

# Forecasting Models Using Deep Learning Algorithms by Means of Recurrent Neural Networks LSTM to Estimate Demand of Building Making Materials

Forecasting Models Using Deep Learning Algorithms by Means of Recurrent Neural Networks LSTM to Estimate the Demand of Building Making Materials

Marcos Moya Navarro, Ph.D<sup>1</sup>, José Ugalde Rodríguez, Bachelor's in Industrial Engineering<sup>2</sup>

<sup>1</sup>Universidad Latina de Costa Rica, Costa Rica, marcos.moya@ulatina.net

<sup>2</sup>Lead University, Costa Rica, jose.ugalde@ulead.ac.cr

*Abstract— Forecasting is an area of knowledge of great interest to companies because not only it allows them to carry out their strategic planning processes but also to obtain valuable information from inventories of finished products, raw materials, materials and supplies to make purchasing and production decisions in the best way possible. Moreover, traditional mathematical forecasting models not always provide robust forecasting results, especially when the variability of historical data is significantly high.*

*The objective of this work is to provide a methodology to forecast the demand of a family of products for building making by using deep learning algorithms through neural networks and compare the results with those obtained by a forecast model with automatic detection of seasonality and a forecasting model smoothed by third degree polynomial regression.*

*The results obtained indicated that the forecast model using neural networks provided an RMSE forecast error 79.14% lower than that detected by the Holt-Winters model found with automatically detected seasonality. Similarly, the neural network forecasting model found a forecast error 79.76% lower than that detected by a third order smoothed polynomial forecasting model.*

*The recommendations based on the results indicate that it is convenient to use neural network algorithms when the demand historical data presents significant variability and traditional forecasting methods explain very little of the data total variability.*

*Keywords—Forecasting, Neural Networks, Deep Learning, Predictive Analytics, Trend Analysis*

**Digital Object Identifier:** (only for full papers, inserted by LACCEI).  
**ISSN, ISBN:** (to be inserted by LACCEI).  
**DO NOT REMOVE**

# Modelos de Pronóstico Utilizando Algoritmos de Aprendizaje Profundo Mediante Redes Neuronales Recurrentes LSTM Para Estimar la Demanda de Materiales de Construcción

Forecasting Models Using Deep Learning Algorithms by Means of Recurrent Neural Networks LSTM to Estimate the Demand of Building Making Materials

Marcos Moya Navarro, Ph.D<sup>1</sup>, José Ugalde Rodríguez, Bachelor's in Industrial Engineering<sup>2</sup>

<sup>1</sup>Universidad Latina de Costa Rica, Costa Rica, marcos.moya@ulatina.net

<sup>2</sup>Lead University, Costa Rica, jose.ugalde@ulead.ac.cr

**Resumen**— La previsión es un área de conocimiento de gran interés para las empresas porque no sólo les permite llevar a cabo sus procesos de planificación estratégica sino también obtener información valiosa de los inventarios de productos terminados, materias primas, materiales e insumos para realizar compras y decisiones de producción de la mejor manera posible. Además, los modelos matemáticos tradicionales de pronóstico no siempre brindan resultados de pronóstico sólidos, especialmente cuando la variabilidad de los datos históricos es significativamente alta.

El objetivo de este trabajo es proporcionar una metodología para pronosticar la demanda de una familia de productos para la construcción mediante el uso de algoritmos de aprendizaje profundo a través de redes neuronales y comparar los resultados con los obtenidos por un modelo de pronóstico con detección automática de estacionalidad y un modelo de pronóstico suavizado por regresión polinómica de tercer grado.

Los resultados obtenidos indicaron que el modelo de pronóstico utilizando redes neuronales proporcionó un error de pronóstico RMSE 79,14% menor que el detectado por el modelo de Holt-Winters encontrado con estacionalidad detectada automáticamente. De manera similar, el modelo de pronóstico de red neuronal encontró un error de pronóstico 79.76% menor que el detectado por un modelo de pronóstico polinómico suavizado de tercer orden.

Las recomendaciones basadas en los resultados indican que es conveniente utilizar algoritmos de redes neuronales cuando los datos históricos de demanda presentan una variabilidad significativa y los métodos de pronóstico tradicionales explican muy poco de la variabilidad total de los datos.

**Palabras Clave**— Pronósticos, Redes Neuronales, Aprendizaje Profundo, Análisis Predictiva, Análisis de Tendencia

**Abstract**— Forecasting is an area of knowledge of great interest to companies because not only it allows them to carry out their strategic planning processes but also to obtain valuable information from inventories of finished products, raw materials, materials, and supplies to make purchasing and production decisions in the best way possible. Moreover, traditional mathematical forecasting models do not always provide robust forecasting results, especially when the variability of historical data is significantly high.

The objective of this work is to provide a methodology to forecast the demand of a family products for building making by using deep learning algorithms through neural networks and compare the results with those obtained by a forecast model with automatic detection of seasonality and a forecasting model smoothed by third degree polynomial regression.

The results obtained indicated that the forecast model using neural networks provided an RMSE forecast error 79.14% lower than that detected by the Holt-Winters model found with automatically detected seasonality. Similarly, the neural network forecasting model found a forecast error 79.76% lower than that detected by a third order smoothed polynomial forecasting model.

The recommendations based on the results indicate that it is convenient to use neural network algorithms when the demand historical data presents significant variability and traditional forecasting methods explain very little of the data total variability.

**Keywords**—Forecasting, Neural Networks, Deep Learning, Predictive Analytics, Trend Analysis

## I. INTRODUCCION

Los pronósticos de la demanda robustos son esenciales para la toma de decisiones empresariales en áreas que van desde la gestión de las cadenas de suministro hasta la planeación estratégica y táctica de las empresas para planear su capacidad de producción de tal manera que les permita operar con costos competitivos.

