NEXT ITEM BASKET PREDICTION
Sistemas de recomendación para E-commerce basado en reglas de asociación y modelos secuenciales

CARLOS ANDRÉS CEPEDA LAGOS
JOSE ANDRÉS DIAZ CÉSPEDES
DANIEL IVÁN ESCALONA STOCKER

Tesis para optar al título de Ingeniero en Información y Control de Gestión con Magíster en Gestión de Negocios Digitales

Profesor guía: Ignacio Tapia Pérez

FACULTAD DE ADMINISTRACIÓN Y ECONOMÍA
ESCUELA DE INGENIERÍA EN CONTROL DE GESTIÓN

Santiago, Chile
2023

AGRADECIMIENTOS

Agradecemos a la Universidad Diego Portales, Facultad de Administración y Economía por habernos abierto las puertas de su prestigiosa y respetable institución, formadora de impecables profesionales.

Al profesor Nicolás Mágner Pulgar por su gran labor al brindarnos los conocimientos básicos de cómo construir nuestro proyecto de tesis desde el principio de nuestro último año como estudiantes de Ingeniería en Información y Control de Gestión.

Al profesor Ignacio Tapia Pérez, por haber aceptado ser nuestro guía a lo largo de todas las etapas por las que atravesó este proyecto de investigación que finalmente construyeron nuestro reporte oficial.

A todos los compañeros que formaron parte de nuestra formación como profesional y persona, brindándonos apoyo incondicional en todo momento y con quienes logramos metas y objetivos a lo largo de los años de la carrera.

Finalmente, a nuestras familias y amigos por todo su apoyo incondicional durante nuestro camino hacia la obtención del título, por su presencia constante, aliento, amor y confianza que han sido fundamentales para alcanzar este importante logro en nuestras vidas. Agradecidos por ser quienes son y por creer en nosotros

Gracias

Resumen ejecutivo

Esta investigación estudia el desempeño que tienen los sistemas de recomendación en la predicción de la categoría a la que pertenece el siguiente producto que un cliente desea agregar a su canasta. Estos modelos buscan determinar en qué categoría se encuentra el producto que es probable que un consumidor busque adquirir. El objetivo principal de los sistemas de recomendación es que las canastas de compras aumenten su valor y por ende generar beneficio económico para la empresa en términos de incremento en el valor de las ventas digitales. Específicamente, se analiza y compara el desempeño de los sistemas de recomendaciones basados en reglas de asociación, modelos secuenciales y heurísticas (Aleatorio y Top k). La investigación demuestra que, en términos de predicción, el modelo que utiliza reglas de asociación tiene un mejor desempeño frente a los modelos secuenciales y heurísticas. Para analizar estos sistemas, se utiliza la base de datos de una aplicación de compras estadounidense con 32 millones de datos de transacciones, donde bajo distintas métricas de desempeño se compara la efectividad en la predicción de categorías de los diferentes sistemas de recomendación. Los resultados obtenidos demuestran que el modelo de reglas de asociación incrementa el valor promedio de la canasta en un 25.64%, versus el 9.46% de modelos secuenciales, 24.84% de Top k y 0.66% de Aleatorio. Estos resultados ayudan a determinar qué modelo se adapta de mejor manera a la compañía dado sus implicancias y formas de predicción, además se genera conocimiento respecto al incremento económico que puede alcanzar cada sistema de recomendación. El estudio está orientado a las empresas con problemas de ventas, para todas las empresas de E-commerce y principalmente a aquellas que buscan hacer la transición a las plataformas digitales. La investigación se limita a la base de datos de transacciones y categorías de la empresa estudiada, por lo que los resultados son muestrales y podrían no ser representativos para otro conjunto de datos.

Palabras claves: Ítem basket, Sistema de Recomendación, E-commerce, Reglas de Asociación, Modelos Secuenciales.

Tabla de contenido

1. Introducción 8
2. Revisión bibliográfica 21
2.1 E-commerce, el comportamiento del consumidor actual e ítem basket. 21
2.2 Algoritmos de los sistemas de recomendación. 22
2.3 Reglas de asociación y modelos secuenciales. 24
3. Metodología. 26
3.1 Descripción de la base de datos 27
3.2 Selección de datos 30
3.3 Transformación de los Datos 30
3.4 Data mining (Modelos) 31
3.4.1 Modelo de Reglas de Asociación (Algoritmo Apriori) 32
3.4.1.1 Hiperparámetros del Modelo de Reglas de Asociación 33
3.4.1.1.1 Support 33
3.4.1.1.2 Confidence 34
3.4.1.1.3 Lift 34
3.4.1.1.4 Leverage 35
3.4.2 Modelos Secuenciales (Red Neuronal GRU4Rec) 35
3.4.2.1 Hiperparámetros del Modelo Secuencial (GRU4Rec) 39
3.4.2.1.1 Función de pérdida (loss function) 39
3.4.2.1.2 Arquitectura de la Red (capa de embedding y dimensión de embedding [32], N° de capas ocultas GRU) 40
3.4.2.1.3 Optimizador (Adagrad) 41
3.4.2.1.4 Épocas (epochs) 42
3.4.2.1.5 Patience Early stopping 43
3.4.3 Heurísticas 44
3.5 Técnicas de robustez 45
3.6 Métricas de desempeño 47
3.7 Diferencia de medias 48
4. Resultados 49
4.1 Análisis estadístico de los resultados 56

4.2 Análisis económico de los resultados 58
5. Limitaciones 60
6. Conclusiones 61
7. Referencias 65

Índice de Tablas

Tabla 1: "*Cantidad de recomendaciones al final del flujo de compra en las top 15 empresas de E-commerce con mayor tráfico en Chile el año 2022"* 13

Tabla 2: *Descripción base de datos* 27

Tabla 3*: Resultados Heurísticas* 50

Tabla 4*: Resultados reglas de asociación* 51

Tabla 5*: Resultados modelos secuenciales* 53

Tabla 6*: Test de diferencia de medias entre métricas de reglas de asociación contra benchmarks* 57

Tabla 7*: Análisis Económico* 59

Índice de figuras

Figura 1*: Frecuencia absoluta de productos añadidos a la canasta en primer lugar* 29

Figura 2*: Frecuencia absoluta de último puesto en el que se añadió en la canasta de compra* 29

Figura 3*: Diagrama conceptual del algoritmo gated recurrent unit (GRU)* 38

Figura 4*: "Resultados métricas de desempeño por modelo"* 55

1. Introducción

El propósito de esta investigación es estudiar el desempeño que tienen los sistemas de recomendación en la predicción de la categoría a la cual pertenece el siguiente producto que un cliente desea agregar a su canasta, y mostrar cómo impacta el resultado de los modelos en el incremento del ingreso de las ventas digitales de la compañía.

El comercio electrónico ha cambiado algunos aspectos de la cadena de valor de las organizaciones. Por un lado, las empresas físicas se apoyan de este, aprovechando y buscando nuevas oportunidades de generar ingresos. Por otro lado, las empresas de internet dominan este canal y pueden enfrentar de mejor manera la volatilidad que tiene este último teniendo una ventaja competitiva frente a las físicas (Dehning et al. 2004).

De acuerdo con lo planteado por el autor anteriormente, los sistemas de recomendación hoy en día son una herramienta sumamente potente para extraer información respecto al comportamiento del consumidor y determinar estrategias empresariales adecuadas para sacar provecho económico de eso, es decir, son útiles para diferenciarse respecto a los competidores.

Dado que existen muchos productos y opciones, la elección de productos se presenta como un gran desafío para los consumidores al momento de escoger la opción más adecuada (Sarwar et al., 2000).

Los sistemas de recomendación intentan igualar la experiencia de compra de una tienda física, como si se tratase de un vendedor ofreciendo productos, es decir, estos algoritmos ayudan a generar tantas recomendaciones como sean necesarias, facilitando la búsqueda de las opciones de productos y mejorando la experiencia de los clientes porque se vuelve cómodo al poder realizar la compra desde cualquier lugar.

Adicionalmente, los sistemas de recomendación basados en reglas de asociación y modelos secuenciales sostienen la idea de predecir y descubrir cuáles son los productos más probables que el consumidor desee adquirir, dado el comportamiento de compra actual (productos ingresados a la canasta de compra). En otras palabras, estos modelos buscan recomendar en base a la relación con los productos que ya se han ingresado a la canasta anteriormente.

Así lo plantea De Moya y Rodríguez quienes mencionan que:

Un claro ejemplo, en relación con los algoritmos basados en reglas de asociación, es el análisis de la canasta adquirida por los compradores, la cual es utilizada para encontrar asociaciones entre los diferentes productos comprados por los clientes (De Moya, Rodríguez, 2003).

Por otro lado, otros autores mencionan respecto a los modelos secuenciales:

Los modelos secuenciales, utilizan como input el orden en que los ítems fueron ingresados a la canasta, utilizando las acciones en un orden cronológico (Tang, Zhouÿ, 2018).

