

PREDICCIÓN DE LA DEMANDA DE UN PRODUCTO CON REDES NEURONALES

**Ángel Felipe Altamirano Tapias, aathatint@libertadores.edu
Maria Alejandra Marin Peralta, mamarinp02@libertadores.edu**

RESUMEN

La obtención de un pronóstico acertado que brinde información relevante del comportamiento del mercado y de la demanda de un producto, siempre ha sido fundamental para las empresas. Por ello se han realizado diversos esfuerzos en la creación de metodologías para predecir con un alto grado de exactitud el comportamiento de un negocio. Usualmente, los modelos estadísticos de predicción lineales y de estadística descriptiva han sido los más utilizados por su sencillez y fácil interpretación.

En este trabajo se realizó un modelo de redes neuronales recurrentes LSTM para predecir las unidades facturadas de una determinada referencia, alcanzando niveles de error bajo, lo que confirma la confiabilidad de la herramienta para pronóstico de demanda.

Palabras clave: Pronostico de demanda, Redes Neuronales recurrentes, LSTM.

ABSTRACT

Obtaining an accurate forecast that provides relevant information on the behavior of the market and the demand for a product has always been essential for companies. For this reason, various efforts have been made to create methodologies to predict the behavior of a business with a high degree of accuracy. Usually, the statistical models of linear prediction and descriptive statistics have been the most used due to their simplicity and easy interpretation.

In this work, an LSTM recurrent neural network model was carried out to predict the billed units of a given reference, reaching low error levels, which confirms the reliability of the demand forecasting tool.

Keywords: Demand Forecasting, Recurrent Neural Networks, LSTM

INTRODUCCIÓN

En un entorno cada vez más competitivo, las empresas han de tomar decisiones estratégicas acertadas en la elaboración de sus presupuestos y planeación operativa. Para ello, tener la información del comportamiento del mercado y de sus datos de ventas es fundamental para predecir el comportamiento a futuro del mercado y de todo a aquello que signifique un riesgo u oportunidad de progreso en el manejo de sus finanzas.

Por lo anterior es valioso realizar un pronóstico que permita predecir este comportamiento a futuro; a partir de este “el tomador de decisiones puede determinar la capacidad que se requiere en la red de transmisión para satisfacer la demanda, así como determinar con anticipación si es necesaria una expansión de capacidad” (Salazar & Cabrera, 2007).

Los autores Salazar & Cabrera (2007), señalan: “para un pronóstico es común requerir información cuantitativa del comportamiento de la demanda a través del tiempo, es decir, una serie de tiempo, siendo el Análisis de la serie de tiempo la técnica estadística más utilizada para estimar su comportamiento” (p.7).

El análisis anterior descrito ayudará al objetivo de encontrar un modelo para la realización de pronóstico de demanda que reduzcan la incertidumbre de los datos y den información para una mejor toma de decisiones y así mejorar la eficiencia de la planeación

de la demanda, esto a su vez podrá contribuir a mejorar el nivel de servicio a los clientes y los niveles de inventario, lo que representa un cambio positivo. (Infante, 2018, p.16)

A lo largo del tiempo estos análisis se han visto sometidos por métodos estadísticos lineales, en la práctica vemos que no todas estas series se comportan de manera lineal en los datos, por esta razón se hace necesario utilizar herramientas que consideren la No linealidad de los datos, para de esta forma obtener mayor precisión en las predicciones de demanda.

Dado lo anterior, debido a su importancia para cumplir con las exigencias del objetivo se tiene a la Inteligencia artificial, la cual “se anuncia como la nueva revolución industrial. Si el aprendizaje profundo es el vapor motor de esta revolución, entonces los datos son su carbón: la materia prima que impulsa nuestras máquinas inteligentes, sin la cual nada sería posible” (Chollet, 2018). Así, se considera primordial contar con un modelo de pronóstico que de respaldo a las decisiones en algo más que la intuición y los demás métodos simples que pudiesen ser aplicados.

