

Patrones de consumo y predicción con redes neuronales en comercio electrónico para un producto insignia: caso del Reino Unido

Consumption patterns and prediction with neural networks in e-commerce from a star product: case of United Kingdom

Areli Abigail Domínguez-Barreto¹, Oscar Domínguez-Barreto^{1*}, Héctor Daniel Molina-Ruiz¹

¹ Universidad Autónoma del Estado de Hidalgo. Av. del Maestro, 41, Tepeji del Río de Ocampo, Hidalgo.

*Correspondencia: studentuach@gmail.com (Oscar Domínguez-Barreto)

DOI: <https://doi.org/10.54167/tch.v19iEspecial.1988>

Recibido: 21 de junio de 2025; Aceptado: 23 de septiembre de 2025

Publicado por la Universidad Autónoma de Chihuahua, a través de la Dirección de Investigación y Posgrado.

Editor de Sección: Dr. Vladimir Villarreal-Contreras

Resumen

El comercio electrónico ha transformado la relación entre empresas y consumidores, generando grandes volúmenes de datos que requieren herramientas avanzadas para su análisis. Las Redes Neuronales Artificiales (ANN) son útiles para predecir tendencias y patrones de consumo en mercados dinámicos. El estudio se centra en el Reino Unido, líder europeo en comercio electrónico, para analizar el comportamiento del consumidor y el producto insignia más vendido: *Popcorn Holder* o *Popcorn Bouquet*. El objetivo fue predecir el precio del *Popcorn Holder* en el Reino Unido mediante una red neuronal artificial, identificando patrones de consumo y proporcionando información útil para la toma de decisiones en comercio electrónico. Se analizaron 536,350 registros de ventas globales, filtrando 1,352 datos correspondientes al producto y país seleccionados. Se realizó limpieza y análisis exploratorio de datos usando Python en Google Colab®, empleando librerías como *pandas*, *numpy* y *tensorflow*. Se construyó y entrenó una red neuronal secuencial con optimizador Adam, función de pérdida *mean squared error* y 3,000 épocas. Se evaluó la pérdida durante el entrenamiento y se compararon las predicciones con precios reales. El Reino Unido fue el mayor consumidor del producto, que también resultó el más vendido a nivel global. La ANN generó una ecuación lineal que capturó la tendencia general a la baja de los precios, aunque con fluctuaciones a corto plazo. La pérdida disminuyó rápidamente al inicio del entrenamiento y se estabilizó, indicando convergencia del modelo. El cliente número 14646 destacó por el mayor volumen de compras, dato relevante para estrategias de fidelización. Las redes neuronales demostraron ser herramientas efectivas para predecir precios en comercio electrónico y apoyar la gestión de inventarios y estrategias de mercado. Los resultados confirman la posición del Reino Unido como líder europeo en este sector y resaltan

la utilidad del análisis basado en ANN para identificar patrones de consumo y oportunidades de negocio.

Palabras clave: análisis de datos, comercio electrónico, pronóstico, redes neuronales.

Abstract

E-commerce has transformed the relationship between businesses and consumers, generating large volumes of data that require advanced tools for analysis. Artificial Neural Networks (ANNs) are valuable for predicting trends and consumption patterns in dynamic markets. This study focuses on the United Kingdom, Europe's e-commerce leader, to analyze consumer behavior and the best-selling flagship product: Popcorn Holder or Popcorn Bouquet. The objective was to predict the price of the Popcorn Holder in the United Kingdom using an artificial neural network, identifying consumption patterns and providing useful insights for decision-making in e-commerce. A total of 536,350 global sales records were analyzed, filtering 1,352 data points corresponding to the selected product and country. Data cleaning and exploratory analysis were performed using Python in Google Colab®, employing libraries such as *pandas*, *numpy*, and *tensorflow*. A sequential neural network was built and trained with the Adam optimizer, *mean squared error* loss function, and 3,000 epochs. The loss during training was evaluated, and predictions were compared with actual prices. The United Kingdom was identified as the largest consumer of the product, which was also the best-selling item globally. The ANN generated a linear equation that captured the overall downward trend in prices, despite short-term fluctuations. Loss decreased rapidly during the initial training phase and stabilized, indicating model convergence. Customer number 14646 stood out as the top buyer, a valuable insight for customer loyalty strategies. Artificial neural networks proved to be effective tools for predicting prices in e-commerce and supporting inventory management and market strategies. The results confirm the United Kingdom's position as Europe's e-commerce leader and highlight the usefulness of ANN-based analysis for identifying consumption patterns and business opportunities.

Keywords: data analysis, e-commerce, forecasting, neural networks.

1. Introducción

En la era digital, el comercio electrónico ha transformado radicalmente la manera en que los consumidores realizan compras, así como la relación de las empresas con sus clientes. Este entorno genera una cantidad masiva de datos, que abarca desde historiales de compras hasta patrones de navegación, lo que ha propiciado la adopción de tecnologías avanzadas destinadas a analizar y predecir el comportamiento del consumidor. En este contexto, las redes neuronales juegan un papel fundamental, en el análisis y predicción de dicho comportamiento.