La Ref. [1] indica que es alentador que en las últimas décadas se hayan visto avances dramáticos en los métodos de pronóstico que tienen el potencial de aumentar significativamente la precisión de los pronósticos y mejorar el desempeño operativo y financiero. Los autores también indican que muchas organizaciones no han adoptado métodos sistemáticos de previsión a pesar de sus beneficios, por lo que proporcionan una descripción general de los avances recientes en la predicción y luego utilizan una combinación de datos de encuestas y entrevistas semiestructuradas en profundidad con

pronosticadores para investigar las razones de la baja tasa de adopción. Finalmente, identifican las vías que podrían conducir a un uso mayor y más generalizado de métodos de pronóstico.

La Ref. [2] indica que se compararon dos métodos de aprendizaje profundo que son la red neuronal convolucional (RNC) y la memoria a corto plazo (LSTM) para detectar instrumentos de endodoncia separados en radiografías dentales. Los autores indican que se utilizaron un total de seis modelos de aprendizaje profundo, cuatro de los cuales son algunas variedades de RNC y dos son algunas variedades de modelos LSTM. Los rendimientos diagnósticos de los modelos se compararon en términos de precisión, sensibilidad, especificidad y valor predictivo positivo y negativo para determinar si existe una diferencia estadísticamente significativa entre el rendimiento de los modelos. Las conclusiones del estudio indicaron que tanto el modelo CNN como el LSTM lograron un alto rendimiento predictivo para distinguir instrumentos endodónticos separados en radiografías.

En la Ref. [3] se propone un método de previsión de la demanda basado en redes LSTM multicapa. El método propuesto mejora la precisión del pronóstico y tiene una gran capacidad para capturar patrones no lineales en datos de series de tiempo. Los resultados empíricos muestran que el método supera a otras técnicas estándar. Los autores indican que, en un entorno empresarial con competencia estricta entre empresas, hacer pronósticos precisos de la demanda no es sencillo, por lo que proponen un método de pronóstico que tiene una gran capacidad de predecir datos de demanda altamente fluctuantes.

La Ref. [4] establece que la creciente amenaza del cambio climático global derivada de la enorme huella de carbono que dejan los combustibles fósiles ha despertado el interés en explorar y utilizar recursos energéticos renovables. Para pronosticar la irradiación horizontal global solar que no solo ayuda en la gestión de la red y la distribución de energía, sino que también sobre el potencial de la producción de energía solar en Pakistán se utilizaron modelos estadísticos de aprendizaje profundo entre los que se incluyeron métodos estacionales autorregresivos integrados con promedios móviles, métodos de aprendizaje automático de memoria de corto y largo plazo (LSTM), redes neurales recurrentes (RNN), Redes Neuronales Convolucionales (CNN) y Redes Neuronales Artificiales (ANN) los cuales fueron seleccionados para el estudio por su capacidad para trabajar con datos de series de tiempo. Los autores indican además que el rendimiento de cada modelo se estudia utilizando diferentes métricas de error, como el coeficiente de determinación ( $R^2$ ), el error absoluto medio (MAE), el error cuadrático medio (MSE) y el error cuadrático medio (RMSE).

La Ref. [5] indica que el interés de la investigación por predecir a partir de series temporales ha aumentado considerablemente en las últimas décadas, ya que, por las características de las series temporales, era una tarea

complicada y con resultados inexactos. Los autores apuntan que concretamente, en este campo han aparecido modelos de aprendizaje profundo como las redes neuronales convolucionales (CNN) y las redes neuronales recurrentes (RNN) con resultados prometedores en comparación con enfoques tradicionales. Para realizar una previsión precisa y en tiempo real del precio del petróleo que juega un papel importante en la economía mundial los autores reunieron dos tipos de redes neuronales, combinando las características de una Red Convolucional de Gráficos (GCN) y una red Bidireccional de Memoria a Corto Plazo (BiLSTM). Se trata de una evolución novedosa que mejora los resultados existentes en la literatura y proporciona nuevas posibilidades en el análisis de series temporales. Los resultados confirman un mejor rendimiento del enfoque combinado BiLSTM-GCN en comparación con los modelos BiLSTM y GCN por separado, así como con los modelos tradicionales, con un menor error en todas las métricas de error utilizadas: el error cuadrático medio (RMSE), el error cuadrático medio (MSE), el error porcentual absoluto medio (MAPE) y el R cuadrado ( $R^2$ ). Estos resultados representan una menor diferencia entre el resultado devuelto por el modelo y el valor real y, por tanto, una mayor precisión en las predicciones de este modelo.

En la Ref. [6] se indica que una serie temporal es una secuencia de datos ordenados en el tiempo y generalmente se utiliza para describir cómo evoluciona un fenómeno a lo largo del tiempo. La previsión de series temporales, estimando valores futuros de series temporales, permite implementar estrategias de toma de decisiones. El aprendizaje profundo, el campo actualmente líder del aprendizaje automático, aplicado al pronóstico de series temporales puede hacer frente a series temporales complejas y de alta dimensión que normalmente no pueden manejarse con otras técnicas de aprendizaje automático. Los autores en este trabajo proporcionan una revisión de las arquitecturas de aprendizaje profundo más modernas para la predicción de series temporales, subrayan los avances recientes y los problemas abiertos, y también prestan atención a los conjuntos de datos de referencia. Además, el trabajo presenta una distinción clara entre arquitecturas de aprendizaje profundo que son adecuadas para la previsión a corto y largo plazo. Además, en este trabajo se describen las arquitecturas más recientes para el pronóstico de series de tiempo, tales como redes neuronales gráficas, procesos gaussianos profundos, redes generativas adversarias, modelos de difusión y transformadores.

