



**FACULTAD DE INGENIERÍA, ARQUITECTURA Y
URBANISMO**

ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS

TESIS

**ANÁLISIS COMPARATIVO DE ALGORITMOS DE
PRONÓSTICO DE VENTAS PARA SU
IMPLEMENTACIÓN EN MYPES DEL SECTOR
FERRETERÍA DE CHICLAYO**

**PARA OPTAR EL TÍTULO PROFESIONAL DE INGENIERO DE
SISTEMAS**

Autores:

Bach. Azañero Burga Jhynno Amado

Bach. Ramirez Sipion Richard Junior

Asesor:

Ing. Valdivia Salazar Carlos Alberto

Línea de Investigación:

Infraestructura, Tecnología y Medio Ambiente

Pimentel, Perú

2019



DEDICATORIA

Dedicamos este trabajo principalmente a Dios, por habernos dado la vida y permitirnos haber llegado hasta este momento tan importante de nuestra formación profesional.

A nuestras madres, por ser el pilar más importante y por demostrarnos siempre su cariño y apoyo incondicional sin importar nuestras diferencias de opiniones.

A nuestros padres que, a pesar de nuestra distancia física, sentimos que están con nosotros siempre y, sé que este momento les hubiera sido tan especial para ellos como para nosotros.

A mis hermanos(as) por darme consejos y no dejarme derrumbar en los momentos más difíciles. También dedicamos este trabajo a nuestros hijos para que más adelante se sientan orgullosos de nosotros y seamos un ejemplo para ellos.



AGRADECIMIENTOS

Me van a faltar páginas y palabras para agradecer a las personas que se han involucrado en la realización de este trabajo, sin embargo, merecen reconocimiento especial nuestros Padres que con su esfuerzo y dedicación nos ayudaron a culminar nuestra carrera universitaria y nos dieron el apoyo suficiente para no decaer cuando todo parecía complicado e imposible.

Gracias a nuestros hijos que a pesar de estar pequeños nos entienden ya que, mediante el proceso de elaboración de esta tesis, fue necesario realizar sacrificios como no estar en algunos momentos a su lado, y otras situaciones que requerían tiempo, tiempo del cual les pertenecían a ellos.

Gracias a nuestras parejas por entendernos en todo, gracias a ellas porque en todo momento fueron un apoyo incondicional en nuestras vidas, fue la felicidad encajada en una sola persona, Mis sinceras gracias para ellas, nunca podremos terminar de agradecerle por tanta ayuda.

Asimismo, agradezco infinitamente a mis Hermanos(as) que con sus palabras nos hacían sentir orgullosos de lo que somos. Ojalá algún día seamos esa fuerza para que puedan seguir avanzando en su camino y logren lo que se propongan.

RESUMEN

En la actualidad algunas ferreterías en la provincia de Chiclayo no cuentan con un software que les permitan realizar el pronóstico de sus ventas.

Con la finalidad de mejorar el pronóstico, se realizó un análisis comparativo de algoritmos de pronóstico (Promedio Móvil, Suavizado Exponencial Simple, Red Neuronal, ARIMA, ANFIS) de ventas para su implementación de un sistema en C# .NET. El Promedio Móvil, Suavizado Exponencial Simple solo pronostican un periodo más. La Red Neuronal necesita tiempo de aprendizaje elevado, elevada cantidad de datos para entrenamiento se puede pronosticar varios periodos. El ARIMA es complicado y difícil de entender, son buenos en el pronóstico a corto plazo. El ANFIS son tolerantes a datos imprecisos, necesita mayor tiempo de cálculo computacional se puede pronosticar varios periodos.

La red neuronal es el que obtiene el mejor MAPE (20%), MAD (3,976288), MSE (22,08480291), MPE (0,20430195903) y mejor grado de confiabilidad. El suavizado exponencial simple con un alfa (α) de 0.6 posee un menor MAD (7651.666) que el promedio móvil, ANFIS, ARIMA. El promedio móvil obtiene un MSE (82554152,45) menor que el suavizado exponencial simple. El suavizado exponencial simple el MPE (0,050563077) es menor que el promedio móvil.

Palabras claves: Pronóstico, Promedio Móvil, Suavizado Exponencial Simple, Red Neuronal, Perceptrón Multicapa, ARIMA, ANFIS.

ABSTRACT

At present some hardware stores in the province of Chiclayo do not have software that allows them to make the forecast of their sales.

In order to improve the forecast, a comparative analysis of forecast algorithms (Moving Average, Simple Exponential Smoothing, Neuronal Network, ARIMA, ANFIS) of sales was made for its implementation of a system in C # .NET. The Moving Average, Simple Exponential Smoothing only forecast one more period. The Neural Network needs high learning time, a high amount of data for training can predict several periods. The ARIMA is complicated and difficult to understand, they are good at short-term forecasting. The ANFIS are tolerant to inaccurate data, it needs more computational calculation time can be predicted several periods.

The neural network is the one that obtains the best MAPE (20%), MAD (3,976288), MSE (22,08480291), MPE (0,20430195903) and better degree of reliability. The simple exponential smoothing with an alpha (α) of 0.6 has a lower MAD (7651.666) than the moving average, ANFIS, ARIMA. The moving average obtains an MSE (82554152.45) less than the simple exponential smoothing. The simple exponential smoothing the MPE (0.050563077) is lower than the moving average.

Keywords: Prognosis, Moving Average, Simple Exponential Smoothing, Neural Network, Multilayer Perceptron, ARIMA, ANFIS

ÍNDICE

I. INTRODUCCIÓN	12
1.1. REALIDAD PROBLEMÁTICA.....	13
1.2. ANTECEDENTES DE ESTUDIO.	14
1.3. ESTADO DEL ARTE	25
1.4. BASES TEÓRICO CIENTÍFICAS	26
1.5. DEFINICIÓN DE LA TERMINOLOGÍA.	65
1.6. FORMULACIÓN DEL PROBLEMA.	66
1.7. JUSTIFICACIÓN E IMPORTANCIA DEL ESTUDIO.....	67
1.8. HIPÓTESIS.....	69
1.9. OBJETIVOS.....	69
II. MATERIAL Y MÉTODO.....	71
2.1. TIPO Y DISEÑO DE INVESTIGACIÓN.....	71
2.2. POBLACIÓN Y MUESTRA.....	71
2.3. VARIABLES, OPERACIONALIZACIÓN.	72
2.4. TÉCNICAS E INSTRUMENTOS DE RECOLECCIÓN DE DATOS, VALIDEZ Y CONFIABILIDAD.	74
2.5. PROCEDIMIENTOS DE ANÁLISIS DE DATOS.....	74
2.6. CRITERIOS ÉTICOS	75
2.7. CRITERIOS DE RIGOR CIENTÍFICO.....	76
III. REPORTE DE RESULTADOS.....	78
3.1. RESULTADOS EN TABLAS Y FIGURAS.....	78
3.2. DISCUSIÓN DE RESULTADOS	133

IV. CONCLUSIONES Y RECOMENDACIONES REFERENCIAS	141
4.1. CONCLUSIONES.....	141
4.2. RECOMENDACIONES	143
REFERENCIAS.....	144
ANEXOS.....	153

ÍNDICE DE FIGURAS

Figura 1. Esquema general de una red neuronal artificial..... 39

Figura 2. Operación en una neurona artificial..... 40

Figura 3. Arquitectura de una red neuronal artificial..... 41

Figura 4. Arquitectura General de un MLP..... 42

Figura 5. Modelo ARIMA Box Jenkins..... 51

Figura 6. Modelo ANFIS..... 58

Figura 7. Sistema de inferencia Takagi-Sugeno de primer orden..... 59

Figura 8. Arquitectura ANFIS..... 60

Figura 9. Ventas reales, ventas pronosticadas por mes con menor MAPE y mayor grado de confiabilidad..... 80

Figura 10. Ventas reales y pronostico del promedio móvil a 2 meses..... 81

Figura 11: Suavizado exponencial simple con ventas reales y serie de tiempo..... 85

Figura 12. comparación del pronóstico de las ventas con la red neuronal..... 88

Figura 13. Comparación de las ventas reales con el pronóstico ARIMA..... 89

Figura 14. Comparación de las ventas reales con el pronóstico ANFIS..... 92

Figura 15. Carga de ventas..... 162

Figura 16. Datos cargados SPSS..... 162

Figura 17. Definir fecha y hora..... 163

Figura 18. Definir fechas..... 163

Figura 19. Datos definidos por fecha..... 164

Figura 20. Crear grafico de secuencia para observar estacionalidad..... 164

Figura 21. Definir parámetros gráficos de secuencia..... 165



Figura 22. Gráfico de secuencia con muchos picos. 165

Figura 23. Análisis espectral para observar estacionalidad..... 166

Figura 24. Diagramas espectrales. 166

Figura 25. Peridograma de venta por frecuencia. 167

Figura 26. Crear autocorrelaciones. 167

Figura 27. Definir parámetros autocorrelaciones. 168

Figura 28. Autocorrelaciones. 169

Figura 29. Autocorrelaciones parciales..... 170

Figura 30. Analizar informes por columnas..... 171

Figura 31. Informes estadísticos en columnas media..... 171

Figura 32. Informes estadísticos en columnas varianza. 172

Figura 33. Autocorrelaciones parte regular..... 172

Figura 34. Autocorrelaciones FAS..... 173

Figura 35. Autocorrelaciones parciales FAP..... 174

Figura 36. Autocorrelaciones parte estacional. 175

Figura 37. ARIMA, crear modelos tradicionales. 175

Figura 38. Modelizador de series temporales: Criterios ARIMA. 176

Figura 39. Modelizador de series temporales: Estadísticas. 176

Figura 40. Modelizador de series temporales: Opciones. 177

Figura 41. Modelo de Box-Jenkins ARIMA(1,0,1)(0,1,1). 177

Figura 42. Diagrama de flujo para su adaptación del sistema de pronóstico en las MYPES 178



ÍNDICE DE TABLAS

Tabla 1. Notación utilizada por el algoritmo Backpropagation	45
Tabla 2. Diferencias lógicas difusa y redes neuronales	61
Tabla 3. Métodos para analizar el error	64
Tabla 4. Algoritmos de Pronóstico.....	73
Tabla 5. Sistema de predicción de ventas	74
Tabla 6. Diferencias lógicas difusa y redes neuronales	75
Tabla 7. Grado de Confiabilidad del Método Determinístico Promedio Móvil.	78
Tabla 8. Grado de confiabilidad del método suavizado exponencial simple	82
Tabla 9. Grado de confiabilidad de la red neuronal en el pronóstico.....	86
Tabla 10. Grado de confiabilidad ARIMA	89
Tabla 11. Grado de confiabilidad del método ANFIS	90
Tabla 12. Comparación del error MAPE entre el Promedio Móvil, el Suavizado Exponencial Simple	93
Tabla 13. Comparación del error MAPE entre la Red Neuronal, ARIMA y ANFIS	96
Tabla 14. Comparación de la Desviación Media Absoluta del Promedio Móvil.....	98
Tabla 15. Comparación de la Desviación Media Absoluta, Suavizado Exponencial Simple	101
Tabla 16. Comparación de la Desviación Media Absoluta de la Red Neuronal.....	104
Tabla 17. Comparación de la Desviación Media Absoluta ARIMA	107
Tabla 18. Comparación de la Desviación Media Absoluta ANFIS	107
Tabla 19. Comparación de Error Cuadrado Medio del Promedio Móvil.....	109
Tabla 20. Comparación de Error Cuadrado Medio del Suavizado Exponencial Simple	112
Tabla 21. Comparación Error Cuadrado Medio de la Red Neuronal.....	115



Tabla 22. Comparación Error Cuadrado Medio ARIMA 118

Tabla 23. Comparación Error Cuadrado Medio ANFIS
..... 118

Tabla 24. Comparación Error Porcentual Medio Promedio Móvil 120

Tabla 25. Comparación Error Porcentual Medio Suavizado Exponencial Simple 123

Tabla 26. Comparación Error Porcentual Medio Red Neuronal..... 127

Tabla 27. Error Porcentual Medio ARIMA
..... 130

Tabla 28. Comparación Error Porcentual Medio ANFIS..... 131

Tabla 29. Características, ventajas y desventajas de los algoritmos Promedio Móvil,
Suavizado Exponencial Simple..... 153

Tabla 30. Características, ventajas y desventajas de los algoritmos Redes Neuronales:
Perceptrón Multicapa 155

Tabla 31. Características, ventajas y desventajas de los algoritmos ARIMA y ANFIS 157

Tabla 32. Similitudes de los algoritmos Promedio Móvil, Suavizado Exponencial Simple,
Redes Neuronales: Perceptrón Multicapa, ARIMA, ANFIS 160

Tabla 33. Diferencias de los algoritmos Promedio Móvil, Suavizado Exponencial Simple,
Redes Neuronales: Perceptrón Multicapa, ARIMA, ANFIS 161



I. INTRODUCCIÓN

En la administración de cualquier empresa la planeación se convierte en una herramienta fundamental para proyectarse al futuro. El éxito en breve, medio y extenso plazo de una entidad se relaciona con las competencias que la administración tiene para anticiparse al futuro y elaborar estrategias adecuadas. Conocer, el entorno económico permite al administrador tener una idea de lo que podría suceder en el futuro. No es fácil convertir una idea en un número que represente las ventas del mes próximo. La meta de esta tesis es llevar a cabo un análisis comparativo de algoritmos de pronóstico de ventas.

Seguramente Ud. tiene que revisar los datos de ventas pasadas. Examinar esta información histórica para identificar el monto total de las ventas por mes. Una revisión cuidadosa de las ventas para determinar si son estacionales. Revisar las ventas históricas permite entender cómo se ha desarrollado las ventas en periodos anteriores, esto nos permite realizar un mejor pronóstico de las ventas que se esperan obtener en un futuro.

El promedio móvil, se utiliza para pronosticar la siguiente etapa, utilizando como término medio los valores de la n datos nuevos de una serie de tiempo. El suavizado exponencial simple, utiliza el cociente contenido del valor anterior de la serie. ARIMA, utiliza métodos más complejos y su aplicación requiere serie más largas. Las redes artificiales, poseen un buen desempeño de la aproximación de los pronósticos de las ventas utilizando series de tiempo. ANFIS, combina modelos de inteligencia artificial para pronosticar.

Esta tesis empieza por definir un problema de investigación para luego desarrollar las bases teóricas y marco metodológico, después analizamos e interpretamos los resultados obtenidos,



para luego proponer el desarrollo del estudio, finalizado con su respectiva conclusión y recomendación.

1.1. Realidad Problemática.

Algunas ferreterías en la provincia de Chiclayo no cuentan con un software que les permitan realizar el pronóstico de sus ventas. Estas empresas operan en un clima de incertidumbre al momento de decidir una decisión.

En la economía del mercado cada vez más competitivo una mala decisión puede ocasionar grandes pérdidas económicas en estas organizaciones. Las organizaciones tienen que hallar nuevos métodos predictivos para lograr la supervivencia en el mercado ferretero.

El pronóstico de las ventas se convierte en datos de gran importancia en la planificación. En un mercado competitivo, es de gran importancia para estas organizaciones contar un software de pronóstico que permita estimar sus ventas futuras, analizando las ventas históricas; lo que permitirá a los expertos tomar decisiones para realizar modificaciones en sus propósitos, y en esta manera anticipar a la necesidad que demanda el mercado.

Pero no se debe olvidar que estos métodos intentan “pronosticar” las ventas. Lo que se busca es hacer más ajustado el pronóstico con la realidad; nunca coincidirá con el valor real que se obtenga. Por tal motivo nace la necesidad de analizar diferentes tipos de algoritmos que nos permitan realizar un mejor pronóstico de las ventas.

1.2. Antecedentes de Estudio.

1.2.1. Nivel internacional

Rosas (2014), en su estudio denominada Proyecto de un sistema de pronóstico de la demanda de nitrógeno y oxígeno para la entidad CRYOGAS, S.A. establecido en redes neuronales para nombrar el grado de Magister en Ingeniería presentado en la Universidad EAFIT – Medellín, Colombia – tiene como objetivo plantear un método de predicción de la demanda en el producto de O líquido medicinal y N líquido para el rubro petrolero por intermedio de redes neuronales artificiales escudriñando conseguir una mínima equivocación entre la verdadera y la prevista.

En la construcción de la RNA realizo los siguientes pasos:

Identificar producto a pronosticar.

Identificación de variables que se utilizaran como entradas en la red.

Recopilación de datos de las variables de entrada a la red.

Recopilar las ventas históricas de la compañía.

Construcción de la RNA.

Tratamiento de datos para hacer uso de ellos en la RNA.

Entrenamiento de la RNA.

Validación de la RNA.

RNA cumple con los criterios de error propuesto.

Pre selección RNA final entre las arquitecturas que cumplen.

Selección de la RNA más apropiada para solucionar el problema.

En el pronóstico se utilizaron las siguientes redes neuronales:

Perceptrón multicapa.

RDE

RBF

RDJ

El Perceptrón multicapa presento un excelente trabajo medido entre el error del pronóstico y la información autentica. Se concluye que la observación de diferentes técnicas para generar un pronóstico, y basándose en la conducta de datos e investigación académica se valida a través de la red Neuronal artificial para sistemas inestables que no es lineal; el pronóstico obtenido por medio de la “RNA” se comprueban con la información verdadera y con el pronóstico de la empresa, y se deduce que es el procedimiento propuesto en el presente plan es más correcto, esta confirmación se dio en distintas suposiciones en dos productos utilizados en fragmentos con distintas variables y un comportamiento diferente, tal modo establece que el método propuesto forma un mejor resultado que el proceso actual de la entidad.

Valencia et al. (2017), En su artículo de investigación denominado Comparativo de modelos de pronóstico: clásicos, bayesianos y técnicas de combinación presentado en la Universidad Nacional de Colombia – Medellín – Se plantea una igualdad en la precisión de pronóstico de un modelo estadístico individual y combinación entre ellos empleando un algoritmo multi-producto para las mezclas utilizando un caso de investigación de ventas en la sección de lácteos. Se utilizaron las ventas diarias de tres productos lácteos en Colombia, en el pronóstico se tomaron los siguientes métodos:

- 1) Estudio descriptivo de las series de tiempo.
- 2) Estimar modelos para pronosticar cada serie de tiempo:
 - a) Patrón recto mixto general.
 - b) Modelo lineal mixto generalizado bayesiano.
 - c) Modelo lineal dinámico bayesiano.
 - d) Modelo de regresión bayesiana.
- 3) Incorporar pronósticos a las técnicas de combinación de pronósticos con un algoritmo multiproducto.
 - a) Combinación de Bates and Granger.
 - b) Combinación de valor propio.
 - c) Combinación alternativa de RMSE.
- 4) Algoritmo diseñado para múltiples productos que arroja los resultados para las combinaciones usadas.

Se acierta que el diseño propio de regresión Bayesiana con innovación es mejor opción para el caso analizado. Se concluye que se realizó una revisión de diferentes modelos para pronósticos, así como técnicas de combinación que se usan diferentes pronósticos individuales para buscar una mayor precisión; Se diseñó un algoritmo en R para tres productos que incorpora los pronósticos individuales y genera pronósticos combinados usando tres técnicas, que también puede replicarse en otros casos en los que se requiera comparar resultados.

Guevara y Moreno (2016), en su indagación denominada Modelo de pronóstico para las ventas semanales en la entidad Américas BPS en la campaña ETB presentado en la Universidad Los Libertadores – Bogotá, Colombia – tiene como objetivo es implementar un estándar que permita la pronosticación de ventas establecido en el registro semanal de la compañía Américas BPS en la campaña ETB a través de series de tiempo. Para crear mencionado diseño, se debe realizar el estudio de la serie de la variable de investigación. Para luego aplicar los modelos HoltWinters, ARMA y ARMAX, con la finalidad de ajustar la conducta de datos, asimismo determinar que variables exógenas se debe aplicar. El adecuado patrón de pronóstico para la secuencia de estudio, es el “HW”, porque su procedimiento grafico es adaptable a la conducta de la serie y su falla es menos al ARMA. Se concluye que los estudios de variables son versátil y dinámico, por ello es indispensable examinar los datos con distintos diseños para sus respectivas comparaciones y poder escoger la mejor opción.

1.2.2. Nivel nacional

Según Rodríguez y Valdivia (2015), en su tesis denominada **Modelo de pronóstico de precios de acciones en la bolsa de valores de lima basado en redes neuronales artificiales** para tener el grado de Ing. de Sistemas en la Universidad Nacional de Ingeniería – Lima, Perú –tiene como objetivo desarrollar un estándar de pronóstico capaz de anunciar la conducta de la lista de costos y cotización de las acciones comercializadas en la Bolsa de Valores de Lima, cogiendo como base el uso de las técnicas de inteligencia artificial; específicamente las Redes Neuronales Artificiales. Se utilizó el procedimiento RUP para la investigación, diseño, etc. del sistema y en la implementación de la red neuronal se siguieron los pasos a continuación:

Seleccionar variables.

Recolecciones de información.

Pre-proceso de la investigación

Selección (conjuntos de entrenamiento y prueba).

Definición de la arquitectura.

Selección de la medida de rendimiento.

Entrenar la red.

Implementación.

En la deducción conseguida se muestran que el modelo basado en RNA puede aplicarse al pronóstico de serie de tiempo financiera en el mercado de valores y lograr buenas aproximaciones debido a sus capacidades para el reconocimiento de patrones. En esta tesis se han considerado 15 modelos de RNA contra el pronóstico realizado por la metodología ARIMA, demuestran que el modelo de RNA obtiene mejores deducciones en el pronóstico de secuencias de duración financiera frente a métodos estadísticos tradicionales de pronóstico y pueden ser utilizados como una primera fuente de información que permita a expertos, analistas bursátiles y especialistas en mercados de valores esbozar su conducta a futuro en el costo de acciones en el mercado de valores del Perú para tomar mejores decisiones de inversión bursátil, y por tanto, disminuir el riesgo de tomar una decisión errada. Se concluye que este trabajo presenta los fundamentos para la edificación de un estándar de Red Neuronal para pronosticar los importes de las gestiones comercializadas en el mercado de valores del Perú; la propuesta nos presenta un modelo novedoso para el pronóstico de los precios de acciones. De este modo,

se intenta obtener un modelo de mejor desempeño que refleje el comportamiento y las fluctuaciones del precio de cada acción comercializada en la bolsa de valores del Perú. Los resultados muestran que los modelos basados en Redes Neuronales Artificiales pueden aplicarse al pronóstico de la secuencia de tiempo financieras en los mercados de valores y lograr buenas aproximaciones ($MSE < 0.02$) debido a sus capacidades para el reconocimiento de patrones. Es importante realizar un trabajo exhaustivo en la identificación y obtención de información histórica y periodos de la serie de duración, además, se debe definir una arquitectura consistente para el modelo de redes neuronales que permita obtener buenos resultados de aproximación en el pronóstico de costos de las gestiones comercializadas en la BV de Lima.

Según Espinoza y Gutiérrez (2015), en su tesis denominada Procedimiento de investigación para la toma de decisiones, usando técnicas de estudio predictivo para la organización IASACORP INTERNATIONAL S.A para obtener el título profesional de Ingeniero Informático en la Universidad Ricardo Palma – Lima, Perú – Su objetivo es ampliar un sistema de informaciones que ayuden al apoyo de decisiones en la oficina de Marketing, mediante procesos de Análisis Predictivo que permita realizar la proyección (venta/compra) de las líneas (mercadería) de manera exacta, así mismo conocer el comportamiento de consumo de los consumidores preferenciales para realizar estrategias de marketing eficientes. Se utilizó SQL Server Business Intelligence Development Studio y Datawarehouse, Dataming para el modelo de predicción. Se realizó el algoritmo de árboles de decisión dentro de la herramienta de análisis predictivo, que género información sobre el comportamiento del consumo de usuarios recurrentes, establecida en las líneas (producto) que distribuye la entidad, por lo tanto, también podrá ser utilizada en la proyección, estimación y promoción comercial de venta. En

conclusión, se ha desarrollado la minería de datos para obtener información que contribuya a la mejorar las técnicas de presupuestos en ventas y compras de la empresa IASACORP INTERNATIONAL S.A., es mas de poder obtener tendencias del proceder de los compradores para ofrecer mejores tácticas de promoción, oferta y descuento; ahora bien en el progreso de los tiempos de preparar los reportes de estimación de venta y plan de adquisiciones basado en los resultados del pronóstico, el instrumento de predicción que se realice en un día, contra el proceso anterior que duraba entre tres a cuatro días.

Según Carpio (2016), en su tesis denominada **Modelo de predicción de la morosidad en el otorgamiento de crédito financiero aplicando metodología CRISP-DM** para conseguir el título profesional de Ing. de Sistemas en la Universidad Andina “Néstor Cáceres Velázquez” – Juliaca, Perú – tiene como objetivo desarrollar un estándar de predicción de prórroga al otorga un crédito financiero estableciendo el método CRISP-DM. Su método de investigación es análisis y síntesis. Se utilizó técnicas modernas de DATA MINING que permitió elegir el algoritmo que ayude en el avance e implementación del sistema propuesto. Las redes neuronales son algunos algoritmos que utilizaremos para el aprendizaje del sistema. Se evaluó 4 algoritmos de credit scoring para el pronóstico de la morosidad, sobresaliendo “Bosques aleatorios”, a menos que, su grado de certeza global fue del 82%, el uso del método ágil en conjunto con la “CRISP-DM” fue significativo para alcanzar el avance del sistema web de predicción de demora de crédito denominado SISMO. En conclusión, se obtuvo que “Bosques Aleatorios” es el principal algoritmo para el desarrollo del sistema web SISMO; con el uso de su metodología CRIS-DM.

Según Malaver (2015), en su tesis denominada **Aplicación de redes neuronales para hallar el pronóstico de ingresos en la entidad CATERING & BUFFETS MyS situada en Piura** para lograr el título profesional de Ing. de Sistemas en la UCV, Perú – su propósito es emplear redes neuronales para establecer el pronóstico de ventas con el menos % de errores en la entidad en estudio. Esto se llegó a alcanzar gracias al proceso que planteó Kaastra y Boyd. El tipo de red que se escogió fue la red neuronal multicapa, puesto que, posee 1 cubierta oculta donde se realizan el proceso de datos de entrada (suministra), cuyo resultado es enviada a la capa de salida. Analizando la red planteada a los últimos cuatro años arrojó como error el 1%, y se consiguió evidenciar la Hipótesis planteada. Finalmente se confirmó que es la red adecuada para efectuar el pronóstico de ventas, y la herramienta precisa para este tipo de estudio.

Según Angulo (2016), en su tesis denominada **DISEÑO ARIMA para el pronóstico de la liquidez monetaria mensual en el sistema financiero peruano** para alcanzar el título de Lic. en Estadística en la Universidad Nacional de Trujillo – Perú – Su objetivo principal es comprobar si el estándar ARIMA describe mejor el procedimiento mensualmente la liquidez monetaria del sistema financiero. La Metodología empleada es Box Jenkins (Identificación-aprobación), y el sistema Eviews 6.0. El tiempo de pronóstico fue Agosto 2014-Julio 2015. (2'193,388 millones). Al realizar el estudio presentó un fallo aproximado de S/1,793 en la liquidez del sistema financiero dentro del tiempo de estimación, equivalente al 0.98% del periodo mensual. En conclusión, el modelo cumple con el supuesto básico necesario para su adecuación. Existiendo la raíz unitaria, estacionalidad, no autocorrelación y normalidad; la validez de pronóstico para el diseño fue de una desviación media (DAM) de 6,607.25, etc.



1.2.3. Nivel regional

Según Carpio (2016), en su tesis denominada Pronóstico de ingresos tributarios recaudados de impuestos generales a las ventas a nivel nacional, por la SUNAT, mediante la metodología de Box y Jenkins y Redes neuronales artificiales para optar el título de Licenciado en Estadística – Lambayeque, Perú – Su objetivo es determinar un acercamiento al ingreso por IGV a nivel nacional recaudados mensualmente por la entidad estatal en investigación en el periodo 2015 por medio de un hipertexto de su página web; con dos procedimientos: Box-Jenkins y Redes Neuronales Artificiales. Así mismo evaluar qué proceso se adapta mejor con el objetivo planteado para el 2016. Para el primer proceso se consideró una sola variable dependiente a los ingresos tributarios a nivel nacional; mientras que el segundo método se utilizó 26 covariables que significan entrada tributaria en cada región del país. Para el proceso de los datos se ha utilizado el software estadístico SPSS Ver. 20. El diseño de “B y J” es un SARIIMA (0, 1,1) (1,1 ,0) 12 el cual tiene un error cuadrático promedio (RMSE) igual a 66,921.87 y un error absoluto porcentual (MAPE) de 3.56%; por otro lado, el modelo con redes neuronales artificiales tiene su estructura 26:1:4:1 con RMSE igual a 17,511.13 y un MAPE de 0.85%. Finalmente se determina que el método más eficiente es el de RN para la predicción de ingresos (IGV) recolectados por la SUNAT.

Según Peralta (2017), en su tesis denominada Evaluación de métodos de pronóstico de serie de tiempo para estimar la demanda de la línea de producto Ajino moto en la ciudad de Chiclayo – periodo 2014 – 2016 para obtener el título de Lic. en Administración de Empresas en la USAT –Chiclayo, Perú – tiene como objetivo hallar la técnica de pronóstico de la demanda de los principales productos de la marca antes mencionada. Para iniciar con el estudio se propuso una técnica de patrón de serie de tiempo, lo cual no fue satisfactorio con el propósito. Luego se

utilizó el método Winters mediante series de datos, el cual si se ajustó al objetivo de análisis. Se concluye con un modelo estacionario y selección de un método de pronóstico a través de la técnica de suavizado exponencial (Winters) que cumpla con el supuesto estadístico que se requiere.

1.2.4. Nivel institucional

Según Benites (2018), en su indagación denominada Implementación de un sistema de pronóstico de ventas con redes neuronales para la empresa industrial “Cerámicos Lambayeque SAC” para conseguir el título de Ing. de Sistemas en la USS – Pimentel, Perú – El propósito principal es efectuar un procedimiento usando redes neuronales para pronosticar los ingresos de la empresa Industrial “Cerámicos Lambayeque SAC”. Se utilizó la metodología desarrollada por Kaastra y Boyd siguiendo los siguientes pasos: selección de la variable, recaudación de información, Pre-proceso de datos, definición del grupo de ejercicio, validación, elección de la arquitectura de RN, criterios de evolución, implementar el diseño de la Red Neuronal. Se tomó las ventas diarias del año 2016 y 2017.

Se puede observar que en el mes de enero la empresa logró en la venta diaria real S/. 670,675 y la venta diaria pronosticada con la red neuronal obtuvo S/. 668,705. El grado de confiabilidad de la red neuronal para este mes es de 99,71 %, esto indica que la red neuronal se aproximó más a la venta diaria real, difiriendo solo en el 0,29 % en la aproximación a la venta diaria real.

Las deducciones obtenidas en la predicción empleando redes neuronales artificiales (RNA) optimizan la toma de decisión en el área de compra y venta de la organización.

Tiempo utilizado por la red neuronal para predecir las ventas diarias mensuales, este tiempo asciende a 24 minutos con 37 segundos, esto se debe a que la red neuronal utiliza las ventas que

se encuentran en una matriz para pronosticar la venta siguiente y luego introducirla en la matriz de ventas que será utilizada en las siguientes predicciones, repitiendo así el ciclo hasta acabar con todo el pronóstico. El tiempo utilizado para ejecutar la red neuronal depende del procesador, etc. que estemos utilizando.

La memoria consumida por el sistema para ejecutar la red neuronal es de 0.0165328 Gigabytes, esta memoria es la suma acumulativa del espacio que ocupa en memoria los objetos que se han utilizado en la programación de la red neuronal – int, double, etc. –. Para disminuir el consumo de memoria es necesario optimizar la programación de la red neuronal. En conclusión se utilizó el análisis de regresión de serie temporal mediante datos de ventana con desplazamiento combinados con la red neuronal perceptrón multicapa; dicha red propuesta tiene 4 nodos de entrada, 12 nodos de procesamiento confidencial y un único nodo de salida; la red neuronal propuesta tienen 73 pesos sinápticos; En la instrucción de la red para la predicción de las ventas se manejó el algoritmo de retro propagación con un índice de aprendizaje de 0.01 y 10.000 iteraciones; con un ratio de aprendizaje de 0.01 se obtienen las siguientes ventas pronosticadas: 22.380, 22.294, 22.349....., etc. Si ajustamos la ratio de enseñanza a 0.02 se adquieren las siguientes ventas: 22.315, 22.321, 22.408....., etc. Con una ratio de aprendizaje de 0.1 se obtienen ventas por encima de las ventas diarias avenenadas en el año 2018. Se debe ajustar la ratio de aprendizaje para suavizar las ventas; la dimensión de equivocación en la predicción expuesta por la sociedad es enorme, en cambio el pronóstico de la red neuronal tiene un nivel de error pequeño.

Roque (2016), en su tesis denominada **Estudio comparativo de procesos de minería de datos para la predicción de ventas** para alcanzar el título profesional de Ing. de Sistemas en la “USS” – Pimentel – se realiza un análisis comparativo entre las distintas técnicas usadas en

la minería de datos para el diseño de modelo de pronósticos de series de tiempo. La problemática no trata de la creación de un prototipo de minería de datos, si no evaluar que algoritmo y técnica sirve para un problema específico, ya que, no es igual el pronóstico de series de ventas con el de clima; esto dependerá mucho del problema que busca resolver. El análisis determina la estimación de venta según lo que genera mensual o trimestral, uno de los algoritmos estadísticos más comunes para pronósticos es el Holtwinters.

1.3. Estado del arte

Según Fernández (Sin año de publicación), en su artículo denominado **Modelos de pronósticos de ventas** tiene como objetivo analizar el método ARIMA, elementos no visibles (UC), wavelets y support vector machines (SVM). Esto se logró tomando las ventas de manufacturas de materiales y metales exportados en los últimos 20 años por Chile a EEUU para pronosticar las ventas futuras. los resultados muestran que ARIMA y UC son un poco más exactos. Se concluye que la mezcla de lineales de predicción puede ser preferibles al pronóstico individual.

Según Corres et al (2015), en su artículo **Estudio comparativo de modelos de pronóstico de ventas** tiene como objetivo comparar la conducta de métodos de pronósticos sobre ventas sobresalientes. Esto se logró tomando las ventas de diez años de atún en aceite y al natural, caballa (aceite-natural) y sardina en aceite. Se calcularon los pronósticos utilizando diversos métodos: determinísticos (suavizado exponencial en su versión simple y compleja), ARIMA (Procedimiento Autor regresivo Integrado de Medias Móviles) y ANFIS (Sistema Adaptativo de Inferencia Neuro Difuso). El resultado obtenido demuestra que cuando los datos son analizados cada tres meses su error de valor en mínimo y este resultado es asociado a la menor

variabilidad de la serie. Se concluye que los sistemas utilizados tienen como ventajas que pueden ser mejorados.

Según Manjarres y Mogollon (2017) en su tesis denominada **Diseño de una herramienta de pronóstico, para una línea de envasados de una planta que elabora productos de consumo masivo** para optar el título de Máster en Ingeniería Administrativa en la Universidad del Norte – Barranquia, Colombia – propone un diseño para la deducción de pronóstico de ingresos en una entidad de aceites vegetales. Basado en diseños de clase cuantitativos; después de haber hecho los cálculos en el sistema de forma automática, dicho proceso describe de mejor modo la conducta de los datos del producto en estudio, así mismo el estándar seleccionado debe minimizar el error del pronóstico. Y de tal modo poder hacer válido el funcionamiento del método propuesto. Al finalizar el procedimiento de este trabajo se presentan las validaciones realizadas, además se muestra una mejora del 27% aprox.

1.4. Bases teórico científicas

1.4.1. Algoritmo

Algoritmo, conforme la Real Academia, lo describe como el grupo regulado y definido de operaciones que logran hallar la respuesta a cualquier problemática. (Baeza R., Sin año de publicación).

1.4.2. Pronóstico

Según Villareal (2016) Se refiere a una evaluación cuantitativa o cualitativa de una o más elementos que forman un hecho futuro.

¿Cuál es el objeto del pronóstico?