ECSI SAS es una empresa del sector de transformación de plásticos, encargada de fabricar empaques plásticos para empresas de consumo masivo, dentro de estos maneja líneas de envases de polietileno y PET, bidones, canastas, cuñetes, tapas, entre otros productos plásticos los cuales, son producidos en distintas bodegas ubicadas en Bogotá, Medellín y Cali y comercializados a distintas personas jurídicas por medio de asesores comerciales. Actualmente no se manejan adecuados métodos estadísticos para el pronóstico de ventas. La predicción deficiente genera en ocasiones excesivo inventario, gastos inútiles en la fuerza de ventas, reducciones costosas de precio, pérdida de ventas, programas ineficientes de producción y planeación inadecuada del flujo de caja e inversiones de capital.

Es preciso tomar la data que se tiene del comportamiento de las ventas, analizar su conducta y generar previsión de la demanda futura con la mayor exactitud posible utilizando métodos estadísticos de machine learning, con el fin de extraer conclusiones y aprovecharlas para proveer de información útil a la organización.

REFERENTES TEORICOS

El proceso de pronosticar o *Forecasting* consiste en predecir el valor futuro de una serie temporal, bien modelando la serie temporal únicamente en función de su comportamiento pasado (autorregresivo) o empleando otras variables externas a la serie temporal (Amat Rodrigo, 2021)

Las series que queremos pronosticar varían con el tiempo y, a menudo, atribuimos la variación de componentes subyacentes no observados, como tendencias, estacionales y ciclos (Diebold, 2001).

La predicción de series de tiempo se ha convertido en un campo de investigación muy intensivo, que incluso está aumentando en los últimos años. Las redes neuronales profundas han demostrado ser poderosas y están logrando una alta precisión en muchos campos de aplicación.

Consecuentemente, se han convertido en los métodos de aprendizaje automático más utilizados para resolver problemas relacionados con grandes datos en el presente.

En coherencia, estudios previos dan cuenta que las redes neuronales profundas superan otros métodos convencionales los autores Xuanyi Song, Yuetian Liu, Liang Xue, Jun Wang, Jingzhe Zhang, Junqiang Wang, Long Jiang & Ziyang Cheng (2020), quienes proponen un modelo basado en la red neuronal Long Short-Term Memory (LSTM) para

inferir la producción de pozos horizontales fracturados en un yacimiento volcánico, comparan el rendimiento del enfoque propuesto con las redes neuronales tradicionales, demostrando que el modelo LSTM propuesto supera a otros enfoques.

Sumado a ello, autores como Lei Ji, Yingchao Zou, Kaijian He & Bangzhu Zhu (2019), encuentran mejoras en la capacidad de predicción de los precios futuros de carbono después de la combinación del modelo ARIMA, el modelo CNN y el modelo LSTM, los resultados experimentales demuestran que se puede lograr una mejor precisión de predicción que modelos individuales, en términos de medidas de rendimiento del error cuadrático medio (RMSE) y del error porcentual absoluto medio (MAPE).

Al mismo tiempo Kim, T. Y., & Cho, S. B. (2019). proponen una red neuronal CNN-LSTM que puede extraer características espaciales y temporales para predecir de manera efectiva el consumo de energía de la vivienda. Los experimentos demostraron que la combinación de la red neuronal convolucional (CNN) y la memoria a corto plazo (LSTM), puede extraer características complejas del consumo de energía. La capa CNN puede extraer las características entre varias variables que afectan el consumo de energía, y la capa LSTM es apropiada para modelar información temporal de tendencias irregulares en componentes de series de tiempo. El modelo arroja el valor más pequeño del error cuadrático medio en comparación con los métodos de pronóstico convencionales

En el sector industrial también se están utilizando técnicas de aprendizaje profundo para llevar a cabo tareas de diferentes tipos, como se puede evidenciar con los autores Xin Huang, Cecilia Zanni-Merk & Bruno Crémilleux (2019) quienes utilizan red neuronal LSTM basada en ontología, realizando experimento con un conjunto de datos de fabricación real con series de tiempo multivariadas para problemas de clasificación

demostrando que el modelo puede mejorar el rendimiento en comparación con los métodos convencionales.

