






Modelo de pronóstico de cadena de suministro mediante redes neuronales Supply chain forecasting model using neural networks

D. Palafox-Palafox ^{a,*}, J. Medina-Marín ^a, J. C. Seck-Tuoh-Mora ^a, M. G. Serna-Díaz ^b, N. Hernández-Romero ^a

^aÁrea Académica de Ingeniería y Arquitectura, Universidad Autónoma del Estado de Hidalgo, 42184, Pachuca, Hidalgo, México.

^bÁrea Académica de Química, Universidad Autónoma del Estado de Hidalgo, 42184, Pachuca, Hidalgo, México.

Resumen

Los inventarios con stock superior a los niveles requeridos, afectan la cadena de suministro, haciéndola vulnerable y generando costos por obsolescencia. Actualmente, las organizaciones buscan implementar herramientas que pronostiquen demandas, planeen la producción y optimicen los niveles de inventarios de la cadena de suministro para reducir costos de almacenamiento. Por otro lado, las redes neuronales artificiales (RNAs) han mostrado ser eficientes comparado con otros métodos, como promedio móvil y regresión lineal para realizar pronósticos. En este trabajo, se desarrolló un modelo de simulación de una cadena de suministro considerando cuatro eslabones (Proveedor, Producción, Distribución y Detallista) con sus respectivos almacenes de productos, para generar datos históricos de los niveles de inventario a través del tiempo y a la vez utilizarlos para el entrenamiento de 110 diferentes configuraciones de RNAs, para buscar la RNA que mejor modele el conjunto de datos. La RNA que presentó mejor rendimiento ($r^2 = 0.99408$, $RMS E = 1.44217$) contiene 12 neuronas en la capa de entrada, 70 neuronas en la primera capa oculta, 60 en la segunda capa oculta y 4 neuronas en la capa de salida.

Palabras Clave: pronóstico, demanda, cadena de suministro, redes neuronales, simulación.

Abstract

Inventories with stock higher than required levels affects the supply chain, making it vulnerable and generating costs due to obsolescence. Up to now, the organizations it is needed to implement tools to forecast demand, plan production and optimize inventory levels of the supply chain to reduce storage costs. On the other hand, the artificial neural networks (ANNs) has proven to be efficient compared with others methods, as moving average and linear regression to make forecast. In this work, a simulation model of a supply chain was developed, considering four links (Supplier, Production, Distribution and Retailer) with their respective warehouses, to generate historical data on inventory levels over time and at once use them for training of 110 different artificial neural network (ANNs) configurations, to identify the ANN with the best model the data set. The ANN with the best performance ($r^2 = 0.99408$, $RMS E = 1.44217$) contains 12 neurons in the input layer, 70 neurons in the first hidden layer, 60 in the second hidden layer and 4 neurons in the output layer.

Keywords: forecast, demand, supply chain, neural networks, simulation.

1. Introducción

En tiempos actuales, las cadenas de suministro enfrentan diversas problemáticas como la incertidumbre de la demanda, costos por almacenaje, costos por inventario, capacidad de respuesta a las fluctuaciones de demanda, flujo de información entre proveedores y clientes, escasez de productos, poca certidumbre de los niveles de inventario por exceso o escasez, entre otros (Molina, 2023); lo que hace que ocurran interrupciones a lo lar-

go de cada uno de los eslabones que la conforman.

La cadena de suministro busca satisfacer necesidades, desde el proveedor hasta el cliente final. Dada la segmentación de procesos y la multiplicidad de actores que participan en una cadena de suministro, la correcta orquestación de todos ellos requiere de un alto grado de visibilidad (Calatayud y Katz, 2019).

La visibilidad en la cadena de suministro tiene la capacidad de trazar, monitorear y obtener información durante el proceso logístico, con el fin de tomar decisiones que optimicen las

* Autor para correspondencia: pa296400@uaeh.edu.mx

Correo electrónico: pa246400@uaeh.edu.mx (Daniela Palafox-Palafox), jmedina@uaeh.edu.mx (Joselito Medina-Marín), jseck@uaeh.edu.mx (Juan Carlos Seck Tuoh-Mora), maria_serna10342@uaeh.edu.mx (María Guadalupe Serna-Díaz), nhromero@uaeh.edu.mx (Norberto Hernández-Romero).

Historial del manuscrito: recibido el 12/08/2023, última versión-revisada recibida el 12/10/2023, aceptado el 14/10/2023 publicado el 20/11/2023. **DOI:** <https://doi.org/10.29057/icbi.v11iEspecial3.11482>



operaciones y aumenten la capacidad de respuesta al cliente (Patsavellas *et al.*, 2021). La visibilidad garantiza un panorama general para comprender los niveles de inventario y demanda, permite acceder a información útil sobre el movimiento de los productos (Silva *et al.*, 2017), lo cual permite anticipar un evento disruptivo.

Para Calatayud (2017) el incremento de la visibilidad de una cadena de suministro es la base para mejorar la coordinación de procesos y actores. Los beneficios de una mayor visibilidad y coordinación es mejorar el control de inventario, mayor utilización de recursos y equipos, reducir costos y tiempos, mejorar el monitoreo de demanda y reacción, mayor flexibilidad y mejores resultados financieros.

Sin embargo, sin una buena gestión, organización y uso de tecnología podemos tener poca certidumbre en el pronóstico de los niveles de inventario.

Por otra parte, las tendencias tecnológicas en la cadena de suministro marcadas por el internet de las cosas (IoT), la inteligencia artificial (IA), la robotización y la analítica de big data están transformando los procesos (Casalet, 2018). En la Cuarta Revolución Industrial las cadenas de suministro se caracterizan por un alto nivel de interconexión entre los ámbitos físicos y digitales, donde los sensores del IoT permiten recolectar y transmitir información en tiempo real a lo largo de toda la cadena. La analítica de big data, la inteligencia artificial y la computación en la nube, hacen posible tomar decisiones de manera simultánea para diferentes procesos a fin de optimizar el desempeño global de la cadena en tiempo real (Calatayud y Katz, 2019).

