
PRONÓSTICO DE DEMANDA USANDO REDES NEURONALES ARTIFICIALES COMO HERRAMIENTA TECNOLÓGICA EN LOS PROCESOS DE LAS EMPRESAS

DEMAND FORECAST USING ARTIFICIAL NEURAL NETWORKS AS A TECHNOLOGICAL TOOL IN COMPANY PROCESSES

Tania Guadalupe Ramos García¹, Mirella Parada Gonzalez², Ulises Martínez Contreras³, Arturo Woocay Prieto⁴, Laura Elizabeth Silva Leyva⁵

¹Maestra en Ingeniería Industrial. Tecnológico Nacional de México/Instituto Tecnológico de Ciudad Juárez, Departamento de Educación a Distancia. taniaraga9@gmail.com. Teléfono (656) 6882500, Avenida Tecnológico No. 1340 Fraccionamiento El Crucero Código Postal 32500, Ciudad Juárez

²Maestra en Ciencias Ing. Industrial. Tecnológico Nacional de México/Instituto Tecnológico de Ciudad Juárez, División de Posgrado e Investigación. mirella.pg@cdjuarez.tecnm.mx. Teléfono (656) 6882500, Avenida Tecnológico No. 1340 Fraccionamiento El Crucero Código Postal 32500, Ciudad Juárez

³Doctor en Ingeniería Mecánica. Tecnológico Nacional de México/Instituto Tecnológico de Ciudad Juárez, División de Posgrado e Investigación. ulises.mc@cdjuarez.tecnm.mx. Teléfono (656) 6882500, Avenida Tecnológico No. 1340 Fraccionamiento El Crucero Código Postal 32500, Ciudad Juárez

⁴PhD Environmental Science and Engineering. Tecnológico Nacional de México/Instituto Tecnológico de Ciudad Juárez, División de Posgrado e Investigación. arturo.wp@cdjuarez.tecnm.mx. Teléfono (656) 6882500, Avenida Tecnológico No. 1340 Fraccionamiento El Crucero Código Postal 32500, Ciudad Juárez

⁵Maestra en Administración De Negocios Internacionales. Tecnológico Nacional de México/Instituto Tecnológico de Ciudad Juárez, Departamento Industrial-logística. laura.sl@cdjuarez.tecnm.mx. Teléfono (656) 6882500, Avenida Tecnológico No. 1340 Fraccionamiento El Crucero Código Postal 32500, Ciudad Juárez.

Resumen -- Este artículo muestra la aplicación de las redes neuronales artificiales (RNA) en pronósticos de demanda en una empresa concretera. El objetivo fue comparar la exactitud de pronóstico obtenida al utilizar RNA en contraste con la obtenida a través de los modelos tradicionales para pronosticar utilizados actualmente por la empresa y, de esta forma constatar que es posible conseguir una exactitud mayor en los pronósticos de demanda al utilizar RNA. Para el desarrollo se utilizó la metodología de modelos de redes simples perceptrón multicapa y se realizó con el uso de datos extraídos de los programas de la empresa. Al evaluar los pasos anteriores se pudo concluir que la técnica que proporcione mayor exactitud del pronóstico es RNA, los resultados se pueden apreciar en la figura 5.

Palabras clave -- Red Neuronal Artificial (RNA), Inteligencia Artificial (IA), pronóstico, proceso.

Abstract -- This article shows the application of artificial neural networks (ANN) in demand forecasting in a concrete company. The objective was to compare the forecast accuracy obtained by using RNA in contrast to that obtained through traditional forecasting models currently used by the company and, in this way, to verify that it is possible to achieve greater accuracy in demand forecasts when using RNA. For the development, the methodology of simple multilayer perceptron network models was used, and it was carried out with the use of data extracted from the company's programs. When evaluating the previous steps, it was possible to conclude that the technique that provided the greatest accuracy of the forecast is RNA, the results can be seen in figure 5.

Keywords -- Artificial Neural Network (ANN), Artificial Intelligence (AI), forecasting, process.

