

**UNIVERSIDAD NACIONAL MAYOR DE SAN MARCOS**

**FACULTA DE CIENCIAS MATEMÁTICAS**

**E. A. P. DE ESTADÍSTICAS**

**“PRONÓSTICOS Y COMPARACIÓN DE UNA  
SERIE DE TIEMPO CON CAMBIOS  
ESTRUCTURALES MEDIANTE LA RED  
NEURONAL ARTIFICIAL DE  
RETROPROPAGACIÓN RESILIENTE Y  
MODELOS NO LINEALES”**

**TESIS**

Para optar el Título Profesional de Licenciado en Estadística

**AUTOR**

José Antonio Cárdenas Garro

**ASESOR**

Erwin Kraenau Espinal

**Lima – Perú**

**2015**

**PRONÓSTICOS Y COMPARACIÓN DE UNA SERIE DE TIEMPO  
CON CAMBIOS ESTRUCTURALES MEDIANTE LA RED  
NEURONAL ARTIFICIAL DE RETROPROPAGACIÓN RESILIENTE  
Y MODELOS NO LINEALES**

**Br. José Antonio Cárdenas Garro**

Tesis presentada a consideración del Cuerpo Docente de la Facultad de Ciencias Matemáticas de la Universidad Nacional Mayor de San Marcos, como parte de los requisitos para obtener el Título Profesional de Licenciado en Estadística.

Aprobada por:

Mg. Ana María Cárdenas Rojas .....  
(Presidente)

Lic. Fátima Medina Merino .....  
(Miembro – Jurado)

Dr. Erwin Kraenau Espinal .....  
(Miembro – Jurado)

Lima – Perú  
Junio 2015

Tesis de Licenciatura

PRONÓSTICOS Y COMPARACIÓN DE UNA  
SERIE DE TIEMPO CON CAMBIOS  
ESTRUCTURALES MEDIANTE LA RED  
NEURONAL ARTIFICIAL DE  
RETROPROPAGACIÓN RESILIENTE Y  
MODELOS NO LINEALES

Br. José Antonio Cárdenas Garro

Escuela Profesional de Estadística

Tesis de Licenciatura presentada como requisito parcial para optar el Título  
Profesional de Estadística en la Facultad de Ciencias Matemáticas

Universidad Nacional Mayor de San Marcos  
Facultad de Ciencias Matemáticas  
Escuela Profesional de Estadística  
Tesis de Licenciatura  
Lima, 2015

## **AGRADECIMIENTOS**

Por la Vida

A Dios y a mis Padres

Por el esfuerzo realizado, por su paciencia y apoyo constante:

Mi Madre y Abuelita

Por creer en mí y alentarme siempre a seguir adelante:

Dr. Erwin Kraenau Espinal

A la profesoras Estela Ponce y Fátima Medina por ser como una Madre hacia mi persona y cada una de aquellas personas que me apoyaron, colaboraron y contribuyeron para hacer posible la realización de este trabajo.



# INDICE

<i>RESUMEN</i>	8
<i>ABSTRACT</i>	9
<b>I. PLANTEAMIENTO DE LA INVESTIGACIÓN</b>	<b>12</b>
1.1. IDENTIFICACIÓN DEL PROBLEMA	13
1.2. FORMULACIÓN DEL PROBLEMA	15
1.3. OBJETIVOS DE LA INVESTIGACIÓN	17
1.4. JUSTIFICACIÓN	18
<b>II. MARCO TEÓRICO</b>	<b>20</b>
2.1. ANTECEDENTES A NIVEL NACIONAL	20
2.2. ANTECEDENTES A NIVEL INTERNACIONAL	20
2.3. METODOLOGÍA PARA EL MODELAMIENTO DE SERIES TEMPORALES	22
2.3.1. IDENTIFICACIÓN DEL MODELO	23
2.3.2. ESTIMACIÓN DE LOS PARÁMETROS DEL MODELO	24
2.3.3. DIAGNÓSTICO DEL MODELO	25
2.3.4. METADIAGNÓSTICO	26
2.3.5. USO DEL MODELO	26
2.4. REDES NEURONALES ARTIFICIALES	26
2.4.1. ESTRUCTURA DE UNA RED NEURONAL ARTIFICIAL	28
2.4.2. ENTRENAMIENTO DE LA RED	29
2.4.3. APRENDIZAJE EN LAS REDES NEURONALES ARTIFICIALES	29
<i>Tipos de aprendizaje:</i>	<b>29</b>
2.4.3.1. SUPERVISADO	29
2.4.3.2. NO SUPERVISADO	30
2.4.3.3. CON FORTALECIMIENTO	30
2.4.4. LA FUNCIÓN DE ACTIVACIÓN	33
2.4.5. REDES CON APRENDIZAJE SUPERVISADO	35
2.4.6. REDES CON APRENDIZAJE NO SUPERVISADO	35
2.4.6.1. REGLA DE HEBB	35
2.4.7. RED NEURONAL ARTIFICIAL DE RETROPROPAGACIÓN	37
<b>III. METODOLOGÍA</b>	<b>39</b>
3.1. TIPO Y DISEÑO DE LA INVESTIGACIÓN	39
3.1.1. COBERTURA	40
3.1.2. UNIVERSO	40

<b>3.2.</b>	<b>TÉCNICAS E INSTRUMENTOS DE RECOLECCIÓN DE DATOS.</b>	<b>40</b>
3.2.1.	INSTRUMENTO DE RECOLECCIÓN DE DATOS	40
<b>3.3.</b>	<b>PROCEDIMIENTOS DE RECOLECCIÓN DE DATOS</b>	<b>43</b>
<b>3.4.</b>	<b>METODOLOGÍA ESTADÍSTICA</b>	<b>44</b>
3.4.1.	METODOLOGÍA PARA EL MODELAMIENTO DE SERIES TEMPORALES NO LINEALES	44
3.4.2.	RED NEURONAL ARTIFICIAL DE RETROPROPAGACIÓN RESILIENTE	45
3.4.3.	CAMBIOS ESTRUCTURALES	49
3.4.4.	MODELOS NO LINEALES	51
3.4.5.	MODELOS ARCH	54
3.4.6.	MODELOS GARCH	57
3.4.7.	MODELOS TGARCH	58
<b>IV.</b>	<b>APLICACIÓN</b>	<b>61</b>
<b>V.</b>	<b>DISCUSIÓN DE LOS RESULTADOS</b>	<b>92</b>
<b>VI.</b>	<b>CONCLUSIONES</b>	<b>95</b>
<b>VII.</b>	<b>RECOMENDACIONES</b>	<b>98</b>
<b>VIII.</b>	<b>REFERENCIAS BIBLIOGRÁFICAS</b>	<b>100</b>
<b>IX.</b>	<b>ANEXOS</b>	<b>104</b>

## RESUMEN

En esta investigación se propone una metodológica alternativa a la metodología de Box y Jenkins, donde se podrá evidenciar el modelamiento de series temporales no lineales, mediante el enfoque paramétrico y el enfoque No paramétrico.

En el enfoque paramétrico me inclinaré por la extensión de los métodos de Box y Jenkins, es decir, los modelos ARCH, GARCH, TGARCH entre otros, para el modelado de series temporales no lineales, en la cual obtendré los pronósticos del año 2012 para la serie temporal:

- Número de peruanos retornantes según año de regreso mediante medio de transporte aéreo.

En el enfoque No paramétrico presentaré el método de la red neural de retropropagación resiliente para el modelado de series temporales no lineales, en la cual obtendré los pronósticos del año 2012 para la serie temporal:

- Número de peruanos retornantes según año de regreso mediante medio de transporte aéreo.

La serie de tiempo estudiada para esta investigación presenta un cambio estructural durante los años del 2000-2003, lo que induce a la no linealidad de la serie.

La estimación de los dos enfoques serán comparados y se elegirá el enfoque que otorgue mejores pronósticos, la cual escogeré mediante indicadores de validación como por ejemplo el MAD (Desviación Media Residual) y SSE (Suma de los Cuadrados de los Residuos).

**Palabras claves:** Cambios Estructurales, Series Temporales No Lineales, Red Neuronal de Retropropagación Resiliente



## **ABSTRACT**

In this research an alternative to Box and Jenkins methodology, where you can demonstrate the modeling of nonlinear time series, using parametric and nonparametric approach is proposed methodological approach.

In the parametric approach, we prefer the extension of the methods of Box and Jenkins, ie ARCH, GARCH, TGARCH models among others, for modeling nonlinear time series, in which we obtain forecasts for 2012 for the series time:

- Number of returnees back Peruvians by year by means of air transport.

In the parametric approach not present the method of the Resilient Backpropagation Neural Network for modeling nonlinear time series, in which we obtain forecasts of 2012 to the time series:

- Number of returnees back Peruvians by year by means of air transport.

The time series studied for this research presents a structural change during the years of 2000-2003, which leads to the nonlinearity of the series.

The estimation of the two approaches will be compared and approach that gives better predictions will be chosen , which will choose validation using indicators such as MAD (mean deviation residual) and SSE ( sum of the squares of the waste )

**Keys words:** Structural Changes, Nonlinear Time Series, Resilient Backpropagation Neural Network



# **CAPÍTULO 1**

## **PLANTEAMIENTO DE LA INVESTIGACIÓN**

## I. PLANTEAMIENTO DE LA INVESTIGACIÓN

El modelamiento de series temporales ha sido un área de creciente interés para muchas disciplinas y en el que muchos esfuerzos se han dedicado para el desarrollo de nuevos métodos y técnicas. Su objetivo es proveer al modelador de la representación matemática de una serie temporal, que permita capturar total o parcialmente, las características más relevantes del fenómeno real, a partir de la información contenida en los datos. Si bien, en la literatura se han propuesto diversos modelos orientados a la representación de series temporales, su utilidad depende del grado de similitud entre la dinámica del proceso generador de la serie y la formulación matemática del modelo con que se represente.

En este trabajo se presentará un método alternativo al pronóstico de series de tiempo, donde en la mayoría de casos reales éstas presentan irregularidades en las cuales no se puede utilizar los métodos tradicionales para predicción como los Métodos de Box y Jenkins, en tal sentido se presentará los fundamentos teóricos del método de Redes Neuronales Artificiales (RNA) de Retropropagación Resiliente y los modelos no lineales, que será aplicado a la serie de tiempo:

- Número de peruanos retornantes según año de regreso mediante medio de transporte aéreo.

La cual presenta cambios estructurales que fueron causados por valores atípicos (outliers) o quizá por su naturaleza de la variable.

A la serie de tiempo se le procederá a obtener sus pronósticos mediante los métodos de Red Neuronal Artificial de Retropropagación Resiliente y los Modelos No Lineales aplicados a la series de tiempo, los pronósticos de los dos métodos serán comparados y se elegirá el método que otorgue mejores **estimaciones** y **pronósticos**.

## 1.1. IDENTIFICACIÓN DEL PROBLEMA

Es comúnmente aceptado que muchas series de tiempo presentan comportamientos dinámicos no lineales, cuya complejidad hacen que sea imposible formular un modelo econométrico basado en leyes físicas o económicas que representen su evolución adecuadamente. El problema de la formulación del modelo se ve agravado por la presencia de observaciones atípicas y cambios estructurales, para las cuales no existen modelos matemáticos que permitan su representación en el caso no lineal.

Una de las características que distingue a las series temporales de otros tipos de datos estadísticos es el hecho de que, en general, los valores de la serie en diferentes instantes del tiempo están correlacionados. De esta manera, el problema básico en el análisis de las series temporales es el estudio del patrón de correlación de los valores de la serie y la elaboración de un modelo estadístico que explique su estructura.

La metodología para el análisis de las series temporales “Metodología Box y Jenkins” (1970) permite la identificación y estimación de los modelos ARMA (Autoregresivo y de Media Móvil). Estos modelos asumen las siguientes hipótesis:

$H_0$ : La serie es estacionaria o puede transformarse en estacionaria a partir de una transformación simple.

$H_0$ : La serie sigue un modelo lineal (en los parámetros)

Ambas hipótesis suponen una idealización matemática que en algunos casos puede ser válida pero, en otras ocasiones, puede estar muy alejada de la situación real.

La asunción de las hipótesis da lugar a algunas ventajas y limitaciones de los modelos ARMA.

Algunas de las ventajas que presentan los modelos ARMA son:

- La serie temporal puede expresarse como una ecuación lineal en diferencias con una perturbación aleatoria que sigue la distribución. La teoría matemática de las ecuaciones lineales en diferencias posee un cuerpo de doctrina completo y, en particular, para los modelos lineales Gaussianos ha conseguido un mayor desarrollo de la teoría de la inferencia estadística.
- Los modelos ARMA Gaussianos estacionarios se fundamentan en la teoría de los espacios de Hilbert para desarrollar, especialmente, su comportamiento predictivo; la visión geométrica que esta teoría aporta permite dar una interpretación sencilla a resultados algebraicos complejos.
- Existen gran cantidad de programas informáticos que nos facilitan el ajuste del modelo.
- Estos modelos han resultado razonablemente satisfactorios como instrumentos de análisis, previsión y control.

Pero no obstante presentan limitaciones como por ejemplo:

- No se pueden obtener soluciones periódicas estables independientes del valor inicial.
- Dado que las distribuciones conjuntas de los modelos ARMA Gaussianos estacionarios son simétricas, estos modelos no permiten estudiar datos con comportamientos muy asimétricos.
- Los modelos ARMA no son útiles para analizar series temporales que presentan, de manera irregular en el tiempo, saltos de gran amplitud.
- El estudio de los modelos ARMA se basa en el cálculo de las covarianzas; otros parámetros pueden contener información importante que no es recogida por las covarianzas, por ejemplo la función de regresión de retardo  $j, E(X_t/X_{t-j})$  es útil para capturar comportamientos cíclicos de los datos.
- Los modelos ARMA lineales no son adecuados cuando los datos presentan irreversibilidad respecto al tiempo.

Ante esta situación es natural que la investigación en el campo de las series temporales se haya extendido a modelos más generales en los que no se asumen las hipótesis de linealidad y estacionariedad. Estudios realizados sobre diferentes conjuntos de datos indican que los modelos no lineales y no estacionarios son más flexibles para capturar las características de los datos y, en algunos casos, pueden mejorar la calidad del ajuste y la capacidad de predicción del modelo.

Tiao y Tsay (1994) consideran que estos avances no significan que los modelos lineales sean menos útiles, al contrario, los modelos lineales nos proporcionan una primera aproximación que puede resultar de gran ayuda como primera estimación de algunos parámetros.

La modelización de la serie temporal debe empezar por evaluar si el comportamiento de la serie sigue un esquema lineal o no lineal y, en este último caso, analizar el tipo de no linealidad. Diferentes test que permiten determinar este comportamiento contrastando la hipótesis de linealidad frente a alternativas no lineales concretas.

Por otro lado, las Redes Neuronales Artificiales han ido tomando fuerza en los últimos años, los problemas de la vida real suelen tener en la series de tiempo irregularidades o cambios estructurales ocasionados por datos atípicos o datos inconsistentes que no pueden ser tratados por los métodos de Box y Jenkins, por tal motivo las Redes Neuronales Artificiales constituyen una herramienta muy útil para obtener un mejor pronóstico.

Por los escasos antecedentes encontrados resulta un tema poco explorado tanto de manera teórica como aplicada.

## **1.2. FORMULACIÓN DEL PROBLEMA**

En la actualidad un problema frecuente en las series de tiempo es la presencia de perturbaciones o cambios en la estructura, que afecta tanto la especificación de modelos lineales como no lineales, los cuales modifican sus propiedades estadísticas, conducen a

modelar inadecuadamente la serie y al no representar apropiadamente su comportamiento pueden llevar a tomar conclusiones incorrectas o inexactas y tener una mala interpretación. Para modelos no lineales no hay muchos estudios o metodologías que traten estos inconvenientes de cambio estructural sin embargo hay algunos estudios que reconocen las bondades de las Redes Neuronales en el modelamiento de datos atípicos o perturbaciones, los trabajos existentes son más aplicativos que conceptuales, por lo que carecen de una base metodológica sólida que permita generalizarlos.

Cabe indicar que para el caso no lineal, se han realizado algunos trabajos en el contexto de modelos paramétricos, existe realmente muy poca experiencia acerca de éste tópico, más aún, el modelamiento mediante éstas técnicas se ve afectado por los problemas en la representación de características no lineales.

No obstante en el caso lineal, éste problema ha sido ampliamente estudiado, planteándose varias metodologías encaminadas a la detección de datos atípicos o datos aberrantes y a los cambios de estructura de la serie temporal.

En la literatura no se ha encontrado aplicaciones orientadas a patrones complejos de no linealidad sobre series temporales, por lo que existe un campo abierto de investigación en cuanto a cómo debería especificarse correctamente un modelo para series temporales no lineales afectadas por cambios en su estructura.

Como se pudo evidenciar los problemas antes mencionados acerca del modelamiento de series temporales evidencian la necesidad de contar con modelos adecuados para la representación de las características de cada componente estructural de la serie temporal no lineal afectada por cambios en su estructura y así obtener un mejor pronóstico y por ende la toma de decisiones sea correcta.

De los argumentos expuestos surgen muchos interrogantes de carácter investigativo en lo referente a los aspectos relacionados con la selección de variables explicativas, la determinación de la complejidad del modelo, la optimización de los parámetros, etc.; pero más importante aún es direccionar el problema del modelamiento de series temporales no



lineales cuando existe la presencia de observaciones atípicas y cambios importantes en su estructura.

Con ésta investigación se pretenden resolver algunas de todas las posibles preguntas de investigación que surgen al encarar dicha problemática; específicamente ellas son:

1. ¿Es posible formular un modelo estructural basado en Redes Neuronales Artificiales para la representación de series temporales no lineales?
2. ¿Es posible formular un modelo paramétrico para la representación de series temporales no lineales con cambios en su nivel?

En éste trabajo, se propone una alternativa para el modelamiento de series temporales no lineales con cambios en sus componentes estructurales, en el cual utilizaremos el método de Red Neuronal Artificial de Retropropagación Resiliente.

### **1.3. OBJETIVOS DE LA INVESTIGACIÓN**

#### **OBJETIVO GENERAL**

- **Pronosticar la serie de tiempo con cambio estructural por el método de Red Neuronal Artificial de Retropropagación Resiliente** a la serie de tiempo: Número de peruanos retornantes según año de regreso mediante medio de transporte aéreo y **compararlos con los modelos no lineales.**

#### **OBJETIVOS ESPECÍFICOS**

- Realizar pronósticos mediante la Red Neuronal Artificial de Retropropagación Resiliente a la serie de tiempo: Número de peruanos retornantes según año de regreso mediante medio de transporte aéreo del año 2001 al 2012.
- Realizar pronósticos mediante los modelos no lineales a la serie de tiempo: Número de peruanos retornantes según año de regreso mediante medio de transporte aéreo del año 2001 al 2012.

- Comparar los pronósticos de la Red Neuronal Artificial de Retropropagación Resiliente con los pronósticos de las series temporales no lineales.

