



Universidad de Cuenca
Facultad de Ciencias Químicas
Carrera de Ingeniería Industrial

**“Modelo de elaboración de pronóstico de ventas mediante el uso de
redes neuronales artificiales y SVR”**

Ensayo Académico previo a la obtención del título de Ingeniero Industrial

Autor: Jonnatan Mesias Aucapiña Peralta

C.I: 0105342448

Director: Ing. Mario Patricio Peña Ortega

C.I: 0302168141

Cuenca - Ecuador

2018



Resumen: La importancia de pronosticar o prever el nivel de ventas es vital para la supervivencia de una empresa. Al no tener un patrón claro, la investigación sobre mejores modelos continúa en desarrollo. A través del avance tecnológico ha sido posible desarrollar aplicaciones basadas en redes neuronales artificiales (RNA), enfocadas en el desarrollo de pronóstico de ventas de productos de consumo frecuente, mejorando la exactitud de los sistemas de pronóstico tradicionales. En el presente estudio se compara el desempeño de los modelos tradicionales frente a sistemas más desarrollados como son redes neuronales artificiales y máquinas de soporte vectorial o regresión de soporte vectorial (SVM-SVR). Se demuestra la importancia de considerar factores externos como indicadores macroeconómicos e internos como los microeconómicos, (por ejemplo, precios de productos relacionados), los cuales afectan el nivel de ventas en una organización. Estas consideraciones no se habían tomado en cuenta en el pasado. La aplicación de este estudio fue en un supermercado. En primera instancia se realizó un pre-procesado para limpiar, adecuar y normalizar las bases de datos. Luego, debido a que no se tenía información etiquetada respecto a cuáles pares de productos eran sustitutos o complementarios, fue necesario aplicar un análisis de elasticidad cruzada. Además, se considera una media armónica (f1-score) en varios puntos para establecer prioridades en algunos productos y resultados obtenidos. Estudios en los que se realizan análisis comparativos entre pronósticos, demuestran la eficacia al usar redes neuronales, se presenta en: [7], [16] y [25]. El modelo propuesto en este estudio presenta una potencial aplicación en el pronóstico de ventas de productos de alta rotación en supermercados, ya que sus resultados son más exactos que los obtenidos con procedimientos tradicionales.

Palabras claves: ARIMA, Promedio móvil, Pronóstico, RNA, SVR, Variación cíclica.



Abstract: The importance of forecasting and predicting the level of sales is vital to the survival of a company. There is continuous research on the development for better systems due to the lack of clear sales patterns. Through the rapid advancement of technology, it has been possible to develop applications based on artificial neural networks (ANN). These applications focus on the development of sales forecasts of products of frequent consumption, improving the accuracy of traditional forecasting systems. In the present study, the performance of traditional models is compared with more developed systems such as neural networks and support vector machines or support vector regression (SVM-SVR). It demonstrates the importance of considering external factors as macroeconomic and internal indicators such as microeconomics, (for example, prices of related products), which affect the level of sales in an organization. These considerations had not been taken into account in the past. The application of this study was in a super-market. In the first instance, a preprocessor was carried out to clean, adapt and standardize the databases. Then, because there was no labeled information regarding which pairs of products were substitutes or complements, it was necessary to apply a cross-elasticity analysis. In addition, a harmonic average (f1-score) is considered in several points to establish priorities in some products and obtain results. Studies in which comparative analyzes are made between forecasts, which demonstrate the effectiveness of using neural networks is presented in: [7], [16], and [25]. The model proposed in this study presents a potential application in the forecast of sales of high turnover products in supermarkets, since their results are more accurate than those obtained with traditional procedures.

Keywords: ARIMA, Moving average, Forecast, ANN, SVR, Cyclic variation.



INDICE

Resumen.....	2
Abstract	3
Clausula de licencia y autorización pára publicación en el Repositorio Institucional.....	5
Clausula de propiedad intelectual.....	6
1. Introducción.	8
1.1. Fundamentación y justificación	8
1.2. Revisión de la literatura.....	10
1.2.1. Clasificación de los modelos tradicionales de pronóstico	10
1.2.2. Uso de las RNA y regresión de soporte vectorial.....	10
1.2.3. Consideración de indicadores microeconómicos y macroeconómicos	11
1.2.4. Sistema de valoración.....	13
1.2.5. Algoritmo de Garson para determinar el nivel de importancia	14
2. Materiales, fuentes y métodos.....	14
2.1. Recopilación de datos.....	15
2.2. Procedimiento modelo.....	15
2.2.1. Recolección de datos y filtración	15
2.2.2. Análisis para selección de productos sustitutos y complementarios	15
2.2.3. Preparación de indicadores macroeconómicos.....	16
2.2.4. Consideraciones de cada modelo de pronóstico a comparar	16
3. Resultados.	17
3.1. Indicadores macroeconómicos considerados	17
3.2. 10 productos principales considerados.....	18
3.3. Comparación de resultados obtenidos en la aplicación de pronósticos en un supermercado	18
3.4. Importancia de indicadores macroeconómicos	20
4. Discusión.....	20
4.1. Comparación de pronósticos más ajustados	20
5. Conclusiones.	22
6. Agradecimiento.	23
7. Bibliografía.	23



Cláusula de licencia y autorización para publicación en el Repositorio Institucional

Yo, Jonnatan Mesias Aucapiña Peralta, en calidad de autor y titular de los derechos morales y patrimoniales del trabajo de titulación "Modelo de elaboración de pronóstico de ventas mediante el uso de redes neuronales artificiales y SVR", de conformidad con el Art. 114 del CÓDIGO ORGÁNICO DE LA ECONOMÍA SOCIAL DE LOS CONOCIMIENTOS, CREATIVIDAD E INNOVACIÓN reconozco a favor de la Universidad de Cuenca una licencia gratuita, intransferible y no exclusiva para el uso no comercial de la obra, con fines estrictamente académicos.

Asimismo, autorizo a la Universidad de Cuenca para que realice la publicación de este trabajo de titulación en el repositorio institucional, de conformidad a lo dispuesto en el Art. 144 de la Ley Orgánica de Educación Superior.

Cuenca, 24 de septiembre de 2018

Jonnatan Mesias Aucapiña Peralta

C.I: 010534244-8



Cláusula de Propiedad Intelectual

Yo, Jonnatan Mesias Aucapiña Peralta, autor del trabajo de titulación "Modelo de elaboración de pronóstico de ventas mediante el uso de redes neuronales artificiales y SVR", certifico que todas las ideas, opiniones y contenidos expuestos en la presente investigación son de exclusiva responsabilidad de su autor.

Cuenca, 24 de septiembre de 2018

A handwritten signature in blue ink, consisting of a large, stylized 'J' followed by several loops and a long horizontal stroke.

Jonnatan Mesias Aucapiña Peralta

C.I: 010534244-8



Modelo de elaboración de pronóstico de ventas mediante el uso de redes neuronales artificiales y SVR.

Model for the preparation of sales forecasts through the use of artificial neural networks and SVR.