Actualmente dado el gran alcance y popularidad al que se puede llegar al utilizar ventas online, una parte importante de las industrias se han digitalizado y venden sus productos por internet obteniendo buenos resultados. Esta investigación está orientada hacia las empresas con problemas de ventas, hacia todas las empresas de comercio electrónico, y principalmente a aquellas que buscan hacer la transición a las plataformas digitales.

De hecho, según Muñoz (2021), Amazon declara que alrededor del 35% de sus ingresos se debe a recomendaciones de productos. Esto es una prueba de que personalizar la experiencia de compra para el cliente y potenciar el descubrimiento de productos son estrategias clave en el E-commerce. También menciona que los

beneficios de un sistema de recomendación para tienda online son: Entre 15% y 45% de aumento de las conversiones, 25% de media de incremento del valor promedio de compra, alargamiento del ciclo de vida del cliente; generación de fidelización del comprador; mayores ventas a través de up-sell y cross-sell.

Por otro lado, de acuerdo con un estudio realizado por “Blacksip”, los chilenos han aumentado un 23% en la participación en comercio electrónico, llegando al 67% de penetración de este último. El mercado de comercio electrónico chileno contribuyó a la tasa de crecimiento global de comercio electrónico con un 29% en 2021.

Los ingresos del comercio electrónico continúan aumentando, están surgiendo nuevos mercados y los mercados existentes tienen un potencial de expansión, lo cual para las empresas es beneficioso en términos de poder aumentar sus ingresos y hacerle la vida más fácil al usuario de sus páginas o app de comercio electrónico (Blacksip, 2022).

Además, estudios de “Nasdaq” muestran que, en 2018, el 18 % de todas las ventas minoristas se realizaron en línea y para 2040, se cree que el comercio electrónico facilitará el 95 % de las compras en línea (Nasdaq, 2017).

De acuerdo con lo planteado por los estudios anteriores, los sistemas de recomendación y el comercio electrónico generan beneficios tanto para la empresa como para el consumidor. La empresa obtiene ventajas al acceder a información valiosa sobre el cliente, lo que a su vez resulta en beneficios económicos. Por su parte, los consumidores experimentan mejoras en la facilidad y calidad de su experiencia de compra en línea.

Es importante comprender los sistemas de recomendación en los que se basa la investigación, ya que el comercio electrónico es el tipo de comercio que los consumidores prefieren en la actualidad, por lo tanto, las organizaciones necesitan establecer estrategias para diferenciarse y sacar beneficios económicos de estos

modelos, dado que, al recomendar productos altamente probables que los clientes consuman, ayuda directamente al incremento del ingreso de ventas digitales.

Por otra parte, una herramienta tan potente como son los sistemas de recomendación aportan a la idea de incrementar las ventas, dado que, asocia los datos relevantes de cada canasta de compra con las opciones más probables asociadas a los ítems seleccionados, y le dan un orden lógico a los datos para que esa probabilidad sea aún más certera según la dependencia de estos últimos.

Las contribuciones de esta investigación son:

En primer lugar, entender la importancia de los sistemas de recomendación para las empresas de comercio electrónico como herramienta de predicción, realizando un análisis robusto del funcionamiento de los modelos en los que se basa la investigación y mostrando el impacto económico que puede generar cada modelo en la compañía. Esta comparación es aplicada sobre datos reales pertenecientes a un comercio electrónico extranjero, para ver la posibilidad y viabilidad que podría llegar a tener en el comercio electrónico de Chile. Según Sarwar (2000), este tipo de sistemas están siendo alimentados por un gran volumen de datos de clientes y serán aún más alimentados por el creciente volumen de estos en los sitios web.

En segundo lugar, mostrar las implicancias, el funcionamiento y la lógica de cada uno de los sistemas de recomendación. También, se muestran resultados respecto a las recomendaciones generadas y se analiza el desempeño obtenido por los modelos medidos bajo métricas de desempeño con el objetivo de determinar qué modelo recomienda productos de mejor manera y por ende genera mayores beneficios.

Por último, respecto a los resultados obtenidos de cada modelo, se toma una postura respecto al mejor modelo de predicción de ítems para la canasta, se

presentan las limitaciones del estudio y se generan recomendaciones de mejoras para futuras investigaciones.

En el contexto de los sistemas de recomendación para las canastas de compra en comercio electrónico, en mayo de 2023, los autores llevaron a cabo un estudio donde compararon los 15 sitios de comercio electrónico más utilizados en Chile durante el año 2022. Esta información se basó en los datos proporcionados por la herramienta App Annie según Ramírez (2022). Los resultados obtenidos se encuentran en el **Tabla 1**, donde destaca que sólo 8 de los 15 sitios con mayor tráfico de consumidores tienen sistemas de recomendación al final del flujo de compra, y de estas, solo 3 son chilenas. En otras palabras, se muestra que las empresas que triunfan en ventas de comercio electrónico son las que cuentan con recomendaciones al final del flujo de compra de la canasta y que en su mayoría, estas empresas son internacionales.

Tal como se mencionó en un comienzo, para efectos de esta investigación se utiliza la base de datos de una aplicación de compras estadounidense, con el objetivo observar cómo opera la predicción de la canasta en un comercio electrónico del extranjero y así evaluar la viabilidad de implementación en el mercado nacional, poniendo énfasis en incorporar mejoras al sistema de recomendación a la canasta utilizado en Chile.

Tabla 1: "*Cantidad de recomendaciones al final del flujo de compra en las top 15 empresas de E-commerce con mayor tráfico en Chile el año 2022"*

Apps	Origen de Empresa	N° de recomendaciones
Shein*	China	4
Kobai	Chile	4
Alibaba*	China	3
Spid	Chile	3
Jumbo App	Chile	3
Shopee*	Singapur	2
AliExpress*	China	2
Amazon*	EE. UU	2
Falabella	Chile	0
Mercado Libre*	Argentina	0
París App	Chile	0
Líder*	EE. UU	0
Santa Isabel	Chile	0
Unimarc	Chile	0
Sodimac	Chile	0

Nota: * Corresponde Apps no nacionales

Fuente: Elaboración propia

La tabla anterior muestra un claro ejemplo de que empresas líderes en ventas digitales tienden a ser aquellas que tienen incorporado sistemas de recomendación en la canasta de las ventas digitales. Adicionalmente, ayudan a la experiencia de compra de los consumidores logrando aumentar el número de artículos seleccionados, así lo plantean diversos autores que mencionan:

Los sistemas de recomendación en los comercios electrónicos son una tecnología potente para la generación de valor adicional para una empresa en base a los datos transaccionales de sus clientes, dado que, estos sistemas ayudan a encontrar los productos de la canasta que desea (Sarwar et al., 2000).

También los sitios de comercio electrónico utilizan estos sistemas para sugerir productos a sus consumidores y proporcionar información que les ayude a determinar qué productos comprar. (Li et al.2005).

Además, juegan un papel importante en los sitios y plataformas de comercio electrónico. Con el objetivo de predecir el próximo conjunto de artículos que un usuario probablemente compraría, en relación con la recomendación de la próxima cesta de compra. (Shen et al. 2022).

En esta investigación, para ajustar los modelos a la base de datos, se utilizó el método *Knowledge Discovery in Databases* (KDD), que tiene por objetivo principal descubrir conocimiento a partir de los datos. En cuanto al entendimiento del método KDD, cuenta de una serie de etapas para lograr su objetivo, es fundamental formalizar el proceso del conocimiento implícito en los datos (minería de datos), y comprender en qué se basan los sistemas de recomendación estudiados, es decir, las reglas de asociación y los modelos secuenciales.

Es vital comprender el funcionamiento de los sistemas en los que se enfoca esta investigación porque son incrementadores de ventas, mejoradores de experiencias de compra y muy beneficiosos tanto para la compañía como para el consumidor.

Sarwar, plantea que durante mucho tiempo se ha interesado en idear recomendaciones de productos a clientes en función de diferentes técnicas. Una de las más utilizadas se encuentran las reglas de asociación entre conjunto de productos adquiridos (Sarwar et al 2000).

Entonces, a partir de todo lo mencionado hasta aquí, surge la siguiente pregunta:

¿Qué tipo de sistema de recomendación tiene mejor desempeño para predecir el siguiente ítem de la canasta de compra?

Las hipótesis de esta investigación, plantea que, dado la estructura de los modelos, la forma de operar, y lo planteado por diversos autores en la literatura, el modelo basado en las reglas de asociación simples (algoritmo Apriori) deberían tener una mejor performance que el modelo basado en modelos secuenciales (red neuronal secuencial GRU4Rec) y que las recomendaciones heurísticas (Top K y Aleatorio).

El objetivo principal de esta investigación es estudiar el desempeño que tienen los sistemas de recomendación en la predicción del siguiente ítem de la canasta del consumidor en un comercio electrónico. Para esto, mediante la metodología KDD implementada a los datos de un comercio electrónico extranjero, se programan los modelos y heurísticas para analizar los resultados obtenidos.