#### **1.4. JUSTIFICACIÓN**

En este trabajo se propone un procedimiento alternativo a los métodos de modelado de Box y Jenkins, que han evidenciado sus bondades pronosticando diferentes series en distintos países como en Colombia, España entre otros. Este tema es aún poco explorado en el ámbito nacional y podría presentar aplicaciones de mucha utilidad para variados fines, es por esto que urge ahondar en los fundamentos teóricos y prácticos de las Redes Neuronales Artificiales (RNA) para pronosticar series con cambios estructurales que quizá nos otorgue un mejor pronóstico de las series temporales no lineales.

Los modelos presentados constituyen un avance en el modelamiento de series temporales no lineales, obteniéndose mejores pronósticos, permitiendo dar solución a los problemas que presentan las metodologías existentes.

# **CAPÍTULO 2**

## **MARCO TEÓRICO**

## **II. MARCO TEÓRICO**

En todo proceso de investigación, un elemento que sustenta el camino a seguir en todo trabajo científico es el marco teórico, ya que en base a éste se inicia, continúa y se extraen la teoría que permiten respaldar la tesis. Este paso implica analizar y exponer aquellas teorías, enfoques teóricos, investigaciones y antecedentes en general que se consideran válidos para un correcto encuadre del estudio.

### **2.1. ANTECEDENTES A NIVEL NACIONAL**

A nivel nacional cabe mencionar que no se han elaborado estudios similares.

### **2.2. ANTECEDENTES A NIVEL INTERNACIONAL**

1. En el año 1994, los Sres. Marc Sáez Zafra y Jorge V. Pérez presentaron su tesis para optar el grado de Magister en la Universidad de Barcelona-España sobre “MODELOS AUTOREGRESIVOS PARA LA VARIANZA CONDICIONADA HETEROCEDÁSTICA (ARCH)”, donde aplican la metodología de los modelos no lineales para realizar pronósticos.
2. En el año 2001, el Sr. Juan Gabriel Hernández presento en el Campus Vicálvaro de la Universidad Rey Juan Carlos en Madrid-España el estudio sobre “UNA INTRODUCCIÓN A LOS MODELOS DE SERIES TEMPORALES NO LINEALES”, sobresaliendo la metodología de los modelos no lineales, ampliando un estudio sobre la familia de los ARCH (Autoregresivos de heterocedasticidad condicional) y GARCH.
3. En el año 2005 en el mes de junio a noviembre se realizó un estudio en el país de Colombia, en la Universidad Nacional de Córdoba, en la Facultad de Ciencias Agropecuarias el estudio de: “*MODELADO Y PRONÓSTICO DE UNA SERIE DE TIEMPO CONTAMINADA EMPLEANDO REDES NEURONALES Y*

*PROCEDIMIENTOS ESTADÍSTICOS TRADICIONALES*” en las que los autores Silvia Joeques (Facultad de ciencias económicas de la misma universidad de Córdoba), Emanuel P. Barbosa (IMECC. Unicam Brasil) y Walter Robledo (Facultad de ciencias agropecuarias de la misma universidad de Córdoba) emplearon las redes neuronales en la serie contaminada de RESEX utilizando el método de la Red Neuronal Artificial de backpropagation y comparándolos con los procedimientos estadísticos tradicionales.

4. En el año 2005 en el mes de octubre a noviembre se realizó un estudio en el país de Colombia, en la Universidad Nacional de Colombia en la Facultad de Ingeniería de Sistemas el estudio de *“MODELADO ESTRUCTURAL NO LINEAL DE SERIES TEMPORALES”* en las que los autores Paola Andrea Sánchez y Juan David Velásquez, emplearon las Redes Neuronales Artificiales como una alternativa promisoría para el modelado de series con características no lineales.
5. En el año 2005, la Mg. Paola Andrea Sánchez Sánchez presentó su tesis para optar el grado de Magister en la Facultad Nacional de Minas en la Escuela de Ingeniería de Sistemas de la Universidad Nacional de Colombia sobre *“MODELADO DE CAMBIOS ESTRUCTURALES EN SERIES TEMPORALES NO LINEALES UTILIZANDO REDES NEURONALES”*, donde aplico los métodos no paramétricos de Redes Neuronales Artificiales Perceptrón Multicapa, donde logró un pronóstico bueno utilizando esta metodología.
6. En el año 2007, la Lic. Claudia Analía Bahi realizó un estudio en Argentina, en la Universidad Nacional de Cuyo, en la Facultad de Ciencias Económicas, *“MODELOS DE MEDICIÓN DE LA VOLATILIDAD EN LOS MERCADOS DE VALORES: APLICACIÓN AL MERCADO BURSÁTIL ARGENTINO”* sobresaliendo la metodología de los modelos no lineales, ampliando un estudio sobre la familia de los ARCH (Autoregresivos de heterocedasticidad condicional).
7. En el año 2007, se realizó un estudio en el país de España, sobre *“PREDICCIÓN DE SERIES TEMPORALES NO LINEALES CON EL MODELADO NARMAX (APLICACIÓN A LA PREDICCIÓN DE LA DEMANDA DE ENERGÍA ELÉCTRICA)”* en las que los autores el Dr. Antonio Muñoz San Roque y el Ing.

Thomas Czernichow emplearon las Redes Neuronales Artificiales para el modelado de la demanda de energía eléctrica.

8. En el año 2008, la Mg. Paola Andrea Sánchez en la revista de Ingenierías Universidad de Medellín realizó el estudio sobre “CAMBIOS ESTRUCTURALES EN SERIES DE TIEMPO UNA REVISIÓN DEL ESTADO DE ARTE”, donde su objetivo su trabajo fue presentar los desarrollos recientes en el campo del modelado de cambios estructurales, y mostrar cómo estos afectan la identificación del modelo, su pronóstico y las pruebas de estabilidad, utilizando los modelos no lineales.

### 2.3. METODOLOGÍA PARA EL MODELAMIENTO DE SERIES TEMPORALES

En la literatura de series temporales han sido propuestas diferentes estrategias para la especificación del modelo de una serie [véase Box y Jenkins (1970), Tong (1990), Granger y Teräsvirta (1993) y Harvey (1989)]. Un esquema representativo para la especificación y construcción de dicho modelo basado en el procedimiento propuesto por Box y Jenkins (1970) para modelos ARIMA (Autorregresive Integrated and Moving Average) es presentado en la Figura 1 y se discute a continuación cada fase del proceso.

#### Metodología General para el Modelamiento de Series Temporales

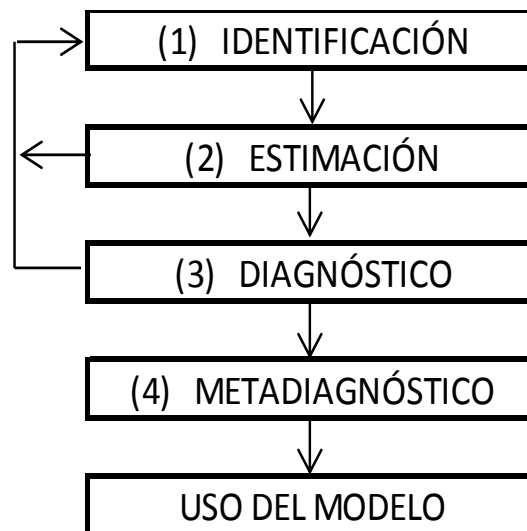


Figura N° 1

Fuente: Elaboración Propia

### 2.3.1. IDENTIFICACIÓN DEL MODELO

Esta fase busca determinar el proceso estocástico que ha generado los datos de la serie, en ésta se realiza el análisis exploratorio de los datos con los siguientes objetivos:

- Determinar si la serie es estacionaria en sentido homogéneo, es decir si su varianza y media son constantes.
- Especificar la forma funcional  $\hat{f}(\cdot)$  del modelo.

La condición de que la serie temporal sea estacionaria requiere en primer lugar que la varianza de la serie sea constante, es decir, que ésta no posea cambios bruscos en su nivel, ni altas volatilidades asociadas. Si dicha exigencia no se cumple, será necesario establecer una transformación adecuada para la serie estudiada. El análisis de la varianza suele hacerse de forma visual mediante la evaluación del gráfico de la serie, aunque también pueden ser útiles gráficos de contraste entre la media y la desviación estándar, en los que se busca una relación lineal.

Box y Cox (1964), plantean que una transformación de la forma:

$$y_t^{\{\lambda\}} = \frac{y_t^{\{\lambda\}} - 1}{\lambda} \quad (I.1)$$

Es útil, para conseguir una varianza constante, donde  $\lambda$ , es llamado el parámetro de transformación.

Un caso común en series económicas lo constituye cuando  $\lambda = 0$ , para el cual la transformación correspondiente  $y_t^{\{\lambda\}}$  es  $\ln(y_t)$ .

En segundo lugar, en cuanto a la estacionariedad de la media, es necesario que la serie conserve un nivel constante y por tanto, que no posea una tendencia. Al igual que para la varianza, el análisis de la estabilidad de la media puede hacerse mediante la evaluación del gráfico de la serie y de los correlogramas [autocorrelograma y autocorrelograma parcial], aunque se apoya dicha decisión en las pruebas de raíces unitarias [Dickey y Fuller (1979), presenta una prueba útil para evaluar la no estacionariedad en la media, conocida como Test de Raíces Unitarias de Dickey-Fuller]. Una serie estacionaria, presenta en los

correlogramas un comportamiento bien sea, que decrece exponencialmente tendiendo a cero, o después de cierto rezago se extingue; dichos comportamientos pueden estar presentes en el autocorrelograma [ACF], o en el autocorrelograma parcial [PACF]. Decrecimientos lentos en el autocorrelograma, indican la necesidad de diferenciar la serie [hacer  $y_t - y_{t-1}$ ]. El proceso de diferenciación termina cuando la serie se convierte en estacionaria. En general el grado de diferenciación requerido para convertir en estacionarias series reales es cero, uno o dos.

En caso de que la serie presente una componente estacional, es necesaria una diferencia estacional.

En el gráfico de la serie, la estacionalidad se manifiesta por la presencia de patrones que se repiten cada cierto periodo de tiempo, situación también visible en el gráfico de autocorrelación, el cual es útil para determinar el periodo estacional de la serie. En principio, es teóricamente posible que una serie requiera más de una diferencia estacional, pero en la práctica esto no ocurre, por lo que la decisión se reducirá a aplicar o no una diferencia estacional.

Con la serie estacionarizada, el segundo objetivo que se persigue es determinar la forma funcional del modelo. En éste proceso se evalúan los correlogramas de la serie, en busca de similitudes a patrones teóricos conocidos, que permitan identificar el orden autorregresivo y de medias móviles para el modelo.

Con base en el análisis se propone uno o varios modelos tentativos para la serie.

En ésta fase se comprueba además si la serie estacionaria tiene una media distinta de cero, usualmente dicha comprobación es realizada de forma automática por la mayoría de los paquetes estadísticos desarrollados para el modelamiento de series temporales, por lo que no se hace énfasis en éste punto.

### **2.3.2. ESTIMACIÓN DE LOS PARÁMETROS DEL MODELO**

La fase de estimación, busca determinar los parámetros que mejor caracterizan el modelo mediante algún proceso de optimización. Usualmente estos modelos asumen que  $v_t$  sigue una distribución normal con media cero y varianza  $\sigma_v^2$ . En la



literatura de series temporales es posible encontrar varios métodos utilizados para la estimación de los parámetros del modelo, como son el método de la máxima verosimilitud, el de los mínimos cuadrados ordinarios, entre otros; más aún, todos los programas estadísticos para el análisis de series temporales incluyen en su proceso la estimación de los parámetros de modelo y su significancia, por lo que no se profundiza en ésta etapa.

### 2.3.3. DIAGNÓSTICO DEL MODELO

Después del cálculo del modelo es necesario verificar si las hipótesis que han permitido la estimación de los parámetros son válidas. Los supuesto básicos con que se trabaja, son que los residuales del modelo  $v_t$  son incorrelacionados y normalmente distribuidos con media cero y varianza constante.

El diagnóstico del modelo es usualmente realizado mediante la evaluación visual de diferentes gráficos hechos para los residuales y la realización de pruebas estadísticas aplicadas a estos.

Para verificar si los residuales se comportan como **ruido blanco** [media cero y varianza constante], es común analizar el comportamiento de los correlogramas, el gráfico de los residuales con respecto al tiempo y de los residuales cuadráticos. En el primero se examina si las correlaciones son estadísticamente significativas, o si forman algún patrón, los cual es un indicio de incorrelación en los errores; en el segundo se evalúa si los residuales se distribuyen uniformemente alrededor de cero; y en el tercero se analiza la variabilidad de los residuales, la presencia de altas volatilidades es reflejo de una varianza no constante.

La hipótesis de normalidad es validada mediante el gráfico exploratorio de normalidad p-plot. Se busca que la distribución de los residuales se aproxime a la diagonal del gráfico, con lo que puede concluir que estos se distribuyen normalmente.

El incumplimiento de los supuestos hechos sobre los residuales es una fuerte evidencia de falta de especificación en el modelo, ausencia de componentes significativos, inclusión de componentes no relevantes o presencia de cambios estructurales. Si la validación de los supuestos no es adecuada se requiere una nueva fase de identificación.

#### **2.3.4. METADIAGNÓSTICO**

La fase de metadiagnóstico persigue dos objetivos:

- La elección del mejor modelo.
- El análisis de la bondad del ajuste del modelo a la serie.

Después de la fase de diagnóstico es posible encontrar varios modelos adecuados para la serie, donde es necesario elegir el mejor. Para éste objetivo muchos criterios de comparación de modelos han sido propuestos en la literatura basados en los residuales, el más común es el de Akaike (1973), no obstante, también son válidas las comparaciones basadas en el Error Cuadrático Medio [Mean Square Error - MSE]. En ambos casos se considera como mejor modelo aquel que presente un menor valor.

El segundo objetivo puede examinarse mediante la inspección del gráfico de la serie original y su estimación.

#### **2.3.5. USO DEL MODELO**

En el modelamiento de series temporales el modelo construido puede ser utilizado para satisfacer los siguientes objetivos: explicar el comportamiento de la serie temporal basado en sus observaciones pasadas; pronosticar valores futuros de la serie o predecir su comportamiento ante determinados escenarios.

(Andrea, 2005)

#### **2.4. REDES NEURONALES ARTIFICIALES**

Las Redes Neuronales Artificiales (RNA) fueron desarrolladas a partir de los trabajos de investigación sobre la filosofía de las neuronas biológicas (NB) de Erlonger y Gaser en 1924, y de dos estudios sobre la actividad de los neurotransmisores de Hadgking y Huxley en 1956 (Kovács, 1996).

Una RNA simula una RNB (Red Neuronal Biológica) en la que cada nodo (unidad de procesamiento) se corresponde con una neurona y tiene como función recibir varios impulsos (entradas), procesarlos y transmitir un resultado a otro u otros nodos (salidas).

Las RN han resultado apropiadas para el análisis de datos generados en amplia variedad de disciplinas, por ejemplo la aplicación de las RN a la predicción con series de tiempo no es nueva, existen numerosos trabajos al respecto, siendo los más conocidos los de Werbos (1974, 1988), Lapedes (1987), Weigend et al. (1990), entre otros. (Weigend y Gershenfeld, 1994)

El funcionamiento de las Redes Neuronales consiste en simular las propiedades observadas en los sistemas nerviosos de los seres vivos a través de modelos matemáticos simulados mediante mecanismos artificiales. El objetivo es conseguir que las máquinas de una respuesta similar a la que daría un cerebro humano.

### Estructura de las Redes Neuronales Artificiales

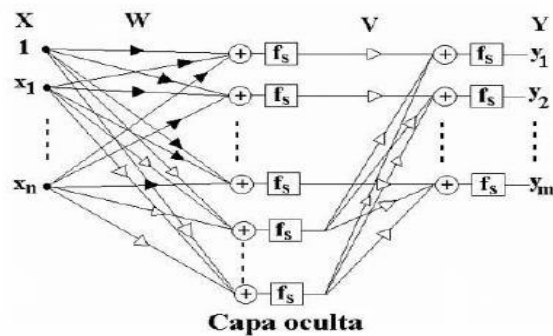


Figura N° 2

Fuente: (Ordieres, Cendon, Castejon, & Fernandez, 2002)

Las RNA son modelos matemáticos compuestos por un gran número de elementos procesales organizados en niveles que intentan reproducir el comportamiento del cerebro. Tal como lo hace el cerebro, realizan simplificaciones, obteniendo los elementos relevantes del sistema, bien porque la cantidad de información de que se dispone es excesiva o bien

porque es redundante, las RNA son una tecnología matemático-computacional, inspirada en modelos biológicos, que puede utilizarse en un gran número y variedad de aplicaciones. Los diferentes tipos de RNA son interpretados como funciones no lineales o sistemas. Un sistema matemáticamente definido, es una transformación que en forma única traza un patrón de entrada en un patrón de salida.

### Funcionamiento de las Redes Neuronales Artificiales

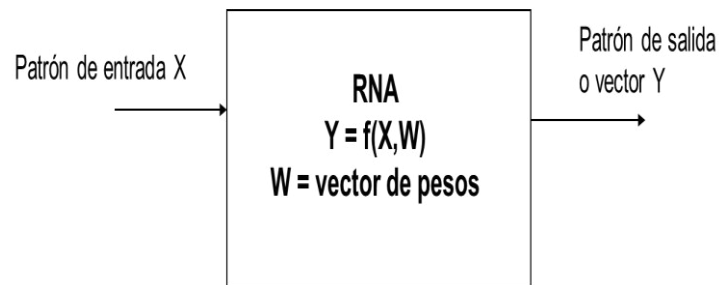


Figura N° 3

Fuente: (Javier Trujillano, 2004)

#### 2.4.1. ESTRUCTURA DE UNA RED NEURONAL ARTIFICIAL

- Número de niveles o capas. La distribución de neuronas dentro de la red se realiza formando niveles o capas de un número determinado de neuronas cada una. A partir de su situación dentro de la red, se pueden distinguir tres tipos de capas: de entrada, ocultas y de salida.
- Número de neuronas por nivel.
- Patrones de conexión.
- Flujo de información.
- Formas de conexión entre neuronas. La conectividad entre los nodos de una red neuronal está relacionada con la forma que las salidas de las neuronas están canalizadas para convertirse en entradas de otras neuronas. Cuando ninguna salida de las neuronas es entrada de neuronas del mismo nivel o de niveles precedentes, la

red se describe como la propagación hacia delante. Cuando las salidas pueden ser conectadas como entradas de neuronas de niveles previos al mismo nivel, incluyéndose ellas mismas, la red es de propagación hacia atrás.

#### **2.4.2. ENTRENAMIENTO DE LA RED**

Las redes neuronales artificiales necesitan ser entrenadas antes de utilizarse. El proceso empieza con la asignación de valores a los pesos asociados a cada conexión y la definición de los parámetros de aprendizaje utilizados.

Los valores de la configuración inicial se eligen de forma aleatoria, después se realiza el entrenamiento de la red, lo cual lleva la adaptación de los pesos.

El ajuste de los pesos se debe hacer de acuerdo a alguna regla de aprendizaje.

#### **2.4.3. APRENDIZAJE EN LAS REDES NEURONALES ARTIFICIALES**

La principal propiedad de una red neuronal artificial es la capacidad de aprender del entorno donde opera (los parámetros se adaptan al entorno) y mejorar su funcionamiento.