Jonnatan Aucapiña¹, Mario Peña²

¹Egresado de la carrera de Ingeniería Industrial, Facultad de Ciencias Químicas
Universidad de Cuenca, jonatan.aucapina2312@ucuenca.ec

²Docente de la facultad de Ciencias Químicas
Universidad de Cuenca, mario.pena@ucuenca.edu.ec

Resumen: La importancia de pronosticar o prever el nivel de ventas es vital para la supervivencia de una empresa. Al no tener un patrón claro, la investigación sobre mejores modelos continúa en desarrollo. A través del avance tecnológico ha sido posible desarrollar aplicaciones basadas en redes neuronales artificiales (RNA), enfocadas en el desarrollo de pronóstico de ventas de productos de consumo frecuente, mejorando la exactitud de los sistemas de pronóstico tradicionales. En el presente estudio se compara el desempeño de los modelos tradicionales frente a sistemas más desarrollados como son redes neuronales artificiales y máquinas de soporte vectorial o regresión de soporte vectorial (SVM-SVR). Se demuestra la importancia de considerar factores externos como indicadores macroeconómicos e internos como los microeconómicos, (por ejemplo, precios de productos relacionados), los cuales afectan el nivel de ventas en una organización. Estas consideraciones no se habían tomado en cuenta en el pasado. La aplicación de este estudio fue en un supermercado. En primera instancia se realizó un pre-procesado para limpiar, adecuar y normalizar las bases de datos. Luego, debido a que no se tenía información etiquetada respecto a cuáles pares de productos eran sustitutos o complementarios, fue necesario aplicar un análisis de elasticidad cruzada. Además, se considera una media armónica (f1-score) en varios puntos para establecer prioridades en algunos productos y resultados obtenidos. Estudios en los que se realizan análisis comparativos entre pronósticos, demuestran la eficacia al usar redes neuronales, se presenta en: [7], [16] y [25]. El modelo propuesto en este estudio presenta una potencial aplicación en el pronóstico de ventas de productos de alta rotación en supermercados, ya que sus resultados son más exactos que los obtenidos con procedimientos tradicionales.

Palabras claves: ARIMA, Promedio móvil, Pronóstico, RNA, SVR, Variación cíclica.

Abstract: The importance of forecasting and predicting the level of sales is vital to the survival of a company. There is continuous research on the development for better systems due to the lack of clear sales patterns. Through the rapid advancement of technology, it has been possible to develop applications based on artificial neural networks (ANN). These applications focus on the development of sales forecasts of products of frequent consumption, improving the accuracy of traditional forecasting systems. In the present study, the performance of traditional models is compared with more developed systems such as neural networks and support vector machines or support vector regression (SVM-SVR). It demonstrates the importance of considering external factors as macroeconomic and internal indicators such as microeconomics, (for example, prices of related products), which affect the level of sales in an organization. These considerations had not been taken into account in the past. The application of this study was in a super-market. In the first instance, a preprocessor was carried out to clean, adapt and standardize the databases. Then, because there was no labeled information regarding which pairs of products were substitutes or complements, it was necessary to apply a cross-elasticity analysis. In addition, a harmonic average (f1-score) is considered in several points to establish priorities in some



products and obtain results. Studies in which comparative analyzes are made between forecasts, which demonstrate the effectiveness of using neural networks is presented in: [7], [16], and [25]. The model proposed in this study presents a potential application in the forecast of sales of high turnover products in supermarkets, since their results are more accurate than those obtained with traditional procedures.

Keywords: ARIMA, Moving average, Forecast, ANN, SVR, Cyclic variation.

1. Introducción.

1.1. *Fundamentación y justificación*

El mundo de los negocios está impulsado por la demanda de productos y servicios que los clientes requieren. No obstante, los patrones de la demanda varían considerablemente de un período a otro. Toda empresa actualmente debe hacer planes frente a la incertidumbre que puede surgir en el entorno en el que se encuentra. Estos planes trazan una guía para poder determinar cuáles serían los recursos necesarios para que la empresa pueda cubrir la demanda prevista.

En el contexto de la administración de inventarios, es bien conocido que, ante la variación de la demanda y la demora en la entrega de un nuevo pedido por parte del proveedor, las organizaciones definen un inventario de seguridad que les permita atender los pedidos. Esta acción se toma para no llegar a la penosa situación de tener déficit de inventarios que les representarían pérdidas en ventas, así como una mala imagen ante los consumidores. Todo lo anterior es esencial en la actualidad ante la enorme competencia que se ha desatado en la mayoría de sectores comerciales [17].

Debido al comportamiento no lineal de ventas, en la gran mayoría de empresas existe un alto nivel de incertidumbre en la formulación de pronósticos. La planificación de la producción empieza por fijar la cantidad necesaria de producto terminado para producir o mantener almacenado para un tiempo determinado. Esta planificación determina el nivel de ventas que podría llegar a tener la empresa considerando factores como: habilidades, capacidades, actitudes y comportamientos de la población [23]. Los modelos de pronóstico que se conocen hasta la actualidad presentan resultados con un cierto grado de error.

Bernstein [4] explica metafóricamente la importancia de un pronóstico para la planificación de cualquier industria:

“Para la planeación de recursos es imprescindible primero determinar que le espera en el futuro. Asegúrese que los insumos necesarios que se solicitan se entreguen a tiempo, sepa que los artículos a vender se produzcan conforme a lo programado y verifique sus instalaciones antes que el cliente entre por la puerta. El ejecutivo de negocios exitoso es, en primer lugar, un pronosticador: la compra, la producción, el marketing, la fijación de precios y la organización vienen todos después.”

En cuanto se determina un pronóstico inmediatamente se lo evalúa y como resultado se obtiene un error, el cual es comparado entre todos los modelos de pronóstico. Finalmente se utiliza el pronóstico que logre el mínimo error. El error en este caso representa el nivel de inventario en excedente o por el contrario insuficiente para satisfacer la demanda, lo que a su vez en el ámbito económico representa gasto por ventas no realizadas o gasto por obsolescencia.

En síntesis, mientras el pronóstico sea menos acertado provocaría mayores pérdidas económicas para la empresa. Es por eso el interés de encontrar un pronóstico el cual sea lo bastante confiable para que las pérdidas sean lo mínimas posible, siempre anticipando a los cambios que pueda ocurrir en el entorno que lo rodea. Elaborar un presupuesto bien estructurado es el enfoque vital de la planeación estratégica, para que la empresa pueda tomar el rumbo correcto.

Existen modelos tradicionales, determinísticos, probabilísticos e híbridos tales como: promedio móvil simple, promedio móvil ponderado, suavización exponencial, análisis de regresión, técnica Box Jenkins (ARIMA), proyecciones de tendencia, etc., que han sido utilizados para generar pronósticos, presentando ciertas ventajas y desventajas de unos sobre otros. Sin embargo, estos aún son incapaces de ofrecer buenos resultados en un entorno de alta incertidumbre y cambios constantes, como los de la actualidad. Para ello, se buscan nuevos paradigmas basados en modelamientos de sistemas no lineales, tales como las redes neuronales artificiales (RNA) y regresión de soporte vectorial (SVR).

Sapankevych y Sankar [24] mencionan:

“Tradicionalmente las máquinas de soporte vectorial (SVM), así como otros algoritmos de aprendizaje tales como RNA, se utilizan como aplicación para el ordenamiento en el reconocimiento de patrones. Estos algoritmos de aprendizaje también han sido aplicados al análisis de regresión general: el ajuste de una función ajustando la curva a un conjunto de puntos de datos. La aplicación de SVM al caso de análisis de regresión general se llama regresión de soporte vectorial (SVR) y es transcendental para muchas aplicaciones en las predicciones de series de tiempo, o lo que es lo mismo, los pronósticos”

Las RNA son un sistema de neuronas artificiales las cuales se encuentran interconectadas de forma aproximadamente análoga como sucede en un cerebro biológico (figura 1). Cada neurona se encuentra conectada con muchas otras sinápticamente lo que hace posible que el sistema completo adquiera una experiencia a partir de datos históricos con los cuales se entrene previamente a la RNA.




Figura 1. RNA de propagación hacia adelante

Fuente: Villada et al. [27]

De manera análoga la implementación de una RNA para el análisis de cualquier situación sería ineficiente sin el uso de las tecnologías adecuadas como mencionan Hanke y Wichern en [15]: “Los problemas generan una enorme cantidad de registros y la necesidad molesta de extraer información útil. Actuales herramientas de pronósticos,

junto con las capacidades de la tecnología, se han vuelto imprescindibles para las empresas que operan el mundo moderno.”