¿Qué modelo utilizar?

Según Gálvez (sin año de publicación) Elegir el modelo de pronóstico adecuado no es cosa fácil para una organización, ya que existen varios sistemas que podrían utilizar conforme a su necesidad. El propósito es localizar cuál de todos se adapte con la venta real.

Clasificación de los pronósticos

Según Manjarres y Mogollon (2017) Los clasifican en 4 clases: cualitativo, análisis de serie-tiempo, relación causal y simulación.

a) Métodos de pronósticos cualitativos

Según los autores antes citados, indican que aquellos datos que son integrados al pronóstico no podrían ser cuantitativas, deben ser intangibles y subjetivas. La información verdadera no resulta ser sobresaliente. Por lo tanto, el ambiente de los procedimientos, se vuelven complicado y difícil de establecer y realizar su validación.

b) Métodos Cuantitativos

Según Manjarres y Mogollon (2017) los define como una metodología objetiva derivaba de un estudio (datos). Los estándares causales son aquellos que usan información proveniente de una fuente diversa a la serie que están siendo objeto de análisis, es decir, pueden existir otras variables con valores que están vinculadas de otra manera a lo pronosticado.

1.4.3. Promedio Móvil

Concepto

Según Jiménez (2013) refiere el procedimiento de promedios móviles es utilizado para realizar un pronóstico rápido, económico, simples y de mediano plazo, dando mayor énfasis a la información más reciente de la serie de tiempo, para pronosticar el periodo siguiente.

Según Contreras et al (2011) refiere que el promedio aritmético es calculado por un N° predeterminado de valores por un cierto factor, separado por el N° de etapas de período.

Objetivo

Según Montoya (2006) refiere que para realizar un cálculo estimado sobre los acontecimientos futuros utilizando el modelo de promedio móvil¹.

Comportamiento histórico

Según Gálvez (Sin año de publicación) tiene un comportamiento histórico horizontal o estacionario.

Características

Según Montoya (2006) presenta las siguientes características:

Se utiliza para calcular los valores futuros en base a una data histórica. Se necesita orden sucesivo de la información y tener la misma duración. Deben obtenerse los periodos de manera uniforme de la muestra de datos que falte tiene que ser substituida por una nueva.

Hay muchas metodologías, las organizaciones deben decidir por alguna, después experimentar su efectividad para el pronóstico, para después aplicarlo a hechos determinados.

Estima valores para la fase que se quiere pronosticar, tomando en cuenta la valoración del promedio calculado de la variable, durante un N° Definido de un periodo anterior. Una media móvil provee informaciones de tendencias que se encuentran ocultas por una simple media de toda la data histórica.

Cuanto menos sea el N° de periodos a usar para el promedio móvil, el pronóstico reacciona rápidamente a los cambios que se tiene en la data histórica y viceversa.

Procedimiento

Según Montoya (2006) se debe seguir el siguiente procedimiento:

Contar con información histórica apropiada y veraz.

Seleccionar N periodos para empezar a calcular el promedio A_t de los datos D_t seleccionados de los N últimos periodos en el tiempo t. esto se realiza aplicando la siguiente fórmula matemática:

$$A_t = \frac{D_t + D_{t-1} + \dots + D_{t-N+1}}{N}$$

A_t es el pronóstico para el siguiente periodo.

Dado que la serie de tiempo es continua, la mejor predicción para el periodo

$t + 1$ es $F_{t+1} = A_t$.

Proceder a procesar la información.

Decidir si se toma el pronóstico o se toma otro método.



Aplicaciones

Según Gálvez (Sin año de publicación) refiere que son fáciles de comprender y enseñar porque diseñan componentes perceptibles de la secuencia como: estilo y estacionalidad.

Ventajas

Según Montoya (2006) presenta las siguientes ventajas:

Accede aproximarnos al futuro, para facilitar al tomar una decisión.

Los pronósticos que son planificados. Es valioso y exacto que los automáticos.

Desventaja

Según Montoya (2006) presenta las siguientes desventajas:

No hay un procedimiento de pronóstico que sea mundial, idóneo de adecuarse a varias circunstancias y contextos, tiene que ser elegido minuciosamente, dependiendo del uso determinado que se le quiera dar al producto y las particularidades cualitativas que se podrían tener.

Es una simplificación y no se afirma que las variables influyan en el pronóstico.

Se utiliza para pronosticar un periodo más.

Ejemplo

El siguiente ejemplo se ha tomado de Gálvez (Sin año de publicación). Se identifica el cálculo $n=2$ para el pronóstico **6**. Se consigue el error en valor absoluto y se divide por el valor actual de las ventas. Esto se utilizará para calcular la Media Absoluta del % de fallo (MAPE).

Este modo se vuelve a repetir hasta conseguir el valor del pronóstico del periodo 6. Conforme se observar en la Tabla 3, se comprueban distintos valores de “n” y se suspende el cálculo cuando el MAPE sea el más corto.

$$\text{Pronóstico}_3 = (\text{Venta}_1 + \text{Venta}_2) / N$$

$$= (9+4)/2$$

$$\text{Pronóstico}_3 = 6.5$$

$$\text{Pronóstico}_4 = (\text{Venta}_2 + \text{Venta}_3) / N$$

$$= (4+7)/2$$

$$\text{Pronóstico}_4 = 5.5$$

$$\text{Error}_3 = \text{Venta}_3 - \text{Pronóstico}_3$$

$$= 7 - 6.5$$

$$\text{Error}_3 = 0.5$$

Error Absoluto₃= Si es negativo el Error₃ lo pasamos como positivo, si es positivo pasa como positivo.

$$\text{MAPE}_3 = \text{Error Absoluto}_3 / \text{Venta}_3$$

$$= 0.5/7$$

$$\text{MAPE}_3 = 0,0714285714285714$$

Cálculo de Pronostico del mes 6 y el MAPE con N=2

$$\text{Pronostico mes 6} = (9+5)/2 = 7$$



$$\text{MAPE} = ((0.7+0.38+0.60)/3)/100 = 35.00 \%$$

El valor de “n” puede variar de acuerdo a la información disponible. El objetivo es encontrar aquel que minimice el MAPE.

1.4.4. Suavizado exponencial simple o atenuación exponencial simple (AES)

Concepto

Según Burgaentzle (2016) refiere que el suavizado exponencial simple se basa en un término medio imparcial de la observación nueva y la anterior. El peso aplicado a la observación más reciente es a , donde $0 < a < 1$, y el peso aplicado al último pronóstico es $1 - a$.

Según Gálvez (Sin año de publicación) la atenuación exponencial simple (AES) utiliza la siguiente fórmula matemática.

$$\text{Pronóstico}_{t+1} = \text{Pronóstico anterior}_t + (\alpha)e_t$$

Pronóstico_{t+1} = Pronóstico para el siguiente periodo.

Pronóstico anterior_t = Pronóstico en el periodo t.

(α) = Factor de ponderación o peso del error "t".

e_t = Error en periodo t.

Según la Universidad Simón Bolívar, (Sin año de publicación) el valor de a se escoge de manera subjetiva. Gonzalo (2008) el valor de a toma las siguientes condiciones:

Si a esta más cerca de 1 , la serie suavizada considera firmemente el valor principal; después las dos se asemejan y como resultado, el suavizamiento es bajo.



Vemos que a se aproxima a $\frac{1}{2}$, pasamos a ponderar de manera moderada la serie original y la suavizada, por lo tanto, el suavizado es solo contenido.

Si a esta próximo a cero, $(I-a)$ está más cerca de I , y la serie suavizada pondera más fuerte al valor inmediato previo, esto indica que es significativo.

Objetivo

Según Mata (2018). Se utiliza para obtener un valor suavizado para la serie utilizando los datos históricos para convertirse en el pronóstico del valor futuro de una serie.

Según Mata (2018) el objetivo de este tipo de métodos de predicción es distinguir entre las fluctuaciones aleatorias y el patrón básico subyacente, mediante el “suavizamiento” (promedio) de los valores históricos. De esta manera se elimina el término aleatorio encontrado en la secuencia histórica y se establece un pronóstico en el patrón suavizado de los datos.

Comportamiento histórico

Según Gálvez (Sin año de publicación) tiene un comportamiento histórico horizontal o estacionario.

Características

- 1) Es muy fácil y se puede reaccionar automáticamente ante variaciones de la venta (Álvarez 2009).
- 2) Es utilizada para pronosticar valores futuros en base a una data histórica (Montoya 2006).
- 3) Es utilizada en ocasión que la data histórica de la venta no posee tendencias o factores estacionales que la cambien (Gálvez Sin año de publicación).
- 4) Es importante que la data se encuentre ordenada de acuerdo a los periodos que se deseen utilizar debiendo tener la misma duración (meses, días, etc.). La obtención de la data debe haber sido recolectada teniendo en cuenta periodos semejantes de la muestra (toda la semana/lunes-viernes) la investigación que falte debe ser sustituida por nueva información (Montoya 2006).
- 5) Calcula el promedio a través de un sistema de autocorrección que pretende ajustar el pronóstico de ventas en orientación contraria a las desviaciones del pasado. (Salazar 2016).

Procedimiento

Según Montoya (2006) se debe seguir el siguiente procedimiento:

1. Tener información histórica adecuada y confiable.
2. Para el primer periodo no se calcula el pronóstico. El pronóstico del segundo periodo se le asigna la venta del primer periodo.

$$\text{Pronóstico}_{t+1} = \text{Venta}_{t-1}$$

Se calcula el error:

$$E_t = \text{Venta}_t - \text{Pronóstico}_t$$

Se calcula el error absoluto:

$$EA_t = \text{ABS}(E_t)$$

Se calcula el MAPE:

$$MAPE_t = \frac{EA_t}{\text{Venta}_t}$$

A partir del tercer periodo se aplica la fórmula matemática que se encuentra en la definición del suavizado exponencial simple Gálvez (Sin año de publicación).

3. Procesamiento de la información.
4. Elegir si tomamos el pronóstico o utilizamos otro algoritmo.

Aplicaciones

Según Gálvez (Sin año de publicación) refiere a un sistema computarizado de control de inventario/producción.



Ventajas

- 1) Es uno de los métodos más utilizados para pronosticar ya que se necesitan pocos datos (Ariza 2013).
- 2) Es uno de los métodos que responde mejor a los cambios de la demanda (Ariza 2013).
- 3) Tiene la superioridad sobre el promedio móvil ponderado y no requiere de mucho aumento de períodos y aprobaciones para conseguir un óptimo resultado (Salazar 2016).

Desventaja

- 1) Su crecimiento es exponencial, da significación al estudio final, es por eso que únicamente trabaja con los últimos datos reales o pronosticados (Ariza 2013).
- 2) No ofrecen buenos resultados para productos con poca historia de ventas (Ibarra 2006).

Ejemplo

El siguiente ejemplo se ha tomado de Gálvez (Sin año de publicación). El pronóstico del segundo mes es el mismo que el anterior. Se consigue la desigualdad del valor actual de venta de la primera fase y del pronóstico, luego se le pondera por el valor de alfa (α) seleccionado. (" α " asigna un peso al error). Por lo tanto, entre más errores contenga, obtendrá mayor importancia. Se calcula el error en valor absoluto y se divide entre el valor real para el cálculo de la Media Absoluta del Porcentaje de Error (MAPE). Como se demuestra en la Tabla N°4 el cálculo de este proceso.

Se asigna la venta del primer periodo al pronóstico del segundo periodo.

$$\text{Pronóstico}_2 = \text{Venta}_1$$

$$\text{Pronóstico}_2 = 9$$

Se calcula el error del segundo periodo.

$$E_2 = \text{Venta}_2 - \text{Pronóstico}_2$$

$$E_2 = 4 - 9$$

$$E_2 = -5$$

Se calcula el error absoluto del segundo periodo.

$$EA_2 = \text{ABS}(E_2)$$

$$EA_2 = 5$$

Se obtiene el MAPE para el segundo periodo.

$$\text{MAPE}_2 = \frac{EA_2}{\text{Venta}_2}$$

$$\text{MAPE}_2 = \frac{5}{4}$$

$$\text{MAPE}_2 = 1.25$$

Se calcula el pronóstico del tercer periodo de manera consecutiva hasta llegar al periodo 6.

$$\text{Pronóstico}_3 = \text{Pronóstico}_2 + (a) * E_2$$

$$\text{Pronóstico}_3 = 9 + (0.1) * (0.5)$$

$$\text{Pronóstico}_3 = 8.5$$



1.4.5. Redes Neuronales

Según López et al (2005) y Maciado (2013) presentan las siguientes definiciones:

- a) Nueva manera de informática iluminada en diseños biológicos.
- b) Un modelo matemático variado entre el N° de elemento procesal establecido en niveles.
- c) Un sistema de procesamiento de datos mezclado por una gran cantidad de elemento simple, de técnicas interrelacionadas, aquellos tienen la función de procesar información a través de un estado dinámico.
- d) Redes neuronales artificiales llamadas también redes interconectadas abundantemente en paralelo de elementos sencillos (adaptables) y con estructura de alto nivel.

Estructura

Según Serrano et al. (2015) afirma que la red neuronal está constituida por 1 o más capas, las neuronas interactúan unas con otras utilizando la sinapsis. La neurona está considerada como un componente simple (Figura 1). Las dendritas son las vías por donde se ingresa información; el cuerpo de la neurona es la encargada de integrar las señales de entrada para proporcionar una respuesta, habitualmente sigue una función matemática no lineal de transferencia; el axón se encarga de propagar esta respuesta a todas las neuronas. La intensidad con la que interactúan las neuronas está dada por el peso sináptico de cada una de ellas: si el valor es positivo, la neurona pre sináptica estimulará al pos sináptica; si su valor es negativo, la inhabilitará. Todo ello en mayor o menor medida según el valor absoluto.



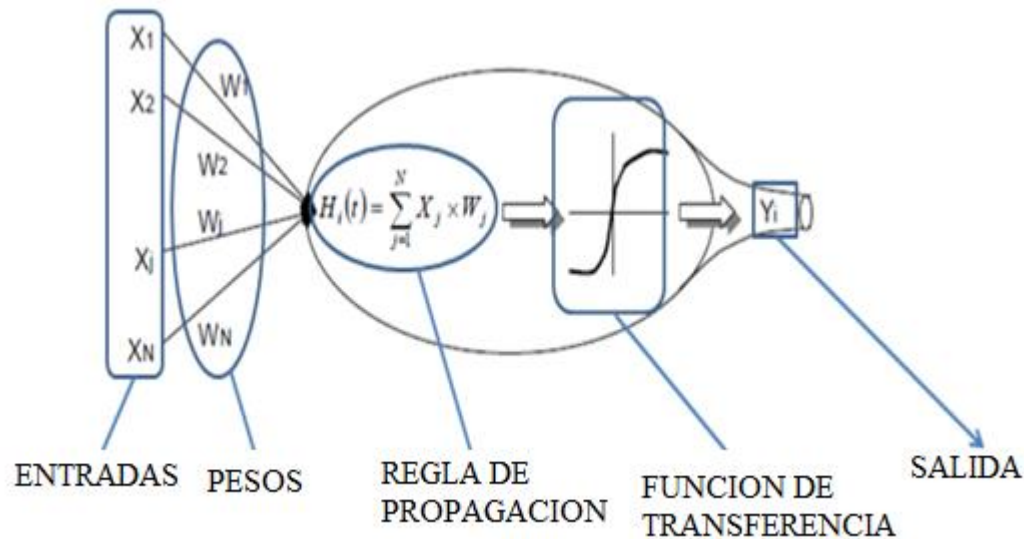


Figura 1. Esquema general de una red neuronal artificial.

Fuente. Maciado (2013).

Operación

Según Serrano et al. (2015) afirma que la red neuronal utiliza dos operaciones para aprender: aprendizaje y recuerdo. La red neuronal está conectada a muchas neuronas de manera aleatoria, no dispone de ninguna información previamente almacenada, debe ser preparada para ejecutar un específico trabajo. Por ello debe tener un grupo de patrones, el cual se constituye en la etapa de enseñanza. La comprensión no es programada de manera directa en la red neuronal, como se hace en el sistema algorítmico tradicional, sino que se le suministra patrones, estos tienen que adecuarse al ejercicio que pretende realice el proceso. La red neuronal, basándose en este ejemplo y llevando a cabo un algoritmo de estudio, iterativamente cambia el valor de los pesos sinápticos, adecuando constantemente la solución a lo que se espera de los programadores. El cálculo de la red neuronal no está definido por un algoritmo, sino por la complicada estructura de conexiones que durante las fases de aprendizaje se crearan entre las neuronas. La sinapsis almacenara la información de una manera distribuida.



Se ha elegido un diseño de RN conforme a la necesidad de la problemática, se seleccionó un grupo de patrones característicos de la operación que queremos que se efectúe, la red neuronal revelará la capacidad de generalización: basándose en los ejemplos dados separara la regla subyacente, y manifestara en un futuro pertinentemente a nuevos patrones que jamás habían percibido.

Terminado el ejercicio, la red neuronal trabajará en la condición recuerdo, el que responde a un definitivo patrón de ingreso, sin cambiar la estructura y las interconexiones, conforme el entrenamiento recogido proporciona una respuesta. El cálculo que realiza una neurona operando en modo recuerdo es el siguiente:

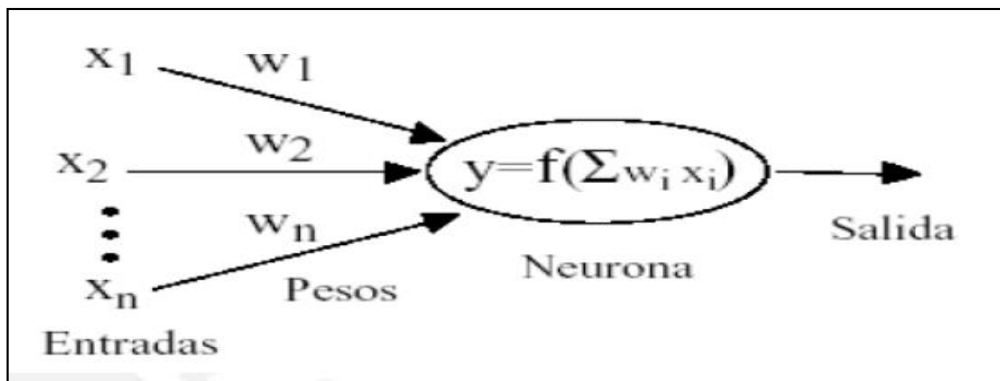


Figura 2. Operación en una neurona artificial

Fuente. Carranza (2014)

Arquitectura

Según Serrano et al. (2015) la arquitectura de la red neuronal es el modo que se organiza la neurona. Las diferentes podemos dividir las en dos tipos básicos: feedforward (la información fluye adelante), como en el ejemplo de la Figura 3. Y las recurrentes (el dato informativo a veces retrocede), a través de realimentaciones. Tenemos miles de tipos en diseños neuronales, depende de la operación y el tipo de aprendizaje de la arquitectura.



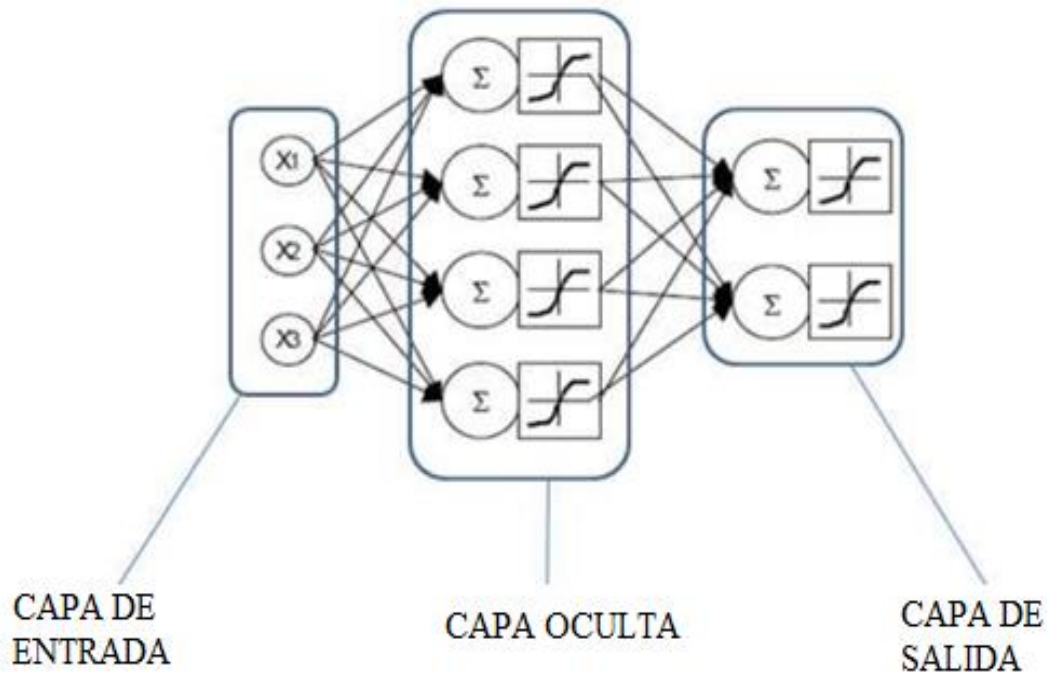


Figura 3. *Arquitectura de una red neuronal artificial.*
Fuente: Maciado (2013).

Perceptrón Multicapa

Según Serrano et al. (2015) refiere que se trata de una arquitectura multicapa, la primera capa es un conjunto de neuronas que transmiten las variables de entrada a las capas internas, las cuales se encargan del proceso, y otras de salida que dan a conocer el resultado al exterior.

Ha mediado de la década de los 70, Paul Werbos en su plan doctoral plantea el Algoritmo Backpropagation, que accede ejercitar al Perceptrón multicapa y facilita su adaptación en la solución de una gran diversidad de problemas de gran complicación (Caicedo et al, 2017).

Se observa en la imagen #4 la distribución del Perceptrón, que a desigualdad del Adaline, este tiene al menos 03 niveles de neuronas. Podemos plantear más de una capa interna, pero no es recomendable pues aumenta su complejidad computacional del algoritmo de estudio, basta un MLP con una sola capa oculta.



Para el Multi Layer Perceptrón la conexión es completa, ya que, si agarramos una neurona del nivel de ingreso, ésta tiene un enlace con todas las neuronas de la capa oculta siguiente, para mejor entendimiento se observa la imagen N° cuatro. Por lo habitual, se le efectúan unidades de umbral con el propósito de hacer que la superficie de desprendimiento no permanezca anclada en el principio del espacio *n-dimensional* en donde se esté ejecutando la separación. La función de activación que usan las neuronas de una red MLP suele ser lineal o en otros casos sigmoideal (Caicedo et al, 2017).




Figura 4. *Arquitectura General de un MLP*

Fuente. *Caicedo et al. (2017)*



Procedimiento

Según Ariza (2013) refiere que se debe seguir en la implementación de la red las siguientes fases:

- 1) Selección de la Variable.
- 2) Recolección de Datos.
- 3) Procesar información.
- 4) Definir grupo de Preparación, Validación y Prueba.
 - a. Grupo de Elaboración.
 - b. Conjunto de Validación.
 - c. Agrupación de Prueba.
- 5) Selección topología de la red neuronal.
 - a. Cantidad de Neuronas de Entrada.
 - b. N de Capas Internas.
 - c. N° Neuronas Ocultas.
 - d. N° de Neuronas de Salida.
 - e. Ocupación de Transferencia.
- 6) Razonamiento de evaluación.
- 7) Adiestramiento de la red.
 - a. N de Iteraciones.
- 8) Ejecución del diseño de Redes Neuronales Artificiales.

Entrenamiento de un MLP

Según Caicedo et al. (2017) y Lara (Sin año de publicación) explican conceptualmente el algoritmo de aprendizaje Backpropagation de la siguiente manera:

- 1) Escogemos un grupo de patrones correspondientes a la problemática a resolver. Depende de la cualidad de datos usados para la preparación, será la característica de enseñanza de la red.
- 2) Empleamos un vector de ingreso a la red y deducimos la salida de las neuronas internas, difundimos estos valores hasta tener el cálculo final.
- 3) Deducimos la inexactitud entre el valor deseado y la salida de la red.
- 4) Reproducimos el error hacia atrás (capa oculta).
- 5) Cambiamos los pesos de las capas de salida e internas con base en una estimación del cambio de los pesos Δw en cada una.
- 6) Comprobamos la condición de parada del algoritmo por error calculado en la salida.
- 7) Al no cumplir con ninguna de las circunstancias de parada, volvemos a exponerle a la red un patrón de entrenamiento.

Algoritmo Backpropagation

Según Caicedo et al. (2017) y Lara (Sin año de publicación) presentan la nomenclatura en la tabla 1 y el algoritmo de aprendizaje Backpropagation.

Tabla 1.
Notación utilizada por el algoritmo backpropagation

SIMBOLO	DESCRIPCION
X_p	Patrón o vector de entrada.
X_{pi}	Entrada i-ésima del vector entrada X_p .
N	Dimensión del vector entrada.
P	Numero de ejemplos, vectores de entrada y salidas diferentes.
L	Numero de neuronas de la capa oculta : h.
M	Numero de neuronas de la capa de salida, dimensiones del vector de salida.
w_{ji}^h	Peso de interconexión entre la neurona i-ésima de la entrada y la j-ésima de la capa oculta.
θ_j^h	Termino de tendencia de la neurona j-ésima de la capa oculta.
Net_{pj}^h	Entrada neta de la j-ésima neurona de la capa oculta.
i_{pj}	Salida de la j-ésima neurona de la capa oculta.
f_j^h	Función de activación de la j-ésima unidad oculta.
w_{kj}^0	Peso de interconexión entre la j-ésima neurona de la capa oculta y la k-ésima neurona de la capa oculta.
θ_k^0	Termino de tendencia de la k-ésima neurona de la capa oculta.
Net_{pk}^0	Entrada neta de la k-ésima neurona de la capa oculta.
y_{pk}	Salida de la k-ésima unidad de salida.
f_k^0	Función de activación de la k-ésima unidad de salida.
d_{pk}	Valor de salida deseado de la k-ésima neurona de la capa oculta.
E_p	Valor del error para el p-ésima patrón de aprendizaje.
α	Taza o velocidad de aprendizaje.
δ_{pk}^0	Termino de error para la k-ésima neurona de la capa de salida.
δ_{pj}^h	Termino de error para la j-ésima neurona de la capa oculta h.
f_j^h	Derivada de la función de activación de la j-ésima neurona de la capa oculta.
f_k^0	Derivada de la función de activación de la k-ésima neurona de la capa de salida.

Fuente. *Caicedo et al. (2017) y Lara (Sin año de publicación)*



Algoritmo de aprendizaje Backpropagation.

1. Inicializamos los pesos del MLP.
2. Mientras la condición de parada sea falsa ejecutamos los pasos 3 a 12.
3. Aplicamos un vector de entrada $x_p = [x_{p1}, x_{p2}, \dots, x_{pi}, \dots, x_{pn}]$.
4. Calculamos los valores de las entradas netas para la capa oculta.

$$Neta_{pj}^h = \sum_i^N w_{ji}^h x_{pi} + \theta_j^h$$

5. Calculamos la salida de la capa oculta.

$$i_{pj}^h = f_j^h(Neta_{pj}^h)$$

6. Calculamos los valores netos de entrada para la capa de salida.

$$Neta_{pk}^0 = \sum_{j=1}^L w_{jk}^0 i_{pj}^h + \theta_k^0$$

7. Calculamos las salidas de la red.

$$y_{pk} = f_k^0(Neta_{pk}^0)$$

8. Calculamos los términos de error para las unidades de salida.

$$\delta_{pk}^0 = (d_{pk} - y_{pk}^0) f_k^0(Neta_{pk}^0)$$

9. Estimamos los términos de error para las unidades ocultas.

$$\delta_{pj}^h = f_j^h(Neta_{pj}^h) \sum_{k=1}^M \delta_{pk}^0 w_{kj}^0$$

10. Actualizamos los pesos en la capa de salida.

$$w_{kj}^0(t + 1) = w_{kj}^0(t) + \alpha \delta_{pk}^0 i_{pj}^h$$

11. Actualizamos pesos en la capa oculta.

$$w_{ji}^h(t + 1) = w_{ji}^h(t) + \alpha \delta_{pj}^h x_{pi}$$

12. Verificamos si el error global cumple con la condición de finalizar.

$$E_p = \frac{1}{2} \sum_{P=1}^P \sum_{K=1}^M (d_{pk} - y_{pk})^2$$



Ventajas

Según Wikidot.com. (Sin año de publicación) refiere que este tipo de redes presentan las siguientes ventajas:

- 1) **Aprendizaje:** Tiene la destreza de aprender a través de una fase de enseñanza. Esta radica en facilitar a la red datos de ingreso y le señale la salida deseada.
- 2) **Auto organización:** Diseña su propio grafico de indagación en su interior, eliminando al consumidor.
- 3) **Tolerancia a fallos:** Una red acumula la investigación de forma repetitiva, por lo tanto, seguirá en función, aunque se presenten alguna falla.
- 4) **Flexibilidad:** La red logra manipular una alteración, no importantes en la investigación de entrada, como caracteres de sonido u otras alteraciones.
- 5) **Duración real:** Su organización de la red es equivalente, por lo tanto, si se le implementa un dispositivo electrónico obtiene una respuesta en tiempo actual.

Desventajas

Según Wikidot.com. (Sin año de publicación) refiere que este tipo de redes presentan las siguientes desventajas:

Complicación de enseñanza para extensos trabajos.

- 1) Duración de aprendizaje elevado por 02 componentes:
 - ✓ Si se aumenta el conjunto de patrones a distinguir o archivar.
 - ✓ Si necesita una alta demanda de ser flexible de adaptar.

- 2) Restringe la interpretación de lo aprendido, quiere decir, que requiere la participación del procesador y la adaptación para definirle un significado a la salida proporcionada.
- 3) Para tener una fácil identificación de la red, debe procesarle un alto monto de datos para la preparación.
- 4) Deficiencia de normas definitorias que aporten a realizar una red para una dificultad dada.

1.4.6. ARIMA (Método Autorregresivo Integrado de Medias Móviles)

Concepto

Según Gonzalo (2008) los diseños multivariantes intentan explicar la conducta de uno o más variables en función del avance de unas terceras que se consideren explicativas y predeterminadas. Por otro lado, los estándares econométricos examinan de modo explicativo la indagación que suman las variables causales del fenómeno de interés conforme una establecida práctica monetaria. La ventaja radica en las deducciones que originan estas son eficientes y tienen poder explicativo que el de tipo univariante. En cambio, cuando el futuro suele presumir una variación de tendencias de comportamiento con relación al pasado, es aconsejable usar estos diseños causales para tener una mejor predicción a medio término (uno a cinco años).

Los estándares univariantes no requieren estar al tanto de ninguna relación de causalidad explicativa de la conducta de la variable endógena. Le basta solo con conocer una secuencia transitoria de la variable en análisis, para apreciar el patrón que se utilizará para realizar el pronóstico.

Para dar soluciones a problemas financieros tenemos dos propósitos:

El pronóstico de alguna variable explicativa de un esquema causal, esto nos servirán si queremos conservar una de sus cualidades del avance anterior.

El pronóstico a corto termino, debido a su gran capacidad para recolectar la dinámica de la conducta de la variable en indagación.

Entre las técnicas univariantes existen algunas muy sencillas como los diseños: autorregresivo, tendencia lineal o exponencial, etc. Las técnicas más rigurosas para la predicción univariante son las técnicas Box-Jenkins, porque dicho proceso constituye el grupo más enorme, dentro el cual los modelos ARIMA univariantes son sólo una parte.

Objetivo

- 1) Ser flexible y un buen manejo apropiado para la modelización y predicción de una extensa variedad de secuencias de tiempo (Yacuzzi et al, Sin año de publicación).
- 2) Señalar y considerar un estándar estadístico que puede ser interpretado como procesador de información (Pérez et al, 2017).

Características

Según Box y Jenkins. (Sin año de publicación) los modelos ARIMA tienen las siguientes características:

- 1) ARIMA se emplean el dato discreto (N° entero) o continuo (no cifra decimal). Mientras que los datos continuos son medidos en intervalos fraccionarios.
- 2) Dicho método tanto con datos discretos y continuos, solo se aplican en intervalos discretos de tiempo. Se clasifica en dos tipos: 1) datos que son producto de la acumulación durante un periodo de tiempo (ahorros). 2) datos que son producto de

la medición instantánea periódicamente (medición de la presión en una tubería en intervalos de una hora).

- 3) Este prototipo requiere una pequeña cantidad de datos. Los profesores Box y Jenkis sugieren un mínimo de 50 observaciones.
- 4) Los modelos ARIMA son especialmente útiles en el tratamiento de series que presentan patrones estacionales.
- 5) Los procesos Box-Jenkins aplican a series que son y no son estacionarias.
- 6) Se asume que las perturbaciones aleatorias (a_t) presentes en la serie, son independientes. No existe correlación ni tampoco un patrón modelable.

Tipo modelo

Según Corres et al (2015) el promedio móvil integrado (ARIMA o método estocástico) pertenece al modelo cuantitativo.

Etapas para la construcción de un modelo ARIMA

Según Angulo (2016) sostiene que ARIMA es como (p, d, q) donde los parámetros son n° enteros positivos que señalan el orden de los diferentes componentes del estándar respectivo, estos elementos Autorregresiva, compuesta y de media móvil. Cuando algunos de los 03 parámetros es 0, es común quitar los símbolos proporcionados por el acrónimo; AR para la componente Autorregresiva, I para la integrada y MA para la media móvil. Por ejemplo, ARIMA (0, 1, 0) se puede expresar I (1) y ARIMA (0, 0, 1) como MA (1).

El modelo ARIMA (p, d, q) puede generalizarse aún más para considerar el efecto de la estacionalidad.