Tipos de aprendizaje:

##### **2.4.3.1. SUPERVISADO**

A la red se le suministra un conjunto de datos de entrada y las respuestas correctas correspondientes. Se compara la salida obtenida por la red con la que se espera, si no son iguales se ajustan los pesos en función de la diferencia y si son iguales no se hace ningún cambio.

El entrenamiento excesivo origina la memorización, la red deja de generalizar y empieza a reproducir, sólo funciona bien para los datos del entrenamiento pero si prueba con otros no.

Se emplea en aplicaciones: problemas de predicción de series temporales, de control, de reconocimiento de caras, etc.

#### **2.4.3.2. NO SUPERVISADO**

La red sólo recibe un conjunto de datos de entrada, es necesario que la red se auto-organice (“se enseñe a sí misma”), dependiendo de la existencia de una estructura (debido a una redundancia o clusters) en el conjunto de datos de entrada. La red decide cuales son las características que determinan el agrupamiento de los vectores de entrada y generan la salida.

Las neuronas compiten y las triunfadoras son las únicas que modifican los pesos asociados a las conexiones.

#### **2.4.3.3. CON FORTALECIMIENTO**

Método intermedio entre los dos anteriores. Se provee a la red de un conjunto de datos de entrada y se propaga la activación, pero sólo diremos a la red si ha producido o no la verdadera respuesta.

### **PRINCIPALES TIPOS DE REDES**

#### **a) PERCEPTRÓN SIMPLE Y ADALINE**

Tiene una estructura de varias neuronas de entrada y una o más de salida, no tiene capa oculta. La diferencia entre ambos es la presencia de un umbral al calcular en Adaline las salidas.

$$o = \sum_j w_j x_j + \theta \quad (\text{II.1})$$

## b) PERCEPTRÓN MULTICAPA

Si los conjuntos de datos no son linealmente separables pueden ser modelados por el perceptrón multicapa.

### Perceptrón Multicapa




Figura N° 4

Fuente: (Javier Trujillano, 2004)

Red neuronal tiene una o más capas intermedias, el tiempo de entrenamiento puede ser excesivo con muchas capas intermedias. El número de neuronas en las capas ocultas influyen en la capacidad de generalización de la red:

- Redes con muchos pesos tienden a memorizar el conjunto de datos.
- Redes con muy pocos pesos no son capaces de aprender lo suficiente.

Los algoritmos se deben tratar de diseñar con el mínimo número de neuronas en la capa oculta.

## c) REDES DE FUNCIONES DE BASE RADIAL (RBF)

La característica más importante es el uso de una función de cálculo y no una función de activación tradicional en las neuronas de la capa intermedia.

## Redes de Funciones de Base radial

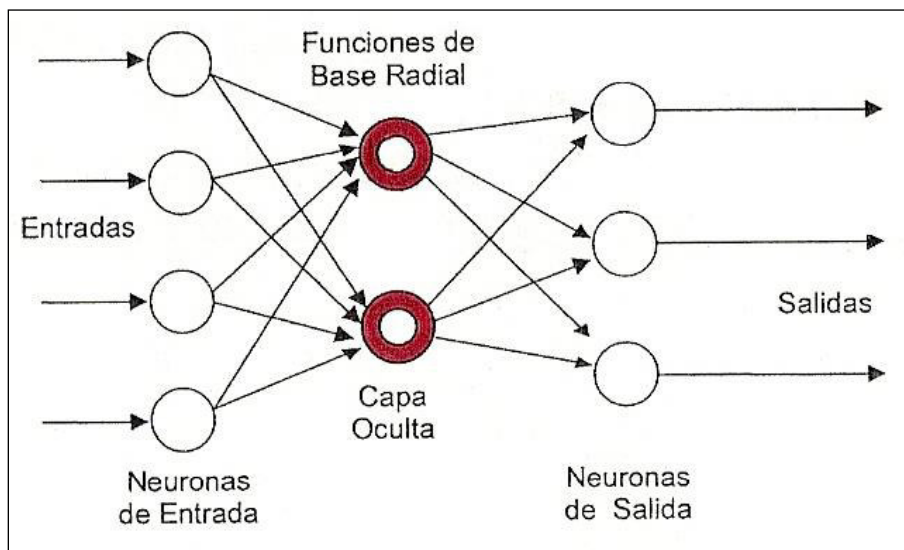


Figura N° 5

Elaboración: Propia

La función lleva a cabo una transformación no lineal desde el espacio de entrada al espacio de la capa intermedia.

- Las neuronas de la capa intermedia son las funciones base para los vectores de entrada.
- Las neuronas de la capa de salida calculan una combinación lineal de las salidas de las neuronas intermedias.

Frecuentemente se utilizan funciones gaussianas en la capa intermedia, la media y desviación se determinan sobre el conjunto de datos de entrada.

### d) COMPETITIVO SIMPLE

Se basa en encontrar la neurona ganadora y actualizar los pesos, así tiene más posibilidades de ganar la próxima vez con una entrada similar.



La ecuación de transferencia de activación es:

$$y_i = \sum_j w_{ij} x_j, \forall i \quad (\text{II.2})$$

La modificación de los pesos es una diferencia entre los pesos y las entradas, los pesos deben ser actualizados y normalizados en cada iteración para que una neurona no gane siempre.

$$\Delta w_{jk} = \eta (x_j - w_{jk}) \quad (\text{II.3})$$

**Regla de propagación:**

En función de las entradas y los pesos se hace algún tipo de operación para obtener el valor del potencial, el cual se utilizará para realizar el procesamiento.

Una de las operaciones más comunes es sumar las entradas teniendo en cuenta la importancia de cada una (Suma Ponderada).

$$y = \sum_j w_{ij} x_j \quad (\text{II.4})$$

Otra regla puede ser la distancia euclídea, la cual se utiliza en los mapas auto-organizados (SOM) o las funciones de base radial (RBF).

#### **2.4.4. LA FUNCIÓN DE ACTIVACIÓN**

El valor obtenido en la regla de propagación se filtra a través de la función de activación y define el nuevo estado o la salida de la neurona. Según para que se entrene la red neuronal se elige una función de activación u otra.

### Resumen de las Funciones de Activación más comunes

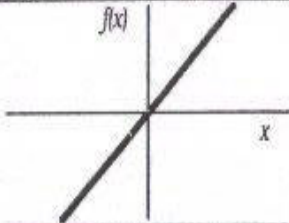
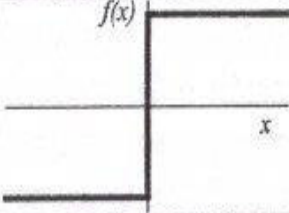
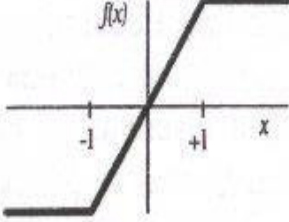
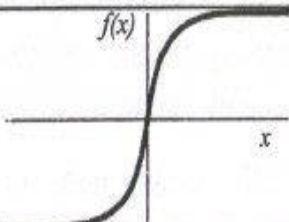
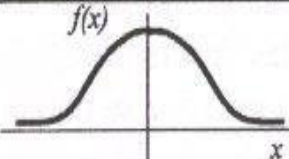
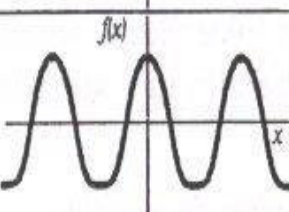
	Función	Rango	Gráfica
<b>Identidad</b>	$y = x$	$[-\infty, +\infty]$	
<b>Escalón</b>	$y = \text{sign}(x)$ $y = H(x)$	$\{-1, +1\}$ $\{0, +1\}$	
<b>Lineal a tramos</b>	$y = \begin{cases} -1, & \text{si } x < -l \\ x, & \text{si } +l \leq x \leq -l \\ +1, & \text{si } x > +l \end{cases}$	$[-1, +1]$	
<b>Sigmoidea</b>	$y = \frac{1}{1+e^{-x}}$ $y = \text{tgh}(x)$	$[0, +1]$ $[-1, +1]$	
<b>Gaussiana</b>	$y = Ae^{-Bx^2}$	$[0, +1]$	
<b>Sinusoidal</b>	$y = A \text{sen}(\omega x + \varphi)$	$[-1, +1]$	

Figura N° 6

Fuente: L'Huillier, G., & Weber, R. (2010)

### **2.4.5. REDES CON APRENDIZAJE SUPERVISADO**

Proporciona a la red un conjunto de datos de entrada y la respuesta correcta, el conjunto de datos es propagado hacia adelante hasta la capa de salida. Entonces se compara la respuesta calculada de la red y se ajustan los pesos para tratar de conseguir una respuesta correcta.

Esto es útil para las tareas de regresión y clasificación, algunas aplicaciones:

- Reconocimiento de códigos de barras.
- Predicción de series temporales y mercados financieros.
- Control de robots.
- Reconocimiento óptico de caracteres.
- Teledetección.

### **2.4.6. REDES CON APRENDIZAJE NO SUPERVISADO**

Descubre modelos o características significativas a partir de los datos de entrada, no existen valores de salida para poder contrastar.

Se trata de imitar el comportamiento humano, la capacidad de aprender sin supervisión explícita. La red debe auto-organizarse y debe actuar ante algunos aspectos del conjunto de entrada como la existencia de redundancia o grupos en el conjunto de datos.

Debe hacer algún tipo de estructura en los datos ante la cual pueda responder.

Se utilizan dos métodos principales:

- Aprendizaje de Hebb
- Aprendizaje competitivo

#### **2.4.6.1. REGLA DE HEBB**

Si dos neuronas  $j$  y  $k$  están activadas simultáneamente, su interconexión debe ser fortalecida, si la neurona  $k$  recibe como entrada la salida de la neurona  $j$ , la regla de Hebb establece que el peso sináptico  $w_{jk}$  debe modificarse.

$$\Delta w_{jk} = \eta y_j y_k \quad (\text{II.5})$$

$\eta$  - Constante de aprendizaje

## **TOPOLOGÍA DE LA RED**

### ✓ **RED MONOCAPA CON PROPAGACIÓN HACIA ADELANTE**

Una capa de entrada captura y distribuye las señales de entrada a la capa de salida que procesa la información y genera la salida de la red. La propagación de las señales es siempre hacia adelante.

### ✓ **RED MULTICAPA CON PROPAGACIÓN HACIA ADELANTE**

Como el anterior pero con la diferencia de incluir una o más capas intermedias. Las redes multicapa no añaden capacidad computable a menos que la función de activación de las capas sea no lineal.

### ✓ **REDES RECURRENTE**

La diferencia con los anteriores es que existe una o más realimentaciones, la salida de una neurona es a su vez la entrada a otra neurona de un procesamiento anterior.

## **MODO DE OPERACIÓN**

Indica como el estado de la red varía en el tiempo, el cambio de estado de las neuronas se realiza de dos formas:

#### **a) SINCRONÍA**

Todas las neuronas cambian su estado simultáneamente.

#### **b) ASÍNCRONA**

Cada neurona tiene una probabilidad de modificar su estado en un determinado momento, normalmente sólo una neurona cambia su estado de activación en un instante de tiempo.

#### **2.4.7. RED NEURONAL ARTIFICIAL DE RETROPROPAGACIÓN**

El algoritmo de retropropagación o propagación del error hacia atrás (backpropagation), es una regla de aprendizaje que se puede aplicar en modelos de redes con más de dos capas de neuronas, una característica importante de este algoritmo es la representación interna del conocimiento que es capaz de organizar en la capa intermedia de las neuronas para conseguir cualquier correspondencia entre la entrada y la salida de la red.

De forma simplificada, el funcionamiento de una red de retropropagación consiste en un aprendizaje de un conjunto predefinido de pares de entradas-salidas dados como ejemplo, empleando un ciclo propagación y adaptación de dos fases : primero se aplica un patrón de entrada como estímulo para la primera capa de neuronas de la red, se va propagando a través de todas las capas superiores hasta generar una salida, se compara el resultado obtenido en las neuronas de la salida con la salida que se desea obtener y se calcula un valor del error para cada neurona de salida.

A continuación, estos errores se transmiten hacia atrás, partiendo de la capa de salida, hacia todas las neuronas de la capa intermedia que contribuyan directamente a la salida, recibiendo el porcentaje de error aproximado a la partición de la neurona intermedia en la salida original.

Este proceso se repite, capa por capa, hasta que todas las neuronas de la red hayan recibido un error que describa su aportación relativa al error total. Basándose en el valor del error recibido, se reajustan los pesos de conexión de cada neurona, de manera que en la siguiente vez que se presente el mismo patrón, la salida esté más cercana a la deseada, es decir, el error disminuya.

# CAPÍTULO 3

# METODOLOGÍA

### III. METODOLOGÍA

Es el conjunto de acciones destinadas a describir y analizar el fondo del problema planteado, a través de procedimientos específicos que incluye las técnicas de observación y recolección de datos, determinando el “cómo” se realizará el estudio, esta tarea consiste en hacer operativa los conceptos y elementos del problema que estudiamos, al respecto **Carlos Sabino** nos dice: “En cuanto a los elementos que es necesario operacionalizar pueden dividirse en dos grandes campos que requieren un tratamiento diferenciado por su propia naturaleza: el universo y las variables” (p. 118).

Así mismo **Arias (2006)** explica el marco metodológico como el “Conjunto de pasos, técnicas y procedimientos que se emplean para formular y resolver problemas” (p.16). Este método se basa en la formulación de hipótesis las cuales pueden ser confirmadas o descartadas por medios de investigaciones relacionadas al problema.

**Tamayo y Tamayo (2003)** define al marco metodológico como “Un proceso que, mediante el método científico, procura obtener información relevante para entender, verificar, corregir o aplicar el conocimiento”, dicho conocimiento se adquiere para relacionarlo con las hipótesis presentadas ante los problemas planteados. (p.37)

#### 3.1.TIPO Y DISEÑO DE LA INVESTIGACIÓN

Cuando se inicia el capítulo de la metodología lo primero que se encuentra el investigador es la definición del tipo de investigación que desea realizar. La escogencia del tipo de investigación determinará los pasos a seguir del estudio, sus técnicas y métodos que puedan emplear en el mismo. En general determina todo el enfoque de la investigación influyendo en instrumentos, y hasta la manera de cómo se analiza los datos recaudados. Así, el punto de los tipos de investigación en una investigación va a constituir un paso importante en la metodología, pues este va a determinar el enfoque del mismo.

El enfoque es de tipo cuantitativo, en el tipo del diseño es de tipo no experimental observacional. Se realiza esta investigación pues no se realiza una manipulación deliberada de la variable de interés, es decir, se trata de un estudio donde no hacemos variar en forma intencional la variable independiente.

Lo que se realiza en la investigación no experimental es observar fenómenos tal como se da en su contexto natural.

En la presente investigación se clasificara en el tipo Longitudinal.

### **3.1.1. COBERTURA**

Nacional

### **3.1.2. UNIVERSO**

Movimientos de salidas internacionales de peruanos, en el período 2000 – 2011 que se registraron a través de los distintos aeropuertos en los cuales se da el control migratorio en el ámbito nacional.

## **3.2. TÉCNICAS E INSTRUMENTOS DE RECOLECCIÓN DE DATOS.**

### **Técnica**

Falcón y Herrera se refieren al respecto que "se entiende como técnica, el procedimiento o forma particular de obtener datos o información". (p.12)

La aplicación de una técnica conduce a la obtención de información, la cual debe ser resguardada mediante un instrumento de recolección de datos.

### **3.2.1. INSTRUMENTO DE RECOLECCIÓN DE DATOS**

En nuestra investigación la fuente de información es:



### **3.2.1.1. FUENTE DE INFORMACIÓN**

La fuente de información lo constituyen los registros administrativos de la Dirección General de Migraciones y Naturalización (DIGEMIN). Especialmente la Tarjeta Andina de Migraciones (TAM).

La DIGEMIN, elevada a esa jerarquía el 9 de Junio del año 1995 por Ley N° 26473, es el órgano que depende funcional y administrativamente de la Alta Dirección del Ministerio del Interior. Es el organismo responsable de la emisión de pasaportes, del control migratorio, de la inmigración y naturalización y tiene por función dirigir, coordinar y controlar el movimiento migratorio de nacionales y extranjeros por los lugares autorizados de ingreso y salida del país. La DIGEMIN es el único ente encargado de elaborar y proporcionar cifras del movimiento migratorio de entradas y salidas internacionales, de peruanos y extranjeros.

El Registro Nacional de Identificación y Estado Civil (RENIEC), en concordancia con los artículos 26, 31 y 8 de la Ley N° 26497 otorga el Documento Nacional de Identidad (DNI) a todos los peruanos en el extranjero a través de los Consulados del Perú. La información que se presenta en este estudio ha sido recabada al 30 de junio del 1999 y proviene de la base de datos de la RENIEC.

## Tarjeta Andina de Migración (TAM)

MINISTERIO DEL INTERIOR DIRECCIÓN GENERAL DE MIGRACIONES Y NATURALIZACIÓN TARJETA ANDINA DE MIGRACION	
PERÚ	
(USE LETRA IMPRENTA)	
1. APELLIDO (S)	
2. NOMBRES (S)	
3. PAÍS DE NACIMIENTO	
4. NACIONALIDAD	
5. PAÍS DE RESIDENCIA	
6. PAÍS DE RESIDENCIA, NO ESCALA TÉCNICA	
7. TIPO DE DOCUMENTO DE VIAJE	PASAPORTE <input type="checkbox"/> CÉDULA DE IDENTIDAD <input type="checkbox"/> SALVOCONDUCTO <input type="checkbox"/> OTROS <input type="checkbox"/>
8. NÚMERO DE DOCUMENTO	
9. FECHA DE NACIMIENTO	10. SEXO MASCULINO <input type="checkbox"/> FEMENINO <input type="checkbox"/> 11. ESTADO CIVIL SOLTERO <input type="checkbox"/> CASADO <input type="checkbox"/> OTROS <input type="checkbox"/>
12. OCUPACIÓN PROFESIÓN	
13. TIPO DE ALOJAMIENTO	DIRECCIÓN
PARTICULAR <input type="checkbox"/> HOTEL <input type="checkbox"/> HOSTAL <input type="checkbox"/>	
14. MEDIO DE TRANSPORTE	AÉREO <input type="checkbox"/> TERRESTRE <input type="checkbox"/> MARÍTIMO <input type="checkbox"/> FLUVIAL <input type="checkbox"/>
15. COMPAÑÍA DE TRANSPORTE UTILIZADO	
16. MOTIVO PRINCIPAL DEL VIAJE	VACACIONES <input type="checkbox"/> VISITAS <input type="checkbox"/> NEGOCIOS <input type="checkbox"/> SALUD <input type="checkbox"/> TRABAJO <input type="checkbox"/> OTROS <input type="checkbox"/>
(SOLO PARA USO OFICIAL)	
PERUANO <input type="checkbox"/> OFIC/DIPLOMA <input type="checkbox"/> TRIPULANTE <input type="checkbox"/>	SELLO DE ENTRADA O SALIDA
TIPO DE VISA TEMPORAL <input type="checkbox"/> RESIDENTE <input type="checkbox"/>	
MINISTERIO DEL INTERIOR DIRECCIÓN GENERAL DE MIGRACIONES Y NATURALIZACIÓN TARJETA ANDINA DE MIGRACION	
PERÚ	
(USE LETRA IMPRENTA)	
1. APELLIDO(S)	
2. NOMBRES	
3. FECHA DE NACIMIENTO	DÍA <input type="text"/> <input type="text"/> MES <input type="text"/> <input type="text"/> AÑO <input type="text"/> <input type="text"/>
4. NACIONALIDAD	
5. TIPO DE DOCUMENTO DE VIAJE	PASAPORTE <input type="checkbox"/> CÉDULA DE IDENTIDAD <input type="checkbox"/> SALVOCONDUCTO <input type="checkbox"/> OTROS <input type="checkbox"/>
6. NÚMERO DE DOCUMENTO	
7. MONTO GASTADO DURANTE SU ESTADÍA	
(SOLO PARA USO OFICIAL)	
CONSERVAR PARA SU RETORNO	
SELLO DE ENTRADA	SELLO DE SALIDA

Fuente: INEI-Migraciones

### **3.3. PROCEDIMIENTOS DE RECOLECCIÓN DE DATOS**

El registro migratorio se efectúa a partir de un documento de identificación del usuario, el pasaporte, que para el caso de peruanos lo expide la autoridad migratoria (DIGEMIN). El documento de viaje tradicional es el pasaporte, pero en la actualidad y en el ámbito regional sudamericano, se extiende progresivamente el uso de los documentos nacionales de identidad para visitas temporales a otros países. Es el caso de nuestro DNI que sirve para visitar Ecuador, Bolivia, Colombia, de acuerdo a la Decisión N° 503 de la Comunidad Andina, de igual manera a Chile de acuerdo al Decreto Supremo N° 002.