La Ref. 7 indica que, en el competitivo mercado actual, la previsión de ventas de productos recién lanzados y de corto plazo es un desafío importante porque no hay suficientes datos de ventas. Para abordar estos desafíos, este estudio propone un modelo de pronóstico de ventas para productos nuevos y de corto plazo y estudia el caso de los teléfonos móviles. El enfoque principal es desarrollar un modelo integrado de pronóstico de ventas entrenando los patrones de ventas y las

características del producto de la misma categoría de producto. En particular, se analiza el rendimiento de 12 modelos de aprendizaje automático y se propone el mejor modelo de rendimiento. Los autores indican que se han utilizado modelos de aprendizaje automático para comparar el rendimiento mediante el desarrollo de Ridge, Lasso, Support Vector Machine (SVM), Random Forest, Gradient Boosting Machine (GBM), AdaBoost, LightGBM, XGBoost, CatBoost, Deep Neural Network (DNN), Recurrent Neural Network (RNN) y memoria largo y corto plazo (LSTM). Se utilizó un conjunto de datos que consta de datos de ventas mensuales de 38 teléfonos móviles obtenidos en el mercado coreano. El estudio concluye que el modelo Random Forest es un modelo excelente que supera a otros modelos en términos de precisión de predicción.

La Ref. 8 indica que la previsión precisa y en tiempo real de la demanda de productos es la necesidad del momento en el mundo de la gestión de la cadena de suministro, por lo que predecir la demanda futura de productos a partir de datos históricos de ventas es un problema altamente no lineal, sujeto a diversos factores externos y factores ambientales. Los autores proponen un modelo de pronóstico optimizado: un modelo de aprendizaje de máquina extremo (ELM) junto con el algoritmo de optimización Harris Hawks (HHO) para pronosticar la demanda de productos en una empresa de comercio electrónico.

Los autores además indican que se prefiere el modelo ELM a las redes neuronales tradicionales principalmente debido a su rápida velocidad computacional, lo que permite un pronóstico de demanda eficiente en tiempo real. Los resultados del estudio muestran que el modelo ELM-HHO mejora en un 62.73% el error RMSE comparado con el obtenido por el modelo de ARIMA que comúnmente se utiliza y en un 34.05% comparado con el modelo de red neuronal.

La Ref. 9 establece que los comercios minoristas deben tener pronósticos de ventas precisos para operar sus negocios de manera eficiente y efectiva y seguir siendo competitivos en el mercado. El estudio también indica que los modelos de pronóstico global como los RNN pueden ser una herramienta poderosa para el pronóstico en entornos minoristas, donde múltiples series de tiempo a menudo están interrelacionadas e influenciadas por una variedad de factores externos, de tal manera que al incluir covariables en un modelo de pronóstico, a menudo se puede capturar mejor los diversos factores que pueden influir en las ventas en un entorno minorista, y esto puede ayudar a mejorar la precisión de los pronósticos y permitir una mejor toma de decisiones para la gestión de inventario, compras y otras decisiones operativas. En este estudio se investiga cómo la precisión de los modelos de pronóstico global se ve afectada por la inclusión de diferentes covariables de demanda potencial. Los resultados obtenidos de los modelos DeepAR entrenados en diferentes combinaciones de características indican que la inclusión de características relacionadas con el tiempo, el evento y la identificación mejora

constantemente la precisión del pronóstico, y que el rendimiento óptimo se logra cuando todas estas covariables se emplean juntas, lo que genera una mejora del 1,8 % en el indicador de raíz cuadrada del error cuadrático medio RMSE y una mejora del 6,5 % en el indicador de error medio absoluto escalado MASE en comparación con el modelo de referencia sin características.

La Ref. 10 propone que, para fomentar una programación adecuada de los empleados para gestionar la carga del personal, los restaurantes necesitan una previsión de ventas precisa. En este estudio los autores proponen un estudio de caso que incluye modelos de redes neuronales recurrentes (RNN). Para probar los efectos de la tendencia y la estacionalidad, se generaron tres conjuntos de datos diferentes para entrenar los modelos de redes neuronales recurrentes y comparar sus resultados. Los modelos se compararon en función de su rendimiento para pronosticar pasos de tiempo de un día y una semana en un conjunto de datos de prueba seleccionados. Los mejores resultados observados en las previsiones a un día provienen de modelos lineales con un error medio absoluto porcentual simétrico (sMAPE) de sólo el 19,6%. Dos modelos RNN, LSTM y TFT, y modelos de conjunto también obtuvieron buenos resultados con errores inferiores al 20%. Adicionalmente, al pronosticar una semana, los modelos que no son RNN tuvieron un desempeño deficiente y arrojaron resultados con un error inferior al 20 %.

La Ref. 11 indica que el pronóstico de series de tiempo es una herramienta poderosa que puede ayudar a las empresas de construcción a optimizar su cadena de suministro al pronosticar la demanda de materiales, mano de obra y equipos de construcción. El autor establece que analizar datos históricos sobre ventas, proyectos de construcción y otras variables, las empresas constructoras pueden tomar decisiones informadas sobre inventario, producción, contratación, programación, adquisiciones y precios. Más aún se establece que la previsión de series de tiempo puede ayudar a las empresas de construcción a reducir los residuos, mejorar la eficiencia en la cadena de suministro y garantizar la entrega oportuna de materiales, por lo que el pronóstico de series de tiempo se convertirá en una herramienta esencial para los líderes y tomadores de decisiones en esta industria.

La Ref. 12 indica que las técnicas tradicionales de aprendizaje automático a menudo no logran generar estimaciones predictivas precisas de los costos de materiales de construcción debido a las altas incertidumbres asociadas con los precios de los materiales. Para abordar este problema, los autores de esta investigación proponen un método basado en redes neuronales artificiales (RNA) para cuantificar las incertidumbres mediante la generación de intervalos de pronóstico. Se adopta el método de estimación del límite superior inferior óptimo (LUBE óptimo) para entrenar a ANN para que genere intervalos directamente. El método propuesto se utiliza para predecir los precios de los materiales de

construcción en los EE. UU. para asfalto y acero. Los resultados de otras tres funciones de costos se comparan con la función de costos LUBE óptima propuesta para testificar la precisión del modelo. Los resultados obtenidos muestran que la función de coste LUBE óptima propuesta presenta los intervalos de predicción más precisos, por lo que el método de pronóstico de intervalos propuesto presenta una nueva dirección para los estudios de predicción de costos para gestionar los riesgos asociados con los costos de los proyectos.

