

Aplicación de redes neuronales artificiales en la toma de decisiones del control de inventarios en una PYME.

Application of Artificial Neural Networks in Decision-Making for Inventory Control in
an SME

James Adolfo Vargas Niño

Julián González Velasco

Director de Trabajo de Grado

Universidad del Valle, Facultad de Ingeniería Industrial.

Estudiante de Pregrado de Ingeniería Industrial.

Orcid ID: <https://orcid.org/0009-0000-8531-3433>. james.vargas@correounivalle.edu.co

Colombia.

Origen de subvenciones: Este artículo se realizó en el marco de la investigación para la Tesis de grado.

Correspondencia: Dirección: Andalucía, Calle 22 n°. 3-98. Teléfono: +57 3154848062

RESUMEN

La gestión y control de inventarios es uno de los problemas más críticos en las pequeñas y medianas empresas (Pymes), por lo tanto, las decisiones en este ámbito requieren de estrategias que simplifiquen y fortalezcan su papel como actores fundamentales de la economía de un país. Este trabajo analiza la aplicación de las Redes Neuronales Artificiales (RNA) como alternativa para optimizar dichos procesos en una Pyme. La investigación parte de las limitaciones de los métodos tradicionales, que aunque ofrecen cierta utilidad, resultan insuficiente frente a escenarios de alta variabilidad de la demanda, prácticas manuales ineficientes, restricciones presupuestales y resistencia al cambio organizacional. Estas condiciones generan riesgos de desabastecimiento o sobreacumulación de inventarios, afectando la eficiencia y competitividad.

El estudio se desarrolló en cinco fases: Diagnóstico del entorno empresarial, evaluación del nivel de madurez, selección de técnicas de gestión de inventarios, implementación de RNA y validaciones en un caso de estudio. Este enfoque permitió caracterizar las condiciones reales de la organización y demostrar el potencial de las RNA en la toma de decisiones.

Palabras claves: Control de inventario, digitalización, inteligencia artificial, índice de madurez, Pymes, redes neuronales.

ABSTRACT

Inventory management and control is one of the most critical challenges faced by small and medium-sized enterprises (SMEs). Therefore, decision-making in this area requires strategies that simplify and strengthen their role as fundamental actors in a country's economy. This study examines the application of Artificial Neural Networks (ANNs) as an alternative to optimize these processes within an SME. The research begins with the limitations of traditional methods which, although useful to some extent, prove insufficient when confronted with scenarios of high demand variability, inefficient manual practices, budgetary constraints, and organizational resistance to change. These conditions create risks of stockouts or overstocking, directly affecting efficiency and competitiveness.

The study was developed in five phases: diagnosis of the business environment, evaluation of the level of maturity, selection of inventory management techniques, implementation of ANNs, and validation through a case study. This approach made it possible to characterize the organization's real conditions and demonstrate the potential of ANNs in supporting decision-making.

Keywords: Inventory control, digitalization, artificial intelligence, maturity index, SMEs, neural networks.

INTRODUCCIÓN

Con el transcurrir del tiempo, los avances tecnológicos han generado transformaciones profundas tanto en la sociedad como en los sectores productivos, impulsando la creación de nuevos modelos industriales, consolidando tendencias globales y ofreciendo múltiples alternativas de uso tecnológico. El contexto empresarial se caracteriza por una competencia cada vez más intensa, lo que obliga a las organizaciones a buscar mecanismos que les permitan optimizar sus procesos internos. En este escenario, la automatización se convierte en un elemento esencial, al construir una herramienta que favorece la eficiencia operativa y facilite la respuesta frente a los retos que impone la transformación tecnológica. Tal como lo señala [1], dicha transformación conlleva desafíos significativos para los distintos mercados, pero al mismo tiempo abre puertas a beneficios relevantes, entre los cuales se encuentran el fortalecimiento de la educación, el desarrollo de competencias laborales y la transición hacia un modelo de trabajo más orientado al uso intensivo de la tecnología.

La transformación tecnológica ha impulsado la consolidación de nuevos enfoques y herramientas que han modificado de forma significativa el escenario empresarial contemporáneo. Dentro de este panorama, innovaciones como el Big Data han adquirido un papel protagonista, al proporcionar a las organizaciones la posibilidad de controlar con mayor detalle y precisión sus procesos internos. No obstante, el acelerado ritmo de la digitalización plantea retos relevantes en la adopción de estrategias y soluciones emergentes. Como lo menciona [1], dichas innovaciones se configuran como elementos determinantes de la competitividad, pues un entorno dinámico y cambiante exige a las empresas una capacidad constante de adaptación a las demandas de los consumidores.

Para enfrentar estos retos y capitalizar las oportunidades que ofrece la era digital, las empresas han comenzado a incorporar con mayor intensidad el uso de soluciones tecnológicas emergentes. En este sentido, las tecnologías como la robótica, la Inteligencia Artificial (IA), el Machine Learning, el Big Data, el Blockchain y el Internet de las Cosas por sus siglas en inglés (IoT), se han consolidado como pilares del crecimiento empresarial en múltiples sectores. Estas no solo optimizan procesos, sino que también generan transformaciones profundas en los paradigmas tradicionales de las empresas, redefiniendo la manera en que las compañías organizan, gestionan y compiten dentro del mercado [2] [3].

La adopción de tecnologías emergentes, en particular con la IA, han generado notables progresos en la gestión de las operaciones al permitir la automatización de tareas, la toma de decisiones basadas en datos, la detección anticipada de fallas y la programación de mantenimientos en los sistemas productivos. Tal como lo señalan en [4], estas funciones se sustentan en un conjunto de herramientas que dentro del marco de la transformación digital, se consolidan como ejes centrales de la modernización organizacional. Entre ellas sobresalen la Automatización mediante

los RPA (Robotic Process Automation), el análisis predictivos y mantenimientos preventivos a través de las redes neuronales artificial (RNA), la optimización de la cadena de suministro, así como el control de calidad y la gestión de defectos. Pese a la diversidad de sus aplicaciones, todas estas soluciones confluyen en el perfeccionamiento de las dinámicas productivas, otorgando mayor control y capacidad de seguimiento en cada fase operativa.

De acuerdo con [5], la IA en el sector industrial no debe entenderse únicamente como una herramienta operativa, sino como un recurso estratégico que conecta la gestión de la información con el control de los procesos. Su integración con las RNA ha transformado el aprendizaje automatizado, generando una sinergia que amplía la capacidad de innovación. Esta interacción además, demuestra un alto potencial para su aplicación en entornos productivos, ya que incrementa la eficiencia mediante herramientas que emulan la lógica del cerebro humano y fortalecen la toma de decisiones en contextos altamente competitivos.

No obstante, la adopción de estas tecnologías enfrenta limitaciones importantes en el contexto de las Pymes. Tal como lo menciona [6], este tipo de organizaciones suele lidiar con obstáculos persistentes asociados a la escasez de recursos financieros, la falta de personal con competencias técnicas especializadas y la resistencia al cambio. Estas restricciones estructurales reducen la posibilidad de aprovechar plenamente los beneficios de la IA, limitando su aplicación práctica en escenarios donde, paradójicamente podría generar impactos sumamente positivos.

La gestión de los inventarios presenta un reto constante para las Pymes, ya que los métodos manuales y los sistemas básicos disponibles no ofrecen la flexibilidad ni la precisión necesarias para adaptarse a escenarios de alta variabilidad en la demanda. Como señala [23], la dependencia de procedimientos tradicionales suele derivar en errores recurrentes en el control de las existencias, incrementando costos de almacenamiento y frecuentes quiebres en el stock, lo que afecta tanto la eficiencia de las operaciones como la satisfacción del cliente. La ausencia de herramientas predictivas que anticipen variaciones en el consumo agrava esta situación, reduciendo la competitividad de aquellas empresas que no han incorporado soluciones digitales frente a las que sí lo han hecho.

En este sentido, el uso de IA, y particularmente, las RNA surgen como una alternativa prometedora para superar tales limitaciones. Como lo señala [24], la IA permite analizar grandes volúmenes de datos con mayor precisión, generando modelos predictivos que faciliten decisiones más acertadas sobre las compras, almacenamiento y distribución. Las RNA, al imitar la estructura de aprendizaje del cerebro humano, tiene la capacidad de identificar patrones no lineales en la información, adaptándose con eficiencia a entornos caracterizados por la incertidumbre.

Dentro de las principales limitaciones que enfrentan las Pymes, se encuentran las restricciones presupuestarias, consideradas como un factor decisivo en la adopción

tecnológica. Tal como lo señala [7], estas organizaciones operan con recursos financieros limitados, lo que reduce la posibilidad de invertir en soluciones tecnológicas avanzadas para áreas estratégicas como la gestión de inventarios. En consecuencia, muchas optan por mantener procesos manuales o sistemas básicos que, por su naturaleza, presentan baja eficiencia y alta propensión a errores. A ello se suma la falta de experiencia y conocimiento técnico especializado, que dificulta aún más la implementación efectiva de herramientas digitales.

Según lo expuesto por [6], una de las principales limitaciones para la adopción tecnológica en las Pymes se relaciona con la resistencia al cambio. En muchos casos, tanto directivos como empleados muestran preferencias por mantener prácticas tradicionales, consideradas seguras y familiares, aun cuando resultan ineficientes frente a las demandas del entorno actual. Esta inclinación hacia lo conocido genera comodidad, pero al mismo tiempo frena la implementación de innovaciones, incluso cuando los beneficios se encuentran documentados y son evidentes.

Frente a este contexto, la investigación plantea la utilización de las RNA como un recurso estratégico para fortalecer la toma de decisiones en la gestión de los inventarios en una Pyme. El propósito es demostrar como esta tecnología puede aportar a la optimización de procesos críticos, minimizando errores y elevando los niveles de eficiencia operativa, al mismo tiempo que permite superar varias de las limitaciones que caracterizan a los métodos tradicionales empleados en este tipo de organizaciones.