García [10], realiza un análisis de pronóstico del precio externo del café mediante el uso de RNA las cuales según menciona él, son un método más aproximado a un comportamiento no lineal:

“Existen problemas que no se han podido solucionar en este momento por medio de modelos matemáticos y que requieren de métodos no tradicionales de cálculo para obtener una respuesta. La gran mayoría de las situaciones económicas tienen un comportamiento no lineal, lo que sugiere utilizar métodos que los trabajen tal como son, o que por medio de una transformación emulen un comportamiento lineal. Las RNA al ser, por definición, no lineales y al comportarse como un sistema dinámico se presentan como una solución a este tipo de problemas.”

El uso de estas RNA sería un gran aporte sobre la predicción en todos los proyectos que incluyen series de tiempo como: estimación y predicción de la moneda, predicción de las condiciones ambientales, toma de decisiones desde el punto financiero y predicción en el crecimiento poblacional [19].

Además, Toro [26], realiza un estudio sobre RNA aplicadas al estudio de pronósticos tomando en consideración los parámetros de estacionalidad, en donde el pronóstico obtenido representa una aproximación más ajustada a otros modelos tradicionales considerados.

Zhang [31] ha reconocido la relevancia de los pronósticos en el momento de la toma de decisiones. Considerar el pronóstico sin tener en cuenta el error del mismo puede provocar impactos no deseados en todas las áreas de la empresa, desde los insumos de entrada, atravesando por la producción hasta el mercadeo de los productos.

1.2. *Revisión de la literatura*

1.2.1. *Clasificación de los modelos tradicionales de pronóstico*

Los pronósticos son la mejor forma de realizar una planeación de ventas para el futuro. Según el modelo que se elija, se plantea hacer un incremento sobre los resultados anteriores o mediante el uso de herramientas tecnológicas que posibilitan hacer innumerables cálculos para obtener un pronóstico lo más cercano a la realidad. Según Chase et al., [5] los principales modelos de pronósticos en series de tiempo son:

- Promedio móvil simple
- Promedio móvil ponderado
- Suavización exponencial
- Análisis de regresión
- Técnica Box Jenkins
- Proyecciones de tendencia

En cuanto a la precisión obtenida por cada pronóstico, la principal forma de evaluación es según la comparación del error obtenido. El vocablo error hace mención a la diferencia entre el valor de pronóstico y lo que ocurrió en verdad. En estadística, estos errores llevan el nombre de residuales. Siempre que el valor del pronóstico este dentro del rango de confianza, éste no es realmente un error. Por lo tanto, el uso frecuente se refiere a la divergencia como un error [5].

1.2.2. *Uso de las RNA y regresión de soporte vectorial*

Matich [18], explica que las semejanzas de las RNA con el desempeño de una neurona biológica son muy parecidas. Por ejemplo, tienen la capacidad de aprendizaje, pueden omitir detalles de datos que se obtienen a partir de información irrelevante, aprender de

errores anteriores, etc. Esto hace que brinden varias ventajas y que este tipo de tecnología se esté usando en múltiples campos. Entre las ventajas incluyen:

- Aprendizaje Adaptativo.
- Auto-organización.
- Tolerancia a fallos.
- Operación en tiempo real.

Las RNA han tenido un desarrollo considerable en reducir el error en comparación con modelos tradicionales de pronóstico. La diferencia radica en que este nuevo método de analizar indicadores se basa en el aprendizaje artificial, es decir, este algoritmo adquiere una experiencia a través de los registros históricos que se introducen como valores de entrada.

La demanda de un producto se genera mediante la interacción de varios factores demasiado complejos para describirlos con precisión en un modelo matemático, debido a esto, en este estudio se ha considerado tratar el pronóstico de la demanda.

En la actualidad gracias a diversos grupos de investigación repartidos por universidades de todo el mundo, las RNA han alcanzado una madurez muy aceptable y poseen un sinnúmero de aplicaciones entre las que se puede citar:

- Reconocimiento de patrones, voz y vídeo, compresión de imágenes.
- Estudio y predicción de sucesos muy complejos como la bolsa de valores.
- Aplicaciones de apoyo a la medicina, en todo tipo de aplicaciones que necesiten el análisis de grandes cantidades de datos, etc.

Otro método que logra buenos resultados es una regresión de soporte vectorial (SVR) en términos de mayor precisión, mejora la medida global óptima [14]. Inicialmente las máquinas de soporte vectorial (SVM) se implementaron para reconocimiento de patrones y clasificaciones [8]. En la actualidad, SVM se ha implementado para regresión lineal (SVR). Wu, Yan, y Yang [30] y Du, Leung, Zhang, y Lai [9] utilizaron este sistema para pronosticar ventas de productos de consumo como son automóviles y productos agrícolas perecederos respectivamente.

Consecuentemente, SVR es un método de pronóstico muy preciso, por la poca cantidad de información que necesita. Wen, Mu, Sun, Hua, y Zhou [30] concluyen que el pronóstico de demanda de la uva con este modelo tiene limitaciones como no considerar los productos sustitutos.

El uso de sistemas más desarrollados como RNA y máquinas de soporte vectorial han presentado una gran mejora de los pronósticos conforme se ha desarrollado la tecnología y el manejo de datos más complejos. Una extensa revisión de publicaciones científicas utilizando RNA entorno al pronóstico de precios en el mercado de valores en alrededor del mundo es exhibida por Atsalakis y Valavanis [2], estos estudios concluyen que los métodos de aprendizaje profundo en comparación con modelos convencionales presentan mejores resultados incrementando su precisión considerablemente. Por el contrario, recalcan la dificultad en la concepción estructural del modelo debido a que en la mayoría de casos se elaboran por prueba error. En cambio, Chen, Su, Cheng, y Chiang [6], confrontaron el desempeño resultante en series de tiempo y lógica difusa con una estructura basada en series de tiempo cambiando las entradas a la variación del precio y el signo de la tendencia, de esta manera el índice del mercado de valores de Taiwán resultó más preciso que los modelos tradicionales de pronóstico.

1.2.3. Consideración de indicadores microeconómicos y macroeconómicos

En este estudio se considera otros parámetros los cuales influyen notablemente en la demanda de un producto o servicio. Los indicadores en conjunto pueden proporcionar

un panorama de la situación de un proceso, de un negocio, de la salud de un enfermo o de las ventas de una compañía.

Los indicadores que engloben fácilmente el desempeño total del negocio deben recibir la máxima prioridad. El paquete de indicadores puede ser mayor o menor, dependiendo del tipo de negocio, sus necesidades específicas entre otros.

La importancia de considerar los precios de productos relacionados, ya sean productos complementarios o sustitutos radica en la estrecha relación que consideran los consumidores a la hora de la decisión de compra [3].

Además, la correcta evaluación e interpretación de los indicadores macroeconómicos es fundamental para todo país, pues a partir de ahí se pueden tomar decisiones de política fiscal o monetaria y son señales que da el mercado para que los agentes económicos tomen sus precauciones. Así mismo, los indicadores económicos son una forma de pronosticar y anticiparse a los fenómenos, es por eso que se implementarán en el estudio los principales indicadores económicos de Ecuador. Según Vitez [28], los siguientes son considerados los principales indicadores económicos:

- Producto interno bruto
- Índice de precios al consumidor
- Índice de precios al productor
- Indicadores de empleo
- Ventas al por menor
- Confianza del consumidor

Los indicadores descritos en la tabla 1 son el resultado del análisis de disponibilidad y correlación, que será mostrado en la sección 2.2.3.