Kosasih y Brintrup (2022) destacaron la importancia de la visibilidad en las interdependencias de adquisiciones entre proveedores para desarrollar planes de contingencia comerciales más informados. La visibilidad de la cadena de suministro tiene un problema de predicción de bienes y/o productos desde el campo de Machine Learning (ML), en donde se propone un método automatizado para detectar datos desconocidos que afecten a los diferentes eslabones de la cadena de suministro con redes neuronales gráficas (GNN).

Aamer *et al.* (2020) en su artículo señalan que la economía global acelerada trae consigo una lista de oportunidades y desafíos para las cadenas de suministro. Una de las técnicas disruptivas que necesita el análisis de datos, el cuál impactará en el crecimiento y la desigualdad en el mercado es ML. El pronóstico de la demanda mejorará la eficiencia y toma de decisiones para mejorar las acciones de transformación. Las RNAs, regresión de vectores y máquina de vectores se encuentran entre los algoritmos más utilizados para la previsión de la demanda.

Más aún, Feizabadi (2022) desarrolló un método híbrido de previsión de demanda basados en el aprendizaje automático con el modelo ARIMAX y RNAs, ya que esto mitigará el efecto de la previsión de la demanda e ineficiencia operativa. Tanto las series temporales como los factores explicativos se incorporaron al método. El método se aplicó y evaluó en el contexto de un producto funcional. Las diferencias estadísticamente significativas en la mejora del rendimiento de la cadena de suministro se encontraron entre los métodos tradicionales de previsión de demanda y los métodos basados en ML.

Las RNAs ayudan a tomar decisiones de forma inteligente y con potencia de procesamiento. En el artículo "Demand fore-

casting using artificial neural networks - a case study of American Retail Corporation" se utilizaron RNAs en la previsión de la demanda modelándola matemáticamente con los softwares MATLAB y R. Chawla *et al.* (2019) realizó un análisis utilizando la previsión de la demanda y lo que se logró fue una precisión casi perfecta al pronosticar la demanda, asegurando que el conjunto de insumos es lo suficientemente completo para proporcionar un resultado, en el cual se utilizó un factor de corrección para compensar la estacionalidad.

En un estudio Barba *et al.* (2019) dieron a conocer un resultado positivo al utilizar RNAs para la solución de problemas relacionados con el control de inventarios, puesto que, la maximización fue superior al 22 % reflejado en las ventas. Más aún, Reategui y Hirvyn (2023) agregaron que las RNAs permiten ofrecer solución a los problemas relacionados con la gestión de inventarios, dado que, generan registro del stock de productos, maximizan ventas, lo cual repercute sobre la calidad del servicio y satisfacción del cliente.

Medina y Oscar (2021) afirman que mejorar la precisión de los pronósticos de la demanda es muy importante para gestionar eficientemente los inventarios en almacenes; ante la variabilidad de la demanda, ocasionados por los pedidos de urgencia altamente variables. En su investigación proponen un modelo de RNA para pronosticar la demanda de pedidos de urgencia y mejorar el pronóstico, obteniendo una tasa de retorno superior al 20 %; evitando una rotura de stock.

En un estudio realizado por Miranda (2023) en la industria textil para predecir los niveles de producción por los operarios utilizando RNAs, resultó favorable, ya que, ayudó a reducir tiempos de entrega evitando sobreproducción y mejorando los niveles de inventario.

Las RNAs tienen una buena aproximación en los pronósticos, obteniendo un buen ajuste a los datos reales registrados. Se realizó un modelo matemático con RNAs para el pronóstico de producción en una fábrica de galletas obteniendo una eficiencia del 97 % (Duchi Ortega, 2022).

En una investigación realizada a un operador logístico ferroviario para mejorar el proceso de gestión de inventario, implementaron herramientas de apoyo para la toma de decisiones dentro de la perspectiva de la Industria 4.0. La toma de decisiones multicriterio y un modelo de RNA se complementan para el proceso de toma de decisiones en la gestión de inventarios, los resultados apuntaron a una mejor precisión de los pronósticos de demanda comparado con los pronósticos que la empresa tenía, los resultados consolidan a la agilidad y calidad del proceso para la toma de decisiones para la gestión de inventarios (de Paula Vidal *et al.*, 2022).

En este artículo se propone utilizar RNAs para pronosticar el comportamiento de los niveles de inventario, aprovechando los datos históricos a través del tiempo que arroja un modelo de simulación de una cadena de suministro. Para ello se han considerado los diferentes eslabones desde el proveedor hasta el cliente. Los datos recopilados de los niveles de inventario son utilizados para el entrenamiento de la RNA, desarrollar el método de promedio móvil y regresión lineal para que sean capaces de predecir los niveles de inventario y comparar los resultados entre métodos a través del cálculo del coeficiente de determinación r^2 y la raíz del error cuadrático medio (RMSE, Root Mean Square Error), con ello determinar quién ofrece mayor

certidumbre en el pronóstico. Conocer un buen pronóstico de los niveles de inventario de una cadena de suministro ayudará a tomar mejores decisiones para reabastecerlos, evitando inventarios en exceso, así como costos innecesarios.

Anticipar eventos futuros deriva su importancia económica y social, además, facilita a las empresas a actuar de manera acertada ante los riesgos de posibles interrupciones y con ello incrementar la competitividad, abasteciendo la demanda necesaria.

2. Cadena de suministro

La administración de la cadena de suministro es una herramienta valiosa que se utiliza como ventaja competitiva para mejorar el desempeño de la organización. Uno de los principales objetivos de la administración de la cadena de suministro es reducir o eliminar los almacenamientos intermedios de inventario que existen entre las organizaciones en una cadena mediante el intercambio de información sobre la demanda y los niveles de existencias actuales (Christopher, 2016).

La globalización ha empujado a las empresas a que estas implementen mejoras en sus procesos con el fin de hacerlos más eficientes y con ello ofrecer a sus clientes los productos y servicios en la cantidad, calidad, lugar y tiempo requeridos, todo ello minimizando los costos asociados a ellos. La importancia de la cadena de suministro radica en la relación y dependencia que existe entre los eslabones desde el punto de origen hasta el punto de consumo (Flores *et al.*, 2019).