Durante la revisión documental, se identificaron diversas investigaciones que exploran el uso de RNA en el ámbito del control de inventarios, evidenciando su aplicabilidad en contextos empresariales reales. Uno de estos trabajos profundiza en las herramientas utilizadas para dicho control de inventarios en una Pymes, definiéndolo como el proceso de gestión y monitoreo de existencias en función de las necesidades actuales y proyectadas. Este estudio resalta principalmente la implementación de un algoritmo computacional basado RNA, con el cual se desarrolla un modelo de control de inventarios capaz de adaptarse a la variabilidad de la demanda y al lead time, lo que permite una gestión más precisa y dinámica de los recursos disponibles dentro de la compañía [8].

En [9] se presenta un análisis comparativo entre los modelos predictivos basados en RNA y enfoques estadísticos tradicionales aplicados a pronósticos de ventas. Para ello, los autores emplearon registros históricos de ventas generales y ejecutaron ambos esquemas de predicción. Los resultados mostraron que las RNA alcanzaron niveles superiores de exactitud, lo que constituye un soporte más confiable para la toma de decisiones estratégicas, con mayor coherencia frente a las dinámicas del mercado.

En el desarrollo del estudio se emplearon modelos tradicionales como ARIMA y la suavización exponencial, ampliamente reconocidos en el ámbito de los pronósticos.

No obstante, durante su aplicación práctica se evidencio imprecisiones relevantes que derivaron en una gestión poco eficiente de la información. De igual manera, se identificaron obstáculos para la incorporación de las RNA, asociados principalmente a la falta de conocimiento especializado por parte del personal, la dificultad en la adaptación al uso de estas herramientas y la resistencia al cambio organizacional. Estas condiciones reflejan que aún persisten las limitaciones significativas para aprovechar de manera integral el potencial de las RNA dentro de las empresas.

En concordancia con lo expuesto, [10] plantea una metodología apoyada en modelos predictivos basados en RNA, orientando a gestionar con mayor precisión datos caracterizados por su alta volatilidad. La capacidad de estas redes para reconocer patrones no lineales en grandes volúmenes de información favorece la anticipación de la demanda con un grado superior de fiabilidad, lo que a su vez permite optimizar los niveles de inventario. Como resultado, se logra una disminución en los costos operativos y una reducción de los riesgos asociados al desabastecimiento.

Por otro lado, [11] propone un enfoque orientado a fortalecer la gestión de inventarios en las Pymes, considerando el comportamiento dinámico de la demanda mediante el análisis de datos. A partir de este proceso, se aplicaron modelos de Economic Order Quantity (EOQ), los cuales resultaron fundamentales para calcular la cantidad optima de pedido y con ello optimizar tanto los costos de adquisición como los de almacenamiento. Entre los aportes más relevantes del estudio se encuentra en el desarrollo de un software basado en códigos QR, diseñado para automatizar el control de inventarios mediante la definición de un punto de reorden. Este aporte evidencia la importancia de encaminar los esfuerzos hacia soluciones tecnológicas innovadoras que garanticen mayor precisión en los resultados.

Finalmente, [12] sostiene que las tecnologías de la información y comunicación (TIC) constituyen un recurso esencial para las Pymes, dado que incrementan su eficiencia y eficacia, al mismo tiempo que impacta positivamente en la calidad de los bienes y servicios que ofrecen.

La transformación digital constituye una oportunidad estratégica para que las Pymes se adapten a un entorno empresarial cada vez más dinámico, cerrando brechas en términos de madurez digital. Estas empresas representan más del 90% del tejido empresarial del país, generando cerca del 65% del empleo y aportan alrededor del 35% del PIB, lo que evidencia su papel en el desarrollo económico y social. Diversos estudios resaltan su contribución en la creación de empleo y en la reducción de la pobreza, especialmente en zonas rurales, al tiempo que subraya la importancia del acceso al financiamiento y de mecanismos de apoyo que fortalezcan su consolidación y expansión [12][13].

En este contexto, la presente investigación se centra en la aplicación de RNA como un recurso estratégico para fortalecer los procesos de toma de decisiones en el control de inventarios dentro de una Pymes. El propósito es evidenciar como estas

tecnológicas pueden transformar la gestión organizacional, al ofrecer un análisis más preciso de la información, disminuir la incertidumbre operativa y optimizar el uso de recursos. En este sentido, la implementación de las RNA brinda a las Pymes capacidad analítica más sólidas, que contribuyen a una toma de decisiones sustentadas en información confiable y en concordancia con las condiciones reales de su entorno empresarial. A partir de ello, la investigación se orienta a responder la pregunta central de la investigación : *¿Cómo implementar las RNA para optimizar la toma de decisiones en el control de inventarios en una Pyme?*

METODOLOGÍA

Para el desarrollo de esta investigación, se toma como referente a [8], quienes destacan los elementos claves en la aplicación de herramientas estadísticas y de IA, tales como la simulación Monte Carlo, los modelos de ARMAX y las RNA. En línea con este enfoque, se realiza un caso de estudio en una Pyme, que permite examinar de manera practica la implementación de las RNA en los procesos de toma de decisiones vinculadas al control de inventarios. Esta aproximación metodológica se fundamenta en lo expuesto en [14], quien señala que el caso de estudio ofrece una guía efectiva para aquellas organizaciones que buscan incorporar soluciones digitales en sus operaciones. Al comprender los principios fundamentales de estas tecnologías e integrarlas adecuadamente, las empresas pueden aplicar modelos ya desarrollados y avanzar hacia una mayor eficiencia operativa y una posición más competitiva en el mercado.

En este orden de ideas, la investigación se realiza por etapas las cuales se distribuyen de la siguiente manera:

- I. **Etapa 1: Diagnóstico de la empresa y su entorno.** Esta fase tiene como objetivo describir los factores claves del entorno en que se encuentra ubicada la empresa caso de estudio. Posteriormente, se realiza un diagnóstico interno, enfocado principalmente en las áreas vinculadas al con el control de inventarios como el almacén, la bodega y las oficinas administrativas. El propósito es identificar el estado actual de los procesos y evaluar el uso de herramientas y tecnologías disponibles. Para ello, se aplican técnicas como la observación no participativa, encuestas estructuradas y entrevistas dirigidas al personal administrativo y operarios, permitiendo así tener una visión integral y precisa de la situación actual de la organización.
- II. **Etapa 2: Evaluación del índice de madurez digital.** Esta etapa hace referencia a la aplicación de un marco conceptual que permite a las organizaciones evaluar su grado de madurez digital en un área específica, facilitando así su proceso de transformación. Dichos modelos contribuyen a mejorar la gestión de proyectos y la calidad de los procesos internos, y generalmente están estructurados en niveles o etapas que reflejan el nivel

de desarrollo o competencias alcanzadas por la empresa, tal como lo señala [15].

En el contexto de esta investigación, se adaptó el modelo de madurez propuesto en [16], el cual fue seleccionado tras completar la etapa de diagnóstico inicial. Con base en los resultados obtenidos en la etapa anterior, se identificaron las dimensiones más relevantes del modelo y se determinó el nivel de madurez de la Pyme en estudio. El modelo contempla una escala de cinco niveles, cada uno contiene criterios específicos relacionados con el uso y apropiación de tecnologías, permitiendo así una evaluación estructurada y precisa.

- III. **Etapa 3: Técnicas y pasos para el control de inventarios.** En esta fase se detallan las principales técnicas y procedimientos necesarios para establecer un control de inventarios eficiente y dinámico dentro de la organización. Tal como lo menciona [17], contar con información precisa y en tiempo real sobre la demanda y los puntos de consumo es fundamental para una gestión efectiva. Además, se resalta la importancia de estandarizar los procesos y definir con claridad los objetivos del sistema de inventarios. Estos elementos son claves para seleccionar el método de control más adecuado.
- IV. **Etapa 4: Implementación RNA.** En esta etapa se realiza un análisis detallado orientado a la incorporación de herramientas basadas en IA, específicamente RNA. Siguiendo la metodología propuesta por [8], se desarrolla un proceso secuencial que guía cada fase de la implementación. Inicialmente, se recopilan los datos relevantes y se evalúa su naturaleza, lo cual permite definir la estructura más adecuada para la RNA. Posteriormente, se aplica un modelo de aprendizaje automatizado que facilite la construcción de una ecuación predictiva, capaz de estimar con mayor precisión el valor de la demanda. Este enfoque proporciona una base sólida para mejorar la toma de decisiones en la gestión de inventarios, ajustándose a las condiciones reales de la empresa.
- V. **Etapa 5: Caso de estudio.** En esta etapa se integran los resultados obtenidos a lo largo del proceso investigativo para aplicar el modelo de RNA en una Pyme, esta implementación tiene como propósito evaluar el desempeño del modelo en un entorno real, considerando las condiciones específicas de la empresa, su nivel de madurez digital y los procesos actuales de la gestión de inventarios. Se retoman las recomendaciones metodológicas planteadas por [14], quienes destacan que el caso de estudio es una herramienta eficaz para comprender la aplicabilidad de soluciones tecnológicas en contextos concretos.

RESULTADOS Y DISCUSIÓN

Resultados

I. Etapa 1: Diagnóstico de la empresa y su entorno.

Contexto caso de estudio

La empresa caso de estudio fue fundada en julio del 2018 y está ubicada en el municipio de Argelia, una zona rural al noroccidente del departamento del Valle del Cauca, Colombia. Este territorio ha sido históricamente afectado por el conflicto armado interno, situación que, según [18], han generado múltiples alertas relacionadas con violencia, el desplazamiento forzado y una profunda crisis socioeconómica para sus habitantes. La falta de oportunidades laborales ha incentivado la migración de buena parte de la población en busca de mejores condiciones de vida.