El comercio electrónico es una parte importante de la economía de un país, es por esto que se requiere efectuar un análisis acerca de los productos insignia de un negocio (es decir, el más consumido dentro del país); de esta manera, se pueden conocer las necesidades del mercado, además de considerarse los diversos factores para cubrir la demanda de un producto dado y brindando la pauta para generar ideas de negocio. El comercio electrónico es un pilar fundamental de la economía del

Reino Unido, posicionando al país como líder europeo y uno de los mercados más avanzados a nivel mundial en ventas y adopción digital (Rokicki, 2018; Hood et al., 2020; Fedushko et al., 2021).

El Reino Unido ha experimentado un crecimiento sostenido en ventas online, con una infraestructura digital avanzada y una alta penetración de Internet (Rokicki, 2018; Fedushko et al., 2021). En este sentido, el comercio electrónico es estratégico tanto para grandes empresas como para Pymes, que lo consideran clave para la transformación y resiliencia empresarial (Drew, 2003; Fedushko et al., 2021).

El sector minorista, especialmente el de alimentación, ha invertido en canales online y entrega a domicilio, adaptándose a nuevas preferencias de los consumidores (Kirby-Hawkins et al., 2018; Hood et al., 2020). Reino Unido lidera en innovación de canales (entrega a domicilio, *click & collect*) y en la adopción de pagos digitales (Hood et al., 2020; Fedushko et al., 2021). Aunado a ello, el marco legal y regulatorio británico es avanzado y promueve la confianza y protección del consumidor en transacciones electrónicas (Jaradt, 2018; Lloyd, 2020).

Cabe hacer mención que, en el ecosistema del comercio electrónico, como indica González García (2020), Estados Unidos y China se encuentran como punteros en el comercio B2C (*Business to Consumer* – Negocio a Consumidor). El Reino Unido destaca como el mercado más importante de comercio electrónico en Europa y ocupa una posición privilegiada a nivel mundial, situándose como el tercero en importancia. Esto se debe en gran medida a la amplia conectividad de su población, ya que aproximadamente el 90 % de los adultos británicos tiene acceso a Internet. Siguiendo a Hall y Grogan (2017), el 86 % de los hogares británicos tiene acceso a Internet.

Siguiendo a Robayo-Botiva (2020), aunque es difícil predecir la intensidad e importancia del cambio que se va a producir en los próximos años en el comercio, algunos auguran una auténtica revolución. Lo que supone ya una realidad es el hecho de que cualquier empresa debe tener en cuenta: la comunicación y su relación con los consumidores; el reto que supone el Internet; el uso de dispositivos móviles; la combinación de Internet y el uso de dispositivos móviles; la web 2.0 y 3.0; y otros muchos elementos que surgen día a día y que configuran la sociedad digital. Lo anterior es para concretar sus ventas.

Además, una parte significativa de esta población utiliza servicios de banca digital de manera habitual, lo que refleja un alto nivel de adopción tecnológica. El cambio hacia la banca digital en Reino Unido ha sido tan marcado que una parte considerable de las sucursales físicas ha sido reemplazada por servicios de autoservicio y plataformas digitales (Grigorescu et al., 2023; Wu, 2024). Aunque la adopción es alta en la mayoría de los grupos demográficos, los jóvenes y adultos de mediana edad son los usuarios más activos, mientras que los mayores de 55 años muestran una adopción más lenta (Koya y Jones, 2021; Grigorescu et al., 2023). Por otro lado, el comercio electrónico es una práctica común para los habitantes, quienes recurren regularmente a estas plataformas para realizar sus compras, consolidando al Reino Unido como un referente global en este sector.

En el contexto del ecosistema del comercio electrónico, las redes neuronales pueden ser empleadas para predecir tendencias de compra. Esto suele basarse la búsqueda y encuentro de patrones de comportamiento; de esta manera se puede potenciar el mercado para generar oportunidades de crecimiento en el sector. La capacidad de las redes neuronales para ajustarse de manera autónoma a nuevas condiciones también es crucial en áreas como la predicción del clima o la gestión de sistemas

de energía, donde las variables pueden cambiar de forma dinámica. Por ejemplo, si aplicación se extiende en: medicina y salud, con el diagnóstico asistido por IA (inteligencia artificial), pronóstico de enfermedades, análisis de imágenes médicas y apoyo en tratamientos personalizados (Abiodun et al., 2018; Haglin et al., 2019); agricultura, con la predicción de rendimientos, detección de enfermedades y plagas, control inteligente de malezas, clasificación de calidad de cultivos y optimización de procesos agrícolas (Abiodun et al., 2018; Kujawa y Niedbała, 2021); energía por el modelado y predicción en sistemas solares, estimación de cargas térmicas, control de sistemas de energía y optimización de consumo (Kalogirou, 1999; Kalogirou, 2000; Abiodun et al., 2018); negocios y finanzas, a través de la predicción de quiebras, pronóstico de precios de acciones, sistemas de soporte a la decisión y clasificación de riesgos (Tkáč y Verner, 2016; Abiodun et al., 2018); visión por computadora y procesamiento de imágenes, con el reconocimiento de patrones, clasificación de objetos, análisis de imágenes satelitales y sistemas de vigilancia (Liu et al., 2017; Li et al., 2022; Xie et al., 2022); procesamiento de lenguaje natural, con la traducción automática, análisis de sentimientos, reconocimiento de voz y sistemas de recomendación (Liu et al., 2017; Li et al., 2022); redes sociales y biología molecular, en el análisis de grafos complejos, categorización de nodos y predicción de enlaces (Wu et al., 2019; Wu et al., 2022; Ponzi y Napoli, 2025). Por esta razón, se justifica el uso de redes neuronales en diversos campos del conocimiento.

