

UNIVERSIDAD NACIONAL DEL ALTIPLANO

FACULTAD DE INGENIERÍA ESTADÍSTICA E INFORMÁTICA

ESCUELA PROFESIONAL DE INGENIERÍA ESTADÍSTICA E INFORMÁTICA



**MODELO DE PREDICCIÓN DE COLOCACIÓN DE CRÉDITOS DE
CAJAS MUNICIPALES EN LA REGIÓN DE PUNO 2006 - 2018**

TESIS

PRESENTADA POR:

Bach. GLORIA SOLEDAD VILLANUEVA ALVARADO

**PARA OPTAR EL TÍTULO PROFESIONAL DE:
INGENIERO ESTADÍSTICO E INFORMÁTICO**

PUNO – PERÚ

2018

UNIVERSIDAD NACIONAL DEL ALTIPLANO
FACULTAD DE INGENIERÍA ESTADÍSTICA E INFORMÁTICA
ESCUELA PROFESIONAL DE INGENIERÍA ESTADÍSTICA E INFORMÁTICA

MODELO DE PREDICCIÓN DE COLOCACIÓN DE CRÉDITOS DE CAJAS
MUNICIPALES EN LA REGIÓN DE PUNO 2006 - 2018

TESIS PRESENTADA POR:

Bach. GLORIA SOLEDAD VILLANUEVA ALVARADO

PARA OPTAR EL TITULO PROFESIONAL DE:

INGENIERO ESTADÍSTICO E INFORMÁTICO



APROBADA POR:

PRESIDENTE:



M.Sc. Samuel Donato Pérez Quispe

PRIMER MIEMBRO:



M.Sc. Luis Venturo Orbegoso

SEGUNDO MIEMBRO:



Ing. Ronald Mamani Mayta

DIRECTOR / ASESOR:



M.C. Confesor Milán Vargas Valverde

Área : Estadística
Tema : Series de tiempo
Fecha de Sustentación : 16/08/2018

DEDICATORIAS

*A Dios, al ser supremo por darme
Las fuerzas de voluntad y espiritual
Para llegar a mí meta tan anhelada.*

*A mis Padres Mariano Villanueva Pérez
y Yola Alvarado Quispe quienes son el
soporte y mi guía para seguir adelante,
a pesar de los obstáculos en mi vida
siempre están presente conmigo
apoyándome.*

*Como olvidar a mí esposo Eloy Mendoza y
Mis dos Hijos Cristhian y Airolg Por ser
Fuente de Inspiración, Motor y Motivo,
La que me llena de energías Positivas Para
Seguir escalando un peldaño Más en mí
Vida profesional.*

*Para mis cuatro hermanas por su apoyo
Moral. Que siempre están ahí en cada
Momento De mi Vida aconsejándome.*

Gloria Villanueva

AGRADECIMIENTOS

Primero quiero agradecer a Dios por llenar mi vida de dichas y bendiciones, por estar conmigo en cada paso que doy, por fortalecer mi corazón e iluminar mi mente, por haber puesto en mi camino a aquellas personas que han sido mi soporte y compañía durante todo el período de estudio.

A la Universidad Nacional del Altiplano Puno, a la Facultad de Ingeniería Estadística e Informática. En especial a los docentes, que con su amabilidad y apoyo contribuyen con mi formación profesional impartiendo sus sabios conocimientos.

Al, Ing. Confesor Vargas Valverde docente de la Escuela Profesional de Ing. Estadística e Informática por colaborar durante todo este proceso, quien con su dirección, conocimiento, enseñanza y colaboración permitió el desarrollo de este trabajo de investigación. Gracias por su guía.

Mi reconocimiento a mi Presidente. M.Sc. Samuel Donato Perez Quispe, al primer miembro del jurado M.Sc. Luis Venturo Orbegoso, y el Segundo miembro de Jurado el Ing. Ronal Mamani Mayta, por sus acertadas observaciones y las sugerencias para el desarrollo y culminación del estudio de Investigación.

Gloria Villanueva

ÍNDICE GENERAL

RESUMEN	13
ABSTRACT	14
CAPITULO I INTRODUCCION	15
1.1. PLANTEAMIENTO DEL PROBLEMA	17
1.2. JUSTIFICACIÓN DE LA INVESTIGACIÓN	18
1.3. LIMITACIONES DE LA INVESTIGACIÓN.....	19
1.4. HIPÓTESIS.....	20
1.4.1. HIPOTESIS GENERAL.....	20
1.5. OBJETIVOS DE LA INVESTIGACIÓN.....	20
1.5.1. OBJETIVO GENERAL	20
1.5.2. OBJETIVOS ESPECÍFICOS.....	20
CAPITULO II REVISION DE LITERATURA	21
2.1. ANTECEDENTES DE LA INVESTIGACIÓN	21
2.2. BASE TEÓRICA.....	23
2.2.1. COLOCACIÓN DE CRÉDITOS.....	23
2.2.2. SERIES TEMPORALES	24
2.2.3. PROCESOS ESTOCÁSTICOS	25
2.2.4. PROCESOS ESTACIONARIOS.....	25
2.2.5. PROCESOS NO ESTACIONARIOS	26
2.2.6. MODELOS	26
2.2.7. MODELOS UNIVARIANTES.....	27
2.2.8. COMPONENTES DE UNA SERIE TEMPORAL	28
2.2.8.1.LA TENDENCIA	28
2.2.8.2.LAS VARIACIONES ESTACIONALES	29
2.2.9. UTILIZACIÓN DE LAS SERIES DE TIEMPO	29
2.2.10.ANÁLISIS DE LAS SERIES DE TIEMPO	30
2.2.11.MODELO	31
2.2.12.RUIDO BLANCO.....	31
2.2.13.METODOLOGÍA BOX – JENKINS.....	32
2.2.13.1.ETAPA 1. IDENTIFICACIÓN	32
2.2.13.2.ETAPA 2. ESTIMACIÓN	33
2.2.13.3.ETAPA 3. VERIFICACIÓN DE DIAGNOSTICO	34
2.2.13.4.ETAPA 4. PRONOSTICO	35

2.2.14. ESTACIONALIDAD	36
2.2.15. NO ESTACIONARIEDAD ESTACIONAL	36
2.2.16. MODELO ARIMA ESTACIONAL.....	37
2.2.17. MODELOS LINEALES ESTACIONARIO.....	37
2.2.17.1. MODELOS AUTORREGRESIVOS (AR)	37
2.2.17.2. MODELOS DE MEDIASMÓVILES (MA)	40
2.2.18. CONDICIONES Y RAÍCES UNITARIA PARA MODELOS	41
2.2.19. LA ESTACIONARIEDAD DE LAS SERIES TEMPORALES EN LA REALIDAD	42
2.2.20. PROCESO ARIMA – NO ESTACIONARIOS.....	42
2.2.21. MODELO ARIMA (p,d,q) ARIMA (P,D,Q).....	43
2.2.22. FUNCIÓN DE AUTOCORRELACIÓN.....	43
2.2.23. FUNCIÓN DE AUTOCORRELACIÓN PARCIAL.....	44
2.2.24. HETEROCEDASTICIDAD.....	46
2.2.25. PROCESOS ARIMA ESTACIONALES.....	46
2.2.26. TRANSFORMACIÓN DE BOX-COX.....	47
2.2.27. ERROR DE PREDICCIÓN.....	47
2.3. DEFINICIÓN DE TÉRMINOS BÁSICOS	47
2.3.1. CORRELOGRAMA.....	47
2.3.2. ESTACIONARIEDAD	48
2.3.3. ESTACIONALIDAD	48
2.3.4. MODELO	48
2.3.5. MODELO DE BOX-JENKINS	48
2.3.6. PASEO ALEATORIO	48
2.3.7. PERIODO.....	49
2.3.8. POBLACIÓN.....	49
2.3.9. PRONOSTICO	49
2.3.10. RUIDO BLANCO.....	49
2.3.11. SERIE	49
2.4. OPERACIONALIZACION DE VARIABLES	50
CAPITULO III MATERIALES Y METODOS	51
3.1. LOCALIZACION.....	51
3.2. MATERIALES Y MÉTODOS	51
3.3. POBLACIÓN	51
3.4. MUESTRA	52

3.5. UNIDAD MUESTRAL.....	52
3.6. MÉTODOS DE RECOPIACIÓN DATOS	52
3.7. METODOLOGÍA	52
3.8. METODOLOGÍA DE ANÁLISIS DE DATOS.....	53
3.9. METODOLOGÍA DE BOX-JENKINS	53
3.10. FASES DE LA METODOLOGÍA BOX-JENKINS	55
3.11. PROCESO DE PREDICCIÓN.....	57
CAPITULO IV RESULTADOS Y DISCUSION	59
4.1. ANÁLISIS Y PRESENTACION DE RESULTADOS CON LA APLICACIÓN DE LA METODOLOGIA BOX – JENKINS	59
4.1.1. FASE DE IDENTIFICACIÓN DEL MODELO	60
4.1.2. FASE DE ESTIMACIÓN DEL MODELO.....	67
4.1.3. FASE DE EVALUACIÓN O VALIDACIÓN DEL MODELO	68
CAPITULO V CONCLUSIONES.....	76
CAPITULO VI RECOMENDACIONES.....	77
CAPITULO VII REFERENCIAS	78

INDICE DE GRAFICOS

GRÁFICO 1: Número de Colocaciones en las Cajas Municipales de la Región Puno, Periodo 2006 –2016.	60
GRÁFICO 2: Autocorrelaciones estimadas de la extracción mensual de la serie del Número de Colocaciones de Créditos en las Cajas Municipales de la Región puno, periodo 2006-2016.....	61
GRÁFICO 3: Autocorrelaciones parciales estimadas (FACP) de la serie del Número de Colocaciones de Créditos en las Cajas Municipales de la Región Puno, periodo 2006-2016.	62
GRÁFICO 4: Primera Diferencia no estacional por primera diferencia estacional de la Serie del Número de Colocaciones de Créditos en las Cajas Municipales de la Región Puno, periodo 2006-2016.....	63
GRÁFICO 5: Autocorrelaciones estimadas para la primera diferencia no estacional por primera diferencia estacional de la Serie del Número de Colocaciones de Créditos en las Cajas Municipales de la Región Puno, periodo 2006-2016	64
GRÁFICO 6: Autocorrelaciones parcial estimada para la primera diferencia no estacional por primera diferencia estacional de la Serie del Número de Colocaciones de Créditos en las Cajas Municipales de la Región Puno, periodo 2006-2016	65

- GRÁFICO 7:** Comparación de datos pronosticados con los datos originales para la serie del número de colocaciones de créditos en las cajas municipales de la región Puno..... **69**
- GRÁFICO 8:** Funcion de autocorrelacion estimada FAC de los residuos para la serie del número de colocaciones de créditos en las cajas municipales de la región Puno..... **70**
- GRÁFICO 9:** Funcion autocorrelacion parcial estimada FACP de los residuos para la serie del número de colocaciones de créditos en las cajas municipales de la región Puno..... **71**
- GRÁFICO 10:** Función de pronóstico de la Serie del Número de Colocaciones de Créditos en las Cajas Municipales de la Región **73**

ÍNDICE DE TABLAS

Tabla 1: Comportamientos de las FAC y FACP	46
Tabla 2: Operacionalización de variables.	50
Tabla 3: Resultados para el modelo ARIMA (3,2,0)	67
Tabla 4: Pronostico de la serie del número de colocaciones en las cajas municipales de la región Puno.....	74

ÍNDICE DE FIGURAS

FIGURA 1: Función de Autocorrelación y Autocorrelación Parcial..... **45**

FIGURA 2: Metodología del Enfoque Box - Jenkins **54**

ÍNDICE DE ACRÓNIMOS

SBS	: Superintendencia de Banca y Seguros del Perú
FAC	: Función Autocorrelacion
FACP	: Función de Autocorrelacion Parcial
S/	: Soles
MYPE	: Micro y Pequeña Empresa
CMAC	: Cajas Municipales de Ahorro y Crédito

RESUMEN

El presente trabajo de investigación, titulado “Modelo de Predicción de Colocación de Créditos de Cajas Municipales en la Región Puno, 2006 - 2018”, se realizó con el objetivo general de determinar el modelo de predicción de colocación de créditos de las cajas Municipales en la Región Puno.