2.1. Gestión de la cadena de suministro

La gestión de la cadena de suministro es el proceso por el cual se planifica, se controlan y se pone en ejercicio las operaciones de una red de abastecimiento y almacenaje (Cruz, 2023).

La importancia de una buena gestión se ve reflejada en la rentabilidad de la empresa, la productividad y la satisfacción del cliente. Consiste en sincronizar y alinear los procesos logísticos y sus actores (proveedor, productor, distribuidor y cliente) para satisfacer la necesidad del cliente y generar un valor agregado (Gómez *et al.*, 2019).

2.2. Gestión de inventarios

El modelo de gestión de inventarios ayuda a la mejora de la organización ya que reducirá o eliminará las consecuencias de una mala gestión y evitará el consumo excesivo. Se busca garantizar que una empresa tenga suficiente inventario para satisfacer las necesidades del cliente (Bazan, 2023).

Cada etapa está conectada por el flujo de productos, información y fondos. Estos flujos suelen ocurrir en ambas direcciones y pueden ser gestionados por una de las etapas o un intermedio (Chopra y Meindl, 2013).

Las etapas de la cadena de suministro (Figura 1), están descritas a continuación:

- **Proveedor:** Durante este eslabón ocurre el proceso de abastecimiento de materia prima, insumos y materiales en general; encargados de obtener los materiales de alta calidad y bajo costo, los cuales fluirán a la siguiente fase de la cadena de suministro para ser transformados en un producto de valor (Flores *et al.*, 2019).

- **Producción:** Esta fase incluye todas las empresas encargadas de realizar una transformación a la materia prima en los diferentes productos destinados a los clientes (Flores *et al.*, 2019).
- **Distribución:** Lugar en donde transitan los productos o servicios hasta llegar al consumidor (Molinillo, 2020).
- **Detallista:** Canales de distribución que permiten hacer realidad los esfuerzos de mercadeo y constituyen uno de los soportes principales en la satisfacción del consumidor final (Flores *et al.*, 2019).

El éxito de una cadena de suministro dependerá del flujo de información adecuado (García, 2022), lo que genera que los altos mandos se incorporen de la mejor manera con los clientes y proveedores.

3. Redes neuronales artificiales

Las RNAs son técnicas populares de aprendizaje automático que simulan el mecanismo de aprendizaje de los organismos biológicos. La fuerza de las conexiones sinápticas a menudo cambia en respuesta de estímulos externos, así es como se lleva a cabo el aprendizaje en organismos vivos. Las unidades computacionales están conectadas entre sí a través de pesos, que cumplen el papel de las conexiones sinápticas. Cada entrada a una neurona se escala con un peso, que afecta la función calculada en esa unidad. Una RNA calcula una función de las entradas propagando los valores calculados desde las neuronas de entrada a las neuronas de salida y utiliza los pesos como parámetros intermedios; el aprendizaje ocurre cambiando los pesos que conectan las neuronas, el estímulo externo lo proporcionan los datos de entrenamiento (Aggarwal, 2018).

3.1. Pronósticos con redes neuronales

Las RNAs son uno de los exponentes de la inteligencia artificial que hace posible que se ejecuten tareas de manera automatizada a través del aprendizaje. Se han utilizado en diferentes campos, para llevar a cabo la modelación de sistemas de ingeniería, procesos químicos, reconocimiento de patrones, entre otros, donde se ha observado mejor eficiencia que otras herramientas estadísticas (Guamán *et al.*, 2023; Rodríguez *et al.*, 2023; Suárez y Ladino, 2023).

En esta investigación será utilizada como pronóstico de los niveles de inventario de cada uno de los eslabones de la cadena de suministro es decir proveedor, producción, distribución y detallista a partir de lo que el cliente pide.

Las decisiones más importantes del pronosticador para la construcción de una RNA son la preparación de datos, selección de las variables de entrada, la elección de un tipo de arquitectura, los algoritmos de entrenamiento y los modelos de validación, evaluación y selección (Morales *et al.*, 2019).

Es importante determinar el número y tipos de variables apropiadas para la capa de entrada ya que estas serán las que afectan el comportamiento y rendimiento de la red.

En la figura 2 se muestra la estructura general de una RNA.