En términos de desarrollo industrial, Argelia enfrenta serios desafíos asociados a su ubicación geográfica, la falta de infraestructura adecuada y las secuelas del conflicto armado, como lo indica [19]. Su economía ha dependido tradicionalmente de actividades agropecuarias como el cultivo de café, la caña de azúcar y plátano, sin consolidar un sector industrial sólido.

Datos recientes del DANE, muestran que el 0,7% de la población reside en zonas urbanas. En cuanto al nivel de educativo, el 54,7% han alcanzado la educación básica primaria, el 20% ha cursado estudios secundarios y solo el 2% ha accedido a educación superior o posgrados. Un 17% de los habitantes no cuenta con formación académica, lo cual evidencia brechas importantes en términos de urbanización, digitalización y acceso a la educación.

Ahora bien, la empresa caso de estudio es una maquila dedicada a la confección de prendas de vestir, específicamente gorras. Cuenta con 76 trabajadores, trabajadores mayores de 18 años, entre los cuales se destaca una proporción significativa de madres cabeza de hogar y jóvenes con formación secundaria. Los trabajadores laboran bajo la modalidad de contrato por obra o labor, una práctica ampliamente utilizada en Colombia, como señala [20], este tipo de contrato es común en el contexto colombiano, ya que su duración está sujeta a la culminación de una tarea o proyecto en específico.

Contexto tecnológico

El acceso limitado a tecnologías dentro de las empresas puede representar un obstáculo considerable para el crecimiento, eficiencia y capacidad competitiva. En la actualidad, la tecnología desempeña un papel fundamental en la optimización de procesos, la mejora de la comunicación interna y el fortalecimiento de la toma de decisiones estratégicas.

En el caso de la empresa caso de estudio, se identificó un uso restringido de herramientas tecnológicas, limitándose principalmente a Microsoft Excel para el control de inventarios y medios de comunicación convencionales como el correo electrónico, WhatsApp y llamadas telefónicas. Esta información se recopiló mediante observación no participativa y entrevista realizadas al personal administrativos.

Si bien dichas herramientas ofrecen una funcionalidad básica, su utilización exclusiva representa una barrera para el desempeño organizacional. En particular, Excel carece de actualización automática y en tiempo real, lo que puede generar inconsistencias como registros duplicados o inexistentes, además de dificultar la aplicación de análisis predictivos y la elaboración automatizada de reportes. Tal como lo señala [21], este software presenta limitaciones en materia de colaboración simultánea y control de versiones, lo que incrementa el riesgo de errores y problemas de comunicación al no existir visibilidad plena sobre las modificaciones realizadas.

II. Etapa 2: Índice de madurez digital

En el contexto de la transformación digital, la capacidad de una organización para adaptarse a los cambios tecnológicos representa una ventaja significativa. De acuerdo con [16], definen el concepto de madurez digital como una herramienta que permite a las organizaciones medir su nivel de desarrollo y establecer rutas de transformación para alcanzar una mayor eficiencia digital dentro de las compañías.

Teniendo en cuenta lo anterior, el índice de madurez digital se convierte en la herramienta clave dentro de la investigación, con el objetivo de identificar un modelo adecuado y ajustable para la aplicación en la empresa caso de estudio. Se llevó a cabo una revisión a la literatura encontrando un modelo que destaca y es propuesto por [22], quien estructura la evaluación de la madurez digital a través de seis dimensiones fundamentales, (1) Personas y Cultura, (2) Estrategia, (3) Organización y Estructura, (4) Procesos, (5) Tecnología y (6) Clientes. Este enfoque integral permite obtener una visión más holística de la situación o estado de la empresa, permitiendo así, un diagnóstico más preciso y una planificación más efectiva hacia el horizonte de la transformación.

En relación con el modelo de madurez propuesto por [22], este se estructura en cinco niveles progresivos que permiten evaluar el desarrollo digital de las organizaciones y es el siguiente:

Nivel 1- denominado Primario: La organización se encuentra en una etapa inicial, con capacidades básicas que contribuyen a la base para un futuro avance tecnológico.

Nivel 2- Cognitivo: Refleja una etapa de mayor conciencia y comprensión sobre los procesos digitales, aunque aún limitada a lo esencial.

Nivel 3- Identificado como **Consistente**: La organización ya muestra una madurez media con procesos estables y una gestión más estructurada.

Nivel 4 – Adelantado: Implica que las dimensiones evaluadas superan las expectativas básicas, indicando un estado avanzado en términos de digitalización.

Nivel 5- Empoderado: Representa una etapa en la que la organización no solo domina las practicas tecnológicas, sino que también

El esquema del modelo de madurez propuesto se toma de [22] para la siguiente investigación.

Tabla 1 Esquema modelo madurez Digital

Nivel de Madurez	Dimensiones					
	Personas y Cultura	Estrategia	Organización y Estructura	Procesos	Tecnología	Cliente
Nivel 5: Empoderado						
Nivel 4: Adelantado						
Nivel 3: Consistente						
Nivel 2: Cognitivo						
Nivel 1: Primario						

E. Z. Galindo, "Modelos de madurez digital en Pymes – caso de estudio de una Pyme de telecomunicaciones de Colombia," Universidad Nacional De Colombia, Jan. 2020, [Online]. Available: <https://repositorio.unal.edu.co/handle/unal/77419>

La tabla 1 representa un esquema de madurez digital que permite valorar el grado de avance de una organización en distintas dimensiones clave, como personas, cultura, estrategia, estructura organizacional, procesos, tecnología y relación con los clientes. Cada nivel, desde el primario hasta el empoderado, reflejan un estudio progresivo en la integración de la transformación digital dentro de la empresa.

Uso

En cuanto al uso, se adopta una escala de valoración que maneja un rango de uno a cinco según (Álvarez Marcos et al., 2019) citado por [22], siendo 1=Pobre, 2= Débil, 3=Avanzado, 4= Fuerte y 5= Excelente, en los casos que no haya evidencia el indicador toma un valor de 0. A partir de los resultados obtenidos, se calcula un promedio de las valoraciones por dimensiones, lo que permite establecer un indicador consolidado del nivel de madurez digital de la organización.

Medición del nivel de madurez

Para efectos de esta investigación, el modelo de madurez digital fue acotado específicamente a la dimensión tecnológica, con el propósito de enfocar el análisis en los aspectos más relevantes para el desarrollo del caso de estudio. Esta delimitación contribuye a simplificar la interpretación de los datos de decisiones vinculadas con la adopción de soluciones basadas en IA. Los resultados alcanzados se presentan de manera consolidada en la Ilustración 1.

	Dimensión Tecnológica	
Nivel de Madurez		20%
Nivel 5: Empoderado		23%
Nivel 4 : Adelantado		19%
Nivel 3: Consistente		17%
Nivel 2: Cognitivo		17%
Nivel 1: Primario		23%

Ilustración 1 Índice de madurez tecnológica de la Pyme Fuente: *Elaboración propia*

Los resultados presentados en la ilustración 1 evidencian que la empresa se encuentra en un nivel bajo de madurez dentro del componente tecnológico, ubicándolos en una fase inicial de acuerdo con la escala definida por [22]. En particular, se observan debilidades relevantes en la dimensión estratégica tecnológica, reflejadas en la falta de visión clara que orienta a la incorporación de herramientas orientadas a la innovación de los procesos operativos. Esta limitación reduce la capacidad de la organización para modernizar sus prácticas y alcanzar estándares de eficiencia que fortalezcan la gestión de inventarios.

El índice de madurez calculado corresponde al 20% del total, sitúa a la Pyme en un nivel primario, lo que implica que se encuentra en una etapa incipiente o primaria, que contribuye apenas la base para un desarrollo futuro en materia de tecnología. Según [22], este nivel inicial representa el primer peldaño en el proceso de transformación, lo que demanda una intervención estratégica que permita avanzar progresivamente hacia etapas superiores de integración digital.

Es importante destacar que, aunque el análisis se concentró únicamente en la dimensión tecnológica, una valorización complementaria que integre aspectos como la dimensión estratégica, de procesos y organizacional permite obtener una

perspectiva más completa. De este modo, se alcanzaría una visión más amplia y detallada de las condiciones actuales de la empresa caso de estudio.

III. Etapa 3: Técnicas y pasos para el control de inventarios

La gestión de los inventarios constituye un pilar esencial en las empresas dedicadas a la fabricación o comercialización de productos. Este proceso no solo implica el seguimiento de las existencias desde su ingreso al sistema hasta su salida final, sino que también representa un componente clave para asegurar el equilibrio operativo y financiero de la organización.

Como señala [17], mantener un control riguroso y estratégico de los inventarios puede traducirse en importantes beneficios desde el aumento de la rentabilidad y la eficiencia de los procesos internos, hasta una significativa reducción de costos y una mayor satisfacción del cliente.

En este contexto, se propone una serie de pasos estructurados que permitan la implementación de un sistema de control de inventarios, adaptando características particulares de cada empresa. Estos pasos, basados en el enfoque metodológico presentado por [17], se describen a continuación:

Paso 1: Diagnóstico inicial

- Identificación de los productos: Es importante conocer el tipo de producto que se comercializa o se fabrica, entendiendo cuales deben ser sus insumos, su materia prima, y como deben ser almacenados una vez se conviertan en producto terminado.

Paso 2: Recolección de datos históricos

- En esta fase se recopila la información clave sobre la demanda histórica y los tiempos de entrega. Es esencial procesar los datos cuidadosamente, evitando errores comunes los cuales pueden ser confundir la demanda con ventas reales o mantener registros sesgados.