Adicional , en el sector Financiero , el análisis ha sido un tema crucial , por tanto cada vez más se amplían los trabajos relacionados a esta área , como lo es el de los autores Yan, H. & Ouyang, H. (2018), quienes proponen un modelo de predicción de series de tiempo para capturar características complejas como la correlación de secuencia, no lineal y no estacionaria de series de tiempo financieras utilizando LSTM aplicado a la predicción del precio de cierre diario del Índice Compuesto de Shanghai, comparando su capacidad de predicción con modelos de aprendizaje automático como perceptrón multicapa, máquina de vectores de soporte y K vecinos más cercanos. Los resultados empíricos muestran que el LSTM realiza un mejor efecto de predicción, y muestra excelentes efectos sobre la predicción estática y la predicción de tendencias dinámicas de las series de tiempo financieras, lo que indica su aplicabilidad y efectividad a la predicción de series de tiempo financieras.

En este orden de ideas, el aprendizaje profundo se puede aplicar a numerosas investigaciones. Las aplicaciones a problemas supervisados y no supervisados se pueden encontrar abundantemente en la literatura.

El método para la predicción de la demanda utilizado en la presente investigación está constituido por una red neuronal recurrente LSTM que aprende de los datos históricos a largo plazo.

La red aprende los valores futuros de una serie temporal en función de los valores anteriores y, como toda RNN, permite conexiones arbitrarias entre las neuronas, generando temporalidad y, desde luego, memoria

La red LSTM tiene una arquitectura recurrente con conexiones que retroalimenta las capas de la red, permitiendo analizar los mismos problemas que una máquina de Turing. Una red neuronal recurrente tradicional está compuesta por una sola capa, la cual calcula el peso que van a tener los datos históricos. Por lo tanto, las redes LSTM solucionan el problema de largo plazo con el que se encuentran las redes neuronales recurrentes tradicionales, logrando resolver el problema que surge cuando se necesitan datos de muchos ciclos atrás para realizar la predicción del ciclo. (Coy-Mondragón, G. E., Granados, O. & Garcia-Bedoya, O, 2021)

METODOLOGÍA

Fase 1. Análisis Exploratorio de los datos

En esta fase se compilo la información necesaria como instrumento para el modelo de pronóstico.

Para el caso de estudio se propone el análisis de Pareto, para determinar el producto con mayor cantidad de unidades demandadas. Basándose en este análisis se decidió seleccionar el producto de referencia PT951955, de la línea de producto, Envases PET.

De igual manera se seleccionaron las variables a considerar para realizar el modelo de pronóstico.

Fase 2. Diseño de Herramienta para el Pronostico

En esta fase se busca obtener el instrumento para la creación del modelo de pronóstico.

El método utilizado para el pronóstico de demanda del producto seleccionado fue una red neuronal recurrente LSTM, que aprendió con datos históricos a largo plazo. Esta técnica utilizada en Deep learning, “permite conexiones arbitrarias entre las neuronas, generando temporalidad y, desde luego, memoria” (Coy-Mondragón, Granados & Garcia-Bedoya, 2021).

- Los datos contienen el registro histórico del comportamiento de demanda del producto de 2006 a 2018.
- Para el entrenamiento del modelo se tomaron los datos de 2016 hacia atrás. La validación se realizó con datos de 2017 en adelante, para ambos casos sólo se utilizó el valor más alto de la demanda para cada año.
- Se utilizó la librería Scikit-learn de Python para normalizar los valores de entrenamiento en el rango de 0 a 1, usando la función `MinMaxScaler`
- La red LSTM tuvo como entrada "time_step" datos consecutivos (60), y como salida (1) dato (la predicción a partir de esos "time_step" datos). De esta manera se conformó el set de entrenamiento.
- Reajuste de los sets de entrenamiento, para indicar que cada ejemplo de entrenamiento a la entrada del modelo será un vector de 60x1. Se utilizó la función `reshape` de Numpy:

Fase 3. Implementación del modelo

En esta fase se procedió a crear y entrenar el modelo utilizando la librería de Keras para las Redes LSTM en Python.

La red LSTM fue definida con tamaño de datos de entrada (60) y (1) dato de salida con un total de (50) neuronas.

Se pretende en esta fase conocer las desviaciones y/o errores de los resultados obtenidos. Para ello se validarán los resultados a través de la función de coste (*l*) también llamada función de pérdida, *loss function* o *cost function*, como menciona Amat (2021), es la encargada de cuantificar la distancia entre el valor real y el valor predicho, en otras palabras, mide cuánto se equivoca el modelo al realizar predicciones.

