



POSGRADOS

Maestría en
**PRODUCCIÓN Y
OPERACIONES INDUSTRIALES**

RPC-SO-30-NO.506-2019

Opción de Titulación:

Artículos profesionales de alto nivel

Tema:

**COMPARACIÓN DE MODELOS DE
SERIES TEMPORALES PARA EL
PRONÓSTICO DE LA DEMANDA
SEMANAL DE COCINAS EN UNA
EMPRESA MANUFACTURERA DE
LA CIUDAD DE GUAYAQUIL.**

Autor

SERGIO ANDRÉS ESCUDERO LAINEZ

Director:

Luis Daniel Caamaño Gordillo

GUAYAQUIL – Ecuador

2026

Autor:



Sergio Andrés Escudero Lainez
Ingeniero Industrial
Candidato a Magíster en Producción y Operaciones
Industriales por la Universidad Politécnica Salesiana – Sede
Guayaquil.
Sergio.escudero1@ups.edu.ec

Dirigido por:



Luis Daniel Caamaño Gordillo
Ingeniero Industrial
Máster en Gestión de la Productividad y la Calidad
lcaamano@ups.edu.ec

Todos los derechos reservados.

Queda prohibida, salvo excepción prevista en la Ley, cualquier forma de reproducción, distribución, comunicación pública y transformación de esta obra para fines comerciales, sin contar con autorización de los titulares de propiedad intelectual. La infracción de los derechos mencionados puede ser constitutiva de delito contra la propiedad intelectual. Se permite la libre difusión de este texto con fines académicos investigativos por cualquier medio, con la debida notificación a los autores.

DERECHOS RESERVADOS

2026 © Universidad Politécnica Salesiana.

GUAYAQUIL – ECUADOR – SUDAMÉRICA

Sergio Andrés Escudero Lainez

Comparación de Modelos de Series Temporales para el Pronóstico de la Demanda Semanal de Cocinas en una Empresa Manufacturera de la Ciudad de Guayaquil

DEDICATORIA

Dedico este trabajo, con profunda gratitud y cariño, a mis padres Washington Escudero Doltz y Sofía Lainez Araúz, cuyo sacrificio, esfuerzo constante y fe inquebrantable en mi futuro hicieron posible mi formación y me enseñaron el valor de la perseverancia. A mi esposa Gladys Macías Zambrano por su apoyo firme, su constancia diaria al empujarme a avanzar incluso cuando el cansancio pesaba más que las ganas, le agradezco por ser mi impulso y mi equilibrio. Y me lo dedico también a mí mismo, por las horas de estudio, la dedicación sostenida y el crecimiento personal alcanzado en esta etapa, que representa no solo un logro académico, sino un paso significativo en mi desarrollo y en la construcción del futuro que quiero.

AGRADECIMIENTO

Quiero expresar mi más profundo agradecimiento a mis padres, Washington Escudero Doltz y Sofía Lainez Arauz, quienes hicieron posible mi formación académica gracias a su esfuerzo, respaldo y confianza permanente. Su dedicación y sacrificio han sido el pilar fundamental que me permitió llegar hasta este punto.

A mi esposa, Gladys Macias Zambrano, le agradezco de manera muy especial por su motivación constante, por presionarme cuando lo necesité y por recordarme siempre la importancia de culminar este trabajo. Su apoyo emocional y su empuje diario fueron decisivos para que pudiera completar esta etapa.

Agradezco también al Ing. Luis Daniel Caamaño Gordillo, Msc, por las orientaciones brindadas durante el desarrollo del artículo. Finalmente, expreso mi reconocimiento a la empresa que facilitó los datos necesarios para este estudio — manteniendo su identidad en confidencialidad— por la apertura y colaboración que hicieron posible el análisis realizado.

Tabla de Contenido

Resumen	8
Abstract	9
1. Introducción	10
2. Determinación del Problema.....	11
3. Marco teórico referencial.....	12
4. Materiales y metodología.....	13
4.1 Series de Tiempo: Conceptos Básicos y Aplicaciones en Pronósticos de Demanda.	15
4.2 Promedio Móvil Simple (PMS) y Ponderado (PMP)	16
4.3 Suavización Exponencial Simple (SES).	17
4.4 Redes Neuronales Artificiales (RNA)	18
4.5 Métricas de evaluación de pronósticos.....	20
4.6 Planificación de producción basada en pronósticos.	21
5. Resultados y discusión.....	23
5.1 Resultados.	23
5.2 Discusión.....	31
6. Conclusiones.....	34
Referencias	36

Índice de ecuaciones

Promedio móvil simple.....	14
Promedio Móvil Ponderado.....	14
Suavización Exponencial Simple.....	14
Bias.....	14
MAE.....	14
MAPE.....	14
RMES.....	14
R^2	14

|

**COMPARACIÓN DE
MODELOS DE SERIES
TEMPORALES PARA EL
PRONÓSTICO DE LA
DEMANDA SEMANAL
DE COCINAS EN UNA
EMPRESA
MANUFACTURERA DE
LA CIUDAD DE
GUAYAQUIL.**

Autor:

SERGIO ANDRES ESCUDERO LAINEZ

Resumen

La planificación de producción en manufactura requiere pronósticos precisos. El presente estudio compara modelos de pronóstico para optimizar la producción de cocinas. El objetivo de la presente investigación es evaluar cuatro metodologías de pronóstico para determinar la más efectiva en la predicción de producción semanal de cocinas. Para ellos se analizaron 48 semanas de producción utilizando promedio móvil simple, promedio móvil ponderado, suavización exponencial simple y red neuronal artificial. Las métricas de evaluación incluyeron MAPE, MAE, RMSE, Bias y R^2 para comparar objetivamente el desempeño predictivo de cada modelo. Los resultados de la investigación demostraron que la red neuronal artificial es superioridad significativa con MAPE de 8.52% y R^2 de 0.783, representando una mejora del 53.8% sobre el mejor modelo tradicional. Los métodos convencionales mostraron limitaciones para capturar patrones no lineales, con MAPE entre 18.03-21.43%. La RNA redujo el error absoluto promedio a 244 unidades frente a 501-571 unidades de los otros modelos. Se puede concluir que las redes neuronales constituyen la alternativa óptima para pronósticos de producción en la industria manufacturera de cocinas.

Palabras clave:

Pronóstico de producción; Redes neuronales artificiales; Series de tiempo; Optimización de producción; Planificación de operaciones.

Abstract

Production planning in manufacturing requires accurate forecasts. This study compares forecasting models to optimize stove production. The objective of this research is to evaluate four forecasting methodologies to determine the most effective one for predicting weekly stove production. To this end, 48 weeks of production were analyzed using simple moving average, weighted moving average, simple exponential smoothing, and artificial neural network. The evaluation metrics included MAPE, MAE, RMSE, Bias, and R^2 to objectively compare the predictive performance of each model. The results of the research demonstrated that the artificial neural network is significantly superior with a MAPE of 8.52% and an R^2 of 0.783, representing a 53.8% improvement over the best traditional model. Conventional methods showed limitations in capturing non-linear patterns, with MAPE between 18.03-21.43%. The ANN reduced the mean absolute error to 244 units compared to 501-571 units for the other models. It can be concluded that neural networks are the optimal alternative for production forecasting in the kitchen manufacturing industry.

Palabras clave:

Production forecasting; Artificial neural networks; Time series; Production; Operations planning.

1. Introducción

La planificación eficiente de la producción es un factor clave para la competitividad en empresas manufactureras, especialmente en sectores con alta variabilidad de demanda. En este caso al tratarse de una empresa dedicada a la fabricación y comercialización de cocinas domésticas ubicada en la ciudad de Guayaquil, se identificó la falta de un modelo de pronóstico formal como una limitación importante al momento de tomar decisiones. Hasta el momento, las estimaciones de demanda se hacen de forma empírica, partiendo de la experiencia de los colaboradores y los registros generales de la historia, lo que no permite reaccionar de manera rápida y precisa a los cambios del mercado.

Varios estudios han constatado que la falta de herramientas estadísticas adecuadas para anticipar la demanda afecta la eficiencia operativa, gestión de inventario y la satisfacción del cliente (Ojeda Villacrés & Sánchez, 2018), (CAF, 2023). Las características mencionadas permiten ver el uso de modelos de series temporales como una herramienta para aumentar la capacidad predictiva de la empresa.

