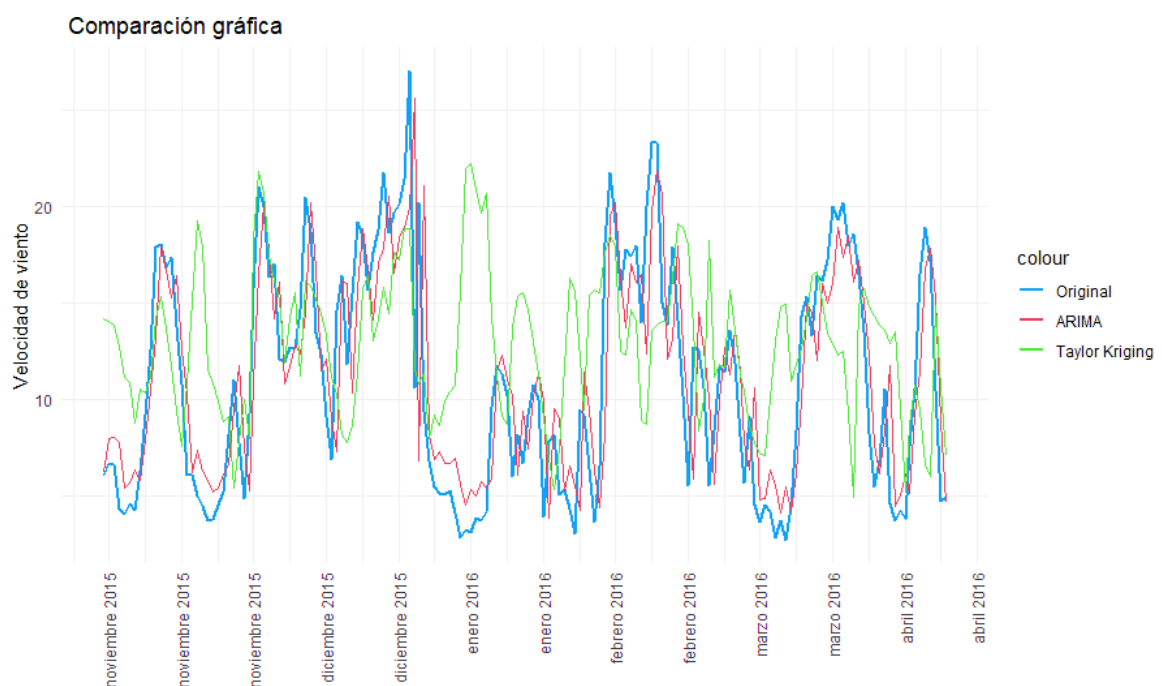
**Tabla 4–15: MAE Y RMSE**

Tiempo	ARIMA (1, 1, 3)		Taylor Kriging	
	MAE	RMSE	MAE	RMSE
15 días	4.108585	6.240188	9.183541	11.30677
30 días	3.189486	4.847474	6.561852	8.667188
3 meses	2.794736	3.784533	5.575528	6.694189

**Fuente:** Base de datos octubre 2014 hasta diciembre 2015.

**Realizado por:** Luz, Kerly, 2023.

Según las métricas Error absoluto medio (MAE) y el Error cuadrático medio (RMSE) nos dicen que cuanto más cercanos a cero sean estos valores, mejor será el rendimiento del modelo. Observamos que para los 15 y 30 días el modelo ARIMA (1, 1, 3) es más bajo que el modelo Taylor Kriging. También para los 3 meses el modelo ARIMA (1, 1, 3) presenta un MAE de 2.277787 y un RMSE de 3.023229. Las métricas indican que, en promedio, las predicciones de este modelo tienen un error absoluto de aproximadamente 2.27 y un error cuadrático medio de alrededor de 3.02. Por otro lado, el modelo Taylor Kriging en los 3 meses tiene un MAE de 5.575528 y un RMSE de 6.694189. Estas métricas revelan que las estimaciones del modelo Taylor Kriging presentan un promedio de error absoluto de aproximadamente 5.58 y un error cuadrático medio de alrededor de 6.7. Con respecto a estas métricas, se concluye que el modelo ARIMA (1, 1, 3) es el mejor en términos de precisión de las predicciones, ya que presenta un menor MAE y RMSE en comparación con el modelo Taylor Kriging.