En la primera columna, CODIGO, se indican los códigos que fueron utilizados para facilitar la manipulación de los datos y tablas relacionadas. En la columna dos, INDICADOR, se encuentran tanto indicadores microeconómicos como macroeconómicos, su valor fue analizado con las unidades que se encuentra representado entre paréntesis.

Tabla 1. Indicadores internos y externos utilizados

CODIGO	INDICADOR	FUENTE
INDICADORES INTERNOS / MICROECONOMICOS		
I1	Año	Empresa
I2	Mes	Empresa
I3	Precio (USD)	Empresa
CANT	Demanda (Unidades)	Empresa
I4	Precio del producto sustituto (USD)	Empresa
I5	Precio del producto complementario (USD)	Empresa
INDICADORES EXTERNOS / MACROECONOMICOS		
I6	Divisa (US DOLLAR INDEX)	www.tradingeconomics.com
I7	PIB tasa de crecimiento anual (%)	Banco mundial
I8	PIB tasa de crecimiento (%)	Banco central del Ecuador
I9	Tasa de empleo (%)	INEC
I10	Tasa de participación laboral (%)	Banco central del Ecuador
I11	Salario mínimo (USD/MONTH)	Banco central del Ecuador
I12	Tasa de desempleo (%)	Banco central del Ecuador
I13	Salario mínimo en manufactura (USD/MONTH)	Banco central del Ecuador
I14	Índice de precio al consumidor (IPC) (Índex points)	INEC



I15	IPC Transporte (Índex points)	INEC
I16	Inflación de alimentos (%)	INEC
I17	Tasa de inflación (%)	INEC
I18	Tasa de inflación, MoM (%)	INEC
I19	Índice del precio al productor (Índex points)	INEC
I20	Cambio del índice del precio al productor (%)	INEC
I21	Reserva de divisas (USD MILLION)	Banco central del Ecuador
I22	Tasa interbancaria media ponderada (%)	Banco central del Ecuador
I23	Tasa de interés (%)	Banco central del Ecuador
I24	Préstamos al sector privado (USD MILLION)	Banco central del Ecuador
I25	Oferta monetaria M1 (USD MILLION)	Banco central del Ecuador
I26	Balanza comercial (USD Thousand)	Banco central del Ecuador
I27	Flujo de capital (USD MILLION)	Banco central del Ecuador
I28	Producción de crudo (BBL/D/1K) miles de barriles por día	Organización de países exportadores de petróleo
I29	Cuenta corriente (USD MILLION)	Banco central del Ecuador
I30	Exportaciones (USD Thousand)	Banco central del Ecuador
I31	Inversión extranjera directa, corrientes netas (USD MILLION)	Banco central del Ecuador
I32	Importaciones (USD Thousand)	Banco central del Ecuador
I33	Remesas (USD MILLION)	Banco central del Ecuador
I34	Gasto fiscal (USD MILLION)	Banco central del Ecuador
I35	Valor del presupuesto público (USD MILLION)	Banco central del Ecuador
I36	Ingresos públicos (USD MILLION)	Banco central del Ecuador
I37	Gasto público (USD THO)	Banco central del Ecuador
I38	Confianza empresarial (Índex points)	Banco central del Ecuador
I39	Variaciones de existencias (USD THO)	Banco central del Ecuador
I40	Índice de corrupción (Points)	Transparency International
I41	Rango en corrupción	Transparency International
I42	Facilidad de hacer negocios en Ecuador	Banco Mundial
I43	Índice económico adelantado (5)	INEC
I44	Producción de acero (Thousand Tonnes)	World Steel Association
I45	Confianza del consumidor (Índex points)	Banco central del Ecuador
I46	Crédito al consumo (USD MILLION)	Banco central del Ecuador
I47	Gasto del consumidor (USD THO)	Banco central del Ecuador
I48	Crédito al sector privado (USD MILLION)	Banco central del Ecuador
I49	IVA - Impuesto al valor agregado (%)	SRI

La tabla 1 presenta información obtenida principalmente de dos fuentes. Para los indicadores internos provienen de una fuente primaria (la empresa); y los indicadores externos provienen de una fuente secundaria (Instituciones de gubernamentales detalladas en la columna FUENTE).

1.2.4. Sistema de valoración

Para hacer posible la comparación de los diferentes métodos y su efectividad es necesario llevarlos a una sola escala. El error descrito en la ecuación (1), resume la precisión de cada modelo de pronóstico:

$$MAPE = \frac{\sum_{i=1}^N |x_i - \hat{x}_i|}{N \cdot |x_i|} \quad \text{Ecuación (1)}$$

Donde:



MAPE = error porcentual absoluto medio
N = número de periodos a ser evaluados
 x_i = demanda real en el periodo i
 \hat{x}_i = pronóstico en el periodo i

1.2.5. Algoritmo de Garson para determinar el nivel de importancia

El algoritmo de Garson fue desarrollado para determinar el grado o nivel de importancia que tiene un indicador de entrada en una RNA. En muchos casos relacionados con la medida de las variables se considera dos aspectos: los pesos en la capa oculta y sus interacciones en la red de salida. Una medida propuesta por Garson [11], consiste en dividir los pesos de la capa oculta en componentes asociados con cada nodo de entrada para después atribuir a cada uno de ellos un porcentaje del total de pesos.

Varios estudios revelan la efectividad del algoritmo de Garson para evaluar la importancia de una entrada en la RNA [1], [12], [13]. De manera experimental determinaron la certeza del algoritmo de Garson concluyendo que la medida se aplica exitosamente bajo una amplia variedad de condiciones. Como resultado de este análisis el algoritmo de Garson determina en una escala de 0 a 1 un valor único para cada variable explicativa que describe la relación con la variable de respuesta en el modelo.

Por lo tanto, este estudio plantea, por un lado, implementar una RNA, y por otro, el algoritmo SVR para realizar pronósticos de ventas en productos de alta rotación en un supermercado. La expectativa es que estos enfoques disminuyan notablemente el error que generan los pronósticos tradicionales. Existe un volumen importante de experiencias reportadas que señalan la efectividad de los modelos de RNA para el pronóstico de series de tiempo, entre los que se incluyen: pronóstico del precio de la electricidad [7], series de producción industrial europeo [16] y pronóstico de modelos econométricos [25].

2. Materiales, fuentes y métodos.

La propuesta que se plantea en el presente trabajo es establecer un sistema de RNA que permita la aceptación de varios indicadores los cuales pueden determinar el pronóstico de ventas en una empresa.

En este caso la empresa a considerar se trata de un supermercado que, en promedio sus ventas anuales ascienden a 3 millones de dólares aproximadamente, y tiene a su disposición productos de consumo frecuente como: frutas y vegetales, enlatados, artículos de primera necesidad, artículos de aseo personal, artículos de limpieza, artículos de bodega, licores, juguetes, piñatería, etc.

La población considerada son todos los productos vendidos en la empresa, para obtener la muestra a considerar en el estudio se obtienen los diez productos de mayor cantidad y mayor valor vendidos (f1-score), detallados en la sección 3.2. Se usa la RNA perceptron multicapa (rprop+) la cual admite el ingreso de diferentes indicadores de entrada, en este caso los indicadores mencionados en la tabla 1, además de los productos a ser analizados, se necesita información sobre productos sustitutos y complementarios analizados en la sección 2.2.2. Cabe recalcar que el detalle específico de cada producto no puede ser revelado por un acuerdo de confidencialidad estipulado con la empresa. La SVR necesita solamente información histórica de la demanda para establecer un pronóstico.

Se usó dos paquetes informáticos: RStudio (versión 3.4.4) y Python (versión 3.6.3), los cuales son utilizados para realizar el pronóstico usando los algoritmos de aprendizaje automático (machine learning) RNA y SVR.