INTRODUCCIÓN

En la actualidad las empresas buscan constantemente la mejora en todos sus procesos; aprovechando el uso de la tecnología, las mejoras en la productividad se generan de tres formas: reduciendo los tiempos en la ejecución de procesos, eliminando o sustituyendo total o parcialmente tareas dentro de esos procesos, o incorporando nuevas funcionalidades que aportan valor al proceso ya existente [1].

Utilizar las RNA para realizar pronósticos en una empresa, aborda la opción de incorporar nuevas funcionalidades.

Se sabe que las redes neuronales artificiales son aproximadores universales de funciones, y que no requieren un conocimiento a priori sobre el proceso en cuestión. Las RNA también son conocidas por su capacidad para modelar sistemas no lineales. Diversos autores concuerdan en afirmar que las series de datos reales presentan comportamientos complejos, caóticos, no lineales y la aproximación que pueda hacerse con modelos lineales resulta inadecuada [10] [11]. Para modelos no lineales hay estudios que tratan estos inconvenientes de cambios abruptos o estructurales y reconocen las bondades de

las RNA en el modelado de datos atípicos con perturbaciones [12].

Las RNA consultadas en la literatura para esta investigación son las llamadas perceptrón multicapa (MLP), que están compuestas por una o varias capas de entrada, una capa de salida y capas ocultas intermedias.

Antecedentes

La Concretera Chamizal es una mediana empresa con más de 30 años en el mercado; proporciona concreto premezclado a todo tipo de clientes, desde pequeños que amplían su casa, constructoras que desarrollan fraccionamientos, hasta grandes obras de gobierno como calles o puentes.

El concreto premezclado por su propia naturaleza requiere un plan de producción especial, ya que una vez que se produce no puede mantenerse en almacenamiento, por lo que debe ser fabricado con el tiempo exacto al considerar la hora establecida para su uso. Del mismo modo, la materia prima empleada para su fabricación tiene un tiempo de vida útil establecido para asegurar las condiciones de calidad requeridas para el producto final deseado.

En sus inicios la empresa registraba de forma manual los procesos como las programaciones, las ventas y la producción; conforme pasó el tiempo se adquirieron softwares como SAP, que hacen que los procesos tengan un mayor control.

Planteamiento del problema

Actualmente los pronósticos se obtienen al combinar los promedios móviles y la composición de la fuerza de ventas, con lo cual se alcanza una exactitud de pronóstico entre 70% y 80%. La empresa considera que puede mejorar la productividad en las operaciones al aumentar la exactitud de los pronósticos.

Objetivo

En esta investigación se busca utilizar redes neuronales artificiales para superar la exactitud del pronóstico actual de la empresa, estableciendo el objetivo de conseguir mínimo un 85% de exactitud. Además, se pretende introducir esta nueva técnica a la empresa, permitiéndole que dé un paso más hacia la óptima toma de decisiones.

MARCO TEÓRICO

Pronósticos

En los negocios, un pronóstico es una herramienta que proporciona un estimado cuantitativo o un conjunto de estimados acerca de la probabilidad de eventos futuros, los cuales se elaboran en base a la información de interés con relación a su dimensión pasada y actual. [2]

Hay numerosas técnicas utilizadas para pronosticar, tanto en el enfoque cuantitativo como en el enfoque cualitativo. Las más socorridas, dentro del enfoque cualitativo, son: jurado de opinión ejecutiva, encuestas en el mercado de consumo, grupos de consenso, método Delphi y composición de la fuerza de ventas. Los modelos cuantitativos que tradicionalmente se han utilizado, enfoque intuitivo, promedios móviles, suavizamiento exponencial, proyección de tendencias y regresión lineal [13]. La elección del método o métodos dependerá de los costos involucrados, el propósito del pronóstico, la confiabilidad y consistencia de los datos históricos de ventas, el tiempo disponible para hacer el pronóstico, el tipo de producto, las características del mercado, la disponibilidad de la información necesaria y la pericia de los encargados de hacerlo. Lo normal es que las empresas combinen varias técnicas. [4]

Los métodos actualmente utilizados por la empresa es una combinación de composición de la fuerza de ventas y promedios móviles. La fuerza de ventas puede ser una buena fuente de información acerca de las tendencias futuras y los cambios en el comportamiento del comprador, ya que los vendedores tienen contacto directo con los compradores; son el contacto más cercano que la mayoría de las compañías tiene con sus clientes. El método de promedios móviles es un modelo estadístico que emplea sus datos históricos prediciendo bajo el supuesto que el futuro es una función del pasado. [13] Al combinar ambos métodos se complementan y pueden dar un pronóstico con más exactitud.