Los objetivos específicos son, por un lado, comprobar que el modelo funciona correctamente en la predicción y que este sea automático. Por otro lado, comparar cuál modelo tiene mejor desempeño al momento de predecir el siguiente ítem de la canasta basado en las métricas de desempeño de los modelos, si las reglas de asociación, las heurísticas o los modelos secuenciales. Las métricas de desempeño con las que se evalúan los modelos son Hit Rate y Mean Reciprocal Hit Rate y Coverage (Mayor detalle en el punto 3.6).

En esta investigación el análisis de datos se realiza mediante la metodología *Knowledge Discovery Databases* (KDD), fuertemente utilizada en minería de datos cuya aplicación tiene por objetivo generar conocimiento a partir de los datos y se extiende hasta los sistemas de recomendación basados en los algoritmos de interés.

Por un lado, se encuentran las reglas de asociación que se programan en base al algoritmo Apriori, por otro, se encuentran los modelos secuenciales que utilizan redes neuronales secuenciales, respectivamente. Para esto se busca generar un modelo que describa los sistemas de recomendación y entregue una respuesta a la hipótesis planteada.

En primer lugar, se trabaja la base de datos de una aplicación de compras estadounidense, la cual pasa por cada una de las etapas del método KDD con el objetivo de poder trabajar los datos y obtener conocimiento valioso de ello, como lo son comportamiento del consumidor, patrones de compra, relaciones entre productos o tendencias. Todos los pasos de esta investigación están contenidos en la metodología del método KDD.

En segundo lugar, en la etapa da minería de datos (del método KDD) se implementa la programación los sistemas de recomendación mediante la codificación respectiva, los cuales se programan en base a reglas de asociación con modelo Apriori, y de los modelos secuenciales programados con las redes neuronales (GRU4Rec). Adicionalmente se proponen como parámetros adicionales de comparación a los modelos de interés, modelos basados en heurísticas como Top k y Aleatorio. Esto con la finalidad de aumentar la competencia y comparación de los modelos principales.

Finalmente, luego de comparar el desempeño de los cuatro modelos, se muestran los resultados obtenidos y se entrega una conclusión respecto a la efectividad de los modelos en términos de predicción de categorías, además se toma una postura sobre si es que se cumple o no con la hipótesis planteada y se determina el mejor modelo para esta base de datos.

La base de datos utilizada en la investigación pertenece a Instacart, aplicación de pedidos y comestibles estadounidense. Esta compañía da a disposición los datos en la plataforma Kaggle, siendo esta última una plataforma gratuita donde se pone

a disposición de los usuarios una serie de problemas para solucionar con distintas temáticas, entre ellas la ciencia de datos, el análisis predictivo y el machine learning. El conjunto de datos es anónimo y contiene una muestra de más de 3 millones de transacciones, 32 millones de filas (productos por transacción) y más de 200.000 clientes únicos de Instacart (Kaggle, 2017).

La razón de usar esta metodología es porque dada la problemática de la investigación (predecir el siguiente ítem de la canasta del consumidor) esta opción es la que mejor se adapta para entender cómo funcionan los sistemas de recomendación para dar respuesta certera a la predicción del siguiente ítem de la canasta y dar una respuesta concreta la pregunta de investigación, es decir, determinar qué modelo predice mejor la siguiente categoría a ingresar a la canasta. Adicionalmente, esta es una metodología probada y ampliamente utilizada en distintos proyectos académicos e industriales cuando el objetivo principal es obtener valor e información desde los datos.

Por un lado, la obtención de reglas de asociación que pueden actualizarse en tiempo real y que permitan obtener conocimiento oculto de los datos históricos, pueden ser útiles en la toma de decisiones. (Martínez et. al., 2009).

Por otro lado, los modelos secuenciales buscan ocurrencias cronológicas y se aplican principalmente en el análisis de la canasta de mercado. (Agrawal y Srikant, 1995).

Por último, la importancia de ocupar redes neuronales se debe a su constitución y a sus fundamentos, las redes neuronales artificiales presentan un gran número de características semejantes a las del cerebro. Por ejemplo, son capaces de aprender de la experiencia, de generalizar casos anteriores a nuevos casos, de abstraer características esenciales a partir de entradas que representan información irrelevante, etc. Esto hace que las predicciones sean mucho más precisas (Matich, et. al., 2001).

Adicionalmente, las redes neuronales son capaces de descubrir formas funcionales más complejas que el resto de los modelos como lo son los programados con las reglas de asociación o los modelos heurísticos Aleatorio y Top k. Esto dado a la capacidad de datos que son capaces de procesar.

Los resultados obtenidos en esta investigación demuestran que el modelo de reglas de asociación tiene una mejor performance que los modelos secuenciales y las heurísticas Top k y Aleatorio determinado a través de métricas de desempeño

Es importante comprender a su vez, que cada modelo analizado en esta investigación tiene asociado un costo y un beneficio para la empresa que desea implementarlos. Esto es vital a la hora de decidir cuál modelo es mejor para la compañía (Para mayor detalle de los costos y beneficios de cada modelo ver punto 4.2).

Los sistemas de recomendación estudiados han demostrado ser una herramienta eficaz sumamente efectiva para incrementar las ventas en el comercio electrónico. En respuesta a la pregunta de principal de la investigación, es decir:

¿Qué tipo de sistema de recomendación tiene mejor desempeño para predecir el siguiente ítem de la canasta de compra?

Mediante la comprobación de los resultados obtenidos y las métricas de desempeño de los modelos analizados, se concluye lo siguiente:

La hipótesis planteada en el inicio se acepta, dado que, las reglas de asociación obtuvieron mejores resultados en términos de métricas de desempeño frente a los modelos secuenciales, Top k y Aleatorio (Los resultados se muestran con mayor detalle en el punto 4).

Los resultados del estudio indican que el sistema de recomendación basado en reglas de asociación tiene un mejor rendimiento que los modelos heurísticos (Top k y Aleatorio) y los modelos secuenciales (GRU4Rec). Esto se debe a que el modelo de reglas de asociación aumenta el valor promedio de la canasta en un 25.64%, en comparación con el 9.46% de los modelos secuenciales, el 24.84% de Top y el 0.66% de Aleatorio. Además, se realizó un análisis estadístico que demostró que las reglas de asociación tienen un rendimiento significativamente mejor en cuanto al aumento del valor promedio de la canasta en comparación con todos los benchmark.

En esta investigación se muestra y comprueba la relevancia de los sistemas de recomendación en el incremento de las ventas de comercio online. Siendo estos modelos una herramienta fundamental para apoyar el negocio en términos de aumentar el valor promedio de la canasta de los clientes del comercio electrónico. Según el análisis económico, las reglas de asociación tienen mejor desempeño en relación con la venta incremental (Ingresos) que el resto de los modelos, alcanzando un beneficio extra de USD $1.090.115 en un escenario pesimista bajo los supuestos descritos en el cuerpo de esta investigación.

Las implicancias abarcan diferentes perspectivas. Por una parte, desde la perspectiva gerencial, aporta en la gestión de negocio de empresas que estén instaladas en plataformas digitales y específicamente las que quieran hacer la transición al comercio electrónico y deban decidir qué modelo implementar en su negocio, siendo los sistemas de recomendación una herramienta relevante para la estrategia empresarial de la compañía, el enfoque del negocio y su ventaja competitiva.

El valor de los pedidos promedio puede aumentar un 50%, las tasas de conversión un 150% y los ingresos un 300% (Sánchez - Herrera, 2017).

Por otra parte, desde la perspectiva académica, ayuda a comprender a las personas interesadas, el impacto de los sistemas de recomendación en el comercio electrónico, el funcionamiento de los modelos de reglas de asociación y modelos secuenciales, sus similitudes, diferencias, costos y beneficios.

En conclusión, cada sistema de recomendación analizado en esta investigación presenta costos y beneficios asociados. Esto es sumamente importante a la hora de escoger un modelo u otro y determinar cuál es mejor para la compañía. Todos se centran en mejorar la experiencia de compra del cliente, ofrecer productos de manera personalizada, pero se diferencian en su manera de trabajar, su eficiencia en los aciertos, sus costos, complejidad y beneficios.

Esta investigación parte en primer lugar con la referencia bibliográfica, donde se abordarán las ideas de diferentes autores que hablan sobre comercio electrónico, el comportamiento de los consumidores, los sistemas de recomendación, las reglas de asociación y los modelos secuenciales.

En segundo lugar, se detalla la metodología de la investigación, es decir, la utilización del método KDD para implementar los modelos, la explicación de la base de datos utilizada, los sistemas de recomendación, las reglas de asociación, y redes neuronales respectivamente.

En tercer lugar, se muestra el desempeño de los modelos, con los resultados obtenidos.

Finalmente, se plantean conclusiones y discusiones respecto a los resultados obtenidos en la investigación.

2. Revisión bibliográfica

El propósito de esta investigación es estudiar el desempeño que tienen los sistemas de recomendación para predecir la categoría de productos que agrega a la canasta un consumidor al momento de la compra, y mostrar cómo impacta en el incremento al valor promedio de la canasta de comercio electrónico.