En una segunda parte de esta fase se procedió a evaluar el modelo a través de métricas de error. Mañas (2019) afirmó lo siguiente:

No tiene por qué haber una medida del error que sea mejor que otra; para cada caso, dependiendo de la naturaleza del fenómeno que se pronostica, puede convenir utilizar unas u otras métricas, teniendo siempre claro cómo interpretar la información arrojada por cada una.

Por medio del error cuadrático medio se evaluó la diferencia entre los datos reales y pronosticados, calculando la media de los cuadrados del error. Asimismo, se calculó error porcentual absoluto medio, como la media de los errores porcentuales absolutos calculados en el conjunto de datos pronosticados.


RESULTADOS

La primera fase del procedimiento se desarrolló de forma satisfactoria, los resultados permitieron visualizar y entender el panorama de los procesos de la empresa, así como de sus interacciones con el proceso de planificación.

Seguidamente se analizó la demanda en unidades y facturación por línea de producto.

Figura 1.

Comportamiento de líneas de Productos de ECI de 2006 a 2018.



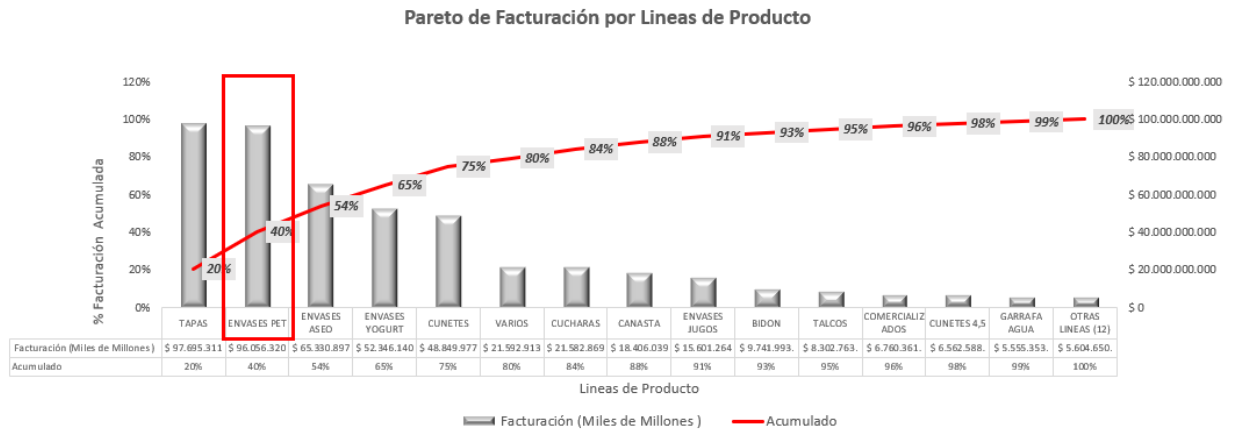
Nota. Elaboración propia. El grafico muestra las unidades vendidas (Columnas agrupadas) y la facturación (Área) por líneas de productos en los periodos comprendidos de 2006 a 2018.

Se observo que la línea de producto Envases Pet, tiene una alta facturación a pesar de las pocas cantidades vendidas, en comparación de otras líneas, ubicándola en el segundo lugar de las líneas con mayor facturación.

Se realizó análisis de Pareto de donde se comprueba lo anterior mencionado, la línea de envases Pet se encuentra ubicada en el 40% de la facturación total de la compañía. Se decidió realizar el modelo de pronóstico para la línea de productos envases Pet, concretamente para el producto de referencia PT951955, el cual, fue seleccionado a partir del trabajo con los expertos de la entidad.

Figura 2.

Pareto de Facturación 2006 a 2018 por líneas de producto.



Fuente: elaboración propia


División de Entrenamiento y Validación

Se dividieron los datos disponibles de las unidades demandadas del producto de referencia PT951955, en un conjunto de entrenamiento y un conjunto de test o validación. Para el entrenamiento se tuvo en cuenta la cantidad de unidades demandadas de 2006 a 2016 y para validación las unidades demandadas de 2017 a 2018.

En la Figura 3. Se observa el comportamiento de los datos en los periodos analizados y la división de los datos.

Figura 3.

Comportamiento de la demanda del producto PT951955



Fuente: elaboración propia

Cuando los predictores son numéricos, la escala en la que se miden, así como la magnitud de su varianza pueden influir en gran medida en el modelo, por tal motivo se utilizó la clase `sklearn.preprocessing.MinMaxScaler` traduciendo los datos individualmente de modo que estén el rango dado en el conjunto de entrenamiento.