Redes Neuronales Artificiales

La inteligencia artificial es un intento por descubrir y describir aspectos de la inteligencia humana que pueden ser simulados mediante máquinas. Una red neuronal es “un nuevo sistema para el tratamiento de la información, cuya unidad básica de procesamiento está inspirada en una célula del sistema nervioso humano: la neurona”. Esta disciplina se ha

desarrollado fuertemente en los últimos años teniendo amplias aplicaciones.

Actualmente las RNA son usadas para desarrollar tareas tales como reconocimiento facial, desarrollo de pronósticos, minería de datos, composición de música, creación de imágenes, lectura de labios, etc. Lo más destacable de esta herramienta es que tiene un aprendizaje adaptativo, es decir, la capacidad de aprender a realizar tareas basadas en un entrenamiento o una experiencia inicial; a su vez, es autoorganizada porque puede crear su propia organización o representación de la información que recibe mediante una etapa de aprendizaje, y puede realizar grandes procesos con datos de forma muy rápida [1].

Una red neuronal artificial (Figura 1) es un modelo computacional que se basa en la estructura de la red neuronal del sistema nervioso humano. Las neuronas artificiales están conectadas tanto unas con otras como con las entradas y salidas de la red, al utilizar varios pesos: aceptan una serie de entradas, ajustan los pesos para minimizar la función de rendimiento y finalmente producen la salida [8].

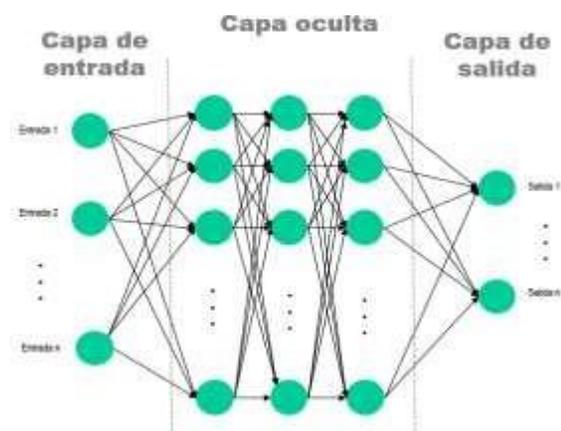


Figura 1. Estructura básica de una RNA.

Cualquier modelo de red neuronal consta de dispositivos elementales de proceso: las neuronas. Generalmente se pueden encontrar tres tipos de neuronas: 1) aquellas que reciben estímulos externos relacionados con el aparato sensorial y que tomarán la información de entrada; 2) aquellas en las que dicha información se transmite a ciertos elementos internos que se ocupan de su proceso, es decir, la sinapsis entre neuronas en donde se genera cualquier tipo de representación interna de la información, y

puesto que no tienen relación directa con la información de entrada ni con la de salida, se denominan "unidades ocultas", y 3) aquellas en las que, una vez que finaliza el periodo del proceso, la información llega a las unidades de salida, cuya misión es dar la respuesta del sistema. [1]

Hay investigaciones que proponen el uso de redes neuronales artificiales como herramienta eficiente para la realización de pronósticos, ya que no presentan un análisis lineal [1] [3]. Dentro de la investigación propuesta [14], se determina que la inteligencia computacional, a través de una red neuronal, resuelve de mejor forma problemas de optimización de cartera en comparación con otros modelos. En [14] [16], se propone el uso de tecnologías de la inteligencia artificial como los sistemas difusos para la predicción de costos y el establecimiento de una planeación agregada, respectivamente. Algunas de las implementaciones de la inteligencia artificial dentro del sector industrial demuestran las ventajas de su uso en comparación con métodos tradicionales, propiciando así una ventaja competitiva en las organizaciones.