El modelo ARIMA se puede representar como:

$$Y_t = -(\Delta^d Y_t - Y_t) + \phi_0 + \sum_{i=1}^p \phi_i \Delta^d Y_{t-1} - \sum_{i=1}^q \theta_i E_{t-1} + E_t$$

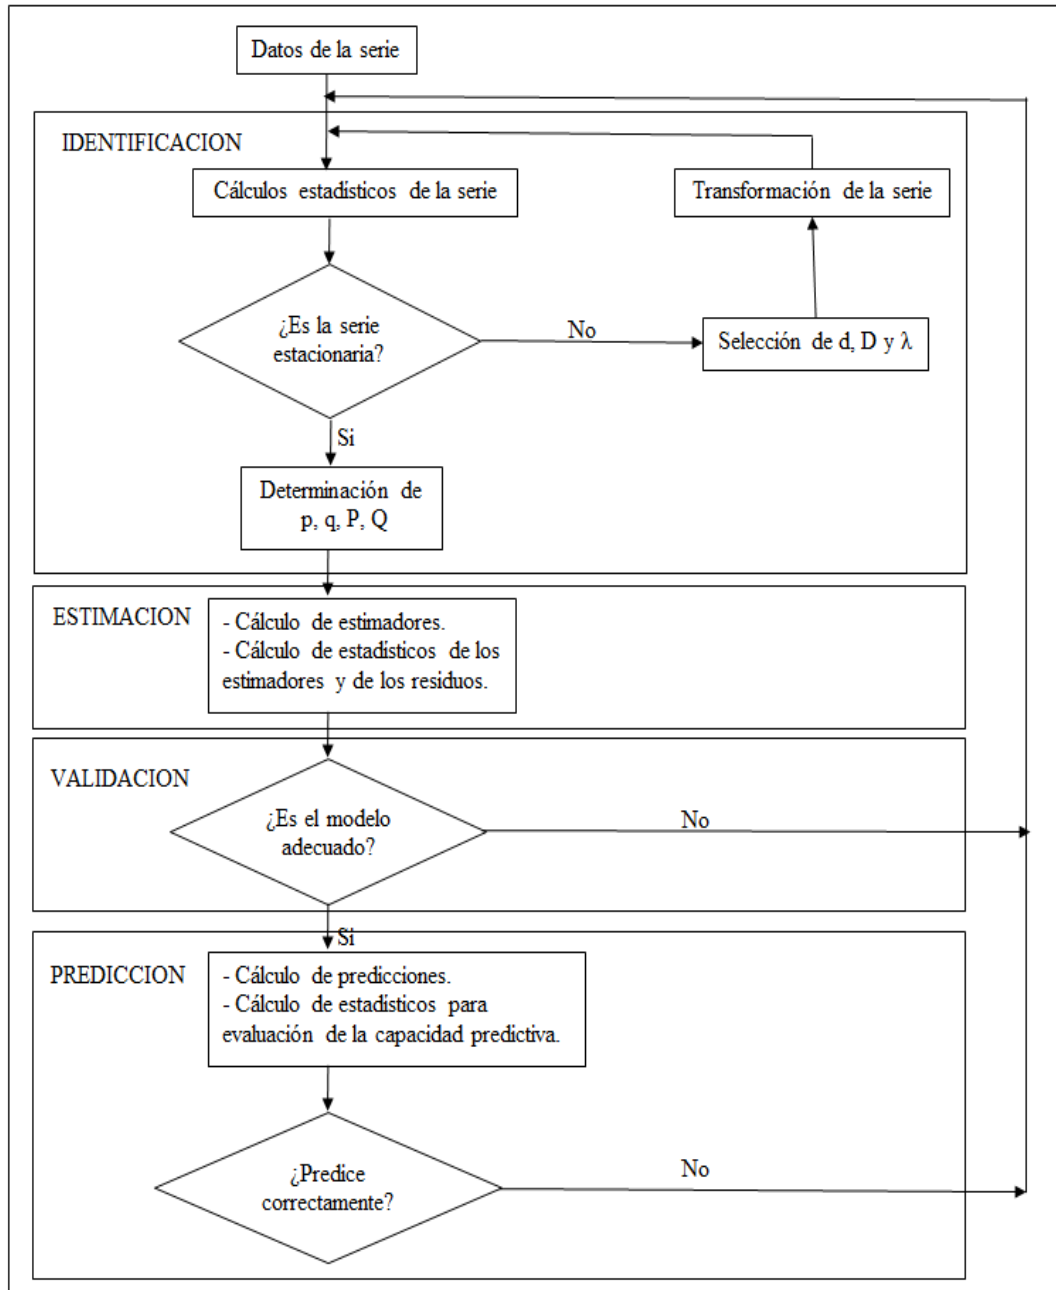


Figura 5. Modelo ARIMA Box Jenkins.
Fuente. Villalobos (2015)



Procedimiento

Según el Centro de Indagación y Desarrollo del Instituto Nacional de Estadística e Informática (INEI - Perú) et al (Agosto, 2002) afirman que se deben utilizar los siguientes pasos para calcular el ARIMA.

Corregir los problemas propios de la serie

Análisis exploratorio

Casi todas las secuencias tienen un prototipo de tendencia, y es fácil de identificar la conducta estacional cuando se elabora con datos de frecuencia mínima a la anual.

La aplicación de patrones ARIMA puede ejecutarse con series estacionarias, porque obliga que cumplan un doble requerimiento en la práctica:

Una $1/2$ aprox. constante en el tiempo, y

Una varianza o dispersión también invariable.

En procesos gráficos, una $1/2$ constante simula la no presencia de tendencia y varianza firme correspondiente a un gráfico en que las oscilaciones alrededor de la $1/2$ sean similares (homocedasticidad).

Si la secuencia de tiempo no cumple con el requisito de estacionariedad será necesario realizar posiblemente las siguientes transformaciones:

Eliminación de la tendencia lineal.

La manera elemental de quitar la tendencia, es decir, de alcanzar una sucesión estacionaria en la media, es desarrollar diferencias sucesivas de la misma, así:

$$\Delta y_t = y_t - y_{t-1}, d=1 \text{ (orden regular)}$$

y si la tendencia aún persiste, calcularemos una segunda diferencia:

$$\Delta^2 y_t = \Delta(\Delta y_t) = (y_t - y_{t-1}) - (y_{t-1} - y_{t-2}), d=2 \text{ (orden regular)}$$

Y así consecutivamente. En general es capaz con uno o dos distintas sucesivas, para que la serie se formalice en medias.

Transformación previa de datos.

Una manera fácil de minimizar la heteroscedasticidad, es decir cambiar una secuencia en otra con varianza relativamente constante, es tomar logaritmos, ya que ello supone trabajar con valores relativamente más homogéneos.

Las transformaciones logarítmicas de datos son muy habituales en los modelos ARIMA – AI.

Sea y_t la serie original de $y_t^* = \ln y_t$ la transformada. Al tomar ahora diferencias, obtenemos:

$$y_t^* - y_{t-1}^* = \ln y_t - \ln y_{t-1} = \ln\left(\frac{y_t}{y_{t-1}}\right)$$

Y esta expresión es una aproximación de la tasa de variación de y_t , al menos para tasas de cambio relativamente pequeños.

Hay una rama extensa de posible transformación, de la que los logaritmos constituyen un caso particular. Se trata de la denominada transformación de Box Cox. Esta sugerida es para, $\gamma = 0$ es decir, el logaritmo neperiano.



Para entenderlo mejor se aplicarán contrastes de confirmación de la estacionariedad, entonces, dado que el procedimiento de Box y Jenkins, determinan que las secuencias sean estacionarias, es elemental evidenciar esta situación antes de trabajar con estas. La técnica formal para analizar si una serie es estacionaria es el test de raíces unitarias.

El test de raíces unitarias más difundido es el Dickey Fuller que muestra una variante llamada test de DF aumentado (ADF). Así mismo, puede considerarse el Phillips-Perron (PP).

El test de Dickey aumentado, acceder a verificar la apariencia de raíces unitarias, considera:

$$y_t = \mu + py_{t-1} + a_t$$

Donde μ y p son parámetros a evaluar y es un término de fallo que supuestamente cumple la propiedad de ruido blanco. Dado que P es un coeficiente de autocorrelación que, asimila valores

$-1 < p < 1$, si $p = 1$, la serie Y_t es no estable, la varianza Y_t decrece en el periodo. Si el valor de $P > 1$, entonces se dice que la serie es explosiva. De esta forma, la suposición es estacionariedad de una sucesión puede ser evaluado analizando si el valor absoluto de P es rigurosamente menor que 1. Tanto el test de Dickey-Fuller como test de Phillips Perron plantea como presunción nula la presencia de una raíz unitaria:

$$H_0: p = 1^{17}(\text{problema de raices unitarias o serie no estacionaria})$$

$$H_1: p < 1$$

La interpretación al test estadístico ADF sería:



Se rechaza la Hipótesis nula si el estadístico de Dickey-Fuller Aumentado es superior que los valores críticos de MacKinnon. Por consecuencia, se afirma que una secuencia es estacionaria en la componente regular.

Eliminación de la tendencia estacional.

El tratamiento de la Estacionalidad en los patrones ARIMA, se da usualmente cuando los datos son al mes, como es esta indagación, en un contexto de predicción a corto término. De esta forma la estacionalidad se encuentra en un papel central en el lapso de modelización.

El componente estacional puede exigir una o varias diferencias de orden estacional (D), es decir, para datos mensuales sería de la siguiente manera:

$$\nabla_{12}y_t = (1 - B^{12})y_t = y_t - y_{t-12}, D = 1(\text{orden estacional})$$

$$\nabla_{12}^2y_t = (1 - B^{12})^2y_t = y_t - y_{t-12} - (y_{t-12} - y_{t-24}), D = 2(\text{orden estacional})$$

Ordinariamente bastara con un único desigualdad estacional $D=1$

Ya analizados las características relevantes de la serie de tiempo, se procederá con el cálculo de la desviación estándar a las transformaciones realizadas originalmente, luego se solo la que posea menor desviación y se reconocerá el modelo ARIMA a través de esta elección.

Hasta este punto hemos conocido algunos conceptos básicos para analizar una serie. Sin embargo, aún no sabemos cómo distinguir el modelo más conveniente para cada caso, pasamos a la búsqueda del diseño más beneficioso

Identificar un modelo ARIMA

Para iniciar el análisis de una serie primero se identifica el modelo. Si la serie no presenta estacionalidad, determinar los órdenes del modelo *ARIMA* (p, d, q), y si la serie presenta



estacionalidad de periodo s , los órdenes del modelo será de tipo multiplicativo *ARIMA* $(p, d, q)*(P, D, Q)$.

Ya determinados los parámetros d y D en el estudio experimental, el siguiente paso será identificar los parámetros p y q y, si la serie presentara estacionalidad, Los parámetros P y Q . El instrumento técnico básico para identificar un modelo *ARIMA* es la denominada función de autocorrelación parcial (esta función no tiene la misma potencia identificadora) y la simple (si identifica), se sugiere utilizarlo solo en caso de indecisión acerca de la identificación del patrón.

Ventajas

- 1) Facilidad de implementación y de expresar. No obstante, pueden ser absolutamente inadecuado cuando el mecanismo que genera la serie es no lineal (Corres et al, 2015).
- 2) Metodología más completa para pronosticar series de tiempos, ya sean estacionales o no (Corres et al, 2015).
- 3) Excelente para el pronóstico en corto término, por su capacidad de aprender de los cambios en la dinámica de la serie (Hernández 2015).
- 4) Se utilizan como punto de referencia (Hernández 2015).
- 5) Son cómodos y rápidos de edificar (Hernández 2015).

Desventajas

- 1) Son lineal (Corres et al, 2015).
- 2) No pueden predecir en situaciones de modificaciones estructurales y puntos de giro (Hernández 2015).
- 3) Son de memoria corta. El horizonte de predicción es en ocasiones muy
- 4) corto (Hernández 2015).



- 5) Menos eficiente en el uso de la información (Hernández 2015).
- 6) Complejo y dificultoso de comprender. Promete más de lo que proporciona (Gálvez Sin año de publicación).
- 7) Para determinar el tipo que mejor se adapte a la serie de datos es trivial y, por lo que, se necesita que la persona que realice predicciones tenga extensos entendimientos sobre esta estrategia (Maciado 2013).

1.4.7. ANFIS (Sistema Adaptativo de Inferencia Neuro Difuso)

Concepto

El ANFIS o Método derivado de la Inteligencia Computacional ANFIS adapta parámetros de los Sistemas de Inferencia Difusa (de las ocupaciones de pertenencia difusas, de las funciones de salida) usando tanto algoritmo de retro propagación de falla, únicos o mezclados con métodos de mínimos cuadrados. Este ajuste permite que los Sistemas de Inferencia aprendan de los datos que están diseñando, provocando espontáneamente a la base de reglas que mejor se adapta al conjunto de datos de entrenamiento (Corres et al, 2015).

Objetivo

Optimizar el error de pronóstico (Suya et al, 2016).

Características

Según Cachuara (Sin año de publicación) presenta las siguientes características:

- 1) Factible de deducir, los conceptos lógicos son sencillos.
- 2) Adaptable, su escalada es sencilla.
- 3) Es comprensivo a datos inciertos.



- 4) Consigue formar funciones no lineales de complicación arbitraria.
- 5) Puede ser edificada encima de la información de la práctica de los operarios que manipulan el sistema que se desea automatizar.
- 6) A veces es complementaria a los procesos de control tradicionales.
- 7) Basado en la expresión manejado por las personas.

Arquitectura

Su construcción es funcional, equivale a una base de reglas clase Sueño (Suya et al, 2016) porque ofrece las siguientes ventajas: computacional eficaz, trabaja bien con técnicas lineales, de optimización y control adaptable, garantiza una superficie de control constante, está bien adaptado al análisis matemático.

Procedimiento

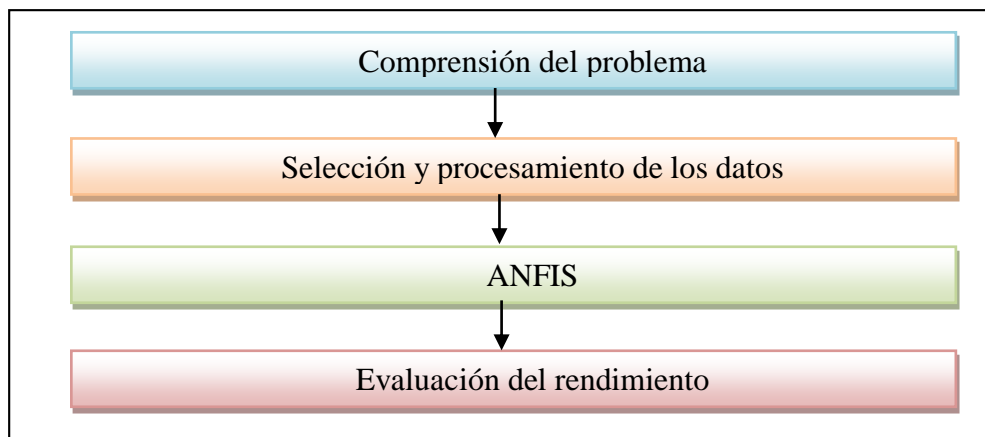


Figura 6. Modelo ANFIS.
Fuente: Suya et al. (2016).

Comprensión del problema: Definir atributos de entrada y salida.

Selección y procesamiento de los datos: Cantidad de datos históricos a procesar definidos en 2 matrices: una matriz de entrada y una matriz de salida.



ANFIS: Implementación está basado en reglas tipo Sugeno. Expresado en reglas de la siguiente manera (Zúñiga et al, 2005):

Regla 1: Si x es A₁ y y es B₁, entonces z₁ = p₁x + q₁y + r₁

Regla 2: Si x es A₂ y y es B₂, entonces z₂ = p₂x + q₂y + r₂

Donde A_i y B_i son conjuntos fuzzy.




Figura 7. Sistema de inferencia Takagi-Sugeno de primer orden

Fuente. Zúñiga et al. (2005).

Los niveles de activación de las reglas se calculan como $W_i = A_i(x).B_i(y)$, $i=1,2$, donde el operador lógico *and* (.) puede ser ajustado por una t-regla constante (producto). La salida individual de cada regla es obtenida como una mezcla lineal entre los parámetros del antecedente de cada una:

$z_i = p_i x + q_i y + r_i$, $i = 1,2$. La salida de control del modelo z_0 se obtiene por la normalización de los grados de activación de las reglas por la salida individual de cada una:

$$z_0 = \frac{w_1z_1 + w_2z_2}{w_1 + w_2} ; \quad z_0 = w_1z_1 + w_2z_2$$

\bar{W}_1 y \bar{W}_2 Son los valores estandarizados de w_1 y w_2 con respecto a la adición $\bar{W}_1 + \bar{W}_2$.

La red neuronal híbrida que simboliza este tipo de inferencia es flexible con 5 capas, donde cada capa representa una operación del componente de inferencia fuzzy. Como se muestra en la siguiente figura.

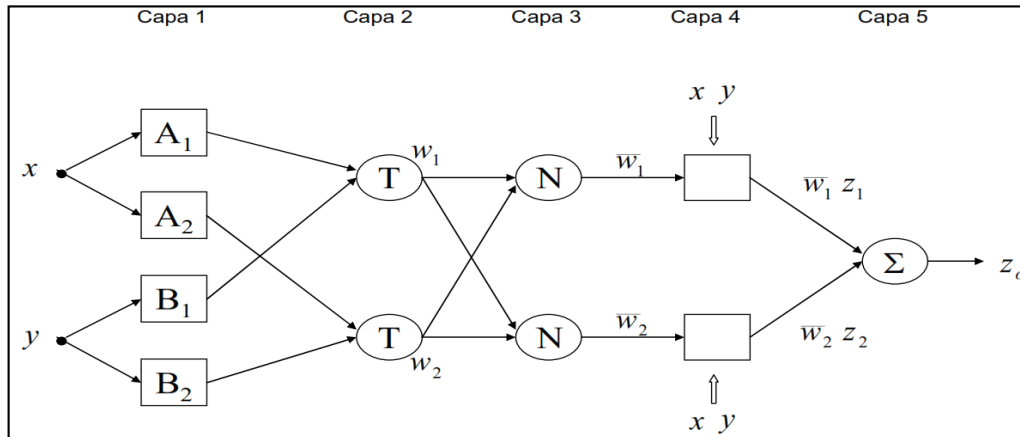


Figura 8. *Arquitectura ANFIS.*
Fuente. *Zúñiga et al. (2005).*

En esta arquitectura, todos los nodos de una misma capa tienen la misma función (parámetros son ajustables). La formación de la red ANFIS consiste de cinco cubiertas:

- a) Capa 1: Pertenecen a las entradas x y y , y la salida del nodo es el grado de pertenencia por el cual la variable de entrada satisface el término lingüístico asociado a este nodo.

$$O_i^1 = A_i(x)$$

- b) Capa 2: Cada uno computariza el grado de activación de la regla asociada a dicho nodo.

Estos nodos están reconocidos con una T, para diferenciar de cualquier t-norma para ajustar la operación lógica and. Son conocidos como “nodos de reglas”.

$$O_i^2 = w_i = A_i(x) \cdot B_i(y), i = 1, 2..$$

- c) Capa 3: individualmente están representados por una N, para enseñar la normalización de los grados de activación. La salida del nodo es el grado de activación regulado de la regla i .



$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2}, i = 1, 2.$$

d) Capa 4: La salida de los nodos corresponde al producto entre el grado de activación ordenado por la ida individual de cada regla.

$$O_i^4 = \bar{w}_i z_i = \bar{w}_i (p_i x + q_i y + r_i), i = 1, 2.$$

e) Capa 5: solo esta capa calcula la totalidad de salida del procedimiento (agregación) como la sumatoria de todas las entradas individuales de este nodo.

$$O^5 = z_0 = \bar{w}_1 z_1 + \bar{w}_2 z_2$$

Evaluación del rendimiento: Se utiliza los errores de pronóstico.

Diferencias

Tabla 2.

Diferencias lógicas difusa y redes neuronales.

Lógica difusa	Redes Neuronales
Permite utilizar el conocimiento disponible para optimizar el sistema directamente.	No existe un método sencillo que permita modificar u optimizar la red, ya que esta se comporta como una caja negra.
Permite describir el comportamiento de un sistema a partir de sentencias “si – entonces”.	La selección del modelo apropiado de red y el algoritmo de entrenamiento requieren de mucha experiencia.
Permite utilizar el conocimiento de un experto.	Permite hallar soluciones a partir de un conjunto de datos.
El conocimiento es estático.	Son capaces de aprender y auto adaptarse.
Existen muchas aplicaciones comerciales.	Su aplicación es mayormente académica.
Permiten encontrar soluciones sencillas con menor tiempo de diseño.	Requieren un enorme esfuerzo computacional.

Fuente. Chachuara (Sin año de publicación).



Ventajas

Posibilidad de agregar al grupo de datos que sostienen al sistema, un conjunto de variable, denominado “variables exógenas” que podrían favorecer a optimizar la salida (Corres et al, 2015).

Desventajas

Tiene la alternativa de mejorar su respuesta modificando los parámetros del estándar. Ocasionando un máximo consumo de duración de cálculo computacional. Esto dependerá en gran medida de los costos que el fallo del pronóstico genera la entidad (Corres et al, 2015).

Medidas de error

Según Malaver (2015) y Villareal (2016) refieren que todo procedimiento de pronóstico siempre habrá un error, puesto que, las deducciones anticipan lo que va a pasar en un futuro, y gracias a la existencia de algunos métodos, se puede evaluar el cumplimiento de algunos objetivos de aquel modelo que se haya escogido, siendo los siguientes:

Suma Acumulada de Errores de Pronostico (CFE)

Se representa como el sesgo en el pronóstico, el cual consiste en la suma de la diferencia entre los valores pronósticos con las ventas reales, cuyo resultado si es positivo significa que existe un sesgo (error) en el pronóstico.

Desviación Absoluta Media (DAM)

Calcula el error global de un modelo de previsión calculándose la suma de todos los errores absolutos de todas las etapas entre el N° total de aquellos periodos; mientras el resultado sea menor, mejor es el diseño de previsión que se ha elegido.

Error Cuadrático Medio (ECM)

Consiste en la adición de las diferencias entre el valor pronosticado y el verdadero por cada etapa, elevada al cuadrado, dividiendo el resultado entre el número total de periodos, siendo el valor menor como aquel que indique que la precisión del tipo es mayor.

Señal de Rastreo (TS)

Aquella medida comparada entre los datos reales y los pronosticados, calculándose entre la suma de todas las equivocaciones de la predicción y la DAM, siendo el valor positivo como el indicio que la demanda está por encima del pronóstico, y al contrario, una señal de rastreo negativa indicaría una demanda inferior a la previsión, pero este tiene que identificarse entre los valores de ± 6 . Esta señal, si son positivas manifiesta que la demanda es mayor que el pronóstico, de lo contrario, significaría que la demanda es menor. Así mismo menciona, que, si la señal del rastreo excede el límite superior e inferior, el proceso de pronóstico no es el adecuado y tal vez es necesario volver a evaluar la manera en que se pronostica la demanda.

Errores Porcentuales de la media absoluta (PEMA)

Esta medida es aquella que normaliza el error mediante el cálculo de un error porcentual, permitiendo comparar los errores de pronósticos para distintas series de tiempo.

Tabla 3.

Métodos para analizar el error.

DESCRIPCION	FORMULA
Suma acumulada de errores de pronostico	$CFE = \sum_{t=1}^n e_t$
Desviación absoluta media	$DAM = \frac{\sum_{t=1}^n e_t }{n}$
Error cuadrático medio	$ECM = \frac{\sum_{t=1}^n e_t^2}{n}$
Señal de rastreo	$TS = \frac{CFE}{DAM}$
Errores porcentuales de la media absoluta	$PEMA = \frac{\sum_{t=1}^n \left \frac{e_t}{D_t} \right }{n}$

Fuente: Malaver (2015).

Dónde:

- D_t , representa el valor del pronóstico.
- e_t , representa el error, cuyo valor resulta en la diferencia entre el valor pronosticado y el valor real.
- n , número de períodos.



1.5. Definición de la terminología.

Análisis.

Se denomina así a la distinción y separación de las partes de un todo para así permitirnos llegar a conocer sus principios y elementos.

Comparación.

Examen que se realiza a cualquier cosa u objeto para descubrir sus semejanzas y diferencias.

Pronostico.

Es la predicción de lo que sucederá con un elemento determinado dentro del marco de un conjunto dado de condiciones.

Confiabilidad.

Capacidad de desempeñar una función requerida, en condiciones establecidas durante un período de tiempo determinado.

Promedio.

Es la vinculación con la media aritmética, que consiste en el resultado que se obtiene al generar una división con la sumatoria de diversas cantidades por el dígito que las represente en total.

Red Neuronal.

Básicamente consisten en redes de neuronas simuladas conectadas entre sí. Existen varios tipos en función de su arquitectura y forma de aprendizaje. Una de las más utilizadas es la red basada en varias capas de neuronas de tipo perceptrón, entrenadas mediante la técnica de retro propagación.

Perceptrón multicapa.

Es una red neuronal artificial (RNA) formada por múltiples capas de tal manera que tiene la capacidad de resolver problemas que no son linealmente separables.

Periodo.

Se usa regularmente para designar el intervalo de tiempo necesario para completar un ciclo repetitivo.

Algoritmo.

Es una serie ordenada de instrucciones paso o procesos que llevan a solucionar un determinado problema.

1.6. Formulación del Problema.

¿Cómo realizar un análisis comparativo de algoritmos de pronóstico de ventas para su implementación en MYPES del sector ferretería de Chiclayo?

1.7. Justificación e importancia del estudio.

Justificación Social

Esta investigación permite apoyar a las empresas ferreteras para realizar pronósticos de ventas teniendo como base las ventas históricas para poder pronosticar las ventas mensuales del siguiente periodo.

Con la utilización de las ventas pronosticadas se podrá tomar decisiones más acertadas en la implementación de estrategias de ventas para aumentar los ingresos en las empresas del mismo rubro

1.7.1. Justificación Tecnológica

Actualmente la tecnología viene creciendo exponencialmente en cuanto a conocimiento, ingeniería e innovación, dentro de este gran campo las redes neuronales, algoritmos determinísticos, “Sistema Adaptativo de Inferencia Neuro Difuso” y “Método Autor regresivo Integrado de Medias Móviles”, han hecho grandes aportes en el campo de la economía, finanzas, banca, éste último para realizar el pronóstico de sus posibles clientes o empresas con menos riesgo crediticio y rentabilidad económica.

El pronóstico de las ventas de la organización es muy importante, en este caso por ejemplo el cemento, fierro, etc. pues así se determina cuanto se debe tener en almacén para alcanzar las ventas mensuales en miles de soles proyectadas por la aplicación. La evaluación del presentimiento de venta en la entidad, permitirá conocer la cantidad del porcentaje de ingresos en los próximos periodos, así mismo, se tendrá mayor toma de decisiones en cuanto a las estrategias de ventas

1.7.2. Justificación Económica

Con el sistema propuesto se conseguirá incrementar los ingresos o mejorar los gastos de la empresa, debido a que nos permite realizar un pronóstico de ventas que influye en los ingresos de la empresa con mayor exactitud.

1.7.3. Justificación académica

La investigación aporta el conocimiento necesario en el uso de redes neuronales, algoritmos determinísticos, ANFIS y ARIMA para pronosticar las ventas futuras en las empresas ferreteras.

Además, nos permite poner en práctica los conocimientos recibidos durante los estudios universitarios, así como también, nos ayuda a investigar nuevas tecnologías y técnicas utilizadas en la implementación de redes neuronales, algoritmos determinísticos, Sistema “AIND” y Método Autorregresivo Integrado de Medias Móviles que sean aplicadas en pronóstico de ventas futuras de una empresa.

Por lo tanto, la presente tesis se justifica por el alto grado de impacto en la solución a los problemas que se originan en el pronóstico de ventas, y de esta manera generar valor en el ámbito empresarial usando redes neuronales, algoritmos determinísticos, “ANFIS y ARIMA”, los cuales tendrán que ser evaluados para medir su efectividad.

Con la utilización de redes neuronales, algoritmos determinísticos, ANFIS y ARIMA, podrá evaluar las ventas e ingresos futuros de la empresa, permitiéndoles tomar decisiones más acertadas a los empresarios, evitando la pérdida de dinero que se generaría si se tomaran decisiones equivocadas en las inversiones a realizar.

1.7.4. Justificación científica

La investigación aporta un conjunto de conocimientos que podrían ser aprovechados para realizar nuevas investigaciones en tecnologías y redes neuronales, algoritmos determinísticos, “Sistema Adaptativo de Inferencia Neuro Difuso” y “Método Autorregresivo Integrado de Medias Móviles” que sirvan para realizar los pronósticos en ventas de manera eficiente, efectiva y eficaz.

1.7.5. Justificación institucional

Los conceptos impartidos en esta investigación servirán de apoyo a los alumnos que deseen investigar en nuevas tecnologías, metodologías y técnicas actuales de redes neuronales, algoritmos determinísticos, Sistema Adaptativo de Inferencia Neuro Difuso y ARIMA para desarrollar nuevas aplicaciones que le sirvan al usuario para pronosticar las ventas futuras de una empresa.

1.8. Hipótesis.

Mediante aplicación de algoritmos de pronóstico se apoyará con la implementación de un sistema a las MYPES del sector ferretería de Chiclayo en la predicción de sus ventas futuras.

1.9. Objetivos

1.9.1. Objetivos General

Ejecutar un análisis comparativo de algoritmos en pronóstico de ventas para su implementación en MYPES del sector ferretería de Chiclayo.

1.9.2. Objetivos Específicos

Examinar los diferentes algoritmos sobre pronóstico en ventas.

Determinar las características de los diferentes algoritmos de pronóstico de ventas.

Evaluar las diferencias y similitudes de los diferentes algoritmos de pronóstico de ventas.

Identificar las ventas históricas para pronosticar las ventas.

Implementar el sistema de pronóstico de ventas con los algoritmos analizados en C# .NET.

Evaluar los resultados obtenidos.

II. MATERIAL Y MÉTODO.

2.1. Tipo y Diseño de Investigación.

2.1.1. Tipo de investigación

La presente investigación es de tipo tecnológica (Hernández et al, 1997), debido a que el producto desarrollado es un sistema que utiliza redes neuronales, algoritmos determinísticos (promedio móvil, suavizado exponencial), ANFIS (Sistema Adaptativo de Inferencia Neuro Difuso) y ARIMA (Método Autorregresivo Integrado de Medias Móviles) en C#.NET 2010, con el fin de pronosticar las ventas en PYMES en el sector ferretería de Chiclayo. Y, propositiva (Alvitres 2000); porque los resultados obtenidos en función de los indicadores, son estimaciones que se podrían generar al implementarse la aplicación.

2.1.2. Diseño de la investigación

Al plantear el desarrollo de la investigación se ha considerado emplear el diseño de Campo por ser este un tipo de diseño adaptable para una tesis de ingeniería.

Se ha optado por el diseño estadístico porque este efectúa mediciones para determinar los valores de una variable. Consiste en el estudio cuantitativo o evaluación numérica de los hechos colectivos.

2.2. Población y muestra.

2.2.1. Población

En este trabajo de investigación la población está determinada de la siguiente manera:

Por todos los algoritmos de pronósticos cualitativos y cuantitativos que existen actualmente.

2.2.2. Muestra

Según Samaja (2004) y Dieterich (2001) refieren que para la determinación de la muestra se hace a partir de una población; Muestra es tomar una porción representativa y adecuada de la población, es una parte o subconjunto representativo de dicha población para poder hacer generalizaciones válidas. Se estima que una muestra es representativa cuando reúne las características principales de la población en relación con la variable que se pretende estudiar.

En esta investigación la muestra está determinada por los siguientes algoritmos de pronósticos:

Redes neuronales.

Perceptrón multicapa.

Algoritmos determinísticos.

Promedio móvil.

Suavizado exponencial.

ANFIS (Sistema Adaptativo de Inferencia Neuro Difuso).

ARIMA (Método Autorregresivo Integrado de Medias Móviles).

2.3. Variables, Operacionalización.

2.3.1. Variable Independiente

Algoritmos de pronóstico.

2.3.2. Variable Dependiente

Sistema de predicción de ventas.

2.3.3. Operacionalización

Tabla 4.

Algoritmos de Pronóstico.

<i>Indicadores</i>	<i>Descripción</i>	<i>Unidad medición</i>	<i>Fórmula</i>	<i>Herramienta de medición</i>
Grado de confiabilidad de los algoritmos.	Es el número porcentual de aproximación en el pronóstico de las ventas realizada por los algoritmos. Según Vidaurre, Y. (Abril, 2012) refiere que para saber qué tan eficaz es un pronóstico, es decir que tan lejos esta del valor real de la variable a predecir, existen ciertas métricas estándares que nos permite medir los errores en los pronósticos.	%	$= \frac{\text{Grado de confiabilidad}}{\text{Venta mensual pronosticada}} \times \text{Venta mensual obtenida}$	Fórmula matemática
Errores de pronóstico.		Error	Las fórmulas se encuentran en la Tabla 6 y Figura 10	Fórmula matemática

Fuente: *Elaboración propia.*



Tabla 5.

Sistema de predicción de ventas.

<i>Indicadores</i>	<i>Descripción</i>	<i>Unidad medición</i>	<i>Fórmula</i>	<i>Herramienta de medición</i>
Tiempo consumido por el sistema.	Tiempo utilizado por el sistema en la presentación de las ventas pronosticadas con la red neuronal.	Tiempo	$TA = TF - TI$ TA = Tiempo Acumulado. TI = Tiempo Inicio. TF = Tiempo Final.	Cronómetro

Fuente: *Elaboración propia.*

2.4. Técnicas e instrumentos de recolección de datos, validez y confiabilidad.

Se van a tabular, ponderar e interpretar todos los datos obtenidos para lo cual se hará uso de la herramienta informática Microsoft Excel que permitirá evaluar el comportamiento de las variables y permitirá indicar un análisis estadístico que serán presentados en cuadros y gráficos descriptivos.

2.5. Procedimientos de análisis de datos.

En esta investigación para la recolección de datos se utilizaron las técnicas que se encuentran especificadas en el siguiente cuadro.



Tabla 6.

Diferencias lógicas difusa y redes neuronales.

Lógica difusa	Redes Neuronales
Permite utilizar el conocimiento disponible para optimizar el sistema directamente.	No existe un método sencillo que permita modificar u optimizar la red, ya que esta se comporta como una caja negra.
Permite describir el comportamiento de un sistema a partir de sentencias “si – entonces”.	La selección del modelo apropiado de red y el algoritmo de entrenamiento requieren de mucha experiencia.
Permite utilizar el conocimiento de un experto.	Permite hallar soluciones a partir de un conjunto de datos.
El conocimiento es estático.	Son capaces de aprender y auto adaptarse.
Existen muchas aplicaciones comerciales.	Su aplicación es mayormente académica.
Permiten encontrar soluciones sencillas con menor tiempo de diseño.	Requieren un enorme esfuerzo computacional.

Fuente: Chachuara (Sin año de publicación).

El procesamiento de los datos obtenidos obedecerá a un plan de tabulación previamente definido, de modo que cuando se obtengan los datos, se los vierta en las tablas o cuadros de análisis que se han diseñado.

2.6. Criterios éticos

Los criterios éticos utilizados en la elaboración de esta tesis es el Código Deontológico del Colegio de Ingenieros del Perú en su Capítulo III “Faltas Contra la Ética Profesional y Sanciones” y su Sub Capítulo II “De la Relación con El Público” en su Artículo 106 expresa:

Los ingenieros, al explicar su trabajo, méritos o emitir opiniones sobre temas de ingeniería, actuarán con seriedad y convicción, cuidando de no crear conflictos de intereses, esforzándose por ampliar el conocimiento del público a cerca de la ingeniería y de los servicios que presta a la sociedad.



En relación con la sociedad, el Ingeniero deberá:

- A. Aceptar la responsabilidad total de su trabajo.
- B. Actuar teniendo como objetivo el servicio a la sociedad, promoviendo en la propuesta de soluciones el bienestar público, social y medioambiental.
- C. Aprobar un software si cumple un bien social.
- D. Cooperar en los esfuerzos para solucionar asuntos importantes de interés social causados por el software, su instalación, mantenimiento, soporte o documentación.
- E. Ofrecer voluntariamente asistencia técnica a buenas causas y contribuir a la educación pública relacionada con esta profesión.

2.7. Criterios de Rigor científico.

2.7.1. Credibilidad

Se buscará incrementar la probabilidad de que los datos de esta investigación sean creíbles.

Para ello se utilizará: observación persistente, análisis de documentos, etc.

2.7.2. Transferencia

Se refiere a la posibilidad de aplicar los hallazgos de la investigación a otros sujetos o en otros contextos. Para este propósito se deberá: Recoger abundante información, realizar descripciones detalladas del proceso seguido durante el desarrollo del estudio para la recolección y análisis de información.

2.7.3. Dependencia

Es la repetición de los resultados en el mismo contexto y a los mismos sujetos. Para esto se realizará: identificación y descripción de las técnicas de visión artificial, establecer pistas de revisión a través de los informes de investigación, análisis de documentos, etc.

2.7.4. Confiabilidad

Esta referida a la garantía de que los hallazgos de esta investigación no estén sesgados por motivaciones, intereses y perspectivas del investigador. Se realizará a través de: descripción de baja inferencia, buscar a través de la observación, análisis de documentos.

III. REPORTE DE RESULTADOS

3.1. Resultados en tablas y figuras.

Tabla 7.

Grado de confiabilidad del método determinístico promedio móvil desde mayo del 2017 hasta abril del 2019.

MES/AÑO	VENTA	2 MESES		9 MESES	
		PRONOSTICO 2	Confiabilidad	PRONOSTICO 9	Confiabilidad
			MAPE 22%		MAPE 20%
				%	%
may-17	11224,45				
jun-17	25798,7				
jul-17	19536,1	18511,6		95	
ago-17	27871,6	22667,4		81	
sep-17	29961,1	23703,9		79	
oct-17	25286,62	28916,4		114	
nov-17	36626,9	27623,9		75	
dic-17	43944	30956,8		70	
ene-18	43069,35	40285,5		94	
feb-18	42762,5	43506,7		102	29257,6
					68,4



Continuación de tabla 7

Grado de confiabilidad del método determinístico promedio móvil desde mayo del 2017 hasta abril del 2019.