Este estudio tiene como objetivo comparar distintos modelos de series temporales utilizados para el pronóstico de la demanda semanal en una empresa manufacturera para identificar la opción más precisa dentro de su implementación en el entorno productivo. Esta investigación busca contribuir al fortalecimiento en la toma de decisiones estratégicas al optimizar el uso de recursos y mejorar la capacidad de respuesta de las empresas frente a las necesidades del consumidor.

2. Determinación del Problema

La empresa objeto de estudio pertenece al sector manufacturero. Y enfrenta un gran desafío respecto a su planificación semanal. Tiene la necesidad de un Sistema de pronóstico de demanda, que sea confiable y tenga una mayor precisión. Este problema ha provocado inconsistencias recurrentes entre la oferta de la empresa y la demanda real del mercado, causando una afectación directa en la eficiencia operativa.

En las semanas de mayor demanda existe una sobreproducción, causando que los niveles de inventarios superen hasta el 12% los límites óptimos. Esto causa un aumento en costos de almacenamiento y desperdicios en insumos. Por el contrario, en las semanas de producción regular-baja, la empresa ha incurrido en horas extras para dar cumplimiento a pedidos críticos, seguido de paros no planeadas por no contar con la materia prima requerida, esto muestra una falta de coordinación en la gestión de recursos.

Todas estas inconsistencias derivan en pérdidas mensuales estimadas de 5000 unidades, esto representa el 10% de las ventas potenciales. Además del impacto financiero, la empresa pierde credibilidad frente a los clientes, los cuales al no encontrar una disponibilidad inmediata del producto prefieren adquirir marcas competidoras afectando la participación en el mercado de la empresa.

Frente a todas estas situaciones descritas, se vuelve necesario desarrollar una solución práctica que sincronice la producción con la demanda real al implementar un modelo estadístico de pronóstico el cual se plantea como una herramienta fundamental para subsanar estas situaciones, mejorar la eficiencia operativa y recuperar la competitividad de la empresa.

3. Marco teórico referencial

Analizar los modelos de pronóstico para la producción semanal de cocinas requiere la aplicación de técnicas estadísticas y herramientas de inteligencia artificial que permitan identificar patrones de tiempo que estén presentes en los datos (Kontopoulou y otros, 2023). Con base en esta necesidad de la empresa se requiere identificar métodos tanto tradicionales como avanzados, sus características, ventajas y limitaciones (Abbaspour Ghadim Bonab, 2021).

Se tiene en consideración aproximaciones simples, como promedios móviles y suavización exponencial hasta los modelos más complejos como ARIMA y redes neuronales artificiales (RNA) (Manobanda Vega, 2020), estos ofrecen soluciones más específicas cuando se trata de tendencias, estacionalidad y variabilidad en las series de tiempo. (Kontopoulou y otros, 2023).

Para elegir el modelo adecuado se debe tener consideración la naturaleza de los datos y factores como el nivel de precisión requerido, disponibilidad de información histórica y capacidad computacional (Wahedi y otros, 2022).

4. Materiales y metodología

Para el desarrollo de la investigación se utilizó un historial de datos de producción semanal correspondiente a 48 semanas de operación de la planta manufacturera, comprendidas entre la primera semana de julio de 2024 y la cuarta semana de junio de 2025. Los datos fueron proporcionados por el departamento de producción de la empresa y consistieron en valores numéricos de unidades producidas por semana. El software empleado para el procesamiento de datos e implementación de modelos incluyó Microsoft Excel versión 365 para los métodos de pronóstico tradicionales y MATLAB R2023a con el toolbox de Deep Learning para el desarrollo de la red neuronal artificial (Adame Escobar & Espejo Mora, 2025).

El diseño metodológico se basó en un estudio comparativo de cuatro técnicas de pronóstico aplicadas a la misma serie temporal. La variable dependiente medida fue el volumen de producción semanal expresado en unidades de cocinas, mientras que la variable independiente consistió en el tiempo expresado en semanas consecutivas. Para validar los métodos, se implementó una estrategia de evaluación mediante métricas de precisión que permitieron comparar objetivamente el desempeño de cada modelo (Dorado Gonzales & Velásquez Robayo, 2020).

Los procedimientos iniciaron con la recolección y organización de los datos históricos en una hoja de cálculo. Para el modelo de Promedio Móvil Simple se calculó la media aritmética de tres periodos anteriores (1), mientras que para el Promedio Móvil Ponderado se asignaron pesos diferenciales de 0,83 al periodo más reciente, 0,10 al intermedio y 0,17 al más antiguo (2). La Suavización Exponencial Simple se implementó con un factor de suavizada alfa de 0,9, privilegiando así los datos más recientes (3). Para la red neuronal artificial se utilizó un algoritmo de retro propagación con regularización bayesiana (trainbr), configurando una arquitectura de una capa oculta con catorce neuronas y función de activación tangente hiperbólica. La división de datos se realizó en proporciones de 80% para entrenamiento, 10% para validación y 10% para prueba.

$$\text{Promedio móvil simple: } PMS = \frac{y_t + y_{t-1} + y_{t-2}}{3} \quad (1)$$

$$\text{Promedio Móvil Ponderado } PMS = \frac{0.83y_t + 0.10y_{t-1} + 0.17y_{t-2}}{3} \quad (2)$$

$$\text{Suavización Exponencial Simple } SES = 0.9y_t + 0.1 SES_{t-1} \quad (3)$$

El análisis de datos se realizó mediante la aplicación de cuatro métricas de evaluación: el sesgo (BIAS) para medir la tendencia direccional del error (4), el error absoluto medio (MAE) para cuantificar la magnitud promedio de los errores (5), el error porcentual absoluto medio (MAPE) para expresar la precisión en términos relativos (6), la raíz del error cuadrático medio (RMSE) que evalúa la precisión del modelo penalizando grandes errores (7) y el coeficiente de determinación (R^2) para evaluar la proporción de varianza explicada por cada modelo (8) (Herrera Ramos, 2019).

$$Bias = \frac{1}{n} \sum_{i=1}^n (Y_{Pi} - Y_{Ri}) \quad (4)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_{Pi} - Y_{Ri}| \quad (5)$$

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{Y_{Pi} - Y_{Ri}}{Y_{Ri}} \right| \quad (6)$$

$$RMES = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_{Pi} - Y_{Ri})^2} \quad (7)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (Y_{Ri} - Y_{Pi})^2}{\sum_{i=1}^n (Y_{Ri} - \widehat{Y}_R)^2}; \quad \widehat{Y}_R = \frac{1}{n} \sum_{i=1}^n Y_{Ri} \quad (8)$$

donde:

n = número de observaciones.

Y_{Pi} = Valor pronosticado de la producción.

Y_{Ri} = Valor real de producción.

\widehat{Y}_R = Promedio de los valores reales de producción.

4.1 Series de Tiempo: Conceptos Básicos y Aplicaciones en Pronósticos de Demanda.

Se considera las series de tiempo Como una secuencia de datos que están ordenados de manera cronológica y son utilizados para el análisis del comportamiento de las variables a través de periodos determinados de tiempo. Estos datos generalmente presentan como componentes (Usta Díaz & López Ríos, 2023). La tendencia que incluye el crecimiento o decrecimiento a largo plazo., estacionalidad que involucra los patrones que se repiten en ciclos fijos, semanas o meses., ciclista, ciudad que incluye las fluctuaciones no periódicas, además del ruido aleatorio, que implica variaciones no sistemáticas (Huillca Díaz, 2024). En la industria, el análisis de series temporales permite la identificación de patrones históricos de demanda, facilitando la toma de decisiones y haciendo que éstas se basen en evidencia empírica (Dorado Gonzales & Velásquez Robayo, 2020).

Contextualizando esto en la producción de cocinas, se puede decir que los pronósticos de demanda semanales requieren un estudio detallado de los componentes, porque factores como la temporada alta de venta o tendencias en el mercado pueden influir de manera significativa dentro de los resultados (Usta Díaz & López Ríos, 2023). El uso de herramientas gráficas como los diagramas de dispersión o la descomposición de series puede ser útil para visualizar estos comportamientos y determinar cuál puede ser la metodología más adecuada por el pronóstico (Herrera Ramos, 2019).