Las Redes Neuronales Artificiales (ANN) son un método para resolver problemas, de forma individual o combinadas con otros métodos, para aquellas tareas de clasificación, identificación, diagnóstico, optimización o predicción en las que el balance datos/conocimiento se inclina hacia los datos y donde, adicionalmente, puede haber la necesidad de aprendizaje en tiempo de ejecución y de cierta tolerancia a fallos (Salas, 2004). Las redes neuronales artificiales (ANN) son modelos matemáticos y computacionales inspirados en sistemas biológicos, adaptados y simulados en computadoras; han surgido como un intento de desarrollar modelos que emulen las características del cerebro humano (Menacho, 2014).

La factibilidad de uso de las redes artificiales neuronales y sus diferentes modelos ha aumentado su posibilidad de resolución, debido al avance tecnológico y el incremento de poder computacional disponible. Para los problemas de predicción, los modelos de redes neuronales son aplicados de forma similar a una variedad de modelos estadísticos, tales como los modelos de regresión lineal, los lineales generalizados, los de regresión no paramétrica y los de análisis discriminante; pero, con la limitación de no poder realizar un análisis explicativo del modelo ajustado (Menacho, 2014).

Las Redes Neuronales Artificiales (Artificial Neural Network - ANN) son modelos computacionales que suelen estar inspirados en el cerebro humano. Están diseñadas para resolver problemas complejos de clasificación, identificación, diagnóstico, optimización o predicción. Las redes neuronales son particularmente útiles en casos para los cuales el comportamiento de los datos no es lineal; permiten el aprendizaje en tiempo real, y su estructura distribuida les otorga cierta tolerancia a fallos, lo que las hace ideales para aplicaciones dinámicas y de alta complejidad. Méndez-Castillo et al. (2025) sugieren que el uso de redes neuronales puede ser útil para capturar mejor los procesos subyacentes a los cambios.

El auge, dinámica y complejidad del comercio electrónico ha generado una gran cantidad de datos sobre las transacciones de los clientes. Si bien estos datos son valiosos, su volumen y complejidad dificultan la extracción de información útil para la toma de decisiones. En este contexto, se presenta la necesidad de analizar un conjunto de datos de transacciones de una empresa de comercio electrónico con sede en el Reino Unido para identificar patrones de consumo, comprender el

comportamiento del consumidor y vislumbrar el enfoque de ventas en el producto insignia, con el objetivo de predecir el precio del *Popcorn Holder* a través del uso de una red neuronal artificial, identificando patrones de consumo que den la pauta para el reconocimiento de patrones en comercio electrónico para la venta del producto insignia.

2. Materiales y métodos

A continuación, se presenta la metodología desarrollada, con un enfoque basado en análisis de datos y redes neuronales.

2.1 Metodología

2.1.1 Análisis de datos

El comercio electrónico es el uso de las tecnologías de la informática y las telecomunicaciones para habilitar las transacciones comerciales de productos o servicios entre las empresas, entre estas y particulares o con el Estado (Malca, 2001). De acuerdo con Kotler y Keller (2021), un producto se puede clasificar en 5 niveles: beneficio básico; producto genérico; producto esperado; producto aumentado y, producto potencial. Cabe hacer mención que *Popcorn Holder* o *Popcorn Bouquet* (contenedor para palomitas de maíz), se puede considerar un producto esperado o aumentado, dependiendo su presentación.

Para la presente propuesta se analiza una base de datos (Dataset) correspondiente a las ventas mediante comercio electrónico para Alemania, Arabia Saudí, Australia, Austria, Baréin, Bélgica, Brasil, Canadá, Chipre, Dinamarca, Emiratos Árabes Unidos, España, Estados Unidos, Finlandia, Francia, Grecia, Hong Kong, Islandia, Islas del Canal, Israel, Italia, Japón, Líbano, Lituania, Malta, Noruega, Países Bajos, Polonia, Portugal, Reino Unido, República Checa, República de Sud África, Singapur, Suecia, Suiza y Reino Unido. El conjunto de datos analizado fue de 536,350 registros, a los cuales se realizó un análisis preliminar con la finalidad de conocer el producto más vendido y el país con mayor consumo del producto seleccionado. De acuerdo con el análisis de los datos, se encontró que el país que genera la mayor cantidad de ventas es Reino Unido para el producto *Popcorn Holder* o *Popcorn Bouquet*. Una vez identificado el producto, se filtraron 1,352 datos, los cuales se utilizaron para procesar la Red Neuronal.