Las series de colocaciones de las cajas municipales en la Región de Puno, presentaron una tendencia creciente en su comportamiento histórico, por lo que fue sometido a las transformaciones de primera diferencia a fin de estimar los comportamientos de los modelos, usando la metodología de Box – Jenkins y el modelo univariante integrado, con dicho modelo se realizó los pronósticos respectivos.

El resultado para la serie de colocaciones de créditos en las cajas municipales, se concluye de acuerdo a los resultados que el modelo de predicción mensual que mejor se ajusta para decidir y predecir el comportamiento de la serie de tiempo del número de colocaciones de créditos en las cajas municipales de la región Puno es: ARIMA (3, 2,0)₁₂. Cuya ecuación de pronóstico es:

$$\hat{Y}_t = 2Y_{t-1} + Y_{t-2} - 0.65596Y_{t-2} - 0.48307Y_{t-2} - 0.25602Y_{t-3}$$

Palabras Claves: Estimación, Modelo, Parámetros, Predicción Mensual, Colocación, Créditos.

ABSTRACT

The present research work, entitled "Prediction Model for the Loan Placement of Municipal Savings Banks in the Puno Region, 2006 - 2018", was carried out with the general objective of determining the Box - Jenkins model for the series of loan placements. Municipalities in the Puno Region.

The series of placements of the municipal savings banks in the Puno Region showed a growing trend in their historical behavior, so they were subjected to the transformations of first difference in order to estimate the behavior of the models, using the methodology of Box - Jenkins and the integrated univariate model, with that model the respective forecasts were made.

The result for the series of loan placements in the municipal savings banks is concluded according to the results of the monthly forecast model that best fits to decide and predict the behavior of the time series of the number of loan placements in the municipal boxes of the Puno region is: ARIMA (3, 2, 0).

Whose forecast equation is:

$$\hat{Y}_t = 2Y_{t-1} + Y_{t-2} - 0.65596Y_{t-2} - 0.48307Y_{t-2} - 0.25602Y_{t-3}$$

Keywords: Estimation. Model, Parameters, Monthly Prediction, Placement, Credit

CAPITULO I

INTRODUCCIÓN

Uno de los problemas que carece las cajas municipales, es que aún no existen trabajos de investigación que describan su comportamiento en el futuro de las colocaciones. Por cuanto a estudios de los modelos se series de tiempo constituye una necesidad para describir y efectuar las predicciones que estos ayuden para prever recursos humanos, infraestructura, equipamiento tecnológico y financiero para la toma de decisiones a futuro. Por lo tanto, el estudio de series de tiempo, dentro de ellos los modelos univariantes constituye una necesidad para efectuar predicciones a futuro.

La información de colocaciones de crédito de las Cajas Municipales de Ahorro y Crédito (CMAC) se obtuvo en la página web oficial de SBS (Superintendencia de Banca Seguro y AFP) correspondiente a los periodos de los años 2006 – 2016, de los mismo que fueron agrupados mensualmente, surgen de la necesidad de evaluar el comportamiento de la serie histórica, fin de tomar decisiones relacionadas con la variable de estudio.

Una serie temporal, llamada también serie histórica cronológica es una sucesión de valores observados, de una variable referida a periodos de tiempo

generalmente regulares. El análisis univariante de una serie temporal consiste en hacer uso de estos datos para elaborar un modelo que describa adecuadamente el comportamiento de esta variable en pasado y permita realizar predicciones satisfactorias – metodología estocástica ARIMA. Que resulta es uno de los métodos cuantitativos modernos de predicción más sofisticados.

En el capítulo I, se explica los fundamentos para la realización de la tesis, así como planteamiento del problema, justificación objetivos e hipótesis.

En el capítulo II, se describe el marco teórico y presenta los diversos conceptos necesarios para el correcto entendimiento de la tesis, que consiste en: antecedentes de la investigación, base teórica, definición de términos básicos y operacionalización de variables.

En el capítulo III, se describe los materiales y método para el modelo de pronóstico, para el número colocaciones de créditos en las cajas municipales de la Región Puno.

En el capítulo IV, se muestra los resultados del mejor modelo que ajuste para el número de colocaciones de créditos en las cajas municipales de la Región Puno periodo 2006 – 2016.

Por último, se muestra, las conclusiones y las recomendaciones sobre los resultados pronosticados (2017-2018) del modelo de predicción mensual de la colocación de créditos en las cajas municipales en la Región Puno.

1.1. PLANTEAMIENTO DEL PROBLEMA

El año 2017, la actividad económica del Perú fue afectada por dos crisis muy vulnerables, los casos de corrupción vinculados a Odebrecht y el fenómeno de El Niño Costero; los cuales paralizaron la inversión privada. Sin embargo, el Producto Bruto Interno (PBI) se recuperó desde el segundo trimestre del año 2016, luego que se empezaran a revertir los choques de oferta que la economía enfrentó a inicios del año.

Según reporte de la Superintendencia de Banca, Seguros y AFP (SBS) a diciembre del 2017, las colocaciones de las 11 CMAC que operan en el mercado peruano sumaron 19,318 millones de soles, lo que implica un crecimiento de 15.02% respecto a las registradas en el 2016.

Para anticiparse y proyectarse ante una demanda futura de colocaciones de créditos que deriva del rápido crecimiento de la población urbana en el Perú y por ende en la Región de Puno, a causa principal por las migraciones en las últimas décadas y consecuentemente la demanda de servicios básicos, vivienda, empleo, salud, educación, turismo y otras dimensiones que genere mayores colocaciones de créditos, lo que ocasiona la necesidad de previsión, para responder adecuadamente con personal capacitado, disponibilidad de efectivo, buena infraestructura y publicidad adecuado por parte de las cajas municipales en la región de Puno, impulsando el crecimiento de la economía peruana, motivo del presente trabajo de investigación.

Otro alcance del problema es que, en los últimos años, la población ha incrementado considerablemente, ocasionado un alto colocación de

créditos siendo necesario realizar predicciones a futuro, esto conlleva a que las cajas municipales de la región Puno, proveerá los sucesos a futuro que puede llegar a ocurrir en el transcurso de los años, para luego obtener resultado muy confiables. Es la variabilidad en el comportamiento de las colocaciones de créditos, que comprende el desarrollo económico, pretendiendo así encontrar un modelo de predicción que defina los promedios generales pretéritos en el futuro. Sin embargo, carece de información que se refiere a la predicción de colocaciones de créditos en las Cajas Municipales.

Finalmente las herramientas útiles en el planteamiento de un sistema de colocaciones es la predicción de créditos; la finalidad de la predicción es el mejoramiento del servicio hacia los usuarios, convirtiéndose en uno de los primeros pasos en cualquier proceso de planeamiento de un sistema de colocaciones.

¿Cuál es el modelo que mejor se ajusta para pronosticar el número de colocaciones de créditos de las cajas municipales en la Región Puno en periodo 2006 – 2018?

1.2. JUSTIFICACIÓN DE LA INVESTIGACIÓN

La presente investigación se realiza por la creciente dependencia de calidad de servicio de colocación de créditos en las Cajas Municipales de Ahorro y Ahorro y Crédito. Por tanto, beneficiará al sistema financiero, MYPES, persona dependiente e independiente en la Región Puno, en donde permitirá conocer a futuro el comportamiento del número de

colocaciones en las cajas municipales y así prever las necesidades. (BCRP, 2018)

El propósito de la presente investigación es ver el comportamiento de las colocaciones de las cajas municipales, que depende de la oferta y demanda. Ante esto, existe la necesidad de la banca múltiple, empresas financieras, empresas administradoras financieras, cajas municipales, cajas rurales, pymes, analistas financieros y entidades supervisoras de conocer el comportamiento futuro de las colocaciones y nace el interés de realizar pronósticos utilizando métodos de series temporales de variables a fin de realizar las acciones o proyecciones de la demanda en el mercado financiero de un nuevo producto y servicio. Implementar políticas para la mejora de colocaciones en los siguientes años, en la base de modelo obtenido. (FEPCEMAC, 2018)

La técnica estadística más empleada en series de tiempo es usando la metodología de Box – Jenkins, de manera que permitió tomar acertadas decisiones, y obtener aproximaciones certeras, cuando se hace un buen uso de las series de tiempo estacionarias o que pueda convertirse en estacionarias mediante la transformación adecuada.

Específicamente para determinar el comportamiento de la serie mensual de colocación de créditos de Cajas Municipales de Ahorro y Crédito en la Región Puno 2006 – 2016.

1.3. LIMITACIONES DE LA INVESTIGACIÓN

Una de las limitaciones para la presente investigación es la dificultad en la recopilación de información histórica mensual, donde se

encuentra en diferentes bases de datos y cambian o actualizan a cada año, mes, día, hora, por lo cual solo se obtendrá la información disponible del momento que está publicado en la página web de SBS, para la investigación.

Otra limitación es la obtención de la licencia del software, por el elevado costo, el mismo que se usó en la presente investigación.

1.4. HIPÓTESIS

1.4.1. HIPOTESIS GENERAL

Los modelos univariantes integradas de BOX – JENKINS, proporciona un mejor ajuste para la predicción mensual de colocación de créditos de las cajas municipales en la Región Puno 2006 – 2018.

1.5. OBJETIVOS DE LA INVESTIGACIÓN

1.5.1. OBJETIVO GENERAL

Determinar el modelo de predicción de colocación de créditos de las cajas Municipales en la Región Puno 2006 – 2018.

1.5.2. OBJETIVOS ESPECÍFICOS

- Estimar Validar el modelo identificado que se ajuste para predecir la serie de colocación de créditos de las cajas municipales 2006 – 2018.
- Obtener pronósticos de colocaciones de crédito, a periodos cortos de las cajas municipales.

CAPITULO II

REVISION DE LITERATUA

2.1. ANTECEDENTES DE LA INVESTIGACIÓN

Las investigaciones de proyecciones a partir de series históricas, se ha realizado en variedad de disciplinas, en la parte financiera, es conveniente mencionar las investigaciones que mucho se asemeja, aplicando herramientas estadísticas para la toma de decisiones en las políticas bancarias y/o cajas municipales.

Castro (2017), En la investigación “Modelo de Deserción de Cliente en una Financiera Usando Algoritmo de K-media y Maquinas de Soporte Vectoriales”, donde se ha determinado las variables que más afectan en la deserción de un cliente utilizando dos modelos diferentes. Se analizó cada uno de los costos, ahorros e ingresos que incurre cada alternativa con el fin de poder construir el flujo de caja. Se ha determinado los ratitos financieros como el TIR, VPN y B/C cada alternativa.

Vergara & Bernal (2012), en la investigación “Influencia de la Participación de Mercado de Colocaciones y la Eficiencia de la Caja Municipal de Ahorro y Crédito de Trujillo en su Rentabilidad en el Periodo 2005 - 2011”, demuestran que la participación en el mercado de colocaciones y la eficiencia influyen positivamente en la rentabilidad así también determinan que la cuota de mercado la rentabilidad también disminuirá y por el contrato los ratios deposito tiene un impacto negativo, lo que no influye en la rentabilidad.