**Ilustración 4–35:** Resultados de la comparación del método ARIMA y Taylor Kriging

**Realizado por:** Luz, Kerly, 2023.

En base a los resultados, se observa que el modelo ARIMA se ajusta mejor a la gráfica de los datos originales en comparación con el otro modelo (Taylor Kriging).

La gráfica del modelo ARIMA presenta una línea que se aproxima a los puntos de los datos originales, indicando una coincidencia más cercana entre las predicciones del modelo y los valores reales en este caso los datos originales. Esto sugiere que el modelo ARIMA captura mejor los patrones y la variabilidad de los datos originales.



Por otro lado, en la gráfica del modelo Taylor Kriging, se observa una mayor discrepancia entre las predicciones y los datos reales. Estas discrepancias se pueden deber a una menor capacidad del modelo para capturar la variabilidad y las características específicas de los datos. En resumen, la gráfica del modelo ARIMA muestra un ajuste más cercano y una mejor concordancia con los datos originales, lo que sugiere que este modelo es más adecuado para describir y predecir el comportamiento de la variable de interés que es la velocidad de viento en comparación con el otro modelo.

## CONCLUSIONES

- Al desarrollar un análisis exploratorio de los datos se logró identificar que no existen datos atípicos, pero si 26 datos faltantes a los cuales se aplicó un método de relleno de datos teniendo así una base de datos óptima para la estimación.
- Mediante la aplicación del método ARIMA se toma el mejor modelo según el criterio de AIC Y BIC, donde se realiza las predicciones con el modelo (1, 1, 3) mediante el cual se puede corroborar que el método ARIMA es el que más se ajusta al realizar predicciones de 15 días, 30 días y 3 meses de la variable velocidad del viento.
- Al realizar las predicciones con el método Tylor Kriging dio como resultado que las predicciones realizadas a los 15 días, 30 días y 3 meses no se ajusta adecuadamente a la gráfica de la serie de tiempo original
- Al comparar el rendimiento de los métodos ARIMA y TK con las medidas del error absoluto medio (MAE) y el error cuadrático medio (RMSE), dando como resultado en el modelo ARIMA un MAE de 26.42 % y un RMSE de 30.23 %. Cuanto más cercanos a cero sean estos valores, mejor será el rendimiento del modelo. Por otro lado, el modelo Taylor Kriging tuvo un MAE de 50.09 % y un RMSE de 60.143 %, se finiquita que el mejor método para realizar las predicciones de velocidad del viento es ARIMA (1, 1, 3).

## **RECOMENDACIONES**

- Se recomienda la limpieza y depuración de los datos para de esta manera evitar inconvenientes a futuro.
- Se debe realizar el test de normalidad antes de trabajar con lo datos en estudio para verificar que los datos se ajusten a una distribución normal.
- Cuando se trabaja con variables ambientales no se puede predecir a más de 1 año.

## BIBLIOGRAFÍA

**CAPEL, José y MUÑOZ, Manuel.** *El regimen del vientos y la presión.*Almeria-Valencia,2004, pp. 69-90.

**GERRERO, Marco y MEDINA, Sonny.** "Modelos de series de tiempo aplicados a los expedientes de la Comision de Derechos Humanos del Distrito Federal",*Economía Informa*,Mexico, 2016, pp. 89-90.

**HERRERA, Cristina.** *Estudio de la velocidad del viento.España.*GCA:España,2015,pp. 45-46.

**MAURICIO, Jose Alberto.** *Analisis de Series de Temporales.*DF-Mexico, 2007,pp.56-57.

**MUR, Joaquin.**"Energia Eolica". *Departamento de Ingenieria de la Universidad de Zaragoza*,2016,España pp. 4-5.

**SÁNCHEZ, Camila, y otros.** Corrección por exposición de las velocidades de viento medidas en dos estaciones de Cuba. Cuba : Universidad del Norte, 2021.

**SANTOS, Diana.** *Caracterización de la velocidad y dirección de viento en la provincia de Chimborazo.*Nº1.1.Ecuador-Riobamba,2020 . ISSN: 2600-5859,pp. 389-407.