En una revisión [15], se analiza la importancia de reducir el nivel de inventario en una organización a través del pronóstico de venta. Los resultados obtenidos muestran que es posible establecer buenos niveles de inventario a través de los pronósticos realizados por una red neuronal de propagación hacia adelante.

Python

Es un lenguaje de programación, multiparadigma y multinivel con soporte en programación orientada a objetos, imperativa y funcional. Con este tipo de lenguaje se pueden crear aplicaciones nativas e híbridas, y también cuenta con una sintaxis accesible para las personas con un nivel de 'alfabetización' básico en lenguajes de programación.

Este es un lenguaje de programación de código abierto, de propósitos generales y es gratuito, por lo que no se tendría que pagar una licencia para utilizarlo. Es interpretado, es decir, que no requiere compilación, lo que implica un tiempo mayor de ejecución frente a otros programas desarrollados con lenguajes de tipo compilado.

Python es una tecnología imprescindible en plataformas de entretenimiento y social media, destinado al aprendizaje automático y a la

construcción de algoritmos de recomendación; por esta razón, aplicaciones como Instagram, Pinterest, Dropbox, Facebook, Spotify y Netflix utilizan este lenguaje en su desarrollo ya que permite programar tareas con el objetivo de procesar grandes cantidades de datos y obtener información de valor. [9]

Asimismo, es posible abordar los siguientes tipos de proyectos con el lenguaje:

- Aplicaciones web.
- Ciencia de datos.
- Aprendizaje automático.
- Análisis y automatización de datos.
- Inteligencia artificial.

DESARROLLO

A continuación, se presenta la metodología que se empleó para el análisis y desarrollo de la investigación.

Metodología

Dentro de la revisión de literatura se encontró una serie de pasos elementales para realizar el entrenamiento de la red y el pronóstico a aplicar; después, se comenzó la creación del procedimiento de acuerdo con las necesidades de este trabajo. En la Figura 2 se visualizan los pasos a seguir y como metodología para obtener los pronósticos de demanda, los cuales se dividieron en 3 fases: datos, RNA y evaluación.

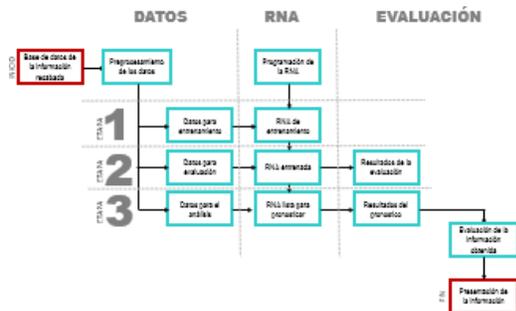


Figura 2. Flujo básico para pronosticar demanda con una RNA.

Fase 1 - Datos

En esta fase de datos se presenta la serie de tareas que se llevaron a cabo para recolectar toda la información.

Base de datos de la información recabada

En la primera etapa del proceso se buscaba que los datos que entrarían a la red neuronal fueran confiables y válidos. La primera parte corresponde a los datos que se utilizan para entrenar la RNA; los segundos sirven para validar los resultados que se obtuvieron en el paso anterior, y, por último, se analizan los datos que se utilizan para los resultados a usar en la operación de la empresa.

Para la recolección de datos se utilizó el software SAP que maneja la empresa; éste es un sistema informático que le permite a las empresas administrar sus recursos, además de que las principales compañías del mundo lo utilizan para gestionar exitosamente todas las fases de sus modelos de negocios.

Preprocesamiento de datos

En esta etapa se realiza la selección de los datos que servirán para realizar el pronóstico y se eliminan de la base de datos aquellos no útiles. Por ejemplo, se quitan tanto las columnas de datos alfanuméricos como las columnas con datos no relevantes tales como códigos de materiales o sus nombres.