Paso 3: Clasificación de Ítems

- Se recomienda aplicar herramientas como el método ABC, que permite agrupar los productos según su relevancia o frecuencia de rotación, esto facilita la definición de políticas diferenciadas de control para cada grupo, de acuerdo con su impacto en la empresa.

Paso 4: Selección del modelo de control

- Una vez clasificados los ítems, se elige el modelo que cumpla con las directrices y el manejo que la empresa este buscando, como alternativa se mencionan los siguientes, Sistema Two-Bin o revisión visual para

operaciones pequeñas, Modelo EOQ (cantidad económica de pedido) y revisión periódica con punto de reorden.

Paso 5: Pronóstico de la demanda

- En este punto, es crucial anticipar el comportamiento futuro de la demanda y para ello se pueden utilizar técnicas estadísticas o modelos computacionales, dentro de los modelos estadísticos más utilizados esta ARIMA, que ofrece predicciones ajustadas a patrones históricos.

Paso 6: Monitoreo e indicadores

- Se deben establecer métricas claras para hacer seguimiento al desempeño del sistema de inventarios, algunos indicadores clave incluyen la rotación de inventario, el nivel de servicio y los costos asociados al almacenamiento y reposición.

Paso 7: Ajustes y mejora

- Los resultados obtenidos a través de los indicadores permiten tomar decisiones correctivas, es importante realizar ajustes periódicos, considerando factores como el ciclo de vida del producto, variables financieras y las oportunidades que ofrecen las nuevas tecnologías, acompañadas de la IA.

Aplicación práctica de los pasos con relación al caso de estudio

Una vez descritos los pasos sugeridos para la conformación de la estructura metodológica para implementar un sistema de control de inventarios, se procede a su aplicación en el contexto de la empresa caso de estudio. Esta aplicación no solo permite validar la utilidad del modelo propuesto, sino también identificar aquellas particularidades y desafíos específicos que enfrenta una organización en un entorno rural, con limitaciones logísticas y tecnológicas.

Paso 1: Diagnóstico Inicial.

La fase inicial de la intervención consistió en reconocer y clasificar de manera precisa los productos e insumos esenciales que participan en el proceso de confección de gorras. Entre los materiales más representativos se identificaron telas (Poliéster y algodón), viseras plásticas, hilos, broches metálicos, etiquetas, vinilos para estampados y empaques.

Durante esta etapa se identificó que, aunque la empresa dispone de un control de inventario elemental, dicho proceso se llevaba a cabo de forma manual y con base en inspecciones visuales. Además, se evidencio la ausencia de políticas formalizadas y de herramientas tecnológicas que respaldaran su gestión. Esta condición limitaba la trazabilidad efectiva de los insumos y dificulta la implementación de alertas tempranas para la reposición de materiales, lo que

incrementa el riesgo de desabastecimiento en momentos críticos del ciclo productivo. Adicionalmente, se identificaron quince ítems cuyos registros de ventas mensuales abarcan un periodo continuo de siete años, lo que constituye una base robusta para el análisis del comportamiento de la demanda, dentro del análisis se observan diferentes patrones de rotación, un aspecto clave para una posterior clasificación. No obstante, se plantea como recomendación la necesidad de caracterizar a profundidad cada producto e insumo, con el fin de consolidar una implementación más precisa y ajustada a las particularidades del entorno operativo de la empresa.

Paso 2: Recolección de datos históricos

Se recopilaron registros de ventas y consumo mensual de productos terminados desde el año 2018 a 2024, asegurando que los datos representen la demanda real y no solo las ventas acumuladas, se realizó una depuración de la información para corregir inconsistencias y sesgos, especialmente en periodos donde la producción fue interrumpida por factores externos.

Paso 3: Clasificación ABC

Con el propósito de establecer estrategias de control diferenciadas para los productos, se implementó el método ABC, el cual permite jerarquizar los ítems según su peso relativo en el valor total del consumo. Esta metodología es fundamental en entornos donde no todos los artículos tienen el mismo impacto financiero u operativo.

El proceso se desarrolló a partir de los datos históricos de ventas correspondientes a un periodo de 78 meses. Inicialmente, se calculó la venta total acumulada para cada uno de los quince ítems, organizándolos de mayor a menor, para posteriormente calcular el porcentaje de participación de cada producto sobre el total general, así como su participación acumulada. Con esta información, se establecieron tres categorías según su nivel de prioridad para el control de inventarios.

- Clase A: Incluye los productos más relevantes, que representan en conjunto aproximadamente el 70 -80 % del total de las ventas.
- Clase B: Corresponden a los ítems que, si bien no son tan críticos como los anteriores, tienen una participación influyente aproximadamente entre el 15 y el 20 %.
- Clase C: Abarca los productos de menor impacto, que en conjunto representan un pequeño porcentaje restante del total, generalmente menos del 10%.

Ítems	Total Ventas	% Acumulado	Clasificación ABC	Columna1
3	25412	7,2%	A	80%
5	24911	14,2%	A	80%
10	24106	21,0%	A	80%
9	24099	27,8%	A	80%
8	24033	34,6%	A	80%
1	23626	41,3%	A	80%
12	23618	47,9%	A	80%
13	23392	54,5%	A	80%
14	23323	61,1%	A	80%
4	23193	67,7%	A	80%
15	23039	74,2%	A	80%
7	22999	80,7%	B	80%
11	22950	87,2%	B	80%
2	22776	93,6%	B	80%
6	22701	100,0%	C	80%

Ilustración 2 Clasificación ABC Fuente: Elaboración propia




Ilustración 3 Gráfico de Pareto Fuente: Elaboración propia

Finalmente, al clasificar los 15 ítems disponibles como se observa en la Ilustración 2 y 3, se identificó que once ítems concentraban cerca del 74% de las ventas acumuladas, lo que justifica la asignación a la categoría A. Estos elementos debido a su clasificación e importancia dentro de la empresa exigen un control de inventarios más riguroso y un monitoreo constante para evitar interrupciones en la producción y comercialización del producto. Por su parte, tres ítems fueron categorizados como B, al representar alrededor del 19.4% adicional, lo que trae como consecuencia necesidades intermedias al tener control sobre los inventarios, por último, un ítem fue clasificados como C, al tener un impacto mucho menor sobre el consumo global, permitiendo así una gestión mediante mecanismos o herramientas simples y con una baja frecuencia.

Paso 4: Selección del modelo de control

Una vez se concluyó el análisis de la clasificación ABC, se procede a la selección del modelo de control más adecuado para cada categoría, teniendo en cuenta su impacto al interior de la empresa. Para los ítems clasificados en la categoría A, que representan aproximadamente el 80% de las ventas acumuladas y, por ende, tienen un peso significativo en la operación productiva, se adoptó el modelo EOQ (Economic Order Quantity). Como lo menciona [17], el uso de puntos de reorden combinado con lotes económicos de pedidos permite minimizar el costo del valor del inventario al activar pedidos justo cuando se alcance un nivel crítico, sin embargo es necesario la supervisión constante del stock disponible.

En el caso de los ítems de categoría B, cuya participación acumulada en la demanda se encuentra entre el 80% y el 95%, se recomienda un modelo de revisión periódica, mediante el cual se evalúa el inventario en intervalos definidos, según [17] este sistema permite la reposición del inventario en periodos preestablecidos, ajustando la cantidad según el inventario disponible.

Finalmente, los ítems clasificados como C, que representan una fracción marginal de la demanda y presentan baja rotación, pueden ser gestionados a través de mecanismos más simples como el sistema de revisión visual o el método Two-Bin, si bien [17] hace referencia a estos dos sistemas de la siguiente manera, el sistema Two-Bin se basa en el uso de dos ubicaciones para un mismo ítem, lo que permite que al agotarse el contenido de una, se activa la reposición desde la segunda posición, para el caso del sistema de revisión visual, se basa en una inspección física y la decisión del inspector.

La selección diferenciada de modelos según la clasificación ABC permite asignar recursos de control en función de la relevancia estratégica de cada insumo, optimizando así la gestión del inventario y facilitando la toma de decisiones informadas dentro de la empresa.

Paso 5: Pronóstico de la demanda

Con el fin de asegurar una gestión más eficiente del inventario y prevenir tanto quiebres del stock como el exceso innecesario, resulta fundamental implementar métodos de pronóstico que faciliten la anticipación de la demanda. Esta fase se articula como un complemento del análisis ABC y los modelos de control utilizados, permitiéndole a la empresa el análisis por medio de una herramienta predictiva fundamentada en datos históricos.

Para tal fin, se empleó un enfoque estadístico sustentado en el análisis de series temporales, considerando los registros históricos de consumo acumulado correspondientes a los últimos 84 meses. Este periodo extenso permite detectar patrones estacionales, tendencias de crecimiento o decrecimiento, así como variaciones características del comportamiento del mercado. Entre las herramientas estadísticas disponibles, se empleó el modelo ARIMA AutoRegressive Integrated Moving Average (Media móvil integrada autorregresiva), debido a su capacidad para ajustarse a datos con dependencia temporal y fluctuaciones estructurales [18].

La aplicación del modelo ARIMA se realizó de manera individual para los ítems clasificados como tipo A, debido a su alto impacto en la operación se evidencian los ítems en la ilustración 4. Para los ítems B y C, se optó por aplicar modelos de suavizamiento exponencial simple o métodos de promedio móvil, dado que su comportamiento suele ser más estable o menos crítico desde el punto de vista logístico.

Ítems	Pronóstico
3	264
5	339
10	270
9	356
8	307
1	219
12	433
13	224
14	292
4	238
15	342

Ilustración 4 Pronóstico ARIMA Fuente: *Elaboración propia*

La implementación de los modelos de pronóstico diferenciados según la clasificación ABC permite el aprovechamiento de los recursos logísticos de la empresa, asignando esfuerzos analíticos más sofisticados a los ítems críticos (tipo A) y aplicando métodos más simples pero eficaces a los de menor rotación (tipos B y C). Este análisis estratégico no solo facilita una mayor precisión en la planeación

de compras y producción, sino que también fortalece la toma de decisiones basada en datos históricos y patrones de consumo reales.