Creación de modelo de pronóstico

Se realizó la construcción de una red neuronal recurrente Long Short-Term Memory layer LSTM, las cuales se caracterizan por ser una clase de red neuronal poderosa para modelar datos de secuencia, como series de tiempo o lenguaje natural.

Se utilizó las capas `keras.layers.LSTM`, que permite crear rápidamente modelos recurrentes.

El modelo construido `Sequential` que procesa secuencias, incrusta cada unidad facturada en un vector de 60 dimensiones y luego procesa la secuencia de vectores usando una capa LSTM.

Figura 4.

Modelo Secuencial

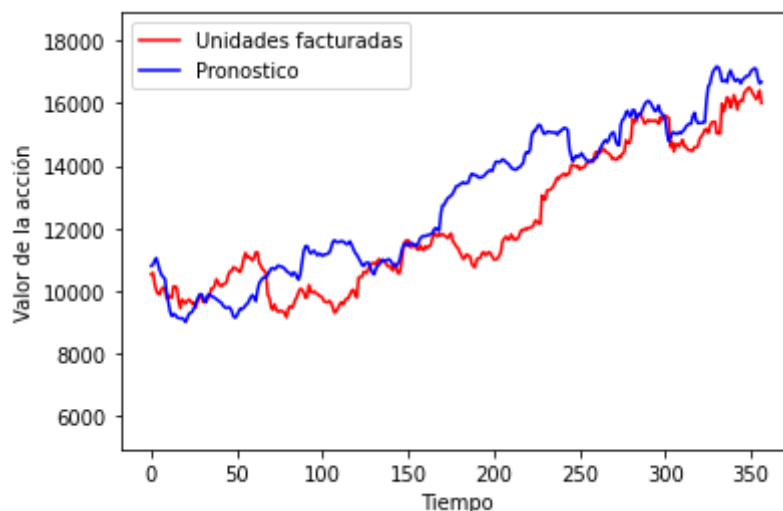
```
Model: "sequential"
-----
Layer (type)                Output Shape                Param #
-----
lstm (LSTM)                  (None, 50)                  10400
-----
dense (Dense)                (None, 1)                    51
-----
Total params: 10,451
Trainable params: 10,451
Non-trainable params: 0
-----
```

Fuente: elaboración propia

Con el modelo ajustado y los pronósticos del conjunto de datos de prueba, se calculó la puntuación del error del modelo empleando el error cuadrático medio (RMSE). El resultado obtenido fue de 911.314 unidades, lo cual se encuentra muy por debajo de la media y desviación de los datos, de igual manera se calculó el error porcentual absoluto medio (MAPE), el cual expresa la exactitud como un porcentaje del error, obteniendo un 6,33 %. lo que confirma la eficiencia de la red LSTM en la predicción.

Figura 5.

Gráfico de pérdida en la predicción



Fuente: elaboración propia

DISCUSIONES

Dado el objetivo del presente trabajo, se puede concluir que la fiabilidad de los datos obtenidos con el modelo entrenado (LSTM) es aprobado, al observar un margen de error porcentual del 6,33% y un error cuadrático medio de 911.314 unidades entre los datos reales y predichos, lo anterior es considerado un error bajo al compararlo con la media de los datos originales, 6.816 unidades y la desviación estándar de 4.334 unidades, por tanto, al obtener un error muy por debajo se consideró el modelo entrenado como fiable. De acuerdo a la metodología establecida, se puede determinar que es viable realizar investigaciones en ambientes de planeación de inventarios y de demanda, obteniendo mejores resultados a los que se podrían obtener con las otras metodologías menos robustas. Aunque la metodología realizada demanda mayor tiempo en la limpieza de los datos y la elección de la mejor herramienta para la elaboración del modelo, al final, esta brinda confianza en el resultado obtenido.

Someter los datos a una red neural recurrente LSTM con Time Steps o datos de entrada, una salida, estableciendo la cantidad de neuronas, permite concluir que los resultados de predicción obtenidos son más robustos, dado que esta arquitectura es capaz de “recordar” un dato relevante en la secuencia y de preservarlo por varios instantes de tiempo. Por tanto, puede tener una memoria tanto de corto plazo como lo hacen las Redes Recurrentes básicas, como también de largo plazo, haciéndolo muy confiable para este caso de estudio.