La metodología a seguir demostrará en sus resultados la medida de error porcentual absoluto medio, con la cual se podrá demostrar si aplicar este tipo de análisis puede poseer validez.

2.1. *Recopilación de datos*

Este estudio lleva a cabo una investigación descriptiva y un diseño no experimental, ya que sólo se observaron las variables sin manipularlas.

Para la selección de la población de estudio se ha considerado que los pronósticos a ser analizados dependen de la fluctuación o estabilidad de sus ventas. En un supermercado se puede encontrar diversidad de productos los cuales son seleccionados de acuerdo al nivel de ventas que presentan. Los ítems que se han escogido para el estudio son los productos que se han vendido durante los últimos 3 años en el supermercado.

2.2. *Procedimiento modelo*

2.2.1. *Recolección de datos y filtración*

Se considera todos los productos que el supermercado ha facturado desde octubre de 2015 hasta diciembre de 2017. Para la fase de entrenamiento la RNA necesita una cantidad significativa de datos por lo cual, en este caso, no se puede esperar resultados con una proyección mayor a 6 meses.

Es de suma importancia considerar tanto la cantidad como las ventas históricas. La cantidad representa un rango más amplio para elaborar un pronóstico de mayor asertividad como efecto de la sensibilidad sobre los demás factores a considerar y las ventas representan mayor rentabilidad para la empresa.

En este estudio se considera un ordenamiento de acuerdo a la media armónica f1-score, que, se define como el recíproco de la media aritmética de los recíprocos. Este valor se emplea para promediar variaciones con respecto al tiempo, también es usado en su mayoría para encontrar la media de valores de eficiencia y error. En este estudio permite obtener un factor, considerando importante tanto las ventas, como la cantidad, la ecuación (2) muestra la estructura del factor:

$$f1 = 2 * \frac{Q * V}{Q + V} \quad \text{Ecuación (2)}$$

Donde:

$f1$ = media armónica f1-score

Q = cantidad vendida en unidades

V = ventas en dólares

El ordenamiento de todos los productos de acuerdo a este factor efectivamente considera dos características o más, dándoles la misma importancia. Los 10 productos más importantes según f1-score se consideran para este estudio.

2.2.2. *Análisis para selección de productos sustitutos y complementarios*

Teniendo la muestra de productos a ser considerados se analiza la interactividad que tiene con otros productos para poder seleccionar los sustitutos y complementarios de cada producto. Una forma cuantitativa de seleccionar productos sustitutos y complementarios es mediante la elasticidad cruzada de la demanda, que analiza dos productos y según su signo establece si es sustituto (+) o complementario (-). Luego, el valor máximo o mínimo resultante representa mayor interacción entre los dos productos,

es decir, se escoge el valor máximo positivo para sustituto y el valor máximo negativo para complementario. La elasticidad cruzada se define como la variación proporcional en la cantidad demandada de un bien o servicio provocada por una variación proporcional del precio de otros bienes [21].

$$E_c = \frac{\Delta\%Q_x}{\Delta\%P_y} = \frac{\frac{\Delta Q_x}{Q_x}}{\frac{\Delta P_y}{P_y}} = \frac{\Delta Q_x}{\Delta P_y} * \frac{P_y}{Q_x} \quad \text{Ecuación (3)}$$

Donde:

E_c = elasticidad cruzada

$\Delta\%Q_x$ = Variación porcentual de la cantidad del bien “x”

$\Delta\%P_y$ = Variación porcentual del precio del bien “y”

Cabe aclarar que, existen otros métodos para la clasificación entre sustitutos y complementarios, como por ejemplo encuestas y grupos focales. En este estudio se utilizó el método de la elasticidad cruzada de la demanda por la agilidad que presenta.

2.2.3. Preparación de indicadores macroeconómicos

Con el fin de mejorar el desempeño de la RNA es necesario realizar un preprocesamiento de los datos de las variables de entrada. Los procesos que se realizaron antes de la fase de entrenamiento son los siguientes:

1) *Correlación (coeficiente de correlación de Pearson)*: Según [22], sí dos variables están altamente correlacionadas, deberíamos eliminar una de ellas. Las variables correlacionadas obstaculizan el desempeño eficiente de los algoritmos de predicción como las RNA y SVR. Se consideraron como variables altamente correlacionadas a aquellas que presentaron un valor del coeficiente de Pearson superior a 0.95.

2) *Normalización (Max – Min)*: Un proceso para mejorar el resultado y evitar la confusión entre indicadores es llevarlos a todos a la misma escala. La normalización se realizó con una filtración max – min el cual lleva todos los valores dentro de un indicador a una escala entre 0 y 1 [20].

3) *Desfase*: La disponibilidad de datos macroeconómicos se convierte en un tema delicado ya que no se puede obtener un dato actualizado al momento de realizar el pronóstico. Los organismos gubernamentales se tardan un tiempo considerable hasta publicar un valor oficial. El tiempo varía desde 1 mes hasta 1 año por lo que los valores más lejanos de 1 año se evitarán considerando indicadores que se actualizan cada mes, trimestre, semestre. Por lo tanto, todos los indicadores que servirán de entrada a la RNA tendrán un retraso de 6 meses.

2.2.4. Consideraciones de cada modelo de pronóstico a comparar

En la tabla 2 se resumen las consideraciones que se plantean para todos los modelos de pronósticos a ser comparados. Se debe aclarar que, el algoritmo en R para determinar el pronóstico a través del modelo ARIMA automáticamente selecciona la mejor configuración de la componente autorregresiva, la componente integrada y la componente para la media móvil (p, d y q respectivamente). Mientras que, el algoritmo en Python para determinar el pronóstico SVR, por defecto, está configurado con las consideraciones resumidas en la tabla 2. Además, el algoritmo en R para determinar el pronóstico usando RNA tuvo que modificarse para que algunas características de entrada pudieran adaptarse y obtener mejores resultados. Las neuronas en la capa oculta

varían de acuerdo a cada producto al igual que el número de repeticiones, tales características se describirán mejor en la sección de resultados.

Tabla 2. Clasificación de consideraciones para cada pronóstico

METODO DE PRONÓSTICO	CONSIDERACIONES
Promedio móvil simple	Periodos considerados: 3
Promedio móvil ponderado	Periodos considerados: 2
Suavización exponencial simple	Alfa = 0.2
Regresión - tendencia	Lineal
Variación estacional o cíclica	Años promedio: 2015, 2016 Año de referencia: 2017
Box Jenkins (ARIMA)	(1,0,0) p=1, d=0, q=0
Regresión de soporte vectorial (SVR)	kernel = RBF C=1x10 ³ gamma = 0.1
Red neuronal artificial (RNA)	1 capa oculta # neuronas variables # repeticiones = 600 learningrate = 0.005 algorithm = "rprop+" (se refieren a la retropropagación elástica con retroceso de peso)

3. Resultados.

3.1. Indicadores macroeconómicos considerados

De un total de 78 indicadores macroeconómicos (ver tabla 1) se eliminaron 29 debido a que no dispone de ellos en periodos iguales o menores a 6 meses (estos indicadores se actualizan anualmente). Luego, al aplicar el análisis de correlación descrito en el punto 2.2.3 se descartaron 4 indicadores que estaban altamente correlacionados con otros indicadores. La tabla 3 presenta los indicadores que se descartaron y los que se mantuvieron para la siguiente fase. Finalmente, se conservaron 44 indicadores para trabajar en la siguiente fase.