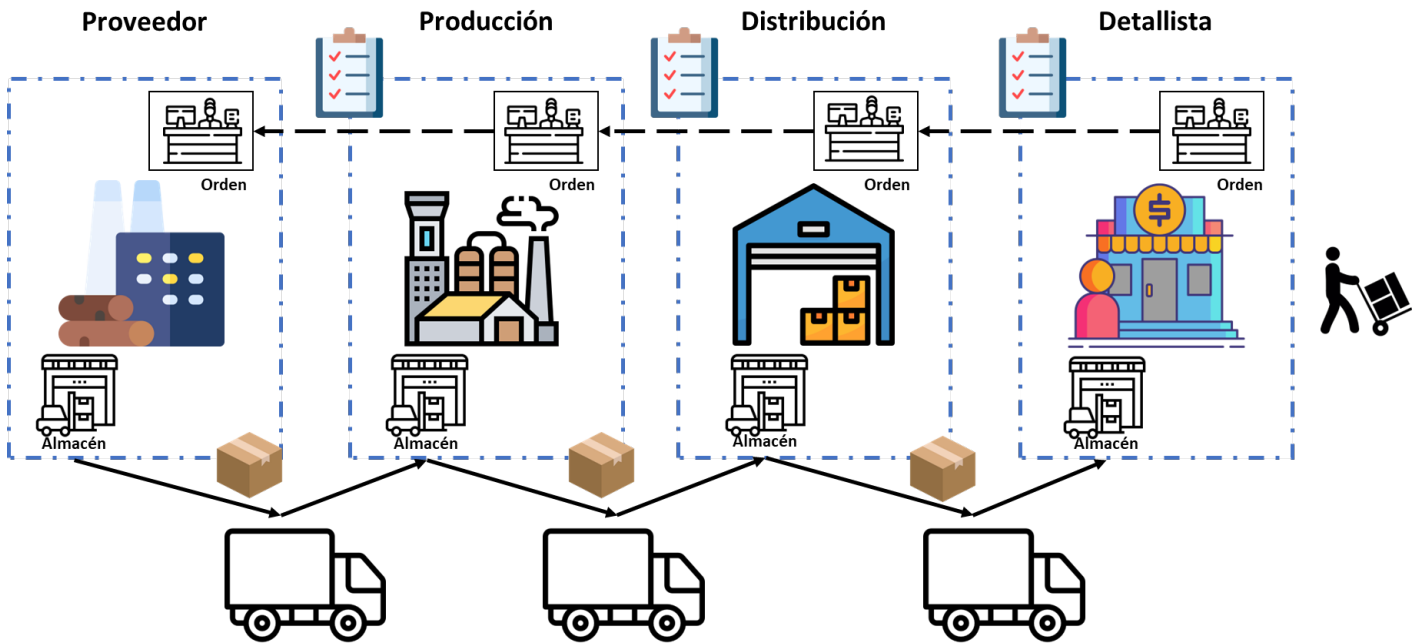


Figura 1: Modelo de la cadena de suministro.

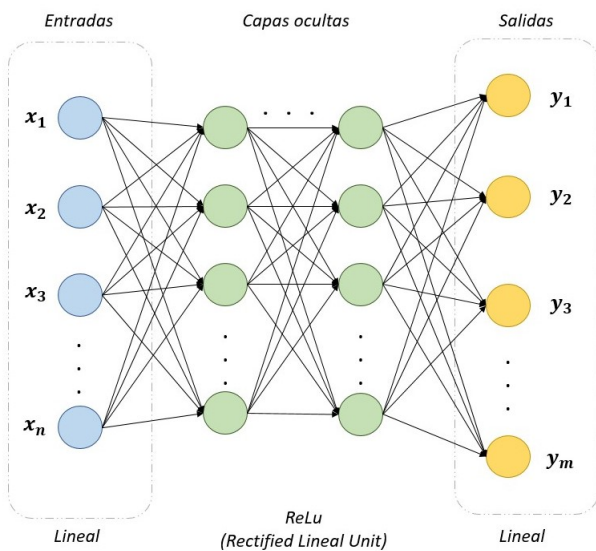


Figura 2: Red neuronal artificial.

4. Promedio móvil

Un método de pronóstico popular es el método de promedios móviles. Un promedio móvil de orden N es sencillamente el promedio aritmético de las observaciones N más recientes (Steven, 2007).

Chopra y Meindl (2013) afirma que este método se emplea cuando la demanda no tiene tendencia o estacionalidad observables. El nivel en el periodo t se estima como la demanda promedio durante los N periodos más recientes. Esto representa un promedio móvil de N periodos y se evalúa como sigue:

$$L_t = \frac{D_t + D_{t-1} + \dots + D_{t-N+1}}{N} \quad (1)$$

El pronóstico actual para todos los periodos futuros es el mismo y se basa en la estimación actual del nivel. El pronóstico se expresa como:

$$F_{t+1} = L_t \quad (2)$$

Para calcular el nuevo promedio móvil agregamos la última observación y eliminamos la antigua.

5. Regresión lineal

Cuando existe una tendencia lineal ascendente o descendente en los datos, el método común de pronóstico es la regresión lineal. La regresión lineal se utiliza para ajustar una línea recta a datos pasados con base en el método de mínimos cuadrados (Steven, 2007).

Walpole *et al.* (2012) señala que cuando un modelo es lineal en los coeficientes se denomina modelo de regresión lineal múltiple. Para el caso de k variables independientes, el modelo que da x_1, x_2, \dots, x_k , la medida de $Y|x_1, x_2, \dots, x_k$ es el modelo de regresión lineal múltiple

$$\mu_{Y|x_1, x_2, \dots, x_k} = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k \quad (3)$$

y la respuesta estimada se obtiene a partir de la ecuación de regresión muestral

$$\hat{y} = b_0 + b_1 x_1 + \dots + b_k x_k \quad (4)$$

donde cada coeficiente de regresión β_i se estima por medio de b_i , a partir de los datos muestrales, usando el método de mínimos cuadrados.

6. Metodología de la investigación

En la figura 3 se muestra el flujo de procesos que se llevó a cabo en la investigación.

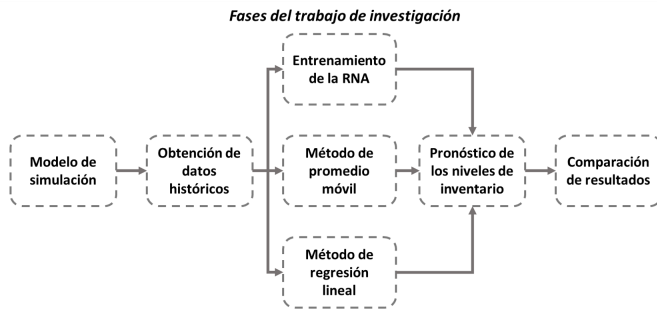


Figura 3: Diagrama de flujo de las etapas del modelo.

Primera fase: Se presenta el modelo de la cadena de suministro, el cual se diseñó y simuló en Promodel 2014 ® con cuatro eslabones, ver figura 4. Se obtuvieron datos históricos de los niveles de inventario al transcurso de los días simulados.

Segunda fase: Se registran los datos obtenidos en un documento Excel de los niveles de inventario a partir de que entra y sale el pedido, como se muestra en la figura 1.

Tercera fase: Los datos obtenidos de la segunda fase se utilizan, para el entrenamiento de la RNA, la cual se desarrolló en el software Visual Studio Code ® con el lenguaje de programación Python y la librería de TensorFlow. Así mismo, se utilizaron para el desarrollo del método de promedio móvil y regresión lineal con el software Microsoft Excel. Para pronosticar los niveles de inventario.

Cuarta fase: Se obtiene el resultado de los pronósticos de los niveles de inventario para 5 días de horizonte con la RNA, promedio móvil y regresión lineal. Obteniendo r^2 y $RMS E$ de cada método. Con modelo de la RNA se obtuvieron gráficos del pronóstico.