La Ref. 13 indica que este trabajo tiene como objetivo evaluar modelos de previsión de la demanda para determinar si el uso de factores exógenos y técnicas de aprendizaje automático ayudan a mejorar el rendimiento de los modelos de pronóstico en comparación con los modelos estadísticos univariados. Los autores indican que se implementó un modelo estadístico de promedio móvil autorregresivo multivariado con entrada exógena (ARMAX) y un modelo híbrido Neural Network-ARMAX (NN-ARMAX) para pronóstico. Posteriormente, compararon ambos con un modelo estadístico univariado estándar para pronosticar la demanda de productos eléctricos en una empresa manufacturera colombiana. Los resultados demostraron que el modelo NN-ARMAX superó a los otros dos, permitiendo la reducción del exceso de existencias y de productos agotados, por lo que el trabajo sugiere que un modelo que utiliza redes neuronales e incluye variables exógenas puede mejorar la precisión del pronóstico de la demanda.

La Ref. 14 establece que, en el ámbito de la gestión de la cadena de suministro minorista, la previsión precisa es fundamental para la toma de decisiones informada, ya que afecta directamente las operaciones comerciales y la rentabilidad. Los autores profundizan en la aplicación de la predicción de conjuntos basada en árboles, específicamente utilizando regresores de árboles adicionales (ETR) y redes de memoria a corto plazo (LSTM). Utilizando más de seis años de datos de demanda histórica de una entidad minorista, el estudio abarca tres categorías de productos perecederos. Frescos. Los resultados obtenidos revelan que el modelo ETR supera a LSTM en métricas que incluyen MAPE, MAE, RMSE y R2.

La Ref. 15 indica que Los datos relativos a las ventas de productos son un tema popular en la previsión de series temporales debido a su multidimensionalidad y su amplia presencia en muchas empresas. Este artículo describe la investigación para predecir el momento y la categoría de producto de la próxima compra basándose en datos históricos de transacciones de clientes. Los modelos construidos se basan en redes neuronales recurrentes (RNN) y redes neuronales de memoria a corto plazo (LSTM) con diferentes características de entrada y salida, y conjuntos de datos de entrenamiento. Se realizaron experimentos con varios conjuntos de datos y se identificaron estructuras y tipos de red óptimos para predecir tanto la categoría de producto como el próximo día de compra.

La contribución clave de esta investigación es el proceso de transformación de datos desde su formato de transacción de compra original a una serie temporal de características de entrada para la predicción de la próxima compra. Con este enfoque, es posible implementar un sistema de marketing personalizado dedicado para un proveedor.

#### *A. Modelos de Pronóstico Utilizando Algoritmos de Aprendizaje Profundo Mediante Redes Neuronales Recurrentes LSTM*

El objetivo principal de este trabajo es encontrar un modelo de pronósticos utilizando algoritmos de aprendizaje profundo como las redes neuronales recurrentes de largo-corto plazo LSTM que mejor se ajuste a un conjunto de datos de ventas de perfiles estructurales de acero utilizados en la construcción de edificios, y comparar el modelo de red neural encontrado con los modelos de pronóstico obtenidos mediante un modelo polinomial de tercer grado que utiliza la regresión múltiple y un modelo de Winter con detección automática de estacionalidad. La comparación se hace en términos de los indicadores de precisión del pronóstico RMSE, MAD y MAPE.

La Ref. 16 indica que en general, los algoritmos tradicionales de pronóstico tienden a utilizar técnicas predefinidas y modelos estadísticos como la regresión lineal, la media móvil integrada autorregresiva (ARIMA) y la media móvil integrada autorregresiva con variable explicativa (ARIMAX), mientras que los algoritmos de pronóstico de aprendizaje automático a menudo utilizan técnicas que involucran características más complejas y métodos predictivos, pero que el objetivo de los métodos de pronóstico de aprendizaje automático es el mismo que el de los métodos tradicionales: mejorar la precisión de los pronósticos y minimizar la función de pérdida. La función de pérdida generalmente se toma como la suma de cuadrados debido a errores en la predicción/pronóstico.

La hipótesis de trabajo indica que los métodos de pronóstico estimados mediante redes recurrentes neuronales de corto plazo LSTM producen errores de pronósticos significativamente menores, haciendo que los valores pronosticados sean más robustos para la toma de decisiones.

La Ref. 17 indica que una red neuronal recurrente (RNN) es un modelo de aprendizaje profundo que está entrenado para procesar y convertir una entrada de datos secuencial en una salida de datos secuencial específica. El autor establece que los datos secuenciales son datos, como palabras, oraciones o datos de serie temporal, en los que los componentes secuenciales se interaccionan en función de reglas semánticas y sintácticas complejas. Además, el autor indica que la memoria a corto plazo largo(LSTM) es una variante de RNN que permite al modelo ampliar su capacidad de memoria para adaptarse a una

línea de tiempo más larga ya que solo puede recordar la entrada pasada inmediata. No puede usar entradas de varias secuencias anteriores para mejorar su predicción.

La Ref. 18 indica que un modelo de regresión lineal múltiple es un modelo estadístico versátil para evaluar las relaciones entre un destino continuo y los predictores. Los predictores pueden ser campos continuos, categóricos o derivados, de modo que las relaciones no lineales también estén soportadas. El modelo es lineal porque consiste en términos de aditivos en los que cada término es un predictor que se multiplica por un coeficiente estimado. El término de constante (intercepción) también se añade normalmente al modelo.

La Ref. 19 denota que el método Holt- Winters es una extensión del método Holt que considera solo dos exponentes suavizantes. El modelo Holt-Winters considera nivel, tendencia y estacionalidad de una determinada serie de tiempo. La autora indica que este método tiene dos principales modelos, dependiendo del tipo de estacionalidad: el primero es el *modelo multiplicativo estacional* el cual presupone que a medida que se incrementan los datos, también se incrementa el patrón estacional. El segundo es el *modelo aditivo estacional* en el cual los efectos de los factores individuales se diferencian y se agrupan para modelar los datos.