Datos para entrenamiento, para evaluación y para el análisis

Los datos de entrada fueron obtenidos de los registros históricos de la empresa, basados en dos criterios:

- A partir de los años 2018 al 2019 para las etapas 1 y 2.
- A partir del año 2020 para la etapa 3.

En la Figura 3 se muestra la representación y comportamiento de los datos de las ventas de concreto en metros cúbicos, obtenidos de la información recolectada.

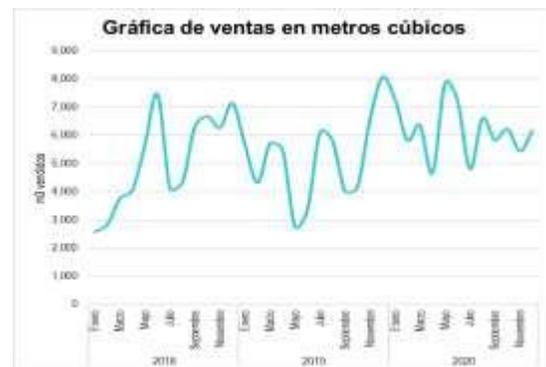


Figura 3. Representación y comportamiento de los datos.

Fase 2 - RNA

En esta fase del proceso se muestran los pasos que se siguieron para realizar la programación y crear el código.

Programación de la RNA

Para realizar la programación de la RNA, primeramente, se creó un algoritmo del que parten los pasos para estructurar el código.

Para esta programación se requirieron las siguientes librerías: pandas, para análisis estadísticos; numpy, para cálculos matemáticos; de sklearn.preprocessing se importó el módulo StandardScaler para normalizar la data; de sklearn.model_selection se importó el módulo train_test_split, para dividir en train y test), y de sklearn.neural_network se importó el módulo MLPClassifier y MLPRegressor para el perceptrón multicapa.

La Figura 4 muestra los pasos del algoritmo que se siguieron para armar la RNA.

ALGORITMO

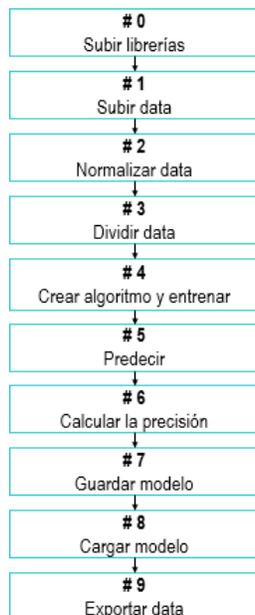


Figura 4. Algoritmo utilizado en Python para el pronóstico.

RNA de entrenamiento

El código de programación que se utilizó en Python

para la RNA es el mismo, solo que en las diferentes etapas el cambio fue en las variables de entrada, las capas ocultas y la cantidad neuronas.

En esta investigación se probaron diferentes combinaciones para la red neuronal artificial, como no hay ninguna forma por el momento de encontrar la cantidad idónea de datos, se trabajó con método de prueba y error hasta obtener la estructura más recomendable para el pronóstico que se buscaba.

RNA de evaluación

En la Tabla 1 se muestran los resultados con las estructuras finales de evaluación RNA para pronóstico de demanda, con el número de Entradas, el de Capas Ocultas y el de Neuronas:

Tabla 1. Estructuras finales de evaluación RNA para pronóstico de demanda.

Entradas	Capas Ocultas	Neuronas
1	5	3
	15	6
2	5	6
	15	9

La selección de la mejor estructura se realizó considerando el paso número 6 del algoritmo (Figura 5), que es el cálculo de precisión dado en porcentaje conjunto con el MAPE (error absoluto porcentual promedio por sus siglas en inglés). Se muestra en la tabla 2.

RNA de pronóstico

Aquí se realizaron las pruebas con los datos obtenidos como resultado de la red de evaluación con los datos de la Tabla 1.

Fase 3 - Evaluación

En este conjunto de pasos se hizo la valoración de los resultados de la fase anterior; aquí se decidió si se hacían modificaciones o si la programación de la red daba un resultado.