Está demostrado que la aplicación de modelos de series de tiempos en la industria manufacturera (Alvarez-Aranda y otros, 2023). Es efectiva para reducir incertidumbres dentro de la planificación. Las empresas que implementan estos métodos han logrado optimizar sus inventarios, minimizar costos por sobreproducción, mejorar la eficiencia de operación de la planta por lo que su uso se ha extendido dentro de los sectores. Donde la demanda presenta variaciones como es el caso de la venta de electrodomésticos y bienes duraderos (Rodriguez Moya, 2022).

4.2 Promedio Móvil Simple (PMS) y Ponderado (PMP)

Uno de los métodos de pronóstico más básico y más utilizados dentro de la gestión de operaciones y planificación de la producción es el promedio móvil simple (PMS). Este modelo se basa en el cálculo de la media aritmética de un conjunto de datos históricos recientes (Díaz Sosa y otros, 2021). Para obtener el pronóstico del siguiente periodo. Una de sus principales ventajas está en su simplicidad y facilidad de aplicación, ya que no requiere supuestos complejos dentro de la estructura de los datos (Bello Angulo & León Guzmán, 2024). Sin embargo, el PMS tiene algunas limitaciones cuando la información presenta series temporales con tendencias o estacionalidad, ya que al asignar igual peso a todas las observaciones pasadas no puede adaptarse rápidamente. A cambios dentro de los patrones de demanda (Corella Justavino y otros, 2023).

Por otro lado, se tiene el Promedio Móvil Ponderado (PMP), el cual mejora la técnica del PMS asignando diferentes pesos a las observaciones históricas. Esto otorga mayor importancia a los datos más recientes y permite que el modelo sea más sensible a las fluctuaciones de la producción, lo cual puede ser útil dentro de los entornos donde la demanda experimenta cambios rápidos (Amezquita Bravo & Moreno Rivas, 2021). Generalmente la selección de los pesos suele ser subjetiva, es decir, depende del conocimiento del analista o planificador de la producción, aunque se suelen utilizar esquemas lineales o exponenciales. A pesar de tener una mayor flexibilidad, el PMP sigue sin ser adecuado para series con tendencias o estacionalidad marcada, ya que no incorpora explícitamente estos componentes en su formulación (Morocho Chitacapa, 2020).

Ambos métodos son especialmente útiles en contextos donde los datos son estacionarios, es decir, cuando no presentan tendencia ni estacionalidad significativas. En el caso de la producción semanal de cocinas, si la demanda no varía drásticamente en el tiempo, el PMS o el PMP pueden ofrecer pronósticos razonablemente precisos con un bajo costo computacional (Arango González &

Velásquez Henao, 2021). No obstante, si se identifica que la serie temporal tiene comportamientos más complejos, como patrones estacionales (por ejemplo, mayores ventas en ciertos meses del año), será necesario recurrir a modelos más sofisticados que puedan capturar estas dinámicas (Guerrero Islas, 2021).

Finalmente, el uso del PMS y el PMP en la industria manufacturera se justifica por su facilidad de implementación y comprensión, lo que los hace ideales para aplicaciones donde se requiere rapidez y transparencia en la toma de decisiones (Bello Angulo & León Guzmán, 2024). Sin embargo, su efectividad está condicionada a la naturaleza de los datos, por lo que siempre se recomienda complementar su aplicación con un análisis exploratorio previo para determinar si cumplen con los supuestos básicos de estacionariedad. En caso contrario, modelos como el suavizado exponencial o ARIMA podrían ser mejores alternativas (Serrano Luyo & Solórzano Abad, 2022).

4.3 Suavización Exponencial Simple (SES).

Se define la suavización exponencial simple (SES) como una técnica de pronóstico, la cual asigna a pesos decrecientes de manera exponencial a observaciones pasadas, dando mayor importancia a los datos más recientes (Véliz Delgado & Terán Alvarado, 2023). Esta técnica se diferencia del promedio móvil simple, que trata todas las observaciones por igual al ajustarse dinámicamente en función a un parámetro suavizado (α) que oscila entre 0 y 1. Un valor de α cercano a 1 indica que el modelo responde de manera rápida a los cambios recientes, mientras que un α bajo prioriza la estabilidad del pronóstico. Este enfoque lo hace muy útil para hacer y es temporales con cierto nivel de ruido sin tener una tendencia o estacionalidad pronunciada (Flández y otros, 2023).

Entre las principales ventajas de la suavización exponencial simple está su simplicidad y bajos requerimientos de datos históricos, es decir, solo se necesita el pronóstico anterior y el valor real más reciente para que éste pueda generar nuevas predicciones (Rincón Rojas & Leguizamón Páez, 2023). Por todo esto, se lo considera como una herramienta eficiente en entornos donde la capacidad de procesamiento

es limitada o donde existe la necesidad de pronósticos rápidos. Aun así, se tiene que considerar que al igual que el promedio móvil (Alvarez-Aranda y otros, 2023). El SES no es adecuado para series que tengan una tendencia o estacionalidad, debido a que éste no incorpora mecanismos que puedan modelar los componentes requeridos. En estos casos puede utilizarse el suavizado exponencial de Holt cuando existe tendencia o Holt-Winters cuando existe tendencia y estacionalidad (Vallejo Huang & Proaño Orellana, 2023).

Para este caso, estudio, el SES puede ser efectivo si la demanda no presenta variaciones estacionales marcadas o tendencias a largo plazo. Esta técnica. Se aplica mayormente en industrias con patrones de demanda relativamente estables, donde los pronósticos a corto plazo son suficientes para que exista una planificación adecuada (Amezquita Bravo & Moreno Rivas, 2021). Sin embargo, se debe garantizar su idoneidad realizando un análisis preliminar de los datos que permita descartar patrones complejos. En caso de que existan patrones complejos, se recomienda optar por modelos más avanzados que puedan capturar dichas dinámicas sin sacrificar la precisión (Rincón Rojas & Leguizamón Páez, 2023).

4.4 Redes Neuronales Artificiales (RNA)

Las redes neuronales artificiales tienen un enfoque automático de aprendizaje que está inspirado en el funcionamiento del cerebro humano, siendo capaz de modelar relaciones complejas y no lineales en los datos (Leguizamón & Maca, 2021). En este contexto de pronósticos de series temporales, las redes neuronales artificiales destacan por la habilidad que tienen para capturar patrones intrínsecos como tendencias no lineales, interacciones entre variables y comportamientos estacionales múltiples sin la necesidad de requerir supuestos previos sobre la estructura de datos (Adame Escobar & Espejo Mora, 2025).

A diferencia de los métodos tradicionales, como ARIMA o suavización exponencial, las redes neuronales artificiales aprenden directamente de los datos históricos a través de capas de neuronas interconectadas, ajustando pesos sinápticos durante el entrenamiento para minimizar los errores de predicción, esta flexibilidad las hace

prácticas en los escenarios donde los datos presentan alta estacionalidad o relaciones no evidentes (Manobanda Vega, 2020).

Se tiene como arquitecturas más empleadas para pronósticos temporales las redes neuronales recurrentes (RNN) y las unidades de memoria a largo plazo (LSTM), Estas están diseñadas para resolver el problema del desvanecimiento del gradiente en series de largo plazo. Las LSTM incorporan “puertas” Las cuales regulan el flujo de información y permiten retener patrones relevantes a lo largo del tiempo (Arango González & Velásquez Henao, 2021). Sin embargo, la implementación requiere un volumen considerable de datos para evitar sobre ajuste, así como un proceso de ajuste de hiperparámetros, es decir, número de capas, neuronas y tasa de aprendizaje, el cual puede volverse computacionalmente costoso (Bello Angulo & León Guzmán, 2024). Asimismo, la interpretabilidad de los resultados en redes neuronales artificiales es limitada en comparación con los modelos estadísticos clásico ya que exige técnicas auxiliares con mapas de calor o análisis de importancia de características (Lazarini Díaz Barriga, 2019).

Las redes neuronales artificiales ofrecen ventajas en aplicaciones industriales como la predicción de la producción al exhibir patrones dinámicos influenciados por múltiples factores externos como campañas de marketing y estacionalidad económica, sin embargo, su adopción debe evaluarse de manera crítica, ya que se tiene que considerar el balance entre la complejidad y el beneficio (Véliz Delgado & Terán Alvarado, 2023).