Aguilar (2013), en su tesis titulado “Modelo de Pronóstico para Colocaciones de Créditos Hipotecarios en el Perú”, obteniéndose el modelo ARIMA (p,d,q) para créditos hipotecarios totales, Bancos, edpyes, cajas municipales y financieras.

Rayo & Lara & Camino (2010), en la investigación titulado “Un Modelo de Crédito Scoring para Instituciones de Micro finanzas en el Marco de Basilea II”, donde se ha diseñado un modelo de créditoscoring para una institución sometida a supervisión y especializada en microcréditos, como es la entidad de desarrollo de la pequeña y micro empresa (Edpyme) del sistema financiero del Perú. El resultado de la investigación muestra la metodología y fases necesarias para diseñar el modelo, así como el proceso de valoración y validación para que pueda ser aplicado en el área de negocio, especialmente para establecer la política de tasas de interés con clientes. Por último, también se muestra cómo puede utilizarse el modelo para desarrollar una gestión de riesgo de crédito en el marco de los métodos IRB de Basilea II.

Kala (2008), en la tesis de maestría titulada “Caracterización del Comportamiento del Mercado de Microcrédito Empresarial Peruano (2006 – 2006)”, se demuestra que el mercado microcrédito empresarial tiene un comportamiento de oligopolio – Cournot, mostrando un índice conjetural global de $a = 0.65$, en donde las empresas participantes maximizan sus beneficios en relación a su propio nivel de producción, considerando que sus rivales mantendrán sus niveles de producción constante.

2.2. BASE TEÓRICA

2.2.1. COLOCACIÓN DE CRÉDITOS

La función principal de los bancos es intermediar los fondos disponibles, provenientes de las captaciones y recursos propios aportados por los accionistas y los generados por el negocio, a personas o empresas debidamente identificados y que son calificados como sujetos de crédito.

Cada entidad financiera desarrolla estrategias de promoción de sus servicios, para seleccionar clientes que le garanticen el retorno financiero a otorgar en las condiciones de riesgo previstas. Entre las principales modalidades de colocación, es decir los financiamientos que otorga la banca múltiple, se muestran en y corresponden a las siguientes.

Prestamos, son los denominados créditos bancarios, los que tienen un calendario de pago que se pacta y en el que los intereses usualmente se pagan por periodo vencido.

Descuentos, son créditos en los que los intereses se pagan por periodo adelantado y el capital al final de cada periodo, normalmente se aplican para descontar letras comerciales de cliente previamente calificados por el banco.

Cuentas Corrientes, son facilidades crediticias denominadas también sobregiros bancarios, los que se cancelan con las cobranzas previstas y/o depósitos que realice el cliente en un plazo prudencial.

Arrendamiento Financiero, en este caso el banco adquiere un bien seleccionado por la empresa que ha sido calificado apto para el financiamiento y lo entrega en “alquiler con opción de compra al finalizar el contrato de leasing” y a cambio la empresa paga al banco una cuota que comprende capital e intereses del financiamiento.

Otras Colocaciones, se refiere a créditos por liquidar, reprogramaciones, así como créditos vencido y en cobranza judicial. El diferencial entre tasas de interés pasivas y activas sigue siendo alta, es especial, si se compara con las tasas de interés del mercado.

2.2.2. SERIES TEMPORALES

Una serie temporal (o simplemente una serie) es una secuencia de N observaciones (datos) ordenados y equidistantes cronológicamente sobre una característica (serie univariante o escalar) o sobre varias características (serie multivariantes o vectorial) de una unidad observable en diferentes momentos.

Representaciones matemáticas frecuentes de series temporales univariantes:

$y_1, y_2, \dots, y_N; (y_t)_{t=1}^N; (y_t : t = 1, \dots, N)$, Donde y_t es la observación n° t ($1 \leq t \leq N$) de la serie y N es el número de observaciones de que consta la serie completa (el tamaño o la longitud de la serie). Las N observaciones y_1, y_2, \dots, y_N pueden recogerse en un vector columna $y \equiv [y_1, y_2, \dots, y_N]^t$ de orden $N \times 1$.

2.2.3. PROCESOS ESTOCÁSTICOS

Un proceso estocástico es una secuencia de variables aleatorias, ordenadas y equidistantes cronológicamente, referidas a una (procesos univariantes o escalar) o a varias (proceso multivariante o vectorial) características de una unidad observable en diferentes momentos.

2.2.4. PROCESOS ESTACIONARIOS

Un proceso estocástico (y_t) es estacionario cuando las propiedades estocásticas de cualquier secuencia finita $Y_{t_1}, Y_{t_2}, \dots, Y_{t_n}$ ($n \geq 1$) de componentes de (Y_t) son semejantes a las de la secuencia $Y_{t_1+h}, Y_{t_2+h}, \dots, Y_{t_n+h}$ para cualquier número entero $h = \pm 1, \pm 2, \dots, \pm n$.

2.2.5. PROCESOS NO ESTACIONARIOS

Un proceso estocástico (Y_t) es no estacionario cuando las propiedades estadísticas de al menos una secuencia finita $Y_{t_1}, Y_{t_2}, \dots, Y_{t_n}$ ($n \geq 1$) de componentes de (Y_t) , son diferentes de las de la secuencia $Y_{t_1+h}, Y_{t_2+h}, \dots, Y_{t_n+h}$ para al menos un número entero $n > 0$.

2.2.6. MODELOS

Un modelo para un proceso estocástico es cualquier conjunto de hipótesis bien definidas sobre las propiedades estadísticas de dicho proceso.

MODELOS UNIVARIANTES

Ruido blanco – ARIMA (0,0,0)

Un proceso de ruido blanco univariante es una secuencia (A_t) de variable aleatorio escalares idéntica e independientemente distribuidas con media 0 y varianza σ_A^2 , lo cual suele representarse como $(A_t) \sim \text{IID}(0, \sigma_A^2)$.

Cuando cada A_t sigue una distribución normal, (A_t) se denomina un proceso de ruido blanco normal o gaussiano, lo cual suele representarse como $(A_t) \sim \text{NIID}(0, \sigma_A^2)$.

Modelo AR (1) – ARIMA (1, 0,0).

Un proceso estocástico univariante estacionario (Y_t) sigue un modelo **AR (1)** (autorregresivo de orden 1) cuando.

$$Y_t = \mu + \phi Y_{t-1} + A_t \text{ Para todo } t = 0, \pm 1, \pm 2, \dots,$$

Donde μ y ϕ son parámetros, $|\phi| < 1$ (condición de estacionariedad), y

$$(A_t) \text{ IID}(0, \sigma_A^2) \dots$$

Modelo MA (1) – ARIMA (0, 0, 1)

Un proceso estocástico univariante estacionario (Y_t) sigue un modelo MA

(1) (media móvil de orden 1) cuando

$$y_t = \mu + A_t - \theta_1 A_{t-1} \text{ Pata toda } t = 0, \pm 1, \pm 2, \dots,$$

Donde μ y θ_1 son parámetros, $|\theta_1| < 1$ (condición de invertibilidad), y

$$(A_t) \sim \text{IID}(0, \sigma_A^2).$$

Paseo aleatorio – ARIMA (0, 1, 0)

Un proceso estocástico univariante no estacionario (Y_t) es un paseo aleatorio cuando

$$Y_t = \mu + Y_{t-1} + A_t \text{ Para todo } t = 0, \pm 1, \pm 2, \dots,$$

Donde μ es un parámetro (que en muchas ocasiones vale cero) y

$$(A_t) \sim \text{IID}(0, \sigma_A^2).$$

Modelos multivariantes estacionarios


2.2.7. MODELOS UNIVARIANTES

Un modelo univariante para un proceso estocástico univariante o escalar (Y_t) es cualquier conjunto de hipótesis bien definidas sobre ciertas

propiedades teóricas de las distribuciones de probabilidad (conjuntas, marginales, o condicionales) de los componentes del proceso (Y_t) del que se supone procede una serie temporal observada $(Y_t)_{t=1}^N$.

Etapas en la construcción de un modelo univariante

- **Identificación:** Selección de un modelo que implique ciertas propiedades teóricas para (Y_t) . Compatibles con las propiedades muestrales observadas en $(Y_t)_{t=1}^N$.
- **Estimación:** Asignación de valores numéricos a los parámetros del modelo.
- **Diagnosis:** comprobación del ajuste del modelo a los datos utilizados.



2.2.8. COMPONENTES DE UNA SERIE TEMPORAL

2.2.8.1. LA TENDENCIA

Es un componente de una serie temporal que refleja su evolución a largo plazo. Puede ser de naturaleza estacionaria y constante (se representa con una recta paralela al eje de las abscisas), de naturaleza línea, parabólica, exponencial (Hamilton, 1994).

2.2.8.2. LAS VARIACIONES ESTACIONALES

Es un componente de la serie que recoge oscilaciones que se producen alrededor de la tendencia, de forma repetitiva y en periodos iguales o inferiores a un año por ejemplo, el clima afecta a la venta de una serie de productos, los helados y refrescos se venden fundamentalmente en verano y la ropa de abrigo en invierno, entre los factores más importantes que origina variaciones estacionales, se encuentran las condiciones climáticas, las costumbres sociales y las fiestas religiosas (Hamilton, 1994).

2.2.9. UTILIZACIÓN DE LAS SERIES DE TIEMPO

Una de las herramientas estadísticas para uso en pronósticos de sucesos futuros que están, en alguna forma, entrelazadas con la economía es el análisis de tiempo. Los fabricantes están en extremo interesados en los ciclos de altibajos de la propia económica así de las economías extranjeras de modo que puedan predecir mejor la demanda de sus productos, que a su vez impacta sus niveles de inventarios, requerimientos de personal, flujos de efectivo y casi todas las demás actividades de negocios dentro de la empresa.

“Los científicos políticos están interesados en el uso de análisis de series de tiempo para estudiar los patrones de cambio de los gastos de gobierno en defensa y programas de bienestar social. Es obvio que estas tendencias tienen un gran impacto en el futuro de industrias complejas” (Hanke, 1996).

2.2.10. ANÁLISIS DE LAS SERIES DE TIEMPO

(Anderson, 1985) el análisis de series de tiempo está dedicado al estudio de series, por lo general, los datos de dichas series son independientes, pero están correlacionados; se puede decir que existe una relación entre observaciones contiguas.

Es el análisis de una secuencia de medidas hechas a intervalos específicos. El tiempo es usualmente la dimensión dominante de los datos. Sirven para establecer la efectividad de medidas que afecta a grupos poblacionales teniendo en cuenta las variaciones naturales que puede haber en el tiempo. Son muy comunes en la evaluación de leyes en la población. Permiten una visión parcial de la relación causa efecto, pero no pueden extrapolar los hallazgos de la población a individuos específicos.

El análisis de series de tiempo consiste en una descripción de los movimientos y componentes presentes.

De acuerdo a Chatfield (1978), son varios objetivos por los cuales se desea analizar una serie de tiempo.

Descripción: al tener una serie de tiempo, el primer paso en el análisis es graficar los datos y obtener medidas descriptivas simples de las propiedades principales de la serie.

Explicación: Cuando las observaciones son tomadas sobre dos o más variables, es posible usar la variación en una serie para explicar la variación en las otras series.

Predicción: dada una serie de tiempo se intenta predecir los valores futuros de la serie. Este es el objetivo más importante en el análisis de series de tiempo.

Control: si una serie se genera por mediciones de calidad de un proceso, el objetivo del análisis puede ser control del proceso.