MES/AÑO	VENTA	10 MESES		11 MESES		12 MESES	
		PRONOSTICO 10	Confiabilidad %	PRONOSTICO 11	Confiabilidad %	PRONOSTICO 12	Confiabilidad %
mar-18	50307,5	30608,1	60,8				
abr-18	24626,9	34516,4	140,2	32399	131,6		
may-18	24267,9	34399,3	141,7	33617,4	138,5	31751,3	130,8
jun-18	21045,1	34872,4	165,7	33478,2	159,1	32838,3	156
jul-18	21989,3	34189,8	155,5	33615,4	152,9	32442,1	147,5
ago-18	44978,05	33392,6	74,2	33080,7	73,5	32646,6	72,6
sep-18	28662,45	35361,8	123,4	34445,8	120,2	34072,1	118,9
oct-18	29630,7	34565,3	116,7	34752,7	117,3	33963,9	114,6
nov-18	24506,19	33134	135,2	34116,7	139,2	34325,9	140,1
dic-18	22014	31277,7	142,1	32349,6	147	33315,8	151,3
ene-19	30610,2	29202,8	95,4	30435,5	99,4	31488,3	102,9
feb-19	29630,1	27233,1	91,9	29330,8	99	30450,1	102,8
mar-19	19396,5	27733,4	143	27451	141,5	29355,7	151,3
abr-19	13928,41	27246,3	195,6	26975,5	193,7	26779,8	192,3
may-19	19500,35	26534,6	136,1	26035,5	133,5	25888,2	132,8

Fuente. *Elaboración propia.*






Figura 9. Ventas reales, ventas pronosticadas por mes con menor MAPE y mayor grado de confiabilidad.

Fuente. Elaboración propia.






Figura 10. Ventas reales y pronostico del promedio móvil a 2 meses.
Fuente. Elaboración propia.



Tabla 8.
Grado de confiabilidad del método suavizado exponencial simple desde mayo del 2017 hasta abril del 2019.

MES/AÑO	VENTA	PRONOSTICO CONFIABILIDAD		PRONOSTICO CONFIABILIDAD		PRONOSTICO CONFIABILIDAD	
		a = 0.1 MAPE 32	%	a = 0.2 MAPE 33	%	a = 0.3 MAPE 30	%
may-17	11224,5						
jun-17	25798,7	11224,5	43,5	11224,5	43,5	11224,5	43,5
jul-17	19536,1	12681,9	64,9	14139,3	72,4	15596,7	79,8
ago-17	27871,6	13367,3	48	15218,7	54,6	16778,5	60,2
sep-17	29961,1	14817,7	49,5	17749,2	59,2	20106,5	67,1
oct-17	25286,6	16332,1	64,6	20191,6	79,9	23062,8	91,2
nov-17	36626,9	17227,5	47	21210,6	57,9	23730	64,8
dic-17	43944	19167,5	43,6	24293,9	55,3	27599,1	62,8
ene-18	43069,4	21645,1	50,3	28223,9	65,5	32502,5	75,5
feb-18	42762,5	23787,5	55,6	31193	72,9	35672,6	83,4
mar-18	50307,5	25685	51,1	33506,9	66,6	37799,6	75,1
abr-18	24626,9	28147,3	114,3	36867	149,7	41551,9	168,7
may-18	24267,9	27795,2	114,5	34419	141,8	36474,4	150,3
jun-18	21045,1	27442,5	130,4	32388,8	153,9	32812,5	155,9
jul-18	21989,3	26802,8	121,9	30120	137	29282,3	133,2
ago-18	44978,1	26321,4	58,5	28493,9	63,4	27094,4	60,2
sep-18	28662,5	28187,1	98,3	31790,7	110,9	32459,5	113,2



MES/AÑO	VENTA	PRONOSTICO		CONFIABILIDAD		PRONOSTICO		CONFIABILIDAD	
		a = 0.1	%	a = 0.2	%	a = 0.3	%		
		MAPE		MAPE		MAPE			
		32		33		30			
oct-18	29630,7	28234,6	95,3	31165,1	105,2	31320,4	105,7		
nov-18	24506,2	28374,2	115,8	30858,2	125,9	30813,5	125,7		
dic-18	22014	27987,4	127,1	29587,8	134,4	28921,3	131,4		
ene-19	30610,2	27390,1	89,5	28073	91,7	26849,1	87,7		
feb-19	29630,1	27712,1	93,5	28580,5	96,5	27977,4	94,4		
mar-19	19396,5	27903,9	143,9	28790,4	148,4	28473,2	146,8		
abr-19	13928,4	27053,2	194,2	26911,6	193,2	25750,2	184,9		
may-19	19500,4	25740,7	132	24315	124,7	22203,7	113,9		

continuación de tabla N.º 8 lado derecho

Grado de confiabilidad del método suavizado exponencial simple desde mayo del 2017 hasta Abril del 2019.

MES/AÑO	VENTA	PRONOSTICO		CONFIABILIDAD		PRONOSTICO		CONFIABILIDAD	
		a = 0.4	%	a = 0.5	%	a = 0.6	%		
		MAPE		MAPE		MAPE			
		28		26		25			
may-17	11224,5								
jun-17	25798,7	11224,5	43,5	11224,5	43,5	11224,5	43,5		
jul-17	19536,1	17054,2	87,3	18511,6	94,8	19969	102,2		
ago-17	27871,6	18046,9	64,8	19023,8	68,3	19709,3	70,7		
sep-17	29961,1	21976,8	73,4	23447,7	78,3	24606,7	82,1		



MES/AÑO	VENTA	PRONOSTICO CONFIABILIDAD		PRONOSTICO CONFIABILIDAD		PRONOSTICO CONFIABILIDAD	
		a = 0.4	%	a = 0.5	%	a = 0.6	%
		MAPE		MAPE		MAPE	
		28		26		25	
oct-17	25286,6	25170,5	99,5	26704,4	105,6	27819,3	110
nov-17	36626,9	25217	68,8	25995,5	71	26299,7	71,8
dic-17	43944	29780,9	67,8	31311,2	71,3	32496	73,9
ene-18	43069,4	35446,2	82,3	37627,6	87,4	39364,8	91,4
feb-18	42762,5	38495,4	90	40348,5	94,4	41587,5	97,3
mar-18	50307,5	40202,3	79,9	41555,5	82,6	42292,5	84,1
abr-18	24626,9	44244,4	179,7	45931,5	186,5	47101,5	191,3
may-18	24267,9	36397,4	150	35279,2	145,4	33616,7	138,5
jun-18	21045,1	31545,6	149,9	29773,5	141,5	28007,4	133,1
jul-18	21989,3	27345,4	124,4	25409,3	115,6	23830	108,4
ago-18	44978,1	25203	56	23699,3	52,7	22725,6	50,5
sep-18	28662,5	33113	115,5	34338,7	119,8	36077,1	125,9
oct-18	29630,7	31332,8	105,7	31500,6	106,3	31628,3	106,7
nov-18	24506,2	30651,9	125,1	30565,6	124,7	30429,7	124,2
dic-18	22014	28193,6	128,1	27535,9	125,1	26875,6	122,1
ene-19	30610,2	25721,8	84	24775	80,9	23958,6	78,3
feb-19	29630,1	27677,2	93,4	27692,6	93,5	27949,6	94,3
mar-19	19396,5	28458,3	146,7	28661,3	147,8	28957,9	149,3
abr-19	13928,4	24833,6	178,3	24028,9	172,5	23221,1	166,7
may-19	19500,4	20471,5	105	18978,7	97,3	17645,5	90,5

Fuente. *Elaboración propia.*



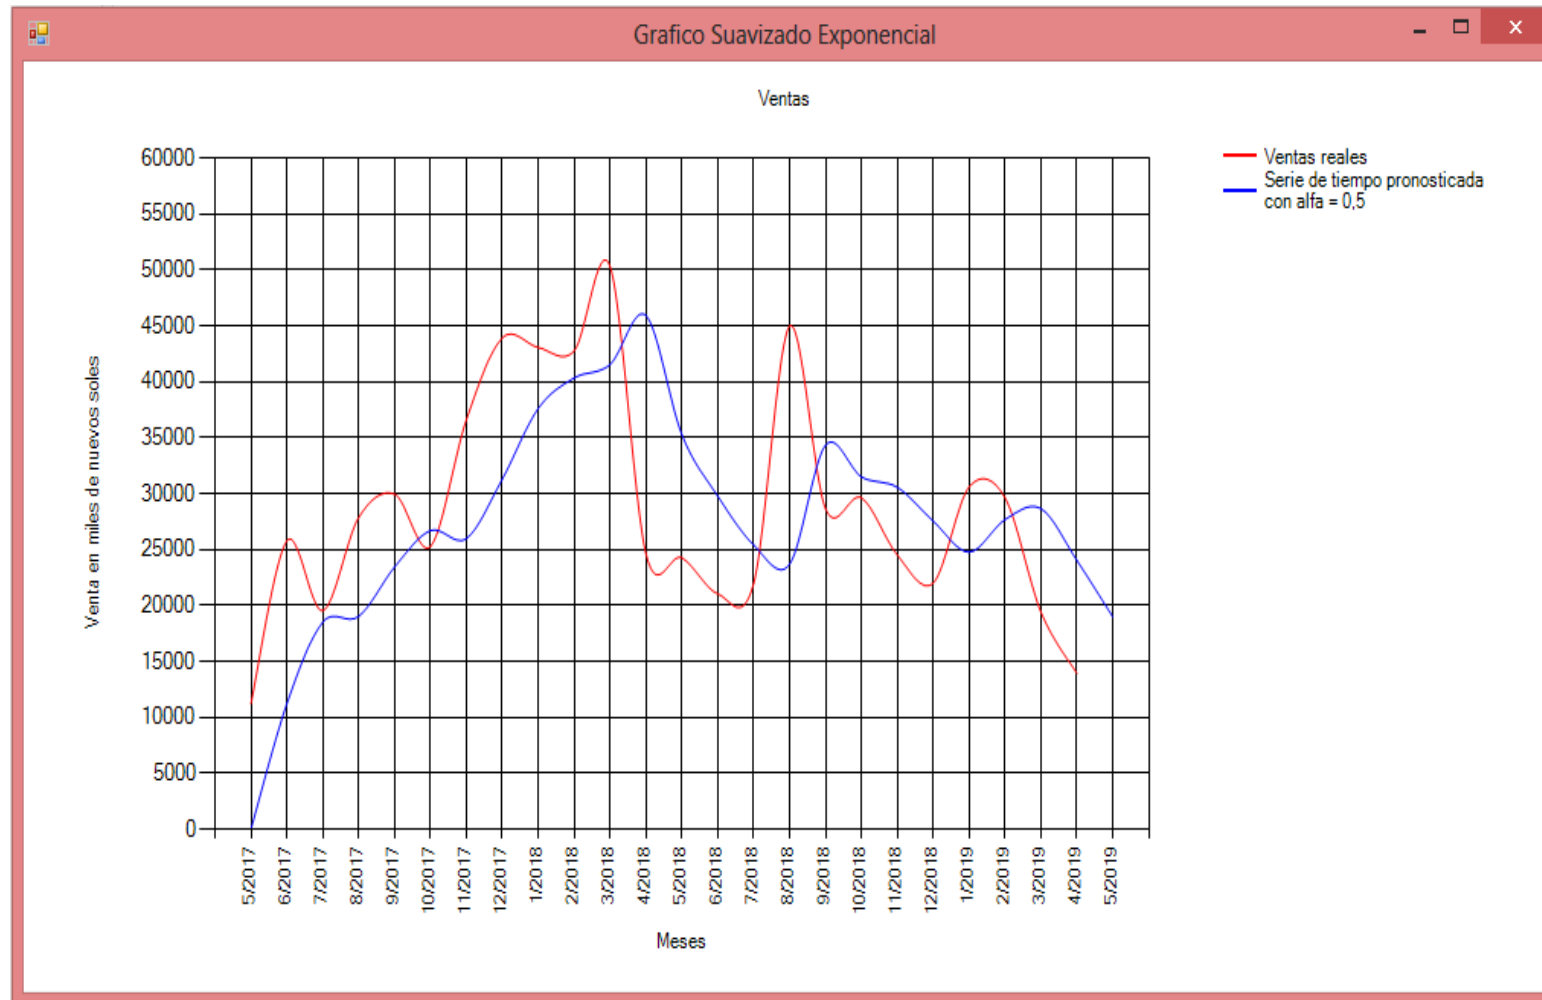


Figura 11: Suavizado exponencial simple con ventas reales y serie de tiempo pronosticada con alfa 0.5.
Fuente. Elaboración propia.



Tabla 9.

Grado de confiabilidad de la red neuronal en el pronóstico de las ventas desde enero hasta mayo del 2019.

FECHA	VENTA REAL	PRONOSTICO VENTA RED NEURONAL							
		EPOCA ENTRENAMIENTO 10000							
		CONFIABILIDAD Y RATIO DE APRENDIZAJE							
		RATIO		RATIO		RATIO		RATIO	
	00.01	%	00.02	%	00.03	%	00.01	%	
	RN		RN		RN		RN		
ene-19	30,6102	32,094	104,85	33,022	107,88	33,259	108,65	31,799	103,88
feb-19	29,6301	33,499	113,06	34,6	116,77	33,186	112	28,664	96,74
mar-19	19,3965	25,294	130,4	22,883	117,97	19,795	102,05	26,567	136,97
abr-19	13,92841	24,298	174,45	22,803	163,72	19,461	139,72	25,417	182,48
may-19	19,50035	29,663	152,12	29,838	153,01	27,246	139,72	30,154	154,63
TOTAL	113,06556	144,848		143,146		132,947		142,601	



Continuación de tabla N.º 9 lado derecho

Grado de confiabilidad de la red neuronal en el pronóstico de las ventas desde enero hasta mayo del 2019.

PRONOSTICO VENTA RED NEURONAL EPOCA ENTRENAMIENTO 11000 CONFIABILIDAD Y RATIO DE APRENDIZAJE				PRONOSTICO VENTA RED NEURONAL EPOCA ENTRENAMIENTO 12000 CONFIABILIDAD Y RATIO DE APRENDIZAJE					
RATIO		RATIO		RATIO		RATIO		RATIO	
00.02	%	00.03	%	00.01	%	00.02	%	00.03	%
RN		RN		RN		RN		RN	
31,449	102,74	30,369	99,21	31,952	104,38	32,171	105,1	31,515	102,96
25,17	84,95	30,987	104,58	31,017	104,68	32,17	108,57	31,873	107,57
26,602	137,15	26,958	138,98	27,372	141,12	28,743	148,19	29,96	154,46
26,237	188,37	26,419	189,68	26,285	188,72	28,514	204,72	29,309	210,43
30,332	155,55	29,545	151,51	30,208	154,91	31,956	163,87	31,005	159
139,79		144,278		146,834		153,554		153,662	

Fuente. *Elaboración propia.*






Figura 12. comparación del pronóstico de las ventas con la red neuronal y las ventas reales obtenidas desde enero hasta mayo del 2019.

Fuente. Elaboración propia.



Tabla 10.

Grado de confiabilidad ARIMA (1, 0, 1) (0, 1, 1).

FECHA	VENTA REAL	PRONOSTICO ARIMA	CONFIABILIDAD %
ene-19	30610,2	29299,22	95,7
feb-19	29630,1	26527,67	89,5
mar-19	19396,5	29410,3	151,6
abr-19	13928,41	28562,79	205,1
may-19	19500,35	29610,57	151,8

Fuente. *Elaboración propia*

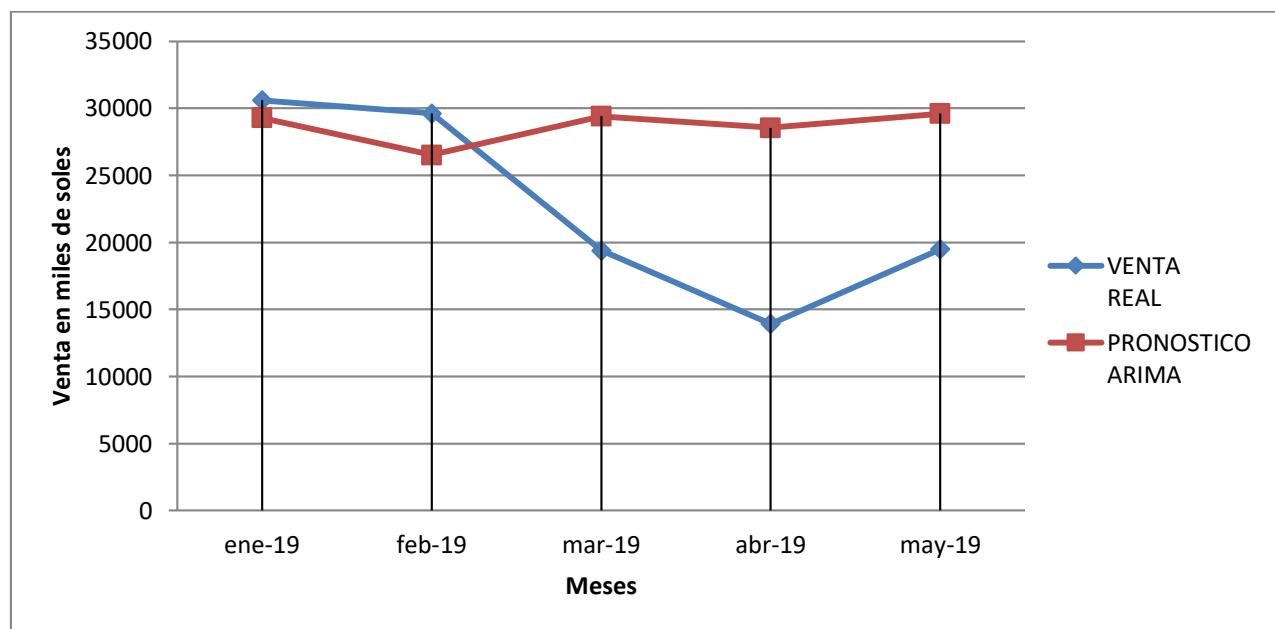


Figura 13. Comparación de las ventas reales con el pronóstico ARIMA.

Fuente. *Elaboración propia.*



Tabla 11.

Grado de confiabilidad del método ANFIS en el pronóstico de las ventas desde enero hasta mayo del 2019.

FECHA	VENTA REAL	ESACALA APRENDIZAJE			
		PRONOSTICO	1	PRONOSTICO	2
			CONFIABILIDAD %		CONFIABILIDAD %
ene-19	30610,2	29996,43	98	31591,86	103,2
feb-19	29630,1	23268,48	78,5	22686,36	76,6
mar-19	19396,5	23419,48	120,7	22098,04	113,9
abr-19	13928,41	28689,72	206	29026,51	208,4
may-19	19500,35	23925,75	122,7	24499,86	125,6
TOTAL	113065,56	129299,86		129902,63	



Continuación de la tabla N.º. 11 lado derecho

Grado de confiabilidad del método ANFIS en el pronóstico de las ventas desde enero hasta mayo del 2019.

ESACALA APRENDIZAJE					
PRONOSTICO	3	PRONOSTICO	4	PRONOSTICO	5
	CONFIABILIDAD		CONFIABILIDAD		CONFIABILIDAD
	%		%		%
32905,28	107,5	35332,57	115,43	37540,09	122,6
20420,06	68,92	16917,98	57,1	13128,77	44,3
19931,14	102,76	16910,49	87,18	13127,65	67,7
27724,63	199,05	25622,63	183,96	21630,66	155,3
24089,75	123,53	22516,29	115,47	19493,06	100
125070,86		117299,96		104920,23	

Fuente: *Elaboración propia*



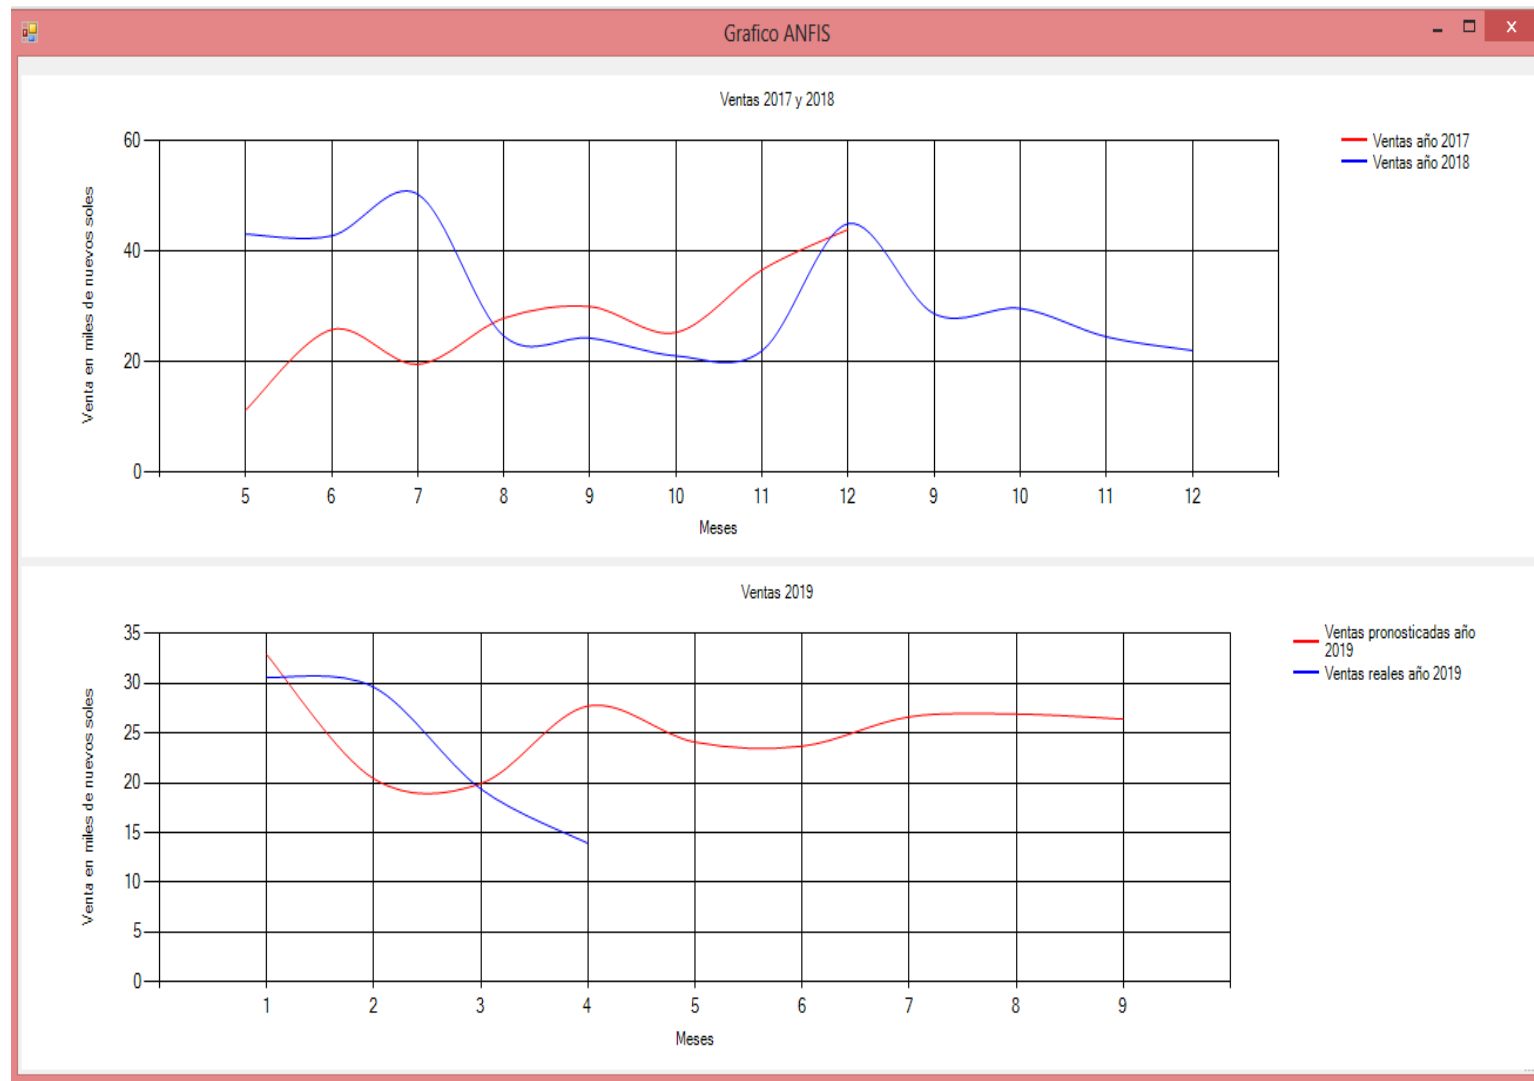


Figura 14. Comparación de las ventas reales con el pronóstico ANFIS con escala de aprendizaje 3.
Fuente. Elaboración propia.



Tabla 12.

Comparación del error MAPE entre el promedio móvil y el suavizado exponencial simple.

	PROMEDIO MOVIL CON PERIODO 2 MESES			
	MAPE 22%			
	VENTA REAL EN S/.	PRONOSTICO	ERROR DE PRONOSTICO	ERROR MEDIO ABSOLUTO PORCENTUAL
may-17	11224,45			
jun-17	25798,7			
jul-17	19536,1	18511,575	1024,525	0,052442657
ago-17	27871,6	22667,4	5204,2	0,186720533
sep-17	29961,1	23703,85	6257,25	0,208845803
oct-17	25286,62	28916,35	-3629,73	0,143543502
nov-17	36626,9	27623,86	9003,04	0,24580404
dic-17	43944	30956,76	12987,24	0,295540688
ene-18	43069,35	40285,45	2783,9	0,064637614
feb-18	42762,5	43506,675	-744,175	0,017402514
mar-18	50307,5	42915,925	7391,575	0,146927893
abr-18	24626,9	46535	-21908,1	0,889600396
may-18	24267,9	37467,2	-13199,3	0,543899555
jun-18	21045,1	24447,4	-3402,3	0,161667086
jul-18	21989,3	22656,5	-667,2	0,03034203
ago-18	44978,05	21517,2	23460,85	0,52160665
sep-18	28662,45	33483,675	-4821,225	0,16820701
oct-18	29630,7	36820,25	-7189,55	0,242638547



PROMEDIO MOVIL CON PERIODO 2 MESES

MAPE 22%

	VENTA REAL EN S/.	PRONOSTICO	ERROR DE PRONOSTICO	ERROR MEDIO ABSOLUTO PORCENTUAL
nov-18	24506,19	29146,575	-4640,385	0,189355628
dic-18	22014	27068,445	-5054,445	0,22960139
ene-19	30610,2	23260,095	7350,105	0,24011947
feb-19	29630,1	26312,1	3318	0,111980722
mar-19	19396,5	30120,15	-10723,65	0,552865208
abr-19	13928,41	24513,3	-10584,89	0,759949628
may-19	19500,35	16662,455	-2837,895	

Continuación de la tabla N.º 12 lado derecho

Comparación del error MAPE entre el promedio móvil y el suavizado exponencial simple.

SUAVIZADO EXPONENCIAL SIMPLE CON ALFA 0.6

MAPE 25%

PRONOSTICO	ERROR DE PRONOSTICO	ERROR ABSOLUTO DE PRONOSTICO	ERROR MEDIO ABSOLUTO PORCENTUAL
11224,45	14574,25	14574,25	0,564921876
19969	-432,9	432,9	0,022158977
19709,26	8162,34	8162,34	0,292855093
24606,664	5354,436	5354,436	0,178712931
27819,3256	-2532,7056	2532,7056	0,100159911



SUAVIZADO EXPONENCIAL SIMPLE CON ALFA 0.6
MAPE 25%

PRONOSTICO	ERROR DE PRONOSTICO	ERROR ABSOLUTO DE PRONOSTICO	ERROR MEDIO ABSOLUTO PORCENTUAL
26299,70224	10327,19776	10327,19776	0,281956643
32496,0209	11447,9791	11447,9791	0,260512905
39364,80836	3704,541642	3704,541642	0,08601341
41587,53334	1174,966657	1174,966657	0,027476566
42292,51334	8014,986663	8014,986663	0,159319916
47101,50533	-22474,60533	22474,60533	0,912603914
33616,74213	-9348,842134	9348,842134	0,385234904
28007,43685	-6962,336854	6962,336854	0,330829355
23830,03474	-1840,734741	1840,734741	0,083710475
22725,5939	22252,4561	22252,4561	0,494740348
36077,06756	-7414,617559	7414,617559	0,258687501
31628,29702	-1997,597023	1997,597023	0,067416464
30429,73881	-5923,548809	5923,548809	0,241716432
26875,60952	-4861,609524	4861,609524	0,220841715
23958,64381	6651,55619	6651,55619	0,217298684
27949,57752	1680,522476	1680,522476	0,056716733
28957,89101	-9561,39101	9561,39101	0,49294414
23221,0564	-9292,646404	9292,646404	0,66717209
17645,46856	-1854,881438		

Fuente. *Elaboración propia.*



Tabla 13.

Comparación del error MAPE entre la red neuronal, ARIMA y ANFIS.

RED NEURONAL						
EPOCA ENTRENAMIENTO 10000 CON UN RATIO DE APRENDIZAJE 0.03						
MAPE 20 %						
FECHA	VENTA REAL EN S/.	PRONOSTICO	ERROR DE PRONOSTICO	ERROR ABSOLUTO DE PRONOSTICO	ERROR MEDIO ABSOLUTO PORCENTUAL	
ene-19	30,6102	33,259	2,6488	2,6488	0,086533247	
feb-19	29,6301	33,186	3,5559	3,5559	0,12000972	
mar-19	19,3965	19,795	0,3985	0,3985	0,020544944	
abr-19	13,92841	19,461	5,53259	5,53259	0,397216193	
may-19	19,50035	27,246	7,74565	7,74565	0,397205691	
jun-19	-	22,975	-	-	-	
jul-19	-	26,501	-	-	-	
ago-19	-	25,91	-	-	-	
sep-19	-	27,203	-	-	-	
oct-19	-	27,253	-	-	-	
nov-19	-	19,904	-	-	-	
dic-19	-	19,52	-	-	-	



Continuación de la tabla N.º 13 lado derecho.

Comparación del error MAPE entre la red neuronal, ARIMA y ANFIS.

ARIMA MAPE 44 %				ANFIS ESCALA APRENDIZAJE 3 CON UN MAPE DE 32 %			
PRONOSTICO	ERROR DE PRONOSTICO	ERROR ABSOLUTO DE PRONOSTICO	ERROR MEDIO ABSOLUTO PORCENTUAL	PRONOSTICO	ERROR DE PRONOSTICO	ERROR ABSOLUTO DE PRONOSTICO	ERROR MEDIO ABSOLUTO PORCENTUAL
29,29922	-1,31098	1,31098	0,042828208	32,90528	2,29508	2,29508	0,0749776
26,52767	-3,10243	3,10243	0,10470535	20,42006	-9,21004	9,21004	0,3108339
29,4103	10,0138	10,0138	0,516268399	19,93114	0,53464	0,53464	0,0275637
28,56279	14,63438	14,63438	1,050685613	27,72463	13,79622	13,79622	0,9905093
29,61057	10,11022	10,11022	0,518463515	24,08975	4,5894	4,5894	0,2353496
-	-	-	-	23,68757	-	-	-
-	-	-	-	26,63426	-	-	-
-	-	-	-	26,92172	-	-	-
-	-	-	-	26,41375	-	-	-
-	-	-	-	26,95538	-	-	-
-	-	-	-	26,80523	-	-	-
-	-	-	-	26,0796	-	-	-

Fuente. *Elaboración propia.*



Tabla 14.

Comparación de la desviación media absoluta del promedio móvil.

FECHA	VENTA REAL EN S/.	PRONOSTICO 2 PERIODOS	ERROR ABSOLUTO	PRONOSTICO 3 PERIODOS	ERROR ABSOLUTO
may-17	11224,45	-	-	-	-
jun-17	25798,7	-	-	-	-
jul-17	19536,1	18511,6	1024,5	-	-
ago-17	27871,6	22667,4	5204,2	18853,08333	9018,516667
sep-17	29961,1	23703,9	6257,2	24402,13333	5558,966667
oct-17	25286,62	28916,4	3629,78	25789,6	502,98
nov-17	36626,9	27623,9	9003	27706,44	8920,46
dic-17	43944	30956,8	12987,2	30624,87333	13319,12667
ene-18	43069,35	40285,5	2783,85	35285,84	7783,51
feb-18	42762,5	43506,7	744,2	41213,41667	1549,083333
mar-18	50307,5	42915,9	7391,6	43258,61667	7048,883333
abr-18	24626,9	46535	21908,1	45379,78333	20752,88333
may-18	24267,9	37467,2	13199,3	39232,3	14964,4
jun-18	21045,1	24447,4	3402,3	33067,43333	12022,33333
jul-18	21989,3	22656,5	667,2	23313,3	1324
ago-18	44978,05	21517,2	23460,85	22434,1	22543,95
sep-18	28662,45	33483,7	4821,25	29337,48333	675,0333333
oct-18	29630,7	36820,3	7189,6	31876,6	2245,9
nov-18	24506,19	29146,6	4640,41	34423,73333	9917,543333
dic-18	22014	27068,4	5054,4	27599,78	5585,78



FECHA	VENTA REAL EN S/.	PRONOSTICO 2 PERIODOS	ERROR ABSOLUTO	PRONOSTICO 3 PERIODOS	ERROR ABSOLUTO
ene-19	30610,2	23260,1	7350,1	25383,63	5226,57
feb-19	29630,1	26312,1	3318	25710,13	3919,97
mar-19	19396,5	30120,2	10723,7	27418,1	8021,6
abr-19	13928,41	24513,3	10584,89	26545,6	12617,19
may-19	-	16662,5	-	20985,00333	-
			7515,710455		8262,794286
			MAD		MAD

Continuación de la tabla N.º 14 lado derecho.
Comparación de la Desviación Media Absoluta del Promedio Móvil.

PRONOSTICO 10 PERIODOS	ERROR ABSOLUTO	PRONOSTICO 11 PERIODOS	ERROR ABSOLUTO	PRONOSTICO 12 PERIODOS	ERROR ABSOLUTO
-	-	-	-	-	-
-	-	-	-	-	-
-	-	-	-	-	-
-	-	-	-	-	-
-	-	-	-	-	-
-	-	-	-	-	-
-	-	-	-	-	-
-	-	-	-	-	-
-	-	-	-	-	-
-	-	-	-	-	-
-	-	-	-	-	-



PRONOSTICO 10 PERIODOS	ERROR ABSOLUTO	PRONOSTICO 11 PERIODOS	ERROR ABSOLUTO	PRONOSTICO 12 PERIODOS	ERROR ABSOLUTO
30608,1	19699,4	-	-	-	-
34516,4	9889,5	32399	7772,1	-	-
34399,3	10131,4	33617,4	9349,5	31751,3	7483,4
34872,4	13827,3	33478,2	12433,1	32838,3	11793,2
34189,8	12200,5	33615,4	11626,1	32442,1	10452,8
33392,6	11585,45	33080,7	11897,35	32646,6	12331,45
35361,8	6699,35	34445,8	5783,35	34072,1	5409,65
34565,3	4934,6	34752,7	5122	33963,9	4333,2
33134	8627,81	34116,7	9610,51	34325,9	9819,71
31277,7	9263,7	32349,6	10335,6	33315,8	11301,8
29202,8	1407,4	30435,5	174,7	31488,3	878,1
27233,1	2397	29330,8	299,3	30450,1	820
27733,4	8336,9	27451	8054,5	29355,7	9959,2
27246,3	13317,89	26975,5	13047,09	26779,8	12851,39
26534,6	-	26035,5	-	25888,2	-
	9451,3		8115,7846		8119,4917
	MAD		MAD		MAD

Fuente. *Elaboración propia.*



Tabla 15.

Comparación de la desviación media absoluta del suavizado exponencial simple.