La Ref. 20 señala que los algoritmos de previsión se han utilizado para apoyar la toma de decisiones en las empresas, siendo necesario aplicar enfoques que faciliten un buen resultado de previsión. Los autores además establecen que este tipo de estudio es importante para comprender el comportamiento de los modelos y la sensibilidad a los hiperparámetros de las redes neuronales recurrentes convolucionales LSTM.

La Ref. 21 indica que existen estudios comparativos que evalúan el rendimiento de los métodos LSTM y los métodos tradicionales en diferentes conjuntos de datos de series temporales, y los resultados sugieren que los métodos LSTM pueden ofrecer una mayor precisión y robustez en algunos casos, pero también requieren más recursos computacionales y son menos interpretables.

La hipótesis de trabajo de este estudio sugiere que dada la variabilidad significativa que presentan en el tiempo los datos de venta de perfiles estructurales, los métodos de pronóstico estimados mediante redes recurrentes neuronales de corto plazo LSTM producen errores de pronósticos significativamente menores que los que se obtienen mediante los métodos tradicionales indicados anteriormente, haciendo que los valores pronosticados sean más robustos en términos de la precisión del pronóstico para la toma de decisiones.

## B. Metodología General Para Realizar el Pronóstico de la Demanda Mediante una Red Neuronal de Largo-Corto Plazo LSTM

La Fig. 1 resume las etapas necesarias para la obtención del pronóstico de la demanda utilizando redes neuronales recurrentes.

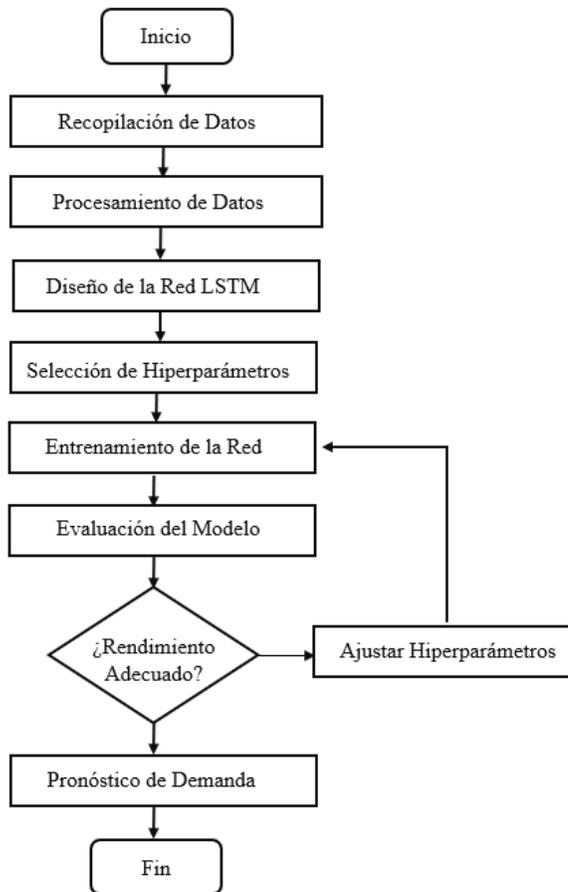


Fig. 1 Metodología General la Determinación del Pronóstico de la Demanda Mediante Redes Neuronales Recurrentes LSTM.

## II. DEFINICIÓN DEL CASO DE ESTUDIO

En Costa Rica el sector ferretero y de construcción está en constante evolución. Para la realización de este estudio se seleccionó una empresa costarricense que se dedica a la venta de materiales de construcción, ferretería, herramientas y productos para el hogar y cuenta con más de 50 sucursales en todo el país. La necesidad de desarrollar un modelo de pronóstico que permita estimar la demanda diaria de productos con un mayor nivel de precisión hace pensar que los algoritmos de aprendizaje profundo podrían proporcionar un mejor desempeño de los indicadores de precisión del error de pronóstico. La Tabla I muestra un segmento de la base de datos de las ventas diarias de perfiles estructurales utilizados para la realización del pronóstico de la demanda.

TABLA I  
SEGMENTO DE LA BASE DE DATOS

Periodo	ID	Fecha	Unidades Vendidas
1	2011026	2021-01-02	636
2	2011026	2021-01-03	25
3	2011026	2021-01-04	1195
4	2011026	2021-01-05	835
5	2011026	2021-01-06	868
...			
899	2011026	2023-07-16	44
900	2011026	2023-07-17	601
901	2011026	2023-07-18	597
902	2011026	2023-07-19	615

### III. METODOLOGÍA PARA LA OBTENCIÓN DE LA RED NEURONAL

La Fig. 2 muestra el procedimiento detallado para la obtención de la red neuronal.

En una primera fase del procedimiento de pronóstico se recopilan y se almacenan los datos con las cantidades de producto vendidas cada día. La calidad y estructura de los datos son fundamentales para el éxito de los modelos analíticos de aprendizaje automático, por lo que se requiere realizar un refinamiento de los datos históricos como se indica en la Fig. 2. En una segunda fase del procedimiento se seleccionan y se optimizan los hiperparámetros, para posteriormente realizar el pronóstico de la demanda.

### IV. MODELADO MATEMÁTICO DEL ALGORITMO LSTM PARA EL PRONÓSTICO DE LA DEMANDA

El modelo matemático LSTM para el pronóstico de la demanda se modeló utilizando el lenguaje de programación Python. El código primero inicializa el modelo LSTM con dos capas LSTM y una capa de salida. La capa de entrada tiene dos características, que son las ventas y la capa de salida tiene una característica, que es el número de ventas pronosticado para el umbral de pronóstico.

El modelo se compila con el optimizador Adam y la función de pérdida de error cuadrático medio. Luego se ajustan los datos durante un número especificado de épocas y tamaño de lote. Finalmente, el modelo hace predicciones para el horizonte de pronóstico especificado.

Una vez completado el proceso de entrenamiento y validación de la red neuronal, se procede a evaluar la capacidad predictiva del modelo utilizando un conjunto de pruebas. Este conjunto está compuesto por datos que el modelo no ha visto desempeño en escenarios del mundo real.