Los resultados obtenidos con relación al comportamiento de la predicción de la demanda del producto estudiado mediante LSTM, son claros y abren la puerta para futuras investigaciones de las demás líneas de productos, planeación de inventarios y otras áreas relacionadas a producción con fines predictivos.

CONCLUSIONES

1. En este artículo se propone metodología para el pronóstico de demanda a través de una red neuronal recurrente LSTM, la cual, fue demostrada a través de métricas de error.
2. Es viable entrenar una red LSTM, para predicción de demanda, alcanzando un buen desempeño que permite su utilización en el proceso de toma de decisiones de una compañía.
3. Las redes neuronales recurrentes LSTM, brindan confiabilidad en la predicción de los datos y los resultados obtenidos confirman la factibilidad de utilización de las mismas, lo cual es demostrado por investigaciones de los autores (Yan, H. & Ouyang, H. (2018); Kim, T. Y., & Cho, S. B. (2019); Xin Huang, Cecilia Zanni-Merk & Bruno Crémilleux (2019)).

REFERENCIAS BIBLIOGRÁFICAS

- Diebold, Francis (2001). Elements of forecasting. University of Pennsylvania.
<https://www.sas.upenn.edu/~fdiebold/Teaching221/FullBook.pdf>
- Amat, Joaquín. (mayo 2021). Forecasting series temporales con Python y Scikit-learn. Ciencia de datos.<https://www.cienciadedatos.net/documentos/py27-forecasting-series-temporales-python-scikitlearn.html>
- Chollet, F. (2018). *Deep Learning with Python*. Manning shelter island.
- Salazar, M. A. y Cabrera, M. (2007). Pronóstico de demandas por medio de redes neuronales artificiales. *Ingenierías*, X (35), 6-12. <http://eprints.uanl.mx/10351/>.
- Infante Acebedo, F. (2018). *Propuesta de una metodología para el pronóstico de la demanda utilizando método de series de tiempo en laboratorios la SANTÉ S.A* [Tesis de postgrado, Universidad Distrital Francisco José de Caldas].
<https://repository.udistrital.edu.co/handle/11349/13623>
- Coy-Mondragón, G. E., Granados, O. y Garcia-Bedoya, O. (2021). Predicción de la serie temporal del indicador bancario de referencia (IBR) con redes neuronales. *Mutis*, 11(1), en prensa. <https://doi.org/10.21789/22561498.1748>
- Xuanyi Song, Yuetian Liu, Liang Xue, Jun Wang, Jingzhe Zhang, Junqiang Wang, Long Jiang & Ziyang Cheng (2020). Time-series well performance prediction based on Long Short-Term Memory (LSTM) neural network model. *Journal of Petroleum Science and Engineering*, 186.
<https://www.sciencedirect.com/science/article/pii/S0920410519311039>
- Lei Ji, Yingchao Zou, Kaijian He & Bangzhu Zhu (2019). Carbon futures price forecasting based with ARIMA-CNN-LSTM model. *Procedia Computer Science*. 162. 33-38.
<https://www.sciencedirect.com/science/article/pii/S1877050919319660>
- Kim, T. Y., & Cho, S. B. (2019). Predicting residential energy consumption using CNN-LSTM neural networks. *Energy*, 182, 72-81. <https://doi.org/10.1016/j.energy.2019.05.230>
- Xin Huang, Cecilia Zanni-Merk & Bruno Crémilleux (2019). Enhancing Deep Learning with Semantics: an application to manufacturing time series analysis, *Procedia Computer Science*, 159, 437-446.
<https://www.sciencedirect.com/science/article/pii/S1877050919313808>
- Yan, H. & Ouyang, H. (2018). Predicción de series temporales financieras basada en Deep Learning. *Wireless Pers Commun* **102**, 683–700. <https://doi.org/10.1007/s11277-017-5086-2>

Pastor-Cobo, M., & Torre-Barrio, P. *Elaboración de un algoritmo predictivo sobre la evolución del precio de las criptomonedas* tesis (de pregrado, Universidad Complutense de Madrid). Repositorio Universidad Complutense de Madrid.