Procedimiento del cálculo del total de peruanos no retornantes, en el período 2000 – 2011:

- a) Se considera peruano emigrante a aquel que ha salido del país y no ha retornado en al menos un periodo de un año.
- b) Se seleccionan los últimos movimientos migratorios de los peruanos, tanto las entradas y salidas en todos los puntos de control del país hasta el 31 de diciembre del 2011.
- c) Se seleccionan únicamente los movimientos migratorios de salidas con fecha de corte hasta el 31 de diciembre del 2011.
- d) Se realiza la fusión del registro de los últimos movimientos de salidas de peruanos con sus correspondientes variables complementarias de la TAM, tales como: fecha de movimiento, sexo, fecha de nacimiento, estado civil, entre otros.

### **3.4. METODOLOGÍA ESTADÍSTICA**

#### **3.4.1. METODOLOGÍA PARA EL MODELAMIENTO DE SERIES TEMPORALES NO LINEALES**

Es común pensar que las series estadísticas deberían seguir una trayectoria estacionaria y estable tanto en media como en varianza, lo que aseguraría que su distribución sea insesgado y que las predicciones que se hicieran sean lo más fiables posibles. Por ello para contrastar esta hipótesis, se ha desarrollado una diversidad de pruebas que tienen como finalidad testear si la serie o series bajo análisis, cumplen con la condición de estacionariedad.

##### **3.4.1.1. GRÁFICO DE LA SERIE ORIGINAL**

La inspección general de la serie por medio del gráfico de la serie original nos da una idea de la estacionariedad en nivel y en variabilidad si podemos observar que el comportamiento de la serie no presenta cambios en su tendencia o en su variabilidad.

##### **3.4.1.2. CORRELOGRAMA**

El gráfico de autocorrelaciones se denomina “correlograma” y se espera que una serie de tiempo que sea estacionaria presente un patrón decreciente de las autocorrelaciones, siendo siempre las primeras mayores que las siguientes. Además la primera autocorrelación deberá ser menor que la unidad.

##### **3.4.1.3. RAÍCES UNITARIAS**

Nos permite tener una concepción más amplia del problema bajo análisis. Bajo esta premisa, el problema estadístico teórico que se presenta es el de la existencia de una discontinuidad en las distribuciones, como funciones de  $\alpha$  cuando esta toma valor 1, para otros valores puede utilizarse otras distribuciones.

Las pruebas de raíz unitaria que se han desarrollado dependen del modelo básico que genera la serie. El más sencillo es de la forma  $X_t = \alpha X_{t-1} + \varepsilon_t$  donde la hipótesis nula es:

$$H_0: \alpha=1$$

$$H_1: \alpha \neq 1$$

#### 3.4.1.4. PRUEBAS DE RAÍCES UNITARIAS

Estas pruebas tienen la finalidad contrastar las hipótesis de una serie estadística que sigue un comportamiento estacionario en media y varianza a lo largo de su trayectoria temporal de estimación o análisis.

$H_0$ : La serie no es Estacionaria (Presenta raíz unitaria)

$H_1$ : La serie es Estacionaria (No presenta raíz unitaria)

- ✓ Contraste de Dickey- Fuller Aumentado
- ✓ Contraste de Dickey – Fuller GLS
- ✓ Contraste de Phillip – Perron
- ✓ Contraste de Kwiatkowski
- ✓ Entre otros.

#### 3.4.2. RED NEURONAL ARTIFICIAL DE RETROPROPAGACIÓN RESILIENTE

El algoritmo de Retropropagación Resiliente está basado en el algoritmo de retropropagación tradicional que modifica los pesos de una red neural para encontrar mínimo local de la función error.

Asimismo, el gradiente de la función error  $dE/dw$  es calculado con respecto a los pesos para encontrar una raíz. En particular, los pesos son modificados yendo en la dirección opuesta de los derivados parciales hasta que el mínimo local es alcanzado. Esta idea básica es ilustrada en la Figura 7 por una función- error invariado.

### Función del error invariado




Figura N° 7

Fuente: Rojas (1996)

Si el derivado parcial es negativo, el peso es incrementado (parte izquierda de la figura N° 7); si el derivado parcial es positivo, el peso es disminuido (parte derecha de la figura N° 7).

Esto asegura que el mínimo local es alcanzado. Todos los derivados parciales son calculados usando el Chain Rule (regla que estudia las composiciones de funciones) desde que la función calculada de la red neural es básicamente una composición de integración y activación de funciones. Una explicación detallada dada en Rojas.

La red neural provee la oportunidad del cambio entre la retropropagación, retropropagación resiliente con o sin el peso y la versión convergente globalmente modificado por Anastasiadis en el 2005.

Todos los algoritmos intentan minimizar la función error añadiendo un rango de aprendizaje hacia los pesos yendo en la dirección opuesta de la gradiente.

El algoritmo de retropropagación tradicional, un rango separado, que puede ser cambiado durante el proceso de entrenamiento, es usado por cada peso en la retropropagación resiliente. Esto resuelve el problema de definir todo un rango de aprendizaje que es apropiado por todo el proceso de entrenamiento y la red entera. Adicionalmente, a pesar de la magnitud de los derivados parciales solo su señal (signo) es usado para incrementar los pesos. Estas garantías en igual influencia de rango de aprendizaje hacia la red entera.

Los pesos son ajustados por la siguiente regla.

$$\omega_k^{(t+1)} = \omega_k^{(t)} - n_k^{(t)} * \text{sign}\left(\frac{dE^{(t)}}{d\omega_k^{(t)}}\right) \quad (\text{III.1})$$

En lugar de:

$$\omega_k^{(t+1)} = \omega_k^{(t)} - n * \frac{dE^{(t)}}{d\omega_k^{(t)}} \quad (\text{III.2})$$

La cual representa al retropropagación tradicional, donde t son los índices de las etapas de interacción, k los pesos y E la función del error.

Con el fin de acelerar la convergencia en las áreas pocas profundas, la tasa de aprendizaje se incrementará si los pasos del derivado parcial mantienen su signo caso contrario, eso podría decrecer si derivada parcial de la función error cambie de signo indica que el mínimo se pierde debido a una tasa de aprendizaje demasiado grande.

El peso retroceso es una técnica de deshacer la última interacción y añadiendo un valor más pequeño para el peso en la siguiente etapa. Sin el uso del peso retroceso el algoritmo puede saltar por encima de los mínimos en varias ocasiones.

La convergencia introducida por ANASTASIADIS en el 2005, realiza un retro resiliente con una modificación adicional de la tasa de aprendizaje en relación a todos los demás ritmos de aprendizaje. Esa es más bien la tasa de aprendizaje asociada con la derivada parcial más pequeña, el aprendizaje más pequeño, es cambiado de acuerdo a:

$$n_i^{(t)} = - \frac{\sum_{k; k \neq i} n_k^{(t)} * \frac{dE^{(t)}}{d\omega_k^{(t)}} + \delta}{\frac{dE^{(t)}}{d\omega_i^{(t)}}}, \text{ Si } \frac{dE^{(t)}}{d\omega_i^{(t)}} \neq 0 \text{ y } 0 < \delta \ll \infty \quad (\text{III.3})$$

$\delta$ : Error encontrado que se presenta en cada neurona en comparación con su salida.

$n$ : Cantidad de datos de entrada en cada capa oculta.

## Otra definición de las RNA de Retropropagación Resiliente

Las redes multicapa suelen utilizar las funciones de transferencia sigmoide en las capas ocultas.

Estas funciones son llamadas funciones de " aplastar ", porque se comprimen un rango de entrada infinita en un rango de salida finita. Las Funciones sigmoideas se caracterizan por el hecho de que sus pistas deben aproximarse a cero cuando la entrada se hace grande.

Esto causa un problema cuando se utiliza un descenso más agudo para entrenar una red de múltiples capas con funciones sigmoideas, porque el gradiente puede tener una magnitud muy pequeña y, por lo tanto, causar pequeños cambios en los pesos y sesgos, a pesar de que los pesos y sesgos están lejos de sus valores óptimos.

El propósito de la retropropagación elástica (Rprop) algoritmo de entrenamiento es eliminar estos efectos nocivos de las magnitudes de las derivadas parciales. Sólo el signo de la derivada puede determinar la dirección de la actualización de peso; la magnitud de la derivada no tiene ningún efecto sobre la actualización de peso. El tamaño del cambio de peso se determina por un valor actualización independiente.

El valor de actualización para cada peso y el sesgo se incrementa por un factor de `delt_inc` siempre que la derivada de la función de rendimiento con respecto a ese peso tiene el mismo signo para dos iteraciones sucesivas. El valor de actualización se reduce por un factor de `delt_dec` siempre que la derivada con respecto al peso que cambia de signo de la iteración anterior.

Si el derivado es cero, el valor de actualización sigue siendo el mismo. Siempre que los pesos son oscilante, se reduce el cambio de peso. Si el peso continúa cambiando en la misma dirección durante varias iteraciones, la magnitud del cambio de peso aumenta. Una descripción completa del algoritmo Rprop se da en [ ReBr93 ] .

El siguiente código recrea la red anterior y entrena usando el algoritmo Rprop. Los parámetros de entrenamiento para `trainrp` son épocas, espectáculo, meta, tiempo, `min_grad` , `max_fail` , `delt_inc` , `delt_dec` , `delta0` y `Deltamax` . Los ocho primeros parámetros se han discutido previamente. Los dos últimos son el tamaño del paso inicial y el tamaño máximo



de paso, respectivamente. El rendimiento de Rprop no es muy sensible a los ajustes de los parámetros de entrenamiento.

Para el siguiente ejemplo, los parámetros de entrenamiento se dejan en los valores por defecto:

```
p = [ -1 -1 2 2 ; 0 5 0 5 ] ;
```

```
t = [ -1 -1 1 1 ] ;
```

```
net = newff (p, t, 3 , { } , ' trainrp ');
```

```
net = tren (neto , p, t);
```

```
y = sim (neto , p)
```

RProp es generalmente mucho más rápido que el algoritmo de máxima pendiente estándar. También tiene la propiedad agradable que requiere sólo un modesto incremento en los requisitos de memoria. Necesitando almacenar los valores de actualización para cada peso y sesgo, lo que equivale a un almacenamiento de la pendiente.

### 3.4.3. CAMBIOS ESTRUCTURALES

Un cambio estructural en una serie temporal se presenta cuando hay modificaciones instantáneas o permanentes en una o más de las componentes estructurales de la serie, debido a eventos específicos. Así mismo, pueden ocurrir observaciones puntuales con muy baja probabilidad de ocurrencia, debido a eventos desconocidos y denominadas usualmente como outliers. Además, ante el conocimiento a priori de la presencia de una perturbación en la serie temporal, son en cierto sentido similares, puesto que todos parten de un modelamiento lineal de tipo ARIMA, pero difieren en el tratamiento posterior que se le da a cada uno; es así como si se trata de un outlier, el procedimiento general está orientado a su detección y posterior eliminación; mientras que si se trata de una intervención o un cambio estructural se pretende un modelamiento conjunto de la serie antes y después de dicho evento. Ésta investigación se centra en el problema de modelamiento de series temporales con cambios en su estructura, puesto que es en éste tópico donde más falencias se han encontrado.

Un cambio estructural se caracteriza por afectar de forma permanente la componente determinística de la serie temporal. Se han desarrollado procedimientos generales basados en modelos lineales de tipo ARMA y ARIMA, especialmente orientados a su detección, los cuales han sido ampliamente utilizados para explicar el efecto en la economía de reformas políticas, fiscales y económicas. No obstante, en el caso general el proceso generador de la serie temporal puede ser no lineal.

La presencia de cambios estructurales en la serie temporal puede ocasionar no linealidades, o más aún la serie en sí misma puede tener una estructura de comportamiento no lineal. Los modelos tradicionalmente empleados en la representación de estos cambios no contemplan dicha variación, por lo que su aplicación a series con las características enunciadas conduce a una especificación inadecuada de su modelo, manifestado mediante una representación errónea de las propiedades de ésta, y en consecuencia, resulta en conclusiones incorrectas en su interpretación.

Si bien en las últimas décadas se han hecho acercamientos a esta problemática vía modelos paramétricos no lineales, la principal falencia que se tiene en estos modelos es que aplican un patrón de no linealidad específico para la serie analizada, no siendo adecuados para modelar otros tipos de no linealidades. Otra forma alternativa de abordar el problema es la utilización de métodos no paramétricos de regresión no lineal, como son las redes neuronales, los cuales han demostrado tener la capacidad de reconocer y modelar comportamientos atípicos, sin una forma de no linealidad predefinida.

Se ha establecido que el modelamiento de una serie temporal se ve ostensiblemente afectado cuando esta presenta cambios estructurales de carácter permanente, y que debido a que estos cambios afectan el comportamiento de la serie, es necesario establecer procedimientos para su representación, lo que puede conducir a modelos más completos. El modelamiento de cambios estructurales mediante modelos lineales puede afectar, tanto el proceso de identificación de la serie, como la estimación de los parámetros, y por ende el poder explicativo del modelo, por lo que para series con características no lineales se

prefiere la utilización de otro tipo de modelos, para los cuales no existe una metodología claramente establecida orientada a su representación.

Debido a las dificultades que dichos cambios ocasionan en los procesos de identificación, estimación y diagnóstico del modelo, es necesario considerar de forma independiente cada uno de ellos. Es necesario entonces, el desarrollo de una metodología que permita la representación de series temporales con cambios en su estructura, y diferentes comportamientos, como pueden ser la presencia de no linealidades.

Como conclusión de lo expresado no existe una formulación de un modelo lineal o no lineal, que permita la representación de cada componente de una serie temporal caracterizada por la presencia de patrones no lineales y de cambios en sus componentes estructurales. No obstante, los modelos estructurales y las Redes Neuronales Artificiales, comportamientos, como los aquí mencionados; lo cual da pie a pensar que el planteamiento de un modelo híbrido que integre éstas metodologías, puede permitir una representación de la serie conceptualmente más adecuada, ante tales características. Cabe recordar que se estableció que cada uno de los cambios estructurales que pueden afectar la evolución de la serie temporal debe ser analizado aisladamente presentan fortalezas que pueden ser complementarias al momento de representar diferentes.

#### **3.4.4. MODELOS NO LINEALES**

En muchas ocasiones en economía se habla de sucesos condicionados o de generación de expectativas a partir de los movimientos relativos que se produjeron en el pasado. Por ejemplo, todo el mundo relaciona inmediatamente la estabilidad o la inestabilidad en los mercados financieros con su comportamiento inmediatamente anterior, produciéndose fuertes hondos en la evolución de sus variables que, después de un gran sobresalto que dura más o menos días, tienden a retomar una senda de evolución tranquila. A cualquiera se le ocurre entonces que, en variables como éstas, el comportamiento en el momento actual responde a una expectativa generada sobre el valor de cambio producido

en el momento precedente; es decir, a un valor esperado condicionado por la varianza del período anterior.

En la teoría clásica de series temporales (metodología de Box-Jenkins), el desarrollo estadístico se realiza a partir de un proceso estocástico estacionario; es decir (en sentido amplio o débil) de un proceso con:

- Media constante.
- Varianza constante.
- Correlación entre dos observaciones distintas igual a la de otras dos cualquiera separadas por la misma distancia (mismo número de períodos).

En torno a la confirmación de la ausencia de tendencia (determinista o aleatoria), hay un nutrido conjunto de teorías y desarrollos matemáticos centrados en la diferenciabilidad de la serie temporal y en la existencia o no de raíces unitarias a partir de los conocidos test de Dickey y Fuller, de Mackinon o de Phillips y Perron, por citar algunos. Sin embargo, el estudio de la componente de varianza constante es un fenómeno menos extendido y, no tener en cuenta una posible no constancia de este componente, puede suponer diversos problemas estadísticos cuando se estiman modelos econométricos (problemas ligados con la eficiencia de los parámetros estimados y su fuerte volatilidad ante el amplio intervalo de confianza en el que se mueven).

Determinar un patrón de comportamiento estadístico para la varianza es el cometido de los modelos Autorregresivos condicionales heterocedásticos: ARCH. Engle (1982) es el autor de una primera aproximación a la varianza condicional del tipo que describiremos más adelante. Después de estos hay una amplia familia de sofisticaciones del modelo inicial que darán nombre a los modelos GARCH, IGARCH, EARCH, TARARCH, SWARCH, QS-ARCH, APARCH, FACTOR-ARCH,

En el artículo seminal de los modelos ARCH, Engle cita tres situaciones que motivan y justifican la modelización de la heterocedasticidad condicional Autorregresiva (nombre por él mismo dado).

Estas serían las siguientes:

- 1) La experiencia empírica nos lleva a contrastar períodos de amplia varianza de error seguidos de otros de varianza más pequeña. Es decir, el valor de la dispersión del error respecto a su media cambia en el pasado, por lo que es lógico pensar que un modelo que atienda en la predicción a los valores de dicha varianza en el pasado servirá para realizar estimaciones más precisas.
- 2) En segundo lugar, Engle expone la validez de estos modelos para determinar los criterios de mantenimiento o venta de activos financieros. Los agentes económicos deciden esta cuestión en función de la información proveniente del pasado respecto al valor medio de su rentabilidad y la volatilidad que ésta ha tenido. Con los modelos ARCH se tendrían en cuenta estos dos condicionantes.
- 3) El modelo de regresión ARCH puede ser una aproximación a un sistema más complejo en el que no hubiera factores innovacionales con heterocedasticidad condicional. Los modelos estructurales admiten, en multitud de ocasiones, una especificación tipo ARCH infinito que determina con parámetros cambiantes, lo que hace a este tipo de modelos capaces de contrastar la hipótesis de permanencia estructural que supone una de las hipótesis de partida y condición necesaria para la validez del modelo econométrico tradicional.