2.1.2 Regresión lineal para predicción

En el ámbito de los problemas de predicción, las redes neuronales artificiales se utilizan de manera comparable a diversos modelos estadísticos, incluyendo los modelos de regresión lineal. No obstante, una de las limitaciones más notables de las redes neuronales es que, a diferencia de estos enfoques estadísticos, no permiten realizar un análisis explicativo detallado. Esto significa que, aunque son herramientas poderosas para identificar patrones y realizar predicciones precisas, no ofrecen la posibilidad de interpretar matemáticamente las relaciones entre las variables que componen el modelo.

Como producto del análisis de redes neuronales se obtuvo una ecuación lineal ($y = mx + b$) que representa el modelo. Los valores de 'm' y 'b' (pendiente e intersección) reflejan la relación aprendida por el modelo entre el número de periodo y el precio. Estos valores pueden ser interpretados para comprender cómo el modelo realiza la predicción.




Figura 1. Diagrama representativo de la metodología aplicada. Fuente: Elaboración propia.

Figure 1. Diagram representing the applied methodology. Source: Prepared by the authors.

2.1.3 Implementación de la Red Neuronal

Se implementó una red neuronal artificial (ANN) con el objetivo de predecir el precio del producto *Popcorn Holder* o *Popcorn Bouquet* en el Reino Unido. La elección de una ANN se basó en su capacidad para aprender relaciones complejas entre variables y su eficacia en tareas de predicción.

Una vez que se obtuvo la nueva base de datos (*DataFrame*), se llamaron las librerías (*pandas*, *numpy*, *tensorflow*, *matplotlib*) para la construcción y entrenamiento del modelo. Se identificaron las variables dependientes e independientes; las fechas fueron ordenadas y se asignó un número de periodo

generando la variable x (independiente), y la variable precio tomó el valor de la variable y (dependiente). Se implementó una red neuronal secuencial (*Sequential*) con una capa densa (*Dense*) como capa de salida. La capa densa tiene una sola neurona, ya que se busca predecir un valor numérico (el precio). Se definió una forma de entrada que consta de 1 capa, indicando que la red recibe un único valor como entrada (el número de periodo).

2.1.4 Entrenamiento de la red

Se compiló el modelo utilizando el optimizador Adam con una tasa de aprendizaje de 0.1 y la función de pérdida (*mean squared error*). Se entrenó el modelo con los datos preparados, utilizando la columna número de periodos (*No_de_periodos*) como entrada, y la columna Precio como salida. Se definieron 3000 épocas (ciclos) para el entrenamiento, permitiendo al modelo iterar sobre los datos un número suficiente de veces, ajustando sus pesos y minimizando la función de pérdida.

La metodología se fundamenta en un enfoque basado en análisis de datos y redes neuronales que permiten obtener información para la toma de decisiones (Fig. 1).

3. Resultados y discusión

Las redes neuronales son extremadamente poderosas para resolver problemas complejos, como el reconocimiento de imágenes, el procesamiento del lenguaje natural y la predicción de datos, porque pueden modelar relaciones no lineales y patrones ocultos en los datos. Para Cañedo Figueroa et al. (2024), las redes neuronales son modelos matemáticos que intentan simular el funcionamiento de la mente humana para la toma de decisiones, que pueden llegar a tener cierto criterio de razonamiento con base en diversos datos obtenidos del entorno.

A diferencia de los algoritmos tradicionales, que se basan en instrucciones predefinidas y siguen un conjunto específico de pasos programados, las redes neuronales artificiales (ANN) requieren un proceso de entrenamiento previo. Este proceso implica que la red recibe una serie de datos (observaciones o ejemplos) a través de su capa de entrada, lo que le permite aprender y ajustar sus parámetros internos para poder realizar tareas como la clasificación o la predicción. En lugar de seguir un conjunto fijo de instrucciones, la red neuronal utiliza una regla de aprendizaje para modificar sus conexiones y optimizar su rendimiento a medida que se le presentan más datos.

En el siguiente pseudo-algoritmo se muestra el paso a paso llevado a cabo para programar la red neuronal (Tabla 1), se destaca que la base de datos inicial fue cargada en formato CSV (*Comma Separated Values Format* – formato de valores separados por comas), constando de 1,352 datos, filtrados de 536,350 registros iniciales.

Tabla 1. Pseudo-algoritmo del entrenamiento de la red neuronal.

Table 1. Pseudo-algorithm on neuralnetwork training.