2.2.11. MODELO

Un modelo es expresado, en símbolos de toma matemática. Para la construcción de un buen modelo es necesario contar con el conjunto de datos observados. También es importante la experiencia, la intuición, la imaginación, la simplicidad y la habilidad para seleccionar el subconjunto más pequeño de variables. El primer paso es establecer el problema en forma clara y lógica delimitando sus fronteras, luego viene la recogida y la depuración de datos, el diseño del experimento; las pruebas de contraste, la verificación del modelo y la validación de las hipótesis (Andre, 1994)

Un modelo debe ser una buena aproximación al sistema real, debe incorporar los aspectos importantes del sistema y debe resultar fácil de comprender y manejar. Un factor muy importante es que debe presentar una alta correlación entre lo que predice el modelo y lo que actualmente ocurre en el sistema real (Andrew, 1994)

2.2.12. RUIDO BLANCO

Uriel (1985). El ruido blanco es una señal aleatoria (proceso estocástico) que se caracteriza porque sus valores de señal en dos instantes de tiempo diferentes no guardan correlación estadística. Como

consecuencia de ello, su densidad espectral de potencia es una constante, si grafica plana. Esto significa que la señal contiene todas las frecuencias y todas ellas tienen la misma potencia. Igual fenómeno ocurre con la luz blanca, lo que motiva la denominación.

2.2.13. METODOLOGÍA BOX – JENKINS

La publicación de G.P.E. Box y G.M. Jenkins “Times Series Análisis: Forecasting and Control” en la década de los 70’s genero un nuevo conjunto de herramientas de predicción, cuyo procedimiento se la llamo metodología Box – Jenkins; también técnicamente conocida como metodología ARIMA.

Este método de predicción se basa en el análisis de las propiedades probabilísticas o estocásticas de las series de tiempo en sí mismas, pues una variable Y_t puede ser expresada como una función de sus valores pasados, razón por la que algunas veces se les denomina modelo teórico, donde no existe relación causal alguna a diferencia de los modelos clásicos de regresión.

Procedimientos

Las etapas que se deben seguir en la elaboración de un modelo ARIMA con fines predictivos son las siguientes.

2.2.13.1. ETAPA 1. IDENTIFICACIÓN

Es fase consiste en detectar que tipo de proceso estocástico ha generado los datos. Esto significa encontrar los valores adecuados de p , d

y q del modelo ARIMA. Las herramientas fundamentales en la identificación son el correlograma muestral y el correlograma parcial muestral.

Es importante tener en cuenta que antes de usar los criterios de identificación FAC y FAP se debe lograr una serie estacionaria. Para ello, se efectúan las pruebas de estacionalidad a la serie original. En caso de que esta no sea estacionaria, la variable puede diferenciarse d veces hasta que esta sea estacionaria. Mediante este procedimiento se identifica el orden de integración d del modelo ARIMA.

Puesto que en la práctica no se observan la FAC y la FAP teóricas, se usan las FAC y FAP estimadas, las cuales presentan cierto error estadístico. Lo que se busca es encontrar la mayor exactitud entre la FAC y la FAP teóricas y estimadas, en tanto que la identificación del modelo ARIMA requiere la habilidad, la cual se obtiene con la práctica.

Cabe anotar, que, en el procedimiento de identificación de p y q , se consideran aquellos rezagos estadísticamente significativos, por lo cual no es necesario incluir rezagos intermedios hasta p o q si estos no son significativos.

2.2.13.2. ETAPA 2. ESTIMACIÓN

En esta etapa se estiman los coeficientes de los términos autorregresivos y de media móvil incluidos en el modelo, cuyo número de rezagos p y q ya han sido previamente identificados en la etapa anterior.

Teóricamente el método de mínimos cuadrados ordinarios en la medida que las muestras sean grandes posee propiedades asintóticas, esto quiere decir que se generan estimadores asintóticamente consistentes y convergen en una distribución normal, por lo que las pruebas hipótesis convencionales sobre los parámetros del modelo serán válidas.

La estimación del modelo ARIMA (p, q) se efectúa para la serie que se ha comprobado es estacionaria. En la práctica los modelos más comunes son los autorregresivos. Hamilton cita que muchas de las series se pueden representar por medio de un modelo AR (1). Sin embargo, de acuerdo con el teorema de descomposición del Wold, el modelo ARMA debería ser la primera opción, teniendo en cuenta que la inclusión de términos adicionales MA son poco comunes y en la práctica a todos los modelos se les incorpora la constante o intercepto.

2.2.13.3. ETAPA 3. VERIFICACIÓN DE DIAGNOSTICO

En esta etapa se busca evaluar si el modelo estimado se ajusta a los datos en forma razonablemente buena, ya que es posible que exista otro modelo ARMA que también lo haga. A esta etapa también se le conoce como validación o comprobación de diagnóstico en la cual se efectúan algunas pruebas antes de hacer uso del modelo para predicción.

La validación o verificación incluye el análisis de los coeficientes o parámetros del modelo la evaluación de la bondad de ajuste y análisis de los residuos.

- a) Análisis de los coeficientes
- b) Bondad de ajuste
- c) Análisis de los residuos

2.2.13.4. ETAPA 4. PRONOSTICO

Para pronosticar un periodo futuro a partir del modelo seleccionado; es decir aquel que es “el mejor” resultante de las etapas anteriores, es importante considerar si la variable original fue diferenciada.

Síntesis de la metodología Box – Jenkins

1. Identificación

Utilizar: FAC estimada

FAP estimada

2. Estimación

Usar:

Mínimos cuadrados ordinarios lineales

Mínimos cuadrados ordinarios no lineales

3. Verificación

Evaluar:

Los coeficientes (estacionariedad, invertibilidad y significancia estadística)

La bondad de ajuste

Los residuos

4. Pronóstico: indicar el periodo de predicción

2.2.14. ESTACIONALIDAD

Si no fuera por la estacionalidad, el análisis de las series temporales se convertiría en una tarea muy simple. De hecho, la mayoría de las series temporales, e ciencia psicológica y social, quedarían bien representadas por los modelos de orden inferior, estos modelos cubren gran parte de los procesos temporales fácilmente identificables. Por desgracia, suele ocurrir que las series temporales presentan ciclos de carácter mensual, trimestral, anual, etc. De modo que se hallan afectados por fuertes componentes estacionales.

La estacionalidad se define por una fluctuación cíclica o periódica de la serie temporal que se repite de forma regular. Desde un punto de vista analítico, la estacionalidad constituye una variación del proceso se debe ser extraída o controlada. Una forma de control de la variación estacional consiste en desestacionar la serie antes de su análisis.

El mejor procedimiento para el manejo de la estacionalidad es construir un modelo causal de las fuerzas estacionales.

2.2.15. NO ESTACIONARIEDAD ESTACIONAL

Un proceso observado o realización empírica puede presentar una inclinación o tendencia en pasos o incrementos, por ejemplo, anuales. Por dicha razón a fin de tener en cuenta la inclinación o tendencia estacional, la serie debe ser diferenciada estacionalmente. Así con datos mensuales se sustrae Y_t de Y_{t-13} y Y_{t-1} de Y_{t-14} , etc. Este proceso se define, mediante el operador de diferencia, por:

$$(1 - \Delta^{12}) y_t = \theta_0$$

$$y_t = y_{t-12} + \theta_0$$

2.2.16. MODELO ARIMA ESTACIONAL

A partir de los puntos anteriores, es posible expresar el modelo estacional ARIMA, en términos generales, por ARIMA(p,d,q)(P,D,Q)S, donde P,D,Q son análogos a los parámetro p,d,q, el parámetro S simboliza la longitud del periodo o ciclo. De esta forma. Con los datos mensuales S=12. Al modelizar procesos estacionales, solemos incorporar tanto estructuras regulares como estacionales de forma aditiva.

2.2.17. MODELOS LINEALES ESTACIONARIO

2.2.17.1. MODELOS AUTORREGRESIVOS (AR)

Definimos un modelo como autorregresivo si la variable endógena de un periodo t es explicada por las observaciones de ella misma correspondientes a periodos anteriores añadiéndose, como en los modelos estructurales, un término de error. En este caso procesos estacionarios con distribución normal, la teoría estadística de procesos estocásticos afirma que, bajo determinadas condiciones previas, toda Y_t puede expresarse como una combinación lineal de sus valores pasados.

Los modelos autorregresivos se abrevian con la palabra AR tras la que se indica el orden del modelo: AR (1), AR (2), etc. El orden del modelo expresa el número de observaciones retrasadas de las series de tiempo analizadas que intervienen en la ecuación.

La expresión genérica de un modelo autorregresivo AR (p) sería de la siguiente forma:

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t$$

Dónde: ε_t es una variable “ruido blanco”, siempre y cuando lo siguiente:

- i. Media nula
- ii. Varianza constante
- iii. Covarianza nula entre errores correspondientes a observaciones diferentes.

Los procesos AR (p), también se puede escribir de forma abreviada como:

$$\phi_p(L)Y_t = \delta + \varepsilon_t$$

Donde $\phi_p(L)$ es lo que se conoce como operador polinomial de retardos:

$$\phi_p(L) = 1 - \phi_1 L - \phi_2 L^2 - \phi_3 L^3 - \dots - \phi_p L^p$$

Y donde, a su vez el termino L, es el que se conoce como operador retardo tal que, implicado al valor de una variable en t, dé como resultado el valor de esa misma variable en t-1:

$$LY_t = Y_{t-1}$$

Y aplicando sucesivamente p veces retarda, el valor en p periodos.

$$L^p Y_t = Y_{t-p}$$

Normalmente, se suele trabajar con modelos autorregresivos de ordenes bajos: AR (1), AR (2), o bien con órdenes coincidentes con la

prioridad de datos de la serie analizada, si es trimestral AR (4), si es mensual AR (12). Si resulta que $p=12$ para todos mensuales, el modelo autorregresivo establece un modelo de índices estacionales que son los coeficientes estimados. Como se mencionó previamente, puede eliminarse el propio patrón estacional para investigar si hay otro modelo que abarca varios años, o si el modelo se extiende un plazo más largo. Naturalmente, el modelo autorregresivo puede también revelar variaciones cíclicas menores de doce meses. Se debe tener en cuenta que es necesario imponer ciertas restricciones a los valores de los parámetros de este modelo para que funciones correctamente estacionario.

- **MODELO AR(1)**

Un modelo AR (1) viene definido por:

$$Y_t = \phi_1 Y_{t-1} + \varepsilon_t$$

Entonces utilizando el operador de retardos para un modelo AR(1) sería de la siguiente forma:

$$(1 - \phi_1 L) Y_t = \varepsilon_t$$

Donde ε_t es ruido blanco

- **MODELO AR(2)**

Un modelo AR (2) viene definido por:

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \varepsilon_t$$

Así mismo aplicando para un modelo AR (2), su operador de retardos sería de la siguiente forma:

$$(1 - \phi_1 L - \phi_2 L^2) Y_t = \varepsilon_t$$

2.2.17.2. MODELOS DE MEDIAS MÓVILES (MA)

Un modelo de Box – Jenkins denominados de medias móviles es aquel que explica el valor de una determinada variable en un periodo t, en función de un término independiente.

Las medias móviles son indicadores que allanan o suavizan, en mayor o menor medida, de tal manera que eliminen determinadas fluctuaciones, sean a corto, medio o largo plazo.

Estos modelos se denotan normalmente con las siglas MA, seguidos como en el caso de los modelos autorregresivos, del orden entre paréntesis. La notación, MA (q) que se refiere a un modelo de media móvil de orden q. entonces la expresión genérica de un modelo autorregresivo MA (q).

Obsérvese que el proceso de medias móviles corresponde a una combinación lineal de variables ruido blanco, siendo los coeficientes “theta” los “ponderados” de la combinación lineal. Esto es, se asemeja a la definición de un “promedio” de las variables ruido blanco.