En definitiva, la clave de estos modelos está en considerar la información pasada de la variable y su volatilidad observada como factor altamente explicativo de su comportamiento presente y, por extensión lógica, de su futuro predecible. Estadísticamente, esta conclusión se refleja en tener en cuenta la esperanza condicional (conocida y fija la información hasta el momento inmediatamente anterior) del cuadrado de una variable (la expresión de su varianza si su media es nula). (Rafael, 1998)

#### **3.4.4.1. ESTACIONARIEDAD**

Para que una serie de tiempo sea estacionaria esta debe girar en torno a su media, sin presentar comportamientos erráticos o atípicos. Estadísticamente hablando, una variable estacionaria es aquella que se comporta con una media y varianza

constante en el tiempo, es decir que el proceso estocástico subyacente que lo generó es invariante con respecto al tiempo entonces podemos modelar el proceso a través de una ecuación con coeficientes fijos que pueden estimarse a través de datos pasados.

#### **3.4.4.2. RAÍCES UNITARIAS**

En el capítulo anterior se definió las Raíces Unitarias.

#### **3.4.4.3. PRUEBAS UNITARIAS**

En el capítulo anterior se definió las Pruebas de Raíces Unitarias.

#### **3.4.5. MODELOS ARCH**

Los modelos ARCH aparecen en los años 80 con el objeto de recoger los episodios de agrupamiento temporal de volatilidad que suele observarse en las series de rentabilidad de casi todo mercado financiero. Desde entonces, su variedad y su aplicación práctica han crecido de manera espectacular. En realidad, hay precursores más antiguos [Bachelier (1900) y Mandelbrot(1963,1967)], trabajos en los que comenzó a caracterizarse las propiedades estadísticas de los precios de activos financieros.

Las características más relevantes de las series financieras recogidas con frecuencias elevadas [Ruiz (1994)], son:

- 1) Ausencia de estructura regular dinámica en la media, lo que aparece reflejado en estadísticos Ljung-Box generalmente no significativos.
- 2) Distribuciones leptocúrticas o exceso de curtosis.
- 3) Suelen ser simétricas, aunque también se encuentran en algunos casos coeficientes de asimetría significativamente distintos de cero,
- 4) Agrupamiento de la volatilidad sobre intervalos de tiempo, lo cual se refleja en funciones de autocorrelación simple significativas para los cuadrados de las variables,

- 5) Persistencia en volatilidad: los efectos de un shock en volatilidad tardan un tiempo en desaparecer.
- 6) Efecto apalancamiento: se observa una respuesta asimétrica de la volatilidad al nivel de los rendimientos, en el sentido de que muchos de estos efectos quedan recogidos en los modelos ARCH, GARCH, EGARCH, que vamos a analizar. Estos modelos recogen en sus formulaciones la idea de que existen agrupaciones de volatilidad, es decir, que fuertes fluctuaciones inesperadas en los mercados tienden a venir seguidas de períodos de iguales características, mientras que períodos de estabilidad tienden a venir seguidos de períodos asimismo estables. Los modelos de esta familia recogen este comportamiento inercial en volatilidad a la vez que el comportamiento dinámico, con autocorrelación que suelen presentar las series financieras.

Una de las contribuciones importantes de la literatura de procesos ARCH es mostrar que las variaciones que aparentemente se producen en la volatilidad de las series temporales económicas pueden explicarse mediante una determinada forma de dependencia no lineal, que permite además predecir dichos cambios en volatilidad sin necesidad de recurrir a la modelización explícita de cambios estructurales en la varianza.

Frente a estas observaciones empíricas, fórmulas de valoración del tipo Black-Scholes(BS) suponen una volatilidad constante para el precio del activo subyacente, que permite deducir la expresión analítica del precio teórico de una opción Europea sobre dicho activo. La fórmula BS es utilizada habitualmente para deducir de ella la volatilidad implícita, forzando el precio que de ella se deriva a coincidir con el precio observado en el mercado.

La volatilidad implícita así obtenida se interpreta como el nivel de volatilidad vigente en el mercado desde el momento de inversión de la fórmula BS hasta el vencimiento de la opción. Sin embargo, no siendo dicha volatilidad constante en el tiempo, es cuestionable la interpretación del valor numérico obtenido para la volatilidad implícita. Suele interpretarse como una expectativa de mercado y en términos del valor medio de volatilidad vigente para el período mencionado, pero tal interpretación no está justificada por el análisis BS.

(Alfonso, 2013)

$$y_t = \varepsilon_t \sigma_t$$

$$\sigma_t^2 = \omega + \sum_{i=1}^q \alpha_i y_{t-i}^2 \quad (\text{IV.1})$$

Dónde:

$y_t$ : Serie de estudio

$\varepsilon_t$ : Ruido blanco normal estandarizado es decir

$$E(\varepsilon_t) = 0$$

$$E(\varepsilon_t^2) = 1$$

$\sigma_t$ : Varianza condicional

$\omega, \alpha_i$ : Parámetros a estimar.

La condición  $\omega > 0$  corresponde a la mínima varianza condicional a ser observada mientras que  $0 < \alpha_i < 1$  es una condición necesaria y suficiente para la existencia de la varianza incondicional y la condicional. El coeficiente  $\alpha_i$  mide la persistencia de la volatilidad; si dicho coeficiente es cercano a uno, se dice que hay una alta persistencia de los shocks de volatilidad.

Por otra parte, dado el conjunto de información disponible hasta el instante (t-i),  $\Omega_{t-i}$ , el valor esperado condicional y la varianza condicional de  $y_t$  están dado respectivamente por:

$$E(y_t / \Omega_{t-i}) = 0,$$

$$\text{Var}(y_t / \Omega_{t-i}) = \sigma_t^2$$

Por lo tanto, la distribución de los errores dado el conjunto de información  $\Omega_{t-i}$  es una normal con media cero y varianza  $\sigma_t^2$ , simbólicamente  $y_t / \Omega_{t-i} \sim N(0, \sigma_t^2)$  y  $\text{Var}(y_t / \Omega_{t-i}) = \sigma_t^2$ , donde la varianza condicional depende de la información disponible en cada instante t.

#### 3.4.5.1. Procedimiento para la construcción de un modelo ARCH

Para construir un modelo ARCH realice los siguientes pasos:



- Construir un modelo ARMA para la serie dada con el fin de eliminar alguna dependencia lineal en la media y usar los residuales del modelo para determinar si existe efecto ARCH. Los residuos del modelo ARMA podrían estar incorrelacionados y posiblemente no serán independientes. Este efecto será visible en la función de autocorrelación de los residuos al cuadrado, que mostrarían correlación serial.
- Especificar el orden del ARCH.
- Validar el ajuste del modelo ARCH.

### **3.4.6. MODELOS GARCH**

La modelación del GARCH proviene de avances en la modelación de la volatilidad en los años ochenta; este proceso se introduce en el grupo de análisis que trata el exceso de curtosis y el agrupamiento de volatilidad, dos de las características más comunes en las series financieras. Los modelos de volatilidad condicional proporcionan una adecuada manera de modelar y pronosticar las varianzas y covarianzas de los retornos activos.

Se pueden aplicar modelos GARCH en cualquiera de los diversos campos de la administración del riesgo, de la administración de portafolio, en la asignación de activos, en las opciones de precios, en las tasas de cambio, en la estructura de tasas de interés, entre otros.

Aunque en todos los modelos que se describen a continuación suponemos que las rentabilidades siguen una estructura ARCH/GARCH, es sobre su innovación sobre la que aplicaremos en la práctica el supuesto. Únicamente en el caso en que la rentabilidad carezca de autocorrelación, podemos hacer el supuesto GARCH sobre la rentabilidad pues, salvo constantes, coincide con su innovación.

#### **MODELOS GARCH (p,q)**

En muchos casos, la especificación ARCH que recoge la estructura de autocorrelación en varianza precisa de un elevado número de retardos. Para evitar que el alto número de coeficientes en términos Autoregresivos, generalmente bastante relacionados, produzca una

importante pérdida de precisión en su estimación, se ha propuesto una parametrización alternativa, restringida, dependiente de un número reducido de parámetros.

$$y_t = \varepsilon_t \sigma_t$$

$$\sigma_t^2 = \omega + \sum_{i=1}^q \alpha_i y_{t-i}^2 + \sum_{j=1}^p \beta_j \sigma_{t-j}^2 \quad (\text{IV.2})$$

Dónde:

$$\alpha_0 > 0, \quad \alpha_i, \beta_j \geq 0, \quad \sum_{i=1}^q \alpha_i + \sum_{j=1}^p \beta_j < 1$$

Dónde:

$y_t$ : Serie de estudio

$\varepsilon_t$ : Ruido blanco normal estandarizado es decir

$$E(\varepsilon_t) = 0$$

$$E(\varepsilon_t^2) = 1$$

$\sigma_t$ : Varianza condicional

$\omega, \alpha_i$ : Parámetros a estimar.

### 3.4.7. MODELOS TGARCH

Un primer modelo que es capaz de producir efectos asimétricos, es el modelo TGARCH (Thershold Heteroscedastic Autoregressive Models), propuesto por Zakoian (1994); son modelos que dependen de un umbral, por medio del cual definen su reacción. En los mercados bursátiles se observa empíricamente que los movimientos a la baja son generalmente más volátiles que los movimientos de alza. En particular, el modelo TGARCH (1,1) o Thershold ARCH propone la siguiente ecuación para estimar la varianza condicional

$$\sigma_t^2 = \delta_0 + \delta_1 \varepsilon_{t-1}^2 + \gamma d_{t-1} \varepsilon_{t-1}^2 + \theta_1 \sigma_{t-1}^2 \quad (\text{IV.3})$$

Donde  $d_{t-1}$  toma dos valores

$$\begin{cases} 1 & \text{si } \varepsilon_{t-1} < 0 \\ 0 & \text{si } \varepsilon_{t-1} \geq 0 \end{cases}$$

Dónde:

$y_t$ : Serie de estudio

$\varepsilon_t$ : Ruido blanco normal estandarizado es decir

$$E(\varepsilon_t) = 0$$

$$E(\varepsilon_t^2) = 1$$

$\sigma_t$ : Varianza condicional

$\delta_0, \delta_1, \gamma, \theta_1$ : Parámetros a estimar

Es decir, valores negativos del residuo de la regresión son interpretados como malas noticias para el mercado y los valores positivos representan las buenas noticias. Las malas noticias tendrán un impacto  $(\delta_1 + \gamma)$  sobre la varianza condicional, mientras que las buenas solo impactaran en  $\delta_1$ . Si  $\gamma > 0$ , se dice que existe el efecto de apalancamiento (leverage effect); dicho efecto se refiere al hecho de que a rentabilidades negativas correspondan una mayor volatilidad condicional que a rentabilidades positivas. Si  $\gamma \neq 0$ , se dice que el impacto de las noticias es asimétrico.

# CAPÍTULO 4


# APLICACIÓN

#### IV. APLICACIÓN

En este apartado se plantean los resultados obtenidos, acompañados de su respectiva explicación y un análisis profundo. Se pueden utilizar tablas y gráficas para reportar los resultados, si esto facilita su comprensión.

##### Gráfico de la serie original

**Número de peruanos retornantes según año de regreso mediante medio de transporte aéreo (2000-2011)**



**Gráfico N° 1**

Fuente: Elaboración Propia

Se puede observar en el gráfico N° 1 en la cual presenta la serie de tiempo Número de peruanos retornantes según año de regreso mediante medio de transporte aéreo entre los años 2000 al 2011. Esta serie presenta una tendencia determinística creciente por lo tanto no es estable ni en nivel ni en variabilidad, presenta asimismo una estacionalidad determinística y también un cambio de nivel entre los años 2001 y 2003 esto se debe a que en esos años del 2000 al 2003 hubo cambios de gobiernos que influenciaron en el retorno

de peruanos a su país natal por diferentes motivos entre ellos una posibilidad de un trabajo estable.

### Gráfico de Autocorrelaciones

**Correlograma del número de peruanos retornantes según año de regreso mediante medio de transporte aéreo (2000-2011)**




Gráfico N° 2

Fuente: Elaboración Propia

Se puede observar que el gráfico N° 2, presenta el Correlograma de la serie de tiempo Número de peruanos retornantes según año de regreso mediante medio de transporte aéreo, la primera autocorrelación es menor que la unidad, y lo que se busca es que sea decreciente, siendo siempre las primeras mayores que las siguientes para que la serie estudiada sea estacionaria, pues se ve claramente que en la parte regular va en decrecimiento pero tiende a elevarse en algunas autocorrelaciones por lo que la serie de tiempo exploratoriamente no es estacionaria.

## Pruebas de raíces unitarias

### Prueba de Dickey-Fuller Aumentado

View	Proc	Object	Properties	Print	Name	Freeze	Sample	Genr	Sheet	Graph		
<b>Augmented Dickey-Fuller Unit Root Test on P_AEREO</b>												
Null Hypothesis: P_AEREO has a unit root												
Exogenous: Constant, Linear Trend												
Lag Length: 13 (Automatic - based on AIC, maxlag=13)												
							t-Statistic	Prob.*				
<b>Augmented Dickey-Fuller test statistic</b>							<b>-1.801658</b>	<b>0.6990</b>				
Test critical values:							1% level		-4.023975			
							5% level		-3.441777			
							10% level		-3.145474			
*Mackinnon (1996) one-sided p-values.												
Augmented Dickey-Fuller Test Equation												
Dependent Variable: D(P_AEREO)												
Method: Least Squares												
Date: 11/30/14 Time: 13:08												
Sample (adjusted): 15 156												
Included observations: 142 after adjustments												
		Variable	Coefficient	Std. Error	t-Statistic			Prob.				
		P_AEREO(-1)	-0.092731	0.051470	-1.801658			0.0740				
		D(P_AEREO(-1))	-0.170217	0.095780	-1.777168			0.0780				
		D(P_AEREO(-2))	-0.008006	0.081680	-0.098014			0.9221				
		D(P_AEREO(-3))	0.065270	0.078558	0.830850			0.4076				
		D(P_AEREO(-4))	-0.033904	0.076777	-0.441599			0.6595				
		D(P_AEREO(-5))	-0.023526	0.075248	-0.312643			0.7551				
		D(P_AEREO(-6))	-0.012429	0.074133	-0.167656			0.8671				
		D(P_AEREO(-7))	-0.064936	0.072791	-0.892087			0.3740				
		D(P_AEREO(-8))	-0.070986	0.071811	-0.988516			0.3248				
		D(P_AEREO(-9))	0.012592	0.071894	0.175142			0.8612				
		D(P_AEREO(-10))	-0.044723	0.070985	-0.630043			0.5298				
		D(P_AEREO(-11))	-0.042830	0.070096	-0.611016			0.5423				
		D(P_AEREO(-12))	0.781177	0.069024	11.31750			0.0000				
		D(P_AEREO(-13))	0.170143	0.093632	1.817142			0.0716				

**Figura N° 8**

Fuente: Elaboración Propia

Se puede observar en la figura N° 8 que la serie de tiempo Número de peruanos retornantes según año de regreso mediante medio de transporte aéreo evaluada no es estacionaria, puesto que el valor de Dickey-Fuller es significativamente menor que los valores críticos de Mackinnon a los 3 niveles de significancia, y también evaluando con p-value se puede concluir con lo mismo puesto no se puede rechazar la hipótesis nula es decir la serie no es estacionaria.

Ahora veremos el mejor **SARIMA** propuesto para nuestra serie de tiempo para tener una referencia.

- ✓ El mejor **SARIMA**

**MODELO: SARIMA (0, 1,1) (0, 1,1)<sub>12</sub>**

$$\nabla^{12}\nabla Y_t = (1 - \theta_1 B)(1 - \theta_{12} B)a_t$$

$$(1 - B^{12})(1 - B)Y_t = (1 - \theta_1)(1 - \theta_{12} B^{12})a_t \quad |\theta_1| < 1 \quad |\theta_{12}| < 1$$

**Cuadro N° 1**  
**Coefficientes y significancia de los parámetros**

Tipo	Coefficiente	SE	T	P
<b>MA 1</b>	0.2694	0.08	3.27	0.001
<b>SMA 12</b>	0.6242	0.08	8	0.000

Fuente: Elaboración Propia

Se puede observar en el cuadro N° 1, la cual muestra la significancia de los parámetros propuestos para el modelo en cual se puede constatar que si son significativos, a un nivel de significancia del 5%.

**Suma de residuos al cuadrado (SSE) y la Desviación Media absoluta (MAD)**

**Cuadro N° 2**  
**Suma de Cuadrados de los Residuos y Desviación Media Absoluta**

<b>SSE</b>	<b>1796204</b>
<b>MAD</b>	<b>84.53</b>

Fuente: Elaboración Propia



Se puede observar en el cuadro N° 2, la cual muestra la sumatoria de cuadrados de los residuos y asimismo la Desviación media absoluta para el modelo SARIMA, estos indicadores nos permiten comparar modelos.

### Correlograma de los residuos

#### Correlograma de los residuos para el modelo SARIMA




Gráfico N° 3

Fuente: Elaboración Propia

En el gráfico N° 3, en el Correlograma de los residuos para el modelo SARIMA propuesto, nos muestra que algunas Autocorrelaciones salen de las bandas de confianza puesto no se comportan como ruido blanco esto nos da a indicar que el modelo no es el adecuado.

## Gráfico de la normalidad para los residuos

### Gráfico de probabilidad Normal para los residuos para el modelo SARIMA





Gráfico N° 4

Fuente: Elaboración Propia

Se puede observar en el gráfico N° 4, que presenta el gráfico de probabilidad normal de los residuos para el modelo SARIMA propuesto, nos muestra que no se comportan mediante una distribución normal puesto no se comportan como ruido blanco esto nos da a indicar que el modelo no es el adecuado.

## Análisis espectral para los residuos



**Gráfico N° 5**


Fuente: Elaboración Propia

Se puede observar en el gráfico N° 5, que presenta el gráfico de densidad espectral para los residuos para el modelo SARIMA propuesto mediante la ventana de Parzen, que prevalece la Estacionalidad de orden bajo cada 3 meses aproximadamente y en segundo lugar una parte Autoregresiva en la parte regular que se puede observar en la curva antes del punto 0,08, por lo que se confirma anteriormente que el modelo escogido no es el adecuado.

**\*\*La ventana de Parzen para todos los modelos se utilizó una amplitud de 35**

## Estimación y Pronóstico de la serie temporal para el modelo SARIMA

**Estimación y Pronóstico del Número de peruanos retornantes según año de regreso mediante medio de transporte aéreo (2001-2012)**



**Gráfico N° 6**

Fuente: Elaboración Propia

Se puede observar en el gráfico N° 6, el pronóstico mediante el mejor SARIMA propuesto para la serie de tiempo Número de peruanos retornantes según año de regreso mediante medio de transporte aéreo del año 2001 al 2012 presenta un buen ajuste con la serie original.