1	Importar librerías (pandas, numpy)
2	Conectar Drive a Google Colab
3	Convertir el csv a DataFrame

4	Renombrar columnas
5	Ordenar el DataFrame por la columna ID_producto Mostrar la tabla ordenada
6	Para cada columna numérica en el DataFrame: Calcular la media, mediana, moda, desviación estándar, varianza y rango Almacenar las medidas en un diccionario Mostrar los resultados
7	Agrupar por cliente y sumar la cantidad comprada Encontrar el cliente que consumió más Mostrar el resultado
8	Encontrar el precio máximo Encontrar el producto asociado al precio máximo Mostrar el resultado
9	Agrupar por país y sumar la cantidad comprada Encontrar el país que más compró Mostrar el resultado
10	Agrupar por producto y sumar la cantidad vendida Encontrar el producto más vendido Mostrar el resultado
11	Agrupar por país y producto, luego sumar la cantidad Encontrar el producto más comprado para cada país Mostrar resultados
12	Filtrar el DataFrame para obtener datos de Reino Unido y <i>Popcorn Holder</i> Convertir 'Fecha_transacción' a datetime Ordenar por 'Fecha_transacción'
13	Para cada columna numérica en el DataFrame: Calcular la media, mediana, moda, desviación estándar, varianza y rango Almacenar las medidas en un diccionario Mostrar los resultados
14	Agrupar por cliente y sumar la cantidad comprada Encontrar el cliente que compró más Mostrar el resultado
15	Encontrar el precio máximo Encontrar el producto asociado al precio máximo Mostrar el resultado
16	Agrupar por país y sumar la cantidad comprada Encontrar el país que más compró Mostrar el resultado
17	Agrupar por producto y sumar la cantidad vendida Encontrar el producto más vendido Mostrar el resultado
18	Agrupar por país y producto, luego sumar la cantidad Encontrar el producto más comprado para cada país Mostrar resultados
19	Filtrar el DataFrame para obtener datos de Reino Unido y <i>Popcorn Holder</i> Convertir 'Fecha_transacción' a datetime Ordenar por 'Fecha_transacción' Crear columna 'No_de_periodos' Mostrar el DataFrame resultante
20	Importar tensorflow como tf

21	Extraer fecha, número de periodo y precio Convertir 'Fecha_transacción' a solo fecha Mostrar los datos extraídos
22	Convertir la lista de periodos a una cadena Convertir la lista de precios a una cadena
23	Definir la arquitectura del modelo Compilar el modelo con optimizador y función de pérdida
24	Entrenar el modelo con los datos Mostrar mensaje de modelo afinado
25	Graficar la pérdida del modelo durante el entrenamiento
26	Graficar los precios en función del número de periodos
27	Predecir el precio para un periodo dado Mostrar el resultado
28	Mostrar los pesos de la capa Mostrar la ecuación del modelo

En las primeras épocas, la magnitud de pérdida disminuyó rápidamente, véase en la Fig. 2. Esto indica que la red neuronal está aprendiendo rápidamente la relación general entre el número de periodo y el precio del *Popcorn Holder* o *Popcorn Bouquet* (contenedor para palomitas de maíz).




Figura 2. Gráfica representativa de la magnitud de la pérdida para análisis de 3000 periodos. Fuente: Elaboración propia con base en el entrenamiento de la red neuronal.

Figure 2. Graph showing the magnitude of loss for an analysis of 3,000 periods. Source: Prepared by the author based on neural network training.

La red ajustó sus pesos y sesgos para realizar predicciones. A medida que el entrenamiento progresó, la disminución de la pérdida se volvió gradual. Esto es un comportamiento típico en el entrenamiento de redes neuronales, ya que el modelo se va acercando a una solución óptima, y los ajustes de los pesos y sesgos se vuelven más finos.

Cuando el entrenamiento continuó por más épocas, la pérdida se estabilizó en un valor mínimo, indicando que la red neuronal convergió hacia una solución óptima para el conjunto de datos filtrado.

En una segunda corrida se tuvo que la disminución de la pérdida durante el entrenamiento indica que el modelo está aprendiendo a realizar predicciones más precisas. Sin embargo, la ralentización en la disminución de la pérdida en las últimas épocas sugiere que el modelo podría estar llegando a un límite en su capacidad de aprendizaje con la configuración actual. Esto podría ser un indicio de que se requiere una arquitectura más compleja. La gráfica de magnitud de pérdida muestra una disminución rápida en las primeras épocas (Fig. 3).




Figura 3. Gráfica representativa de la segunda corrida para la magnitud de la pérdida para análisis de 3000 periodos. Fuente: Elaboración propia con base en el entrenamiento de la red neuronal.

Figure 3. Graph representing the second run of magnitude loss analysis for 3,000 periods. Source: Prepared by the author based on neural network training.

Se graficó la ecuación del modelo $mx + b$ con pendiente -0.00467914 y ordenada al origen 12.235434 para visualizar la capacidad del modelo al capturar la tendencia de los precios a lo largo del tiempo (Fig. 4). Si bien la ecuación del modelo se ajusta en cierta medida a los datos, existen desviaciones significativas en algunos puntos. Esto indica que el modelo no es perfecto y que existen factores adicionales que influyen en el precio del producto.




Figura 4. Gráfica de modelo para tendencia de los precios a lo largo del tiempo. Fuente: Elaboración propia con base en el entrenamiento de la red neuronal.