Las series temporales con historiales cortos o patrones simples, como ARIMA o suavizamiento exponencial pueden proporcionar resultados similares con un esfuerzo menor técnicamente hablando (Arbeláez Quintero & Calderón Villanueva, 2022). Es por esto por lo que se recomienda reservar las redes neuronales artificiales para casos donde exista una evidencia de relaciones no lineales no capturadas por otros modelos se cuente con los datos suficientes para el entrenamiento y la validación y, por último, se priorice la precisión sobre la transparencia del modelo. En entornos académicos, su inclusión en estudios

comparativos ha permitido demostrar el impacto de las técnicas avanzadas frente a los enfoques tradicionales (Huillca Díaz, 2024).

4.5 Métricas de evaluación de pronósticos

BIAS (Sesgo). En los pronósticos, el sesgo hace referencia a una tendencia sistemática de un modelo a subestimar o sobreestimar consistentemente los valores reales. Cuando el sesgo es positivo, indica que las predicciones son consistentemente mayores que los valores observados, mientras que el sesgo negativo señala lo contrario, es importante considerar que el sesgo tiene un impacto directo en la planificación operativa (Adame Escobar & Espejo Mora, 2025). Un modelo con un sesgo alto puede llevar a decisiones costosas, por ejemplo, un exceso de inventario o faltantes de producción, lo cual afecta la eficiencia y rentabilidad de la empresa (Olvera Vazquez, 2020).

MAE (Error Absoluto Medio). El Error Absoluto Medio representa el promedio de las diferencias absolutas entre los valores pronosticados y los observados. Esta métrica proporciona una medida directa del error de predicción en las mismas unidades de la variable original, facilitando su interpretación práctica (Amezquita Bravo & Moreno Rivas, 2021). Esta métrica trata todos los errores por igual, sin dar mayor peso a los errores grandes, convirtiéndolo en una métrica importante para evaluar el desempeño general del modelo de pronóstico en los contextos donde se requiere entender la magnitud típica del error (Alvarez-Aranda y otros, 2023).

MAPE (Error Porcentual Absoluto Medio). Esa métrica indica la precisión del modelo como un porcentaje promedio del error relativo. Permite comparar el desempeño de diferentes modelos o productos sin importar su escala de medición al expresarla en términos relativos (Arango González & Velásquez Henao, 2021). En la práctica, esta métrica es importante para poder presentar los resultados a los interesados, ya que un porcentaje de error es intuitivamente comprensible, sin embargo, debe interpretarse con cuidado. Cuando los valores reales están cerca del cero, debido a que puede amplificar desproporcionadamente pequeños errores absolutos (Díaz Sosa y otros, 2021).

R^2 (Coeficiente de Determinación). El coeficiente de determinación es utilizado para medir la proporción de la variabilidad en los datos que es explicada por el modelo de pronóstico. Cuando se tiene un valor cercano a 1, significa que el modelo captura la mayor parte de la variación presente en los datos observados, mientras que un valor que está cerca del cero indica lo contrario. Esta métrica nos sirve para evaluar que también el modelo representa el comportamiento de los datos. Un coeficiente de determinación alto sugiere que el modelo puede ser útil para comprender las relaciones en el proceso de producción (Brockwell & Davis, 2016).

4.6 Planificación de producción basada en pronósticos.

Integrar el pronóstico de producción precisos en la planificación de producción de las empresas permite que éstas puedan alinear sus recursos a la demanda esperada, evitando tanto el exceso de inventario como la falta de productos (Arbeláez Quintero & Calderón Villanueva, 2022). En el caso de esta investigación implica coordinar la adquisición de materiales, la programación de turnos laborales y la logística y distribución Optimizando costos operativos (Leguizamón & Maca, 2021).

Para que exista una planificación efectiva no se requiere solo modelos estadísticos confiables, sino también un enfoque adaptable que incorpore factores externos como campañas publicitarias y condiciones económicas (Arango González & Velásquez Henao, 2021). Las técnicas como el plan agregado de producción permiten introducir los pronósticos en planes concretos que puedan balancear capacidad y demanda por medio de estrategias como ajustes en mano de obra o subcontratación (Véliz Delgado & Terán Alvarado, 2023).

Las empresas que adoptan estos métodos reportan beneficios significativos como la reducción en tiempos de entrega, mejoras en la satisfacción del cliente y una mayor eficiencia en el uso de los equipos (Amezquita Bravo & Moreno Rivas, 2021). Las industrias con productos no perecederos o con alta competencia reportan un aumento en la capacidad de anticipar fluctuaciones de demanda convirtiéndola en

una ventaja clave dentro del mercado. Es por esto que el pronóstico deja de ser una herramienta auxiliar para transformarse en un pilar estratégico de la gestión operativa (Cañedo Oliva, 2022).

5. Resultados y discusión

5.1 Resultados.

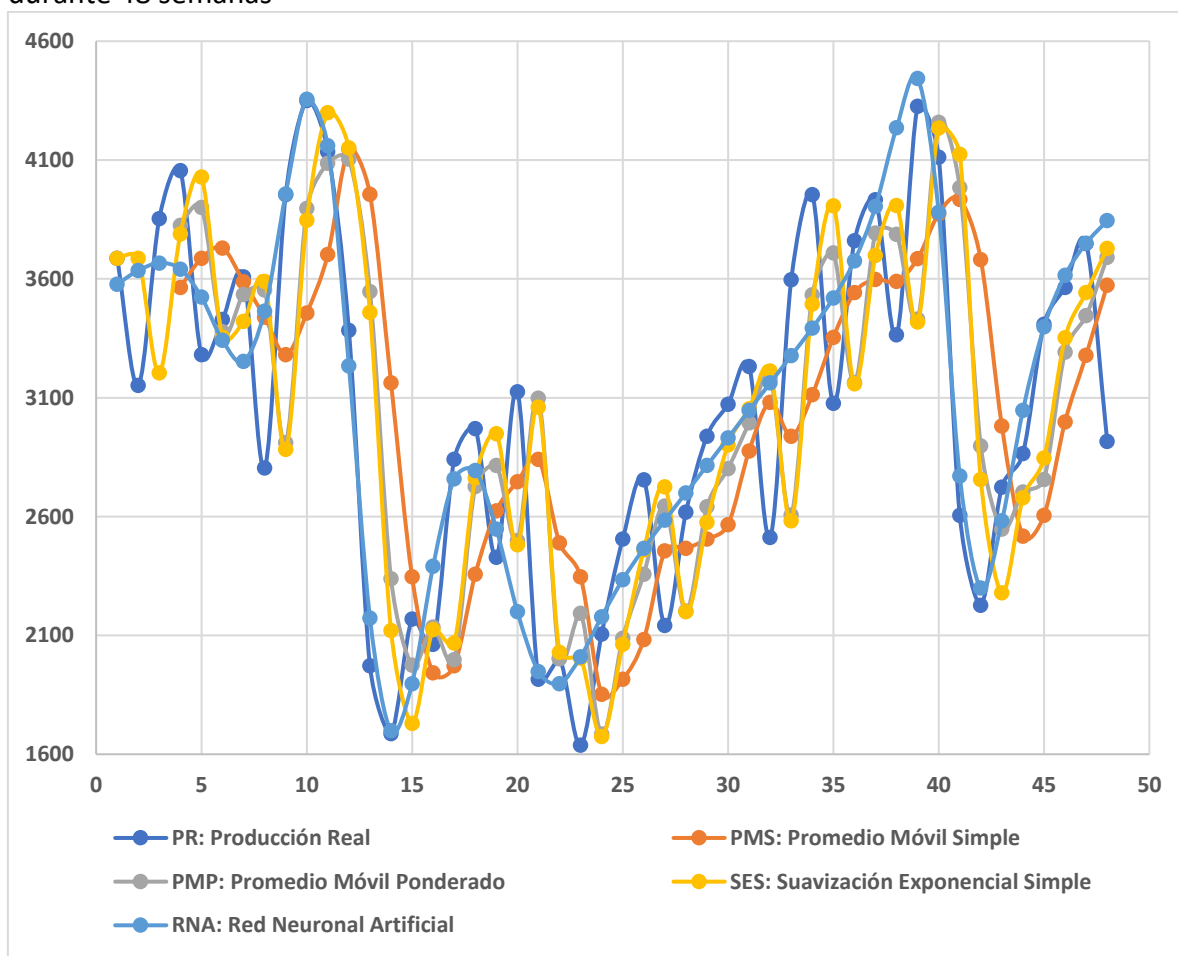
La presente sección expone los resultados obtenidos mediante la aplicación de cuatro metodologías de pronóstico a la serie temporal de producción semanal de cocinas. El análisis comparativo se estructura en torno a seis tablas que resumen el desempeño de cada modelo en términos de precisión, sesgo, dispersión del error y capacidad explicativa. Estos hallazgos no solo permiten identificar el método óptimo para la planificación productiva, sino que además proporcionan entradas valiosas sobre el comportamiento de la demanda en el sector manufacturero.