- **MODELO MA(1)**

Un modelo MA (1) viene definido por:

$$Y_t = \alpha_t - \theta_1 \alpha_{t-1} = (1 - \theta_1 L) \alpha_t$$

Dónde α_t . Es un ruido blanco con las propiedades definidas.

- **MODELO MA(2)**

Un modelo MA (2) viene definido por:

$$Y_t = \alpha_t - \theta_1 \alpha_{t-1} - \theta_2 \alpha_{t-2} = (1 - \theta_1 L - \theta_2 L^2) \alpha_t$$

Donde α_t es un ruido blanco

2.2.18. CONDICIONES Y RAÍCES UNITARIA PARA MODELOS

Hemos afirmado anteriormente que, bajo condiciones generales de todo el proceso estocástico se presenta una especificación tipo AR (p) y en consecuencia podía expresarse también como un MA (q). Es ahora el momento para especificar lo que antes hemos llamado “condiciones generales” y examinar en qué casos es posible la realización de un proceso AR o MA para representar un proceso estocástico estacionario.

Para que un proceso estocástico estacionario admita una formulación, aquí estudiaremos que deben de cumplir dos condiciones importantes.

El proceso debe ser anticipante (hipótesis de recursividad temporal), lo que quiere decir que los valores de una variable en un momento t, no dependerán de los esta misma tome en t+k, siendo k cualquier valor superior a cero.

El proceso ha de ser invertible, lo que supone que la correlación entre una variable y su pasado va reduciéndose a medida que nos alejamos en el tiempo del momento para el que estamos considerando dicha correlación.

2.2.19. LA ESTACIONARIEDAD DE LAS SERIES TEMPORALES EN LA REALIDAD

En términos generales vemos que a, aquellos procesos estocásticos que cumplan, al menos de forma débil, la restricción de la estacionariedad. Cuando en la realidad queremos inferir a partir de una serie temporal (muestra), la estructura del proceso estocástico mediante modelo AR o Ma, debemos cubrir dos etapas importantes.

Primeramente, demos asegurarnos de que la serie temporal, como muestra del proceso estocástico, es estacionaria y, si no lo es. Hay que transformar la serie temporal original de tal forma que la nueva serie transformada si lo sea.

2.2.20. PROCESO ARIMA – NOESTACIONARIOS

La mayor parte de las series económicas corresponden a proceso no estacionarios. Así, se desea obtener un tratamiento de las series basado en el “análisis de series de tiempo” (MODELOS ARMA), es necesario discutir mecanismos de transformación de las series a proceso estacionarios.

En 1970, Box y Jenkins desarrollaron un cuerpo metodológico destinado a identificar, estimar y diagnosticar modelos dinámicos de series temporales en los que la variable tiempo juega un papel fundamental.

2.2.21. MODELO ARIMA (p, d, q) ARIMA (P, D, Q)

Generalmente se suele expresar como ARIMA (p, d, q) donde los parámetros p, d y q son números enteros no negativos que indican el orden de las distintas componentes del modelo respectivamente, las componentes autorregresivo, integrada y de media móvil. Cuando alguno de los tres parámetros es cero, es común omitir las letras correspondientes de acrónimo AR para el componente autorregresivo, I para integrada y MA para la media móvil.

En su forma más general el modelo ARIMA (p, d, q) ARIMA (P, D, Q) se podría escribirse como:

Entendiendo que puede haber más de un proceso generador de la serie (en la parte regular y en la estacional) y escribiendo una combinación de los modelos MA (q) y AR (p) que han precisado de una serie de diferenciaciones “d” en la parte regular p “D” en la parte estacional para que fueran estacionarios.

2.2.22. FUNCIÓN DE AUTOCORRELACIÓN

La función de autocorrelación (fac) y la función de autocorrelación parcial (facp) miden la relación estadística entre las observaciones de una serie temporal. Por ejemplo, el coeficiente de autocorrelación entre la variable y_t y la misma variable un periodo antes, y_{t-1} al que denominaremos coeficiente de autocorrelación de primer orden, se formula como:

$$\rho_1 = \frac{Cov(y_t, y_{t-1})}{\sqrt{var(y_t)}\sqrt{var(y_{t-1})}}$$

Dado el supuesto de estacionariedad, se tiene que $var(y_t) = var(y_{t-1})$ por

lo que:

$$\rho_1 = \frac{cov(y_t, y_{t-1})}{var(y_t)}$$

En general para un desfase de k periodos se tiene que:

$$\rho_k = \frac{cov(y_t, y_{t-k})}{var(y_t)}$$

Y cuando $k=0$:

$$\rho_0 = \frac{cov(y_t, y_{t-1})}{var(y_t)} = \frac{var(y_t)}{var(y_t)} = 1$$

2.2.23. FUNCIÓN DE AUTOCORRELACIÓN PARCIAL

La función de autocorrelación parcial mide la “aportación” que a las variaciones de una variable como y_t tiene otra variable, digamos y_{t+2} asilados los efectos de los posibles restantes variables, por ejemplo y_{t-1} . Por el contrario, la función de autocorrelación ignora el hecho de que parte de la correlación que pueda existir entre, por ejemplo y_t y y_{t-2} , se debe a que ambas están correlacionadas con y_{t-1} . Pues bien, los distintos coeficientes de autocorrelación parcial de los modelos teóricos se denotan como ϕ_{kk} , y los estimados para nuestra muestra.

Esta función entre el rango $[-1, +1]$, donde $+1$ indica una correlación perfecta (la señal se superpone perfectamente tras un desplazamiento temporal de K) “ $y-1$ ” indica una autocorrelación perfecta.

Función de autocorrelación parcial, con el fin de tener en cuenta los valores de correlación entre dos variables aleatorias separadas entre sí “ k ” periodos y en función de los valores intermedios entre ellas, es decir:

$$\Pi_k = \text{corr}(y_t, y_{t-k} \dots y_{t-1} y_{t-2} \dots, y_{t-k+1})$$

FIGURA 1: Función de Autocorrelación y Autocorrelación Parcial.




Tabla 1: Comportamientos de las FAC y FACP

	FAC	FAP
MA(q)	Se anulan para retardos superiores a q	Decrecimiento rápido sin llegar a anularse
AR(p)	Decrecimiento rápido sin llegar a anularse	Se anulan para retardos superiores a p
ARMA(p;q)	Decrecimiento rápido sin llegar a anularse	Decrecimiento rápido sin llegar a anularse

2.2.24. HETEROCEDASTICIDAD

Una fuente importante de no estacionariedad corresponde a la presencia de heterocedasticidad en una serie dada. En ciertos casos ello puede corregirse con la aplicación de logaritmos (si la serie presenta tendencia creciente es muy probable que la varianza de los valores originales también sea creciente en el tiempo).

2.2.25. PROCESOS ARIMA ESTACIONALES

En una serie mensual con estacionalidad anual, cada mes tiene una media distinta, con lo cual la media no es estable. El comportamiento de la serie se repite cada l observaciones (el periodo). En una serie mensual suele ser $l = 12$, en una serie diaria suele ser $l = 7$ si hay estacionalidad semanal, $l = 30$ si hay estacionalidad mensual y/o $l = 365$ si hay estacionalidad anual. En la misma serie pueden existir distintos tipos de estacionalidad.

2.2.26. TRANSFORMACIÓN DE BOX-COX

Box – Cox (1964) definieron una transformación instantánea en el sentido de que no están involucrado simultáneamente varios periodos de tiempo de carácter más general de la transformación logarítmica. Esta transformación se define por:

$$Y_t^\lambda = \begin{cases} (y_t^\lambda), \lambda \neq 0 \\ \ln(y_{t+1}), \lambda = 0 \end{cases}$$

La transformación de Box – Cox requiere definir el parámetro λ de la transformación.

Cuando el parámetro es $\lambda = 1$, la transformación de Box – Cox consisten prácticamente en tomar logaritmos.

2.2.27. ERROR DE PREDICCIÓN

El error de predicción es la diferencia entre la realización de la variable aleatoria y la predicción hecha para dichos valores. El error cometido en la predicción de y_{t+k} depender del periodo en que dicha predicción se realiza.

2.3. DEFINICIÓN DE TÉRMINOS BÁSICOS

2.3.1. CORRELOGRAMA

Es una representación gráfica de los valores individuales de la función de autocorrelación total y parcial respecto a los rezagos.

2.3.2. ESTACIONARIEDAD

Es una serie de tiempo, decimos que la serie es estacionaria si $f(Y_t) = f(Y_{t+k})$, es decir el comportamiento de la variable en el tiempo es el mismo si se produce un desplazamiento de la serie.

2.3.3. ESTACIONALIDAD

Puede definirse como la repetición de un cierto patrón de comportamiento en forma periódica; por ejemplo, se puede repetir cada 3, meses 6 meses, cada año, cada 4 años, etc.

2.3.4. MODELO

Es la representación matemática de las variables de estudio y los parámetros que son estimados, con fines de predicción del comportamiento de la variable en estudio.

2.3.5. MODELO DE BOX-JENKINS

El modelo de BOX – JENKINS es uno de los métodos predictivos y se fundamenta en la estimación eficiente de los parámetros por medio de los procesos iterativos.

2.3.6. PASEO ALEATORIO

Un paseo aleatorio es un proceso estocástico y cuyas primeras diferencias toman un proceso de ruido blanco.

2.3.7. PERIODO

Espacio de tiempo que incluye toda la duración de lago como minutos, horas, días, meses, trimestrales, anuales, etc.

2.3.8. POBLACIÓN

Se define población como la colección completa de elementos acerca de los cuales se desea conocer información.

2.3.9. PRONOSTICO

Son las predicciones de los hechos y condiciones futuras se llaman pronósticos y el acto de hacer tales predicciones de denomina pronostico.

2.3.10. RUIDO BLANCO

Es un proceso puramente aleatorio en donde las variables son distribuidas con media cero, varianza constante y ausencia de autocorrelación entre observaciones.

2.3.11. SERIE

Una serie de tiempo es un conjunto de observaciones ordenadas en el tiempo (o en alguna otra dimensión).

2.4. OPERACIONALIZACION DE VARIABLES

Tabla 2: Operacionalización de variables.

VARIABLES	INDICADORES	ÍNDICE
VARIABLES DEPENDIENTES:	Expresada en miles de	Soles (S/)
Colocaciones mensuales en las cajas municipales de la región Puno	Soles mensuales	
VARIABLES INDEPENDIENTES:	Expresada en miles de	Soles (S/)
Colocaciones mensuales desfasados, en las cajas municipales en la región Puno	Soles mensuales	

Fuente: elaboración propia

CAPITULO III

MATERIALES Y MÉTODOS

3.1. LOCALIZACION

El presente trabajo de investigación se realizó en las cajas municipales de la Región Puno 2006– 2016.

3.2. MATERIALES Y MÉTODOS

Para el presente trabajo de investigación se obtuvo la información de la SBS.

Se usó equipos de cómputo como: laptop Core i5 (Marca: Toshiba, Procesador: Core i3, Memoria: 4GB, Disco Duro: 1TB), Software Microsoft Excel 2016, Minitab 17 y SPSS.

3.3. POBLACIÓN

La población de estudio está conformada por los registros de la serie histórica mensual del **Sistema Financiero de las Cajas Municipales en la Región de Puno** a partir del año 2006 a 2018.

3.4. MUESTRA

La muestra está conformada por la totalidad de registros de la serie histórica mensual de colocación del **Sistema Financiero en la Región de Puno – Cajas Municipales**, la elección de la muestra está basado en un muestreo no probabilístico a criterio del investigador.

En el criterio de la selección de la muestra se consideró el tiempo más reciente y representativo en cuanto a la serie de **Sistema Financiero en la Región de Puno**, que permita realizar ajuste de los datos acorde al más cercano a la realidad.