Figure 4. Model graph showing price trends over time. Source: Prepared by the authors based on neural network training.

El modelo fue capaz de realizar predicciones para un periodo específico. Al comparar la predicción con el precio real, se observó una diferencia. Aunque el modelo logró capturar la tendencia general de los precios, es importante destacar que existen desviaciones en ciertos puntos.

La gráfica mostró una tendencia general a la baja en los precios a lo largo de los periodos analizados. Si bien al inicio se observa una relativa estabilidad alrededor de los 12 euros, los precios experimentan una disminución sostenida, reflejada en la línea roja de tendencia. Sin embargo, es importante notar que esta tendencia general se ve interrumpida por numerosas fluctuaciones a corto plazo, lo que sugiere la presencia de factores adicionales que influyen en la dinámica de los precios más allá de esta tendencia a largo plazo. La ecuación de la línea de tendencia ($y = -0.00x + 12.24$) confirma la disminución de los precios.

Las medidas de tendencia central para el precio del *Popcorn Holder* o *Popcorn Bouquet* en el Reino Unido revela precios relativamente estables alrededor de 12 (12.66), con la media (11.94) y la mediana (11.53) muy cercanas, sugiriendo una distribución simétrica o ligeramente sesgada. La moda, ligeramente inferior, indica una posible concentración de precios más bajos, quizás debido a promociones u ofertas, sin embargo, la similitud entre media y mediana apunta a una distribución no muy sesgada.

Las medidas de dispersión para el precio del *Popcorn Holder* o *Popcorn Bouquet* en el Reino Unido muestra una variabilidad moderada en los precios. El rango (655.49), que representa la diferencia entre el precio máximo y mínimo, indica la amplitud total de precios observados. La desviación estándar (8.49), que mide la dispersión promedio de los precios alrededor de la media, sugiere que la mayoría de los precios se concentran relativamente cerca del promedio. La varianza (72.09), siendo

el cuadrado de la desviación estándar, refuerza esta idea. En conjunto, estas medidas revelan que, si bien existe cierta variación en los precios del *Popcorn Holder* o *Popcorn Bouquet*, la mayoría de ellos se encuentran dentro de un rango relativamente cercano al promedio, con valores extremos que contribuyen a un rango más amplio.

4. Conclusiones

El análisis del producto *Popcorn Holder* o *Popcorn Bouquet* en el Reino Unido revela que, en general, el precio se mantuvo relativamente estable a lo largo de los periodos observados. Aunque existieron fluctuaciones, la red neuronal entrenada logró capturar la tendencia, generando una ecuación que describe la relación entre el número de periodos y el precio.

La red neuronal, tras su entrenamiento, demostró la capacidad de predecir el precio del *Popcorn Holder* o *Popcorn Bouquet* en periodos futuros con cierta precisión. Esto sugiere su potencial como herramienta para la toma de decisiones en la gestión de inventarios y la fijación de precios.

Se identificó al Reino Unido como el país con mayor consumo total en el *data set*. Además, el producto *Popcorn Holder* o *Popcorn Bouquet* se posicionó como el más consumido a nivel global. Estos hallazgos brindan información valiosa sobre las preferencias de los consumidores y los mercados con mayor demanda. Se identificó al cliente número 14646 como el que realizó la mayor cantidad de compras en el periodo analizado. Este dato puede ser relevante para estrategias de fidelización y segmentación de clientes.

Con este análisis se puede concluir la veracidad del estudio realizado por ICEX España Exportación e Inversiones acerca de que Reino Unido mantiene su posición hasta el 2023 como el mercado de comercio electrónico más grande de Europa y tercero del mundo. De acuerdo con la información filtrada, llegamos a la conclusión que, por lo menos para esta empresa, su principal consumidor es dicho país. En contextos como el comercio electrónico, donde el Reino Unido se posiciona como líder, las redes neuronales suelen ser empleadas para predecir tendencias de compra o basarse en encontrar patrones de comportamiento, de esta manera, podemos lograr potencializar el mercado, teniendo oportunidades de crecimiento en el sector.

Contribuciones de los autores

Para el desarrollo de la investigación, la primera autora realizó: la búsqueda, obtención y limpieza de datos; además, realizó la búsqueda y sustento teórico; así como la programación de la red neuronal; la obtención de resultados; y, la reducción del documento. El segundo autor, contribuyó con: el sustento teórico de la propuesta; la programación de la red neuronal; y, la redacción del documento.

Agradecimientos

Los autores agradecemos a la Universidad Autónoma del Estado de Hidalgo, por proveer al base académica y desarrollo profesional para el desarrollo de la presente propuesta.

Conflicto de interés

Los autores declaran bajo protesta de decir la verdad, que a su real entender, no existe conflicto de interés para el desarrollo o validación de la presente propuesta.