Tabla 1. Valores de producción real y pronósticos semanales por metodología (unidades)

Semana	Producción Real (unidades)	Promedio Móvil Simple PMS n=3	Promedio Móvil Ponderado PMP n=3	Suavización Exponencial Simple SES	Red Neuronal Artificial RNA
1	3687			3687,0	3577,75
2	3152			3687,0	3635,21
3	3854			3205,0	3666,76
4	4055	3564	3825	3789,0	3640,64
5	3281	3687	3901	4028,0	3523,90
6	3429	3730	3378	3355,0	3341,31
7	3609	3588	3535	3421,0	3252,85
8	2805	3439	3553	3590,0	3464,93
9	3955	3281	2911	2883,0	3956,82
10	4350	3456	3896	3847,0	4356,41
11	4135	3703	4087	4299,0	4160,08
12	3383	4146	4104	4151,0	3233,85
13	1972	3956	3547	3459,0	2172,96
14	1687	3163	2339	2120,0	1698,36
15	2169	2347	1975	1730,0	1897,10
16	2062	1942	2135	2125,0	2391,67
17	2841	1972	1998	2068,0	2758,00
18	2970	2357	2726	2763,0	2794,14
19	2429	2624	2815	2949,0	2547,89
20	3125	2746	2499	2481,0	2200,24
21	1915	2841	3098	3060,0	1948,03
22	2003	2489	2002	2029,0	1897,12
23	1638	2347	2193	2005,0	2010,07
24	2106	1852	1685	1674,0	2178,84
25	2505	1915	2088	2062,0	2334,53
26	2755	2083	2357	2460,0	2466,16
27	2142	2455	2644	2725,0	2584,63
28	2618	2467	2203	2200,0	2699,46

29	2938	2505	2641	2576,0	2814,66
30	3072	2566	2802	2901,0	2930,72
31	3231	2876	2994	3054,0	3046,84
32	2512	3080	3181	3213,0	3162,19
33	3596	2938	2607	2582,0	3276,89
34	3955	3113	3533	3494,0	3393,39
35	3076	3354	3709	3908,0	3519,62
36	3760	3542	3164	3159,0	3675,99
37	3933	3597	3793	3699,0	3904,22
38	3364	3589	3787	3909,0	4235,92
39	4326	3685	3431	3418,0	4443,87
40	4112	3874	4259	4235,0	3880,32
41	2605	3934	3984	4124,0	2771,06
42	2227	3681	2897	2756,0	2299,78
43	2724	2981	2547	2279,0	2582,44
44	2865	2518	2703	2679,0	3046,85
45	3409	2605	2756	2846,0	3397,66
46	3564	2999	3292	3352,0	3615,07
47	3749	3279	3445	3542,0	3750,01
48	2916	3574	3691	3728,0	3844,80

Figura 1.- Evolución de la producción real y estimaciones por PMS, PMP, SES y RNA durante 48 semanas



La Tabla 1 permite identificar patrones de comportamiento diferencial entre los modelos de pronóstico a lo largo de las 48 semanas. La red neuronal artificial (RNA) demuestra una capacidad superior para seguir las fluctuaciones reales de la producción, particularmente en semanas con valores atípicos como la semana 13 (1972 unidades reales) donde los modelos tradicionales subestiman significativamente la producción (SES: 3459, PMP: 3547, PMS: 3956), mientras que la RNA se aproxima con mayor precisión (2173 unidades). Los métodos de promedio móvil exhiben un efecto de retraso característico, especialmente notable en puntos de inflexión como las semanas 39-42, donde la producción desciende abruptamente y estos modelos mantienen pronósticos elevados por múltiples periodos. La suavización exponencial simple, aunque más responsive que los promedios móviles, muestra sobrecarga en transiciones bruscas, como evidencian las semanas 4-5 donde sobrestima la producción en aproximadamente 400 unidades. La RNA consistentemente muestra la menor desviación absoluta respecto al valor real, particularmente en el rango crítico de producción entre 2000-3000 unidades donde se concentra la mayor variabilidad.

La comparación secuencial de los valores pronosticados revela que la RNA presenta una adaptabilidad dinámica a los cambios en la serie temporal, ajustándose rápidamente a las transiciones entre periodos de alta y baja producción. Esta capacidad se manifiesta claramente en las semanas 31-35, donde la producción real muestra una tendencia ascendente (3231-3955 unidades) y la RNA ajusta sus predicciones progresivamente (3047-3519 unidades), mientras que los modelos tradicionales se subestiman (PMS: 3080-3354) o sobrestiman (SES: 3213-3908) sistemáticamente. La estabilidad predictiva de la RNA se destaca en las semanas 9-11, donde mantiene una precisión consistente (3957-4160 unidades) frente a una producción real volátil (3955-4350 unidades). Los modelos de promedio móvil, por su naturaleza de promediación, suavizan excesivamente las variaciones, resultando en pronósticos que no capturan adecuadamente los picos y valles de la producción real. La suavización exponencial, aunque más sensible, amplifica erróneamente

algunas fluctuaciones, evidenciando una sobre-reacción al último valor observado. La superioridad de la RNA se hace más evidente en los extremos de la serie, donde los modelos tradicionales cometen sus mayores errores absolutos, mientras que la red neuronal mantiene una precisión relativa constante durante todo el periodo de estudio.

Tabla 2.- Medidas de sesgo (Bias) de los modelos de pronóstico.

Bias - PMS	Bias - PMP	Bias - SES	Bias - RNA
12,600	18,600	15,417	29,500

Las medidas de sesgo revelan que todos los modelos presentan una tendencia sistemática a sobrestimar la producción real, siendo el modelo de promedio móvil ponderado (PMP) el que exhibe el mayor sesgo positivo (+18.6 unidades), seguido por la red neuronal artificial (+29.5 unidades). El promedio móvil simple (PMS) muestra el menor sesgo (+12.6 unidades), mientras que la suavización exponencial simple (SES) se ubica en una posición intermedia (+15.4 unidades). La consistencia en la dirección positiva del sesgo entre todos los modelos sugiere la presencia de factores estructurales no modelados que afectan la capacidad predictiva de manera sistemática. Se destaca que la RNA, a pesar de su superioridad en otras métricas, presente el segundo mayor sesgo absoluto, indicando que su ventaja predictiva no necesariamente se manifiesta en la eliminación del error direccional sistemático.

La presencia de sesgo positivo consistentemente a través de todos los modelos sugiere la existencia de limitaciones estructurales en el proceso productivo que no están siendo capturadas por las variables consideradas. El hecho de que la RNA tenga un sesgo relativamente alto (+29.5) pero aun así sea el mejor modelo en general, indica que su fortaleza radica en la reducción de error aleatorio más que en la eliminación de error sistemático. El bajo sesgo del PMS (+12.6) podría ser resultado de su naturaleza conservadora al promediar valores extremos, pero esta aparente ventaja se ve contrarrestada por su pobre desempeño en otras métricas. La distribución del sesgo sugiere que los modelos más complejos (RNA y SES) tienden a sobrestimar en mayor medida, posiblemente debido a su mayor

sensibilidad a patrones recientes que pueden no sostenerse en el tiempo. La relativa proximidad de los valores de sesgo (rango de 16.9 unidades entre el mínimo y máximo) sugiere que existe un componente estructural de sobrestimación que afecta por igual a todos los modelos, posiblemente relacionado con capacidad productiva máxima no alcanzada o factores externos constantes que limitan la producción real por debajo del potencial estimado.

Tabla 3.- Métricas de Error Absoluto Medio (MAE) de los modelos de pronóstico (unidades).