Tabla 3. Indicadores eliminados por correlación

INDICADORES ELIMINADOS POR CORRELACION	CODIGO	INDICADOR RELACIONADO
Formación bruta de capital fijo (USD THO)	I17	Tasa de inflación (%)
Salarios promedio nominales mensuales (USD/MONTH)	I11	Salario mínimo (USD/MONTH)
IPC vivienda y servicios públicos (Índex points)	I14	Índice de precio al consumidor (IPC) (Índex points)
Liquidez total M2 (USD MILLION)	I25	Oferta monetaria M1 (USD MILLION)



Reserva de Oro (Tonnes)

(No existe variación según el histórico registrado)

3.2. 10 productos principales considerados

Para seleccionar los productos sobre los que se realizarán los pronósticos, usamos el criterio del f1-score. El ordenamiento por este factor consideró tanto la cantidad como el valor de las ventas para la selección de los productos más importantes. La tabla 4 presenta los valores del factor f1-score para cada producto seleccionado.

Tabla 4. Priorización y selección de productos

CODIGO	CANT	VENTAS	F1-SCORE
P1	87318	202056.026	121939.957
P2	57785	74968.1623	65264.5132
P3	64679	61119.2437	62848.756
P4	66609	40592.3929	50443.7233
P5	52489	42490.3608	46963.3935
P6	49960	34320.7961	40689.3872
P7	46920	26130.5429	33567.0352
P8	36773	27891.6058	31722.393
P9	25126	41170.5907	31206.8012
P10	27232	30794.6962	28903.9777

En la tabla 5 se presenta la descripción general de los productos sobre los que se realizará el pronóstico usando una RNA y SVR.

Tabla 5. Productos a ser analizados

CODIGO	LINEA	CATEGORIA
P1	Aves	Pollo
P2	Abarrotes	Azúcar
P3	Aves	Huevos
P4	Abarrotes	Fideos y pastas
P5	Licores	Cerveza
P6	Lácteos	Leche
P7	Abarrotes	Sal
P8	Limpieza	Prod. Lavado
P9	Abarrotes	Atún
P10	Abarrotes	Aceite

3.3. Comparación de resultados obtenidos en la aplicación de pronósticos en un supermercado

Indiscutiblemente la cantidad de neuronas que un modelo de RNA tiene en su capa oculta varía, por lo que empíricamente estos valores se determinaron para cada producto. Además, el número de repeticiones en donde se genera el valor mínimo de error se especifica como modelo final en la Tabla 6 el cual podría ser aplicado para el

siguiente periodo del 2018 sujeto a modificaciones dado que el modelo actual podría mejorar al cambiar el rango de datos para la fase de entrenamiento.

En la Tabla 7 se observa los resultados obtenidos incluyendo el error porcentual absoluto medio (MAPE), descrito en la ecuación (1), resultados obtenidos a partir de 600 repeticiones de entrenamiento en RNA. La metodología utilizada exige que una parte de datos sea para entrenamiento y otra para prueba, por lo que se escogió una proporción 80/20 sobre los datos totales, puesto que se contaba con información desde el último trimestre del año 2015 hasta el último trimestre del año 2017, se escogió el último semestre del año 2017 para utilizarlo como parte de prueba y poder comprobar el modelo.

Teniendo en consideración los análisis realizados se puede fundamentar los resultados obtenidos, observando que el mejor valor promedio de MAPE observado en la Tabla 7, es de la RNA con 10,24%. Este valor resulta significativamente diferente a otros modelos tradicionales de pronóstico, resultado que permite sintetizar que puede existir un nivel de ajuste en el caso del entrenamiento conforme pase el tiempo y aumente la información para ajustar el modelo ya entrenado, hipótesis probable si se analiza además el hecho de no contar con una cantidad óptima de ejemplos de entrenamiento para alcanzar niveles de errores más bajos. Como se puede observar en la Tabla 7 las RNA en comparación con otros modelos más tradicionales de pronóstico presentan un error considerablemente más pequeño.

Cabe recalcar que el producto P8 no posee todos los indicadores considerados en los demás productos, el precio del producto complementario no pudo ser configurado ya que este valor no varió según el histórico registrado, consecuentemente una RNA no puede considerar este factor porque no encuentra una relación de variable para poder establecer un patrón, el resto de indicadores varía de periodo a periodo.

Tabla 6. Parámetros considerados en la RNA

PRODUCTO	P1	P2	P3	P4	P5	P6	P7	P8 - (sin I5)	P9	P10
Neuronas	29	30	29	28	29	28	28	32	30	31
# Rep. Óptimas (/600)	294	369	115	285	192	568	285	113	54	506

Tabla 7. Comparación de resultados generales

Producto	P1	P2	P3	P4	P5	P6	P7	P8 (sin I5)	P9	P10	PROMEDIO MAPE
Promedio móvil simple(3)	8.74%	9.73%	7.30%	8.10%	42.43%	7.57%	6.96%	9.79%	4.13%	12.20%	11.70%
Promedio móvil ponderado	10.10%	9.77%	9.22%	9.69%	34.55%	9.51%	7.08%	8.71%	6.24%	16.58%	12.15%
Suavización exponencial simple	7.84%	9.21%	6.36%	8.48%	50.06%	7.38%	5.67%	9.03%	9.28%	12.01%	12.53%
Regresión lineal	10.98%	25.26%	12.78%	12.52%	33.83%	10.94%	9.79%	28.95%	9.53%	20.04%	17.46%
Variación estacional o cíclica	23.49%	32.74%	27.48%	26.39%	38.33%	29.39%	31.64%	68.06%	64.44%	73.45%	41.54%
Box Jenkins - ARIMA (1,0,0)	8.52%	9.57%	7.95%	8.23%	52.57%	6.58%	7.79%	12.01%	6.45%	10.87%	13.05%
RNA	7.01%	13.62%	10.83%	8.08%	21.37%	7.31%	6.20%	10.53%	7.87%	9.57%	10.24%
(SVR) Regresión de soporte vectorial	11.41%	16.37%	5.96%	11.26%	26.11%	13.44%	8.25%	6.52%	10.81%	18.15%	12.83%

3.4. Importancia de indicadores macroeconómicos

La tabla 8 presenta el nivel de importancia que se obtuvo en la RNA con el algoritmo de Garson, el coeficiente mostrado en la última columna presenta el grado de importancia que genera cada indicador, cabe recalcar que para cada producto se obtiene un coeficiente diferente en un mismo indicador por lo cual, se muestra un coeficiente de Garson promedio entre los 10 productos.

Tabla 8. Resumen de indicadores más importantes

CODIGO	DESCRIPCION INDICADOR	COEF. GARSON
INTERNOS - MICROECONOMICOS		
I5	Precio del producto complementario	0.013257374
I2	Mes	0.016043408
I4	Precio del producto sustituto	0.016370018
I3	Precio	0.021072393
I1	Año	0.021388844
EXTERNOS - MACROECONOMICOS		
I20	Cambio del índice del precio al productor (%)	0.023568662
I39	Variaciones de existencias (USD THO)	0.023690179
I37	Gasto público (USD THO)	0.023876179
I49	IVA - Impuesto al valor agregado (%)	0.024390901
I38	Confianza empresarial (Índex points)	0.024481111
I42	Facilidad de hacer negocios en Ecuador	0.025104695
I18	Tasa de inflación, MoM (%)	0.025132292
I26	Balanza comercial (USD THO)	0.025274287
I41	Rango en corrupción	0.025759514
I31	Inversión extranjera directa, corrientes netas (USD MILLION)	0.026626361