Resultado de la evaluación

En este paso se ajustaron las diferentes estructuras, mientras se probaban varias combinaciones de capas ocultas, neuronas y entradas, para ver con cuáles se obtenían los mejores resultados. Al tener las mejores

combinaciones, se dio el visto bueno y se pasó a la siguiente etapa. Los resultados se muestran en la Tabla 2 donde se puede observar que con la estructura 2-15-9 se obtuvo un pronóstico con porcentaje de precisión mayor.

Tabla 2. Resultados de las estructuras de prueba de una RNA para pronóstico de demanda.

Desempeño del pronóstico				
Entradas	Capas Ocultas	Neuronas	% de precisión	RMSE
1	5	3	67.38%	4032.00
	15	6	68.35%	4002.77
2	5	6	68.11%	4019.91
	15	9	71.99%	3918.53

Resultado del pronóstico

Los resultados de esta estructura están plasmados en las siguientes tablas.

En la tabla 3, se observa la exactitud del pronóstico utilizando la técnica cuantitativa de promedio móvil agregando la técnica cualitativa del conocimiento del mercado representada en porcentaje.

Tabla 3. Resultados de pronóstico con Promedio Móvil + conocimiento del mercado año 2021.

Resultados de pronóstico con Promedio Móvil + conocimiento del mercado año 2021						
MES	VENTA REAL EN M\$	PROMEDIO MÓVIL	AGREGAR	CONOCIMIENTO DEL MERCADO	TOTAL PM+CDM	EXACTITUD DEL PRONÓSTICO
2021	6.439	4.997	+	8%	5.397	83.81%
	7.515	4.326	+	11%	4.802	63.90%
	4.962	3.651	+	12%	4.089	82.42%
	4.264	3.220	+	10%	3.542	83.09%
	6.362	3.948	+	9%	4.303	67.64%
	6.790	4.902	+	10%	5.392	79.42%
	3.014	1.808	+	14%	2.061	68.40%
	8.016	5.130	+	8%	5.541	69.12%
	4.445	2.801	+	9%	3.053	68.70%
	4.685	3.402	+	10%	3.742	79.88%
	5.112	3.678	+	11%	4.082	79.86%
	68.064				50.982	75.27%

En la tabla 4, se observa la exactitud del pronóstico utilizando la técnica cuantitativa de RNA agregando la técnica cualitativa del conocimiento del mercado representada en porcentaje.

Tabla 4. Resultados de pronóstico con RNA + conocimiento del mercado año 2021.

Resultados de pronóstico con RNA + conocimiento del mercado año 2021						
MES	VENTA REAL EN M\$	RNA		CONOCIMIENTO DEL MERCADO	TOTAL RN+CDM	EXACTITUD DEL PRONÓSTICO
2021	6.463	4.847	+	10%	5.332	82.50%
	5.439	5.151	+	8%	5.563	86.40%
	7.515	5.929	+	11%	6.470	86.10%
	4.962	3.672	+	12%	4.112	82.88%
	4.264	3.496	+	10%	3.846	90.20%
	6.362	5.089	+	9%	5.547	87.20%
	6.790	5.588	+	10%	6.124	90.20%
	3.014	2.411	+	14%	2.748	91.20%
	8.016	6.333	+	8%	6.840	85.32%
	4.445	3.511	+	9%	3.827	86.11%
	4.685	3.794	+	10%	4.174	89.10%
	5.112	3.885	+	11%	4.312	84.36%
	68.064				58.896	86.80%

Por último, en la tabla 5 se muestra la comparación de resultados utilizando las técnicas de RNA vs

Promedio móvil, pudiendo observar una mejor exactitud del pronóstico al utilizar RNA agregando el porcentaje determinado del conocimiento del mercado.

Tabla 5. Comparación de exactitud del pronóstico con RNA y Promedio móvil año 2021.