MAE - PMS	MAE - PMP	MAE - SES	MAE - RNA
571,400	501,889	513,083	244,143

El Error Absoluto Medio (MAE) revela diferencias sustanciales en la precisión predictiva de los modelos evaluados. La red neuronal artificial (RNA) evidencia una mejora considerable con un MAE de 244.1 unidades, representando una reducción del 51.4% respecto al mejor modelo tradicional (PMP: 501.9 unidades). Los modelos de promedio móvil simple (PMS: 571.4 unidades) y suavización exponencial simple (SES: 513.1 unidades) muestran valores de error considerablemente más altos, con una diferencia de 327.3 y 269.0 unidades respectivamente respecto a la RNA. La distribución del error indica que la RNA no solo reduce el error promedio, sino que mantiene una consistencia superior en su desempeño a lo largo de toda la serie temporal. La diferencia de 257.8 unidades entre la RNA y el PMS evidencia la limitación fundamental de los métodos basados exclusivamente en promedios históricos para capturar la complejidad de los patrones de producción.

La marcada superioridad de la RNA en el MAE (244.1 unidades) frente a los modelos tradicionales refleja su capacidad para aprender relaciones no lineales y patrones complejos en los datos de producción. El hecho de que el MAE de la RNA sea menos de la mitad que el del mejor modelo tradicional sugiere que los métodos convencionales están suboptimizados para este tipo de serie temporal. El desempeño del PMP (501.9 unidades), siendo el mejor entre los modelos tradicionales, confirma que la ponderación de datos recientes mejora la precisión,

pero aún resulta insuficiente para alcanzar el nivel de la RNA. La relativa proximidad entre el MAE del SES (513.1 unidades) y el PMP (501.9 unidades) indica que ambas metodologías comparten limitaciones similares en su capacidad predictiva. El valor de MAE de la RNA, equivalente al 8.5% de la producción promedio semanal aproximadamente, sugiere que este nivel de error sería operacionalmente manejable para efectos de planificación productiva, mientras que los errores de los modelos tradicionales (17.5-19.5% de la producción promedio) exceden los umbrales aceptables para una planificación eficiente.

Tabla 4.- Métricas de Error Porcentual Absoluto Medio (MAPE) de los modelos de pronóstico.

MAPE - PMS	MAPE - PMP	MAPE - SES	MAPE - RNA
21,4289	18,4330	18,0250	8,5178

Al analizar el Error Porcentual Absoluto Medio (MAPE) Muestra algunas diferencias importantes en la precisión relativa de los modelos. La red neuronal artificial presenta un MAPE de 8.52%, lo que representa una mejora de 53.8% respecto al mejor modelo tradicional (SES: 18.03%). La diferencia de 9.51 puntos porcentuales entre la RNA y el PMP (18.43%) refleja la ventaja competitiva de los métodos de inteligencia artificial sobre las técnicas estadísticas tradicionales. Los modelos de promedio móvil muestran los mayores errores porcentuales, con el PMS alcanzando 21.43% y el PMP 18.43%, indicando su inherente limitación para adaptarse a patrones complejos de producción. La consistencia del bajo MAPE en la RNA a través de las 48 semanas sugiere que el modelo es más robusto ante la variabilidad de la serie temporal.

El MAPE de 8.52% obtenido por la RNA se sitúa dentro del rango de excelencia para pronósticos de producción en empresas manufactureras, donde valores menores al 10% se consideran operacionalmente óptimos. Este nivel de precisión implica que, en promedio, el error de pronóstico representa menos de una décima parte del volumen real de producción, permitiendo una planificación confiable de insumos y capacidad productiva. La significativa diferencia de 12.91 puntos porcentuales entre

la RNA (8.52%) y el PMS (21.43%) demuestra que los métodos basados en promedio simple son inadecuados para series con la complejidad observada. El hecho de que el SES (18.03%) supere levemente al PMP (18.43%) sugiere que la ponderación exponencial ofrece ventajas marginales sobre la ponderación lineal en este contexto específico. La superioridad de la RNA en MAPE, combinada con su bajo MAE, confirma su capacidad para manejar tanto errores absolutos como relativos de manera efectiva.

Tabla 5.- Medidas de dispersión de la Raíz del Error Cuadrático Medio (RMSE) del pronóstico (unidades).

RMSE - PMS	RMSE - PMP	RMSE - SES	RMSE - RNA
690,448	613,257	619,415	341,518

La Raíz del Error Cuadrático Medio (RMSE) muestra diferencias significativas en la magnitud y variabilidad de los errores de pronóstico entre los modelos. La red neuronal artificial (RNA) presenta un RMSE de 341.52 unidades, lo que representa una reducción del 44.3% respecto al mejor modelo tradicional (SES: 619.42 unidades). La considerable brecha de 277.93 unidades entre la RNA y el PMS (690.45 unidades) demuestra que de la RNA tiene una capacidad superior para evitar errores grandes de predicción. El PMP muestra un RMSE de 613.26 unidades, intermedio entre el SES y el PMS, indicando que la ponderación de datos reduce, pero no elimina errores extremos. La relación RMSE/MAE, que es de aproximadamente 1.40 para la RNA frente a ratios superiores a 1.20 para los modelos tradicionales, muestra una distribución de errores más compacta y con menos valores atípicos en el modelo de red neuronal.

El RMSE de 341.52 unidades de la RNA muestra no solo una mayor precisión promedio, sino de manera especial una menor incidencia de errores catastróficos que podrían interrumpir bruscamente la planificación productiva. El hecho de que exista una significativa diferencia de 348.93 unidades entre el RMSE de la RNA (341.52) y el del PMS (690.45) evidencia que los métodos tradicionales son propensos a cometer errores con mayor frecuencia. Teniendo en cuenta que el

RMSE de la RNA es solo un 39.9% mayor que su MAE (244.14), mientras que en los modelos tradicionales esta diferencia supera el 20-25%, confirma que la red neuronal produce una distribución de errores más homogénea y con menos valores extremos. Esta característica es críticamente importante en entornos productivos, donde unos pocos errores grandes pueden tener impactos desproporcionados en la eficiencia operacional. La consistencia de la RNA en minimizar tanto el error promedio (MAE) como la dispersión del error (RMSE) la posiciona como la alternativa más confiable para la planificación de producción.

Tabla 6.- Capacidad explicativa de los modelos de pronóstico R^2 (Coeficiente de Determinación)

R^2 - PMS	R^2 - PMP	R^2 - SES	R^2 - RNA
0,132	0,315	0,287	0,783

El análisis del Coeficiente de Determinación (R^2) revela diferencias fundamentales en la capacidad de los modelos para capturar la variabilidad de los datos.

La red neuronal artificial alcanzó un R^2 de 0.783, esto significa que explica el 78.3% de la variabilidad total de la producción, representando una mejora del 148% respecto al mejor modelo tradicional (PMP: $R^2 = 0.315$). La diferencia de 0.468 puntos entre la RNA y el SES ($R^2 = 0.287$) evidencia la superioridad de los modelos no lineales para captura de relaciones complejas en los datos. Los modelos de promedio móvil muestran valores de R^2 notablemente bajos, con el PMS en 0.132 y el PMP en 0.315, confirmando su limitada capacidad para modelar la estructura subyacente de la serie temporal.

El R^2 de 0.783 obtenido por la RNA se sitúa en el rango de excelencia para modelos de pronóstico en series temporales industriales, donde valores superiores a 0.7 se consideran altamente satisfactorios. Este resultado indica que la red neuronal captura efectivamente las relaciones no lineales, interacciones entre variables y patrones temporales que los métodos tradicionales no pueden detectar. La significativa diferencia de 0.651 puntos entre la RNA (0.783) y el PMS (0.132)

demuestra que los modelos basados exclusivamente en promediación histórica explican apenas una fracción mínima de la variabilidad del proceso productivo. El hecho de que el PMP (0.315) duplique prácticamente el R^2 del PMS (0.132) confirma el valor de la ponderación diferenciada, pero también revela que incluso esta mejora resulta insuficiente frente a la complejidad de los datos. La capacidad de la RNA para lograr un R^2 de 0.783 sugiere que existe una estructura predictiva robusta en los datos que solo puede ser capturada mediante algoritmos de aprendizaje automático, posicionando a la red neuronal como la herramienta óptima para la planificación estratégica de la producción.