Quinta fase: Con los resultados obtenidos de la cuarta fase se hace un comparativo de los tres modelos (RNA, promedio móvil y regresión lineal) a partir del cálculo del r^2 y el $RMS E$.

Se pretende cumplir con el abastecimiento de los eslabones de acuerdo a los pedidos realizados en cada periodo, pero sobre todo respetar los niveles de inventarios.

6.1. Modelo de simulación Promodel

La Figura 1 muestra un modelo de una cadena de suministro que consta de cuatro eslabones y que ha sido utilizada por varios autores. Los eslabones de éste son proveedor, producción, distribución y detallista, cada uno de ellos busca relacionarse entre sí para cumplir con la demanda y satisfacer al cliente.

El producto pasa por cuatro eslabones mencionados anteriormente. Consideramos que la llegada de los productos es a partir de que se ha alcanzado el punto de reorden y se tiene que generar una nueva orden al eslabón anterior a ese. El tiempo de llegada de los pedidos es cada 24 horas, el tamaño del pedido es variable con una capacidad en almacenes de 200 unidades con la excepción del primer almacén, su capacidad es infinita. Silva et al. (2017) utiliza una distribución normal con una media de 40 unidades y una desviación estándar de 2 unidades, como tamaño de pedido.

En la Figura 4 se observa el modelo de la cadena de suministro simulada en Promodel 2014 ®, el cual hace un recorrido de un producto que pasa por los cuatro eslabones hasta que llega al cliente final, representando un sistema Pull. Este modelo

se corrió durante 1 año de simulación para medir los niveles de inventario de cada almacén por eslabón y con ello recopilar datos de los niveles de inventarios. Esta información es utilizada para la fase de entrenamiento de la RNA, cálculo del promedio móvil y regresión lineal; para predecir los niveles de inventario. Conocer los niveles de inventario ayudará oportunamente para tomar decisiones congruentes para solicitar la cantidad necesaria de los productos a almacenar, evitando los excesos y faltantes para evitar costos y desperdicios.

En el último eslabón se encuentra el detallista el cual es encargado de cumplir con los pedidos en tiempo y forma, de acuerdo al punto de reorden establecido para realizar un pedido y que este pueda ser incorporado al almacén. Hoy en día las cadenas de suministro busca tener un alto nivel de competitividad. El flujo ideal de una cadena de suministro sería que todos los productos que entren en un almacén sean utilizados, evitando el exceso o falta de productos, por ello es importante conocer el pronóstico de los niveles de inventario.

En la Tabla 1 se muestran algunos de los datos históricos de los niveles de inventario, recopilados de un año de simulación en Promodel 2014 ®.

Tabla 1: Datos de niveles de inventario

Día	Proveedor	Producción	Distribución	Detallista
1	162	163	159	163
2	162	163	159	125
3	162	163	159	86
4	162	163	159	50
...				
312	125	77	67	41

6.2. Cálculo de r^2 y $RMS E$

Los indicadores utilizados para determinar el mejor rendimiento de los métodos promedio móvil, regresión lineal y las RNAs fueron el cálculo del coeficiente de determinación r^2 (Ec. 5), y $RMS E$ (Ec. 6).

Estos indicadores son utilizados para ajustar el modelo a los datos proporcionados, que ayudan a medir la precisión del pronóstico.

Si r^2 es más cercano a 1, entonces, tiene un mejor ajuste de datos.

$$r^2 = \frac{\left(\sum_{i=1}^n (P_{sol,exp} - \overline{P_{sol,exp}})(P_{sol,pred} - \overline{P_{sol,pred}})\right)^2}{\sum_{i=1}^n (P_{sol,exp} - \overline{P_{sol,exp}})^2 (P_{sol,pred} - \overline{P_{sol,pred}})^2} \quad (5)$$

Donde:

$\overline{P_{sol,exp}}$: Valor real

$\overline{P_{sol,exp}}$: Promedio de los valores reales

$\overline{P_{sol,pred}}$: Valor pronosticado

$\overline{P_{sol,pred}}$: Promedio de los valores pronosticados

$RMS E$ se utiliza para estimar valores observados para comparar la predicción del conjunto de datos; entre más bajo sea el valor de $RMS E$ indica un ajuste perfecto de datos.

$$RMS E = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_{sol,pred} - P_{sol,exp})^2} \quad (6)$$

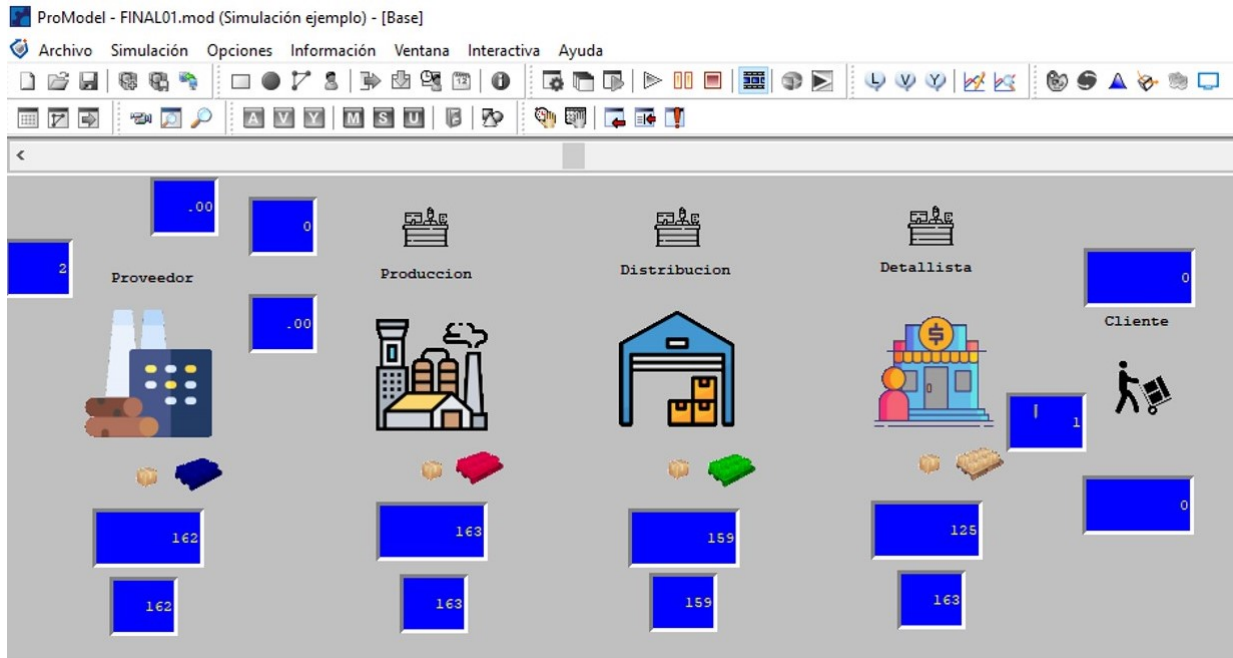


Figura 4: Modelo de simulación de la cadena de suministro.