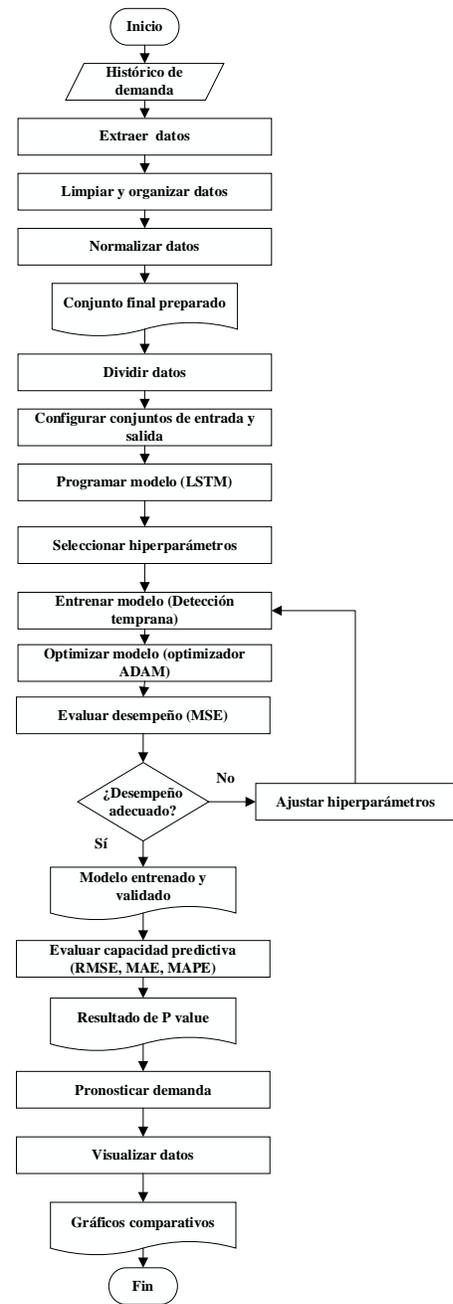


Fig. 2 Metodología Para el Pronóstico de la Demanda Mediante Redes Neuronales Recurrentes LSTM.

La primera etapa de la evaluación implicó generar predicciones para estos datos. Estas predicciones, que inicialmente estaban en una forma normalizada, se sometieron a un proceso de desnormalización utilizando el método MinMaxScaler, para traducirlas nuevamente a su escala original y obtener valores reales y comprensibles. Ver Ref. 21.

Para determinar la eficacia del modelo en términos cuantitativos, se utilizaron tres métricas de cálculo del error de pronóstico. Estas fueron el RMSE, el MAE y el MAPE. La

desviación estándar de los valores residuales o RMSE es especialmente útil, ya que penaliza fuertemente los errores grandes, lo que significa que un RMSE más alto indica peores niveles de precisión. Ver Ref. 22. El error medio absoluto o MAE, que representa el promedio de las diferencias absolutas entre las predicciones y los verdaderos valores proporciona una medida lineal de los errores, lo que significa que todos los errores individuales se tratan por igual, independientemente de su magnitud. Ver Ref. 23. El MAPE o error porcentual absoluto medio es útil para comparar diferentes métodos de pronóstico o para evaluar el desempeño del pronóstico a lo largo del tiempo. Un MAPE bajo significa que el pronóstico es más exacto y se ajusta mejor a la demanda real. Un MAPE alto significa que el pronóstico tiene más error y se aleja de la demanda real.

### C. Nomenclatura

Donde:  $c_t$  es el estado de la celda LSTM en el tiempo  $t$ .  
 $c_{(t-1)}$  es el estado de la celda LSTM en el tiempo  $t-1$ .  
 $h_{(t-1)}$  es la salida de la celda LSTM en el tiempo  $t-1$ .  
 $W_{ic}$  es el peso de la conexión entre la capa oculta, y la celda LSTM.  
 $W_{ic}$  es el peso de la conexión entre la entrada y la celda LSTM.  
 $b_c$  es el sesgo de la celda LSTM.  
 $\sigma$  es la función de sigmoide.  
 $\phi$  es la función tangente hiperbólica.  
 $X_t$ : Entrada.  
 $h_{(t-1)}$ : Estado Oculto.  
 $c_{(t-1)}$ : Estado de la celda LSTM.  
 $C_t$ : Salida  
 $W_{fc}$ : Matriz de pesos para la compuerta de olvido.  
 $W_{ic}$ : Matriz de pesos para la compuerta de entrada  
 $W_{oc}$ : Matriz de pesos para la compuerta de salida  
 $b_c$ : Vector de sesgo para el estado de la celda LSTM

### D. Ecuaciones Matemáticas del Modelo LSTM

1. Función de pérdida de error cuadrático medio:

$$J = 1/(N * \sum (y - y^{\text{hat}})^2)$$

donde  $y$  es el valor real,  $y^{\text{hat}}$  es el valor pronosticado, y  $N$  es el número de muestras.

2. Función de activación de la puerta de entrada:

$$\sigma(x) = 1/(1 + e^{-x})$$

donde  $x$  es la entrada a la puerta de entrada.

3. Función de activación de la puerta de olvido:

$$\phi(x) = 1/(1 + e^{-x})$$

donde  $x$  es la entrada a la puerta de olvido

4. Función de activación de la puerta de salida:

$$\omega(x) = 1/((1 + e^{-x}))$$

donde  $x$  es la entrada a la puerta de salida.

5. Actualización del estado de la celda:

$$c_t = \phi(W_{fc} * h_{(t-1)} + W_{ic} * x_t + b_c) * c_{(t-1)} + \sigma(W_{oc} * h_{(t-1)} + W_{ic} * x_t + b_c) * h_{(t-1)}$$

6. Compuerta de olvido:

$$g_t = \phi(W_{fc} * h_{(t-1)} + W_{ic} * x_t + b_c)$$

7. Compuerta de entrada:

$$I_t = \sigma(W_{ic} * h_{(t-1)} + W_{ic} * x_t + b_c)$$

8. Compuerta de salida:

$$O_t = \sigma(W_{oc} * h_{(t-1)} + W_{ic} * x_t + b_c)$$

9. Actualización del estado de la celda:

$$c_t = g_t * c_{(t-1)} + i_t * \tanh(c_t)$$

10. Salida:

$$h_t = o_t * \tanh(c_t)$$

## V. RESULTADOS OBTENIDOS

La Fig. 3 muestra la variabilidad significativa que presentan las ventas diarias de perfiles estructurales. El gráfico revela que las ventas diarias tienen un rango que va desde cero hasta más de 3000 perfiles vendidos por día.