5. Referencias

- Abiodun, O. I., Jantan, A., Omolara, A. E., Dada, K. V., Mohamed, N. A., & Arshad, H. (2018). State-of-the-art in artificial neural network applications: A survey. *Heliyon*, 4(11): e00938. <https://doi.org/10.1016/j.heliyon.2018.e00938>
- Basogain-Olabe, X (2008). REDES NEURONALES ARTIFICIALES Y SUS APLICACIONES. Universidad del País Vasco - Euskal Herriko Unibersitatea. Curso 00147-06-1-02 del programa Comunicaciones, Electrónica y Control. https://ocw.ehu.eus/file.php/102/redes_neuro/Course_listing.html
- Drew, S. (2003). Strategic Uses of E-Commerce by SMEs in the East of England. *European Management Journal*, 21(1), 79-88. [https://doi.org/10.1016/S0263-2373\(02\)00148-2](https://doi.org/10.1016/S0263-2373(02)00148-2)
- Fedushko, S., Shevchuk, L., Poritska, A., Kravets, R., & Tymovchak-Maksymets, O. (2021). E-Commerce and E-Health Strategies and Implementation Activities in the United Kingdom: Review Study, 10-20. *Digital Libraries*. <https://arxiv.org/abs/2108.08271v1>. Cornell University. <https://doi.org/10.48550/arXiv.2108.08271>
- Guijarro, P. [Pilar Guijarro García] (2019). Popcorn Holder-Big Idea [Vídeo]. YouTube. <https://www.youtube.com/watch?v=n6BUxQQ7y10>
- González García, J. (2020). Comercio electrónico en China y México: surgimiento, evolución y perspectivas. *México y la Cuenca del Pacífico*, 9(27), 53-84. <https://doi.org/10.32870/mycp.v9i27.688>
- Grigorescu, A., Oprișan, O., Lincaru, C., & Pirciog, C. S. (2023). E-Banking Convergence and the Adopter's Behavior Changing Across EU Countries. *Sage Open*, 13(4). <https://doi.org/10.1177/21582440231220455>
- Haglin, J. M., Jimenez, G., & Eltorai, A. E. M. (2019). Artificial neural networks in medicine. *Health and Technology*, 9, 1 – 6. <https://doi.org/10.1007/s12553-018-0244-4>
- Hall, M., & Grogan, S. (2017). Research considerations when investigating psychological factors and health-related issues in online contexts. In Bundon, A. (Ed.) *Digital Qualitative Research in Sport and Physical Activity*, pp. 93-106. Routledge. <https://doi.org/10.4324/9781315304557-7>
- Hilera, R., & Martínez, V. (1995). Redes neuronales artificiales Fundamentos, modelos y aplicaciones. Colección: Informática. RA-MA Editorial. <https://www.researchgate.net/publication/44343683>
- Hood, N., Urquhart, R., Newing, A., & Heppenstall, A. (2020). Sociodemographic and spatial disaggregation of e-commerce channel use in the grocery market in Great Britain. *Journal of Retailing and Consumer Services*, 55, 102076. [10.1016/j.jretconser.2020.102076](https://doi.org/10.1016/j.jretconser.2020.102076)

- ICEX España Exportación e Inversiones. (2023). Reino Unido: Resumen ejecutivo e-País 2023. <https://www.icex.es/content/dam/icex/centros/reino-unido/documentos/2024/informe-e-pais-comercio-electronico-reino-unido-2024-resumen-ejecutivo.pdf>
- Jaradt, N. M. (2018). A critical analysis of e-commerce contracts with relevance to the UAE and the United Kingdom. *International Journal of Law and Management*, 60(2): 586-594. <https://doi.org/10.1108/IJLMA-01-2017-0016>
- Kalogirou, S. A. (1999). Applications of artificial neural networks in energy systems. A review. *Energy Conversion and Management*, 40(10), 1073-1087. [https://doi.org/10.1016/S0196-8904\(99\)00012-6](https://doi.org/10.1016/S0196-8904(99)00012-6)
- Kalogirou, S. (2000). Applications of artificial neural-networks for energy systems. *Applied Energy*, 67(1-2), 17-35. [https://doi.org/10.1016/S0306-2619\(00\)00005-2](https://doi.org/10.1016/S0306-2619(00)00005-2)
- Kirby-Hawkins, E., Birkin, M., & Clarke, G. (2018). An investigation into the geography of corporate e-commerce sales in the UK grocery market. *Environment and Planning B: Urban Analytics and City Science*, 46(6), 1148 – 1164. <https://doi.org/10.1177/2399808318755147>
- Kotler, P., & Keller, K. L. (2001). CAPÍTULO 17: Administración de líneas de producto, marcas y empaques. En: *Dirección de Mercadotecnia, Análisis, Planeación, Implementación y Control 8a. Ed.* Northwestern University. 84 pp. Pearson Education. <https://es.scribd.com/doc/54545203/Direccion-de-Mercadotecnia-8a-Ed-Kotler>
- Koya, K., Venture Matrix Consultants, & Jones, D. (2021). A Path of Roses and Financial Literacy: Exploring the Usability of UK's Digital Banking Services to Improve Younger Adult Adoption. *APIT'21: Proceedings of the 2021 3rd Asia Pacific Information Technology Conference*. pp. 18-25. <https://doi.org/10.1145/3449365.3449369>
- Kujawa, S., & Niedbała, G. (2021). Artificial Neural Networks in Agriculture. *Agriculture*, 11(6), 497. <https://doi.org/10.3390/agriculture11060497>
- Larranaga, P., Inza, I., & Moujahid, A. (1997). Tema 8. redes neuronales. *Redes Neuronales*. Departamento de Ciencias de la Computación e Inteligencia Artificial. pp. 12, 17. Universidad del País Vasco-Euskal Herriko Unibertsitatea. <http://www.sc.ehu.es/ccwbayes/docencia/mmcc/docs/t8neuronales.pdf>
- Li, Z., Liu, F., Yang, W., Peng, S., & Zhou, J. (2022). A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects. *IEEE Transactions on Neural Networks and Learning Systems*, 33(12), 6999-7019. <https://doi.org/10.1109/TNNLS.2021.3084827>
- Liu, W., Wang, Z., Liu, X., Zeng, N., Liu, Y., & Alsaadi, F. E. (2017). A survey of deep neural network architectures and their applications. *Neurocomputing*, 234, 11-26. <https://doi.org/10.1016/j.neucom.2016.12.038>
- Lloyd, I. J. (2020). 22. International and European initiatives in e-commerce. In: *Information Technology Law 9th Ed.*, pp. 393-406. Oxford: Oxford University Press. <https://doi.org/10.1093/he/9780198830559.003.0022>
- Malca, Ó. (2001). Comercio electrónico. Universidad del Pacífico. <http://hdl.handle.net/11354/76>
- Menacho Chiok, C. H. (2014). Modelos de regresión lineal con redes neuronales. *Anales Científicos*, 75(2), 253-260. <https://doi.org/10.21704/ac.v75i2.961>