4. Discusión.

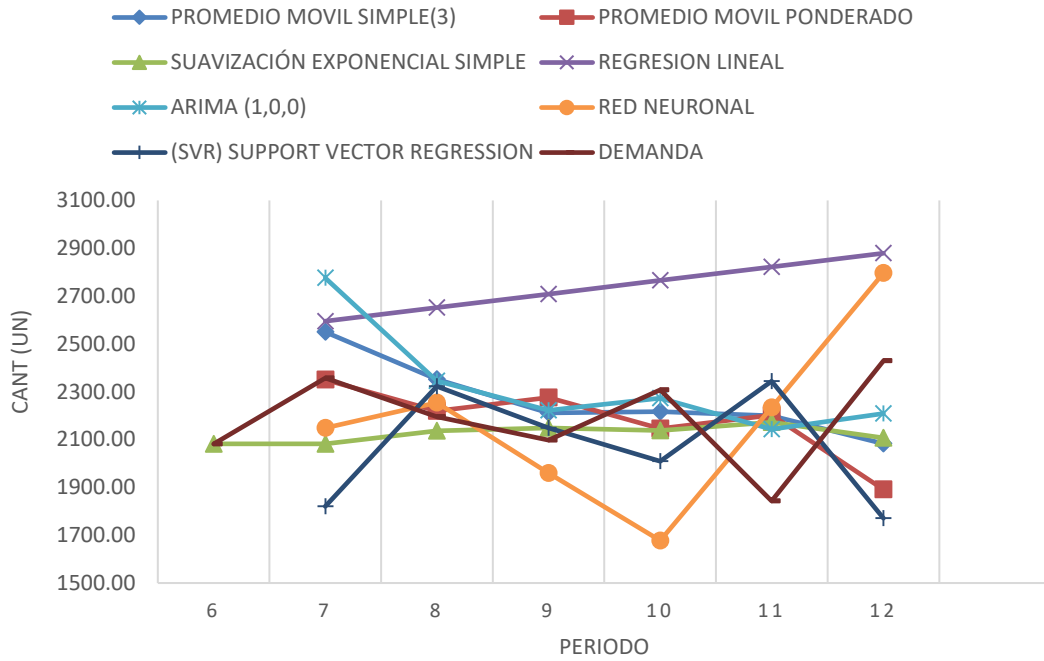
4.1. Comparación de pronósticos más ajustados

Se seleccionó el producto 2 (Gráfica 1) y producto 5 (Gráfica 2) para ejemplificar de mejor manera los resultados obtenidos. El producto 2, porque muestra claramente una variación baja periodo a periodo y el producto 5 por el contrario, refleja una alta variación.

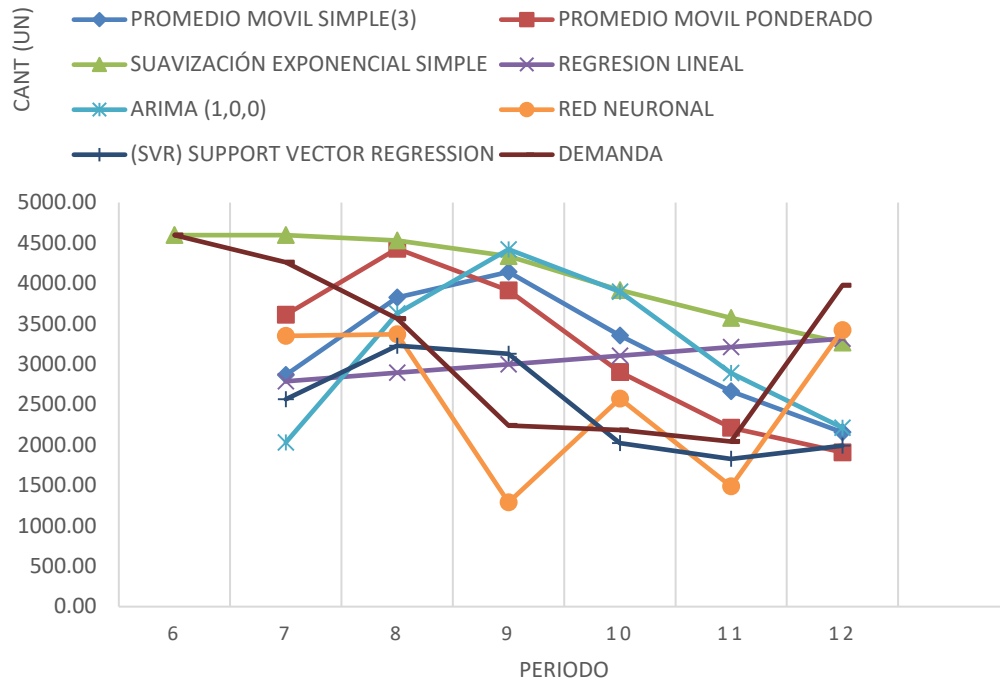
En la gráfica 1 y gráfica 2 se encuentra la comparación obtenida entre todos los pronósticos considerados, pero posteriormente este resultado varió en las dos gráficas, es decir, en la Gráfica 1 a juzgar por el ajuste de regresión lineal, claramente vemos que se trata de una tendencia creciente con poca variabilidad de periodo a periodo, por el contrario, en la Gráfica 2 se puede ver la misma tendencia creciente pero con una variabilidad de periodo a periodo mucho más marcada, según los resultados en la tabla 7 los dos productos obtuvieron diferentes valores de error en RNA, en cuanto al producto



2 la RNA no fue lo suficientemente precisa y otros modelos de pronóstico se ajustaron mejor, mientras que en el producto 5 la RNA fue muy precisa y más ajustada que otros modelos de pronóstico.



Gráfica 1. Comparación de pronósticos del producto 2



Gráfica 2. Comparación de pronósticos del producto 5

Por el contrario el panorama cambia radicalmente con el producto 8 (P8) según los resultados obtenidos, los indicadores macroeconómicos más importantes para este producto, son: la tasa interbancaria media ponderada (I22), la tasa de empleo (I9) y el cambio del índice del precio al productor (I20), de igual manera los indicadores internos más importantes son: el año (I1), el mes (I2), y el precio del producto sustituto (I4), la tabla 8 muestra otros resultados que no concuerdan con los niveles de importancia mencionados, esto sucede por efecto de haber eliminado el precio del producto complementario en el producto 8, afectando severamente los resultados en comparación con los otros productos.

Según el promedio global del MAPE que se muestra en la tabla 7, la RNA logra resultados más precisos que otros modelos tradicionales.

5. Conclusiones.

Indiscutiblemente una RNA artificial es un avance radical en la forma de anticipar comportamientos y valores de acuerdo a factores relacionados con el objetivo, es decir, un entorno fácilmente cuantificable está a la disposición para identificar una tendencia o comportamiento futuro. A partir de los inicios las RNA han estado desarrollándose en cada campo posible, ignorar este gran avance tecnológico sería mala decisión para cualquier organización, no solo por no permanecer a la vanguardia y actualización de conocimientos, sino por perder gran parte del mercado debido a la competitividad de empresas más innovadoras.

En la sección anterior se presentó datos concluyentes del comportamiento de ciertos productos, dos grupos se presentan claramente. El primero cuando no existe gran variabilidad y el segundo cuando efectivamente si la hay, con un estudio de RNA el ajuste es más preciso en el segundo grupo ya que modelos tradicionales no logran ajustarse a alta variabilidad.



Algunos productos de los cuales no se obtiene toda la información necesaria para ajustar el modelo, van a cambiar severamente su resultado. Al no tener el mismo tipo de información, este pronóstico adquiere resultados diferentes en comparación con los otros productos que si tienen la información completa. No solamente cambia la cantidad de entradas en la red, resulta también en el aumento de neuronas en la capa oculta y la variación en el error resultante.