3.5. UNIDAD MUESTRAL

Número de colocaciones de créditos de las cajas municipales de la Región Puno.

3.6. MÉTODOS DE RECOPIACIÓN DATOS

El instrumento de recolección de datos fue la ficha de registro de datos, que los obtiene la Superintendencia de Banca y Seguro (**SBS**) previo informe de las entidades financieras y almacenados en la base de datos de la entidad posteriormente publicados en la web.

3.7. METODOLOGÍA

El presente trabajo de investigación es analítico-aplicada; este método es de gran importancia, ya que está presente en todas las fases de desarrollo de los modelos.

3.8. METODOLOGÍA DE ANÁLISIS DE DATOS


Para la presente investigación se utilizó la metodología de Box-Jenkins, más conocido como enfoque de Box-Jenkins en las series de tiempo de los denominados modelos ARIMA, los pasos a seguir en la obtención del modelo por el método Box-Jenkins fueron:

- 1) Representación gráfica de la serie
- 2) Histograma
- 3) Normalidad de datos transformados
- 4) Cálculo de la función de autocorrelación (F.A.C.) y la función de autocorrelación parcial (F.A.C.P.)
- 5) Proceso de identificación
- 6) Estimación de parámetros
- 7) Proceso de verificación
- 8) Proceso de predicción

3.9. METODOLOGÍA DE BOX-JENKINS

Para el modelo de ajuste del número de colocaciones de créditos de las cajas municipales en la Región de Puno, se aplicó la metodología Box – Jenkins que sigue un proceso que consta de cuatro fases.

FIGURA 2: Metodología del Enfoque Box - Jenkins



3.10. FASES DE LA METODOLOGÍA BOX-JENKINS

FASE 1: IDENTIFICACIÓN DEL MODELO

El primer paso en la identificación del modelo consiste en determinar si la serie es estacionaria en función de la serie original. Si la serie no es estacionaria, se convierte a una serie estacionaria. Se estabiliza la serie mediante la transformación de Box Cox, se especifica el grado de diferenciación según al número de veces que la serie sea diferenciada para obtener una serie estacionaria en media y varianza. El orden de la integración define el parámetro “d” del modelo ARIMA. En la práctica es suficiente tomar una diferencia (d=1), o dos diferencias (d=2) para obtener una serie estacionaria en media, a partir de la tercera diferencia la varianza se deforma, es decir la varianza crece. Un aspecto importante en la modelación ARIMA de una serie de tiempo simple es el número de veces que necesita una diferencia antes de fijar el modelo. Para esto se utiliza la prueba de DickeyFuller o de raíces unitaria en la cual la hipótesis a verificar es:

H_0 = Hay raíz unitaria (proceso no estacionario).

H_1 = Hay raíz unitaria (proceso no estacionario).

El estadístico de prueba es: $T_u = a/\hat{s}(\hat{a}_0)$ Donde:

\hat{a}_0 : Estimación mínimo cuadrado de a. la regla de decisión a considerar será:

Rechazar H_0 si $T_u > T_1$ y por lo tanto el proceso es estacionario. El estadístico T_u sigue una distribución T de Student que se tabulo por Dickey y Fuller:

Una vez obtenida una serie estacionaria con laguna valor para diferencia "d", se deberá de identificar la forma del modelo a utilizar encontrando los valores apropiados de p y q, mediante la comparación de los coeficientes de autocorrelación parcial de los datos. Si el modelo no es estacionario, se puede intentar un modelo alternativo

FASE 2: ESTIMACIÓN DE PARÁMETROS

Una vez seleccionado el modelo tentativo, habiendo identificado los valores apropiados de p, d y q se procede a estimar los valores de parámetros de los términos autorregresivos y de media móvil incluidos en el modelo, a través del uso de los mínimo cuadrados no lineales que minimiza la suma de los cuadrados de los residuos.

FASE 3: VALIDACIÓN O VERIFICACIÓN

La finalidad de esta fase consiste en analizar la adecuación entre el modelo y los datos, o dicho de otra forma en que medida se cumple lo siguiente.

- a) Los residuos del modelo estimado se aproximan al comportamiento de un ruido blanco.
- b) El modelo estimado es estacionario e invertible.
- c) Los coeficientes son estadísticamente significativos.

- d) Una de las formas para detectar anomalías a los supuestos, es a través del análisis de los residuales

FASE 4: REALIZACIÓN DE PRONÓSTICO CON EL MODELO

Una vez identificado y/o encontrado el modelo adecuado se puede realizar predicciones para varios periodos futuros de tiempo.

Estimados los parámetros del modelo encontrado correspondiente y después que haber pasado la etapa de verificación se utiliza el modelo estimado en la predicción de valores futuros de la variable objeto de estudio.

Si la serie cambia a través de tiempo como pudiera ser necesario de calcular los parámetros o incluso desarrollar un nuevo modelo.

3.11. PROCESO DE PREDICCIÓN

Dada una serie estacionaria que sigue cualquier proceso de la forma:

$$z_t = \phi_1 z_{t-1} + \dots + \phi_p z_{t-p} + E_t + \theta_1 E_{t-1} + \dots + \theta_q E_{t-q}$$

Si se tiene la información hasta el momento t y para predecir “ m ” periodos hacia delante, se construye la función.

Cuya función eficiente de predicción sea $Z_{t+m/s}$ cumple con los siguientes supuestos.

- Los parámetros ϕ_p y θ_q son conocidos.
- Los errores pasados y presentes son conocidos.

$E_t, E_{t-1}, \dots, E_1, E_1$ Predictor óptimo se construye de la función lineal de todos los valores conocidos de E_1 .

$\tilde{z}_{t+mf} = \theta_m^* E_t + \theta_{m+1}^* E_{t-1} + \theta_{m+2}^* E_{t-2} + \dots$ Dónde θ_m^* : son los coeficientes a estimar, tal que el predictor óptimo tenga un error cuadrático medio mínimo.

CAPITULO IV

RESULTADOS Y DISCUSIÓN

Para el análisis de datos, se utilizó la información del número de colocaciones de créditos en las cajas municipales de la Región Puno del periodo 2006 – 2016, los cuales fueron obtenidos de la página web oficial de **Superintendencia de Banca y Seguros (SBS)**.

4.1. ANÁLISIS Y PRESENTACION DE RESULTADOS CON LA APLICACIÓN DE LA METODOLOGIA BOX – JENKINS

Valiéndonos de esta metodología en la presente investigación que consta de cuatro pasos indispensables, se llega al objetivo trazado que es el determinar el modelo univariante que mejor se ajusta a los datos, se presentan los datos originales correspondiente a las series. (Anexo 1)

Para un mejor tratamiento de información

- Ordenamiento de información
- Graficar la serie para explorar los movimientos que tiene.

Análisis e interpretación

Se realiza el modelo univariante del número de colocaciones de créditos en las cajas municipales de la Región Puno y sus respectivas variables explicativas.

4.1.1. FASE DE IDENTIFICACIÓN DEL MODELO


GRÁFICO 1: Número de Colocaciones en las Cajas Municipales de la Región Puno, Periodo 2006 –2016.



Fuente: Elaboración Propia en base a datos de la SBS

El **Grafico Nro. 01**, la evolución de la serie histórica del número de colocación de créditos en las cajas municipales de ahorro y crédito de la Región Puno del periodo 2006 – 2016, El modelo univariante, se observa que los registros no muestran una media y varianza constante año tras año, siendo resaltante dos años donde no presenta estacionalidad con respecto a los años anteriores.


GRÁFICO 2: Autocorrelaciones estimadas de la extracción mensual de la serie del Número de Colocaciones de Créditos en las Cajas Municipales de la Región puno, periodo 2006-2016.



Fuente: Elaboración Propia en base a datos de la SBS

Gráfico Nro. 02, El primer paso en la identificación del modelo tentativo es observar los coeficientes de autocorrelación estimados de la serie histórica, los que indican que la serie es no estacionaria debido a que presentan coeficientes significativos (1, 2,3,...11). A partir del coeficiente 12 tiende a ser cero es decir que se encuentran dentro de los límites de confianza, también se ve que la media tiene el valor cero.

GRÁFICO 3: Autocorrelaciones parciales estimadas (FACP) de la serie del Número de Colocaciones de Créditos en las Cajas Municipales de la Región Puno, periodo 2006-2016.



Fuente: Elaboración Propia en base a datos de la SBS


El **Grafico Nro. 3**, Observamos la función de autocorrelacion parcial, donde se aprecia que los coeficiente 1 es significativo, hay una alternancia de coeficientes positivos y negativos alrededor de la media que es cero corroborando de esta manera que la serie no es estacionaria.

Por consiguiente creemos necesario hacer diferencias a la serie. Con la primera diferencia analizaremos las funciones de autocorrelacion y autocorrelacion parcial estacional y no estacional.

SERIE PRIMERA DIFERENCIA

Se tomó una primera diferencia con el objetivo de conseguir que la serie sea estacionaria en media y varianza.


GRÁFICO 4: Primera Diferencia no estacional por primera diferencia estacional de la Serie del Número de Colocaciones de Créditos en las Cajas Municipales de la Región Puno, periodo 2006-2016



Fuente: Elaboración Propia en base a datos de la SBS

El **Grafico Nro. 4**, Muestra la diferencia conjunta de la parte no estacional y la parte estacional debido a que en la serie original se nota claramente periodos largos y cortos indicándonos que debemos diferenciarlo conjuntamente para identificar el modelo que se ajustara a la serie de datos históricos. Esto nos indica que la serie es estacionaria para lo cual obtendremos funciones de autocorrelación y autocorrelacion parcial.


GRÁFICO 5: Autocorrelaciones estimadas para la primera diferencia no estacional por primera diferencia estacional de la Serie del Número de Colocaciones de Créditos en las Cajas Municipales de la Región Puno, periodo 2006-2016



Fuente: Elaboración Propia en base a datos de la SBS

El **Grafico Nro. 5**, Muestra a la autocorrelación estimada que indica que los coeficientes 1 es significativo negativo. Dándonos la idea de una media móvil estacional y no estacional a partir del coeficiente 2 la serie tiende a ser cero.

GRÁFICO 6: Autocorrelaciones parcial estimada para la primera diferencia no estacional por primera diferencia estacional de la Serie del Número de Colocaciones de Créditos en las Cajas Municipales de la Región Puno, periodo 2006-2016



Fuente: Elaboración Propia en base a datos de la SBS

Gráfico Nº 06. Corresponde a la función de Autocorrelaciones parcial estimada que nos indica la existencia de coeficientes significativos (1, 2, 3), lo que corrobora **con** el análisis del gráfico 5. Se observa también una caída exponencial en los coeficientes negativos bajo la media o bajo el promedio, esto nos confirma que es un modelo de medias móviles.

De todo este análisis realizado llegamos a la conclusión de que el modelo identificado para la serie histórica es un ARIMA (3, 2,0), que en forma de ecuación es la siguiente:

PRUEBA ANALÍTICA DE ESTACIONALIDAD DICKEY FULLER

IDENTIFICACION DE LA FORMA DE MODELO A UTILIZAR

En la fase de identificación de modelo se procede a calcular los valores de la parte autorregresivo (p) y de la parte de medias móviles (q) y parte estacionaria de un modelo ARIMA (p, d, q).

Conforme se observa en el gráfico de la parte regular se obtiene (p, d, q). La parte AR (1) proviene del decrecimiento rápido inicial de la función de autocorrelación parcial. Asimismo, la parte AR (2) proviene, que la función de autocorrelación parcial presenta el segundo retardo significativo en la mayoría de los periodos.

Con sus respectivos correlogramas, para las autocorrelaciones simples y parciales, que genera este modelo, en los que se puede apreciar su comportamiento.