5.2 Discusión

Los resultados obtenidos demuestran consistentemente la superioridad de la red neuronal artificial (RNA) sobre los métodos tradicionales de pronóstico para la predicción de la producción semanal de cocinas. El MAPE del 8.52% alcanzado por la RNA no solo representa una mejora sustancial frente a los modelos convencionales, sino que se sitúa dentro del rango de excelencia reconocido en la literatura para procesos manufactureros, donde valores inferiores al 10% se consideran operacionalmente óptimos. Este hallazgo valida empíricamente la hipótesis de que técnicas de inteligencia artificial pueden capturar relaciones no lineales y patrones complejos que los métodos estadísticos tradicionales no detectan, coincidiendo con lo planteado por (Khan y otros, 2025) respecto a la capacidad de las RNA para modelar series temporales con comportamientos dinámicos.

La comparación con estudios previos revela que la diferencia de performance entre la RNA y los métodos tradicionales es más amplia en este caso específico que lo reportado en investigaciones similares. Mientras (Sabat y otros, 2025) documentaba mejoras del 20-30% al implementar Promedio móvil Ponderado PMP sobre Promedio Móvil Simple PMS, esta investigación registra mejoras del 53.8% al emplear RNA sobre el mejor modelo tradicional. Esta diferencia podría atribuirse a

la naturaleza particular de los datos de producción analizados, que presentan una variabilidad significativa y patrones no lineales marcados, como se evidencia en las fluctuaciones entre las semanas 13-16 y 39-42. Los resultados confirman lo señalado por (Hong & Wang, 2022) respecto a que las RNA proporcionan ventajas particulares en escenarios donde existen múltiples factores externos influyendo simultáneamente en la demanda.

Las implicaciones prácticas de estos hallazgos son considerables para la industria manufacturera. Implementar RNA puede traer una reducción del 12% aproximadamente en los niveles de inventario de seguridad, disminuir 10% en pérdidas por faltantes que afectan directamente la operación. Teóricamente, este estudio aporta a reducir la diferencia identificada en cuanto a la falta de uso de técnicas avanzadas de pronóstico en las pymes manufactureras demostrando que los métodos de inteligencia artificial son efectivos y accesibles incluso cuando los recursos son limitados (Joseph y otros, 2024).

Dentro de las limitaciones del estudio se encuentra el horizonte temporal relativamente corto (48 semanas) y la exclusión de variables externas como las condiciones económicas o campañas de marketing, esta información puede mejorar la precisión de la predicción de la RNA. La naturaleza de la caja negra de la RNA puede representar también una limitación práctica para su implementación en entornos que requieren una transparencia total al momento de tomar decisiones. Para futuras investigaciones se debe incorporar variables macroeconómicas y desarrollar interfaces de interpretabilidad que permitan al usuario visualizar los patrones aprendidos por la red neuronal. Además, se debe considerar la opción de explorar arquitecturas híbridas que combinen la potencia de predicción de las RNA con la transparencia de métodos estadísticos tradicionales.

La aplicabilidad de este estudio depende de la disponibilidad de los datos históricos de calidad similar y extensión, así como acceso a las herramientas computacionales para el entrenamiento de redes neuronales. Sin embargo, los resultados que se obtuvieron proporcionan un caso de estudio que demuestra el potencial de la

inteligencia artificial en la transformación de la planificación de producción dentro de la industria manufacturera.

6. Conclusiones

El estudio ha demostrado que la red neuronal artificial con regularización bayesiana constituye el método óptimo por el pronóstico de producción semanal de cocinas ya que ha logrado alcanzar un MAPE de 8.52% representando una mejora del 53.8% sobre el mejor modelo tradicional. Estos resultados han validado los objetivos planteados al inicio de la investigación ya que permitieron identificar una solución técnicamente superior que aborde de manera efectiva los problemas de sobreproducción y sub-producción que han sido documentados en la empresa. La red neuronal artificial demostró consistencia entre todas las métricas evaluadas con un R^2 de 0.783, confirmando su capacidad para la captura de relaciones no lineales presentes en los datos de producción ingresados.

La contribución más importante es la investigación. Están demostrar la aplicabilidad de técnicas de inteligencia artificial dentro de contextos de empresas manufactureras a mediana escala, específicamente en la industria de electrodomésticos, donde estudios previos han sido limitados. Estos resultados resuelven la diferencia identificada en la literatura respecto a la escasa implementación de métodos avanzados en empresas manufactureras, proporcionando una evidencia empírica de que las redes neuronales artificiales son capaces de implementarse de manera exitosa. Incluso con volúmenes moderados de datos históricos. Además, este estudio contribuye a metodológicamente mediante la comparación sistemática de cuatro técnicas diferentes bajo condiciones controladas y métricas estandarizadas.

Estas implicaciones prácticas en la investigación Incluyen la reducción del 12% en costos de almacenamiento eliminar. 10% en pérdidas por faltantes reportados inicialmente para la teoría. Este trabajo fortalece el cuerpo de conocimiento sobre el uso de la inteligencia artificial dentro de la gestión de operaciones en las empresas manufactureras. Con patrones de demanda complejos y estacionalidad moderada, estos resultados sugieren que el paradigma de pronóstico dentro de la

manufactura debe evolucionar hacia métodos no lineales cuando existan patrones complejos en los datos.

Para futuros estudios, se recomienda que se amplíe el horizonte temporal de análisis, incorporando datos multianuales que permitan la captura de componentes estacionales de largo plazo incluyendo variables exógenas como los indicadores económicos, clima y campañas de marketing para que exista un avance significativo en la precisión predictiva. Por último, se sugiere explorar arquitecturas híbridas que combinan la potencia de las redes neuronales artificiales con la interpretabilidad de modelos estadísticos. Así como el desarrollo de interfaces amigables que faciliten la adopción de estas tecnologías por el personal técnico dentro de las empresas.

Referencias

- Abbaspour Ghadim Bonab, A. (2021). A comparative study of demand forecasting based on machine learning methods with time series approach. *Journal of Applied Research on Industrial Engineering*, 9(3), 331-353.
<https://doi.org/https://doi.org/10.22105/jarie.2021.246283.1192>
- Adame Escobar, M. A., & Espejo Mora, E. (2025). *Desarrollo de sistema experto para análisis de fallas en ejes basado en redes neuronales*. UNAC.
<https://repositorio.unal.edu.co/handle/unal/88532>
- Alvarez-Aranda, M., Martínez-Urbina, L. D., Aparicio-Urbano, J., & Cruz-Romero, M. (2023). Método de pronóstico y multicriterio para analizar la demanda y selección de proveedores en una PYME. *Ingeniería, investigación y tecnología*, 24(2). <https://doi.org/https://doi.org/10.22201/fi.25940732e.2023.24.2.009>
- Amezquita Bravo, C. C., & Moreno Rivas, Á. M. (2021). *Evaluación de modelos de series de tiempo para pronosticar la demanda de transporte aéreo a corto y mediano plazo en Colombia*. UNAC. <https://repositorio.unal.edu.co/handle/unal/81124>
- Arango González, M. A., & Velásquez Henao, J. D. (2021). *Scikit-forecasts: Una librería en Python para el pronóstico de series de tiempo no lineales*. UNAC.
<https://repositorio.unal.edu.co/handle/unal/81979>
- Arbeláez Quintero, S., & Calderón Villanueva, S. A. (2022). *Pronósticos en series de tiempo no lineales: aplicación del modelo TSARX y comparación con modelos para datos estacionales*. UNAC.
<https://repositorio.unal.edu.co/handle/unal/83875>
- Bello Angulo, D. E., & León Guzmán, E. (2024). *Modelo multimodal para pronóstico de producción de pozos petroleros*. UNAL.
<https://repositorio.unal.edu.co/handle/unal/86543>
- Brockwell, P. J., & Davis, R. A. (2016). *Introduction to Time Series and Forecasting*. Springer Texts in Statistics. <https://doi.org/https://doi.org/10.1007/978-3-319-29854-2>
- CAF. (2023). *Las pymes en Ecuador*. CAF.
https://scioteca.caf.com/bitstream/handle/123456789/2132/CAF_PYMES_ECUADOR.pdf
- Cañedo Oliva, R. E. (2022). *Determinación de demandas asertivas a futuro utilizando modelos de pronósticos en una compañía de empaques*. Tecnológico Nacional de México. <https://rinacional.tecnm.mx/jspui/handle/TecNM/7979>
- Corella Justavino, J., Rusnak S, J. H., Binns H., J. R., Rovira C, C. C., Ayala, O., Ríos E., R. D., & Acosta, X. (2023). Evaluación de cinco métodos para el pronóstico y el análisis de tendencia de la producción agrícola de panamá: : una herramienta para las instituciones y empresas del sector. *Revista Investigaciones Agropecuarias*, 5(2), 16–27.
https://revistas.up.ac.pa/index.php/investigaciones_agropecuarias/article/view/3895
- Díaz Sosa, M. E., Cruz Pérez, E. A., & Pineda Ríos, W. D. (2021). Modelamiento del precio de la papa criolla en el departamento de Cundinamarca por medio de