6.3. Modelo de la red neuronal artificial

Para identificar la configuración de la RNA con el mejor rendimiento, se implementó un código en Python con la librería TensorFlow para generar una RNA multicapas con entrenamiento supervisado, diferente número de neuronas y diferente número de capas ocultas.

La función de activación que se utiliza en TensorFlow para la entrada y salida es lineal y en las capas ocultas ReLu (Rectified Lineal Unit) como se muestra en la estructura general de la Figura 2; el número de neuronas en cada capa oculta se fueron cambiando de 10 en 10, iniciando con 10 neuronas y finalizando con 100 neuronas, obteniendo un total de 110 configuraciones diferentes; con 1000 épocas. El factor fundamental de entrada son los niveles de inventario recopilados de los datos históricos extraídos de Promodel 2014 ® y el factor fundamental de salida los niveles de inventario pronosticado.

Para cada una de las 110 RNAs se obtuvieron la r^2 y $RMS E$ para determinar la que mejor se ajustara a los datos reales.

Tabla 2: Resultado de las iteraciones

	RNA (1 capa oculta)	RNA (2 capas ocultas)
r^2	0.91945	0.96146
$RMS E$	9.98829	5.99210

Como se observa en la Tabla 2, en esta fase la RNA con mejor rendimiento en r^2 y $RMS E$ tiene una configuración de dos capas ocultas, con 70 neuronas en la primer capa oculta y 60 neuronas en la segunda.

Con esta configuración se procedió a entrenar las RNAs para 1 a 5 períodos de horizonte, y con q días de datos históricos, ajustando el número de neuronas en las capas de entrada y salida.

6.4. Modelo de pronóstico con promedio móvil

En el estudio de este caso se incorporó el método de promedio móvil simple para pronosticar eventos futuros de los niveles de inventario en los almacenes de la cadena de suministro, utilizando los datos históricos recopilados de Promodel 2014 ®; a partir de ello, se obtuvo el cálculo del coeficiente de determinación r^2 y $RMS E$ por eslabón, mostrados en tabla 3.

Tabla 3: Resultado con promedio móvil

	Producción	Distribución	Detallista	Promedio
r^2	0.8766	0.7921	0.7119	0.7935
$RMS E$	11.1843	12.4629	7.9204	10.5225

Los valores de r^2 y $RMS E$ en el método de promedio móvil se calcularon como el promedio de las tres áreas (Producción, Distribución y Detallista), obteniendo como resultado $r^2 = 0.7935$ y $RMS E = 10.5225$.

6.5. Modelo de pronóstico con regresión lineal

Otro método utilizado para pronosticar los niveles de inventario es el método de regresión lineal. Por cada almacén y día de horizonte se obtuvo una r^2 y un $RMS E$, a partir de los datos históricos obtenidos de Promodel 2014 ®, ver Tabla 4 y 5.

Tabla 4: Resultado con regresión lineal r^2 , por almacén

Día	Producción	Distribución	Detallista
1	0.9812	0.9368	0.8663
2	0.9409	0.8724	0.6531
3	0.9090	0.8128	0.4997
4	0.8770	0.7292	0.4084
5	0.8378	0.6283	0.4108
Promedio	0.9091	0.7953	0.5676

En la Tabla 4 se muestra el cálculo del promedio de r^2 por cada área mediante regresión lineal. Producción, Distribución y Detallista tienen $r^2 = 0.9091$, $r^2 = 0.7953$ y $r^2 = 0.5676$, respectivamente. Además, se calcula el promedio general del modelo tomando en cuenta el promedio de cada área, obteniendo un valor de $r^2 = 0.7573$.

Tabla 5: Resultado con regresión lineal RMSE, por almacén

Día	Producción	Distribución	Detallista
1	6.2337	3.5195	2.7584
2	8.9271	6.9199	4.9345
3	10.4576	9.3152	6.5505
4	11.7031	10.6687	7.7642
5	12.9946	10.6129	7.7842
Promedio	10.0632	8.2072	5.9584

De manera similar, en la Tabla 5 se muestra el promedio de *RMSE* por cada área con el modelo de regresión lineal. Para Producción, Distribución y Detallista se obtienen los valores de $RMSE = 10.0636$, $RMSE = 8.2072$ y $RMSE = 5.9584$, respectivamente. Además, se calcula el promedio de *RMSE* de las tres áreas, obteniendo un valor de $RMSE = 8.0762$.

6.6. Comparación de los tres métodos, a partir de r^2 y *RMSE*

En la tabla 6 se muestran los resultados obtenidos de r^2 y *RMSE*, calculados con los niveles de inventario pronosticados con RNAs, promedio móvil y regresión lineal.

Tabla 6: Resultados de r^2 y *RMSE*

	RNA	Promedio móvil	Regresión lineal
r^2	0.96146	0.7935	0.7573
<i>RMSE</i>	5.99210	10.5225	8.0762

En los resultados anteriores (Tabla 6), se observa que el modelo de RNA explica el 96.146 % de los datos utilizados mientras que los modelos de promedio móvil y regresión lineal están por debajo del 80 %. También se puede observar que la distancia entre los valores reales y los pronosticados es menor con el modelo de RNA con un *RMSE* de 5.99210 contra valores de *RMSE* superiores a 8 en los otros dos modelos.