MES	RNA + CDM	PROMEDIO MÓVIL + CDM
Enero	82.50%	77.00%
Febrero	86.40%	83.81%
Marzo	86.10%	63.90%
Abril	82.88%	82.42%
Mayo	90.20%	83.09%
Junio	87.20%	67.64%
Julio	90.20%	79.42%
Agosto	91.20%	68.40%
Septiembre	85.32%	69.12%
Octubre	86.11%	68.70%
Noviembre	89.10%	79.88%
Diciembre	84.36%	79.86%

Evaluación de la información obtenida

Al evaluar los pasos anteriores se pudo concluir que la técnica que proporcionó mayor exactitud del pronóstico es RNA, los resultados se pueden apreciar en la figura 5.

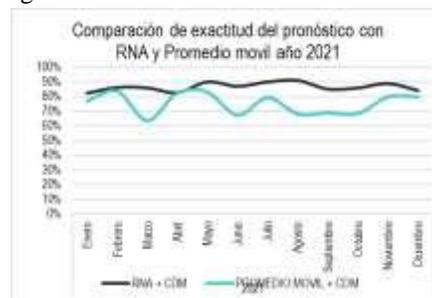


Figura 5. Comparación final de RNA y promedio móvil.

Presentación de la información

La presentación de la información se realizó mediante una gráfica comparativa de la venta real, en cada uno de los meses, contra el pronóstico RNA, la figura 6 ejemplifica los resultados.



Figura 6. Gráfica comparativa de la venta real contra el pronóstico RNA.

DISCUSIÓN Y ANÁLISIS DE RESULTADOS

Como propone Toro, Mejía y Salazar [1] un pronóstico de ventas es una técnica que permite calcular las proyecciones de ventas de una manera rápida y confiable, utilizando como fuentes de datos, ya sea las transacciones de inventarios o la facturación de ventas realizadas. En este trabajo se utilizó la facturación de las ventas como fuente de datos para poder obtener el pronóstico.

La estructura de RNA que se encontró muestra en general un buen desempeño; se destaca la estructura 2-15-9, con 2 entradas de información, 15 capas ocultas y 9 neuronas. Se puede observar que el porcentaje de precisión es el más alto y en el RMSE es el valor más bajo en la etapa de entrenamiento. Por lo que se concluye que tanto el número de neuronas de entrada como el número de neuronas ocultas tienen efectos significativos en la construcción de modelos RNA que concuerda con Zhang, Patuwo, y Hu [10]

Con los resultados obtenidos se destacan los siguientes puntos: 1- Es deseable incluir métodos de pronóstico tanto individuales como combinados con el fin de encontrar la mejor combinación de pronósticos en lugar de simplemente buscar el mejor individualmente. 2. Considerar el uso de pronósticos utilizando metodologías que incluyan tecnología como en este caso RNA, en lugar de métodos tradicionales. 3- Considerar más de una característica de los factores que influyen. Que coincide con las investigaciones de Ma & Fildes [7]

CONCLUSIONES

Generales

En este proyecto el buen resultado de la aplicación de redes neuronales artificiales para el uso de pronósticos de demanda demuestra su aplicabilidad.

Un punto importante para destacar es que esta investigación se llevó a cabo durante la crisis sanitaria por COVID-19 que hasta el día de la preparación de este artículo no se ha podido superar en su totalidad. En el sector de la construcción, que es donde se ubica

la industria del concreto, la contingencia sanitaria provocó un cambio significativo en las ventas, por lo que se concluye que probablemente a finales del año 2022 y comienzos del año 2023 se tenga una mayor estabilidad de los datos, como se presentaba antes de la contingencia, con lo que este proyecto puede ser aplicado nuevamente, con la probabilidad de conseguir mejores resultados.

Específicas

1. Datos. Cumplió con su objetivo ya que fue ideal para lo que se necesitaba y se pudo obtener de forma simple.
2. Base de datos. La base de datos que se armó fue lo suficientemente amplia para realizar las RNA.
3. Procesamiento. Cumplió con su objetivo ya que al realizarlo se mejoró la calidad de los datos.
4. RNA. Cumplió con su objetivo ya que se logró la codificación de una RNA funcional.
5. Programación. Cumplió ya que se logró armar el algoritmo para obtener un resultado.
6. Los resultados de la evaluación y pronóstico fueron superiores a los obtenidos por los métodos utilizados por la empresa.