Para contrastar la bondad de la red neuronal LSTM como modelo de predicción robusto cuando los datos históricos de demanda presentan una variabilidad significativa se seleccionaron dos modelos de pronóstico utilizados con frecuencia: un modelo de regresión polinomial de tercer grado y un modelo de Holt-Winters con estacionalidad detectada automáticamente. La Ref. 24 indica que los modelos de pronóstico polinomiales de orden 3 son herramientas valiosas en la estadística y análisis de datos, especialmente cuando se trata de ajustar curvas a conjuntos de datos que presentan tendencias no lineales.

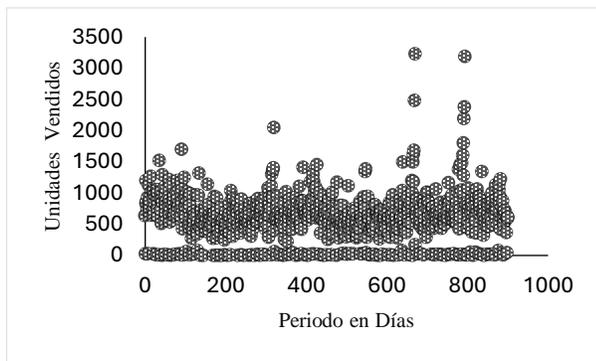


Fig. 3 Variabilidad de los Datos Históricos de Demanda.

Estos modelos son capaces de capturar la relación entre variables independientes y dependientes de una manera que los modelos lineales no pueden. Con respecto al método de pronóstico de Holt-Winters la Ref. 25 indica que este método es ampliamente reconocido por su capacidad para modelar series de tiempo que presentan tanto tendencia como estacionalidad. Es particularmente efectivo para realizar pronósticos a corto plazo, lo que es crucial para la planificación y toma de decisiones.

La tabla II muestra las métricas de desempeño resultantes con los tres métodos de pronóstico estudiados en este trabajo.

TABLA II  
RESULTADOS DE LAS MÉTRICAS DE DESEMPEÑO DEL PRONÓSTICO

Modelo	Métricas de Desempeño		
	RMSE	MAE	MAPE
Polinomial	352.76	241.44	1547.32
Holt-Winters	364.55	227.92	566.9
LSTM	73.72	51.94	15.31

Los resultados de la tabla muestran que el modelo LSTM supera significativamente a los modelos Polinomial y Holt-Winters en términos de precisión de pronóstico, con valores bajos de RMSE, MAE y MAPE. Además, el modelo polinomial parece ser el menos preciso, con los valores más altos en todas las métricas de desempeño, mientras que el modelo Holt-Winters se ubica entre el polinomial y el LSTM en términos de precisión, con resultados intermedios en todas las métricas evaluadas.

La tabla III muestra los porcentajes de reducción del error de predicción RMSE, MAE y MAPE del modelo de pronóstico de red neuronal recurrente LSTM con respecto a los métodos Polinomial y Holt-Winters.

TABLA III  
RESULTADOS DE LAS MÉTRICAS DE DESEMPEÑO DEL PRONÓSTICO

Modelo	Porcentaje de Reducción del Error		
	RMSE	MAE	MAPE
LSTM versus Polinomial	79.14	78.54	99.01
LSTM versus Holt-Winters	79.76	77.22	97.30

Estas comparaciones indican que, el modelo LSTM supera al modelo polinomial y al modelo Winters en términos de precisión predictiva en un porcentaje significativo en todas las métricas consideradas. Esto resalta la ventaja del modelo de red neuronal LSTM sobre los otros dos métodos tradicionales estudiados en este trabajo cuando la variabilidad de los datos es significativamente alta.

## VI. DISCUSIÓN

En este estudio se han comparado los métodos de pronóstico tradicionales de Holt-Winters y polinomial con el método de red neuronal LSTM en un conjunto de datos de demanda histórica que presentan una variabilidad significativa de un periodo a otro. Los resultados de la comparación indicaron que el método de red neuronal LSTM presenta métricas de desempeño significativamente mejores que las obtenidas con los métodos tradicionales de pronóstico indicados anteriormente. Esta mejoría en las métricas de desempeño de los modelos de aprendizaje automático parece estar en concordancia con otros estudios de comparación realizados como los indicados anteriormente en la revisión de literatura.

## CONCLUSIONES

1. Superioridad del modelo LSTM: El modelo LSTM demostró ser superior en términos de precisión predictiva en comparación con los modelos polinomial y Holt-Winters. Esto se evidencia en su menor RMSE, MAE y MAPE en todos los casos.
2. Desempeño deficiente del modelo Polinomial y Holt-Winters: Tanto el modelo Polinomial como el modelo Holt-Winters mostraron un desempeño deficiente en comparación con el LSTM. Esto se refleja en sus altos valores de RMSE, MAE y MAPE, indicando que sus predicciones tienden a estar más alejadas de los valores reales en promedio cuando la variabilidad de los datos es significativamente alta.
3. Gran diferencia en MAPE: La métrica MAPE revela una gran disparidad en el desempeño entre los modelos Polinomial y Holt-Winters con el modelo LSTM, mostrando un MAPE significativamente más bajo. Esta diferencia destaca la capacidad del modelo de red neuronal

LSTM para hacer predicciones más precisas y consistentes.