7. Resultados

En la Figura 5 se muestra el pronóstico que realiza la RNA (línea roja) sobre los valores de los niveles de inventarios registrados en el eslabón de Producción (puntos azules), en la cual se observa un acercamiento puntual a cada uno de los valores obtenidos en la simulación.




Figura 5: Pronóstico de la RNA para Producción.

Los niveles de inventario para el eslabón de Distribución presentan un incremento repentino de productos y posteriormente se da un consumo que reducen el nivel del inventario. Sin embargo, la RNA es capaz de hacer el ajuste necesario para pronosticar los periodos subsecuentes. (Figura 6)

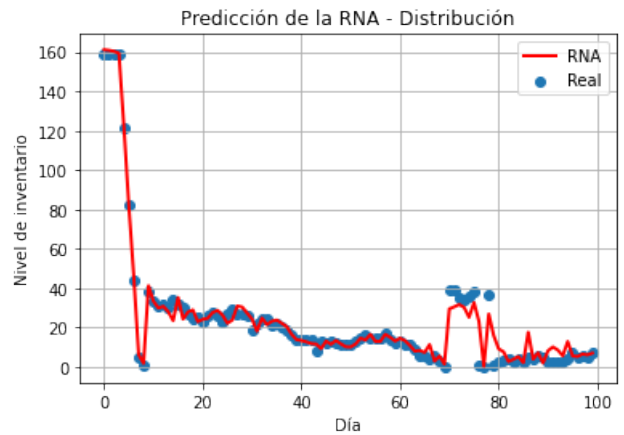


Figura 6: Pronóstico de la RNA para Distribución.

Para el eslabón del Detallista, la RNA presenta un pronóstico más cercano a los valores reales extraídos de Promodel 2014 ®. En la Figura 7 se observa el pronóstico cercano que la RNA va obteniendo en los días analizados.




Figura 7: Pronóstico de la RNA para el Detallista.

Se desarrollaron modelos de RNA utilizando la información de niveles de inventario de q días previos al momento de la generación del pronóstico. Es decir, para $q = 0$ se utilizaron los niveles de inventario de los cuatro almacenes, registrados en el día que se está realizando el pronóstico. Para $q = 1$, se utilizaron los datos de los niveles de inventario registrados de un día previo y el actual. Y para $q = 2$, se utilizó la información registrada a partir de dos días previos hasta el día actual. Por lo tanto, la RNA para $q = 0$ requirió de 4 neuronas en la capa de entrada; para $q = 1$, se necesitaron 8 neuronas en la capa de entrada, por los cuatro almacenes del día actual más los niveles de inventario de los mismos cuatro almacenes en el día previo; y en $q = 2$ se requirieron 12 neuronas en la capa de entrada, considerando los niveles de los cuatro almacenes en tres días.

La Figura 8 muestra el comportamiento del coeficiente de determinación r^2 , para el pronóstico de los niveles de inventario en los 4 almacenes de la cadena de suministro, partiendo de un horizonte de 1 día y hasta 5 días. Se puede observar que la RNA que considera el histórico de 2 días como entrada ($q = 2$) mantiene valores cercanos a 1, mientras que cuando $q = 0$, el valor de r^2 tiende a decrementarse. Es decir, que si r^2 es más cercano a 1 la correlación de los valores del horizonte 1 al 5 es más certero, en otras palabras, el pronóstico será el más adecuado con $q = 2$ días de horizonte.




Figura 8: r^2 para RNAs con datos históricos.

De forma similar, la Figura 9 muestra la evolución del RM-

SE, donde la RNA que utiliza información histórica con $q = 2$ días de horizonte es más cercana a 0.

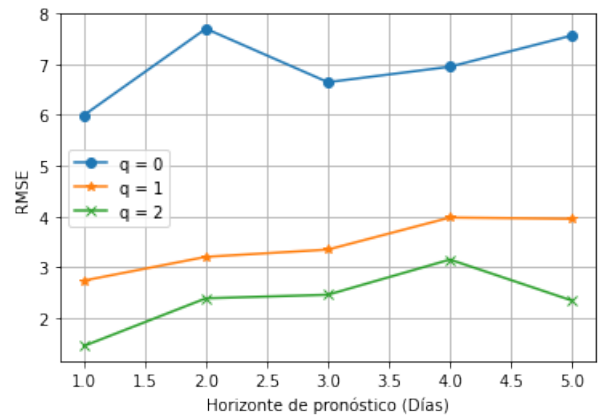


Figura 9: RMSE para RNAs con datos históricos.

Con base en la información plasmada en las gráficas de las figuras 8 y 9, se puede observar que la RNA con mayor rendimiento es la que fue utilizada para hacer el pronóstico de los niveles de inventario del día siguiente, y utilizando información histórica de 2 días previos.

8. Conclusiones

En éste documento se plantea la importancia de tener una relación estrecha entre cada uno de los eslabones que conforman la cadena de suministro, lo cual permite una buena gestión para poder visibilizar las interrupciones en el sistema por falta de inventario suficiente para cumplir con las órdenes de pedidos.

Se aplicaron técnicas de simulación para replicar el comportamiento de los niveles de inventario en los 4 eslabones de la cadena de suministro. De esta manera, se hizo la recopilación de la información necesaria para la fase de entrenamiento de las RNAs propuestas, el desarrollo del método de promedio móvil y regresión lineal para el pronósticos de los niveles de inventario de los días siguientes.

En el proceso de generación de la RNA, el modelo que presentó el mayor rendimiento fue una RNA de configuración 12 neuronas en la capa de entrada, 70 neuronas en la primera capa oculta, 60 neuronas en la segunda capa oculta y 4 neuronas en la capa de salida con una $r^2 = 0.99408$ y un $RMS E = 1.44217$, lo que muestra que tiene un 99.408 % de precisión para el pronóstico de los niveles de inventario para los almacenes de los 4 eslabones en la cadena de suministro, y puede ser utilizado para contar con producto suficiente para satisfacer los pedidos, y sin saturación en los almacenes de cada eslabón. Esto permitirá reducir costos por concepto de manejo de inventario, y en consecuencia, aumentar los ingresos a la empresa.