**\*\*La estimación de la serie se realizó para todos los modelos a partir del año 2001 para tener una uniformidad y una mejor visión de los pronósticos, puesto los modelos No paramétricos pierde el primer año para trabajar la Red.**

Ahora veremos el **primer modelo paramétrico** propuesto donde incluirá el modelamiento de la volatilidad para nuestra serie de tiempo.

### Modelo paramétrico propuesto 1

El siguiente modelo propuesto para modelar el proceso y la volatilidad condicional que presenta nuestra serie de tiempo la cual se realizó con el programa Eviews 8:

$$Z_t = 0.536132Z_{t-1} + 0.408000Z_{t-12} + a_t$$

$$a_t = \sqrt{h_t}\varepsilon_t$$

$$h_t = 13038.84 + 0.784319a_{t-1}^2$$

### Validación del modelo paramétrico 1

View	Proc	Object	Print	Name	Freeze	Estimate	Forecast	Stats	Resids
Dependent Variable: P_AEREO									
Method: ML - ARCH (Marquardt) - Normal distribution									
Date: 11/02/14 Time: 12:00									
Sample (adjusted): 1 144									
Included observations: 144 after adjustments									
Convergence achieved after 21 iterations									
Presample variance: backcast (parameter = 0.7)									
GARCH = C(3) + C(4)*RESID(-1)^2									
Variable	Coefficient	Std. Error	z-Statistic	Prob.					
P_AEREO(1)	0.536132	0.026944	19.89835	0.0000					
P_AEREO(12)	0.408000	0.027811	14.67057	0.0000					
Variance Equation									
C	13038.84	2383.607	5.470211	0.0000					
RESID(-1)^2	0.784319	0.244415	3.208963	0.0013					
R-squared	0.797428	Mean dependent var	883.2917						
Adjusted R-squared	0.796002	S.D. dependent var	390.5711						
S.E. of regression	176.4060	Akaike info criterion	13.04009						
Sum squared resid	4418911.	Schwarz criterion	13.12258						
Log likelihood	-934.8861	Hannan-Quinn criter.	13.07361						
Durbin-Watson stat	1.417332								

Figura N° 9

Fuente: Elaboración Propia

Se puede observar en la figura 9, la cual muestra la significancia de los parámetros propuestos para el modelo en cual se puede constatar que si son significativos, mientras tanto el parámetro ARCH también es significativo a un nivel de significancia del 5%.

### **Criterios de información Akaike( AIC) y Bayesiano (BIC)**

**Cuadro N° 3**  
**Criterios de selección del modelo**

<b>AIC</b>	<b>13.04</b>
<b>BIC</b>	13.12

Fuente: Elaboración Propia

Se puede observar en el cuadro N° 3, la cual muestra los criterios de información de Akaike (AIC) y el criterio de información Bayesiano (BIC) los cuales nos permite determinar con qué eficiencia los modelos se ajustan, estos criterios nos permiten comparar modelos en la cual se escogerá aquellos criterios que contengan valores menores puesto que el modelo que mejor explica los datos con el mínimo de parámetros es el que presenta más bajo valor de AIC y BIC. Para el modelo paramétrico 1 presenta un AIC con un 13.04 y un BIC con un 12.12.

### **Suma de residuos al cuadrado (SSE) y la Desviación Media absoluta (MAD)**

**Cuadro N° 4**  
**Suma de Cuadrados de los Residuos y Desviación Media Absoluta**

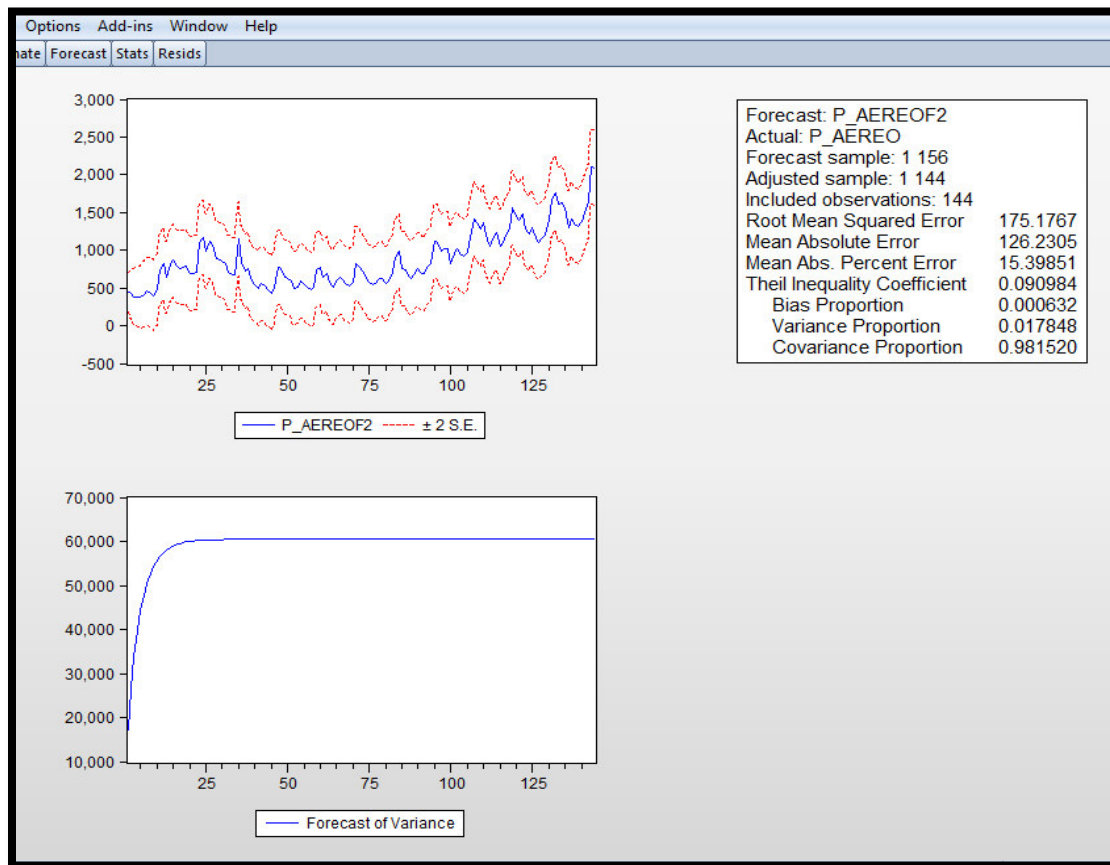
<b>SSE</b>	<b>6106616</b>
<b>MAD</b>	151.11

Fuente: Elaboración Propia

Se puede observar en el cuadro N° 4, la cual muestra la sumatoria de cuadrados de los residuos y asimismo la Desviación media absoluta para el modelo paramétrico 1 con volatilidad, estos indicadores nos permiten comparar modelos.

### Gráfico de volatilidad (predicción de la Media y Varianza)

**Gráfico de la volatilidad**



**Gráfico N° 7**

Fuente: Elaboración Propia

Se puede observar en el gráfico N° 7, la cual muestra el gráfico de la volatilidad la cual para saber si el modelo es considerado adecuado para predecir, en la figura muestra 2 gráficos una para la predicción de la media con intervalos de confianza del 95% y la otra para la predicción de la varianza, en el primero se puede observar que las bandas de confianza son muy grandes por lo que no otorgaría buenos pronósticos, y el segundo

muestra el ajuste de la varianza lo que se busca es que la curva se haga asintótica en menos de un año.

## Correlograma de los residuos

### Correlograma de los residuos para el modelo paramétrico 1




Gráfico N° 8

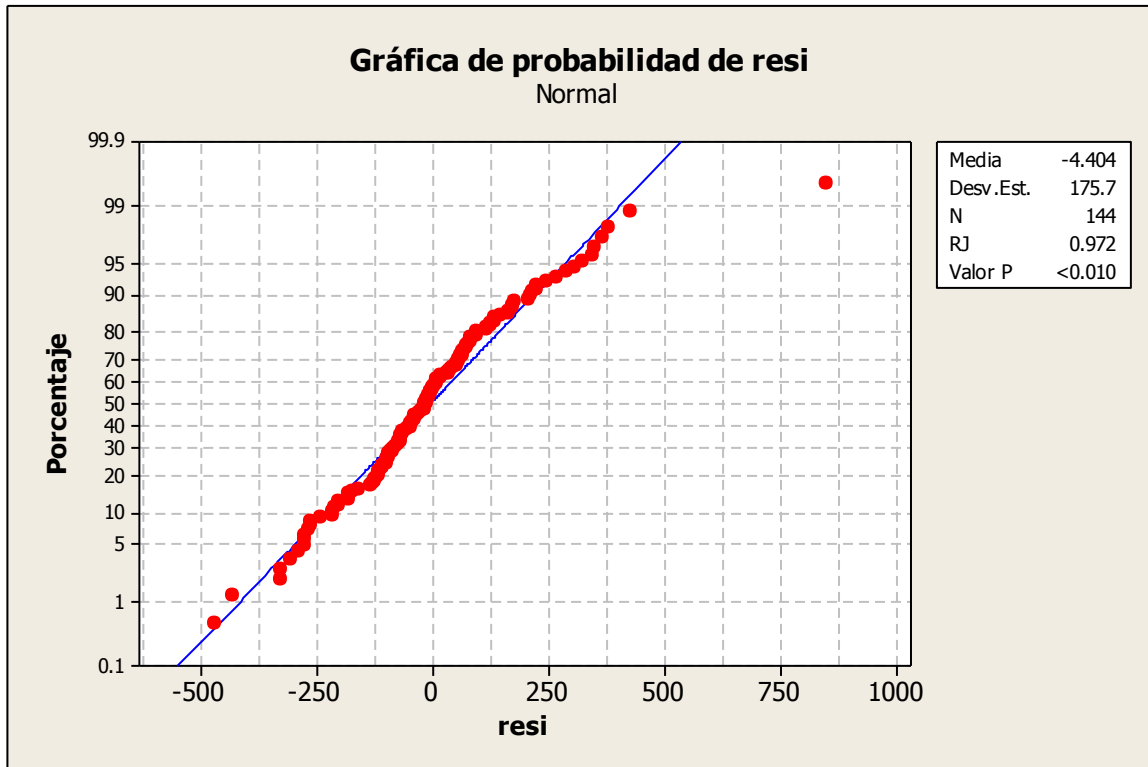
Fuente: Elaboración Propia

Se puede observar en el gráfico N° 8, en el Correlograma de los residuos para el modelo paramétrico 1 con volatilidad propuesto, nos muestra que algunas Autocorrelaciones salen de las bandas de confianza puesto no se comportan como ruido blanco esto nos da a indicar que el modelo no es el adecuado.



## Gráfico de la normalidad para los residuos

### Gráfico de probabilidad Normal para los residuos para el modelo paramétrico 1




**Gráfico N° 9**

Fuente: Elaboración Propia

Se puede observar en el gráfico N° 9, que presenta el gráfico de probabilidad normal de los residuos para el modelo paramétrico 1 con volatilidad propuesto, nos muestra que no tienen una distribución normal, puesto no se comportan como ruido blanco esto nos da a indicar que el modelo no es el adecuado o quizá sugiera una transformación.

## Análisis espectral para los residuos

**Gráfico de Densidad espectral para los residuos para el modelo paramétrico 1**




**Gráfico N° 10**

Fuente: Elaboración Propia

Se puede observar en el gráfico N° 10, que presenta el gráfico de densidad espectral para los residuos para el modelo paramétrico 1 propuesto mediante la ventana de Parzen, nos muestra que prevalece la parte aleatoria que se puede observar partir del punto 0.1, mientras nos da una idea que la tendencia y la estacionalidad no muestran indicios de ser modelado, por lo que se concluye que exploratoriamente es un buen modelo.

## Estimación y Pronóstico de la serie temporal para el modelo paramétrico 1

### Estimación y Pronóstico del Número de peruanos retornantes según año de regreso mediante medio de transporte aéreo (2001-2012)



**Gráfico N° 11**

Fuente: Elaboración Propia

Se puede observar en el gráfico N° 11, el pronóstico mediante el modelo paramétrico 1 con volatilidad propuesto para la serie de tiempo Número de peruanos retornantes según año de regreso mediante medio de transporte aéreo del año 2001 al 2012 presenta un buen ajuste con la serie original, por lo que podríamos decir que es un buen modelo.

Ahora veremos el **segundo modelo paramétrico** propuesto donde incluirá el modelamiento de la volatilidad para nuestra serie de tiempo.

### Modelo paramétrico propuesto 2

$$Z_t = 0.906319Z_{t-1} + 0.752777Z_{t-12} - 0.671823Z_{t-13} + a_t$$

$$a_t = \sqrt{h_t}\varepsilon_t$$

$$h_t = 9349.133 + 0.3616749a_{t-1}^2$$

### Validación del modelo paramétrico 2

View	Proc	Object	Print	Name	Freeze	Estimate	Forecast	Stats	Resids
Dependent Variable: P_AEREO									
Method: ML - ARCH (Marquardt) - Normal distribution									
Date: 11/27/14 Time: 17:48									
Sample (adjusted): 1 143									
Included observations: 143 after adjustments									
Convergence achieved after 14 iterations									
Presample variance: backcast (parameter = 0.7)									
GARCH = C(4) + C(5)*RESID(-1)^2									
Variable	Coefficient	Std. Error	z-Statistic	Prob.					
P_AEREO(1)	0.906319	0.022881	39.61033	0.0000					
P_AEREO(12)	0.752777	0.028433	26.47522	0.0000					
P_AEREO(13)	-0.671823	0.037167	-18.07563	0.0000					
Variance Equation									
C	9349.133	1423.501	6.567704	0.0000					
RESID(-1)^2	0.361674	0.113778	3.178775	0.0015					
R-squared	0.895871	Mean dependent var	874.0000						
Adjusted R-squared	0.894383	S.D. dependent var	375.6331						
S.E. of regression	122.0759	Akaike info criterion	12.35608						
Sum squared resid	2086355.	Schwarz criterion	12.45967						
Log likelihood	-878.4596	Hannan-Quinn criter.	12.39817						
Durbin-Watson stat	2.339002								

Figura N° 10

Fuente: Elaboración Propia

Se puede observar en la figura 10, la cual muestra la significancia de los parámetros propuestos para el modelo en cual se puede constatar que si son significativos, mientras tanto el parámetro ARCH también es significativo a un nivel de significancia del 5%.

### **Criterios de información Akaike( AIC) y Bayesiano (BIC)**

**Cuadro N° 5**  
**Criterios de selección del modelo**

<b>AIC</b>	<b>12.35</b>
<b>BIC</b>	12.45

Fuente: Elaboración Propia

Se puede observar en el cuadro N° 5, la cual muestra los criterios de información de Akaike (AIC) y el criterio de información Bayesiano (BIC) los cuales nos permite determinar con que eficiencia los modelos se ajustan, estos criterios nos permiten comparar modelos en la cual se escogerá aquellos criterios que contengan valores menores puesto que el modelo que mejor explica los datos con el mínimo de parámetros es el que presenta más bajo valor de AIC y BIC. Para el modelo paramétrico 2 presenta un AIC con un 12.35 y un BIC con un 12.45.

### **Suma de residuos al cuadrado (SSE) y la Desviación Media absoluta (MAD)**

**Cuadro N° 6**  
**Suma de Cuadrados de los Residuos y Desviación Media Absoluta**

<b>SSE</b>	<b>2243216</b>
<b>MAD</b>	93.47

Fuente: Elaboración Propia

Se puede observar en el cuadro N° 6, la cual muestra la sumatoria de cuadrados de los residuos y asimismo la Desviación media absoluta para el modelo paramétrico 2 con volatilidad, estos indicadores nos permiten comparar modelos.

### Gráfico de volatilidad (predicción de la Media y Varianza)

Gráfico de la volatilidad

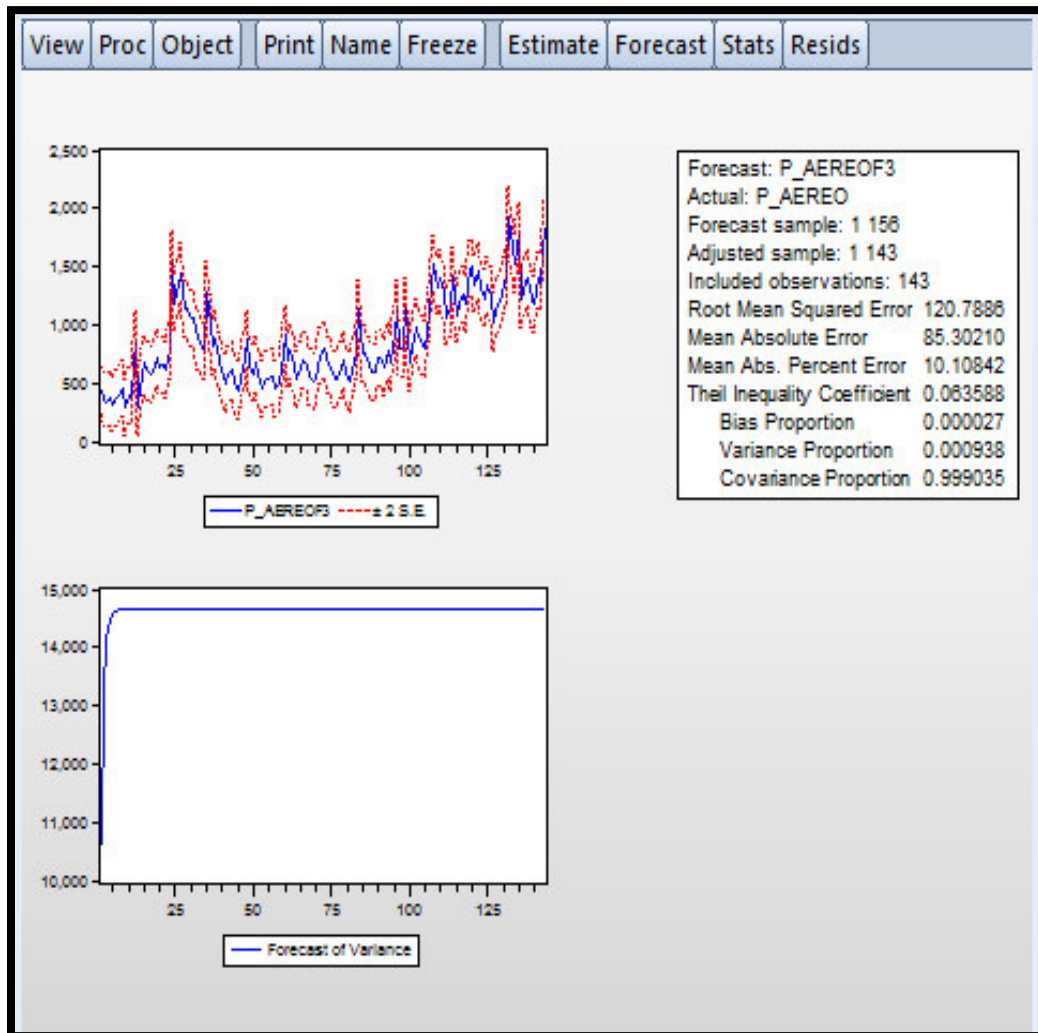


Gráfico N° 12


Fuente: Elaboración Propia

Se puede observar en el gráfico N° 12, la cual muestra el gráfico de la volatilidad la cual para saber si el modelo es considerado adecuado para predecir, en la figura muestra 2 gráficos una para la predicción de la media con intervalos de confianza del 95% y la otra

para la predicción de la varianza, en el primero se puede observar que las bandas de confianza son adecuadas por lo que otorgarían buenos pronósticos, y el segundo muestra el ajuste de la varianza en el cual muestra una la curva se haga asintótica en menos de un año.