Para esto se investigan y describen los siguientes conceptos:

2.1 E-commerce, el comportamiento del consumidor actual e ítem basket.

La interacción y las necesidades de los consumidores han llevado a entender que el comercio electrónico es la nueva forma de comercio que la web 2.0 y las futuras se consolidarán en las siguientes generaciones. Este concepto es empleado por Huan y Chai en el estudio de la “Arquitectura de la plataforma del E-commerce para las próximas generaciones”, el cual muestra que el E-commerce, impulsado por la tecnología informática e internet, ha experimentado un importante crecimiento durante las últimas dos décadas y ha cambiado las reglas del negocio. (Y, Huang, Y. Chai. 2019).

El comportamiento del consumidor, al llevar a cabo una compra de manera online, transforma la manera de pensar, elimina formas antiguas de ejecutar una compra y agrega conceptos nuevos, y funciones que las maneras posteriores de realizar la compra quedaron obsoletas, repercutiendo en los consumidores antiguos y los nuevos. Las personas que crecen integradas en la tecnología a menudo tienen una capacidad y una reacción a esas tecnologías diferentes a las de aquellos que tienen que aprender a usarla más adelante en la vida. (M. Rybaczewska, L. Sparks. 2021).

Esta idea no solo representa una transformación y revolución duradera, sino que también incorpora nuevas características que el comercio electrónico busca democratizar y establecer como pilares para las futuras generaciones. Un ejemplo concreto es la conceptualización de la canasta, carrito o cesta de compra, que ejemplifica esta evolución.

Antes de la llegada del comercio electrónico, se veía limitada la canasta al momento de ingresar un artículo (ítem) de manera física, ya que eran voluminosos o de gran cantidad, provocando en los consumidores no poder completar la compra o seleccionar más de un ítem relacionado al total del proceso final de compra. Generando así, tanto a los consumidores como las empresas que venden los productos, costos que influyen principalmente en elegir más de un artículo. Sin embargo, surge la nueva idea de carrito de compra en el comercio electrónico, el cual rompe el esquema tradicional y disminuye dicho costo. Aumentando la probabilidad de compra de más de un ítem y artículos que están relacionados con otros. (A. Pozzi. 2013).

Junto con la idea del comercio electrónico y los ítems, los algoritmos de recomendación son una herramienta de predicción que ayudan a gestionar y proporcionar facilidad de compra, principalmente lo que se quiere lograr en esta investigación. Adicionalmente, ayudan directamente al incremento al valor promedio de la canasta y por ende genera mayores beneficios a las empresas que los implementan.

2.2 Algoritmos de los sistemas de recomendación.

Los algoritmos, como conjuntos ordenados de pasos y operaciones, permiten a quienes los aplican hallar la solución de un problema determinado.

El principal objetivo que tienen los sistemas de recomendación, cuando hablamos desde el punto de vista de las transacciones digitales, es que al momento en que una persona comienza una experiencia de compra web e ingresa un determinado producto o servicio al carrito de compra, este sistema tiene la facultad de ofrecer a dicho cliente productos o servicios que sean de su agrado. De esta manera se busca que sea altamente probable que compre ese ítem también.

Los sistemas de recomendación se programan en base a algoritmos, que van a depender de su uso, funcionalidad y de quien los maneja. Para efectos de este artículo de investigación, nos centraremos en aquellos sistemas de recomendación que utilizan técnicas de análisis de datos de gran escala, datos de compra y preferencias para así producir recomendaciones que sean útiles a los consumidores.
Específicamente nos enfocaremos en algoritmos de minería de datos tradicional, filtrado colaborativo, reglas de asociación simples (algoritmo Apriori), disminución de la dimensionalidad y modelos secuenciales recurrentes.

Entre los principales y más usados algoritmos con los que se programan los sistemas de recomendación para venta digital es el del filtrado colaborativo. Este método consiste y se centra en generar y encontrar grupos de clientes a lo largo del tiempo que tienen o tuvieron necesidades parecidas y de esta manera aumentar la probabilidad de éxito al momento de la recomendación del siguiente producto.

Por otro lado, para Sarwar este método tiene dos principales desafíos, como lo son el mejorar la escalabilidad del filtrado colaborativo y mejorar la calidad de las recomendaciones para los consumidores. (Sarwar et al., 2000).

Sin embargo, para efectos de esta investigación nos enfocamos principalmente en los sistemas de recomendación programados en base a las reglas de asociación simples, entre las cuales se encuentra el algoritmo Apriori y en los programados con modelos secuenciales (redes neuronales recurrentes).

En lo que respecta a las reglas de asociación, existen criterios que determinan si dos o más productos denominados antecedente y consecuente son llevados conjuntamente y con qué nivel de seguridad. Estos criterios son denominados soporte y confianza.

Las reglas de asociación son apropiadas si satisfacen el valor del mínimo nivel soporte establecido y de la mínima confianza (Hiperparámetros de reglas de asociación en punto 3.4.1.1).

El interés debe centrarse en el descubrimiento de reglas que tienen mucho soporte, este atributo-valor que cubren gran cantidad de instancias se conoce como itemsets frecuente. (De Moya, Rodríguez, 2003).

Como se muestra anteriormente para los autores, soporte y confianza son criterios claves para las reglas de asociación. Entre las reglas de asociación simples encontramos el algoritmo Apriori. Este algoritmo está enfocado principalmente en operar con los “Itemsets frecuentes”. El algoritmo Apriori busca itemsets frecuentes utilizando generación de candidatos. Este algoritmo se resume en dos pasos. Primero se toman todos los posibles pares de ítems que cumplen con las medidas mínimas de soporte inicialmente preestablecidas; esto permite ir eliminando posibles combinaciones: aquellas que no cumplan con los requerimientos de soporte no entrarán en el análisis. Segundo, generación de las reglas revisando que cumplan con el criterio mínimo de confianza. Es interesante observar que, si una conjunción de consecuentes de una regla cumple con los niveles mínimos de soporte y confianza, sus subconjuntos (consecuentes) también los cumplen; en el caso contrario, si algún ítem no los cumple no tiene caso considerar sus superconjuntos. (Agrawal, 1994)

De esta manera podremos centrarnos sólo en aquellos ítems que cumplan con la regla y se descartan aquellos que no valga la pena considerar.

2.3 Reglas de asociación y modelos secuenciales.

Los modelos matemáticos que se utilizarán para programar los sistemas de recomendación en este artículo son: Reglas de asociación con algoritmo Apriori y modelos secuenciales con la red neuronal GRU4Rec.

Las reglas de asociación son técnicas empleadas en el aprendizaje no supervisado para establecer posibles relaciones entre diferentes acciones aparentemente independientes entre sí, reconociendo cómo pueden ocurrir los eventos o acciones a partir de la aparición de otros. Así, este tipo de técnicas se usa cuando el análisis que se desea realizar es exploratorio (Pérez C.Santín-González, D.2007).

Existen diversos algoritmos para encontrar reglas de asociación, el más utilizado es el algoritmo Apriori, el cual “se basa en la búsqueda de los conjuntos de datos con determinada cobertura” (Hernández, J., Ramírez, M., Ferri, C. 2004).

De acuerdo con lo planteado por los autores anteriormente, las reglas de asociación son parte fundamental para resolver la problemática de esta investigación, que es la predicción de categorías a ingresar a la canasta dado un conjunto de datos que se ingresó previamente.

Los modelos secuenciales buscan ocurrencias cronológicas a través de las reglas de asociación. Se aplican principalmente en el análisis de la canasta de mercado y su objetivo es descubrir en los clientes ciertos comportamientos de compra en el tiempo. El dato de entrada es un conjunto de secuencias llamado data-secuencia, en las que cada transacción es un conjunto de ítems (Timarán S., Hernández I., Caicedo S., Hidalgo A. y Alvarado J. 2016). Lo que agrega un soporte dentro de esta investigación

Por último, las redes neuronales están construidas por un conjunto de nodos interconectados que se denominan neuronas y se organizan en capas. Una red neuronal básica tiene una capa de entrada (input layer), una capa intermedia (hidden layer) y una capa de salida (output layer). Los nodos de la capa de entrada corresponden con el número de variables que queremos introducir en la red (serían los equivalentes a las variables independientes en una regresión lineal). Por otro lado, el número de nodos de salida depende del número de variables a predecir.

Por último, la capa intermedia se usa principalmente para aplicar transformaciones no lineales a las variables de entrada originales (Cabezón, M. 2018).

Las redes neuronales recurrentes toman gran importancia en esta investigación ya que automatizan el proceso de clasificación y predicción de ítems.

Los modelos de predicción anteriormente mencionados, es decir, reglas de asociación y modelos secuenciales, en conjunto son los que mejor se adaptan a nuestra problemática, dando soluciones precisas y de forma aplicable. Mostrando qué ítem será el próximo que agrega el consumidor a la canasta.

3. Metodología.

El propósito de esta investigación es estudiar el desempeño que tienen los sistemas de recomendación para predecir la categoría de productos que agrega a la canasta un consumidor al momento de la compra, y mostrar cómo impacta en el incremento al valor promedio de la canasta de comercio electrónico.

Esta investigación usa el método *Knowledge Discovery in Databases* (KDD), esta metodología es utilizada fuertemente en minería de datos, cuya aplicación se extiende hasta los sistemas de recomendación.