Se concluye que las RNAs presentan ventajas para ser utilizadas en las organizaciones, debido a que tiene mayor precisión comparado con otros métodos en la generación de pronósticos.

Como trabajo futuro, la RNA obtenida será aplicada en el modelo de simulación para analizar el impacto de su uso en la satisfacción del cliente, y en la reducción de gastos en toda la cadena de suministro.

Referencias

- Aamer, A., Eka Yani, L., y Alan Priyatna, I. (2020). Data analytics in the supply chain management: Review of machine learning applications in demand forecasting. *Operations and Supply Chain Management: An International Journal*, 14(1):1–13.
- Aggarwal, C. (2018). Neural networks and deep learning. *Springer*, 10(978):3.
- Barba, J., Quinde, C., Cevallos, L., y Rendon, C. (2019). Aplicación de redes neuronales artificiales para la toma de decisiones en el control de inventarios de una despensa ubicada en la ciudad de guayaquil. *ResearchGate*.
- Bazan, R. M. (2023). Metodología 9s para mejorar la gestión de inventarios en los almacenes de una empresa metalmeccánica, lima 2022.
- Calatayud, A. (2017). The connected supply chain: enhancing risk management in a changing world.
- Calatayud, A. y Katz, R. (2019). *Cadena de suministro 4.0: Mejores prácticas internacionales y hoja de ruta para América Latina*, volumen 744. Inter-American Development Bank.
- Casalet, M. (2018). La digitalización industrial: un camino hacia la gobernanza colaborativa. estudios de casos.
- Chawla, A., Singh, A., Lamba, A., Gangwani, N., y Soni, U. (2019). Demand forecasting using artificial neural networks—a case study of american retail corporation. En *Applications of Artificial Intelligence Techniques in Engineering: SIGMA 2018, Volume 2*, pp. 79–89. Springer.
- Chopra, S. y Meindl, P. (2013). *Supply chain management. Strategy, planning, and operation*. New York, NY, USA.
- Christopher, M. (2016). *Logistics & supply chain management*. Pearson Uk.
- Cruz, L. J. L. J. (2023). Gestión de la cadena de suministros y la ventaja competitiva en una empresa comercial del rubro minería, callao, año 2022.
- de Paula Vidal, G. H., Caiado, R. G. G., Scavarda, L. F., Ivson, P., y Garza-Reyes, J. A. (2022). Decision support framework for inventory management combining fuzzy multicriteria methods, genetic algorithm, and artificial neural network. *Computers & Industrial Engineering*, 174:108777.
- Duchi Ortega, B. R. (2022). Propuesta de un modelo matemático aplicado al pronostico de producción utilizando redes neuronales artificiales aplicado a una fabrica de galleta de sal de 100 x 67 gr. Tesis de maestría.
- Feizabadi, J. (2022). Machine learning demand forecasting and supply chain performance. *International Journal of Logistics Research and Applications*, 25(2):119–142.
- Flores, J. A., Manrique, M. A., Taco, A. M., y Teves, J. (2019). Gestión de cadena de suministro: una mirada desde la perspectiva teórica. *Revista Venezolana de Gerencia*, 24(88):1136–1146.
- García, P. T. (2022). Toma de decisiones en la cadena de suministro.
- Gómez, R. A., Zuluaga, A., Ceballos, N. P., y Palacio, D. (2019). Gestión de la cadena de suministros y productividad en la literatura científica. *I+ D Revista de Investigaciones*, 14(2):40–51.
- Guamán, S., Mullo, H., y Marcatoma, J. (2023). Comparación entre modelos de regresión lineal múltiple vs redes neuronales artificiales supervisadas en la predicción de calificaciones ser bachiller 2018-2019 del ecuador. *Revista Iberoamericana de la Educación*, 7(2).
- Kosasih, E. y Brintrup, A. (2022). A machine learning approach for predicting hidden links in supply chain with graph neural networks. *International Journal of Production Research*, 60(17):5380–5393.
- Medina, R. y Oscar, E. (2021). Pronóstico de demanda altamente variable e intermitente usando un modelo básico de red neuronal artificial para disminuir el riesgo de rotura de stock de una compañía que abastece productos en sudamérica.
- Miranda, A. L. A. (2023). Implementación de una red neuronal para la predicción de la producción de los operarios de la empresa textil litex.
- Molina, T. (2023). Economía circular y producción lean en la gestión de las cadenas de suministro: Un modelo de simulación. *Catedracogersa. Com*.
- Molinillo, J. S. (2020). *Distribución comercial aplicada*. Esic.
- Morales, C. A., Ramírez, R. E., y Rodríguez, A. G. (2019). Pronóstico de ventas de las empresas del sector alimentos: una aplicación de redes neuronales. *Semestre Económico*, 22(52):161–177.
- Patsavellas, J., Kaur, R., y Salonitis, K. (2021). Supply chain control towers: Technology push or market pull—an assessment tool. *IET Collaborative Intelligent Manufacturing*, 3(3):290–302.
- Reategui, R. y Hirvyn, A. (2023). Modelo una red neuronal artificial para la mejora de la gestión de inventarios en empresas comerciales del distrito de tarapoto.
- Rodríguez, J., González, J., Moreno, C., Bautista, C., Júnez, H., Castillo, L., y Dávila, S. (2023). Estimación de lluvias mensuales promedio con regresión lineal múltiple y redes neuronales artificiales en una cuenca semiárida. *Research in Computing Science*.
- Silva, N., Ferreira, L. M. D., Silva, C., Magalhães, V., y Neto, P. (2017). Improving supply chain visibility with artificial neural networks. *Procedia Manufacturing*, 11:2083–2090.
- Steven, N. (2007). *Análisis de la producción y las operaciones*. Mc Graw Hill, 5 edición.
- Suárez, R. y Ladino, I. (2023). Redes neuronales aplicadas al control estadístico de procesos con cartas de control ewma. *Tecnura*, 27(75):4–4.
- Walpole, R., Myers, R., y Myers, S. (2012). *Probabilidad y estadística para ingeniería y ciencia*. Pearson, 9 edición.