### Correlograma de los residuos

#### Correlograma de los residuos para el modelo paramétrico 2




**Gráfico N° 13**

Fuente: Elaboración Propia

Se puede observar en el gráfico N° 13, en el Correlograma de los residuos para el modelo paramétrico 2 con volatilidad propuesto, nos muestra que solo una autocorrelación sale de las bandas de confianza pero se podría concluir que los residuos se comportan como ruido blanco.

## Gráfico de la normalidad para los residuos

### Gráfico de probabilidad Normal para los residuos para el modelo paramétrico 2



**Gráfico N° 14**


Fuente: Elaboración Propia

Se puede observar en el gráfico N° 14, que presenta el gráfico de probabilidad normal de los residuos para el modelo paramétrico 2 con volatilidad propuesto, nos muestra que no tienen una distribución normal, puesto no se comportan como ruido blanco esto nos da a indicar que el modelo no es el adecuado o quizá sugiera una transformación.



## **Análisis espectral para los residuos**

### **Gráfico de Densidad espectral para los residuos para el modelo paramétrico 2**



### **Gráfico N° 15**

Fuente: Elaboración Propia

Se puede observar en el gráfico N° 15, que presenta el gráfico de densidad espectral para los residuos para el modelo paramétrico 2 propuesto mediante la ventana de Parzen, nos muestra que prevalece la parte aleatoria que se puede observar partir del punto 0.1, mientras que la tendencia y la estacionalidad, no indican información de importancia para modelar. En consecuencia el modelo es apropiado.

## Estimación y Pronóstico de la serie temporal para el modelo paramétrico 2

### Estimación y Pronóstico del Número de peruanos retornantes según año de regreso mediante medio de transporte aéreo (2001-2012)




Gráfico N° 16

Fuente: Elaboración Propia

Se puede observar en el gráfico N° 16, el pronóstico mediante el modelo paramétrico 2 con volatilidad propuesto para la serie de tiempo Número de peruanos retornantes según año de regreso mediante medio de transporte aéreo del año 2001 al 2012 presenta un buen ajuste respecto a la serie original, por lo que podríamos decir que es un buen modelo.

Ahora veremos el **primer modelo No paramétrico** propuesto para nuestra serie de tiempo.

### Suma de residuos al cuadrado (SSE) y la Desviación Media absoluta (MAD)

**Cuadro N° 7**  
**Suma de Cuadrados de los Residuos y Desviación Media Absoluta**


SSE	3299501
MAD	116.52

Fuente: Elaboración Propia

Se puede observar en el cuadro N° 7, la cual muestra la sumatoria de cuadrados de los residuos y asimismo la Desviación media absoluta para el modelo No paramétrico 1, estos indicadores nos permiten comparar modelos.

### Correlograma de los residuos

**Correlograma de los residuos para el modelo No paramétrico 1**



**Gráfico N° 17**

Fuente: Elaboración Propia

Se puede observar en el gráfico N° 17, en el Correlograma de los residuos para el modelo No paramétrico 1 propuesto, nos muestra que algunas Autocorrelaciones salen de las bandas de confianza puesto no se comportan como ruido blanco esto nos da a indicar que el modelo no es el adecuado.

### Gráfico de la normalidad para los residuos

Gráfico de probabilidad Normal para los residuos para el modelo No paramétrico 1




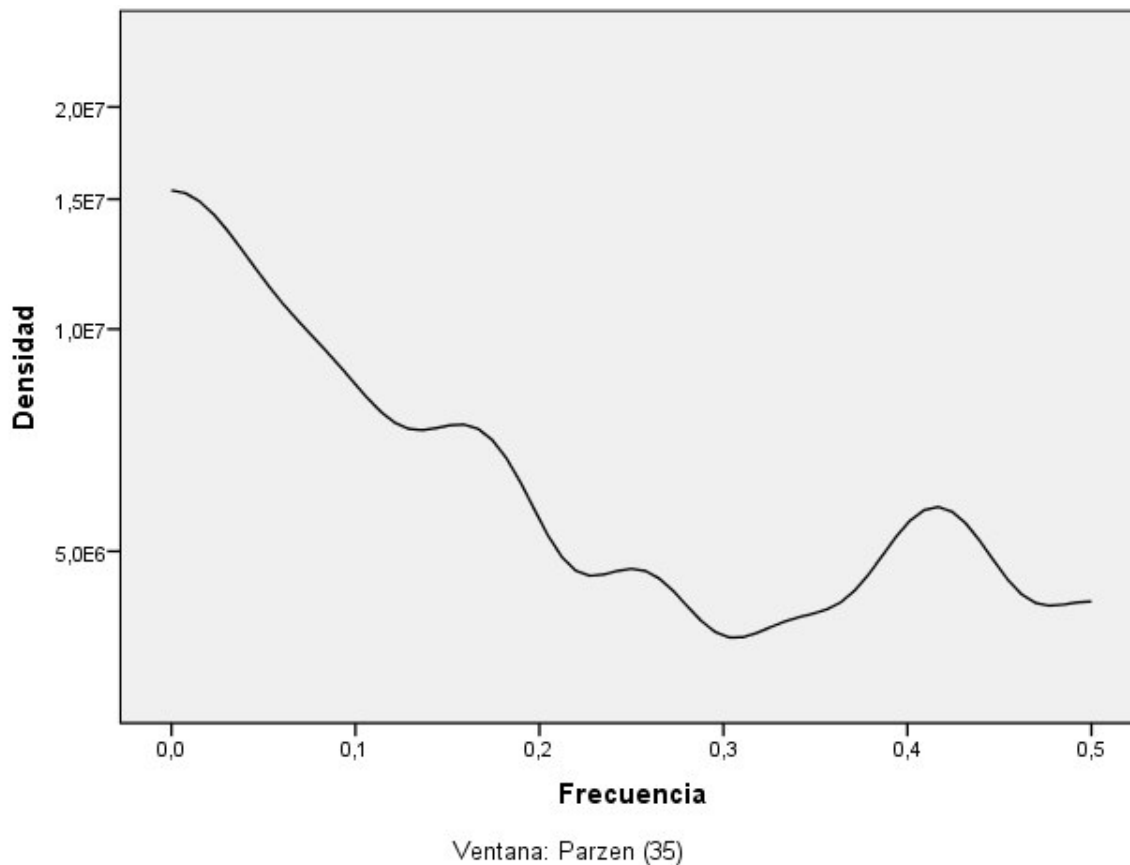
Gráfico N° 18

Fuente: Elaboración Propia

Se puede observar en el gráfico N° 18, que presenta el gráfico de probabilidad normal de los residuos para el modelo No paramétrico 1 propuesto, nos muestra que no tienen una distribución normal, puesto no se comportan como ruido blanco esto nos da a indicar que el modelo no es el adecuado o quizá sugiera una transformación.

## Análisis espectral para los residuos

**Gráfico de Densidad espectral para los residuos para el modelo No paramétrico 1**




**Gráfico N° 19**

Fuente: Elaboración Propia

Se puede observar en el gráfico N° 19, que presenta el gráfico de densidad espectral para los residuos para el modelo No paramétrico 1 propuesto mediante la ventana de Parzen, que prevalece la Estacionalidad de orden bajo cada 3 meses aproximadamente y en segundo lugar una parte Autoregresiva en la parte regular, por lo que se confirma anteriormente que el modelo escogido no es el adecuado.

## Estimación y Pronóstico de la serie temporal para el modelo No paramétrico 1

### Estimación y Pronóstico del Número de peruanos retornantes según año de regreso mediante medio de transporte aéreo (2001-2012)



**Gráfico N° 20**

Fuente: Elaboración Propia

Se puede observar en el gráfico N° 20, el pronóstico mediante el modelo No paramétrico 1 propuesto para la serie de tiempo Número de peruanos retornantes según año de regreso mediante medio de transporte aéreo del año 2001 al 2012 presenta un buen ajuste respecto a la serie original, por lo que podríamos decir que es un buen modelo.

Ahora veremos el **segundo modelo No paramétrico** propuesto para nuestra serie de tiempo.

### Suma de residuos al cuadrado (SSE) y la Desviación Media absoluta (MAD)

**Cuadro N° 8**  
**Suma de Cuadrados de los Residuos y Desviación Media Absoluta**

<b>SSE</b>	<b>1481537</b>
<b>MAD</b>	<b>77.46</b>

Fuente: Elaboración Propia

Se puede observar en el cuadro N° 8, la cual muestra la sumatoria de cuadrados de los residuos y asimismo la Desviación Media Absoluta para el modelo No paramétrico 2, estos indicadores nos permiten comparar modelos.

### Correlograma de los residuos

#### Correlograma de los residuos para el modelo No paramétrico 2




Gráfico N° 21

Fuente: Elaboración Propia

Se puede observar en el gráfico N° 21, en el Correlograma de los residuos para el modelo No paramétrico 2 propuesto, nos muestra que solo una autocorrelación sale de las bandas de confianza pero se podría concluir que los residuos se comportan como ruido blanco.

## Gráfico de la normalidad para los residuos

### Gráfico de probabilidad Normal para los residuos para el modelo No paramétrico 2




Gráfico N° 22


Fuente: Elaboración Propia

Se puede observar en el gráfico N° 22, que presenta el gráfico de probabilidad normal de los residuos para el modelo No paramétrico 2 propuesto, nos muestra que no tienen una distribución normal, puesto no se comportan como ruido blanco esto nos da a indicar que el modelo no es el adecuado o quizá sugiera una transformación.



## Análisis espectral para los residuos

### Gráfico de Densidad espectral para los residuos para el modelo No paramétrico 2



Ventana: Parzen (35)


### Gráfico N° 23

Fuente: Elaboración Propia

Se puede observar en el gráfico N° 23, que presenta el gráfico de densidad espectral para los residuos para el modelo No paramétrico 2 propuesto mediante la ventana de Parzen, que prevalece la Estacionalidad de orden bajo cada 3 meses aproximadamente y en segundo lugar una parte Autoregresiva en la parte regular, por lo que se confirma anteriormente que el modelo escogido no es el adecuado.

## Estimación y Pronóstico de la serie temporal para el modelo No paramétrico 2

### Estimación y pronóstico del Número de peruanos retornantes según año de regreso mediante medio de transporte aéreo (2001-2012)



**Gráfico N° 24**

Fuente: Elaboración Propia

Se puede observar en el gráfico N° 24, el pronóstico mediante el modelo No paramétrico 2 propuesto para la serie de tiempo Número de peruanos retornantes según año de regreso mediante medio de transporte aéreo del año 2001 al 2012 presenta un buen ajuste respecto a la serie original, por lo que podríamos decir que es un buen modelo.

# **CAPÍTULO 5**

## **DISCUSIÓN DE LOS RESULTADOS**

## V. DISCUSIÓN DE LOS RESULTADOS

### Comparación de los modelos propuestos

En este capítulo hablaremos sobre los resultados mostrados en el capítulo anterior, donde se pudo verificar que el modelamiento de la serie de tiempo Número de peruanos retornantes según año de regreso mediante medio de transporte aéreo, por medio de 5 modelos propuestos como se muestra a continuación:

- SARIMA.
- Modelo Paramétrico 1, con modelamiento en volatilidad.
- Modelo Paramétrico 2, con modelamiento en volatilidad.
- Modelo No Paramétrico 1.
- Modelo No Paramétrico 2.

El cual el mejor modelo SARIMA no cumple con algunos pruebas de verificación de residuos, como por ejemplo el gráfico del Correlograma de los residuos (ver gráfico N° 3), y fundamentalmente con el gráfico de densidad espectral para los residuos (ver gráfico N° 5) puesto esto se debe a que la serie de tiempo trabajada no cumple con el supuesto de Estacionariedad.

Para el caso del Modelamiento paramétrico 1 donde se utilizó los modelos ARCH para modelar la volatilidad que presenta nuestra serie temporal, se pudo verificar que en el gráfico de predicción de la Media y Varianza muestra que no es el adecuado para realizar predicciones (ver gráfico N° 7), asimismo no cumple con la verificación del modelo como se muestra en el Correlograma de los residuos que claramente no tienen un comportamiento de ruido blanco (ver gráfico N° 8) y el grafico de distribución normal también no cumple con ese requisito (ver gráfico N° 9).

Para el caso del Modelamiento paramétrico 2 donde se utilizó los modelos ARCH para modelar la volatilidad que presenta nuestra serie temporal, se pudo verificar que en el gráfico de predicción de la Media y Varianza muestra que es un buen modelo para

predicción de nuestra serie temporal (ver gráfico N° 12), asimismo en el Correlograma de los residuos claramente se puede verificar que los residuos tiene un comportamiento de ruido blanco (ver gráfico N° 13). También podemos observar el gráfico de densidad espectral para los residuos en el cual claramente muestra que en la parte regular solo queda aleatoriedad en la cual se utilizó ventana de Parzen (ver gráfico N° 15).

Para el caso del Modelamiento No paramétrico 1, se utilizó la metodología de las Redes Neuronales artificiales por el método de Retropropagación Resiliente donde se observó buenos pronósticos a una tasa de aprendizaje del **0.05**.

Para el caso del Modelamiento No paramétrico 2, se utilizó la metodología de las Redes Neuronales artificiales por el método de Retropropagación Resiliente donde se observó buenos pronósticos a una tasa de aprendizaje **0.005**.

# CAPÍTULO 6

## CONCLUSIONES

## VI. CONCLUSIONES

### Comparación de los indicadores de los modelos propuestos

Como se puede observar en el Cuadro N° 9, el cual muestra la tabla comparativa, nuestro objetivo general es pronosticar he considerado los siguientes indicadores que son adecuados para la comparación de modelos y a su vez adecuados si nuestro objetivo es pronosticar y comparar, en el caso de los modelos paramétricos vemos que el Modelo paramétrico 2 con modelamiento en volatilidad nos otorga menor Criterio de Información de Akaike (AIC) y el Bayesiano (BIC) comparándolo con el primero modelo paramétrico 1, con modelamiento en volatilidad, asimismo nos otorga un menor Suma de Cuadrados de Residuos (SSE) y menor Desviación media absoluta (MAD).

Por otro lado Comparando los modelos No paramétricos se observa que el segundo modelo No paramétrico nos otorga menor Suma de Cuadrados de Residuos (SSE) y menor Desviación Media Absoluta (MAD).

**Cuadro N° 9**  
**Tabla comparativa**

	<b>Tabla Comparativa</b>			
	<b>AIC</b>	<b>BIC</b>	<b>SSE</b>	<b>MAD</b>
<b>SARIMA</b>	-	-	1,686,703.55	82.18
<b>Modelo Paramétrico 1, con volatilidad</b>	13.04	13.12	6,106,616.43	151.11
<b>Modelo Paramétrico 2, con volatilidad</b>	<b>12.35</b>	<b>12.45</b>	<b>2,243,216.85</b>	<b>93.47</b>
<b>Modelo No Paramétrico 1 RNA</b>	-	-	3,299,501.33	116.52
<b>Modelo No Paramétrico 2 RNA</b>	-	-	<b>1,481,537.81</b>	<b>77.46</b>

Fuente: Elaboración Propia

Se puede concluir que el mejor modelo que nos otorga los mejores pronósticos para la serie de tiempo: Número de peruanos retornantes según año de regreso mediante medio de transporte aéreo, es el del segundo modelo No paramétrico, donde se utilizó la metodología de Redes Neuronales artificiales por el método de Retropropagación Resiliente para los pronósticos del año 2012, por lo que se puede concluir que para nuestra serie de tiempo con

cambio estructural la mejor metodología para el caso de pronóstico es la de Redes Neuronales Artificiales.

Asimismo resaltar la gran importancia de la diversidad de software utilizados en esta investigación, en el enfoque paramétrico la utilización del Eviews 8, el SPSS 21, MINITAB 16, STATA 13, y resaltar la importancia del uso del software libre R Project para la estimación y los pronósticos del enfoque no paramétrico, la cual fue de mucha utilidad para la realización de este estudio y el aporte de mi parte hacia el área académica.

Por ultimo resaltar la labor de esta investigación, puesto ayuda mucho para una contribución en el área académica, principalmente en la metodología de series de tiempo, la cual cada día existe nuevos métodos que nos ayuda a obtener una mejor estimación y unos buenos pronósticos.



# **CAPÍTULO 7**

## **RECOMENDACIONES**

## **VII. RECOMENDACIONES**

Como se pudo verificar en los capítulos anteriores, una mejor alternativa para los estudios de series de tiempo con cambios estructurales, es la metodología de las Redes Neuronales Artificiales que es muy utilizada en países como Colombia, España, Chile entre otros, para nuestro estudio se comparó 5 modelamientos desde un enfoque paramétrico y un enfoque No paramétrico, en el que el segundo modelo No paramétrico nos otorgó mejores pronósticos pues ahora nos hacemos la siguiente pregunta:

¿Se podría generalizar el hecho de que el enfoque No paramétrico nos otorga mejores pronósticos que un enfoque paramétrico?

Pues se recomienda realizar próximos estudios con más series de tiempo que presentan cambios estructurales, que será un reto para mi persona en un futuro realizar este estudio, la cual podría ser una Maestría cercana.

# **CAPÍTULO 8**

## **REFERENCIAS BIBLIOGRÁFICAS**

## VIII. REFERENCIAS BIBLIOGRÁFICAS

- A. Anastasiadis, G. Magoulas, and M. Vrahatis. New globally convergent training scheme based on the resilient propagation algorithm. *Neurocomputing*, 64:253–270, 2005.
- de Arce, R., & Mahia, R. (2010). *Modelos Arima*. (D. d. Aplicada, Ed.) España.
- Arias, F. (2006). Proyecto de investigación: Introducción a la Metodología Científica (5° ed.) Caracas: Espíteme.
- Alfonso, N. (2013). *Modelos ARCH univariantes y multivariantes*. Madrid, España: Departamento de Economía Cuantitativa.
- Analia, B. C. (2007). *MODELOS DE MEDICIÓN DE LA VOLATILIDAD EN LOS MERCADOS DE VALORES: APLICACIÓN AL MERCADO BURSÁTIL ARGENTINO*. Mendoza, Argentina.
- Andrea, S. S. (2005). *MODELADO DE CAMBIOS ESTRUCTURALES EN SERIES TEMPORALES NO LINEALES UTILIZANDO REDES NEURONALES*. Medellin, Colombia: Tesis.
- Andrea, S. S., & Velásquez, J. D. (Noviembre de 2004). Modelado de Cambios de Nivel en Series de Tiempo No Lineales Usando Redes Neuronales Artificiales. 10.
- Dolores, G. M. (2011). *Metodología Box-JenkinsEste*. Madrid, España.
- Falcón y Herrera. Análisis del ato Estadístico (Guía didáctica), Universidad Bolivariana de Venezuela, Caracas, 2005.
- Gabriel, r. H. (Mayo de 2011). UNA INTRODUCCIÓN A LOS MODELOS DE SERIES TEMPORALES NO LINEALES. 34.
- Gómez López, W. (2010). *PRONÓSTICO DE UNA SERIE TEMPORAL USANDO REDES NEURONALES*. Oaxaca, Mexico: UNIVERSIDAD TECNOLÓGICA DE LA MIXTECA.