FECHA	VENTA REAL	PRONOSTICO	ERROR	PRONOSTICO	ERROR
		a = 0.1 MAPE 32	ABSOLUTO	a = 0.2 MAPE 33	ABSOLUTO
may-17	11224,45	-	-	-	-
jun-17	25798,7	11224,5	14574,3	11224,5	14574,3
jul-17	19536,1	12681,9	6854,2	14139,3	5396,8
ago-17	27871,6	13367,3	14504,3	15218,7	12652,9
sep-17	29961,1	14817,7	15143,4	17749,2	12211,9
oct-17	25286,62	16332,1	8954,6	20191,6	5095
nov-17	36626,9	17227,5	19399,4	21210,6	15416,3
dic-17	43944	19167,5	24776,5	24293,9	19650,1
ene-18	43069,35	21645,1	21424,2	28223,9	14845,5
feb-18	42762,5	23787,5	18975	31193	11569,5
mar-18	50307,5	25685	24622,5	33506,9	16800,6
abr-18	24626,9	28147,3	3520,4	36867	12240,1
may-18	24267,9	27795,2	3527,3	34419	10151,1
jun-18	21045,1	27442,5	6397,4	32388,8	11343,7
jul-18	21989,3	26802,8	4813,5	30120	8130,7
ago-18	44978,05	26321,4	18656,6	28493,9	16484,2
sep-18	28662,45	28187,1	475,4	31790,7	3128,3
oct-18	29630,7	28234,6	1396,1	31165,1	1534,4
nov-18	24506,19	28374,2	3868	30858,2	6352



FECHA	VENTA REAL	PRONOSTICO	ERROR	PRONOSTICO	ERROR
		a = 0.1 MAPE 32	ABSOLUTO	a = 0.2 MAPE 33	ABSOLUTO
dic-18	22014	27987,4	5973,4	29587,8	7573,8
ene-19	30610,2	27390,1	3220,1	28073	2537,2
feb-19	29630,1	27712,1	1918	28580,5	1049,6
mar-19	19396,5	27903,9	8507,4	28790,4	9393,9
abr-19	13928,41	27053,2	13124,7	26911,6	12983,2
may-19	-	25740,7	-	24315	-
			10635,94313		
			MAD	10048,47513	
				MAD	

Continuación de la tabla N.º. 15 lado derecho

Comparación de la desviación media absoluta del suavizado exponencial simple.

PRONOSTICO	ERROR	PRONOSTICO	ERROR	PRONOSTICO	ERROR	PRONOSTICO	ERROR
a = 0.3 MAPE 30	ABSOLUTO	a = 0.4 MAPE 28	ABSOLUTO	a = 0.5 MAPE 26	ABSOLUTO	a = 0.6 MAPE 25	ABSOLUTO
-	-	-	-	-	-	-	-
11224,5	14574,3	11224,5	14574,3	11224,5	14574,3	11224,5	14574,3
15596,7	3939,4	17054,2	2482	18511,6	1024,5	19969	432,9
16778,5	11093,1	18046,9	9824,7	19023,8	8847,8	19709,3	8162,3
20106,5	9854,6	21976,8	7984,3	23447,7	6513,4	24606,7	5354,4
23062,8	2223,8	25170,5	116,1	26704,4	1417,8	27819,3	2532,7



PRONOSTICO a = 0.3 MAPE 30	ERROR ABSOLUTO	PRONOSTICO a = 0.4 MAPE 28	ERROR ABSOLUTO	PRONOSTICO a = 0.5 MAPE 26	ERROR ABSOLUTO	PRONOSTICO a = 0.6 MAPE 25	ERROR ABSOLUTO
23730	12896,9	25217	11409,9	25995,5	10631,4	26299,7	10327,2
27599,1	16344,9	29780,9	14163,1	31311,2	12632,8	32496	11448
32502,5	10566,8	35446,2	7623,2	37627,6	5441,7	39364,8	3704,5
35672,6	7089,9	38495,4	4267,1	40348,5	2414	41587,5	1175
37799,6	12507,9	40202,3	10105,2	41555,5	8752	42292,5	8015
41551,9	16925	44244,4	19617,5	45931,5	21304,6	47101,5	22474,6
36474,4	12206,5	36397,4	12129,5	35279,2	11011,3	33616,7	9348,8
32812,5	11767,4	31545,6	10500,5	29773,5	8728,4	28007,4	6962,3
29282,3	7293	27345,4	5356,1	25409,3	3420	23830	1840,7
27094,4	17883,7	25203	19775,1	23699,3	21278,7	22725,6	22252,5
32459,5	3797	33113	4450,5	34338,7	5676,2	36077,1	7414,6
31320,4	1689,7	31332,8	1702,1	31500,6	1869,9	31628,3	1997,6
30813,5	6307,3	30651,9	6145,8	30565,6	6059,4	30429,7	5923,5
28921,3	6907,3	28193,6	6179,6	27535,9	5521,9	26875,6	4861,6
26849,1	3761,1	25721,8	4888,4	24775	5835,2	23958,6	6651,6
27977,4	1652,7	27677,2	1952,9	27692,6	1937,5	27949,6	1680,5
28473,2	9076,7	28458,3	9061,8	28661,3	9264,8	28957,9	9561,4
25750,2	11821,8	24833,6	10905,2	24028,9	10100,5	23221,1	9292,6
22203,7	-	20471,5	-	18978,7	-	17645,5	-
	9225,250804		8487,6		8011,2319		7651,6855
	MAD		MAD		MAD		MAD

Fuente. *Elaboración propia.*



Tabla 16.

Comparación de la desviación media absoluta de la red neuronal.

FECHA	VENTA REAL EN S/.		PRONSTICO VENTA RED NEURONAL EPOCA ENTRENAMIENTO 10000 RATIO DE APRENDIZAJE				
	RATIO	ERROR ABSOLUTO	RATIO 00.02		RATIO 00.03		
			RATIO	ERROR ABSOLUTO	RATIO	ERROR ABSOLUTO	
							RN
ene-19	30,6102	32,094	1,4838	33,022	2,4118	33,259	2,6488
feb-19	29,6301	33,499	3,8689	34,6	4,9699	33,186	3,5559
mar-19	19,3965	25,294	5,8975	22,883	3,4865	19,795	0,3985
abr-19	13,92841	24,298	10,36959	22,803	8,87459	19,461	5,53259
may-19	19,50035	29,663	10,16265	29,838	10,33765	27,246	7,74565
			6,356488		6,016088		3,976288
			MAD		MAD		MAD



Continuación de la tabla N.º. 16 lado derecho

PRONSTICO VENTA RED NEURONAL EPOCA ENTRENAMIENTO 11000 RATIO DE APRENDIZAJE					
RATIO 00.01 RN	ERROR ABSOLUTO	RATIO 00.02 RN	ERROR ABSOLUTO	RATIO 00.03 RN	ERROR ABSOLUTO
31,799	1,1888	31,449	0,8388	30,369	0,2412
28,664	0,9661	25,17	4,4601	30,987	1,3569
26,567	7,1705	26,602	7,2055	26,958	7,5615
25,417	11,48859	26,237	12,30859	26,419	12,49059
30,154	10,65365	30,332	10,83165	29,545	10,04465
	6,293528		7,128928		6,338968
	MAD		MAD		MAD



Continuación de la tabla N.º. 16 lado derecho

PRONSTICO VENTA RED NEURONAL					
EPOCA ENTRENAMIENTO 12000					
RATIO DE APRENDIZAJE					
RATIO	ERROR	RATIO	ERROR	RATIO	ERROR
00.01	ABSOLUTO	00.02	ABSOLUTO	00.03	ABSOLUTO
RN		RN		RN	
31,952	1,3418	32,171	1,5608	31,515	0,9048
31,017	1,3869	32,17	2,5399	31,873	2,2429
27,372	7,9755	28,743	9,3465	29,96	10,5635
26,285	12,35659	28,514	14,58559	29,309	15,38059
30,208	10,70765	31,956	12,45565	31,005	11,50465
	6,753688		8,097688		8,119288
	MAD		MAD		MAD

Fuente. *Elaboración propia.*



Tabla 17.

Comparación de la desviación media absoluta ARIMA.

FECHA	VENTA REAL	PRONOSTICO ARIMA	ERROR ABSOLUTO
ene-19	30610,2	29299,22	1311,0
feb-19	29630,1	26527,67	3102,4
mar-19	19396,5	29410,3	10013,8
abr-19	13928,41	28562,79	14634,4
may-19	19500,35	29610,57	10110,2
			7834,362
			MAD

Fuente: *Elaboración propia.*
Tabla 18.

Comparación de la desviación media absoluta ANFIS.

FECHA	VENTA REAL	ESACALA APRENDIZAJE			
		1	2	1	2
		PRONOSTICO	ERROR ABSOLUTO	PRONOSTICO	ERROR ABSOLUTO
ene-19	30610,2	29996,43	613,77	31591,86	981,66
feb-19	29630,1	23268,48	6361,62	22686,36	6943,74
mar-19	19396,5	23419,48	4022,98	22098,04	2701,54
abr-19	13928,41	28689,72	14761,31	29026,51	15098,1
may-19	19500,35	23925,75	4425,4	24499,86	4999,51
			6037,016		6144,91
			MAD		MAD



Continuación de la tabla N.º. 18 lado derecho

Comparación de la desviación media absoluta ANFIS.

ESACALA APRENDIZAJE					
3		4		5	
PRONOSTICO	ERROR ABSOLUTO	PRONOSTICO	ERROR ABSOLUTO	PRONOSTICO	ERROR ABSOLUTO
32905,28	2295,08	35332,57	4722,37	37540,09	6929,9
20420,06	9210,04	16917,98	12712,12	13128,77	16501,3
19931,14	534,64	16910,49	2486,01	13127,65	6268,9
27724,63	13796,22	25622,63	11694,22	21630,66	7702,3
24089,75	4589,4	22516,29	3015,94	19493,06	7,3
	6085,076		6926,132		7481,922
	MAD		MAD		MAD

Fuente. *Elaboración propia.*



Tabla 19.
Comparación de error cuadrado medio del promedio móvil.

FECHA	VENTA REAL EN S/.	PRONOSTICO 2 PERIODOS	ERROR CUADRADO	PRONOSTICO 3 PERIODOS	ERROR CUADRADO
may-17	11224,45	-	-	-	-
jun-17	25798,7	-	-	-	-
jul-17	19536,1	18511,6	1049600,25	-	-
ago-17	27871,6	22667,4	27083697,64	18853,08333	81333642,87
sep-17	29961,1	23703,9	39152551,84	24402,13333	30902110,4
oct-17	25286,62	28916,4	13175302,85	25789,6	252988,8804
nov-17	36626,9	27623,9	81054009	27706,44	79574606,61
dic-17	43944	30956,8	168667363,8	30624,87333	177399135,2
ene-18	43069,35	40285,5	7749820,822	35285,84	60583027,92
feb-18	42762,5	43506,7	553833,64	41213,41667	2399659,174
mar-18	50307,5	42915,9	54635750,56	43258,61667	49686756,25
abr-18	24626,9	46535	479964845,6	45379,78333	430682166,6
may-18	24267,9	37467,2	174221520,5	39232,3	223933267,4
jun-18	21045,1	24447,4	11575645,29	33067,43333	144536498,8
jul-18	21989,3	22656,5	445155,84	23313,3	1752976
ago-18	44978,05	21517,2	550411482,7	22434,1	508229681,6
sep-18	28662,45	33483,7	23244451,56	29337,48333	455670,0011
oct-18	29630,7	36820,3	51690348,16	31876,6	5044066,81
nov-18	24506,19	29146,6	21533404,97	34423,73333	98357665,77
dic-18	22014	27068,4	25546959,36	27599,78	31200938,21



FECHA	VENTA REAL EN S/.	PRONOSTICO 2 PERIODOS	ERROR CUADRADO	PRONOSTICO 3 PERIODOS	ERROR CUADRADO
ene-19	30610,2	23260,1	54023970,01	25383,63	27317033,96
feb-19	29630,1	26312,1	11009124	25710,13	15366164,8
mar-19	19396,5	30120,2	114997741,7	27418,1	64346066,56
abr-19	13928,41	24513,3	112039896,3	26545,6	159193483,5
may-19	-	16662,5	-	20985,00333	-
			91992112,57		104407028,9
			MSE		MSE

Continuación de la tabla N.º. 19 lado derecho

Comparación de error cuadrado medio del promedio móvil.

PRONOSTICO 10 PERIODOS	ERROR CUADRADO	PRONOSTICO 11 PERIODOS	ERROR CUADRADO	PRONOSTICO 12 PERIODOS	ERROR CUADRADO
-	-	-	-	-	-
-	-	-	-	-	-
-	-	-	-	-	-
-	-	-	-	-	-
-	-	-	-	-	-
-	-	-	-	-	-
-	-	-	-	-	-
-	-	-	-	-	-



PRONOSTICO 10 PERIODOS	ERROR CUADRADO	PRONOSTICO 11 PERIODOS	ERROR CUADRADO	PRONOSTICO 12 PERIODOS	ERROR CUADRADO
-	-	-	-	-	-
-	-	-	-	-	-
30608,1	388066360	-	-	-	-
34516,4	97802210,3	32399	60405538,4	-	-
34399,3	102645266	33617,4	87413150,3	31751,3	56001276
34872,4	191194225	33478,2	154581976	32838,3	139079566
34189,8	148852200	33615,4	135166201	32442,1	109261028
33392,6	134222652	33080,7	141546937	32646,6	152064659
35361,8	44881290,4	34445,8	33447137,2	34072,1	29264313
34565,3	24350277,2	34752,7	26234884	33963,9	18776622
33134	74439105,4	34116,7	92361902,5	34325,9	96426704
31277,7	85816137,7	32349,6	106824627	33315,8	127730683
29202,8	1980774,76	30435,5	30520,09	31488,3	771059,61
27233,1	5745609	29330,8	89580,49	30450,1	672400
27733,4	69503901,6	27451	64874970,3	29355,7	99185665
27246,3	177366194	26975,5	170226558	26779,8	165158225
26534,6	-	26035,5	-	25888,2	-
	110490443		82554152,5		82866017
	MSE		MSE		MSE

Fuente: *Elaboración propia.*



Tabla 20.

Comparación de error cuadrado medio del suavizado exponencial simple.

FECHA	VENTA REAL EN S/.	PRONOSTICO 2 PERIODOS	ERROR CUADRADO	PRONOSTICO 3 PERIODOS	ERROR CUADRADO
may-17	11224,45	-	-	-	-
jun-17	25798,7	-	-	-	-
jul-17	19536,1	18511,6	1049600,25	-	-
ago-17	27871,6	22667,4	27083697,64	18853,08333	81333642,87
sep-17	29961,1	23703,9	39152551,84	24402,13333	30902110,4
oct-17	25286,62	28916,4	13175302,85	25789,6	252988,8804
nov-17	36626,9	27623,9	81054009	27706,44	79574606,61
dic-17	43944	30956,8	168667363,8	30624,87333	177399135,2
ene-18	43069,35	40285,5	7749820,822	35285,84	60583027,92
feb-18	42762,5	43506,7	553833,64	41213,41667	2399659,174
mar-18	50307,5	42915,9	54635750,56	43258,61667	49686756,25
abr-18	24626,9	46535	479964845,6	45379,78333	430682166,6
may-18	24267,9	37467,2	174221520,5	39232,3	223933267,4
jun-18	21045,1	24447,4	11575645,29	33067,43333	144536498,8
jul-18	21989,3	22656,5	445155,84	23313,3	1752976
ago-18	44978,05	21517,2	550411482,7	22434,1	508229681,6
sep-18	28662,45	33483,7	23244451,56	29337,48333	455670,0011
oct-18	29630,7	36820,3	51690348,16	31876,6	5044066,81
nov-18	24506,19	29146,6	21533404,97	34423,73333	98357665,77
dic-18	22014	27068,4	25546959,36	27599,78	31200938,21



FECHA	VENTA REAL EN S/.	PRONOSTICO 2 PERIODOS	ERROR CUADRADO	PRONOSTICO 3 PERIODOS	ERROR CUADRADO
ene-19	30610,2	23260,1	54023970,01	25383,63	27317033,96
feb-19	29630,1	26312,1	11009124	25710,13	15366164,8
mar-19	19396,5	30120,2	114997741,7	27418,1	64346066,56
abr-19	13928,41	24513,3	112039896,3	26545,6	159193483,5
may-19	-	16662,5	-	20985,00333	-
			91992112,57		104407028,9
			MSE		MSE

Continuación de la tabla N.º. 20 lado derecho

Comparación de error cuadrado medio del suavizado exponencial simple.

PRONOSTICO 10 PERIODOS	ERROR CUADRADO	PRONOSTICO 11 PERIODOS	ERROR CUADRADO	PRONOSTICO 12 PERIODOS	ERROR CUADRADO
-	-	-	-	-	-
-	-	-	-	-	-
-	-	-	-	-	-
-	-	-	-	-	-
-	-	-	-	-	-
-	-	-	-	-	-
-	-	-	-	-	-
-	-	-	-	-	-



PRONOSTICO 10 PERIODOS	ERROR CUADRADO	PRONOSTICO 11 PERIODOS	ERROR CUADRADO	PRONOSTICO 12 PERIODOS	ERROR CUADRADO
-	-	-	-	-	-
-	-	-	-	-	-
30608,1	388066360	-	-	-	-
34516,4	97802210,3	32399	60405538,4	-	-
34399,3	102645266	33617,4	87413150,3	31751,3	56001276
34872,4	191194225	33478,2	154581976	32838,3	139079566
34189,8	148852200	33615,4	135166201	32442,1	109261028
33392,6	134222652	33080,7	141546937	32646,6	152064659
35361,8	44881290,4	34445,8	33447137,2	34072,1	29264313
34565,3	24350277,2	34752,7	26234884	33963,9	18776622
33134	74439105,4	34116,7	92361902,5	34325,9	96426704
31277,7	85816137,7	32349,6	106824627	33315,8	127730683
29202,8	1980774,76	30435,5	30520,09	31488,3	771059,61
27233,1	5745609	29330,8	89580,49	30450,1	672400
27733,4	69503901,6	27451	64874970,3	29355,7	99185665
27246,3	177366194	26975,5	170226558	26779,8	165158225
26534,6	-	26035,5	-	25888,2	-
	110490443		82554152,5		82866017
	MSE		MSE		MSE

Fuente. *Elaboración propia.*



Tabla 21.
Comparación error cuadrado medio de la red neuronal.

FECHA	VENTA REAL		PRONOSTICO VENTA RED NEURONAL EPOCA ENTRENAMIENTO 10000 RATIO DE APRENDIZAJE				
	RATIO	ERROR	RATIO	ERROR	RATIO	ERROR	
	00.01	CUADRADO	00.02	CUADRADO	00.03	CUADRADO	
	RN		RN		RN		
ene-19	30,6102	32,094	2,201662	33,022	5,81678	33,259	7,01614
feb-19	29,6301	33,499	14,968387	34,6	24,69991	33,186	12,64442
mar-19	19,3965	25,294	34,780506	22,883	12,15568	19,795	0,1588
abr-19	13,92841	24,298	107,528397	22,803	78,75835	19,461	30,60955
may-19	19,50035	29,663	103,279455	29,838	106,86701	27,246	59,99509
			52,5516815		45,65954454		22,0848029
			MSE		MSE		MSE



Continuación de la tabla N.º 21 lado derecho

PRONOSTICO VENTA RED NEURONAL					
EPOCA ENTRENAMIENTO 11000					
RATIO DE APRENDIZAJE					
RATIO	ERROR	RATIO	ERROR	RATIO	ERROR
00.01	CUADRADO	00.02	CUADRADO	00.03	CUADRADO
RN		RN		RN	
31,799	1,41325	31,449	0,70359	30,369	0,05818
28,664	0,93335	25,17	19,89249	30,987	1,84118
26,567	51,41607	26,602	51,91923	26,958	57,17628
25,417	131,9877	26,237	151,50139	26,419	156,01484
30,154	113,50026	30,332	117,32464	29,545	100,89499
	59,8501247		68,268267		63,197094
	MSE		MSE		MSE



Continuación de la tabla N.º. 21 lado derecho

Comparación error cuadrado medio de la red neuronal.

PRONOSTICO VENTA RED NEURONAL					
EPOCA ENTRENAMIENTO 12000					
RATIO DE APRENDIZAJE					
RATIO	ERROR	RATIO	ERROR	RATIO	ERROR
00.01	CUADRADO	00.02	CUADRADO	00.03	CUADRADO
RN		RN		RN	
31,952	1,80043	32,171	2,4361	31,515	0,81866
31,017	1,92349	32,17	6,45109	31,873	5,0306
27,372	63,6086	28,743	87,35706	29,96	111,58753
26,285	152,68532	28,514	212,73944	29,309	236,56255
30,208	114,65377	31,956	155,14322	31,005	132,35697
	66,934321		92,825381		97,271263
	MSE		MSE		MSE

Fuente. *Elaboración propia.*



Tabla 22.
Comparación error cuadrado medio ARIMA.

FECHA	VENTA REAL	PRONOSTICO ARIMA	ERROR CUADRADO
ene-19	30610,2	29299,22	1718668,6
feb-19	29630,1	26527,67	9625071,9
mar-19	19396,5	29410,3	100276190,4
abr-19	13928,41	28562,79	214165078,0
may-19	19500,35	29610,57	102216548,4
			85600311,47
			MSE

Fuente. *Elaboración propia.*

Tabla 23.
Comparación error cuadrado medio ANFIS

FECHA	VENTA REAL	ESACALA APRENDIZAJE			
		1	2	1	2
		PRONOSTICO	ERROR CUADRADO	PRONOSTICO	ERROR CUADRADO
ene-19	30610,2	29996,43	376713,61	31591,86	963656,36
feb-19	29630,1	23268,48	40470209,02	22686,36	48215525,19
mar-19	19396,5	23419,48	16184368,08	22098,04	7298318,37
abr-19	13928,41	28689,72	217896272,9	29026,51	227952623,6
may-19	19500,35	23925,75	19584165,16	24499,86	24995100,24
			58902345,76		61885044,75
			MSE		MSE



continuación de la tabla N.º. 23 lado derecho

comparación error cuadrado medio ANFIS

ESACALA APRENDIZAJE					
3		4		5	
PRONOSTICO	ERROR CUADRADO	PRONOSTICO	ERROR CUADRADO	PRONOSTICO	ERROR CUADRADO
32905,28	5267392,21	35332,57	22300778,4	37540,09	48023375
20420,06	84824836,8	16917,98	161597995	13128,77	272293892
19931,14	285839,93	16910,49	6180245,72	13127,65	39298480
27724,63	190335686	25622,63	136754781	21630,66	59324655
24089,75	21062592,4	22516,29	9095894,08	19493,06	53,1
	60355269,5		67185938,9		83788091
	MSE		MSE		MSE

Fuente. *Elaboración propia*



Tabla 24.

Comparación error porcentual medio promedio móvil.

FECHA	VENTA REAL EN S/.	PRONOSTICO 2 PERIODOS	ERROR PORCENTUAL MEDIO	PRONOSTICO 3 PERIODOS	ERROR PORCENTUAL MEDIO
may-17	11224,45	-	-	-	-
jun-17	25798,7	-	-	-	-
jul-17	19536,1	18511,6	-0,052441378	-	-
ago-17	27871,6	22667,4	-0,186720533	18853,08333	-0,323573697
sep-17	29961,1	23703,9	-0,208844135	24402,13333	-0,185539472
oct-17	25286,62	28916,4	0,14354548	25789,6	0,019891152
nov-17	36626,9	27623,9	-0,245802948	27706,44	-0,243549413
dic-17	43944	30956,8	-0,295539778	30624,87333	-0,303093179
ene-18	43069,35	40285,5	-0,064636453	35285,84	-0,180720396
feb-18	42762,5	43506,7	0,017403099	41213,41667	-0,036225275
mar-18	50307,5	42915,9	-0,14692839	43258,61667	-0,140115954
abr-18	24626,9	46535	0,889600396	45379,78333	0,842691664
may-18	24267,9	37467,2	0,543899555	39232,3	0,616633495
jun-18	21045,1	24447,4	0,161667086	33067,43333	0,571265203
jul-18	21989,3	22656,5	0,03034203	23313,3	0,060211103
ago-18	44978,05	21517,2	-0,52160665	22434,1	-0,501221151
sep-18	28662,45	33483,7	0,168207882	29337,48333	0,023551139
oct-18	29630,7	36820,3	0,242640235	31876,6	0,075796387
nov-18	24506,19	29146,6	0,189356648	34423,73333	0,40469544



FECHA	VENTA REAL EN S/.	PRONOSTICO 2 PERIODOS	ERROR PORCENTUAL MEDIO	PRONOSTICO 3 PERIODOS	ERROR PORCENTUAL MEDIO
dic-18	22014	27068,4	0,229599346	27599,78	0,253737622
ene-19	30610,2	23260,1	-0,240119307	25383,63	-0,170746026
feb-19	29630,1	26312,1	-0,111980722	25710,13	-0,132296887
mar-19	19396,5	30120,2	0,552867785	27418,1	0,413559147
abr-19	13928,41	24513,3	0,759949628	26545,6	0,905860037
may-19	-	16662,5	-	20985,00333	-
			0,084293585		0,09384814
			MPE		MPE

Continuación de la tabla N.º 24 lado derecho

Comparación error porcentual medio promedio móvil.

PRONOSTICO 10 PERIODOS	ERROR PORCENTUAL MEDIO	PRONOSTICO 11 PERIODOS	ERROR PORCENTUAL MEDIO	PRONOSTICO 12 PERIODOS	ERROR PORCENTUAL MEDIO
-	-	-	-	-	-
-	-	-	-	-	-
-	-	-	-	-	-
-	-	-	-	-	-
-	-	-	-	-	-



PRONOSTICO 10 PERIODOS	ERROR PORCENTUAL MEDIO	PRONOSTICO 11 PERIODOS	ERROR PORCENTUAL MEDIO	PRONOSTICO 12 PERIODOS	ERROR PORCENTUAL MEDIO
-	-	-	-	-	-
-	-	-	-	-	-
-	-	-	-	-	-
30608,1	-0,39157978	-	-	-	-
34516,4	0,401573077	32399	0,315593924	-	-
34399,3	0,417481529	33617,4	0,385262013	31751,3	0,3083662
34872,4	0,657031803	33478,2	0,590783603	32838,3	0,5603775
34189,8	0,554838035	33615,4	0,528716239	32442,1	0,4753585
33392,6	-0,25758009	33080,7	-0,26451458	32646,6	-0,274166
35361,8	0,233732636	34445,8	0,201774447	34072,1	0,1887365
34565,3	0,166536734	34752,7	0,172861255	33963,9	0,1462402
33134	0,35206656	34116,7	0,392166632	34325,9	0,4007033
31277,7	0,420809485	32349,6	0,469501226	33315,8	0,5133915
29202,8	-0,04597814	30435,5	-0,00570725	31488,3	0,0286865
27233,1	-0,08089747	29330,8	-0,01010122	30450,1	0,0276746
27733,4	0,429814657	27451	0,41525533	29355,7	0,5134535
27246,3	0,956167287	26975,5	0,93672501	26779,8	0,9226746
26534,6	-	26035,5	-	25888,2	-
	0,272429738		0,317562818		0,3176247
	MPE		MPE		MPE

Fuente: *Elaboración propia*



Tabla 25.

Comparación error porcentual medio suavizado exponencial simple.

FECHA	VENTA	PRONOSTICO	ERROR	PRONOSTICO	ERROR
		a = 0.1 MAPE 32%	PORCENTUAL MEDIO	a = 0.2 MAPE 33%	PORCENTUAL MEDIO
may-17	11224,45	-	-	-	-
jun-17	25798,7	11224,5	-0,564921876	11224,5	-0,564921876
jul-17	19536,1	12681,9	-0,350849197	14139,3	-0,276247562
ago-17	27871,6	13367,3	-0,520397196	15218,7	-0,453972503
sep-17	29961,1	14817,7	-0,505434455	17749,2	-0,407590242
oct-17	25286,62	16332,1	-0,35412226	20191,6	-0,201490021
nov-17	36626,9	17227,5	-0,529648415	21210,6	-0,420900521
dic-17	43944	19167,5	-0,563820808	24293,9	-0,447162867
ene-18	43069,35	21645,1	-0,49743582	28223,9	-0,344687116
feb-18	42762,5	23787,5	-0,443729054	31193	-0,270552704
mar-18	50307,5	25685	-0,489439294	33506,9	-0,333958317
abr-18	24626,9	28147,3	0,142948541	36867	0,497022101
may-18	24267,9	27795,2	0,145350091	34419	0,418292925
jun-18	21045,1	27442,5	0,303985599	32388,8	0,539017287
jul-18	21989,3	26802,8	0,218900402	30120	0,369758844
ago-18	44978,05	26321,4	-0,414794106	28493,9	-0,366493422
sep-18	28662,45	28187,1	-0,016585011	31790,7	0,109141836



FECHA	VENTA	PRONOSTICO a = 0.1 MAPE 32%	ERROR PORCENTUAL MEDIO	PRONOSTICO a = 0.2 MAPE 33%	ERROR PORCENTUAL MEDIO
oct-18	29630,7	28234,6	-0,04711601	31165,1	0,051783047
nov-18	24506,19	28374,2	0,157839211	30858,2	0,259199996
dic-18	22014	27987,4	0,271346594	29587,8	0,344044403
ene-19	30610,2	27390,1	-0,105197564	28073	-0,082886267
feb-19	29630,1	27712,1	-0,064731696	28580,5	-0,035424524
mar-19	19396,5	27903,9	0,438604596	28790,4	0,484308729
abr-19	13928,41	27053,2	0,942300279	26911,6	0,932138371
may-19	-	25740,7	-	24315	-
			-0,123780324 MPE		-0,008764365 MPE



Continuación de la tabla N.º. 25 lado derecho

Comparación error porcentual medio suavizado exponencial simple.

PRONOSTICO	ERROR	PRONOSTICO	ERROR	PRONOSTICO	ERROR	PRONOSTICO	ERROR
a = 0.3	PORCENTUAL	a = 0.4	PORCENTUAL	a = 0.5	PORCENTUAL	a = 0.6	PORCENTUAL
MAPE	MEDIO	MAPE	MEDIO	MAPE	MEDIO	MAPE	MEDIO
30%		28%		26%		25%	
-	-	-	-	-	-	-	-
11224,5	-0,56492188	11224,5	-0,56492188	11224,5	-0,56492188	11224,5	-0,56492188
15596,7	-0,20164593	17054,2	-0,12704429	18511,6	-0,05244266	19969	0,022158978
16778,5	-0,39800595	18046,9	-0,35249752	19023,8	-0,31744724	19709,3	-0,29285509
20106,5	-0,32891462	21976,8	-0,26648895	23447,7	-0,2173946	24606,7	-0,17871293
23062,8	-0,08794258	25170,5	-0,00459141	26704,4	0,056068758	27819,3	0,100159911
23730	-0,35211605	25217	-0,31151806	25995,5	-0,29026167	26299,7	-0,28195664
27599,1	-0,37194938	29780,9	-0,32229803	31311,2	-0,2874748	32496	-0,26051291
32502,5	-0,24534409	35446,2	-0,176998	37627,6	-0,12634847	39364,8	-0,08601341
35672,6	-0,16579754	38495,4	-0,09978517	40348,5	-0,05645187	41587,5	-0,02747657
37799,6	-0,24862977	40202,3	-0,20086941	41555,5	-0,17397031	42292,5	-0,15931992
41551,9	0,687258262	44244,4	0,796586548	45931,5	0,865094438	47101,5	0,912603914
36474,4	0,502990714	36397,4	0,499815573	35279,2	0,453739182	33616,7	0,385234904
32812,5	0,559150103	31545,6	0,498951519	29773,5	0,414749683	28007,4	0,330829355
29282,3	0,331659438	27345,4	0,243577138	25409,3	0,155531294	23830	0,083710475
27094,4	-0,39760903	25203	-0,43966102	23699,3	-0,4730916	22725,6	-0,49474035
32459,5	0,132473841	33113	0,155274328	34338,7	0,19803719	36077,1	0,258687501
31320,4	0,057024215	31332,8	0,057442977	31500,6	0,063105682	31628,3	0,067416464



PRONOSTICO	ERROR	PRONOSTICO	ERROR	PRONOSTICO	ERROR	PRONOSTICO	ERROR
a = 0.3	PORCENTUAL	a = 0.4	PORCENTUAL	a = 0.5	PORCENTUAL	a = 0.6	PORCENTUAL
MAPE	MEDIO	MAPE	MEDIO	MAPE	MEDIO	MAPE	MEDIO
30%		28%		26%		25%	
30813,5	0,257374858	30651,9	0,250783796	30565,6	0,247261723	30429,7	0,241716432
28921,3	0,313767785	28193,6	0,280714237	27535,9	0,250836349	26875,6	0,220841715
26849,1	-0,12287085	25721,8	-0,15969886	24775	-0,19063071	23958,6	-0,21729868
27977,4	-0,05577675	27677,2	-0,06591096	27692,6	-0,06539033	27949,6	-0,05671673
28473,2	0,467957127	28458,3	0,467188974	28661,3	0,477655192	28957,9	0,49294414
25750,2	0,848754545	24833,6	0,782945689	24028,9	0,725173186	23221,1	0,66717209
22203,7	-	20471,5	-	18978,7	-	17645,5	-
	0,026821151		0,040912923		0,047453327		0,050563077
	MPE		MSE		MPE		MPE

Fuente: *Elaboración propia*



Tabla 26.

Comparación error porcentual medio red neuronal.

PRONOSTICO VENTA RED NEURONAL							
EPOCA ENTRENAMIENTO 10000							
FECHA	VENTA REAL	RATIO 0.01 RN	ERROR PORCENTUAL MEDIO	RATIO 0.02 RN	ERROR PORCENTUAL MEDIO	RATIO 0.03 RN	ERROR PORCENTUAL MEDIO
ene-19	30,6102	32,094	0,048474038	33,022	0,07879073	33,259	0,086533247
feb-19	29,6301	33,499	0,130573302	34,6	0,167731462	33,186	0,12000972
mar-19	19,3965	25,294	0,3040497	22,883	0,179748924	19,795	0,020544944
abr-19	13,92841	24,298	0,744492013	22,803	0,637157436	19,461	0,397216193
may-19	19,50035	29,663	0,521152184	29,838	0,530126382	27,246	0,397205691
			0,349748248		0,318710987		0,204301959
			MPE		MPE		MPE



Continuación de la tabla N.º 26 lado derecho

PRONOSTICO VENTA RED NEURONAL

EPOCA ENTRENAMIENTO 11000

RATIO 0.01 RN	ERROR PORCENTUAL MEDIO	RATIO 0.02 RN	ERROR PORCENTUAL MEDIO	RATIO 0.03 RN	ERROR PORCENTUAL MEDIO
31,799	0,038836728	31,449	0,027402631	30,369	-0,00788
28,664	-0,032605357	25,17	-0,150525985	30,987	0,04579
26,567	0,369680097	26,602	0,371484546	26,958	0,38984
25,417	0,824831406	26,237	0,883703883	26,419	0,89677
30,154	0,54633122	30,332	0,555459261	29,545	0,5151
	0,349414819		0,337504867		0,367925001
	MPE		MPE		MPE



CONTINUACION TABLA N°26 LADO DERECHO
**PRONOSTICO VENTA RED NEURONAL
EPOCA ENTRENAMIENTO 12000**

RATIO 0.01 RN	ERROR PORCENTUAL MEDIO	RATIO 0.02 RN	ERROR PORCENTUAL MEDIO	RATIO 0.03 RN	ERROR PORCENTUAL MEDIO
31,952	0,043835062	32,171	0,050989539	31,515	0,029558775
31,017	0,046807132	32,17	0,085720264	31,873	0,075696673
27,372	0,41118243	28,743	0,481865285	29,96	0,544608563
26,285	0,887150077	28,514	1,047182701	29,309	1,104260285
30,208	0,549100401	31,956	0,638739817	31,005	0,589971462
	0,38761502		0,460899521		0,468819152
	MPE		MPE		MPE

FUENTE. Elaboración propia.


Tabla 27.

Error porcentual medio ARIMA.

FECHA	VENTA REAL	PRONOSTICO ARIMA	ERROR PORCENTUAL MEDIO
ene-19	30610,2	29299,22	-0,0428282076
feb-19	29630,1	26527,67	-0,1047053503
mar-19	19396,5	29410,3	0,5162683989
abr-19	13928,41	28562,79	1,0506856131
may-19	19500,35	29610,57	0,5184635148
			MPE

Fuente: Elaboración propia



Tabla 28.
Comparación error porcentual medio ANFIS.