Los modelos sugeridos para esta serie son:

ARIMA (3, 2,0)

Cuya ecuación es respectivamente:

$$\hat{Y}_t = 2Y_{t-1} - Y_{t-2} + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \phi_3 Y_{t-3} + \varepsilon_t$$

4.1.2. FASE DE ESTIMACIÓN DEL MODELO

Continuando con la metodología de Box – Jenkins el paso a seguir es la especificación del modelo identificado para la serie histórica de las colocaciones de créditos de la región de puno.

Tabla 3: Resultados para el modelo ARIMA (3, 2,0)

Resumen del modelo ajustado para: SERIES. Colocaciones créditos				
Parameter	Estimate	Std.error	T-value	P-value
AR (1)	-0.65596	0.08603	-7.62493	0.00000
AR (2)	-0.48307	0.09504	-5.08278	0.00000
AR (3)	-0.25602	0.08636	-2.96450	0.00362

Modelo ajustado a las diferencias de orden 2

Varianza estimada de ruido blanco =1.49279E7 con 127 grados de libertad

Desviación estándar del ruido blanco estimado (stderr) = 3863.66

Estadística de prueba Chi-cuadrado en las primeras 20 autocorrelaciones residuales = 11.4144

Estadística de prueba Chi-cuadrado en las primeras 20 autocorrelaciones residuales = 13.884

Probabilidad de un valor mayor con ruido blanco = 0,834229

Siendo la ecuación estimada y de pronóstico la siguiente:

$$\hat{Y}_t = 2Y_{t-1} - Y_{t-2} + \hat{\phi}_1 Y_{t-1} + \hat{\phi}_2 Y_{t-2} + \hat{\phi}_3 Y_{t-3}$$

Comprobando

$$\hat{Y}_t = 2Y_{t-1} + Y_{t-2} - 0.65596Y_{t-2} - 0.48307Y_{t-2} - 0.25602Y_{t-3}$$

4.1.3. FASE DE EVALUACIÓN O VALIDACIÓN DEL MODELO

En esta etapa de evaluación del modelo vamos a ver la adecuación entre el modelo y los datos, o dicho de otra forma veremos en qué medida los residuos del modelo estimado se aproximan al comportamiento de un ruido blanco. Como se sabe, la función de autocorrelación de los residuales toma valores dentro de las bandas, por lo que podemos admitir que los residuos que hemos obtenido se comportan como un ruido blanco.


Análisis de los residuos (ruido blanco)

La interpretación del estadístico Q' Ljung – Box Pierce es más favorable al ruido blanco cuanto mayor sea la probabilidad p valor. Si se utiliza al nivel de confianza habitual del 95%, entonces los residuos son ruido blanco siempre que el P – Valor sea superior a 0.05, para el coeficiente de autocorrelación de que los residuos forman una secuencia aleatoria, se realizó las siguientes comparaciones.

$H_0: p > \alpha$ Los residuales son ruido blanco.

$H_1: p < \alpha$ Los residuales no son ruido blanco.

GRÁFICO 7: Comparación de datos pronosticados con los datos originales para la serie del número de colocaciones de créditos en las cajas municipales de la región Puno




Fuente: Elaboración Propia en base a datos de la SBS

El **grafico Nro.7**, la probabilidad normal de los residuales del grafico es satisfactoria, ya que revela una dispersión sensiblemente menor en los residuales debido a que se distribuyen en la línea recta sin mostrar signo de tendencia.

El valor de $P > 0.05$, como el valor de P es mayor se acepta la hipótesis nula, confirmamos que los residuos se distribuyen según una distribución normal, es decir que los valores de los residuales de la serie grana en torno a su valor medio y confirmamos que el modelo ARIMA (3, 2,0) es adecuado para realizar pronósticos.


GRÁFICO 8: Función de autocorrelacion estimada FAC de los residuos para la serie del número de colocaciones de créditos en las cajas municipales de la región Puno.



Fuente: Elaboración Propia en base a datos de la SBS

El **grafico Nro.8**, Indica que ningún coeficiente de autocorrelacion es significativo, es decir esta fuera de los límites de probabilidad al 95% , por lo que la serie de la colocaciones de créditos en la región de puno es completamente aleatoria (ruido blanco)

GRÁFICO 9: Función autocorrelacion parcial estimada FACP de los residuos para la serie del número de colocaciones de créditos en las cajas municipales de la región Puno.



Fuente: Elaboración Propia en base a datos de la SBS

Se observa que en el **grafico Nro. 9** de las autocorrelaciones parciales estimadas ningún coeficiente es significativo, es decir ninguno está fuera de los límite de probabilidad.


FASE DE REALIZACIÓN DE PRONÓSTICO CON EL MODELO

En esta fase de predicción nos permite obtener resultados a futuro. La información proyectada es de 24 meses, desde la información existente del número de colocaciones de créditos de las cajas municipales en la Región Puno.

Los valores previstos para el número de colocaciones de créditos de las cajas municipales de la Región Puno, durante el periodo donde los datos reales están disponibles también se muestran los valores predichos a partir de modelo ajustado y los residuos. Para los periodos de tiempo más allá del final de la serie, se muestra 95% límites de predicción para las previsiones. Estos límites muestran donde es probable encontrar los verdaderos, valores en un momento futuro seleccionado al 95% de confianza, asumiendo que el modelo ajustado es apropiado para los datos.

Para las observaciones futuras, muestra una predicción constante ya que el comportamiento es aleatorio dentro de los límites de confianza, los límites de confianza indican la zona en la que razonablemente estará la futura observación.

GRÁFICO 10: Función de pronóstico de la Serie del Número de Colocaciones de Créditos en las Cajas Municipales de la Región



Fuente: Elaboración Propia en base a datos de la SBS

Se observa en el **grafico Nro. 10**, muestra las proyecciones y los intervalos de confianza que el paquete estadístico nos da por defecto y es para 24 periodos de tiempo, con el modelo ARIMA (3, 2,0) cuya ecuación de pronóstico es

$$\hat{Y}_t = 2Y_{t-1} + Y_{t-2} - 0.65596Y_{t-2} - 0.48307Y_{t-2} - 0.25602Y_{t-3} .$$

Tabla 4: Pronostico de la serie del número de colocaciones en las cajas municipales de la región Puno

para intervalos de confianza 95%, $z(0.025) = 1.96$

Año	Mes	Pronostico	intervalo de confianza	
			Inferior	Superior
2017	Ene	941255	934329	948181
	Feb	953513	941513	965513
	Mar	965069	946990	983147
	Abr	977111	952892	1001330
	May	988149	957641	1018657
	Jun	994831	958071	1031592
	Jul	1004846	961896	1047796
	Ago	1015450	966428	1064472
	Set	1022388	967430	1077347
	Oct	1031224	970483	1091965
	Nov	1041705	975341	1108068
	Dic	1052007	980185	1123829
2018	Ene	1057498	980067	1134929
	Feb	1063604	980632	1146575
	mar	1070151	981678	1158624
	abr	1077868	983986	1171750
	May	1085282	986089	1184475
	Jun	1088881	984490	1193273
	Jul	1096293	986819	1205767
	Ago	1104691	990254	1219128
	set	1109763	990482	1229044
	Oct	1117019	993011	1241027
	Nov	1126162	997542	1254783
	Dic	1135332	1002211	1268454

Fuente: Elaboración Propia

Los resultados proyectados en la tabla y el gráfico Nro. 10 del número de colocaciones de créditos en las cajas municipales de la región Puno se muestran pronósticos a un límite inferior y superior del intervalo de confianza del 95%, entonces en el mes de diciembre del año 2018, se tendrá la cantidad de 1135332 Miles de S/. De colocaciones de créditos en las cajas municipales de la región Puno.

CAPITULO V

CONCLUSIONES

- En el presente trabajo de investigación se concluye de acuerdo a los resultados que el modelo de predicción mensual que mejor se ajusta para decidir y predecir el comportamiento de la serie de tiempo del número de colocaciones de créditos en las Cajas Municipales de la región Puno es: modelo ARIMA (3, 2,0). Cuya ecuación pronóstico es:

$$\hat{Y}_t = 2Y_{t-1} + Y_{t-2} - 0.65596Y_{t-2} - 0.48307Y_{t-2} - 0.25602Y_{t-3}$$

- Los predictivos evaluados para la serie de número de colocaciones de créditos en las Cajas Municipales en la región de Puno, revelan una réplica bastante buena que proporcionan una alternativa eficaz para describir y predecir el comportamiento futuro del número de colocaciones de Créditos en las Cajas Municipales.
- Para la predicción de la serie analizada se utilizó del mejor modelo estimado y se obtuvieron predicciones para el año 2017 y 2018, comparando con los datos reales existentes y se comprueba el mínimo error.

CAPITULO VI

RECOMENDACIONES

- Se recomienda usar de modo general la metodología Box – Jenkins, que fundamenta la teoría de procesos estocásticos, cuya naturaleza es característica mediante un modelo.
- En el proceso de estimación se recomienda usar las herramientas necesarias para comprobar la estacionalidad e invertibilidad del proceso, de preferencia la estacionalidad.
- Para la elección del modelo se recomienda pronosticar para datos ya existente de una serie, con el fin de comparar su similitud de las dos series.
- Evitar la sobre diferenciación y parametrización, debido a que nos conducen a obtención de modelos erróneos.
- Se sugiere que realicen este tipo de trabajos otras instituciones privados o públicos, para comprar las diferencias.
- Sugiero que se tome más años de registros, mientras más datos se tiene mejor es el modelo que se obtiene.
- Comparar el grado de eficiencia de la predicción de serie temporal entre redes neuronales y series de tiempo utilizando otro software estadístico.

CAPITULO VII

REFERENCIAS

TEXTOS

Andersson, O. (1989). *"Time Serie Analisis and Forecasting"*. Madrid: 1ra EDICION EDITORIAL.

Aznar, A. (1994). *"Ejecicio de econometria I"*. MADRID: PIRAMIDE S.A.

Aznar, A., & Trivez, F. (1993). *"Métodos de predicción en Economía II. Analisis de series de temporales"*. Barcelona: Ariel Economía.

Espaza, A., & Cancelo, J. (1993). *"Metodos cuantitativos para el análisis de la coyuntura Economica"*. Madrid: Alianza.

Fernandez, C., & Baptista, L. (2014). *"Metodologia de Investigacion"*. MEXICO: INTERAMERICANA EDITORES S. A.

Guerrero, V. M. (2003). *"Análisis Estadístico de Series de Tiempo Economicas"*. Mexico: Thomson Editores.

Hanke, J. E., & Reitsh, A. G. (2006). *"Pronosticos en los negocios"*. Mexico: Atlacomulco.

Hanke, J., & Wichen, D. (2010). *"Pronostico en los Negocios"*. MEXICO:
EDITORIAL PRENTICE HALL HISPANOAMERICANO S.A.

Mate, C. (2014). *"Modelos Arima"*. Madrid: Editorial Mellin Word.

Newbold, P. (1998). *"Estadística para los negocios y la economía"*.MADRID: EDITORIAL PRENTICE HALL INC.

O'Connell, R. T., Bowerman, B. L., & koehler, A. B. (2007). *"Pronósticos, Series de Teimpo y Regresión"*. Mexico: Thomson Editores.

Peña, D. (2000). *"Modelos lineales y series temporales"*. CARTAGENA:
ALIANZA EDITORIAL.

Pindyck, S., & Rubinfeld, L. (2003). *"Econometría, Modelos y Pronosticos"*. Madrid: McGraw-Hill.

Pindyck, R. (2003). *"Microeconomía"*. Estados Unidos: Publicaciones
Adventure.