4. Mejora porcentual significativa: La comparación porcentual de mejora entre el modelo de pronóstico LSTM y los otros modelos revela que el modelo de red neuronal tiene una mejora porcentual significativamente mejor en comparación con todas las métricas de los modelos polinomial y Holt-Winters.
5. Validación de la elección del modelo LSTM: Los resultados respaldan la elección del modelo LSTM para hacer pronósticos de la demanda especialmente cuando las series de tiempo de los datos históricos de venta muestran gran variabilidad en periodos cortos de tiempo.

#### REFERENCIAS

- [1] P. Goodwin, J. Hoover, S. M. Spyros, F. Petropoulos, L. Tashman, "Business forecasting methods: Impressive advances, lagging implementation", *PLoS ONE*, Vol. 18 Issue 12, p1-12. 12p, December 2023
- [2] C. Buyuk, B. Alpay, F. Er, "Detection of the separated root canal instrument on panoramic radiograph: a comparison of LSTM and CNN deep learning methods", *Dentomaxillofacial Radiology*, Vol. 52 Issue 3, p1-10. 10p, February 2023
- [3] H. Abbasimehr, M. Shabani, M. Yousefi, Mohsen, "An optimized model using LSTM network for demand forecasting", *Computers & Industrial Engineering*. Vol. 143, pN.PAG-N.PAG. 1p, May 2020.
- [4] S. Haider, M. Sajid, H. Sajid, E. Uddin, Y. Ayaz, "Deep learning and statistical methods for short- and long-term solar irradiance forecasting for Islamabad", *Renewable Energy*, Vol. 198, p51-60. 10p, October 2022,
- [5] Lazcano, P. Herrera, M. Monge, "A Combined Model Based on Recurrent Neural Networks and Graph Convolutional Networks for Financial Time Series Forecasting", *Mathematics*; Basel Tomo 11, N.º 1, 2023
- [6] Casolaro, V. Capone, G. Iannuzzo, F. Camastra, "Deep Learning for Time Series Forecasting: Advances and Open Problems", *Information*; Basel Tomo 14, N.º 11, 2023
- [7] S. Hwang, G. Yoon, E. Baek, J. K. Byoung-Ki, "A Sales Forecasting Model for New-Released and Short-Term Product: A Case Study of Mobile Phones", *Electronics*; Basel Tomo 12, N.º 15, 2023
- [8] C. Koushiki Dasgupta; A. Bugra. "A hybrid extreme learning machine model with harris hawks optimization algorithm: an optimized model for product demand forecasting applications", *Applied Intelligence*; Boston Tomo 52, N.º 10, August 2022.
- [9] P. Ramos, J. Oliveira. "Robust Sales Forecasting Using Deep Learning with Static and Dynamic Covariates", *Applied System Innovation*; Basel Tomo 6, N.º 5, 2023
- [10] Schmidt, K. Wasi Ul Kabir; T. Hoque, "Machine Learning Based Restaurant Sales Forecasting", *Machine Learning and Knowledge Extraction*; Basel Tomo 4, N.º 1, 2022
- [11] R. David, "Using Time Series Forecasting to Optimize the Supply Chain in Construction Industry", 2023  
<https://www.linkedin.com/pulse/using-time-series-forecasting-optimize-supply-chain-industry-david/>
- [12] M. Mir, H.M. Dipu Kabir, F. Nasirzadeh, A. Khosravi, "Neural Network-Based Interval Forecasting of Construction Material Prices", *Journal of Building Engineering*, Volume 39, July 2021
- [13] H. Quiñones, O. Rubiano, A. Morales, "Demand Forecasting Using a Hybrid Model Based on Artificial Neural", *Journal of Industrial Engineering and Management*; Barcelona Tomo 16, N.º 2, (2023): 363-381
- [14] M. Nasser, F. Taha, P. Brandtner, F. Darbianian, "Applying Machine Learning in Retail Demand Prediction—A Comparison of Tree-Based Ensembles and Long Short-Term Memory-Based Deep Learning", *Applied Sciences*; Basel Tomo 13, N.º 19, 2023
- [15] M. Ćirić, B. Predić, D. Stojanović, "Single and Multiple Separate LSTM Neural Networks for Multiple Output Feature Purchase Prediction", *Electronics*; Basel Tomo 12, N.º 12, 2023
- [16] The evolution of forecasting techniques: Traditional versus machine learning methods, GENPACT. <https://www.genpact.com/insight/the-evolution-of-forecasting-techniques-traditional-versus-machine-learning-methods>
- [17] ¿Qué son las RNN?", AWS. <https://aws.amazon.com/es/what-is/recurrent-neural-network/>
- [18] Regresión Lineal Múltiple, IBM. <https://www.ibm.com/docs/es/cognos-analytics/11.1.0?topic=tests-multiple-linear-regression>
- [19] N. Rosales, "Holt-Winters", RPubS. <https://rpubs.com/nanrosvil/283121>
- [20] C. Mateus, M. Mendes, J. Torres, A. Marques, R. Assis. "Forecasting Steel Production in the World—Assessments Based on Shallow and Deep Neural Networks", *Applied Sciences*; Basel Tomo 13, N.º 1, 2023
- [21] Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., ... & Vanderplas, J. (2011). *Scikit-learn: Machine learning in Python*. *Journal of machine learning research*, 12(85), 2825-2830. 2011.
- [22] Hyndman, R.J., & Athanasopoulos, G. (2018). *Forecasting: principles and practice*. (2a ed.) OTexts.
- [23] Willmott, C.J., & Matsuura, K. (2005). Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate Research*, 30(1), 79-82.
- [24] Villareal, F. "Introducción a los Modelos de Pronósticos", Universidad Nacional del Sur. 2016. [https://www.matematica.uns.edu.ar/uma2016/material/Introduccion\\_a\\_los\\_Modelos\\_de\\_Pronosticos.pdf](https://www.matematica.uns.edu.ar/uma2016/material/Introduccion_a_los_Modelos_de_Pronosticos.pdf)
- [25] Una Introducción Completa a la Predicción de Holt-Winters. ICHI.PRO. <https://ichi.pro/es/una-introduccion-completa-a-la-prediccion-de-holt-winters-213408615547110>