ESACALA APRENDIZAJE					
FECHA	VENTA REAL	PRONOSTICO	1	2	
			ERROR PORCENTUAL MEDIO	PRONOSTICO	ERROR PORCENTUAL MEDIO
ene-19	30610,2	29996,43	-0,020051159	31591,86	0,032069702
feb-19	29630,1	23268,48	-0,214701267	22686,36	-0,234347505
mar-19	19396,5	23419,48	0,207407522	22098,04	0,139279767
abr-19	13928,41	28689,72	1,059798642	29026,51	1,083978717
may-19	19500,35	23925,75	0,226939517	24499,86	0,256380527
			0,251878651		0,255472242
			MPE		MPE



Continuación tabla N°28 lado derecho

ESACALA APRENDIZAJE					
3		4		5	
PRONOSTICO	ERROR PORCENTUAL MEDIO	PRONOSTICO	ERROR PORCENTUAL MEDIO	PRONOSTICO	ERROR PORCENTUAL MEDIO
32905,28	0,074977622	35332,57	0,154274392	37540,09	0,22639153
20420,06	-0,310833916	16917,98	-0,429027239	13128,77	-0,556911047
19931,14	0,027563736	16910,49	-0,128167968	13127,65	-0,323194906
27724,63	0,990509326	25622,63	0,839594756	21630,66	0,55298846
24089,75	0,235349622	22516,29	0,154660814	19493,06	-0,000373839
	0,203513278		0,118266951		-0,02021996
	MPE		MPE		MPE

Fuente: *Elaboración propia*



3.2. Discusión de resultados

En esta sección se analizan y discuten los resultados de la aplicación desarrollada. el análisis estará enfocado a evaluar los indicadores planteados en el capítulo iii. estos indicadores son:

grado de confiabilidad de los algoritmos.

Errores de pronóstico.

La venta real total para el mes de mayo fue de 19500,4. en la tabla 12, se observa que el promedio móvil de 2 meses para el mes de mayo tiene el mejor grado de confiabilidad (85%) con respecto al promedio móvil de 9 meses (138.7%), 10 meses (136.1%), 11 meses (133.5), 12 meses (132.8) para el mismo mes de mayo. la comparación entre las ventas reales y el pronóstico del promedio móvil a 2 meses pronostica que la venta total para el mes de mayo será de s/. 16662,5 (figura 16).

En la tabla 13, se muestra que el suavizado exponencial simple con un alfa (a) de 0.5 para el mes de mayo ofrece el mejor grado de confiabilidad (97.5%) en comparación al suavizado exponencial simple con un alfa (a) de 0.1 (132%), con un alfa (a) de 0.2 (124.7%), con un alfa (a) de 0.3 (113.9%), con un alfa (a) de 0.4 (105%), con un alfa (a) de 0.6 (90.5%) para el mes de mayo.

En la figura 17, se presenta una comparación entre las ventas reales y la serie de tiempo pronosticada con un alfa (a) de 0.5 que la venta total para el mes de mayo es de s/. 18978.7. el alfa (a) es el que minimiza el error de pronóstico.



El grado de confiabilidad de la red neuronal (perceptrón multicapa) se visualiza en la tabla 14, en ella se encuentra la venta real total desde el mes de enero a mayo del 2019, época de entrenamiento, ratio de aprendizaje y confiabilidad. el grado de confiabilidad adecuado se encuentra en la época de entrenamiento de la red con un valor máximo de iteración de 10000 y una ratio de aprendizaje de 0.03. el porcentaje de confiabilidad se encuentra entre el 102.05 % y el 139.72 % estos valores se encuentran muy por debajo a los demás valores obtenidos con un entrenamiento de 11000 y 12000 iteraciones aplicados a la red.

En la figura 18, se presenta una comparación entre las ventas totales pronosticadas con la red desde enero a diciembre del 2019 y las ventas reales totales desde enero a mayo del 2019. se observa que con una época de entrenamiento de 10000 y una ratio de aprendizaje de 0.03 las ventas generadas se acercan mucho más a las ventas reales.

En la tabla 15, se muestra las ventas reales desde enero a mayo del 2019, el pronóstico, el grado de confiabilidad del método arima (1, 0, 1) (0, 1, 1). el grado de confiabilidad deseable para el mes de enero asciende a 95.7%, febrero tiene el 89.5%, para los demás meses superan el 100% porque las ventas son muy equidistantes unas de otras y no son uniformes. en la figura 19, observamos que la venta real y el pronóstico enero, febrero con arima son muy cercanos mientras para los otros meses el arima supera la venta real de cada mes porque la serie tiene valores muy distantes.

El grado de confiabilidad del anfis presentado en la tabla 16, se observa que con un grado de aprendizaje de 3 el pronóstico se acerca a las ventas reales de enero a mayo. en la figura 20, se compara las ventas reales y pronosticadas de enero a mayo, se observa que las ventas de ambos



pronósticos se interceptan en enero y marzo indicando que las ventas pueden frutear entre esos dos puntos.

En la tabla 17, se presenta el mape (media absoluta del porcentaje de error). se han probado distintos valores en la variable n utilizado en el promedio móvil y alfa(a) en suavizado exponencial simple para encontrar aquel valor que minimice el mape (fórmula matemática se encuentra en la figura 10). en el promedio móvil, se ha escogido un periodo de 2 meses, este periodo nos genera un mape del 22% muy por debajo de los demás periodos escogidos. el suavizado exponencial simple con un alfa(a) de 0.6 el cual genera un mape del 25%. en ambos casos la variable n y alfa(a) le da una mayor importancia al error obtenido.

En la tabla 18, se expone una comparación del mape entre la red neuronal, arima y anfis. la red neuronal, con una época de entrenamiento de 10000 y una ratio de aprendizaje de 0.03 tiene un mape del 20%. el arima, alcanza un mape del 44%. el anfis, con una escala de aprendizaje de 3 se obtiene un mape del 32%. la red neuronal es el que obtiene el mejor mape.

La desviación media absoluta del promedio móvil (mad) - fórmula matemática se encuentra en la figura 10 -, en la tabla 19, se presenta una comparación tomando el pronóstico con 2 periodos, con 3 periodos, con 9 periodos, con 10 periodos, con 11 periodos, con 12 periodos. el pronóstico con 2 periodos genera una mad de 7515,710455, con 3 periodos 8262,794286, con 9 periodos 9746,873333, con 10 periodos 9451,3, con 11 periodos 8115,784615, con 12 periodos 8119,491667. con base en estos cálculos se concluye que para esta serie el pronóstico con 2 periodos es mejor que el pronóstico con los demás periodos, porque el primero posee un MAD menor.



La desviación media absoluta (MAD) del suavizado exponencial simple - fórmula matemática se encuentra en la figura 10 -, en la tabla 20, se muestra una comparación tomando el pronóstico con un alfa (α) de 0.1, 0.2, 0.3, 0.4, 0.5, 0.6. el pronóstico alfa (α) 0.1 genera una MAD de 10635,94313, con alfa (α) 0.2 se obtiene 10048,47513, con alfa (α) 0.3 se alcanza 9225,250804, con alfa (α) 0.4 se logra 8487,6, con alfa (α) 0.5 se consigue 8011,231947, con alfa (α) 0.6 se consiguió 7651,685547. con base en estos cálculos se concluye que para esta serie el pronóstico con un alfa (α) de 0.6 es mejor que el pronóstico con las demás alfas, porque el ultimo posee un MAD menor.

La desviación media absoluta (MAD) de la red neuronal - fórmula matemática se encuentra en la figura 10 -, en la tabla 21, se presenta una comparación de la red neuronal con una época de entrenamiento de 10000 (ratio de aprendizaje 0.01, 0.02, 0.03), 11000 (ratio de aprendizaje 0.01, 0.02, 0.02), 12000 (ratio de aprendizaje 0.01, 0.02, 0.02). en base a los cálculos presentados en la tabla 10 la red neuronal con una época de entrenamiento de 10000 y una ratio de aprendizaje de 0.03 obtuvo un MAD de 3,976288 mucho menor a los demás MAD obtenidos para los otros casos.

La Desviación Media Absoluta (MAD) del ARIMA - Fórmula matemática se encuentra en la Figura 10 -, en la Tabla 22, el ARIMA alcanza un MAD de 7834,362.

La desviación media absoluta (MAD) del anfis - fórmula matemática se encuentra en la figura 10 -, en la tabla 23, se presenta una comparación del anfis con una escala de aprendizaje (1, 2, 3, 4, 5). en base a los cálculos presentados en la tabla 12 el anfis con una escala de aprendizaje 1 obtiene un MAD de 6037,016 mucho menor con respecto a las otras escalas de aprendizaje.



Una vez analizados los MAD del promedio móvil, suavización exponencial simple, red neuronal, ARIMA, ANFIS, se concluye que la red neuronal es el que obtiene el mejor MAD.

El Error Cuadrado Medio (MSE) - Fórmula matemática se encuentra en la Figura 10 - del Promedio Móvil presentados en la Tabla 24 para el pronóstico con 2 periodos (91992112,57), con 3 periodos (104407028,9), con 9 periodos (113622910,6), con 10 periodos (110490443,1), con 11 periodos (82554152,45), con 12 periodos (82866016,75), se concluye que el pronóstico con 11 periodos (82554152,45) es el que obtiene un MSE menor.

El Error Cuadrado Medio (MSE) del Suavizado Exponencial Simple mostrados en la Tabla 25 para el pronóstico con un alfa (a) de 0.1 (171447748,2), con un alfa (a) de 0.2 (127416905,9), con un alfa (a) de 0.3 (108505557,8), con un alfa (a) de 0.4 (99019809,5), con un alfa (a) de 0.5 (94139765,7), con un alfa (a) de 0.6 (91888278,24), se concluye que el pronóstico con un alfa (a) de 0.6 (91888278,24) es el que obtiene un MSE menor.

El Error Cuadrado Medio (MSE) Red Neuronal expuestos en la Tabla 26 para el pronóstico con una época de entrenamiento de 10000 con ratio de aprendizaje 0.01 (52,5516815), 0.02 (45,65954454), 0.03 (22,08480291); con una época de entrenamiento de 11000 con ratio de aprendizaje 0.01 (59,85012468), 0.02 (68,26826744), 0.03 (63,19709389); con una época de entrenamiento de 12000 con ratio de aprendizaje 0.01 (66,93432081), 0.02 (92,82538069), 0.03 (97,27126321), se concluye que el pronóstico con una época de entrenamiento de 10000 con ratio de aprendizaje 0.03 (22,08480291) es el que obtiene un MSE menor.



El Error Cuadrado Medio (MSE) ARIMA presentado en la Tabla 27 para el pronóstico de las ventas de Enero a mayo alcanzo un MSE de 85600311,47.

El Error Cuadrado Medio (MSE) ANFIS expuestos en la Tabla 28 para el pronóstico con una escala de aprendizaje 1 (58902345,76), 2 (61885044,75), 3 (60355269,52), 4 (67185938,9), 5 (83788091,14), se concluye que el pronóstico con una escala de aprendizaje de 1 (58902345,76) es el que obtiene un MSE menor.

Una vez analizados los MSE del promedio móvil, suavización exponencial simple, red neuronal, ARIMA, ANFIS, se concluye que la red neuronal es el que obtiene el mejor MSE.

El Error Porcentual Medio (MPE) - Fórmula matemática se encuentra en la Figura 10 - del Promedio Móvil presentados en la Tabla 29 para el pronóstico con 2 periodos (0,084293585), con 3 periodos (0,09384814), con 9 periodos (0,239076603), con 10 periodos (0,272429738), con 11 periodos (0,317562818), con 12 periodos (0,317624728), se concluye que el pronóstico con 2 periodos (0,084293585) es el que obtiene un MPE cercano a cero, no tiene sesgo.

El Error Porcentual Medio (MPE) del Suavizado Exponencial Simple expuestos en la Tabla 30 para el pronóstico con un alfa (a) de 0.1 (-0,123780324), con un alfa (a) de 0.2 (-0,008764365), con un alfa (a) de 0.3 (0,026821151), con un alfa (a) de 0.4 (0,0409129228), con un alfa (a) de 0.5 (0,047453327), con un alfa (a) de 0.6 (0,050563077). Se concluye que el pronóstico con un alfa (a) de 0.2 (-0,008764365) sobreestima de manera consistente las ventas, con un alfa (a) de 0.3 (0,026821151) el pronóstico no tiene sesgo, con un alfa (a) de 0.6 (0,050563077) el pronóstico subestima consistentemente las ventas. El pronóstico con un alfa (a) de 0.6 es el que más se ajusta a este método.



El Error Porcentual Medio (MPE) de la Red Neuronal expuestos en la Tabla 31 para el pronóstico con una época de entrenamiento de 10000 con ratio de aprendizaje 0.01 (0,3497482475), 0.02 (0,3187109868), 0.03 (0,20430195903); con una época de entrenamiento de 11000 con ratio de aprendizaje 0.01 (0,34941481852), 0.02 (0,337504867038), 0.03 (0,367925001); con una época de entrenamiento de 12000 con ratio de aprendizaje 0.01 (0,3876150201), 0.02 (0,46089952135), 0.03 (0,46881915171), se concluye que el pronóstico con una época de entrenamiento de 10000 con ratio de aprendizaje 0.03 (0,20430195903) es el que obtiene un MPE sin sesgo.

El Error Porcentual Medio (MPE) ARIMA mostrado en la Tabla 32 para el pronóstico de las ventas de Enero a mayo alcanzo un MPE de 0,387576794.

El Error Porcentual Medio (MPE) ANFIS expuestos en la Tabla 33 para el pronóstico con una escala de aprendizaje 1 (0,251878651), 2 (0,255472242), 3 (0,203513278), 4 (0,118266951), 5 (-0,02021996). Se concluye que el pronóstico con una escala de aprendizaje de 4 (0,118266951) es el que obtiene un MPE en el pronóstico sin sesgo, con una escala de aprendizaje de 2 (0,255472242) es el que obtiene un MPE en el pronóstico que subestima consistentemente las ventas, con una escala de aprendizaje de 5 (-0,02021996) es el que obtiene un MPE en el pronóstico que sobreestima consistente las ventas. El pronóstico con una escala de aprendizaje 4 es el que más se ajusta a este método por tener el MPE más adecuado.



Una vez analizados los MPE del promedio móvil, suavización exponencial simple, red neuronal, ARIMA, ANFIS, se concluye que la red neuronal, suavización exponencial simple, ANFIS obtienen el mejor MPE.

Después de haber obtenido los resultados de los algoritmos y determinar el algoritmo que se aproxime al mejor pronóstico, se elaboró un diagrama de flujo que le permita a las MYPES adaptar sus datos a la BD del sistema para que los algoritmos realicen el pronóstico sin problemas a continuación, se muestra el diagrama de flujo en la Figura 42 que se encuentra en Anexos

IV. CONCLUSIONES Y RECOMENDACIONES REFERENCIAS

4.1. Conclusiones

- 1) Se analizaron los diferentes tipos de algoritmos de pronóstico de diferentes trabajos de investigación, seleccionando los algoritmos de Redes Neuronales, ARIMA, ANFIS, Promedio Móvil y Suavizado Exponencial por ser los más utilizados en el pronóstico de ventas.
- 2) Se concluyó que una de las características en común de los algoritmos es que la información esta ordenada cronológicamente en un 100% y que no exista grandes diferencias entre un dato y otro para poder realizar un buen pronóstico.
- 3) El promedio móvil y el suavizado exponencial son similares porque son relativamente simples de entender y explicar, ya que se utiliza para pronosticar 1 periodo y son de corto plazo. La red neuronal, ARIMA, ANFIS utilizan procedimientos iterativos complejos, requieren enormes esfuerzos computacional y son utilizados para pronóstico de medio y largo plazo.

En los algoritmos estudiados se encontraron las siguientes diferencias: En el promedio móvil solo es necesario considerar un numero n de periodos históricos para realizar el pronóstico. En el suavizado exponencial simple se utiliza un alfa que permite suavizar las variaciones en el error del pronóstico. Las redes neuronales necesitan entrenamiento de aprendizaje. El ARIMA para realizar el pronóstico se tiene que seguir la metodología de Box-Jenkis. El ANFIS utiliza una comparación real y difusa.



La red neuronal se diferencia de los otros algoritmos porque en su configuración se ha definido una época de entrenamiento que oscila entre 10000 y 20000 iteraciones, con una ratio de aprendizaje que puede fluctuar desde 0 a 1, con lo cual permite al usuario poder entrenar a la red neuronal para acercar el pronóstico a las ventas reales.

- 4) Se utilizaron las ventas históricas de 2 años desde el 18 de mayo del 2017 al 26 de abril del 2019 con 10964 registros que se utilizaron para pronosticar las ventas.
- 5) Se implementó un sistema de pronóstico de ventas utilizando Redes Neuronales, ANFIS, Promedio Móvil y Suavizado Exponencial, utilizando el lenguaje de programación C#.NET 2010 y Microsoft SQL SERVER 2008 R2.
- 6) En los resultados obtenidos la red neuronal, con una época de entrenamiento de 10000 y una ratio de aprendizaje de 0.03 tiene un MAPE del 20%. El ARIMA, alcanza un MAPE del 44%. El ANFIS, con una escala de aprendizaje de 3 se obtiene un MAPE del 32%, en conclusión, se determinó que la red neuronal es el que obtiene el mejor MAPE con respecto a los otros algoritmos analizados y es el que más se asemeja a las ventas reales.



4.2. Recomendaciones

- 1) Seguir con la implementación del software, para ir agregándole nuevos requisitos funcionales.
- 2) Optimizar la programación de la red neuronal y el ANFIS con respecto a la codificación de los algoritmos para reducir el tiempo de ejecución.
- 3) Tener mayor cantidad de ventas históricas de aproximadamente 10 años, para tener una mejor precisión en el pronóstico.
- 4) Se recomienda utilizar otros tipos de redes neuronales con diferente configuración, para determinar quien realiza el mejor pronóstico.
- 5) Se recomienda que el algoritmo ARIMA se implemente ya que por motivo de complejidad no se implementó en el sistema.



Referencias.

- Álvarez, R., (2009). *Análisis y propuesta de implementación de pronósticos y gestión de inventarios en una distribuidora de productos de consumo masivo*. Recuperado de http://tesis.pucp.edu.pe/repositorio/bitstream/handle/20.500.12404/302/%C3%81LVAREZ_RA%C3%9AL_AN%C3%81LISIS_PROPUESTA_IMPLEMENTACI%C3%93N_PRON%C3%93STICO_GESTI%C3%93N_INVENTARIOS.pdf?sequence=1&isAllowed=y
ALVAREZ_RAÚL_ANÁLISIS_PROPUESTA_IMPLEMENTACIÓN_PRONÓSTICO_GESTIÓN_INVENTARIOS.pdf (Acceso mayo 23, 2019).
- Alvitre Castillo, Víctor. (2000). *Investigación científica*. Chiclayo, Perú: Editorial Universidad Católica Santo Toribio de Mogrovejo.
- Angulo, J., (2016). *Modelo ARIMA para el pronóstico de la liquidez monetaria mensual en el sistema financiero peruano*. Recuperado de [http://dspace.unitru.edu.pe/bitstream/handle/UNITRU/7978//ANGULO ESPINOSA, Jorge Eduardo.pdf](http://dspace.unitru.edu.pe/bitstream/handle/UNITRU/7978//ANGULO_ESPINOSA,Jorge_Eduardo.pdf) (Acceso mayo 19, 2019).
- Ariza, A., (2013). *Métodos utilizados para el pronóstico de demanda de energía eléctrica en sistemas de distribución*. Recuperado de <http://repositorio.utp.edu.co/dspace/bitstream/handle/11059/3862/62131A719.pdf;jsessionid=F7E29DB49E06E79693ABAC0B0EF91482?sequence=1> 62131A719.pdf (Acceso mayo 24, 2019).
- Burgaentzle, F., (2016). *Pronósticos y modelos de inventarios en las industrias de alimentos: caso de estudio de una empresa láctea ecuatoriana*. Recuperado de <http://repositorio.usfq.edu.ec/bitstream/23000/6226/1/128660.pdf> 128660.pdf



(Acceso mayo 24, 2019).

Baeza, R., (Sin año de publicación). *Algoritmia*. Recuperado de <https://users.dcc.uchile.cl/~rbaeza/inf/algoritmia.pdf> (Acceso mayo 19, 2019).

Benites, J., (2018). *Implementación de un sistema de pronóstico de ventas con redes neuronales para la empresa industrial “Cerámicos Lambayeque SAC”*. Recuperado de – sin dirección Web – Proyecto de Tesis JMBS Final V F5.0.docx (Acceso mayo 19, 2019).

Carpio, J., (2016). *Modelo de predicción de la morosidad en el otorgamiento de crédito financiero aplicando metodología CRISP-DM*. Recuperado de <http://repositorio.uancv.edu.pe/bitstream/handle/UANCV/743/TESIS.pdf> (Acceso mayo 19, 2019).

Carranza Hernández, S. (2014). *Implementación de un Sistema de Información para el Reconocimiento de Caracteres Basado en la Red Neuronal Perceptrón*. Recuperado de http://tesis.pucp.edu.pe/repositorio/bitstream/handle/123456789/5956/CARRANZA_SAMMY_IMPLEMENTACION_SISTEMA_DE_INFORMACION.pdf?sequence=1&isAllowed=y (Acceso Mayo 26, 2019).

Caicedo, E., & López, J. (2017). *Fundamentos de redes neuronales artificiales*. Recuperado de <http://bibliotecadigital.univalle.edu.co/bitstream/10893/10330/3/Una%20aproximacion%20practica.pdf> /Una aproximación practica.pdf (Acceso Mayo 26, 2019).

Camones, F., Villacorta, M., Centro de Investigación & Desarrollo del Instituto Nacional de Estadística e Informática (INEI). (2002). *Control de calidad en los procesos*



estadísticos: una aproximación basada en los modelos ARIMA con Análisis de intervención. Recuperado de

https://www.inei.gob.pe/media/MenuRecursivo/publicaciones_digitales/Est/Lib0516/Libro.pdf / Libro.pdf (Acceso Mayo 27, 2019).

Contreras, C., Peña, D., Esquivel, J., Llerena, E., Paisa, E., & Mamani, G. (2011). *Evaluar la capacidad predictiva de los métodos de series de tiempo, regresión lineal y RNA Poda exhaustiva considerando el mínimo margen de error, una aplicación a la demanda.* Recuperado de https://revistas.upeu.edu.pe/index.php/ri_bi/article/download/915/883/915-1233-1-PB.pdf (Acceso mayo 23, 2019).

Corres, G., Passoni, L., Zarate, C., & Esteban, A. (2015). *Estudio comparativo de modelos de pronóstico de ventas.* Recuperado de <https://www.scribd.com/document/379250741/2659-13499-1-PB-pdf> (Acceso abril 14, 2019).

Chachuara, J. (Sin año de publicación). *Sistemas neuro - difusos.* Recuperado de http://sisbib.unmsm.edu.pe/bibvirtualdata/Tesis/Ingenie/chahuara_qj/Cap2.pdf / Cap2.pdf (Acceso Mayo 28, 2019).

Dieterich Steffan, Heinz. (2001). *Nueva guía para la investigación científica.* México.

Espinoza, B., & Gutiérrez, N. (2015). *Sistema de información para la toma de decisiones, usando técnicas de análisis predictivo para la empresa IASACORP INTERNATIONAL S.A.* Recuperado de http://cybertesis.urp.edu.pe/bitstream/urp/1271/1/espinoza_by-gutierrez_ne.pdf (Acceso mayo 19, 2019).

Fernández, V., (Sin año de publicación). *Modelos de pronósticos de ventas.* Recuperado de <http://www.centrodefinanzas.cl/index.php?seccion=publicaciones&id=19&document>



[o=descargar / Modelos+de+pronóstico+de+ventas.pdf](#) (Acceso abril 13, 2019).

Fuente, S. (Sin año de publicación). *Series temporales: Modelo ARIMA*. Recuperado de <http://www.estadistica.net/ECONOMETRIA/SERIES-TEMPORALES/modelo-arima.pdf> / modelo-arima.pdf (Acceso Mayo 27, 2019).

Gálvez, T., (Sin año de publicación). *3 métodos prácticos para pronosticar sus ventas*. Recuperado de <https://www.celogis.com/app/download/7244612780/3+M%C3%A9todos+para+pronosticar+ventas.pdf>, 3 Métodos para pronosticar ventas.pdf (Acceso mayo 19, 2019).

Gonzalo, C., (2008). *Series de tiempo*. Recuperado de https://www.u-cursos.cl/ingenieria/2010/1/CC52A/1/material_docente/bajar?id_material=296003 Series_de_Tiempo.pdf (Acceso mayo 24, 2019).

Guevara, J. & Moreno, L. (2016). *Modelo de pronóstico para las ventas semanales en la empresa Américas BPS en la campaña ETB*. Recuperado de <https://repository.libertadores.edu.co/bitstream/handle/11371/683/GuevaraJavierAlfredo.pdf> (Acceso mayo 18, 2019).

Hernández, S. (2015). *Análisis de series de tiempo*. Recuperado de https://www.cepal.org/sites/default/files/courses/files/01_2_arima.pdf / 01_2_arima.pdf (Acceso Mayo 27, 2019).

Hernández Sampiert, R., Fernández Collado, C. & Baptista Lucio, P. (1997). *Metodología de la investigación*. Colombia: Editorial: McGRAW – Hill Interamericana de México, S.A.

Instituto Tecnológico y de Estudios Superiores de Monterrey, (2006). *Métodos estadísticos para la estimación de ingresos*. Recuperado de http://www.cca.org.mx/funcionarios/biblioteca/html/finanzas_publicas/documentos/3



[/m3_metodos.pdf](#) m3_metodos.pdf (Acceso mayo 23, 2019).

- Ibarra, V., (2006). *Aplicación de las Series de Tiempo al Pronóstico de la Demanda en la empresa de manufactura moderna*. Recuperado de <https://tesis.ipn.mx/bitstream/handle/123456789/10943/27.pdf?sequence=1&isAllowed=y> FRIAS MIRANDA EDMUNDO VILIULFO Tesis 2006.pdf (Acceso mayo 24, 2019).
- Jiménez, J., (2013). *Pronóstico de demanda de llamadas en los CALL CENTER, utilizando redes neuronales artificiales*. Recuperado de https://pirhua.udep.edu.pe/bitstream/handle/11042/1745/ING_533.pdf?sequence=1&isAllowed=y ING_533.pdf (Acceso mayo 23, 2019).
- Lara Rosano, F. (Sin año de publicación). *Fundamentos de redes neuronales artificiales*. Recuperado de <https://es.scribd.com/document/343845538/598trabajo-pdf> (Acceso Mayo 26, 2019).
- López, B., Buentello, J., Luna, O., Galindo, J., Villanueva, D., & Medina, G. (2005). *Inteligencia artificial: Redes neuronales*. Recuperado de [http://www.itnuevolaredo.edu.mx/takeyas/Apuntes/Inteligencia%20Artificial/Apuntes/tareas_alumnos/RNA/RNA\(2005-II\).pdf](http://www.itnuevolaredo.edu.mx/takeyas/Apuntes/Inteligencia%20Artificial/Apuntes/tareas_alumnos/RNA/RNA(2005-II).pdf) / RNA(2005-II).pdf (Acceso Mayo 26, 2019).
- Mata, G., (2018). *Proceso para la estimación de ventas en las PYME mexicanas*. Recuperado de <http://148.204.210.201/tesis/1535727791854TesisMaestra.pdf> 1535727791854TesisMaestra.pdf (Acceso mayo 24, 2019).
- Malaver, M., (2015). *Aplicación de redes neuronales para determinar el pronóstico de las ventas en la empresa CATERING & BUFFETS MyS ubicada en la ciudad de Piura*.



- Recuperado de http://repositorio.ucv.edu.pe/bitstream/handle/UCV/164/malaver_em.pdf (Acceso mayo 19, 2019).
- Maciado, J. (2013). *Desempeño de la técnica de redes neuronales artificiales, frente a los modelos de series de tiempo ARIMA-GARCH en la predicción de los precios de la acción BANCOLOMBIA.* Recuperado de <http://polux.unipiloto.edu.co:8080/00000706.pdf> /00000706.pdf (Acceso Mayo 26, 2019).
- Manjarres, E., & Mogollon, J. (2017). *Diseño de una herramienta de pronóstico, para una línea de embazados de una planta que elabora productos de consumo masivo.* Recuperado de <http://manglar.uninorte.edu.co/bitstream/handle/10584/7746/130144.pdf?sequence=1> &isAllowed=y / 130144.pdf (Acceso Mayo 27, 2019).
- Montoya, Y., (2006). *Pronósticos: promedios móviles.* Recuperado de https://www.emagister.com/uploads_courses/Comunidad_Emagister_36642_PROMEDIO_MOVILES.pdf Comunidad_Emagister_36642_PROMEDIO_MOVILES.pdf (Acceso mayo 22, 2019).
- Peralta, R., (2017). *Evaluación de métodos de pronóstico de serie de tiempo para estimar la demanda de la línea de producto Ajinomoto en la ciudad de Chiclayo – periodo 2014 – 2016.* Recuperado de http://tesis.usat.edu.pe/bitstream/usat/871/1/TL_PeraltaPanduroRicardo.pdf (Acceso mayo 19, 2019).
- Pérez, P., & Noboa, P. (2017). *Desarrollo de un modelo de estimación de depósitos*



monetarios para un banco privado. Recuperado de <http://repositorio.uasb.edu.ec/bitstream/10644/5996/1/T2489-MFGR-Perez-Desarrollo.pdf> / T2489-MFGR-Perez-Desarrollo.pdf (Acceso Mayo 31, 2019).

Roque, I., (2016). *Análisis comparativo de técnicas de minería de datos para la predicción de ventas.* Recuperado de http://repositorio.uss.edu.pe/bitstream/uss/2695/1/Tesis_Roque_Montalvo_Irene.pdf ANÁLISIS COMPARATIVO DE TÉCNICAS DE MINERÍA DE DATOS PARA LA PREDICCIÓN DE VENTAS.pdf (Acceso mayo 20, 2019).

Rosas, D. (2014). *Diseño de un sistema de pronóstico de la demanda de nitrógeno y oxígeno para la compañía CRYOGAS, S.A. basado en redes neuronales.* Recuperado de <https://core.ac.uk/download/pdf/47250114.pdf> (Acceso mayo 19, 2019).

Rodríguez, M. & Valdivia, H. (2015). *Modelo de pronóstico de precios de acciones en la bolsa de valores de lima basado en redes neuronales artificiales.* Recuperado de http://cybertesis.uni.edu.pe/bitstream/uni/3459/1/rodriguez_mm.pdf (Acceso mayo 18, 2019).

Salazar, B., (2016). *Suavización exponencial simple.* Recuperado de <https://www.ingenieriaindustrialonline.com/herramientas-para-el-ingeniero-industrial/pron%C3%B3stico-de-ventas/suavizaci%C3%B3n-exponencial-simple/> (Acceso mayo 24, 2019).

Sánchez, J., & García-Martos, C. (Sin año de publicación). *Series Temporales Univariantes.* Recuperado de http://www.etsii.upm.es/ingor/estadistica/Carol/SeriesUNIV_MIO_MP.pdf / SeriesUNIV_MIO_MP.pdf (Acceso Mayo 27, 2019).



- Box y Jenkins. (Sin año de publicación). *Modelación ARIMA*. Recuperado de [https://www.academia.edu/38656568/Modelaci%C3%B3n_Box_Jenkins_ARIMA / A7.pdf](https://www.academia.edu/38656568/Modelaci%C3%B3n_Box_Jenkins_ARIMA_A7.pdf) (Acceso Mayo 27, 2019).
- Samaja, Juan Alfonso. (2004). *Epistemología y metodología: elementos para una teoría de la investigación científica*. Buenos Aires, Argentina: Editorial Universidad de Buenos Aires.
- Serrano, C., & Brío, B. (2015). *Predicción de la quiebra bancaria mediante el empleo de redes neuronales artificiales*. Recuperado de http://umh1480.edu.umh.es/wp-content/uploads/sites/44/2013/02/Serrano_Martin_1993_REFC.pdf (Acceso Mayo 26, 2019).
- Sulla, J., Soto, C., Cárdenas, R., & Huanco, L. (2016). *Sistema Neurodifuso con Optimización por Enjambre de Partículas para la Clasificación de la Obesidad en Niños y Adolescentes*. Recuperado de <http://www.laccei.org/LACCEI2016-SanJose/RefereedPapers/RP247.pdf> / RP247.pdf (Acceso Mayo 28, 2019).
- Universidad Simón Bolívar, (Sin año de publicación). *Estimación de la demanda: Pronósticos*. Recuperado de <http://prof.usb.ve/nbaquero/Pronosticos.pdf> Pronosticos.pdf (Acceso mayo 24, 2019).
- Valencia, M., Osorno, V., & Salazar, J. (2017). *Comparativo de modelos de pronóstico: clásicos, bayesianos y técnicas de combinación*. Recuperado de <https://revistas.unal.edu.co/index.php/rfc/article/download/66085/66085-356287-2-PB.pdf> (Acceso mayo 19, 2019).
- Vidaurre, Y. (2012). *Aplicación de las redes neuronales artificiales para el pronóstico de la demanda de agua potable en la empresa EPSEL S.A de la ciudad de Lambayeque*.



- Recuperado de http://tesis.usat.edu.pe/xmlui/bitstream/handle/usat/525/TL_Vidaurre_Siaden_Yasmin.pdf?sequence=1&isAllowed=y / TL_Vidaurre_Siaden_Yasmin.pdf (Acceso Mayo 29, 2019).
- Villalobos, P., (2015). *Pronóstico de ingresos tributarios recaudados de impuestos generales a las ventas a nivel nacional, por la SUNAT, mediante la metodología de Box y Jenkins y Redes neuronales artificiales*. Recuperado de <http://repositorio.unprg.edu.pe/bitstream/handle/UNPRG/459/BC-TES-4208.pdf> (Acceso mayo 19, 2019).
- Villareal, F., (2016). *Introducción a los Modelos de Pronósticos*. Recuperado de http://www.matematica.uns.edu.ar/uma2016/material/Introduccion_a_los_Modelos_de_Pronosticos.pdf (Acceso mayo 19, 2019).
- Wikidot.com. (Sin año de publicación). *Redes neuronales*. Recuperado de.../ Definición, Ventajas y Desventajas - REDES NEURONALES.html (Acceso Mayo 26, 2019).
- Yacuzzi, E., & Paggi, G. (Sin año de publicación). *Diseño e implementación de un sistema de pronóstico de ventas en WHIRLPOLL Argentina*. Recuperado de <https://ucema.edu.ar/publicaciones/download/documentos/209.pdf> / SeriesUNIV_MIO_MP.pdf (Acceso Mayo 27, 2019).
- Zúñiga, A., & Jordán, C. (2005). *Pronóstico de caudales medios mensuales empleando Sistemas Neurofuzzy*. Recuperado de <http://www.rte.espol.edu.ec/index.php/tecnologica/article/download/236/178> /236-688-1-PB.pdf (Acceso mayo 29, 2019).



ANEXOS.

Tabla 29.

Características, ventajas y desventajas de los algoritmos promedio móvil, suavizado exponencial simple.

Algoritmo	Características	Ventajas	Desventajas
Promedio Móvil	1) Estimar valores futuros en base a datos históricos. 2) Requiere que la información esté ordenada cronológicamente. 3) Proyecta valores en el periodo de pronósticos, basándose en el valor promedio de la variable calculada durante un número específico de periodos anteriores. 4) Cuanto menor el número de periodos utilizados para el promedio móvil, el pronóstico responde en forma más rápida a los cambios que tienen los datos históricos y viceversa	1) Permite aproximar el futuro, facilitando la toma de decisiones. 2) Los pronósticos planeados son más valiosos y exactos que los intuitivos.	1) No existe un método de pronóstico universal, capaz de adaptarse a todas las situaciones y circunstancias, este debe seleccionarse cuidadosamente, dependiendo del uso específico que se le pretenda dar del producto y las características cualitativas que podría tenerse. 2) Son simplificaciones de la realidad y no se asegura que todas las variables que influyen sobre el futuro a pronosticar estén incluidas en el modelo de pronóstico. 3) Solo pronostica un periodo más.