IV. Etapa 4: Implementación RNA




Ilustración 5 Representación Gráfica de una RNA

La metodología central de este proyecto se fundamenta en el uso de RNA cuyo esquema se representa en la ilustración 5. De acuerdo con [8], las RNA pueden entenderse como modelos matemáticos inspirados en la dinámica del cerebro humano. Su procesamiento ocurre de manera paralela, lo que las diferencia de los sistemas convencionales que operan de forma secuencial, en lugar de seguir instrucciones predefinidas, las RNA ajustan sus conexiones internas hasta alcanzar un estado de equilibrio, lo que les permite generar resultados con niveles crecientes de precisión. A diferencia de los métodos tradicionales, estas RNA no ejecutan un programa rígido, sino que tienen la capacidad de aprender, adaptarse y reorganizarse de manera autónoma.

Arquitectura de la RNA

Una RNA está compuesta por tres capas principales, según [8], cada una de estas capas cumple una función específica:

- **Capa de entrada:** Recibe los datos iniciales, que pueden ser valores numéricos, características o patrones. Cada nodo en esta capa representa

una variable de entrada específica. Estos datos se transmiten a las siguientes capas para su procesamiento.

- **Capa oculta:** Realiza operaciones matemáticas y transformaciones no lineales sobre los datos. Está formada por neuronas artificiales que procesan las entradas ponderadas y aplican funciones de activación para transmitir los resultados a la siguiente capa. Dependiendo de la complejidad del problema, una RNA puede tener una o múltiples capas ocultas.
- **Capa de salida:** Proporciona el resultado al final o la predicción después de la corrida del código, cada neurona corresponde a un valor de salida específico, cuya cantidad se determina en función de la naturaleza del problema que se desea resolver.

Aprendizaje de una RNA

El proceso de aprendizaje de una RNA principalmente depende de los enlaces ponderados de las neuronas, debido a que estos se ajustan de manera que obtengan los resultados buscados, una RNA no necesita de algoritmos para solucionar los problemas, ya que cuenta con la capacidad de general de manera interna su propia distribución o dirección de los pesos en cada uno de los enlaces mediante los cuales aprende e itera hasta encontrar el resultado [9].

En este orden de ideas, en este trabajo se utiliza un algoritmo de entrenamiento Backpropagation para predecir los pronósticos de los Items pertenecientes a la clasificación ABC, debido a que esta red es específicamente útil en aplicaciones de reconocimiento o clasificación de patrones, como las tendencias. En este modelo existe una capa de entrada con n neuronas y una capa de salida con m neuronas y como mínimo de acuerdo con la literatura una capa oculta de neuronas internas, donde cada neurona de la capa excepto la de entrada recibe entrada de todas las otras capas anteriores y así poder enviar una salida a todas las neuronas de la capa posterior, excepto la de salida, esto se hace teniendo como referente a [9], quien dentro de su modelo conserva este patrón.

El algoritmo backpropagation tiene dos fases, una consiste en ir hacia adelante y la otra hacia atrás, en este sentido como lo menciona [9], durante los procesos de la primera fase el patrón de entrada representa la red y envía señal a través de las demás capas hasta encontrar una salida, sin embargo una vez culminada esta fase se inicia la segunda, la cual busca comparar los valores con la salida esperada para obtener el error. En este orden de ideas, lo que busca es ajustar los pesos de la última capa proporcional al error para ajustar los pesos y así poder volver a la fase de retropropagación del error, la cual busca ajustar de manera conveniente los pesos para continuar este proceso hasta llegar a la final y poder obtener el resultado óptimo.

Descripción de las RNA utilizadas

En el marco de esta investigación se implementó una Red Neuronal Artificial de tipo Feedforward Multicapa por sus siglas en ingles MLP, reconocida como uno de los modelos más utilizados para el pronóstico de datos en entornos empresariales, de acuerdo con [25], quienes mencionan que este tipo de arquitectura se caracteriza porque la información fluye en una sola dirección, desde la capa de entrada hacia la capa de salida, sin retroalimentación entre sus nodos, lo que facilita la aproximación de funciones no lineales a partir de datos históricos.

La elección de este modelo responde a la capacidad para adaptarse a contextos de alta variabilidad, propios de la gestión de los inventarios, donde los métodos estadísticos convencionales presentan limitaciones. Tal como lo señalan [9], las RNA en su función multicapa ofrecen un desempeño superior frente a la detección de patrones complejos o no lineales, otorgando mayor precisión en el análisis y en la predicción de la demanda. En este orden de ideas, existen aspectos que caracterizan una red neuronal, dentro de esos podemos encontrar su topología, el mecanismo de aprendizaje, tipo de asociación realizada entre la información de entrada y salida, y finalmente la forma de la representación de los resultados obtenidos.

Topología RNA Utilizada

Como se relacionó anteriormente, se van a utilizar dos arquitecturas de la RNA para buscar una solución al problema raíz de la investigación. Estas arquitecturas las vamos a llamar como prueba1 y prueba 2, para llevar a cabo cada una. Una vez definida la arquitectura es importante también mencionar que la RNA que se va a utilizar tiene un tipo de conexión hacia adelante, es decir que todas las señales se propagan hacia adelante a través de las capas de la red, no existe conexiones hacia atrás, buscando así una salida de una neurona aplicada a su propia entrada.




Ilustración 6 Topología 1 Fuente: Elaboración propia




Ilustración 7 Topología II Fuente: Elaboración propia

En este caso, la RNA reciben los datos históricos de ventas como entrada, las capas ocultas, que son internas en la red, no tienen contacto directo con el entorno exterior, mientras que las capas de salida son las encargadas de transferir la información procesada hacía el exterior. Una vez definidas la topología y su conexión, es importante señalar que, para este estudio, todas las pruebas estarán conformadas por tres capas, entrada, oculta y salida. Esto se menciona con el fin de brindar claridad sobre el comportamiento de la red en el análisis realizado.

Número de neuronas por cada capa:

Número de neuronas	Topología	
	I	II
Entrada	1	1
Oculto	1	2
Salida	1	1

Tabla 2 Número de capas

Fuente: Elaboración Propia

En el presente estudio, la red neuronal se estructura en tres capas como anteriormente se ha mencionado, sin embargo, es importante destacar que el número de neuronas va a depender de la topología establecida, tal como se observa en la tabla n°2 , en el caso de la topología I la red cuenta con 64 neuronas su capa oculta, mientras que en la topología II son 64 neuronas en la primera capa y en la segunda capa 32 neuronas, lo que incrementa su capacidad de procesamiento.

Adicionalmente, se debe considerar el concepto de Step, entendiendo como la cantidad de datos históricos que la red toma como referencia en la entrada , esto significa que la capa de entrada está formada por una neurona que representa una variable, pero según la topología, puede utilizar distintas cantidades de observaciones pasadas de manera simultánea, en términos del ejercicio práctico el

modelo tomara 12 datos históricos para la topología I y 24 datos para la topología II.

Mecanismos de aprendizaje

El aprendizaje de una red neuronal se entiende como el ajuste progresivo de los pesos que conectan sus neuronas, en función de la información que reciben como entrada, dicho esto, el proceso implica la modificación, fortalecimiento o debilitamiento de las conexiones internas, lo que permite que la red mejore su capacidad de respuesta ante nuevos datos.

Para este estudio se aplicó un esquema de aprendizaje supervisado, el cual se diferencia de los demás porque el entrenamiento se desarrolla bajo una guía de un externo que actúa como referencia. Este agente indica cuál debería ser la salida para cada conjunto de datos de entrada, permitiendo que la red compare, corrija y optimice de manera palatinamente así va graduando su desempeño.

Tipo de información de entrada y salida

En el desarrollo de las pruebas realizadas, tanto las variables de entrada como las de salida fueron consideradas de naturaleza analógica, es decir, se trabajó con valores numéricos reales y continuos que representaban los registros de ventas, esto con la finalidad de que la RNA procesará de manera directa la información cuantitativa, manteniendo sobre todo la coherencia entre los datos suministrados y los resultados esperados.

Entrenamiento de la RNA

Una vez definida la red, el siguiente paso es la fase de entrenamiento, entendido como el proceso de exposición de los datos históricos a la red para que este aprenda, ajuste sus parámetros internos, para así lograr un entrenamiento adecuado, para ello se establecieron las siguientes fases de acuerdo con lo mencionado por [9]:

- Fase I: Selección de los datos históricos que servirán para el aprendizaje de la red y diferenciación de aquellos que se utilizan como referencia para validar la eficiencia del entrenamiento, es decir dato supervisado.
- Fase II: Definición del criterio de parada del entrenamiento, en este caso, se estableció un umbral del error objetivo del 0.1% , lo que garantizó un ajuste preciso sin riesgo de sobre entrenamiento.
- Fase III: Comprobación visual de la red, contrastando gráficamente los datos históricos de ventas como valores generados por la red entrenada, con el fin de verificar la coherencia y exactitud del aprendizaje.
- Fase IV: Obtener el pronóstico de ventas.

Código Python

El código fue desarrollado en Google Colab (o Colaboratory), un entorno interactivo basado en Jupyter Notebooks que facilita la programación en Python, especialmente en proyectos de ciencia de datos y aprendizaje automático, en el caso de la RNA (ver anexo 1), se diseñó de manera general para que las organizaciones puedan adaptarlo según sus necesidades.