**VELAZQUEZ, Alberto.***Método Kriging de inferencia espacial.* Mexico : CentroGeo, 2019,pp.45-46.





## ANEXOS

	A	B		A	B
1	Por día	Fecha			
2	6,135360518	17/10/2014		4,187	14/1/2016
3	5,67	18/10/2014		9,590	15/1/2016
4	4,897869911	19/10/2014		11,740	16/1/2016
5	4,120062283	20/10/2014		11,274	17/1/2016
6	6,643110971	21/10/2014		10,220	18/1/2016
7	8,93550888	22/10/2014		6,032	19/1/2016
8	7,166368603	23/10/2014		8,174	20/1/2016
9	4,158180566	24/10/2014		6,662	21/1/2016
0	5,753025701	25/10/2014		9,187	22/1/2016
1	4,4276705	26/10/2014		10,734	23/1/2016
2	7,633717263	27/10/2014		9,991	24/1/2016
3	5,119632691	28/10/2014		3,935	25/1/2016
4	3,002731923	29/10/2014		7,834	26/1/2016
5	4,876972696	30/10/2014		8,165	27/1/2016
6	3,988534428	31/10/2014		5,075	28/1/2016
7	5,627529756	1/11/2014		5,317	29/1/2016
8	7,310071296	2/11/2014		4,345	30/1/2016
9	7,127577795	3/11/2014		3,064	31/1/2016
0	2,887436113	4/11/2014		9,488	1/2/2016
1	2,849205903	5/11/2014		9,177	2/2/2016
2	4,738194118	6/11/2014		6,442	3/2/2016
3	5,126563254	7/11/2014		3,675	4/2/2016
4	5,82427809	8/11/2014		6,591	5/2/2016
5	5,462393708	9/11/2014		18,105	6/2/2016
6	4,702197106	10/11/2014		21,750	7/2/2016
7	3,204758887	11/11/2014		19,174	8/2/2016
8	5,590965867	12/11/2014		15,713	9/2/2016
9	6,919600309	13/11/2014		17,805	10/2/2016
0	6,695406345	14/11/2014		17,48124306	11/2/2016
1	3,506183751	15/11/2014		17,96750694	12/2/2016
2	7,799789717	16/11/2014		13,98960417	13/2/2016
3	8,103780065	17/11/2014		20,03394444	14/2/2016
4	4,244023166	18/11/2014		23,3210625	15/2/2016
5	4,216941421	19/11/2014		23,31036806	16/2/2016
6	2,516933568	20/11/2014		15,00511111	17/2/2016
7	3,417299583	21/11/2014		13,85172917	18/2/2016
8	3,417299583	22/11/2014		17,89922917	19/2/2016
9	8,609584389	23/11/2014		14,16403472	20/2/2016
0	11,99444478	24/11/2014		10,19824306	21/2/2016
1	7,774439748	25/11/2014		5,549	22/2/2016
2	2,959732457	26/11/2014		12,72076389	23/2/2016
3	7,215263314	27/11/2014		12,56019444	24/2/2016
4	10,69154257	28/11/2014		10,62469444	25/2/2016
5	13,98833731	29/11/2014		5,516701389	26/2/2016
6	17,06593887	30/11/2014		8,418395833	27/2/2016
7	13,89847468	1/12/2014		11,68029167	28/2/2016
8	15,49147368	2/12/2014		11,45278472	29/2/2016
9	13,41946822	3/12/2014		13,59403472	1/3/2016
0	8,838457232	4/12/2014		11,89077778	2/3/2016
1	6,894485164	5/12/2014		8,132618056	3/3/2016
2	4,143472103	6/12/2014		5,7059375	4/3/2016
3	3,252643638	7/12/2014		9,109645833	5/3/2016
4	3,857415085	8/12/2014		4,508875	6/3/2016
5	3,226270283	9/12/2014		3,674215278	7/3/2016



**ESCUELA SUPERIOR POLITÉCNICA DE CHIMBORAZO**  
**CERTIFICADO DE CUMPLIMIENTO DE LA GUÍA PARA**  
**NORMALIZACIÓN DE TRABAJOS DE FIN DE GRADO**

**Fecha de entrega:** 12/06/2024

<b>INFORMACIÓN DEL AUTOR/A(S)</b>
<b>Nombres – Apellidos:</b> Kerly Natasha Lema Remache Luz Angelica Catucuamba Mendoza
<b>INFORMACIÓN INSTITUCIONAL</b>
<b>Facultad:</b> Ciencias
<b>Carrera:</b> Estadística
<b>Título a optar:</b> Ingeniera Estadística
 Ing. Paulina Fernanda Bolaños Logroño, Mgs. <b>Director del Trabajo de Titulación</b>  Ing. Johanna Enith Aguilar Reyes, Mgs. <b>Asesor del Trabajo de Titulación</b>