Continuación de la tabla N.º. 29 hacia abajo

Algoritmo	Características	Ventajas	Desventajas
Suavizado exponencial simple	1) Es bastante sencillo y permite reaccionar rápidamente ante variaciones en la venta.	1) Es uno de los métodos más populares y frecuentemente usados para pronosticar ya que requiere pocos datos.	1) Por ser exponencial, da mayor importancia a los últimos datos, es por esto que solo trabaja con el último dato real y el último pronosticado.
	2) Se utiliza para estimar valores futuros en base a datos históricos.	2) Este método reacciona mejor a cambios fuertes en la demanda.	2) No ofrecen buenos resultados para productos con poca historia de ventas.
	3) Se utiliza cuando la información histórica de las ventas no tiene tendencia o factores estacionales que la modifiquen.	3) Posee una ventaja sobre el modelo de promedio móvil ponderado ya que no requiere de una gran cantidad de períodos y de ponderaciones para lograr óptimos resultados.	
	4) Requiere que la información esté ordenada cronológicamente.		

Fuente. *Elaboración Propia.*



Tabla 30.

Características, ventajas y desventajas de los algoritmos redes neuronales: perceptrón multicapa.

Algoritmo	Características	Ventajas	Desventajas
Redes neuronales	<p>1) Seleccionamos un conjunto de patrones claramente representativos del problema a solucionar, con los cuales vamos a entrenar la red. Esta fase es fundamental pues dependiendo de la calidad de los datos utilizados para el entrenamiento, será la calidad de aprendizaje de la red.</p> <p>2) Aplicamos un vector de entrada a la red y calculamos la salida de las neuronas ocultas, propagamos estos valores hasta calcular la salida final de la red.</p>	<p>1) Aprendizaje: La red tienen la habilidad de aprender mediante una etapa que se llama etapa de aprendizaje. Esta consiste en proporcionar a la red datos como entrada a su vez que se le indica cuál es la salida (respuesta) esperada.</p> <p>2) Auto organización: La red crea su propia representación de la información en su interior, descartando al usuario de esto.</p>	<p>1) Complejidad de aprendizaje para grandes tareas, cuantas más cosas se necesiten que aprenda una red, más complicado será enseñarle.</p> <p>2) Tiempo de aprendizaje elevado. Esto depende de dos factores: primero si se incrementa la cantidad de patrones a identificar o clasificar y segundo si se requiere mayor flexibilidad o capacidad de adaptación de la red neuronal para reconocer patrones que sean sumamente parecidos, se deberá invertir más tiempo en lograr que la red converja a valores de pesos que representen lo que se quiera enseñar.</p>



Algoritmo	Características	Ventajas	Desventajas
perceptrón	<p>3) Calculamos el error entre el valor deseado y la salida de la red.</p> <p>4) Propagamos el error hacia atrás, es decir, estimamos el error en la capa oculta con base en el error de la capa de salida.</p>	<p>3) Tolerancia a fallos: Debido a que una red almacena la información de forma redundante, ésta puede seguir respondiendo de manera aceptable aun si se daña parcialmente.</p> <p>4) Flexibilidad: La red puede manejar cambios no importantes en la información de entrada, como señales con ruido u otros cambios en la entrada (ej. si la información de entrada es la imagen de un objeto, la respuesta correspondiente no sufre cambios si la imagen cambia un poco su brillo o el objeto cambia ligeramente).</p>	<p>3) No permite interpretar lo que se ha aprendido, la red por si sola proporciona una salida, un número, que no puede ser interpretado por ella misma, sino que se requiere de la intervención del programador y de la aplicación en si para encontrarle un significado a la salida proporcionada</p> <p>4) Elevada cantidad de datos para el entrenamiento, cuanto más flexible se requiera que sea la red neuronal, más información tendrá que enseñarle para que realice de forma adecuada la identificación.</p>
multicapas	<p>5) Modificamos los pesos de la capa de salida y de las capas ocultas con base en una estimación del cambio de los pesos Δw en cada una de las capas que, a su vez, depende del cálculo del error de la capa de salida y de la estimación del error en las capas ocultas realizado en los pasos anteriores.</p>	<p>5) Tiempo real: La estructura de la red es paralela, por lo cual, si esto es implementado con computadoras o en dispositivos electrónicos especiales, se pueden obtener respuestas en tiempo real.</p>	<p>5) Falta de reglas definatorias que ayuden a realizar una red para un problema dado.</p>



Tabla 31.

Características, ventajas y desventajas de los algoritmos ARIMA y ANFIS.

Algoritmo	Características	Ventajas	Desventajas
ARIMA	<p>1) Los modelos ARIMA aplican tanto para datos discretos o continuos. Los datos discretos son aquellos que son métodos solamente en números enteros, nunca con cifras decimales. Mientras que los datos continuos son medidos en intervalos fraccionarios, es decir, cifras decimales.</p> <p>2) Aunque la metodología ARIMA trata tanto con datos discretos y continuos, solo se puede aplicar a datos espaciados equidistantemente en el tiempo, en intervalos discretos de tiempo. Los datos medidos en intervalos discretos de tiempo pueden clasificarse en dos tipos: 1) datos que son producto de la acumulación durante un periodo de tiempo, por ejemplo, los ahorros de una persona. 2) datos que son producto de la medición instantánea periódicamente, por ejemplo, la medición de la presión en una tubería en intervalos de una hora.</p>	<p>1) Fácil de implementar y de explicar. No obstante, pueden ser totalmente inadecuados cuando el mecanismo que genera la serie es no lineal.</p> <p>2) Método más completo para pronosticar series de tiempos, ya sea que se trate de series estacionales o no.</p>	<p>1) Es esencialmente lineal.</p> <p>2) Son pobres para predecir en momentos de cambios estructurales y puntos de giro.</p>



Algoritmo	Características	Ventajas	Desventajas
ARIMA	<p>3) Para elaborar un modelo ARIMA se requiere una cierta cantidad de datos mínimo. Los profesores Box y Jenkins sugieren un mínimo de 50 observaciones. Un modelo ARIMA se puede aplicar a una serie con menor tamaño, realizando con especial cautela su interpretación. Para series con patrones estacionales se aconseja una serie con gran número de muestras observadas.</p> <p>4) Los modelos ARIMA son especialmente útiles en el tratamiento de series que presentan patrones estacionales.</p> <p>5) Los métodos Box-Jenkins aplican a series estacionarias y no estacionarias. Una serie estacionaria es aquella cuya media, varianza y función de autocorrelación permanecen constantes en el tiempo.</p> <p>6) Se asume que las perturbaciones aleatorias (at) presentes en la serie, son independientes entre sí. No existe correlación entre ellas, por lo tanto, ningún patrón modelable.</p>	<p>3) Son buenos para la predicción en el corto plazo, debido a su capacidad de aprender de los cambios en la dinámica de la serie.</p> <p>4) Sirve como punto de referencia.</p> <p>5) Son baratos y rápidos de construir.</p>	<p>3) Son de memoria corta. El horizonte de pronóstico es a veces muy corto.</p> <p>4) Menos eficiente en el uso de la información.</p> <p>5) Complicado y difícil de entender. Promete más de lo que proporciona.</p> <p>6) La determinación del modelo que mejor se adecua a la serie de datos es trivial y, por lo tanto, se requiere que la persona que realice predicciones tenga amplios conocimientos sobre esta metodología.</p>



Algoritmo	Características	Ventajas	Desventajas
ANFIS	1) Es fácil de entender, los conceptos matemáticos son bastante sencillos.		
	2) Es flexible, su escalamiento es sencillo.		
	3) Es tolerante a datos imprecisos.		
	4) Puede modelar funciones no lineales de complejidad arbitraria.	1) Posibilidad de incorporar al conjunto de datos que alimentan al sistema, un conjunto de variables, denominadas “variables exógenas” que podrían contribuir a mejorar la salida.	1) Puede mejorarse su respuesta variando los parámetros del modelo. Esto puede ser motivo de mayor consumo de tiempo de cálculo computacional. La decisión acerca de esto dependerá en gran medida de los costos que el error del pronóstico genera en la organización.
	5) Puede ser construida sobre la información de la experiencia de los operarios que manejan el sistema que se desea automatizar.		
	6) Puede ser complementaria a las técnicas de control convencionales.		
	7) Está basado en el lenguaje utilizado por los humanos.		

Fuente. *Elaboración Propia.*



Tabla 32.

Similitudes de los algoritmos promedio móvil, suavizado exponencial simple, redes neuronales: perceptrón multicapa, ARIMA, ANFIS.

Similitudes / Algoritmo	Promedio Móvil	Suavizado Exponencial Simple	Redes Neuronales Perceptrón Multicapa	ARIMA	ANFIS
Son relativamente simples de entender y explicar.	X	X			
Solo sirve para pronosticar un periodo más.	X	X			
Método útil cuando existen demasiados productos.	X	X	X	X	X
Planeación de corto plazo.	X	X			
Complejo procedimiento iterativo.			X	X	X
Enorme esfuerzo computacional.			X		X
Exactos a corto plazo.				X	
Pronóstico para el período de tiempo mediano a largo plazo.			X		X

Fuente. *Elaboración Propia.*



Tabla 33.

Diferencias de los algoritmos promedio móvil, suavizado exponencial simple, redes neuronales: perceptrón multicapa, ARIMA, ANFIS.

Promedio Móvil	Suavizado Exponencial Simple	Redes Neuronales Perceptrón Multicapa	ARIMA	ANFIS
<p>1) Sólo es necesario considerar un número “n” de periodos históricos para realizar el pronóstico. Dicho número dependerá siempre del nivel de error que genere dicha cantidad de “n”. 2) El valor de “n” puede variar de acuerdo a la información disponible. El objetivo es encontrar aquél que minimice el MAPE.</p>	<p>1) Esta pesa las variaciones o cambios que tiene el error del pronóstico en el tiempo con alfa (a). El valor de alfa es un porcentaje que tiene valores de cero a uno sin incluirlos. 2) Entre mayor sea este valor el error tendrá una mayor importancia.</p>	<p>1) Metodología para la aplicación de las redes neuronales en el pronóstico de ventas desarrollada por Kaastra y Boyd 2) Se compone de capa de entrada, capas ocultas y capa de salida las cuales están compuestas por una serie de neuronas que se encargan de recibir, procesar y enviar datos hacia otras neuronas procesando la información mediante distintas funciones matemáticas. 3) En la estructura de la red se asigna el número entradas, número oculto y número de salidas. 3) Se define una máxima época de entrenamiento. 4) Se especifica una ratio de aprendizaje. 5) La variación de la ratio de aprendizaje y la época de entrenamiento minimiza el error de pronóstico.</p>	<p>1) Se utiliza Metodología de Box-Jenkins. 2) Identificar el correlograma simple y el correlograma muestral. 3) Necesita una serie de tiempo estacionaria. 4) Tipo de modelo que utiliza es el ARMA. 5) Estimar los coeficientes de los términos autorregresivos y de media móvil incluidos en el modelo. 6) Para la predicción de un variable se estiman dos o más modelos que luego tiene que ser evaluados si se ajustan de forma razonable a los datos. 7) Cuando la serie de tiempo es estacionaria, cumple los requisitos de varianza, autocorrelación y normalidad esta lista para genera modelos de predicción.</p>	<p>1) Tener una base de datos confiable. 2) Seleccionar la información. 3) ANFIS. 4) Evaluación difusa. 5) Comparación real y la difusa.</p>

Fuente. *Elaboración Propia.*





Figura 15. Carga de ventas semanales del 5 de Mayo del 2017 al 31 de Diciembre del 2018.
Fuente. Elaboración propia.

	Venta	var	var	var	var	var	var	var	var	var	var	var	var	var	var	var	var
1	1268.60																
2	875.30																
3	367.30																
4	1142.10																
5	676.20																
6	1019.60																
7	1374.45																
8	466.90																
9	952.30																
10	1149.70																
11	1232.00																
12	700.00																
13	710.10																
14	1138.00																
15	360.60																
16	4584.40																
17	439.00																
18	538.10																
19	912.70																
20	1472.10																
21	686.40																
22	630.40																
23	539.80																
24	1170.50																
25	1111.00																
26	1130.40																
27	690.00																
28	232.50																
29	833.20																

Figura 16. Datos cargados SPSS.
Fuente. Elaboración propia.



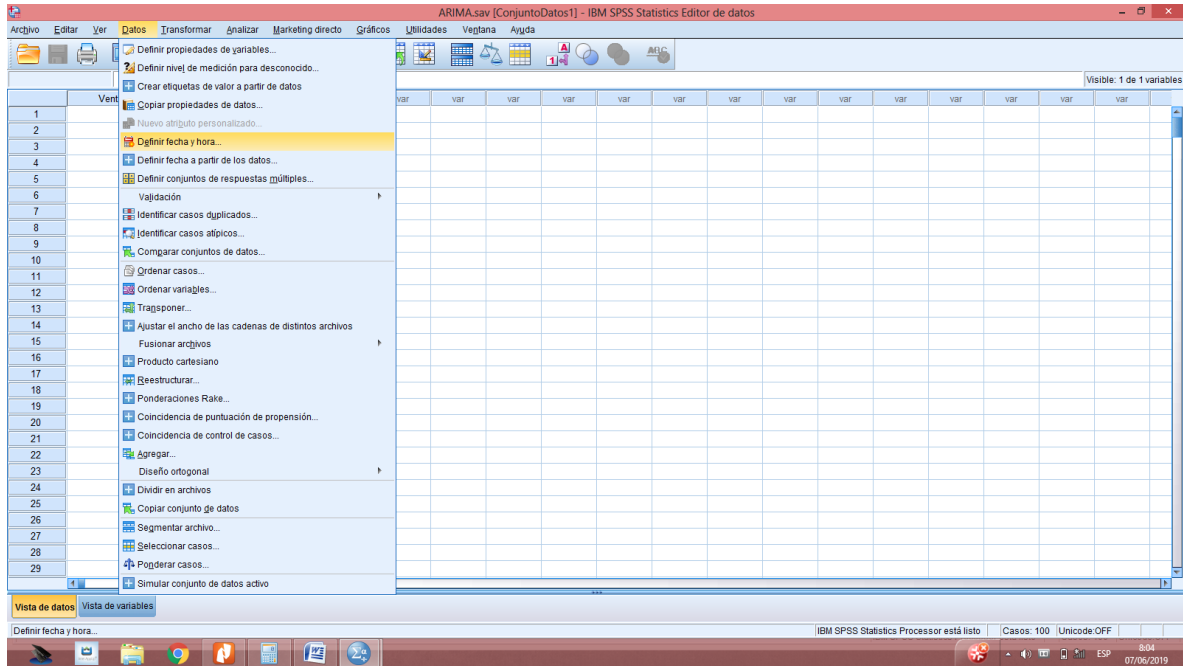


Figura 17. Definir fecha y hora.
Fuente. Elaboración propia.

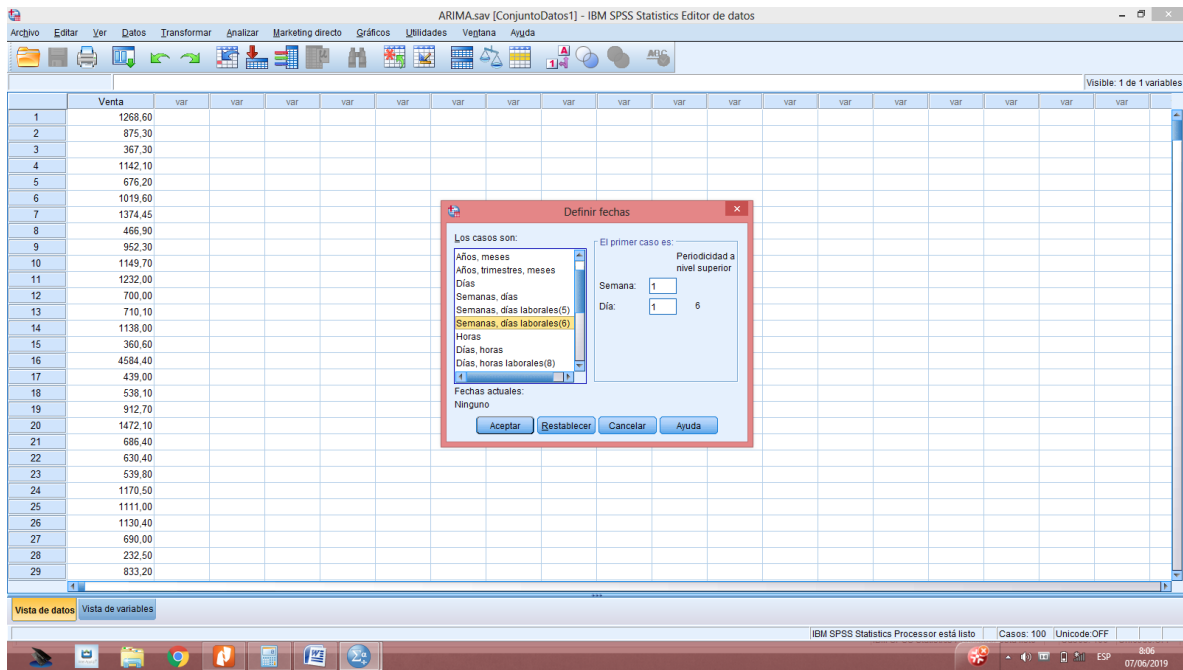


Figura 18. Definir fechas.
Fuente. Elaboración propia.



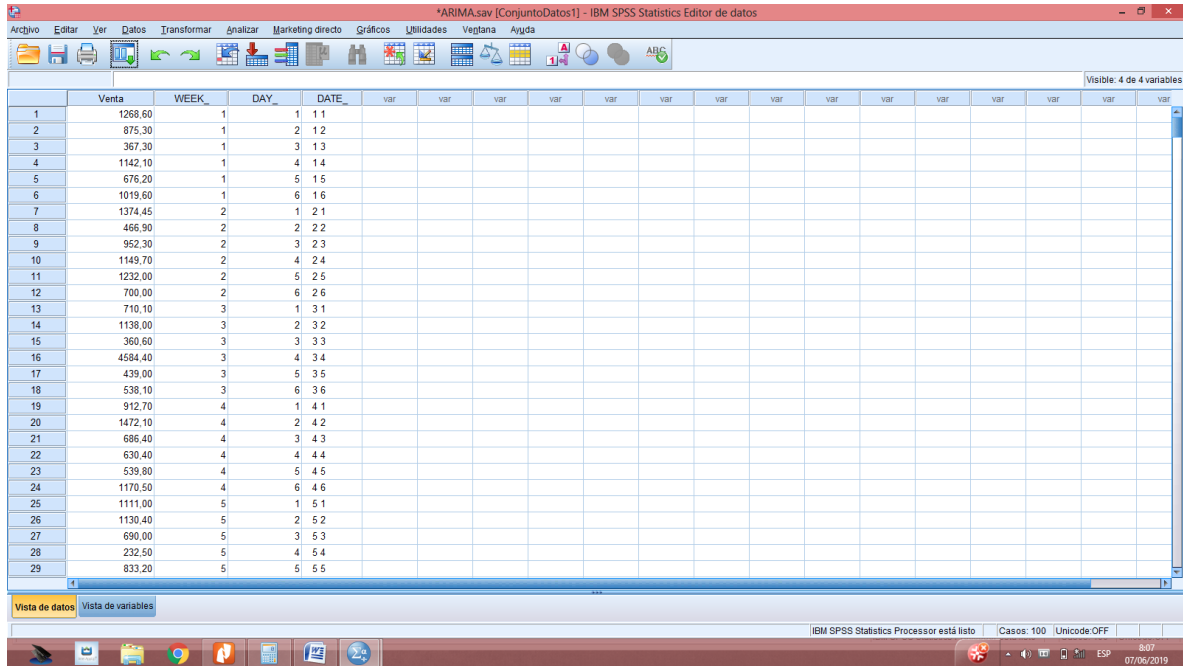


Figura 19. Datos definidos por fecha.
Fuente. Elaboración propia.

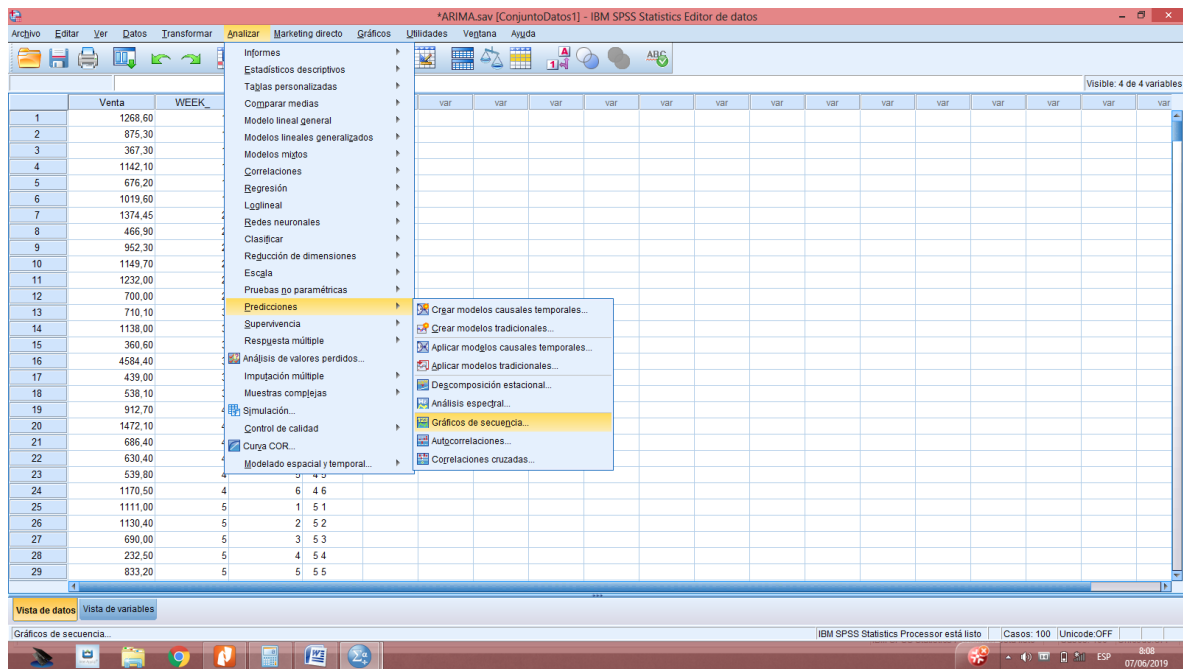


Figura 20. Crear grafico de secuencia para observar estacionalidad.
Fuente. Elaboración propia.



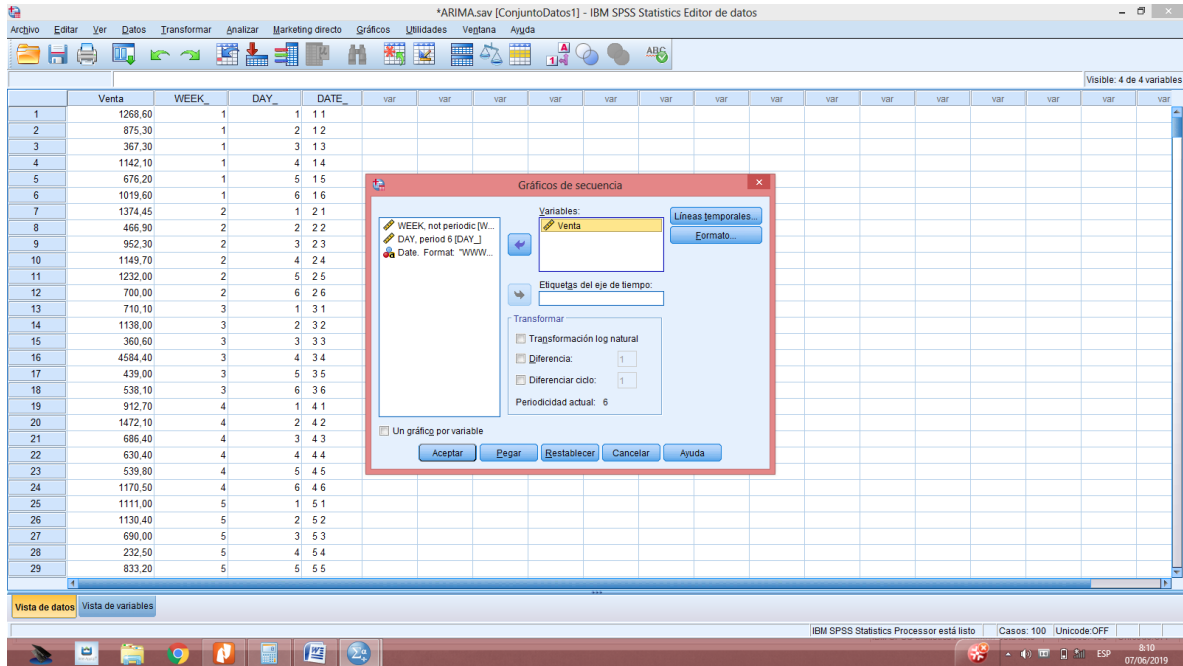


Figura 21. Definir parámetros gráficos de secuencia.
Fuente. Elaboración propia.




Figura 22. Gráfico de secuencia con muchos picos.
Fuente. Elaboración propia.



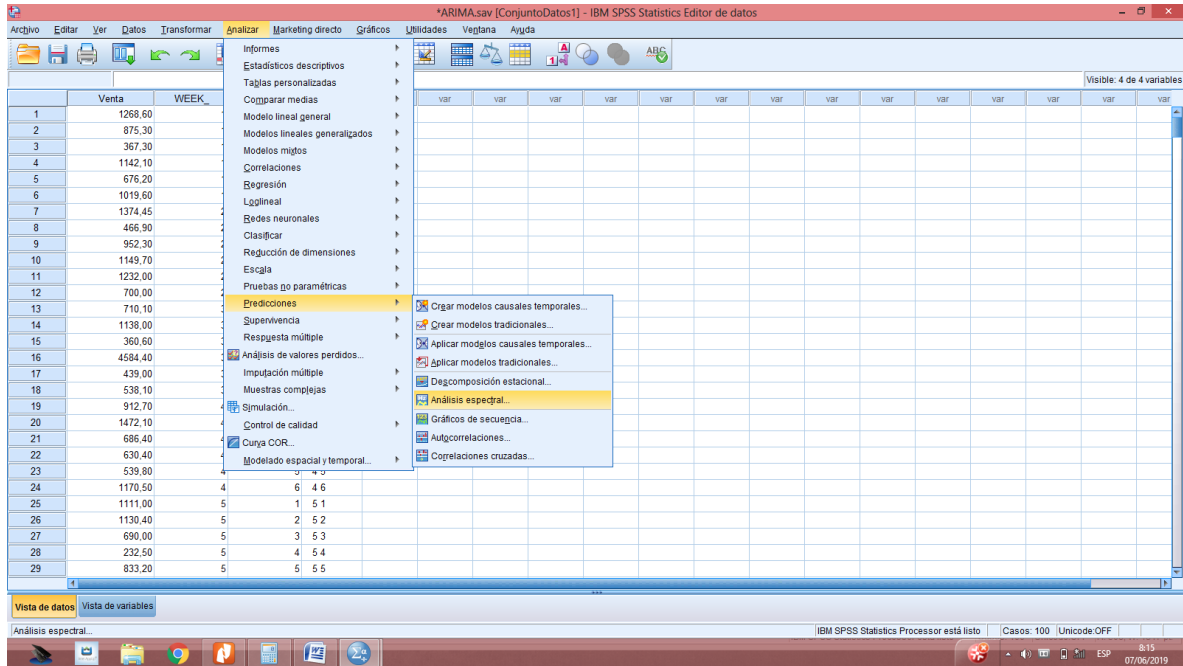


Figura 23. Análisis espectral para observar estacionalidad.
Fuente. Elaboración propia.

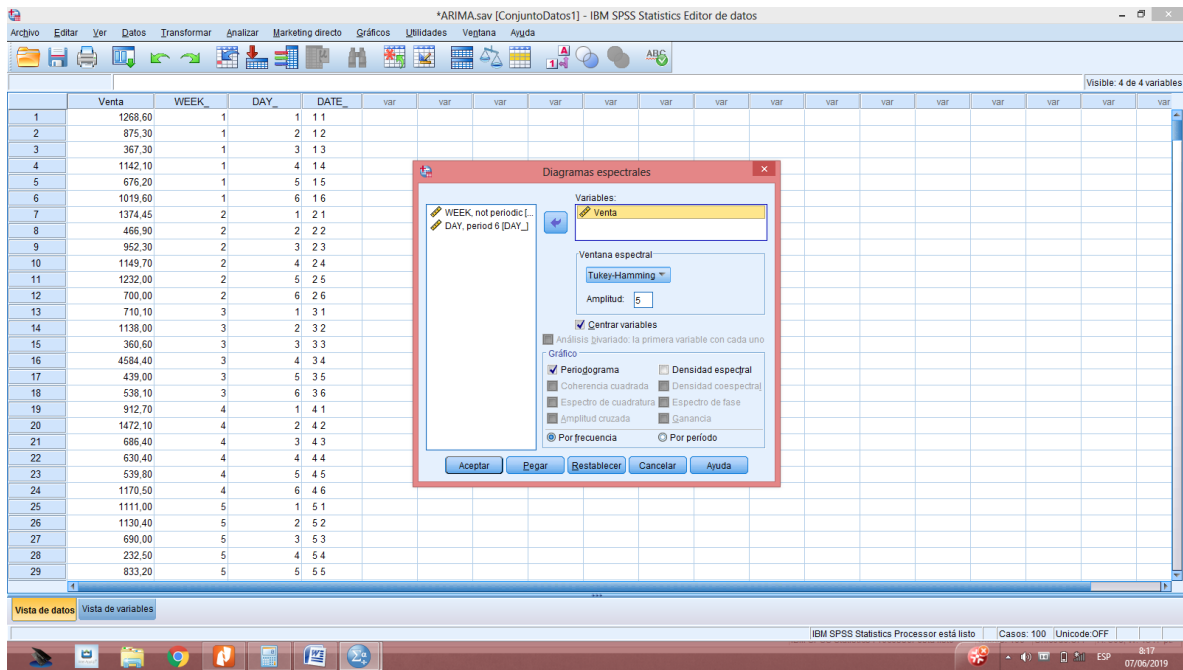


Figura 24. Diagramas espectrales.
Fuente. Elaboración propia.



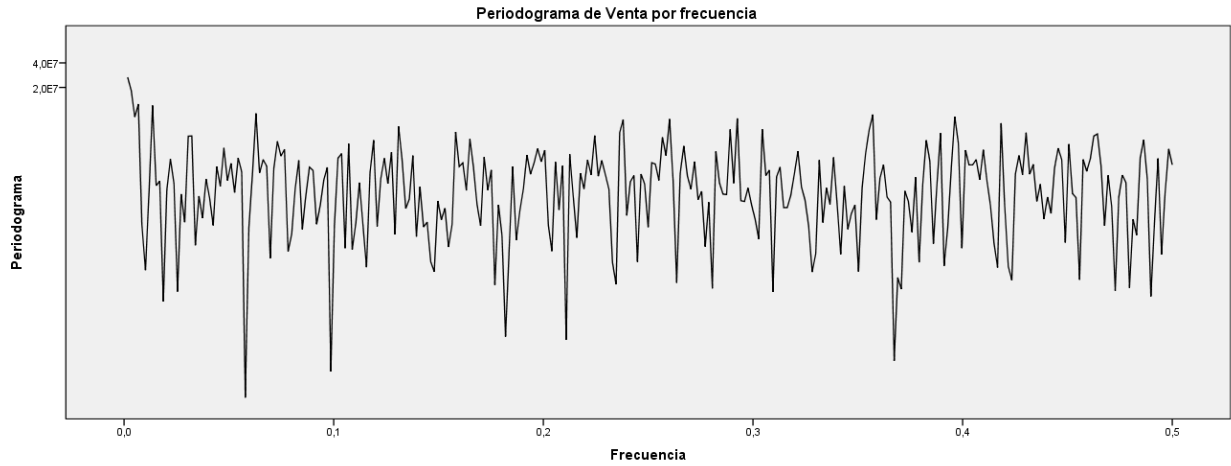


Figura 25. Peridograma de venta por frecuencia.
Fuente. Elaboración propia.

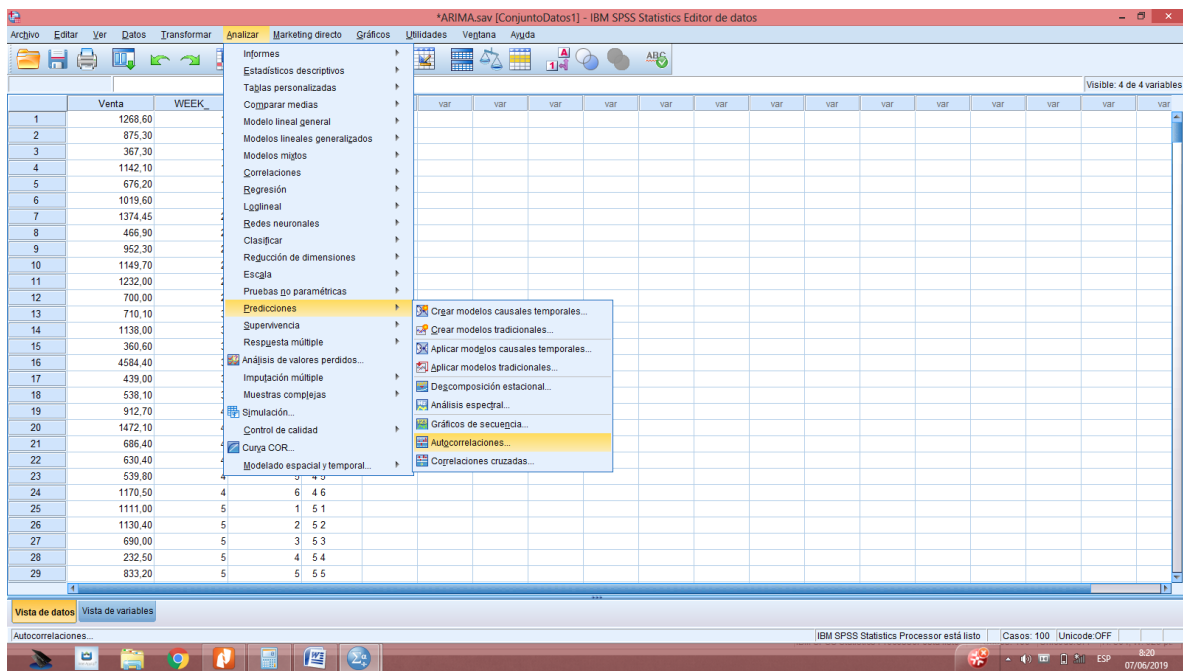


Figura 26. Crear autocorrelaciones.
Fuente. Elaboración propia.