En el método KDD en primer lugar, se seleccionan los datos, lo cual varía según el objetivo que tenga la investigación. En segundo lugar, transformación de los datos, donde se analiza la calidad de estos, se ignoran variables vacías y se reduce la dimensionalidad, es decir, si se encuentran datos agrupados en tuplas o rangos para un mejor trabajo al momento de realizar la minería. En tercer lugar, la minería de datos, donde los sistemas de recomendación se programan en base a algoritmos y aparecen los modelos de reglas de asociación, modelos secuenciales, Top k y Aleatorio. Finalmente, se comprueba el grado de certeza de las hipótesis planteadas inicialmente, se responde la pregunta de investigación y se toma una postura

respecto a la conclusión de la investigación, es decir, si las hipótesis planteadas se aceptan o rechazan.

3.1 Descripción de la base de datos

La base de datos utilizada en esta investigación, llamada "The Instacart Online Grocery Shopping Dataset 2017", pertenece a Instacart, aplicación de pedidos y comestibles estadounidense. Esta compañía da a disposición los datos en la plataforma Kaggle, siendo esta última una plataforma gratuita donde se pone a disposición de los usuarios una serie de problemas para solucionar con distintas temáticas, entre ellas la ciencia de datos, el análisis predictivo y el machine learning. El conjunto de datos es anónimo y contiene una muestra de más de 3 millones de órdenes, 32 millones de transacciones y más de 200.000 usuarios de Instacart. Para cada usuario, proporciona entre 4 y 100 de sus pedidos, muestra también la secuencia de productos comprados agregados al carro en cada pedido. (Kaggle, 2017).

En la **Tabla 2** se muestra el detalle de las variables de la base de datos utilizada en la investigación.

Tabla 2: *Descripción base de datos*

Variable	Tipo de Variable	Descripción
Order_ID	Int	Identificador único de la orden/canasta de compra
Add_to_cart_order	Int	Orden en que se añadieron los productos en la canasta de compra
Product_ID	Int	Identificador único del producto (SKU)
Product_name	Varchar/Obj	Nombre del producto
Aisle_ID	Int	Identificador único del pasillo al que pertenece el producto
Aisle	Varchar/Obj	Nombre del pasillo al que pertenece el producto
Department_ID	Int	Identificador único del departamento al que pertenece el producto
Department	Varchar/Obj	Nombre del departamento al que pertenece el producto

Nota: Int = Variables numéricas enteras. Varchar/Obj = Variables tipo texto.

Fuente: Elaboración propia

Respecto a la variable independiente o de interés con la que los modelos van a basar su predicción es el identificador del pasillo al cual pertenece el producto (Aisle Id), ya que se desea predecir la próxima categoría que agrega el consumidor a la canasta mediante la recomendación de pasillos. Para el caso de estudio sólo se tomaron en consideración las siguientes variables:

- Aisle ID
- Order_ID
- Add_To_Cart Order.

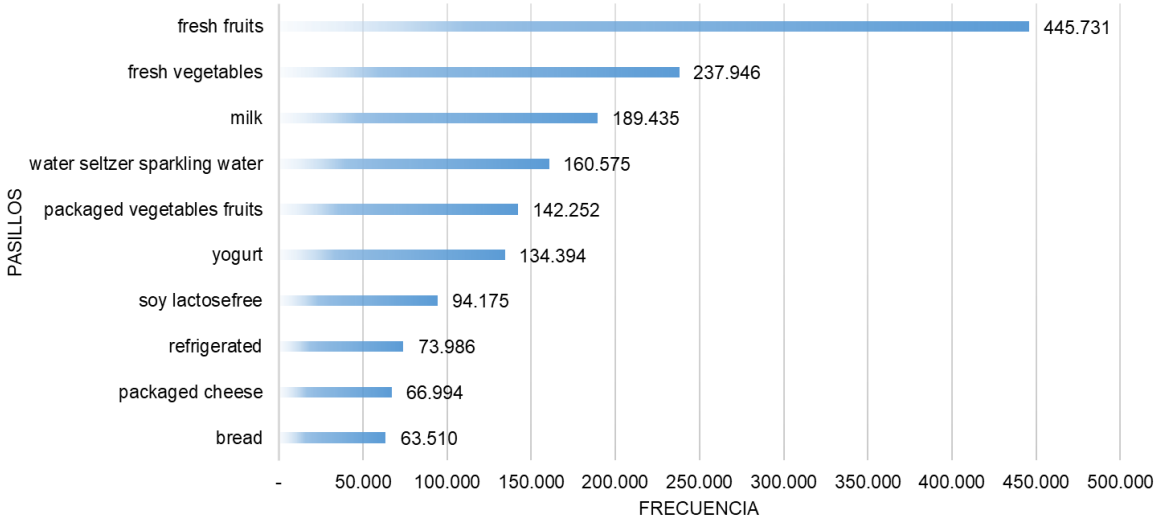
Es importante entender que utilizando los ID de cada variable (identificadores), se determina la manera en que se relacionan las variables y la manera en que se llevan a cabo las recomendaciones de los distintos modelos. Asimismo, es relevante destacar que, entre las variables mencionadas, existen 3.214.874 órdenes/canastas únicas, 134 categorías de productos y 145 posiciones en que se agregaron los productos al carro de compras.

Respecto a lo anterior surge la siguiente interrogante:

¿Qué pasillos se suelen añadir en primer lugar y cuáles en último en las transacciones de esta base de datos?

El **Figura 1 y Figura 2** refleja que “fresh fruits”, tiene la mayor frecuencia de ingreso al carro en primer lugar con 27.7% y también tiene la mayor frecuencia de ingreso al carro en último lugar con un 23.9%, es decir, se puede establecer que, dentro del conjunto de datos, es el pasillo que más predomina al momento de ingresar los productos al carro tanto en el principio como en el final.

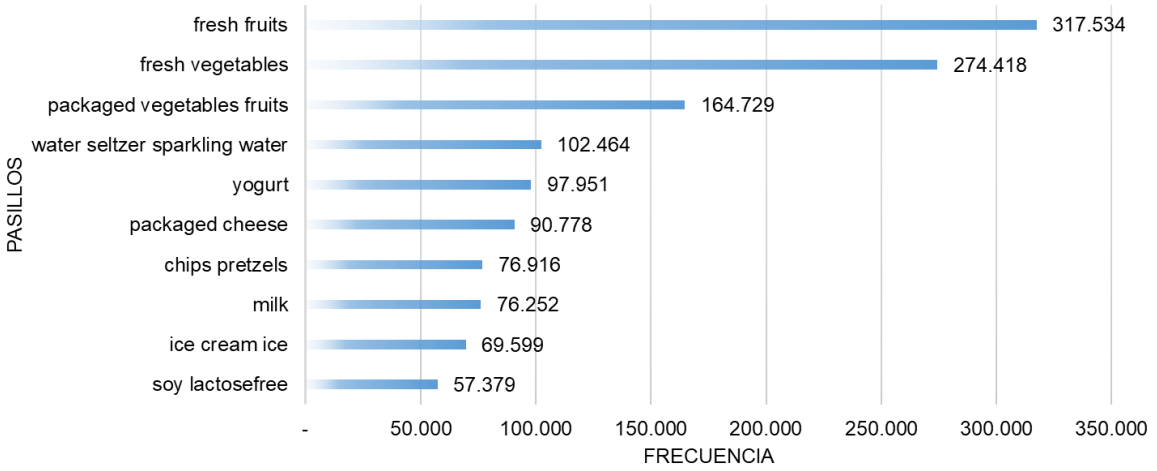
Figura 1*: Frecuencia absoluta de productos añadidos a la canasta en primer lugar*



Nota: Gráfico de barra que muestra la frecuencia absoluta de productos añadidos a la canasta en primer lugar de la orden de compra.

Fuente: Elaboración propia

Figura 2*: Frecuencia absoluta de último puesto en el que se añadió en la canasta de compra*



Nota: Gráfico de barra que muestra la frecuencia absoluta de productos añadidos a la canasta en último lugar de la orden de compra.

Fuente: Elaboración propia

Respecto a los gráficos anteriores, podrían existir secuencias de ingreso lógicas de productos a la canasta de compras que no se están observando y que podrían interesar a las organizaciones para sacar conclusiones que incrementen las ventas del negocio. Esos valores de asociaciones de categorías de productos se obtienen a través de los sistemas de recomendación.

Por último, la base de datos se limita a que para recomendaciones futuras los datos contienen las categorías de productos actuales y no a los nuevos ("*the cold start problem"*). Este problema es un desafío común que enfrentan los diferentes sistemas de recomendación cuando se enfrentan a nuevos elementos para los cuales no tienen información histórica. Este problema ocurre cuando se agrega un nuevo elemento al set de datos y, por ende, el modelo no tiene suficiente información sobre las relaciones de los nuevos elementos para realizar recomendaciones personalizadas. Es por esto por lo que, los resultados y conclusiones de esta investigación serían representativos para la base de datos actual y no las futuras.