- Javier Trujillano, J. M. (2004). *Aproximación metodológica al uso de redes neuronales*. Madrid: Grup de Recerca de Biomatemàtica i Bioestadística. Departament de Ciències Mèdiques Bàsiques. Universitat de.
- Joekes, S., P.Barbosa, E., & Robledo, w. (2005). *MODELADO Y PRONÓSTICO DE UNA SERIE DE TIEMPO CONTAMINADA EMPLEANDO REDES NEURONALES Y PROCEDIMIENTOS ESTADÍSTICOS CLÁSICOS* (Vol. 9). Córdova, Colombia: SAE.
- Jorge, P. R., & Sáez Zafra, M. (Octubre de 1994). Modelos Autoregresivos para la Varianza Condicionada Heteroscedástica. 53.
- Justel, A., Peña, D., & Sánchez, M. J. (1994). *GRUPOS DE ATÍPICOS EN MODELOS ECONÓMICOS*. Madrid.
- Kovács, Z. (1996): “Redes Neuraais Artificiais. Fundamentos e Aplicacones”. 2º Edición Collegium. SP- Brasil.
- L’Huillier, G., & Weber, R. (2010). *Introducción a la Minería de datos*. (D. d. computación, Ed.) Santiago, Chile.
- Muñoz San Roque, A., & Czernichow, T. (2006). Predicción de Series temporales no lineales con el modelado NARMAX. *Anales de mecánica y electricidad*, 12.
- Ordieres, J., Cendon, j. A., Castejon, M., & Fernandez, C. (2002). *La nueva arquitectura del paquete AMORE (A MORE Flexible Neural Network)*. Madrid, España.
- Pedro, G. (2011)., (pág. 66). Madrid.
- Rafael, d. A. (1998). *INTRODUCCIÓN A LOS MODELOS AUTORREGRESIVOS CON HETEROCEDÁSTICIDAD CONDICIONAL*. Madrid, España: Instituto LR Klein,.
- Roberto, H. S. (2006). *METODOLOGÍA DE LA INVESTIGACIÓN* (4ta ed.). Mexico.
- R. Rojas. *Neural Networks*. Springer-Verlag, Berlin,1996.
- Rolando, B. G. (2011). *Efecto de los datos atípicos discordantes y contaminantes en la implementación de las redes neuronales supervisadas Back Propagation*. Madrid.

SABINO, Carlos: El Proceso de Investigación. El Cid Editor.

Tamayo y Tamayo. El Proceso de la Investigación Científica. Limusa Noriega Editores. 4ta Edición. México. 2003.)

Velasquez, J., Zambrano, C., & Velez, I. (2011). *ARNN: un paquete para la predicción de series de tiempo usando redes neuronales autorregresivas* (Vol. 8). Colombia: Red de Revistas Científicas de América Latina, el Caribe, España y Portugal.

# CAPÍTULO 9

## ANEXOS

## IX. ANEXOS

OTROS ANEXOS NECESARIOS PARA RESPALDO DE LA INVESTIGACIÓN.

**Cuadro N° 10**  
**Número de peruanos retornantes según año de regreso mediante medio de transporte aéreo (2000-2011)**

<b>Serie</b>	<b>2000</b>	<b>2001</b>	<b>2002</b>	<b>2003</b>	<b>2004</b>	<b>2005</b>	<b>2006</b>	<b>2007</b>	<b>2008</b>	<b>2009</b>	<b>2010</b>	<b>2011</b>
<b>enero</b>	354	514	893	786	704	685	662	924	897	1244	1323	1609
<b>febrero</b>	430	515	1248	818	686	705	651	733	882	1387	1373	1668
<b>marzo</b>	393	542	1452	886	644	797	647	720	837	1505	1486	1698
<b>abril</b>	305	509	1323	620	511	585	532	592	752	987	1089	1403
<b>mayo</b>	327	455	1193	610	486	546	551	602	771	1140	1189	1346
<b>junio</b>	347	507	1155	550	552	673	596	696	907	1303	1394	1406
<b>julio</b>	392	555	1164	612	584	735	627	707	915	1231	1110	1203
<b>agosto</b>	423	599	1055	544	469	657	626	606	806	1122	1154	1375
<b>septiembre</b>	354	484	896	527	465	528	580	661	856	1181	1137	1324
<b>octubre</b>	379	612	847	445	477	546	610	813	911	1363	1238	1364
<b>noviembre</b>	419	673	934	591	542	608	702	846	1153	1441	1567	1643
<b>diciembre</b>	876	1343	1688	1021	921	995	1042	1207	1541	1709	1843	2212

Fuente: INEI



✓ El mejor **SARIMA**

**Cuadro N° 11**  
**Estimación y pronóstico del Número de peruanos retornantes según año de regreso mediante medio de transporte aéreo**  
**(2001-2012)**

<b>Pronostico</b>	<b>2000</b>	<b>2001</b>	<b>2002</b>	<b>2003</b>	<b>2004</b>	<b>2005</b>	<b>2006</b>	<b>2007</b>	<b>2008</b>	<b>2009</b>	<b>2010</b>	<b>2011</b>	<b>2012</b>
<b>Enero</b>		500.16	888.29	1214.48	469.26	475.26	626.62	696.64	942.94	1239.17	1450.71	1518.18	1847.20
<b>febrero</b>		579.70	941.74	1066.06	755.55	693.38	700.48	888.59	853.71	1202.32	1385.94	1621.14	1837.28
<b>Marzo</b>		537.20	1178.63	969.68	783.26	735.10	719.65	807.93	890.11	1330.15	1416.41	1722.76	1829.77
<b>Abril</b>		438.97	1302.46	812.68	521.71	630.59	493.43	592.40	708.77	1336.99	1197.10	1386.84	1633.21
<b>Mayo</b>		482.43	1292.36	607.38	469.85	560.40	483.93	575.73	733.89	1084.39	1177.56	1473.33	1511.39
<b>Junio</b>		483.85	1252.71	615.57	463.02	563.06	588.89	646.76	828.69	1218.38	1305.45	1531.96	1706.49
<b>Julio</b>		541.16	1224.57	598.04	570.29	681.79	641.36	723.89	915.73	1301.83	1356.58	1324.72	1552.08
<b>Agosto</b>		555.82	1199.69	579.37	536.73	650.24	557.60	665.44	848.46	1167.46	1083.89	1194.57	1506.92
<b>septiembre</b>		509.99	1002.46	436.65	407.90	604.16	527.24	554.58	796.02	1139.67	1160.67	1335.96	1590.22
<b>octubre</b>		519.67	990.68	525.44	433.02	542.66	568.90	645.55	905.22	1231.34	1250.15	1431.83	1876.42
<b>noviembre</b>		645.25	944.91	536.32	563.50	630.91	675.79	850.45	973.37	1458.39	1352.26	1575.20	2088.24
<b>diciembre</b>		1170.50	1503.94	1213.55	1107.17	1105.76	1147.22	1257.28	1496.25	1835.95	1853.47	1943.37	2629.39

Fuente: Elaboración Propia

Ahora veremos el **primer modelo paramétrico** propuesto donde incluirá el modelamiento de la volatilidad para nuestra serie de tiempo.

**Cuadro N° 12**  
**Estimación y pronóstico del Número de peruanos retornantes según año de regreso mediante medio de transporte aéreo (2000-2012)**

<b>Pronóstico</b>	<b>2000</b>	<b>2001</b>	<b>2002</b>	<b>2003</b>	<b>2004</b>	<b>2005</b>	<b>2006</b>	<b>2007</b>	<b>2008</b>	<b>2009</b>	<b>2010</b>	<b>2011</b>	<b>2012</b>
<b>enero</b>	449.08	553.28	1264.10	839.06	708.92	726.22	687.99	766.68	931.68	1429.90	1432.12	1729.66	1715.18
<b>febrero</b>	412.95	599.43	1465.37	904.55	668.97	815.58	673.46	753.13	895.63	1548.07	1545.90	1757.99	1940.09
<b>marzo</b>	328.40	578.51	1343.01	642.10	544.03	608.05	560.28	625.46	819.08	1047.82	1159.36	1482.32	1400.31
<b>abril</b>	348.08	518.53	1201.09	624.93	507.79	563.51	571.74	630.51	808.84	1175.35	1240.73	1395.87	1582.19
<b>mayo</b>	364.63	562.14	1163.37	564.86	570.16	688.76	616.30	723.49	950.34	1340.31	1438.03	1464.89	1660.42
<b>junio</b>	411.53	606.97	1168.84	629.16	608.51	751.89	651.84	741.81	967.23	1281.30	1163.65	1270.83	1405.20
<b>julio</b>	444.51	650.50	1065.70	564.45	499.51	677.34	651.48	643.49	856.64	1158.92	1195.38	1424.51	1602.73
<b>agosto</b>	379.49	531.98	906.43	541.43	491.26	551.14	600.88	691.21	899.47	1219.06	1188.33	1385.87	1830.57
<b>septiembre</b>	397.54	648.30	857.57	461.02	495.82	566.18	633.27	842.63	956.54	1396.09	1284.25	1437.95	1816.88
<b>octubre</b>	443.77	705.22	938.08	604.46	560.38	628.48	731.69	877.96	1203.31	1477.98	1608.20	1710.00	2213.90
<b>noviembre</b>	894.05	1365.24	1683.52	1028.56	934.44	1012.03	1066.00	1244.43	1587.06	1758.35	1893.61	2288.99	2717.50
<b>diciembre</b>	577.33	967.14	825.40	739.65	725.19	705.31	970.70	962.87	1311.54	1396.24	1696.44	1887.38	2870.78

Fuente: Elaboración Propia

Ahora veremos el **segundo modelo paramétrico** propuesto donde incluirá el modelamiento de la volatilidad para nuestra serie de tiempo.

**Cuadro N° 13**  
**Estimación y pronóstico del Número de peruanos retornantes según año de regreso mediante medio de transporte aéreo (2000-2012)**

<b>Pronóstico</b>	<b>2000</b>	<b>2001</b>	<b>2002</b>	<b>2003</b>	<b>2004</b>	<b>2005</b>	<b>2006</b>	<b>2007</b>	<b>2008</b>	<b>2009</b>	<b>2010</b>	<b>2011</b>	<b>2012</b>
<b>enero</b>	432.05	301.14	1216.58	827.13	674.00	711.50	779.78	747.62	802.15	1355.03	1343.38	1683.83	1708.60
<b>febrero</b>	379.59	432.48	1393.39	908.07	588.09	796.39	658.17	753.53	777.97	1431.47	1473.39	1555.71	1932.65
<b>marzo</b>	332.54	616.43	1480.81	705.38	653.28	659.98	618.54	652.93	1100.61	1252.48	1293.03	1769.13	1394.93
<b>abril</b>	366.37	561.00	1185.11	623.75	513.81	534.15	546.32	594.61	680.80	1076.51	1231.98	1232.00	1576.12
<b>mayo</b>	317.36	549.97	1179.45	507.08	472.06	641.93	537.30	612.69	811.06	1171.57	1356.14	1362.49	1654.05
<b>junio</b>	365.12	565.98	1109.44	590.75	547.76	712.38	622.52	708.01	971.87	1416.22	1247.45	1382.57	1399.80
<b>julio</b>	399.14	683.72	1087.15	618.35	525.95	657.48	692.68	683.84	887.16	1094.96	1047.67	1250.26	1596.58
<b>agosto</b>	433.67	600.39	898.18	528.49	552.21	560.25	546.49	633.93	826.68	1192.19	1176.78	1186.41	1823.55
<b>septiembre</b>	301.24	651.23	891.10	438.39	467.46	528.48	515.84	780.17	804.04	1294.39	1216.24	1387.85	1809.91
<b>octubre</b>	386.02	623.32	829.44	547.41	503.43	550.47	684.81	695.52	1110.45	1228.88	1386.63	1393.61	2205.40
<b>noviembre</b>	447.65	856.44	1388.22	769.43	668.73	773.07	809.44	961.34	1370.33	1532.31	1479.56	1889.86	2707.07
<b>diciembre</b>	821.40	1485.75	993.59	859.79	904.63	747.50	1128.59	1103.04	1501.87	1486.28	1905.09	2358.49	2770.09

Fuente: Elaboración Propia

Ahora veremos el **primer modelo No paramétrico** propuesto para nuestra serie de tiempo.

**Cuadro N° 14**  
**Estimación y pronóstico del Número de peruanos retornantes según año de regreso mediante medio de transporte aéreo**  
**(2001-2012)**

<b>Pronostico</b>	<b>2000</b>	<b>2001</b>	<b>2002</b>	<b>2003</b>	<b>2004</b>	<b>2005</b>	<b>2006</b>	<b>2007</b>	<b>2008</b>	<b>2009</b>	<b>2010</b>	<b>2011</b>	<b>2012</b>
<b>Enero</b>		633.98	1016.21	1235.19	810.30	766.45	785.28	865.09	1131.35	1305.00	1453.21	1554.99	1941.47
<b>Febrero</b>		612.28	915.06	1073.91	799.71	746.64	744.35	913.25	964.59	1260.72	1444.61	1605.82	1883.09
<b>Marzo</b>		605.34	1183.51	1160.59	856.75	778.70	795.12	844.63	962.90	1356.89	1580.46	1726.20	1918.84
<b>Abril</b>		556.55	1255.55	988.04	680.68	726.44	647.98	723.29	797.89	1264.33	1229.57	1376.00	1600.62
<b>Mayo</b>		535.68	1164.91	847.39	595.83	616.06	575.41	623.11	710.88	992.04	1138.10	1361.59	1493.23
<b>Junio</b>		538.12	1172.81	776.34	574.30	629.86	611.01	624.04	777.98	1135.66	1302.40	1468.27	1676.95
<b>Julio</b>		546.54	1092.35	702.70	583.20	648.50	639.21	662.20	824.92	1125.36	1291.88	1262.46	1415.62
<b>Agosto</b>		565.01	1074.29	734.89	601.78	657.30	650.32	686.02	807.85	1111.27	1183.14	1272.76	1617.74
<b>Septiembre</b>		580.43	932.04	657.90	569.81	658.73	626.77	644.48	784.47	1090.13	1259.53	1390.74	1856.62
<b>Octubre</b>		523.23	754.42	579.89	514.09	562.04	570.71	611.67	778.96	997.51	1237.14	1401.48	1900.35
<b>Noviembre</b>		569.81	771.14	615.91	543.48	573.41	611.99	698.88	842.58	1281.50	1435.91	1787.43	2165.75
<b>Diciembre</b>		745.80	1104.07	980.89	672.20	688.13	790.23	918.70	1191.53	1658.19	1826.94	2074.71	2443.50

Fuente: Elaboración Propia

Ahora veremos el **segundo modelo No paramétrico** propuesto para nuestra serie de tiempo.

**Cuadro N° 14**  
**Estimación y pronóstico del Número de peruanos retornantes según año de regreso mediante medio de transporte aéreo**  
**(2001-2012)**

<b>Pronóstico</b>	<b>2000</b>	<b>2001</b>	<b>2002</b>	<b>2003</b>	<b>2004</b>	<b>2005</b>	<b>2006</b>	<b>2007</b>	<b>2008</b>	<b>2009</b>	<b>2010</b>	<b>2011</b>	<b>2012</b>
<b>enero</b>		619.45	810.13	784.49	690.70	693.68	678.19	883.61	1152.61	1203.13	1462.38	1508.43	1926.69
<b>febrero</b>		566.16	1015.26	851.93	750.28	794.77	694.28	1038.13	1054.61	1269.32	1389.74	1650.77	1939.35
<b>marzo</b>		498.51	1262.72	816.48	841.61	756.92	706.29	765.87	1003.74	1386.76	1600.35	1736.74	1934.35
<b>abril</b>		516.47	1283.16	777.55	573.90	756.70	562.26	582.94	764.98	1200.86	1257.04	1318.74	1457.36
<b>mayo</b>		555.08	1274.25	803.29	552.47	581.93	552.68	558.25	797.51	989.25	1197.02	1345.66	1375.62
<b>junio</b>		487.81	1191.90	585.59	552.84	594.91	643.60	696.08	958.94	1273.03	1328.65	1422.72	1685.78
<b>julio</b>		487.33	1015.50	557.74	577.80	731.04	671.18	681.43	889.41	1146.33	1350.15	1275.40	1343.70
<b>agosto</b>		527.11	1015.48	724.04	550.84	653.95	636.04	641.57	811.17	1217.23	1364.47	1414.20	1695.67
<b>septiembre</b>		542.60	934.79	582.87	483.69	567.00	564.08	559.93	813.44	1058.00	1253.15	1387.44	1894.85
<b>octubre</b>		469.46	836.72	521.31	463.35	484.77	557.91	631.01	902.40	1160.71	1257.87	1377.78	1706.56
<b>noviembre</b>		566.62	860.67	509.88	527.80	546.97	633.91	805.27	995.85	1456.40	1528.13	1718.96	2192.36
<b>diciembre</b>		1080.43	1254.98	1074.11	783.56	904.16	1088.43	1087.72	1427.19	1704.63	1809.22	2096.19	2758.64

Fuente: Elaboración Propia

**Cuadro N° 15**  
**Número de peruanos retornantes según año de regreso mediante medio de transporte aéreo año 2012**

<b>enero</b>	<b>1754</b>
<b>febrero</b>	1984
<b>marzo</b>	1432
<b>abril</b>	1618
<b>mayo</b>	1698
<b>junio</b>	1437
<b>julio</b>	1639
<b>agosto</b>	1872
<b>septiembre</b>	1858
<b>octubre</b>	2264
<b>noviembre</b>	2779

Fuente: INEI

En el cuadro N° 15 se presenta los valores del Número de peruanos retornantes según año de regreso mediante medio de transporte aéreo para el año 2012 la cual se pudo conseguir por la fuente de información del 2012 para fines de comparación de los pronósticos de los modelos propuestos.

## Prueba de Dickey-Fuller

La prueba Dickey-Fuller se basa en asumir que la serie se puede aproximar por un proceso AR(1) con tres variantes: media cero, media diferente de cero y tendencia lineal. Inicialmente se asume que  $y_t$  sigue un modelo AR(1) y se procede a transformar el modelo de la siguiente manera en la formula (V.1)

$$y_t = \gamma_1 y_{t-1} + \varepsilon_t$$
$$y_t - y_{t-1} = (\gamma_1 - 1)y_{t-1} + \varepsilon_t \quad (V.1)$$
$$\Delta y_t = \rho y_{t-1} + \varepsilon_t$$

Donde  $\rho = \gamma_1 - 1$ . La existencia de una raíz unitaria equivale a  $\gamma_1 = 1$ , es decir, a  $\rho = 0$