Ilustración 8 Proceso de pronóstico de la RNA

Fuente: Elaboración Propia

El flujo de trabajo de la RNA para el pronóstico de inventarios sigue estas etapas:

1. Recolección de datos históricos
2. Preparación y depuración de la información
3. Entrenamiento de la red mediante ajustes iterativos de sus parámetros
4. Evaluación del desempeño del modelo.
5. Generación de predicciones específicas sobre inventarios.
6. Análisis e interpretación de los resultados para apoyar la toma de decisiones.

La construcción del modelo combina fundamentos matemáticos con técnicas inspiradas en el cerebro humano. En Python, este proceso se apoya en bibliotecas como NumPy y Pandas para el manejo de datos, Matplotlib para la visualización y scikit-learn para dividir los conjuntos de entrenamiento y prueba. El modelo se implementa con Keras/TensorFlow, usando Sequential para la estructura de la red,

Dense para las capas, el optimizador Adam y funciones como Fit, Evaluata y Predict para entrenar, validar y realizar predicciones.

Estructura del código practico y modelo matemático

Con el fin de garantizar la transparencia de la metodología, se considera necesario presentar la estructura del código implementado y el modelo matemático. Este desarrollo constituye la base computacional sobre la cual se procesan los datos históricos, se entrenan los modelos de la RNA y se generan los pronósticos.

La exposición de sus componentes principalmente permite evidenciar como se gestionó cada etapa crítica del procedimiento, preparación de los datos, diseño del modelo y visualización de los resultados. En consecuencia, se muestra en el Anexo 1 y a continuación se expone el modelo matemático.

- Datos y escalado:

Sea la serie temporal de ventas un ítem:

$$\{X_1, X_2, \dots, X_T\}$$

Donde T = 85 es el último mes histórico.

Se aplica normalización min-max:

$$x'_t = \frac{x_t - \min(x)}{\max(x) - \min(x)} \text{ para } t = 1, 2, \dots, T.$$

- Construcción de ventanas de entrada

Con un tamaño de ventana de n= 24:

$$x^{(k)} = [x'_k, x'_{k+1}, \dots, x'_{k+n-1}], y^{(k)} = x'_{k+n}$$

Para cada K= 1, 2,T-n.

Esto genera los pares $(X^{(K)}, y^{(k)})$ usados en entrenamiento.

- Red Neuronal

La red tiene tres capas:

1. Capa densa 1(64 neuronas, ReLU):

$$h_1 = a(W_1 x^{(k)} + b_1)$$

2. Capa densa 2 (32 neuronas, ReLU):

$$h_2 = a(W_2 x^{(k)} + b_2)$$

3. Capa de salida (1 neurona, Lineal):

$$y^{(k)} = W_3 h_2 + b_3$$

- Función de pérdida

El entrenamiento minimiza el error cuadrático medio (MSE)

$$L = \frac{1}{N} \sum_{k=1}^n (y^{(k)} - \hat{y}^{(k)})^2$$

- Desescalada

La predicción normalizada $\hat{y}^{(k)}$ se transforma de nuevo a la escala real:

$$\hat{y}^{(k)}_{Real} = \hat{y}^{(k)} * (\max(x) - \min(x)) + \min(x)$$

En conclusión, el modelo matemático que representa el código es un perceptrón multicapa (MLP) entrenado sobre ventas de 12 0 24 meses de ventas, donde la predicción se formula como:

$$\hat{y} = f(x_{t-23}, x_{t-22}, \dots \dots x_t)$$

Con $f(.)$ una composición de transformaciones lineales y funciones de activación ReLU, todo esto se realizó considerando lo expuesto en [8][9].

Descripción de los datos.

La información empleada para esta investigación proviene de los registros históricos de ventas de la empresa textil. Se recopilieron datos de diferentes productos durante un periodo de 78 meses, lo que permitió contar con un conjunto de datos robusto para el análisis. Por motivos de confidencialidad, los artículos fueron rotulados como Items 1, Items 2, ..., evitando así exponer los nombres comerciales.

Cada serie de tiempos refleja un comportamiento particular, donde se logran evidenciar patrones estacionales, tendencias estables o en su defecto variaciones aleatorias según el producto. Esta diversidad resultó útil para probar distintos métodos de pronóstico, desde enfoques estadísticos tradicionales hasta el uso de RNA.

En la práctica, la actualización de los pronósticos se realiza de manera secuencial, para estimar un periodo determinado, para ello se utilizaron los registros inmediatamente anteriores, acumulando progresivamente la base de información. Así, fue posible contrastar el desempeño de los modelos estadísticos frente a la RNA, con el fin de identificar la metodología de la demanda en este contexto productivo.

Consideraciones y supuestos:

Antes de entrenar las RNA, es fundamental llevar a cabo un reprocesamiento de los datos, lo que incluye tareas como la normalización, el tratamiento de valores faltantes y, en caso de ser necesario, la codificación de variables categóricas.

La definición de la arquitectura es otro aspecto clave, el número de las capas ocultas, la cantidad de neuronas y funciones de activación incluyen directamente en

el desempeño del modelo y deben seleccionarse en función de la complejidad del problema y disponibilidad de los datos.

También, se requiere elegir las funciones de pérdida y las métricas de evaluación adecuadas al tipo de tarea, los hiperparámetros de entrenamiento, deben ajustarse cuidadosamente para evitar tanto el sobreajuste como el subajuste, complementariamente, es necesario dividir los datos en conjuntos de entrenamiento, validación y prueba, lo que permite medir el rendimiento de forma objetiva.

En problemas donde exista riesgo de sobreajuste, se puede aplicar técnicas de regularización (como L1 o L2), para mejorar la capacidad de generalización. Si bien se trabaja con volúmenes elevados de datos, conviene recurrir a procesamiento en paralelo o aprovechar el uso de GPU para optimizar los tiempos de entrenamiento.

Finalmente, se debe tener en cuenta que la implementación en Python planteada corresponde a un modelo base y, por lo tanto, requiere ajustes específicos según las características de los datos y el objetivo del análisis. Las anteriores consideraciones se relacionan al modelo acoplado de [9]

Resultados

En esta sección se exponen los resultados derivados de la implementación del modelo de las RNA aplicado al pronóstico. Para facilitar su análisis, los valores se organizan en tablas comparativas donde se incluyen los pronósticos estadísticos junto con los obtenidos mediante la RNA en diferentes topologías.

Posterior, dichos resultados fueron representados gráficamente para cada uno de los ítems dentro del código para su análisis y su proyección estadística obtenidas a través de las RNA, lo que permite identificar las diferencias en los comportamientos entre ambos enfoques y valorar el nivel de ajuste que ofrece cada metodología.

Prueba 1:




Ilustración 9 Topología I

Fuente: Elaboración Propia

Prueba 2:




Ilustración 10 Topología II

Fuente: Elaboración Propia

Comprobación de la prueba

En un proceso de investigación, no siempre los datos cumplen con los supuestos de normalidad que exigen muchas pruebas estadísticas tradicionales, por esta razón, cuando se busca comparar el desempeño de dos métodos de pronósticos, para este caso, uno de base técnica estadística y otro mediante RNA, resulta adecuado recurrir a procedimientos paramétricos que brinden resultados confiables sin depender de dichos supuestos. La prueba de los signos de Kendall se convierte en una herramienta útil para determinar si las diferencias encontradas entre ambos

enfoques son lo suficientemente consistentes para afirmar que una supera al otro en precisión [9].

Descripción

La prueba de los signos de Kendall corresponde a un procedimiento estadístico de tipo paramétrico, diseñado para comparar dos métodos cuando los datos no cumplen con el supuesto de normalidad. Su finalidad es establecer con que grado de confianza puede afirmarse que un método analizado ofrece un mejor comportamiento, de acuerdo con [9], el análisis se basa en contabilizar las diferencias positivas y negativas entre ambos métodos y verificar las tendencias de esas diferencias.

Aplicación

Para la investigación, la prueba se aplicó para confrontar los resultados obtenidos mediante un enfoque estadístico tradicional contra los generados por la RNA, para ello se calcularon los errores absolutos entre las series o ítems y los valores pronosticados para cada método.

El procedimiento consiste en obtener las diferencias entre ambos métodos, eliminar los casos donde estas coincidían, y contabilizar cuantas veces el resultado favorecía a las RNA frente al modelo estadístico, a partir de este propósito y mediante las tablas de referencias de [9], se determinó el nivel de confianza que permite establecer si el desempeño de las RNA resultó más preciso en comparación con el enfoque estadístico.

Prueba 1:

ítem	v	V2	v<V (%)	z	Nivel de Confianza
3	29	78	37%	-2,26455	1,2%
5	41	78	53%	0,452911	67,5%
10	31	78	40%	-1,81164	3,5%
9	37	78	47%	-0,45291	32,5%
8	54	78	69%	3,396831	100,0%
1	37	78	47%	-0,45291	32,5%
12	29	78	37%	-2,26455	1,2%
13	35	78	45%	-0,90582	18,3%
14	42	78	54%	0,679366	75,2%
4	36	78	46%	-0,67937	24,8%
15	36	78	46%	-0,67937	24,8%

Tabla 3 Nivel de confianza Topología I

Fuente: Elaboración propia




Ilustración 11 Grafico Nivel de Confinza Topología I

Fuente: Elaboración Propia

Prueba 2:

ítem	v	V2	v<V (%)	z	Nivel de Confinza
3	40	78	51%	0,2265	59%
5	41	78	53%	0,4529	67%
10	39	78	50%	0,0000	50%
9	42	78	54%	0,6794	75%
8	38	78	49%	-0,2265	41%
1	38	78	49%	-0,2265	41%
12	35	78	45%	-0,9058	18%
13	39	78	50%	0,0000	50%
14	60	78	77%	4,7556	100%
4	43	78	55%	0,9058	82%
15	45	78	58%	1,3587	91%

Tabla 4 Nivel de confianza Topología II

Fuente: Elaboración propia

Nivel de Confinza -Topología II




Ilustración 12 Grafico Nivel de Confianza Topología II

Fuente: Elaboración Propia

Consideraciones sobre las métricas de desempeño

Como se observa en la literatura en el aprendizaje automático, métricas de precisión, recall y accuracy se emplean típicamente para tareas de clasificación, mientras que en contextos de regresión y pronósticos se prefiere medidas como MAE, RMSE o MAPE para cuantificar el error entre los valores reales y estimados [26]. Además, en estudios aplicados de modelos predictivos se han utilizados MAPE, MAE y RMSE como elementos de comparación, entre técnicas de pronósticos. Por lo tanto, para este trabajo dada la naturaleza de las series numéricas de inventarios, se considera importante las métricas de error como referencia conceptual antes de aplicar la prueba de los signos de kendall.