Uriel Jimenez, E. (1985). *"Análisis de Series Temporales - Modelos Arima"*. Paraninfo.

Uriel, E. (1995). *"Análisis de series temporales, Modelos ARIMA"*.
MADRID: EDITORIAL PARANINFO S. A.

TESIS

Diaz N. (2010). *“Pronostico mediante modelos de series de tiempo para el consumo de agua potable de la empresa municipal de saneamiento básico de la ciudad de puno EMSA, periodo (2000-2007)”* Tesis de pregrado de Ingeniero Estadístico e Informático, Universidad nacional del Altiplano, Puno.

Carvajal, P. (2013). *“Estudio del pronóstico de la demanda de energía eléctrica utilizando modelos de series de tiempo”*, Tesis de Postgrado: Maestría en investigación operativa y estadística Universidad tecnológica de Pereira.

Valdez, Y. (2015). *“Modelo de predicción mensual del número de intervenciones quirúrgicas más frecuentes en el Hospital Regional Manuel Núñez Butrón - Puno 2000 - 2013”*.Tesis de Pregrado: Escuela profesional de Ingeniería Estadística e Informática, Facultad de Ingeniería Estadística e Informática de la Universidad Nacional del Altiplano.

Flores, S. (2011) *“Modelo Univariante para el pronóstico de la evolución de los ratios de morosidad de créditos vencidos para la Caja Municipal de Ahorro y Crédito Arequipa período 2002 – 2010”*.Tesis de Pregrado: Escuela profesional de Ingeniería Estadística e Informática, Facultad de Ingeniería Estadística e Informática de la Universidad Nacional del Altiplano.

Ramírez, R.; Hernández, J. (2010). *“Análisis de series de tiempo en el pronóstico de la producción de caña de azúcar”*. Tesis de Pregrado:

Facultad de Economía, Facultad de Ciencias Administrativas y Sociales, Facultad de Ciencias Agrícolas. Universidad Veracruzana. Xalapa, Veracruz, México.

Soncco, W. (2013). *"Modelos univariantes para predecir el comportamiento de las temperaturas máximas (°c) y temperaturas mínimas (°c) de la estación climatológica ordinaria de Azángaro, período 1993-2009"*. (Tesis pregrado). Universidad Nacional del Altiplano. Puno-Perú.

WEBGRAFIA

http://iinei.inei.gob.pe/iinei/metodo/documentos/Series_tiempo.pdf/
[Consulta: 1 de junio de 2017]

<http://www.ccee.edu.uy/ensenian/catmetec/material/Tecnicas%20Econometricas%20-%20Series%20de%20Tiempo.pdf/> [Consulta: 1 de junio 2017]

<http://econometriaii.files.wordpress.com/2010/01/series-de-tiempo.pdf/>
[Consulta: 1 de junio 2017]

<https://www.lokad.com/es/que-es-el-pronostico-de-series-de-tiempo/>[Consulta: 19 de junio 2017]

http://www.udape.gob.bo/portales_html/AnalisisEconomico/analisis/vol14/art02.pdf [Consulta: 23 de junio 2017]

http://www.seduca2.uaemex.mx/ckfinder/uploads/files/u3tema_3_series_de_t.pdf/ [Consulta: 23 de junio 2017]

<https://metodologiaecs.wordpress.com/2016/01/31/libro-metodologia-de-la-investigacion-6ta-edicion-sampieri-pdf/> [Consulta: 23 de noviembre 2017]

<https://www.freelibros.org/economia/pronosticos-en-los-negocios-9na-edicion-john-e-hanke.html/> [Consulta: 23 de noviembre 2017]

http://modelosdepronosticos.info/conceptos_basicos_de_pronosticos.html/
[Consulta: 23 de noviembre 2017]

ANEXOS

Anexo 1

Serie Original del Numero Colocaciones de Créditos en las Cajas Municipales de la Región Puno, periodo 2006 – 2016.

	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016
<i>ene</i>	125015	163828	216019	303775	363146	448023	544986	675956	779330	803310	814115
<i>feb</i>	127432	166934	220974	309861	368184	455497	553141	680807	789646	803526	811428
<i>mar</i>	130720	170336	222926	311814	374236	462594	565179	689558	792714	803742	818625
<i>abr</i>	132656	173945	233970	316594	379512	469850	574647	703351	794713	803958	830786
<i>may</i>	136445	177602	240339	326853	384234	473282	589953	718182	798629	804174	837101
<i>jun</i>	128840	180650	251735	330163	386469	477380	600134	723853	797822	804390	836887
<i>jul</i>	140401	184523	257491	337270	392379	488481	618639	727188	797563	804606	848635
<i>ago</i>	143610	188181	268177	343730	399593	497789	632134	737550	806724	804822	862052
<i>set</i>	147341	191323	274609	346054	408083	506082	639229	740551	802287	805038	875536
<i>oct</i>	150717	197028	283582	351515	419626	515058	647938	749320	802981	805254	891107
<i>nov</i>	156169	204903	293567	357226	432625	527579	663558	761494	802719	805904	909528
<i>dic</i>	159782	212381	298587	361295	444940	539022	671856	771894	803094	814167	929041

Anexo 2
Residuales de las colocaciones de créditos en la región de puno

Variable: WORKAREA.RESIDUALES (length = 132)

(1)	(19)	501.707	(37)	-1949.41	(55)	1577.35	
(2)	(20)	44.2602	(38)	-1131.17	(56)	2371.4	
(3)	871	(21)	-414.41	(39)	-4733.93	(57)	3269.94
(4)	-780.663	(22)	2331.88	(40)	592.748	(58)	5460.79
(5)	1386.91	(23)	3546.9	(41)	5566.75	(59)	4408.88
(6)	-10608.6	(24)	2132.43	(42)	-3047.5	(60)	2072.57
(7)	12241	(25)	-2395.97	(43)	2609.29	(61)	-8195.7
(8)	-809.699	(26)	-838.089	(44)	-110.492	(62)	-1622.44
(9)	1384.98	(27)	-4095.75	(45)	-4505.24	(63)	-2131.55
(10)	859.621	(28)	6775.27	(46)	1083.52	(64)	-330.678
(11)	-42.9622	(29)	175.451	(47)	144.096	(65)	-2777.65
(12)	-515.087	(30)	5583.69	(48)	-1021.5	(66)	-1862.08
(13)	138.672	(31)	-2273.17	(49)	-2371.18	(67)	5633.3
(14)	-1012.85	(32)	2461.94	(50)	1002.89	(68)	2143.37
(15)	-582.244	(33)	-2457.67	(51)	1612.69	(69)	1362.34
(16)	57.9296	(34)	688.177	(52)	860.845	(70)	943.949
(17)	86.1155	(35)	1885.96	(53)	242.745	(71)	3043.66
(18)	-401.737	(36)	-4162.78	(54)	-2965.66	(72)	1317.44
(73)	-4298.76	(91)	-6552.28	(109)	1110.65	(127)	6126.1
(74)	-1016.15	(92)	1335.48	(110)	-41.3324	(128)	4864.87
(75)	2397.45	(93)	-6225.19	(111)	86.2748	(129)	5268.77
(76)	-367.235	(94)	3736.01	(112)	-40.7069	(130)	5999.69
(77)	6588.9	(95)	5431.69	(113)	0	(131)	4678.64
(78)	-1542.91	(96)	1361.35	(114)	0	(132)	3986.8
(79)	7124.45	(97)	-1006.09	(115)	0		
(80)	-530.947	(98)	950.518	(116)	0		
(81)	-6977.33	(99)	-7244.85	(117)	0		
(82)	-2873.22	(100)	-5190.95	(118)	0		

(83)	3595.39	(101)	-1548.2	(119)	434
(84)	-3647.53	(102)	-5837.56	(120)	7897.68
(85)	-5249.17	(103)	-1897.71	(121)	-3111.56
(86)	-3770.42	(104)	7988.69	(122)	-4300.52
(87)	490.117	(105)	-8363.35	(123)	6087.87
(88)	6888.25	(106)	902.17	(124)	8045.77
(89)	6421.58	(107)	-1747.44	(125)	1510.25
(90)	-5044.99	(108)	-992.777	(126)	-5435.26

Anexo 3

Resultados para el modelo ARIMA (3, 2,0)

Resumen del modelo ajustado para: SERIES. Colocación de créditos

Parameter	Estimate	Stnd.error	T-value	P-value
AR (1)	-0.65596	0.08603	-7.62493	0.00000
AR (2)	-0.48307	0.09504	-5.08278	0.00000
AR (3)	-0.25602	0.08636	-2.96450	0.00362

Modelo ajustado a las diferencias de orden 2

Varianza estimada de ruido blanco = 1.49279E7 con 127 grados de libertad

Desviación estándar del ruido blanco estimado (std err) = 3863.66

Estadística de prueba Chi-cuadrado en las primeras 20 autocorrelaciones residuales = 11.4144

Estadística de prueba Chi-cuadrado en las primeras 20 autocorrelaciones residuales = 13.884

Probabilidad de un valor mayor con ruido blanco = 0,834229

Anexo 4
Pronóstico para las colocaciones de créditos en la región de puno

Variable: WORKAREA.FORECASTS (length = 24 3)			
(1,1)	945927	(1,2)	938279
(2,1)	963279	(2,2)	950468
(3,1)	981314	(3,2)	963412
(4,1)	999349	(4,2)	975693
(5,1)	1.01693E6	(5,2)	986328
(6,1)	1.03464E6	(6,2)	996669
(7,1)	1.05248E6	(7,2)	1.00677E6
(8,1)	1.07029E6	(8,2)	1.01634E6
(9,1)	1.08803E6	(9,2)	1.02531E6
(10,1)	1.10579E6	(10,2)	1.03391E6
(11,1)	1.12358E6	(11,2)	1.04214E6
(12,1)	1.14136E6	(12,2)	1.04996E6
(13,1)	1.15913E6	(13,2)	1.05738E6
(14,1)	1.1769E6	(14,2)	1.06444E6
(15,1)	1.19468E6	(15,2)	1.07117E6
(16,1)	1.21246E6	(16,2)	1.07754E6
(17,1)	1.23023E6	(17,2)	1.08359E6
(18,1)	1.248E6	(18,2)	1.08931E6
(19,1)	1.26578E6	(19,2)	1.09472E6
(20,1)	1.28355E6	(20,2)	1.09982E6
(21,1)	1.30133E6	(21,2)	1.10463E6
(22,1)	1.3191E6	(22,2)	1.10915E6
(23,1)	1.33687E6	(23,2)	1.11337E6
(24,1)	1.35465E6	(24,2)	1.11732E6

Anexo 5

**Resultados de la predicción de las colocaciones de créditos en la
región de puno, para los años 2017 y 2018 según meses.**

Año	Mes	Pronostico	intervalo de confianza	
			Inferior	Superior
2017	Ene	941255	934329	948181
	Feb	953513	941513	965513
	Mar	965069	946990	983147
	Abr	977111	952892	1001330
	May	988149	957641	1018657
	Jun	994831	958071	1031592
	Jul	1004846	961896	1047796
	Ago	1015450	966428	1064472
	Set	1022388	967430	1077347
	Oct	1031224	970483	1091965
	Nov	1041705	975341	1108068
	Dic	1052007	980185	1123829
2018	Ene	1057498	980067	1134929
	Feb	1063604	980632	1146575
	mar	1070151	981678	1158624
	abr	1077868	983986	1171750
	May	1085282	986089	1184475
	Jun	1088881	984490	1193273
	Jul	1096293	986819	1205767
	Ago	1104691	990254	1219128
	set	1109763	990482	1229044
	Oct	1117019	993011	1241027
	Nov	1126162	997542	1254783
	Dic	1135332	1002211	1268454