El análisis presentado en este estudio resalta la eficacia de utilizar RNA para el pronóstico de series temporales considerando tanto factores externos como internos a la organización. Se pudo comprobar la eficacia del modelo obteniendo mejores resultados a comparación de los modelos tradicionales. Además, hay que tomar en cuenta el uso de sistemas más desarrollados para prever la demanda de un producto que, cada vez aumenta y para las organizaciones es importante mantenerse siempre a la vanguardia de la tecnología y sobretodo de modelos de pronostico cada vez más precisos.

Todos los indicadores considerados como entradas del modelo no presentan el mismo nivel de importancia por lo que, el nivel de importancia es posible determinar según el algoritmo de Garson implementado en el algoritmo de la RNA, para establecer una relación más estrecha entre estos indicadores y el objetivo, en este caso la demanda de un producto. Consecuentemente el modelo se vuelve más sensible a la variación los indicadores que presentan un mayor coeficiente de Garson.

Aunque verídicamente no se puede obtener indicadores macroeconómicos actualizados, ni mucho menos prever el valor de alguno de ellos en el futuro, es posible utilizar valores desfasados, para obtener excelentes resultados mucho más precisos que los modelos tradicionales.

6. Agradecimiento.

El autor expresa su agradecimiento a la empresa involucrada por su colaboración de la información solicitada, a la carrera de Ingeniería Industrial de la Universidad de Cuenca por su gestión, apoyo en conocimientos y asignación tutorial, al docente e investigador Ing. Mario Peña por su colaboración y apoyo en el proyecto y a mi familia por su apoyo incondicional.

7. Bibliografía.

- [1] C. F. Aquino, L. C. C. Salomão, y A. M. Azevedo, “High-efficiency phenotyping for vitamin A in banana using artificial neural networks and colorimetric data”, *Bragantia*, vol. 75, núm. 3, pp. 268–274, jun. 2016.
- [2] G. S. Atsalakis y K. P. Valavanis, “Surveying stock market forecasting techniques – Part II: Soft computing methods”, *Expert Systems with Applications*, vol. 36, núm. 3, Part 2, pp. 5932–5941, abr. 2009.
- [3] S. Ayala, “La Economía como Ciencia, Objeto y Categorías Fundamentales”, 2015.
- [4] P. L. Bernstein, *Against the Gods: The Remarkable Story of Risk*. John Wiley & Sons, 1996.
- [5] R. B. Chase et al., *Administración de operaciones: producción y cadena de suministros*. México; Bogota: McGraw-Hill/Interamericana Editores, 2009.
- [6] T.-L. Chen, C.-H. Su, C.-H. Cheng, y H.-H. Chiang, “A novel price-pattern detection method based on time series to forecast stock market”, *African Journal of Business Management*, vol. 5, núm. 13, p. 5188, 2011.



- [7] A. J. Conejo, J. Contreras, R. Espinola, y M. A. Plazas, "Forecasting electricity prices for a day-ahead pool-based electric energy market", *International Journal of Forecasting*, vol. 21, núm. 3, pp. 435–462, 2005.
- [8] C. Cortes y V. Vapnik, "Support-vector networks", *Machine learning*, vol. 20, núm. 3, pp. 273–297, 1995.
- [9] X. F. Du, S. C. H. Leung, J. L. Zhang, y K. K. Lai, "Demand forecasting of perishable farm products using support vector machine", *International Journal of Systems Science*, vol. 44, núm. 3, pp. 556–567, oct. 2011.
- [10] M. I. Garcia, "Análisis Y Predicción De La Serie De Tiempo Del Precio Externo Del Café Colombiano Utilizando Redes Neuronales Artificiales", *Universitas Scientiarum*, vol. 8, pp. 45–50, 2003.
- [11] G.D. Garson, "Interpreting neural network connection weights," *AI Expert*, pp. 47–51, 1991.
- [12] T. D. Gedeon, "Data mining of inputs: analysing magnitude and functional measures", *Int J Neural Syst*, vol. 8, núm. 2, pp. 209–218, abr. 1997.
- [13] L. W. Glorfeld, "A Methodology for simplification and interpretation of backpropagation-based neural network models", *Expert Systems with Applications*, vol. 10, núm. 1, pp. 37–54, ene. 1996.
- [14] S. R. Gunn, "Support vector machines for classification and regression", *ISIS technical report*, vol. 14, núm. 1, pp. 5–16, 1998.
- [15] J. E. Hanke y D. W. Wichern, *Pronósticos en los negocios*. Pearson Educación, 2006.
- [16] S. Heravi, D. R. Osborn, y C. R. Birchenhall, "Linear versus neural network forecasts for European industrial production series", *International Journal of Forecasting*, vol. 20, núm. 3, pp. 435–446, jul. 2004.
- [17] J. Izar, C. Ynzunza, y O. Guarneros, "Variabilidad de la demanda del tiempo de entrega, existencias de seguridad y costo del inventario", *Contaduría y Administración*, vol. 61, núm. 3, pp. 499–513, jul. 2016.
- [18] D. J. Matich, "Redes Neuronales: Conceptos básicos y aplicaciones", *Cátedra de Informática Aplicada a la Ingeniería de Procesos–Orientación I*, 2001.
- [19] D. Mercado, L. Pedraza, y E. Martínez, "Comparación de Redes Neuronales aplicadas a la predicción de Series de Tiempo", *Prospectiva*, vol. 13, núm. 2, pp. 88–95, jul. 2015.
- [20] S. C. Nayak, B. B. Misra, y H. S. Behera, "Impact of data normalization on stock index forecasting", *Int. J. Comp. Inf. Syst. Ind. Manag. Appl*, vol. 6, pp. 357–369, 2014.
- [21] J. R. Obando, *Elementos de Microeconomía*. EUNED, 2000.
- [22] D. Ruan, *Fuzzy Systems and Soft Computing in Nuclear Engineering*. Physica, 2013.
- [23] J. C. Sanclemente, "Las ventas y el mercadeo, actividades indisociables y de gran impacto social y económico.: El aporte de Tosdal", *Innovar*, vol. 17, núm. 30, pp. 160–162, jul. 2007.
- [24] N. Sapankevych y R. Sankar, "Time Series Prediction Using Support Vector Machines: A Survey", *IIEEE Computational Intelligence Magazine*, vol. 4, núm. 2, pp. 24–38, may 2009.
- [25] N. Swanson y H. White, "Forecasting economic time series using flexible versus fixed specification and linear versus nonlinear econometric models", *International Journal of Forecasting*, vol. 13, núm. 4, pp. 439–461, 1997.
- [26] E. M. Toro, D. A. Mejia, y H. Salazar, "Pronóstico de ventas usando redes neuronales", *Scientia et technica*, vol. 10, núm. 26, 2004.
- [27] F. Villada, N. Muñoz, y E. García, "Aplicación de las Redes Neuronales al Pronóstico de Precios en el Mercado de Valores", *Información tecnológica*, vol. 23, núm. 4, pp. 11–20, ene. 2012.
- [28] O. Vitez, "Cuáles se consideran los principales indicadores económicos", 2017. [En línea]. Disponible en: <https://pyme.lavoztx.com/cules-se-consideran-los-principales-indicadores-economicos-9641.html>. [Consultado: 07-dic-2017].
- [29] Q. Wen, W. Mu, L. Sun, S. Hua, y Z. Zhou, "Daily Sales Forecasting for Grapes by Support Vector Machine", en *International Conference on Computer and Computing Technologies in Agriculture*, 2013, pp. 351–360.
- [30] Q. Wu, H. S. Yan, y H. B. Yang, "A Forecasting Model Based Support Vector Machine and Particle Swarm Optimization", en *2008 Workshop on Power Electronics and Intelligent Transportation System*, 2008, pp. 218–222.
- [31] G. P. Zhang, "Time series forecasting using a hybrid ARIMA and neural network model", *Neurocomputing*, vol. 50, núm. Supplement C, pp. 159–175, ene. 2003.