- Méndez-Castillo, A. K., Contreras-López, E., Pérez-Flores, J. G., García-Curiel, L., Pérez-Escalante, E., Soto-Vega, K., Ángel-Jijón, C., & Cervantes-Elizarrarás, A. (2025). Improving kinetic model fitting for total titratable acidity in bananas using genetic algorithms. *TECNOCENCIA Chihuahua*, 19, Special Issue, e1847. <http://doi.org/10.54167/tch.v19iEspecial.1847>
- Ponzi, V., & Napoli, C. (2025). Graph Neural Networks: Architectures, Applications, and Future Directions. *IEEE Access*, 13, 62870-62891. <https://doi.org/10.1109/ACCESS.2025.3558752>
- Robayo-Botiva, D. M. (2020). El comercio electrónico: concepto, características e importancia en las organizaciones. Universidad Cooperativa de Colombia. Facultad de Ciencias Económicas, Administrativas y Contables, Administración de Empresas, Villavicencio. <https://doi.org/10.16925/gclc.13>
- Rokicki, T. (2018). E-commerce market in Europe in B2C. *Information System in Management*, 7(2), 133-140. <https://bw.sggw.edu.pl/info/article/WULSd0c9b81c58c54578b121ac123fc620a4/>
- Salas, R. (2004). Redes neuronales artificiales. Universidad de Valparaíso. Departamento de Computación, 1(1), 1-7. https://www.academia.edu/24633757/Redes_Neuronales_Artificiales
- Tkáč, M., & Verner, R. (2016). Artificial neural networks in business: Two decades of research. *Applied Soft Computing*, 38, 788-804. <https://doi.org/10.1016/j.asoc.2015.09.040>
- Wu, L., Cui, P., Pei, J., Zhao, L., & Guo, X. (2022). Graph Neural Networks: Foundation, Frontiers and Applications. *Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*. pp. 4840-4841. <https://doi.org/10.1145/3534678.3542609>
- Wu, Z. (2024). The Rise of Digital Banking in the UK Financial Sector and Its Impact on Commercial Banks. *Advances in Economics, Management and Political Sciences*, 120, 179-184. <https://doi.org/10.54254/2754-1169/120/20242553>
- Wu, Z., Pan, S., Chen, F., Long, G., Zhang, C., & Yu, P. (2019). A Comprehensive Survey on Graph Neural Networks. *IEEE Transactions on Neural Networks and Learning Systems*, 32(1), 4-24. <https://doi.org/10.1109/TNNLS.2020.2978386>
- Xie, Y., Takikawa, T., Saito, S., Litany, O., Yan, S., Khan, N., Tombari, F., Tompkin, J., Sitzmann, V., & Sridhar, S. (2022). Neural Fields in Visual Computing and Beyond. *Computer Graphics Forum*, 41(2), 641-676. <https://doi.org/10.1111/cgf.14505>
- Yamazaki, K., Vo-Ho, V., Bulsara, D., & Le, N. (2022). Spiking Neural Networks and Their Applications: A Review. *Brain Sciences*, 12(7), 863. <https://doi.org/10.3390/brainsci12070863>

2025 TECNOCENCIA CHIHUAHUA.

Esta obra está bajo la Licencia Creative Commons Atribución No Comercial 4.0 Internacional.



<https://creativecommons.org/licenses/by-nc/4.0/>