3.2 Selección de datos

Respecto a la base de datos original (ver detalle de la base en punto 3.1), se debe tener en cuenta que, de la totalidad de las órdenes de compra, solo se toman en cuenta cien mil canastas de compra con la finalidad de otorgar mayor simpleza a la capacidad computacional de la investigación. Adicionalmente, cada producto pertenece a una categoría (pasillo) y se eliminan aquellas órdenes de compra que no cumplan con el mínimo y máximo de categorías preestablecidas, es decir, no se consideran aquellas transacciones que contengan menos de dos y más de diez categorías por la razón mencionada anteriormente.

3.3 Transformación de los Datos

Originalmente el dataset se estructura con 8 columnas de variables, sin embargo, se eliminaron aquellas columnas que no entregan información relevante, y también para obtener mayor simpleza computacional.

Se eliminaron los pasillos duplicados, manteniendo solo el primero de cada orden. Después se genera un conteo de la cantidad de pasillos que tiene el carro, y se eliminan aquellos que tienen menos de dos y más de diez categorías.

Finalmente, los valores nulos se cambiaron por valores booleanos (False), este cambio se genera con el objetivo de generar una matriz nueva donde se haga el conteo de valores que cumplen o no con cierto criterio.

Para lograr que el algoritmo obtenga información, antes de aplicar el modelo, se divide el set de datos aleatoriamente en un set de entrenamiento (Train set) y uno de testeo (Test set). La división de la base de datos se hace en razón 70-30, donde el 70% de la base de datos es de entrenamiento, mientras que el 30% restante corresponde al set de testeo.

Al set de entrenamiento se le aplica la técnica *Cross Validation*, esto con el objetivo de medir la robustez de los resultados, que el sistema genere conocimiento y aprenda a predecir la siguiente categoría. Por lo demás, se utiliza la técnica de *Cross Validation* para escoger el mejor set de hiperparámetros para cada modelo.

3.4 Data mining (Modelos)

La etapa de minería de datos del proceso KDD, es donde los sistemas de recomendación en los que se centra la investigación se programan para obtener resultados que posteriormente son objeto de análisis. Esta investigación se centra en cuatro sistemas de recomendación, con el objetivo de determinar cuál tiene mejor desempeño en términos de predicción. Los modelos para programar analizar y comparar son los siguientes:

- Modelo de reglas de asociación (Algoritmo Apriori)
- Modelos secuenciales (Red Neuronal GRU4Rec)
- Heurísticas (Top k y Recomendación Aleatoria)

3.4.1 Modelo de Reglas de Asociación (Algoritmo Apriori)

En relación con las reglas de asociación simples, el algoritmo Apriori, fue mejorado por Agarwal y Srikant y plantea una serie de pasos a seguir de forma iterativa hasta determinar el conjunto de elementos más frecuentes de la base de datos. Este proceso tiene como finalidad operar con “Itemsets frecuentes”, basándose en los niveles mínimos de soporte y confianza que define el operador (min sup; min conf). Estos criterios determinan si un conjunto de elementos es materia de interés o no.

La principal ventaja de utilizar este algoritmo (Apriori), es que pertenece a las reglas de asociación simples, por lo que se transforma en mecanismo fácil de entender. Es un método eficiente, dado que escanea la base de datos solo una vez y reduce considerablemente el tamaño de los conjuntos proporcionando un buen rendimiento. Además, los pasos de unión o eliminación de ítems son compatibles con grandes cantidades de elementos (Datos), por lo que se puede implementar en la base de datos del estudio.

Entre las desventajas, se encuentra el requerimiento de un alto grado de cálculo si los conjuntos de elementos son muy grandes y el soporte se mantiene muy bajo.

Cálculo de Reglas de Asociación:

Las reglas de asociación generadas y utilizadas tienen como finalidad descubrir hechos que coocurren y que dichas relaciones están implícitamente en los datos. Esto sirve para generar conocimiento respecto a hechos que ocurrieron en el pasado y así influir en acciones futuras. Para esto se utilizó la librería MLxtend, que contiene herramientas para ciencia de datos, entre ellas la generación de las Reglas de Asociación.

En otras palabras, las reglas de asociación siguen patrones establecidos de la forma: Antecedente → Consecuente. En donde, dado una serie de productos que se llevan en conjunto denominados itemset frecuentes, se establecen reglas de

asociación para ofertar productos (consecuentes) que tienen relación con ese conjunto de ítems (antecedentes).

3.4.1.1 Hiperparámetros del Modelo de Reglas de Asociación

Como se mencionó anteriormente, una de las métricas para evaluar calidad y fuerza tanto de un itemset como de una regla de asociación es el Support. Esta métrica mide la frecuencia relativa o importancia de un itemset determinado, es decir, la probabilidad de ocurrencia de ese itemset (Ver punto 3.4.1). Se denomina itemset frecuente cuando el valor mínimo de Support satisface/alcanza el umbral mínimo definido por el usuario del sistema para este criterio. El valor de esta métrica ayuda a identificar series de datos que se llevan en conjunto (itemset frecuentes) y que posteriormente se utilizan en la generación de reglas de asociación.

Medidas de Confianza:

Para evaluar la calidad de un itemset y la fuerza de la regla de asociación producida tenemos 5 medidas de confianza, estas son: Support - Confidence – Lift- Leverage - Conviction.

3.4.1.1.1 Support

Indica la frecuencia con la que los artículos aparecen en los datos. Se entiende como la frecuencia relativa de un producto la cantidad de veces que aparece dentro del total de transacciones. Se calcula dividiendo el número de transacciones que contienen un artículo determinado entre el total de transacciones. Quedando de la siguiente manera. La fórmula de la métrica Support se muestra en la ecuación (1).

$$Support = \frac{Número\ de\ Veces\ que\ ocurre\ el\ Antecedente}{Número\ total\ de\ transacciones} \quad (1)$$

3.4.1.1.2 Confidence

Es una métrica de confianza, que mide la ocurrencia de un itemset consecuente dado que ocurrió un itemset en el antecedente. El objetivo es determinar, de la totalidad de transacciones que tienen un consecuente determinado, cuántas de ellas tienen también un antecedente determinado. Para esta métrica hay que tener en cuenta que no siempre un alto nivel de Confidence es bueno en una asociación de productos, puesto que existen valores de Confidence altos en productos que tienen asociaciones débiles. Esta medida, se refiere a la probabilidad de que un consecuente se compre también una vez que se compra el antecedente. Su valor se obtiene al encontrar el número de transacciones en las que antecedente y consecuente se compran juntos, dividido entre el total de transacciones en las que se compra solo el antecedente (2).

$$Confidence = \frac{Número\ de\ veces\ que\ se\ produce\ antecedente\ y\ consecuente\ en\ conjuntos}{Número\ de\ veces\ que\ antecedente\ solo} \quad (2)$$

3.4.1.1.3 Lift

Esta medida de confianza determina qué tan frecuente el antecedente y consecuente de una regla de asociación ocurren juntos más veces de lo que se esperaría que ocurran si es que fueran independientes. O sea, muestra el beneficio que un antecedente determinado otorga a nuestra métrica Confidence por tener un cierto consecuente. En otras palabras, Lift indica la proporción del Support informado por sobre el esperado si es que ambas fueran independientes. Muestra la diferencia en la probabilidad de que un consecuente se compre una vez que se compra el antecedente versus la probabilidad de que el consecuente se compre de manera independiente. Esta métrica se obtiene dividiendo la confianza del antecedente y consecuente entre el Support (3).

$$Lift = \frac{Confianza\ de\ antecedente\ y\ consecuente\ en\ conjuntos}{Soporte} \quad (3)$$

3.4.1.1.4 Leverage

Es una medida de confianza, que indica la diferencia entre la frecuencia observada de una regla de asociación y la frecuencia esperada si los antecedentes y consecuentes fueran independientes. Un valor positivo de Leverage indica que la regla ocurre con más frecuencia de lo esperado, mientras que un valor negativo indica lo contrario (4).

$$Leverage = soporte\ de\ (A\ y\ C)\ en\ conjunto - soporte\ de\ (A) * soporte\ de\ (C) \quad (4)$$

Donde: A = Antecedente; C= Consecuente

3.4.1.1.5 Conviction

Es una medida de confianza, que se utiliza para medir la fuerza de la implicación entre dos elementos en una regla de asociación. Es una medida que evalúa cuánto se debe incrementar la probabilidad del consecuente (o resultado) dado el antecedente si se elimina la relación causal entre ambas. Un valor de Conviction de 1 indica que el antecedente y el consecuente son independientes, mientras que un valor mayor que 1 indica una mayor dependencia entre ambas (5).

$$conviction = \frac{[1 - soporte\ de\ (C)]}{[1 - confianza\ de\ (A\ y\ C)\ en\ conjunto} \quad (5)$$

Donde: A = Antecedente; C= Consecuente

3.4.2 Modelos Secuenciales (Red Neuronal GRU4Rec)

Las redes neuronales recurrentes (RNN, por sus siglas en inglés), es un tipo de algoritmo que utiliza datos con la capacidad de obtener información de dependencias secuenciales y temporales.