Futuras líneas de investigación

1. Modificar la arquitectura propuesta contra otros modelos para ver mejoras en los resultados.
2. Agregar el concepto de Big Data y ciencia de datos para futuros análisis.

BIBLIOGRAFÍA

- [1] Toro Ocampo, E., Mejía Giraldo, D., Salazar Isaza & H. (2004). Pronóstico De Ventas Usando Redes Neuronales. *Scientia Et Technica* [En Línea]. [<https://doi.org/10.22517/23447214.7047>.]
- [2] Robert S. Pindyck & Daniel L. (2001). *Rubinfeld Microeconomía*. Alhambra.
- [3] Rodríguez Rivero, M (2016). *Modelos no lineales de pronóstico de series temporales basados en inteligencia computacional para soporte en la toma de decisiones agrícolas*. Tesis Doctoral. Universidad nacional de Córdoba.
- [4] Ospina Bolaños, D. (1987). *Sistemas administrativos de producción y operaciones*. Pereira,

UTP.

[5] Granger, C. W. & Terasvirta T. (1993). “Modelling Nonlinear Economic Relationships”. Oxford: Oxford University Pres.

[6] Hilera, J. Martínez, V. (1995). Redes Neuronales Artificiales; fundamentos modelos y aplicaciones. Rama Editorial.

[7] Ma, S. & Fildes, R. (2020). Retail sales forecasting with meta-learning. European Journal of Operational Research.

[8] Caja, O. (2020). Librería Python para el aprendizaje y la implementación de redes neuronales. Universidad Politécnica de Valencia.

[9] Freeman, J.A. & Skapura, D.M. (1991). Neural Networks: Algorithms, Applications and Programming Techniques. Addison-Wesley, Reading.

[10] Zhang, G.P., B.E. Patuwo, and M.Y. Hu. 2001. “A simulation study of artificial neural networks for nonlinear time-series forecasting”. Computers & Operations Research. 28(4), pp.381-396.

[11] Juan David Velásquez Henao. Acotación del error de modelos de redes neuronales aplicados al pronóstico de series de tiempo. UIS Ingenierías, Volumen 10, No. 1, págs. 65 – 71. junio 2011; Facultad de Ingenierías Físico-mecánicas, UIS.

[12] Cristian Rodríguez Rivero. Modelos no lineales de pronóstico de series temporales basados en inteligencia computacional para soporte en la toma de decisiones agrícolas. Universidad Nacional de Córdoba Facultad de Ciencias Exactas, Físicas Y Naturales. Diciembre 2006

[13] Jay Heizer. Barry Render. Principios de administración de operaciones. Séptima edición. 2009 págs. 108 – 109.

[14] Alireza Nazemi (2013) A stochastic reconstruction framework for analysis of water resource system vulnerability to climate-induced changes in river flow regime. [https://doi.org/10.1029/2012WR012755]

[15] Zhai, K., Jiang, N., Pedrycz, W. (2013) Cost prediction method based on an improved fuzzy model. The International Journal of Advanced Link. Volume 65, Issue 5 Manufacturing Technology. Springer8, pp 10451053.

[16] Villanueva E., M. (2002). Las Redes Neuronales

Artificiales y su Importancia como Herramienta en la Toma de Decisiones. Trabajo de Investigación Lic.) Universidad Nacional Mayor de San Marcos. Facultad de Ciencias Matemáticas. EAP de Investigación Operativa.

ROL DE CONTRIBUCIÓN

ROL DE CONTRIBUCIÓN	AUTOR
Conceptualización Curación de datos Metodología Administración del Proyecto Software Redacción	Tania Guadalupe Ramos García
Conceptualización Metodología Administración del Proyecto Supervisión	Mirella Parada González
Conceptualización Validación	Ulises Martinez Contreras
Conceptualización Validación	Arturo Woocay Prieto
Conceptualización Visualización Redacción	Laura Silva Leyva



Esta obra está bajo una licencia internacional Creative Commons Atribución 4.0.