Análisis:

La tabla N° 3 muestra los resultados de la aplicación de la prueba de los signos de Kendall a la Topología I, en la cual se evaluaron los comportamientos de la RNA frente al enfoque estadístico tradicional. Los hallazgos evidencian en términos generales que esta configuración no alcanza niveles de confianza altos, ya que la mayoría de los ítems se concentran por debajo del 50%, lo que permite identificar que para el caso de la RNA no logro demostrar que es mejor que el pronóstico estadístico. A pesar de estos resultados puntuales, el comportamiento global de la topología I es más bien irregular, indicando que su desempeño depende fuertemente de las condiciones bajo las cuales fue entrenada.

En contraste, la topología II ofrece un desempeño más estable y con resultados más favorables en varios ítems, donde los niveles de confianza superan con amplitud el umbral del 60%. También se observa valores intermedios, que refuerzan la evidencia de un rendimiento consistente, si bien, algunos ítems reflejan un

comportamiento similar al modelo estadístico, lo cual demuestra una tendencia que la RNA en esta topología logra un mejor ajuste y ofrece confiabilidad.

Es importante señalar que estos resultados no dependen únicamente del contraste puntual entre las técnicas, sino también de factores asociados al diseño y el entrenamiento de la RNA, entre ellos se destaca la cantidad y calidad de los datos históricos empleados, ya que estos permiten saber que tan delimitado va ser el volumen de uso y restringe la capacidad de aprendizaje de la red, también, el número de neuronas y capas ocultas implementadas, debido a que determinan la complejidad de la red y la habilidad para captar patrones no lineales o series temporales y finalmente los parámetros de entrenamiento y regularización que básicamente influye en la convergencia y la reducción sobre ajustada.

En este sentido, el desempeño más robusto de la topología II puede estar asociado a una mejor configuración de estas variables, lo que favorece la capacidad predictiva del modelo, no obstante, la eficiencia final de las RNA está estrechamente vinculadas a las decisiones de diseño y volumen de información utilizada, lo que resulta de gran importancia para ajustes futuros a estos parámetros.

Discusión

El análisis realizado evidencio que la empresa caso de estudio se encuentra en un nivel de madurez tecnológica primaria, lo que implica que su capacidad de adaptación a herramientas digitales es aún limitada. Esta situación coincide con lo planteado por [22], quienes señalan que muchas de las pymes colombianas presentan rezagos significativos en la integración de tecnologías dentro de sus procesos productivos, en este sentido, esto representa un reto para alcanzar una transformación organizacional más profunda.

La aplicación del método ABC permitió identificar que la concentración de ventas se encuentra en un grupo reducido de ítems, clasificando once de los quince en categoría A, este hallazgo reafirma lo señalado por [17], en cuanto a que no todos los productos tienen el mismo impacto financiero y, por lo tanto, requieren políticas diferenciadas de control. La concentración en pocos artículos también explica la vulnerabilidad de la empresa ante desabastecimientos, ya que la falta de control en estos productos críticos puede generar interrupciones directas en la producción.

Por otra parte, la aplicación del modelo de ARIMA en el pronóstico de los ítems tipo A demostró su capacidad para ajustarse a los patrones históricos de consumo, ofreciendo proyecciones con un grado de realismo aceptable. No obstante, al comparar sus resultados con los obtenidos mediante la RNA, se evidencio que estas últimas poseen una mayor capacidad para identificar tendencias no lineales y captar comportamientos estacionales complejos. Estos hallazgos coinciden con lo señalado por los autores como [9], quienes resaltan el potencial de las RNA para superar las limitaciones de los métodos estadísticos tradicionales. En consecuencia,

aunque ARIMA continúa siendo una herramienta sólida, el uso de técnicas de aprendizaje automático se presenta como una alternativa en escenarios caracterizados por una alta variabilidad en la demanda.

Asimismo, la selección diferenciada de modelos de control de inventarios según la clasificación resulta fundamental para optimizar los recursos de la empresa. Mientras que el modelo EOQ fue pertinente para los ítems de mayor rotación, el sistema de revisión periódica y los métodos simples, resultaron suficientes para los productos clases B y C. Esta adaptación metodológica no solo valida lo propuesto por la literatura [17], sino que también refuerza la idea de que la eficiencia en la gestión de inventarios depende de un diseño flexible que se ajuste a las características específicas de cada empresa.

Finalmente, la implementación de la RNA evidenció un mayor nivel de precisión en los pronósticos en comparación con los métodos convencionales. Este resultado reviste especial importancia, pues confirma la viabilidad de aplicar técnicas de IA en entornos empresariales rurales con limitaciones tecnológicas, siempre que se cuente con registros históricos adecuados. Sin embargo, también se reconoce que la efectividad de las RNA está condicionada por factores como la calidad de los datos, la definición de la arquitectura y el proceso de entrenamiento, aspectos que aún no se encuentran plenamente desarrollados en la empresa caso de estudio.

En conjunto, los resultados permiten afirmar que la transición hacia un sistema de control de inventarios apoyado de técnicas avanzadas representa una oportunidad clave para la empresa. Sin embargo, este proceso debe ir acompañado de un fortalecimiento en la cultura tecnológica y la planeación estratégica, de manera que la digitalización no se limita al control de inventarios, sino que se integre como un eje transversal de la gestión empresarial de cada empresa.

Conclusiones

- La investigación permitió demostrar que las RNA representan una alternativa viable para el pronóstico y control de los inventarios en las Pymes, al ofrecer resultados superiores en determinados ítems frente a los métodos estadísticos tradicionales. Estos hallazgos refuerzan la premisa de que la capacidad de las RNA para modelar relaciones no lineales constituye una ventaja significativa en entornos caracterizados por una alta variabilidad de la demanda.
- El análisis del nivel de madurez digital de la empresa caso estudio mostro que, aunque existe un uso inicial de herramientas como Excel, aún persisten limitaciones para la adopción de modelos avanzados inteligentes por medio de la inteligencia artificial. Estos hallazgos coinciden con estudios que señalan la necesidad de fortalecer las competencias digitales en las Pymes antes de emprender procesos de transformación tecnológica.
- La aplicación de la prueba de los signos permitió realizar una comparación objetiva entre los pronósticos estadísticos y los obtenidos mediante la RNA.

Si bien no en todos los casos se evidencio diferencia significativa, se identificaron ítems con niveles de confianza superiores al 80%, lo que valida el potencial de las RNA como un recurso solido de apoyo para la gestión de inventarios.

- La metodología planteada, estructura en cinco etapas (diagnóstico, madurez digital, control de inventarios, implementación de RNA y caso de estudio), demostrando ser un marco práctico y adaptable para empresas de recursos limitados, ofreciendo una ruta progresiva hacia la digitalización.
- Si bien los resultados son prometedores, su alcance depende en gran medida de factores como la cantidad y calidad de los datos históricos, la correcta definición de la arquitectura de la RNA (número de capas y neuronas) y la disposición organizacional para asumir cambios tecnológicos.
- El análisis de madurez digital evidencio que este instrumento no solo permite diagnosticar el nivel de preparación tecnológica de la organización, sino que también constituye un factor clave para valorar la viabilidad de implementar soluciones avanzadas como las RNA. Un nivel bajo de madurez puede restringir el impacto de estas herramientas, mientras que un entorno más desarrollado favorece su integración y sostenibilidad en el largo plazo.
- Los hallazgos muestran que la problemática del control de los inventarios trasciende de la simple gestión de las existencias, ya que está directamente vinculado con la capacidad de la Pyme para tomar decisiones estratégicas en escenarios de incertidumbre. En este sentido, la incorporación gradual de herramientas de IA como las RNA soportadas en procesos de maduración digital, constituye una vía sólida para incrementar la eficiencia operativa y fortalecer la competitividad en mercados dinámicos.

Recomendaciones

- Considerar la posibilidad de complementar el modelo ABC tradicional con enfoques más dinámicos que respondan mejor a la volatilidad de la demanda, evitando así limitaciones en la segmentación del producto.
- Ampliar el estudio a un número de empresas de diferentes sectores, con el fin de validar la aplicabilidad del modelo en contextos más variables y robustos para observar el comportamiento.
- Explorar la incorporación de otros algoritmos de aprendizaje automático, como es el caso de máquinas de soporte vectorial, bosques aleatorios, o redes LSTM y constatarlos con la RNA para determinar cual ofrece mayor precisión en escenarios de demanda fluctuante.
- Incrementar la base de datos históricos disponibles para el entrenamiento de las RNA, ya que un mayor volumen y diversidad de datos fortalece la capacidad predictiva del modelo y reduce el riesgo de sobreajuste.

- Integrar el modelo de pronóstico con sistemas de información empresariales (ERP o plataformas en la nube) para automatizar el control de los inventarios y facilitar su aplicación en tiempo real.
- Realizar estudios longitudinales que permitan evaluar el impacto de la adopción de la RNA en el desempeño organizacional a largo plazo, considerando indicadores como reducción de costos, mejorando en los niveles de servicio y optimización de inventarios.
- Incorporar conexiones del modelo con sistemas ERP o MRP II, facilitando la automatización del control de inventarios y asegurando su estabilidad en la operación real de las empresas.