Las RNN generalmente aumentan la arquitectura de red multicapa convencional con la adición de ciclos que conectan nodos adyacentes o pasos de tiempo. Estos ciclos

forman la memoria interna de la red que se utiliza para evaluar las propiedades del dato actual con respecto a los datos del pasado inmediato (Arana, 2021).

Es decir, reciben la información teniendo datos del pasado, estos datos conectan entre nodos receptores de una misma adición formando la memoria interna misma de la red, para que al final genere la predicción o recomendación del siguiente dato. Chui et al (2021), definen de mejor forma el funcionamiento típico de una red recurrente que se explica en la capa oculta definida como h. Para efectos de esta investigación, la capa oculta recibe las entradas, donde h_{t-1} Es el estado anterior de la capa oculta, es decir, la historia de los productos. Las RNN estándar actualizan su estado oculto h mediante la siguiente función de actualización (6):

$$h_t = \sigma(Wx_{iht} + Wh_{t-1} + b_h) \quad (6)$$

Donde:

h_t = Estado actual de la capa oculta;

σ = Función de activación de la capa oculta;

h_{t-1}= Estado anterior de la capa oculta;

W = Matriz de pesos entre la capa de entrada con la capa oculta;

b_h = Vector de sesgo de la capa;

x_t= es la entrada de la unidad en el tiempo t ;

t = tiempo.

Una red neuronal recurrente genera una distribución de probabilidad sobre el siguiente elemento de la secuencia, dado su estado actual h_t .

Las ventajas de utilizar las redes neuronales recurrentes son:

En primer lugar, son capaces de capturar y modelar dependencias temporales y secuenciales en los datos, esto significa que tienen en cuenta sucesos que

ocurrieron anteriormente en los datos de compra y además el orden en que los productos son seleccionados, esto permite capturar patrones de compra.

En segundo lugar, este modelo tiene una estructura que permite tener una memoria a largo plazo, esta memoria puede ser útil para recordar y utilizar la información de compras anteriores para predecir la siguiente categoría a ingresar a la canasta.

En tercer lugar, es un modelo flexible y se adapta a diferentes patrones de compra, a medida que la red se entrena con datos históricos, puede aprender patrones de compra más complejos, es decir, capta relaciones no lineales entre los productos y descubre patrones que pueden no ser evidentes.

Las desventajas de las redes neuronales recurrentes, por una parte, es que no son capaces de aprender cuando se trata de secuencias de tiempos prolongados dada la gran información de entrada y salida que la redes forman en la memoria interna de la propia red (*short-term memory problem*). Por otra parte, y tal como menciona Phi (2018), las redes sufren de memoria a corto plazo, es decir, si una secuencia es lo suficientemente larga, tendrán dificultades para llevar información de pasos de tiempo anteriores a los posteriores. Entonces, pueden dejar de lado información importante desde el principio. Estas desventajas se deben a un problema mayor llamado *vanishing gradient problem*, es decir, a la dificultad en el entrenamiento de este tipo de redes debido a la desaparición o reducción del gradiente a través de las capas de la red. Puede ser causada por la función de activación, el número de capas en la red, el tamaño del lote y otros factores (hiperparámetros).

Dado lo anterior nace el modelo GRU (Cho et al., 2014), que es un modelo más elaborado de una unidad recurrente que tiene como objetivo lidiar con el *vanishing gradient problem*. Las puertas GRU esencialmente aprenden cuándo y cuánto actualizar el estado oculto de la unidad, deshaciéndose del estado de celda y usando el oculto para transferir información. En la **Figura 3** se explica el diagrama conceptual del algoritmo GRU.

La activación de la GRU es una interpolación lineal entre la activación anterior h_t(7) y la activación candidata $\widehat{h_t}$ (9):

$$h_t = (1 - u_t)\, h_t - 1 + u_t\, \widehat{h_t} \tag{7}$$

Donde la puerta de actualización u_t viene dada por:

$$u_t \;=\; \sigma_u(W_u x_t\, [\, h_{t-1}\, , x_t\,]) \tag{8}$$

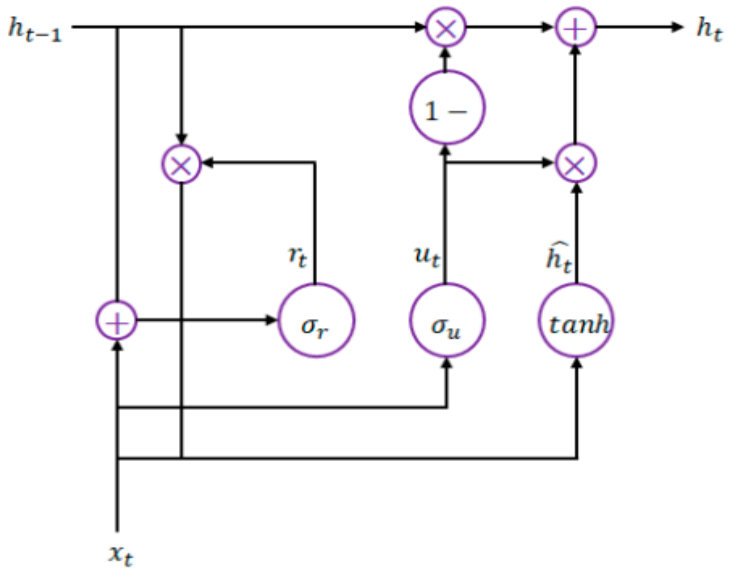
Mientras que la función de activación candidata $\widehat{h_t}$ se calcula de manera similar:

$$\widehat{h_t} \;=\; tanh\,(Wx_t + \,[rt\, \odot h_{t-1}, x_t\,]) \tag{9}$$

Y finalmente la puerta de reinicio r_t viene dada por (10):

$$r_t \;=\; \sigma_r(W_r\; [\, h_{t-1}\, , x_t\,]) \tag{10}$$

Figura 3: *Diagrama conceptual del algoritmo gated recurrent unit (GRU)*



Fuente: Adaptado por Chui, et al (2021).

3.4.2.1 Hiperparámetros del Modelo Secuencial (GRU4Rec)

A continuación, para evaluar el rendimiento de las redes neuronales mencionadas anteriormente aplicamos diferentes hiperparámetros.

3.4.2.1.1 Función de pérdida (loss function)

La función de pérdida, también conocida como función de costo, es una medida que cuantifica la discrepancia entre las predicciones realizadas por el modelo y los valores reales del conjunto de datos durante el entrenamiento de una red neuronal. En el contexto de GRU4Rec, una arquitectura diseñada para la recomendación de secuencias basada en sesiones, se utiliza una función de pérdida específica para este tipo de tareas. En GRU4Rec, una función de pérdida comúnmente utilizada es la pérdida de entropía cruzada (cross-entropy loss). Esta función de pérdida se emplea en problemas de clasificación y evaluación de modelos de recomendación. La pérdida de entropía cruzada mide la diferencia entre la distribución de probabilidad predicha por el modelo y la distribución de probabilidad real de los datos. Específicamente en GRU4Rec, la pérdida de entropía cruzada se utiliza para medir la discrepancia entre las recomendaciones generadas por el modelo y los elementos reales de la secuencia objetivo. (Hidasi, 2016).

En otras palabras, de acuerdo con lo planteado por el autor anteriormente, se entiende que la función de pérdida es un hiperparámetro que se utiliza para analizar el desempeño del modelo en términos de medir la diferencia entre los valores obtenidos en las predicciones y los valores reales. Además, para el tipo de red neuronal se utiliza la función de pérdida de entropía cruzada, que compara la salida predicha del modelo con la etiqueta verdadera de los datos de entrenamiento. Esto tiene como finalidad cuantificar qué tan diferentes son las recomendaciones de los datos de entrenamiento del modelo de las recomendaciones reales

La pérdida de entropía cruzada es ampliamente utilizada en problemas de clasificación en la clase GRU4Rec como función de pérdida y puede expresarse matemáticamente de la siguiente manera:

$$Lec = -\sum_{i=1}^{n} Y_i log(P_i) \quad (11)$$

Donde:

Y_i : Categoría efectivamente ingresada al carro.

P_i : Probabilidad predicha por el algoritmo de ingresar la categoría i a la canasta.

n: Número de clases, categorías.