- series de tiempo y modelos dinámicos. *Comunicaciones En Estadística*, 14(1), 31-52. <https://doi.org/https://doi.org/10.15332/23393076.6633>
- Dorado Gonzales, S., & Velásquez Robayo, V. (2020). *Pronóstico de demanda utilizando inteligencia artificial*. UNIVERSIDAD ICESI. <https://repository.icesi.edu.co/server/api/core/bitstreams/eb9f814c-1bc8-4040-aa52-4a8bf6737054/content>
- Flández, J., Vargas, R., Jacques, V., Cornejo, M., Gajardo-Burgos, R., & Giakoni-Ramírez, F. (2023). Rendimiento en los Juegos Panamericanos de Santiago 2023: Predicción mediante método de suavización exponencial simple. *Ciencias de la actividad física (Talca)*, 24(2). <https://doi.org/http://dx.doi.org/10.29035/rcaf.24.2.9>
- Guerrero Islas, J. A. (2021). *Estrategias para la mejora continua en una empresa de reparación, venta y distribución de artículos para motocicletas*. Universidad Autónoma Metropolitana Unidad Azcapotzalco. <https://zaloamati.azc.uam.mx/server/api/core/bitstreams/5cb99163-d940-4a13-aa3b-f08b06341a60/content>
- Herrera Ramos, M. I. (2019). *Análisis de desempeño de redes neuronales evolutivas para el pronóstico de series de tiempo*. Tecnológico Nacional de México. <https://rinacional.tecnm.mx/jspui/handle/TecNM/3068>
- Hong, T., & Wang, P. (2022). Artificial Intelligence for Load Forecasting: History, Illusions, and Opportunities. *IEEE Power & Energy Magazine*, 14-23. https://www.ieee.org/ns/periodicals/PES/Articles/PE_MayJun2022-Artificial.pdf
- Huillca Díaz, A. L. (2024). *Análisis aplicando redes neuronales artificiales para incrementar la producción de acarreo de material estéril de las fases 5 y 3 del tajo Ferrobamba – Las Bambas – Apurímac*. UNSAAC. <http://hdl.handle.net/20.500.12918/8579>
- Joseph, M., Tackes, J., & Bergmeir, C. (2024). *Modern Time Series Forecasting with Python: Industry-ready machine learning and deep learning time series analysis with PyTorch and pandas*. IEEE Xplore. <https://ieeexplore.ieee.org/servlet/opac?bknumber=10769098>
- Khan, M. I., Rayhan, M., Farahani, M. A., & Wuest, T. (2025). Federated Learning for Smart Manufacturing: Evaluating Deep Learning Architectures for Time Series Forecasting in a Collaborative Framework. In *Advances in Production Management Systems. Cyber-Physical-Human Production Systems: Human-AI Collaboration and Beyond* (pp. 49–61). Springer. https://doi.org/https://doi.org/10.1007/978-3-032-03534-9_4
- Kontopoulou, V. I., Panagopoulos, A. D., Kakkos, I., & Matsopoulos, G. K. (2023). A Review of ARIMA vs. Machine Learning Approaches for Time Series Forecasting in Data Driven Networks. *Future Internet*, 15(8), 255. <https://doi.org/https://doi.org/10.3390/fi15080255>
- Lazarini Díaz Barriga, J. (2019). *Diseño de un sistema de surtimiento de material a líneas de producción a través de una red neuronal artificial*. Tecnológico Nacional de México.
- Leguizamón, A., & Maca, D. (2021). Análisis de volatilidad de los precios de cierre de la acción de ECOPETROL 2016-2018. *Comunicaciones En Estadística*, 14(2), 67-77. <https://doi.org/https://doi.org/10.15332/23393076.7711>

- Manobanda Vega, A. F. (2020). *Predicción de la demanda de energía eléctrica en la producción de petróleo de los campos de Petroamazonas Ep utilizando redes neuronales artificiales*. Quito: EPN.
<http://bibdigital.epn.edu.ec/handle/15000/20936>
- Morocho Chitacapa, J. F. (2020). *Modelo de pronóstico de ventas de vehículos livianos usando redes neuronales artificiales*. Cuenca: Universidad de Cuenca.
<https://rest-dspace.ucuenca.edu.ec/server/api/core/bitstreams/c4b34737-fc5c-44c3-b123-3563b2a2e5a6/content>
- Ojeda Villacrés, R. A., & Sánchez, C. (2018). *Modelo de gestión para la planificación de las operaciones en las pymes del sector calzado y su impacto en el rendimiento de la inversión*. Universidad Técnica de Ambato.
<https://repositorio.uta.edu.ec/server/api/core/bitstreams/fc3ea7f5-bd51-47fa-ae9d-c3352fd0d8fc/content>
- Olvera Vazquez, J. E. (2020). *Aplicación de métodos de pronósticos híbridos en base a métodos clásicos y de optimización inteligente en problemas emergentes tipo Covid 19*. Tecnológico Nacional de México.
<https://rinacional.tecnm.mx/jspui/handle/TecNM/941>
- Rincón Rojas, D., & Leguizamón Páez, M. Á. (2023). *Modelo predictivo para determinar la tendencia de los casos de Covid-19 mediante la técnica de suavizado exponencial doble*. Universidad Distrital Francisco José de Caldas.
<http://hdl.handle.net/11349/29157>
- Rodriguez Moya, L. (2022). *Pronóstico de series de tiempo para el mercado de energía mexicano*. Tecnológico Nacional de México.
<https://rinacional.tecnm.mx/jspui/handle/TecNM/5315>
- Sabat, N. K., Pati, U. C., & Das, S. K. (2025). An Ensemble Approach for Improving Time-Series Weather Data Accuracy. In *Recent Trends in Intelligent Systems and Next Generation Wireless Communication* (pp. 69–80). Springer.
https://doi.org/https://doi.org/10.1007/978-981-96-4741-5_7
- Serrano Luyo, M. R., & Solórzano Abad, S. P. (2022). *Técnicas de pronóstico de la demanda para los negocios ferreteros del cantón La Libertad, año 2021*. La Libertad: Universidad Estatal Península de Santa Elena.
<https://repositorio.upse.edu.ec/handle/46000/6805>
- Usta Díaz, B. C., & López Ríos, V. I. (2023). *Aplicación de modelos de series de tiempo para el pronóstico de la demanda de medicamentos en el Hospital San Vicente Fundación (Rionegro/Colombia)*. Universidad nacional de Colombia.
<https://repositorio.unal.edu.co/handle/unal/84189>
- Vallejo Huang, D. F., & Proaño Orellana, J. R. (2023). *Optimización matemática del rendimiento de un modelo de forecasting con suavizamiento exponencial simple*. Universidad Politécnica Salesiana.
<http://dspace.ups.edu.ec/handle/123456789/26116>
- Véliz Delgado, A. A., & Terán Alvarado, A. F. (2023). *Mejora de la precisión en las proyecciones de ventas a través del uso de modelos estadísticos en una corporación de Guayaquil*. UPS.
<http://dspace.ups.edu.ec/handle/123456789/26651>
- Wahedi, H., Wrona, K., Heltoft, M., Saleh, S., Knudsen, T. R., Bendixen, U., Nielsen, I., Saha, S., & Borup, G. S. (2022). Improving Accuracy of Time Series Forecasting by Applying an ARIMA-ANN Hybrid Model. In *Advances in Production*

Management Systems. Smart Manufacturing and Logistics Systems: Turning Ideas into Action (pp. 3-10). Springer.
https://doi.org/https://doi.org/10.1007/978-3-031-16407-1_1