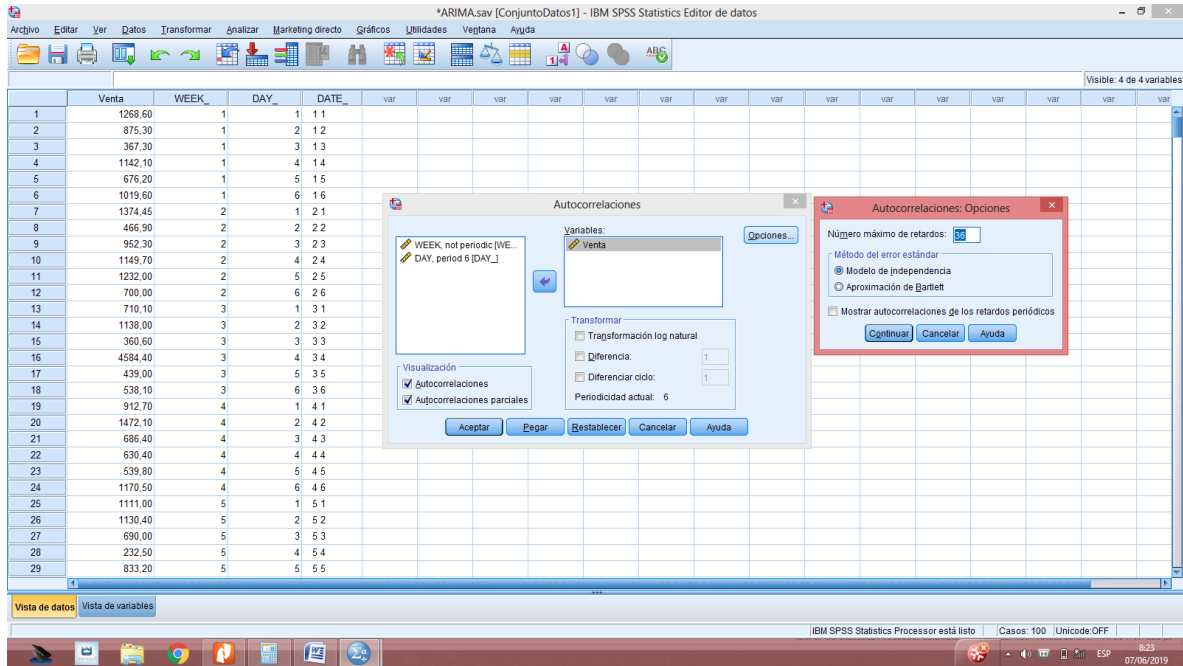


Figura 27. Definir parámetros autocorrelaciones.
Fuente. Elaboración propia.






Figura 28. Autocorrelaciones.
Fuente. Elaboración propia.






Figura 29. Autocorrelaciones parciales.

Fuente. Elaboración propia.



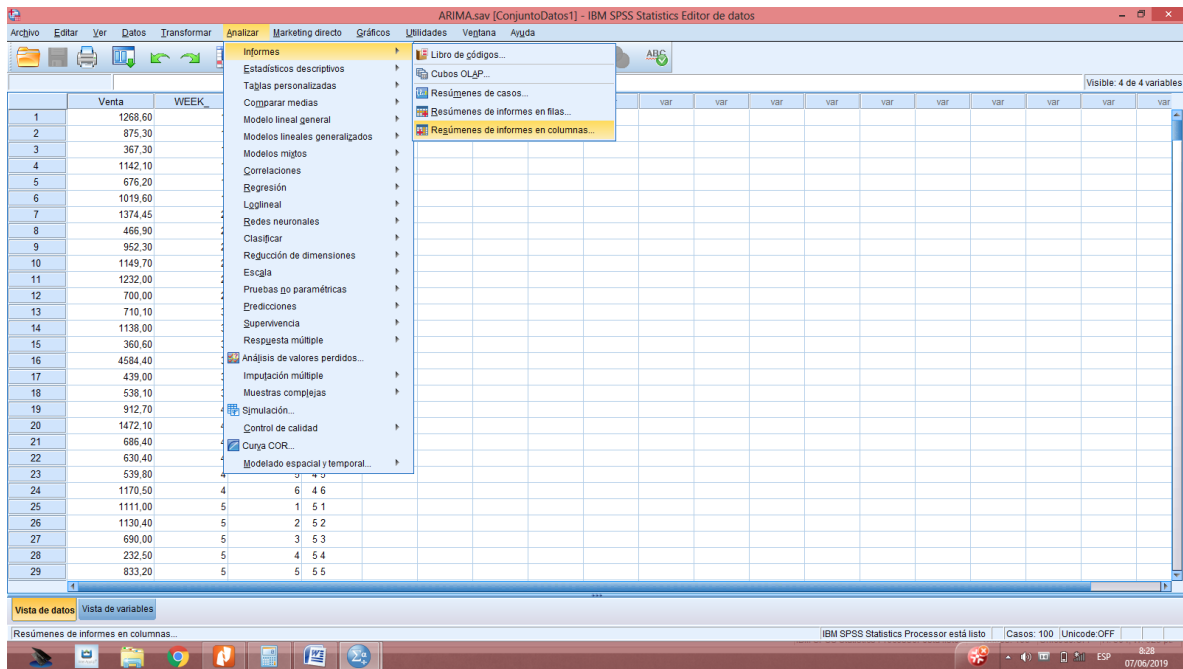


Figura 30. Analizar informes por columnas.
Fuente. Elaboración propia.

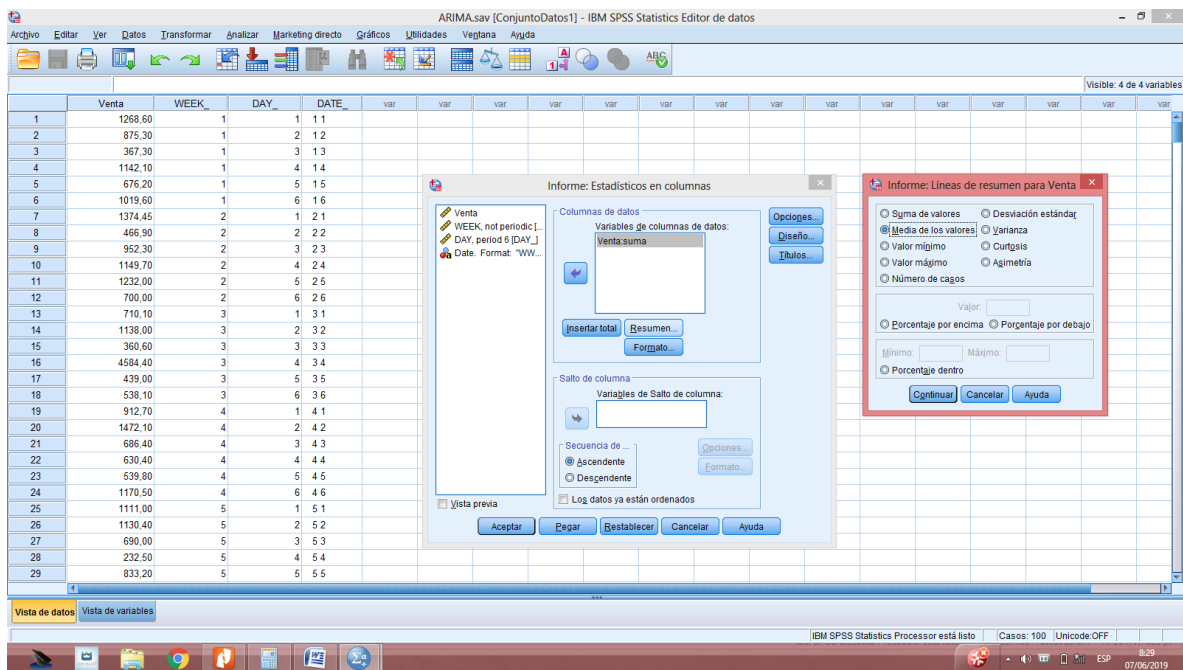


Figura 31. Informes estadísticos en columnas media.
Fuente. Elaboración propia.



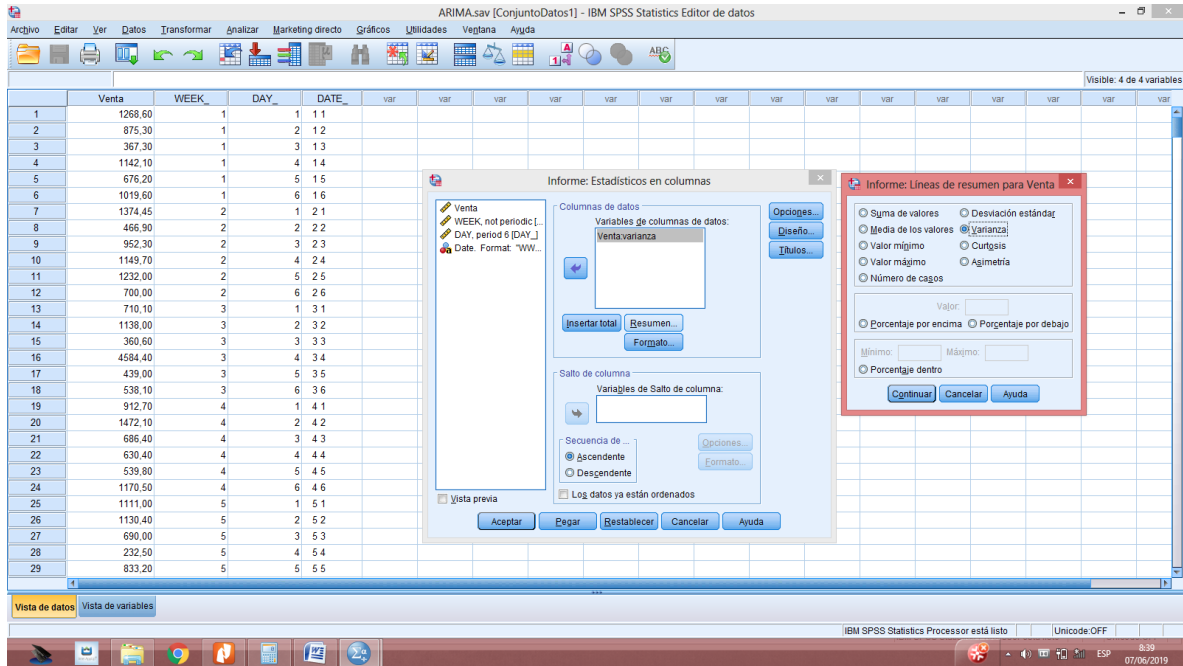


Figura 32. Informes estadísticos en columnas varianza.
Fuente. Elaboración propia.

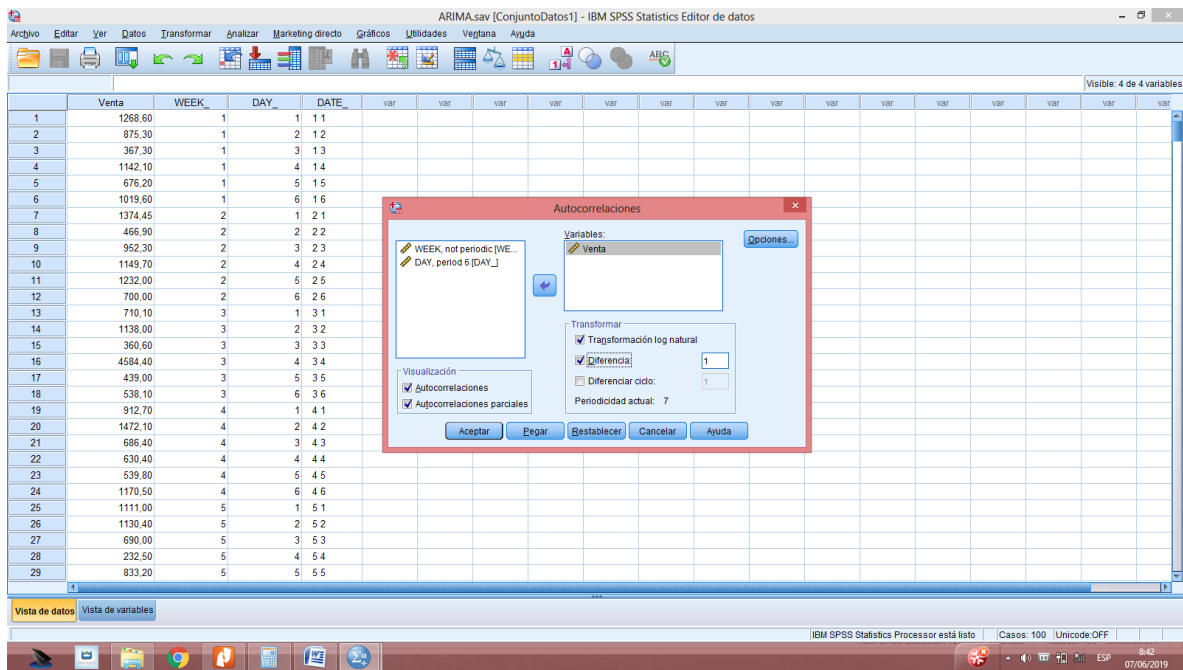


Figura 33. Autocorrelaciones parte regular.
Fuente. Elaboración propia.






Figura 34. Autocorrelaciones FAS.
Fuente. Elaboración propia.



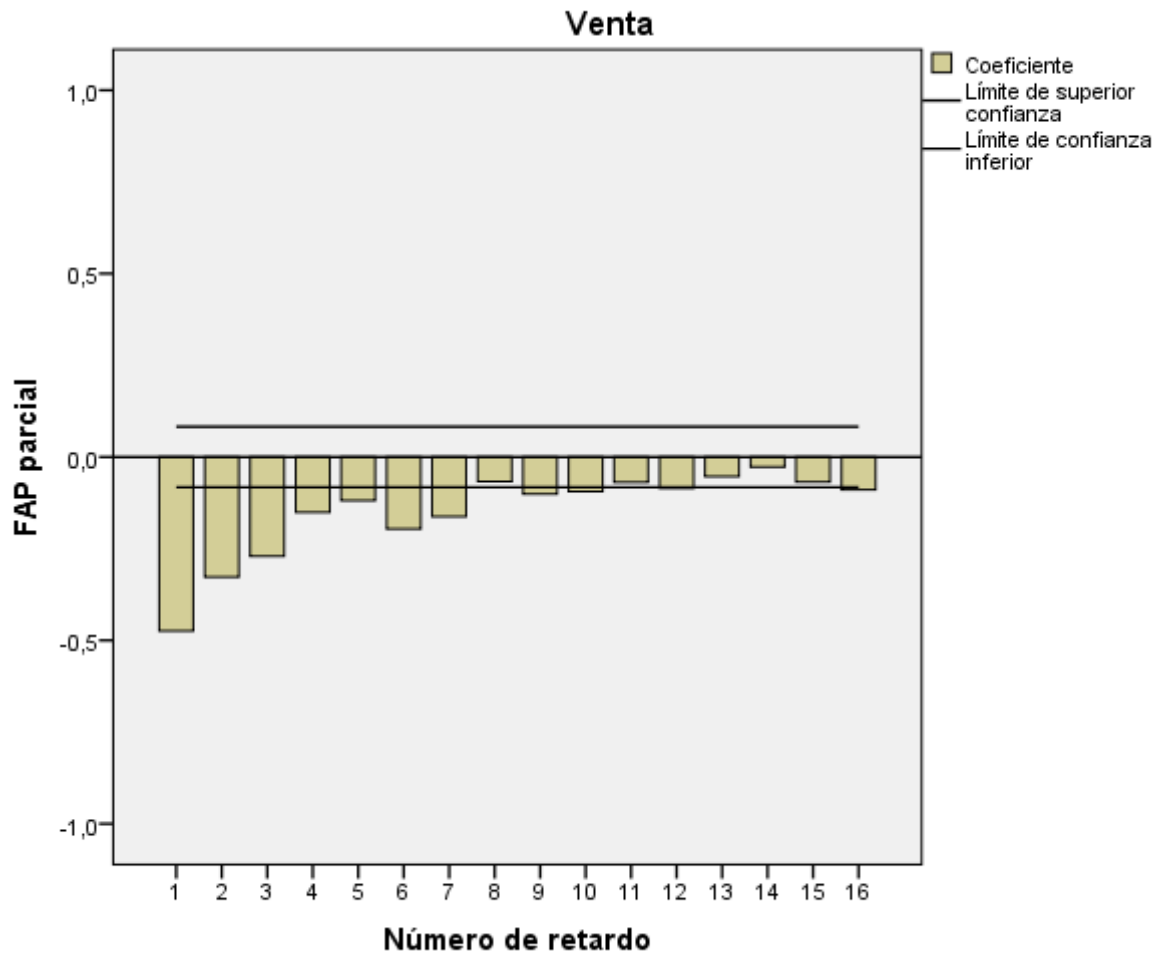


Figura 35. Autocorrelaciones parciales FAP.
Fuente. Elaboración propia.



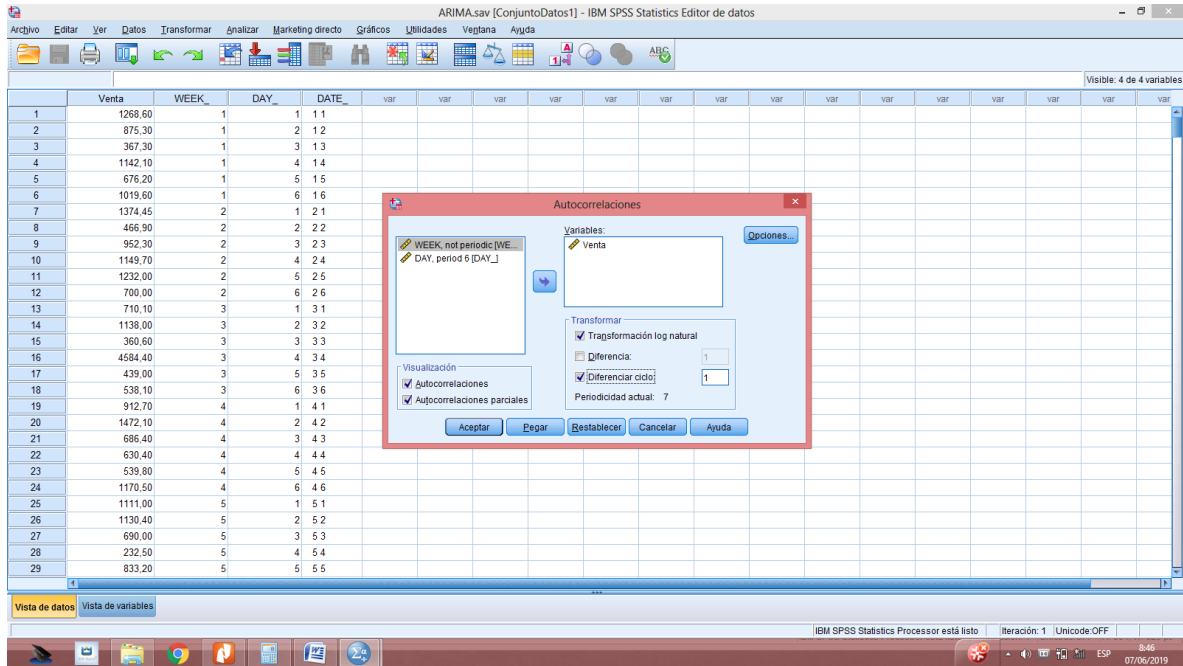


Figura 36. Autocorrelaciones parte estacional.
Fuente. Elaboración propia.

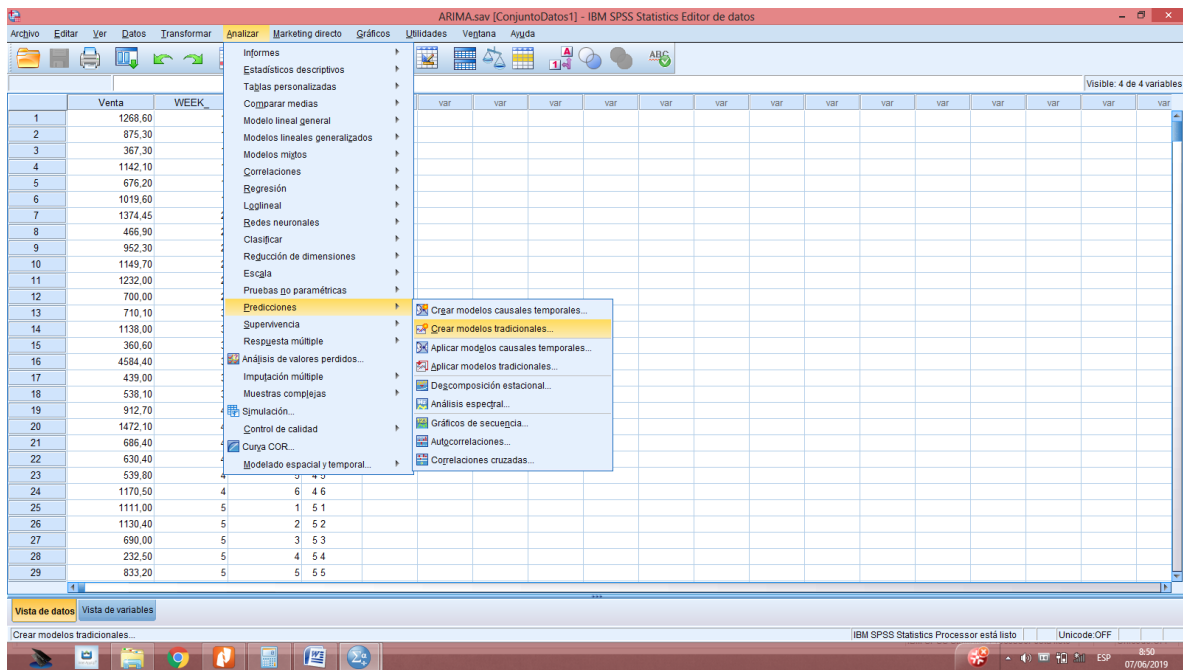


Figura 37. ARIMA, crear modelos tradicionales.
Fuente. Elaboración propia.



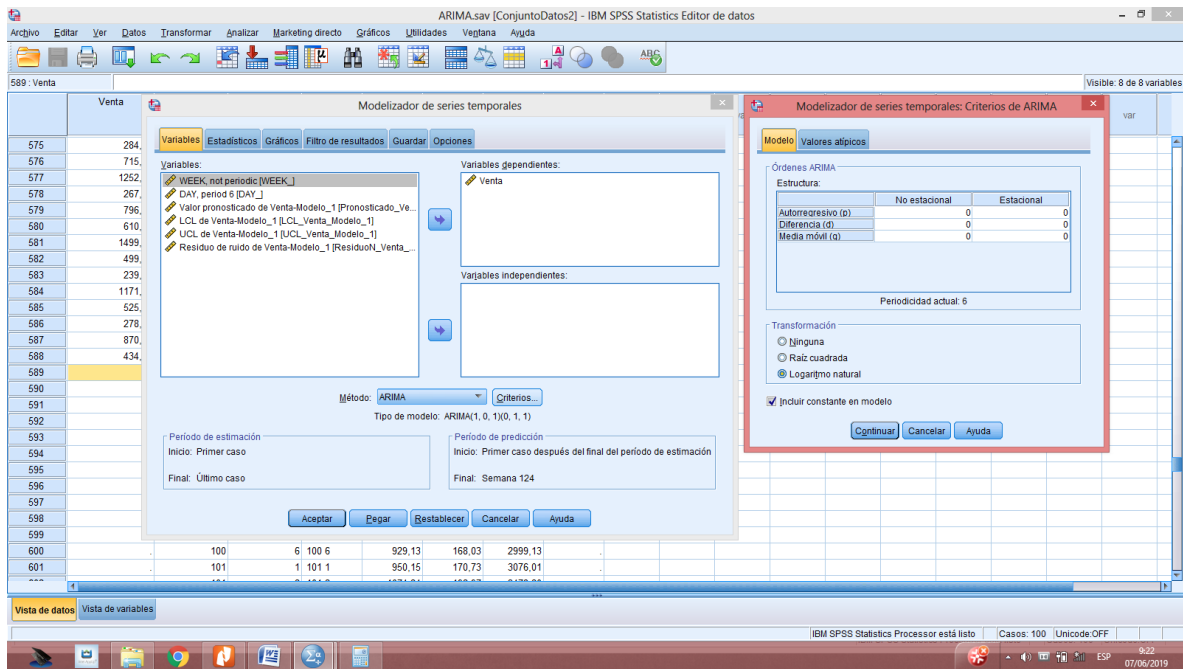


Figura 38. Modelizador de series temporales: Criterios ARIMA.
Fuente. Elaboración propia.

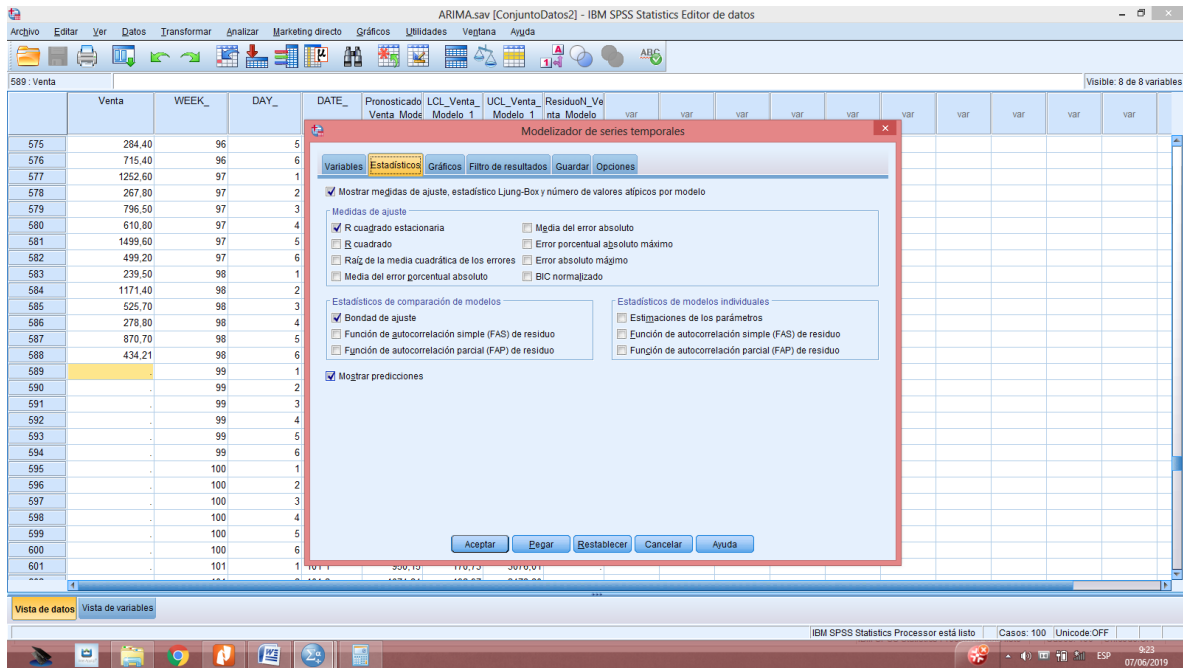


Figura 39. Modelizador de series temporales: Estadísticas.
Fuente. Elaboración propia.



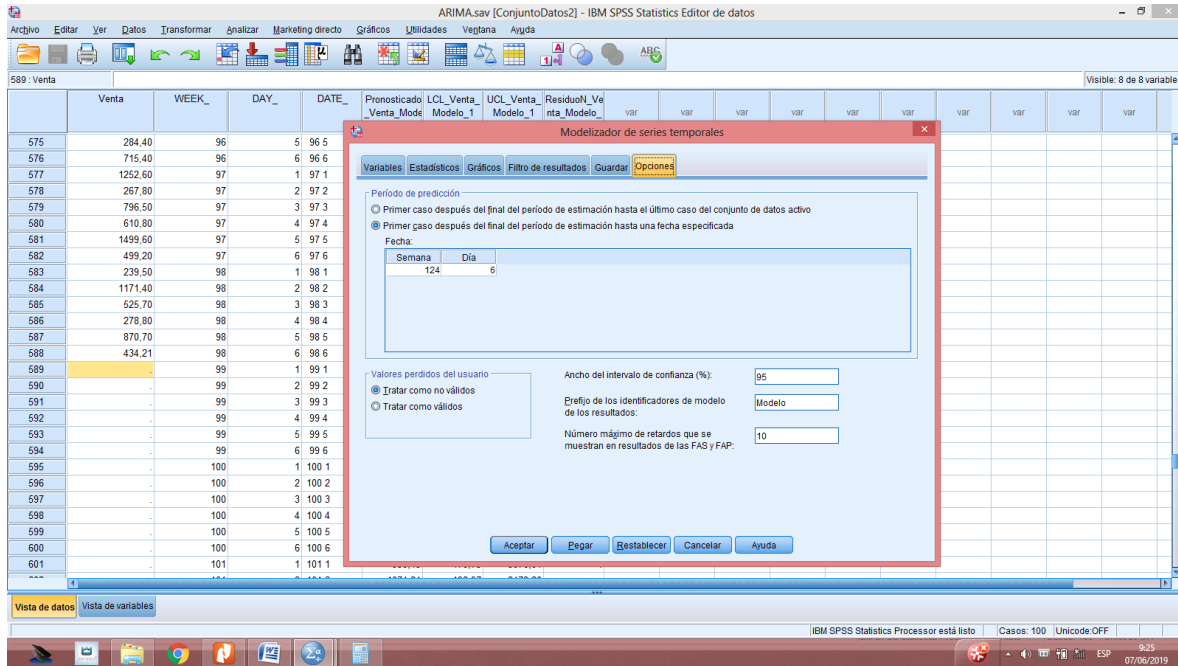


Figura 40. Modelizador de series temporales: Opciones.
Fuente. Elaboración propia.

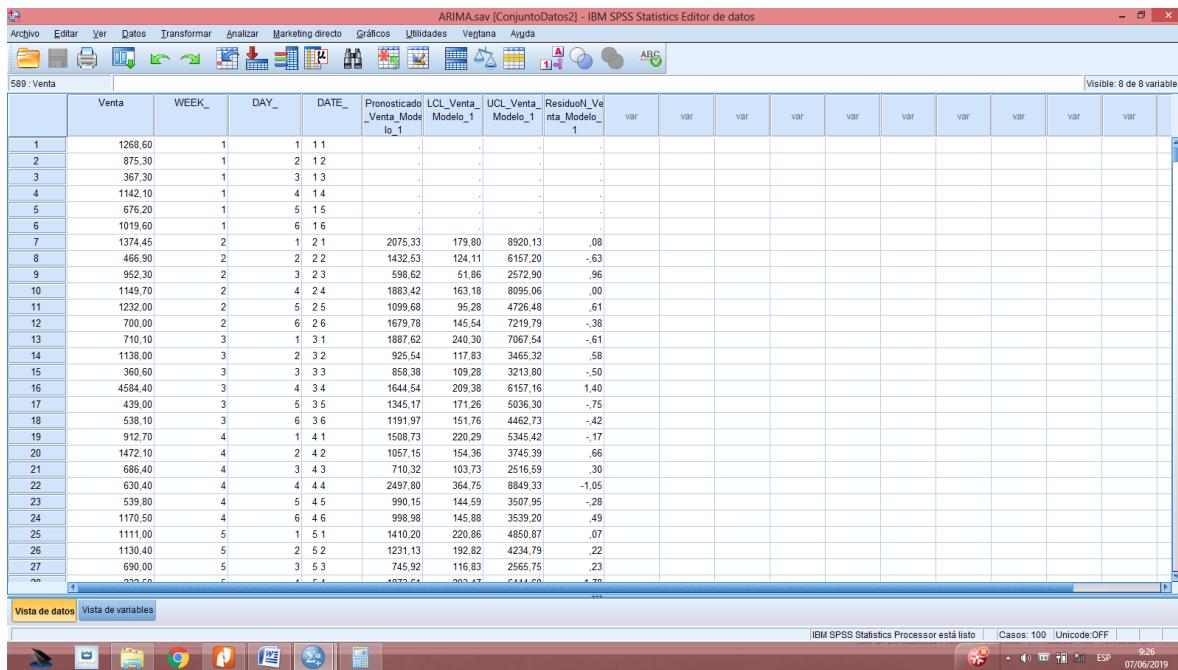


Figura 41. Modelo de Box-Jenkins ARIMA(1,0,1)(0,1,1).
Fuente. Elaboración propia.



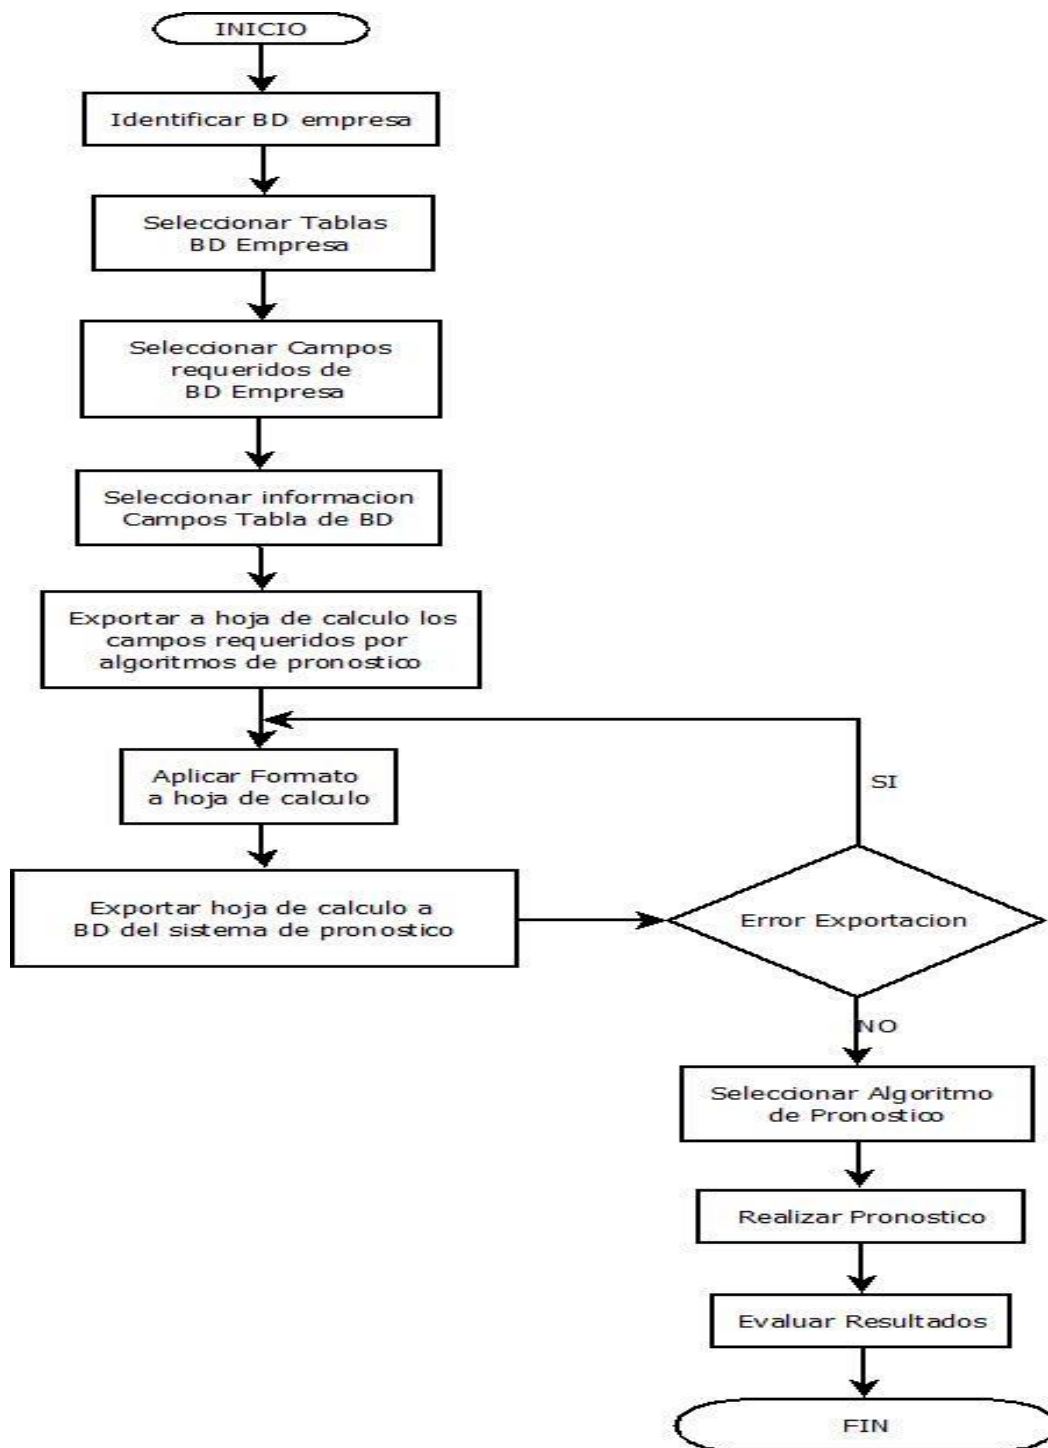


Figura 42. Diagrama de flujo para su adaptación del sistema de pronóstico en las MYPES
Fuente. Elaboración Propia