REFERENCIAS

- [1] G. B. Areous, W. Eichhörn, and J. M. Rodríguez, "Las transformaciones tecnológicas y sus desafíos para el empleo, las relaciones laborales y la identificación de la demanda de cualificaciones," Documentos De Proyectos, nov. 2017, [Online]. Available: <https://ideas.repec.org/p/ecr/col022/42539.html>
- [2] S. Nadkarni and R. Prügl, "Digital transformation: a review, synthesis and opportunities for future research," Management Review Quarterly, vol. 71, no. 1, pp. 233–341, 2020, doi: <https://doi.org/10.1007/s11301-020-00185-7>.
- [3] P. Chen and S. Kim, "The impact of digital transformation on innovation performance - The mediating role of innovation factors," Heliyon, vol. 9, no. 3, p. e13916, Feb. 2023, doi: <https://doi.org/10.1016/j.heliyon.2023.e13916>.
- [4] K. Ellingrud et al., "Generative AI and the Future of Work in America | McKinsey," www.mckinsey.com, Jul. 26, 2023. <https://www.mckinsey.com/mgi/our-research/generative-ai-and-the-future-of-work-in-america>
- [5] M. Díaz, R. Román, G. Santana y M. Morales, "La industria 4.0 y las redes neuronales artificiales en la ingeniería industrial: Una revisión sistemática de la literatura". Jul. 2023. [Online]. Available: https://www.researchgate.net/profile/Marco-Diaz-Martinez-2/publication/372400196_La_industria_40_y_las_redes_neuronales_artificiales_en_la_ingenieria_industrial_Una_revisi3n_sistematica_de_la_literatura/links/64b402fac41fb852dd7b63a3/La-industria-40-y-las-redes-neuronales-artificiales-en-la-ingenieria-industrial-Unarevisi3n-sistematica-de-la-literatura.pdf.
- [6] OECD. (2021). The Digital Transformation of SMEs. Organisation for Economic Co-operation and Development. [En línea]. Disponible en: <https://www.oecd.org/>
- [7] [24] Banco Interamericano de Desarrollo (BID). (2020). "Pequeñas empresas y digitalización en América Latina: Obstáculos y oportunidades". [En línea]. Disponible en: <https://publications.iadb.org>

- [8] J. Barba, C. Quinde, L. Cevallos y C. Rendon, "Aplicación de redes neuronales artificiales para la toma de decisiones en el control de inventarios de una despensa ubicada en la ciudad de Guayaquil". Sep. 2019, [Online] https://www.researchgate.net/publication/335684126_Aplicacion_de_redes_neuronales_artificiales_para_la_toma_de_decisiones_en_el_control_de_inventarios_de_una_despensa_ubicada_en_la_ciudad_de_Guayaquil
- [9] S. Nojek, P. Britos, B. Rossi y R. G. Martínez, "Pronóstico de ventas: comparación de predicción entre redes neuronales y método estadístico", *Rev. Electronica Cienc. Adm.*, vol. 2, n.º 1, pp. 1–18, mayo de 2003. Accedido el 21 de abril de 2024. [En línea]. Disponible: <https://doi.org/10.5329/recadm.20030201008>
- [10] U. Praveen, G. Farnaz y G. Hatim, "Inventory management and cost reduction of supply chain processes using AI based time-series forecasting and ANN modeling", *Procedia Manuf.*, vol. 38, pp. 256–263, 2019. Accedido el 22 de abril de 2024. [En línea]. Disponible: <https://doi.org/10.1016/j.promfg.2020.01.034>
- [11] D. A. C. Dueñas, L. Á. L. González, E. T. R. Orjuela, and F. J. Tiboche, "Diseño de un sistema para la gestión de inventarios de las pymes en el sector alimentario," *Industrial Data*, vol. 22, no. 1, pp. 113–132, jul. 2019, doi: 10.15381/idata.v22i1.16530.
- [12] T. V. L. Angel, "Las tecnologías de la información y comunicación en las pequeñas y medianas empresas de servicios jurídicos en Tijuana, Baja California, México," 2021. <https://repositorioinstitucional.uabc.mx/handle/20.500.12930/7903>
- [13] C. Rohvein, M. Jaureguiberry, S. Urrutia, G. Roark, F. J. Chiodi, and D. Paravié, "MATURITY MODEL AS FOUNDATIONS OF A SME PROCESS MANAGEMENT DIAGNOSIS," *Revista Ingeniería Industrial*-, Mar. 2019, [Online]. Available: <https://revistaschilenas.uchile.cl/handle/2250/133500>
- [14] M. Rossini, A. Ahmadi, and A. P. Staudacher, "Applying a process-centric approach to the digitalization of operations in manufacturing companies: a case study," *Procedia Computer Science*, vol. 232, pp. 1141–1150, Jan. 2024, doi: 10.1016/j.procs.2024.01.112.
- [15] O. L. Ochoa, "Modelos de madurez digital: ¿En qué consisten y qué podemos aprender de ellos?," *BOLETIN DE ESTUDIOS ECONOMICOS*, vol. 71, no. 219, pp. 573–590, Jan. 2016, [Online]. Available: <https://dialnet.unirioja.es/servlet/articulo?codigo=5808328>
- [16] O. L. Ochoa, "Modelos de madurez digital: ¿En qué consisten y qué podemos aprender de ellos?," *ResearchGate*, vol. 71, no. 219, pp. 573–590, Jan. 2016, [Online]. Available: <https://dialnet.unirioja.es/servlet/articulo?codigo=5808328>

- [17] C. Osorio García, “Modelos para el control de inventarios en las pymes,” *Panorama*, vol. 2, no. 6, 2008. [En línea]. Disponible en: <https://www.redalyc.org/articulo.oa?id=343929218002>
- [18] IBM Corporation, “¿Qué es un modelo ARIMA?”, IBM Think, [en línea]. Disponible en: <https://www.ibm.com/es-es/think/topics/arima-model>. [Accedido: 25-jul-2025].
- [19] “Argelia – Valle del Cauca ‘Con gestión, seguridad y trabajo’ PLAN DE DESARROLLO MUNICIPAL.” <https://1library.co/document/7qv9ogly-argelia-valle-cauca-gestion-seguridad-trabajo-desarrollo-municipal.html>
- [20] L. M. Díaz & S. J. García Una mirada al contrato por obra o labor en Colombia. [online]. Disponible en: <https://hdl.handle.net/20.500.14625/29514>
- [21] Slimstock, “Los desafíos al gestionar el inventario con Excel,” Slimstock, Aug. 07, 2019. <https://www.slimstock.com/es/blog/los-errores-al-gestionar-el-inventario-con-excel/>
- [22] E. Z. Galindo, “Modelos de madurez digital en Pymes – caso de estudio de una Pyme de telecomunicaciones de Colombia,” Universidad Nacional De Colombia, Jan. 2020, [Online]. Available: <https://repositorio.unal.edu.co/handle/unal/77419>
- [23] S. Wynn and J. R. Kuhn Jr., "The financial impact of manual inventory record errors," *International Journal of Business and Social Science*, vol. 12, no. 10, pp. 4–11, Oct. 2021. [Online]. Available: https://ijbssnet.com/journals/Vol_12_No_10_October_2021/2.pdf
- [24] O. Çaylı and Z. Oralhan, “Artificial Intelligence-Driven Inventory Management: Optimizing Stock Levels and Reducing Costs Through Advanced Machine Learning Techniques,” *The European Journal of Research and Development*, vol. 4, no. 4, pp. 427–439, 2024. doi: 10.56038/ejrnd.v4i4.615.
- [25] C. A. Mitrea, C. K. M. Lee y Z. Wu, "A Comparison between Neural Networks and Traditional Forecasting Methods: A Case Study," *International Journal of Engineering Business Management*, vol. 1, no. 2, pp. 19-24, 2009. Doi: (PDF) A Comparison between Neural Networks and Traditional Forecasting Methods: A Case Study
- [26] J. Kaliappan, K. Srinivasan, S. M. Qaisar, K. Sundararajan, C.-Y. Chang y C. Suganthan, “Performance Evaluation of Regression Models for the Prediction of the COVID-19 Reproduction Rate,” *Frontiers in Public Health*, vol. 9, Art. 729795, 2021

ANEXOS

Anexo 1. Modelo en colab Red Neuronal Artificial

[Modelo RNA](#)

Anexo 2. Tabla de datos signos de Kendall Topología I

Topología I

ítem	v	V2	v<V (%)	z	Nivel de Confianza
3	29	78	37%	-2,26455	1,2%
5	41	78	53%	0,452911	67,5%
10	31	78	40%	-1,81164	3,5%
9	37	78	47%	-0,45291	32,5%
8	54	78	69%	3,396831	100,0%
1	37	78	47%	-0,45291	32,5%
12	29	78	37%	-2,26455	1,2%
13	35	78	45%	-0,90582	18,3%
14	42	78	54%	0,679366	75,2%
4	36	78	46%	-0,67937	24,8%
15	36	78	46%	-0,67937	24,8%

Anexo 3. Tabla de datos signos de Kendall Topología II

Topología II

ítem	v	V2	v<V (%)	z	Nivel de Confianza
3	40	78	51%	0,2265	59%
5	41	78	53%	0,4529	67%
10	39	78	50%	0,0000	50%
9	42	78	54%	0,6794	75%
8	38	78	49%	-0,2265	41%
1	38	78	49%	-0,2265	41%
12	35	78	45%	-0,9058	18%
13	39	78	50%	0,0000	50%
14	60	78	77%	4,7556	100%
4	43	78	55%	0,9058	82%
15	45	78	58%	1,3587	91%