3.4.2.1.2 Arquitectura de la Red (capa de embedding y dimensión de embedding [32], N° de capas ocultas GRU)

En la capa de embedding de GRU4Rec, cada elemento de la secuencia de entrada (por ejemplo, los ítems en una secuencia de interacciones del usuario) se representa mediante un vector de baja dimensión. La dimensión de embedding especifica el tamaño de estos vectores y afecta la capacidad de representación de la red. Un valor típico para la dimensión de embedding es 32, sin embargo, se debe tener en cuenta que este valor puede variar según el dominio de aplicación y el tamaño del conjunto de datos. El número de capas ocultas GRU determina la profundidad y capacidad para aprender representaciones de alto nivel en los datos secuenciales, es común utilizar de 1 a 3 capas ocultas, aunque como se mencionó anteriormente la elección adecuada depende del tamaño y complejidad del conjunto de datos (Hidasi et al., 2015)

De acuerdo con lo planteado por el autor anteriormente, la arquitectura de la red GRU4Rec consta de varios componentes clave, incluyendo la capa de embedding y el número de capas ocultas GRU. Una “capa” se refiere a una neurona de procesamiento en una red neuronal. Cada capa de la red, incluyendo las capas de entrada y las capas ocultas, contiene un conjunto de neuronas de procesamiento. Por otro lado, dimensión de embedding se refiere a la longitud de los vectores de representación asignados a cada elemento de entrada

La capa de entrada es la que recibe los datos iniciales, que suelen ser secuencias de eventos o sucesos. Cada uno de los elementos de la secuencia se representa mediante una codificación del estilo *one hot encoding* que crea un vector que indica la presencia del elemento correspondiente en la secuencia. Por otro lado, la dimensión de embedding se refiere a la longitud de estos vectores de representación asignados a los elementos de entrada, es decir, la cantidad de números que se utilizan para representar a cada elemento.

3.4.2.1.3 Optimizador (Adagrad)

La función principal del algoritmo optimizador de la red neuronal es ajustar los pesos y los sesgos de la red para minimizar la función de pérdida, esto implica encontrar valores óptimos de los parámetros que permitan que la red neuronal haga predicciones precisas.

El algoritmo de Adagrad utiliza un mecanismo de acumulación de gradientes al cuadrado para actualizar las tasas de aprendizaje. Los gradientes se acumulan en un vector acumulativo a lo largo del tiempo y se utilizan para escalar las actualizaciones de los parámetros. A medida que los gradientes de un parámetro específico continúan acumulándose, la tasa de aprendizaje para ese parámetro disminuye, lo que permite actualizaciones más pequeñas a medida que el entrenamiento progresa. En lugar de utilizar una tasa de aprendizaje global constante para todos los parámetros, Adagrad asigna una tasa de aprendizaje más alta a los parámetros que tienen gradientes pequeños y una tasa de aprendizaje más baja a los parámetros con gradientes grandes. Esto permite que los parámetros con gradientes más grandes tengan actualizaciones más pequeñas, evitando así que el proceso de entrenamiento se vuelva inestable debido a actualizaciones excesivas. En esencia, adapta automáticamente la tasa de aprendizaje a las características de los datos y los parámetros específicos. (Duchi et al., 2015)

En otras palabras, de acuerdo con lo planteado anteriormente por los autores, el algoritmo Adagrad ha demostrado ser eficaz en problemas donde los datos tienen características dispersas o raras, ya que puede adaptarse a diferentes escalas de

gradientes y proporcionar actualizaciones más precisas para los parámetros relevantes. Esto permite un ajuste adaptativo de la tasa de aprendizaje para los parámetros en función de su comportamiento previo. El optimizador Adagrad es ampliamente utilizado en problemas de optimización de redes neuronales y puede expresarse matemáticamente de la siguiente manera:

$$_{\theta}(t+1) = \theta(t) - \left(\frac{\eta}{\sqrt{(G(t)+\varepsilon)}}\right) * \Delta\theta(t) \quad (12)$$

Donde:

t = Paso de tiempo

η = Tasa de aprendizaje. Determina qué tan grande es el paso de actualización de los parámetros

θ (t) = Valor actual del parámetro en t

$G(t)$ = Suma acumulativa de gradientes cuadrados anteriores hasta t.

∇θ (t) = Gradiente del parámetro en t.

ε = Es una pequeña cantidad que se utiliza para evitar la división de cero

3.4.2.1.4 Épocas (epochs)

El concepto “epochs” se refiere al número de veces que se recorre todo el conjunto de datos durante el proceso de entrenamiento de la red neuronal. Cada vez que se completa un recorrido completo de los datos, se dice que se ha completado una época.

En el contexto de las redes neuronales, especialmente en el campo de la recomendación de secuencias, las épocas se refieren al número de veces que se entrena un modelo de red neuronal en todo el conjunto de datos disponible. Durante cada época, se pasa por todo el conjunto de datos de entrenamiento y se ajustan los pesos de la red neuronal en función de los errores cometidos durante la predicción. Los datos se presentan a la red neuronal en lotes o muestras, y los pesos se actualizan gradualmente a medida que la red aprende de estos ejemplos. (Hidasi et al., 2015).

La elección del número adecuado de épocas es un aspecto crucial al entrenar modelos de redes neuronales, ya que afecta tanto el tiempo de entrenamiento como el rendimiento del modelo. Si se utilizan muy pocas épocas, es probable que el modelo no haya tenido suficiente tiempo para aprender patrones en los datos y no pueda generalizar bien a nuevos ejemplos. Por otro lado, si se utilizan demasiadas épocas, existe el riesgo de sobreajuste, lo que significa que el modelo se ajusta demasiado a los datos de entrenamiento y tiene un rendimiento deficiente en datos no vistos. La determinación del número óptimo de épocas puede requerir experimentación y ajuste, dependiendo del conjunto de datos y la complejidad del problema. Algunos enfoques comunes para determinar el número adecuado de épocas incluyen el seguimiento de la pérdida en un conjunto de validación y detener el entrenamiento cuando la pérdida deja de disminuir significativamente o comienza a aumentar (Wu et al., 2017).

De acuerdo con lo planteado por los autores anteriormente, “epochs” determina la cantidad de veces que se recorre el conjunto de datos para entrenar a una red neuronal. La elección adecuada de este hiperparámetro es importante para obtener un modelo bien entrenado y generalizado. Adicionalmente la determinación óptima del número de épocas depende del conjunto de datos, la complejidad del problema y otros factores. Algunas estrategias comunes para determinar el número de épocas son: Monitorear rendimiento en conjunto de validación, Early Stopping y Validación cruzada.

3.4.2.1.5 Patience Early stopping

Patience Early stopping, también conocido como detención temprana basada en paciencia, es una técnica ampliamente utilizada en el entrenamiento de redes neuronales para evitar el sobreajuste y determinar el momento adecuado para detener el proceso de entrenamiento. Esta técnica implica monitorear el rendimiento del modelo en un conjunto de validación durante el entrenamiento y detenerlo cuando no se observa una mejora significativa después de un número predefinido de iteraciones consecutivas.

La paciencia (patience) se refiere al número de iteraciones consecutivas en las que no se observa una mejora en el rendimiento del modelo en el conjunto de validación antes de detener el entrenamiento. Por ejemplo, si se establece una paciencia de 5, el entrenamiento se detendrá si no hay mejoras en el rendimiento del modelo en las últimas 5 iteraciones.

La utilización de Patience Early stopping es esencial para evitar el sobreajuste, que ocurre cuando el modelo se adapta demasiado a los datos de entrenamiento y pierde la capacidad de generalizar correctamente a nuevos datos. Al detener el entrenamiento en el momento adecuado, se logra un equilibrio entre el rendimiento en el conjunto de entrenamiento y la capacidad de generalización del modelo.

La interrupción temprana es ampliamente utilizada porque es fácil de entender e implementar y se ha informado que es superior a los métodos de regularización en muchos casos. (Prechelt, 2002)

3.4.3 Heurísticas

Esta investigación, propone heurísticas tales como Top k y Aleatorio para poder generar benchmark y compararlo con los modelos de Reglas de Asociación y Modelos Secuenciales.

Las heurísticas de recomendación Top k y recomendación aleatoria son dos enfoques ampliamente utilizados en sistemas de recomendación basados en data mining. La heurística de recomendación Top k consiste en seleccionar los K elementos más relevantes para un usuario, mientras que la heurística de recomendación aleatoria selecciona elementos al azar de un conjunto de elementos relevantes.

Esta heurística ha sido ampliamente evaluada en la literatura científica. Por ejemplo, Zhang et al. (2016) realizaron una evaluación experimental de varios algoritmos de

recomendación Top k, y encontraron que estos algoritmos logran buenos resultados en términos de precisión. Sin embargo, la principal desventaja de la heurística de recomendación Top k es que a menudo no logra recomendar elementos nuevos o diferentes, lo que puede llevar a que los usuarios pierdan interés en el sistema de recomendación. Por lo tanto, es importante tener en cuenta que la heurística de recomendación Top k puede no ser adecuada para todos los casos de uso.

Por otro lado, la heurística de recomendación aleatoria puede ser una buena opción en situaciones en las que los datos son escasos o es difícil encontrar patrones claros en los datos. Este enfoque puede ser útil para proporcionar recomendaciones diversas y sorprendentes a los usuarios. Fouss et al. (2007), presentaron un modelo de random walk para la recomendación de elementos en sistemas de recomendación basados en grafos, y encontraron que este enfoque de recomendación aleatoria puede producir recomendaciones precisas y diversas. Sin embargo, la principal desventaja de la heurística de recomendación aleatoria es que puede producir recomendaciones irrelevantes o poco interesantes para el usuario, lo que puede llevar a una baja satisfacción del usuario. Por lo tanto, es importante tener en cuenta que la heurística de recomendación aleatoria debe utilizarse con cuidado y en combinación con otros enfoques de recomendación.

En conclusión, tanto la heurística de recomendación Top k como la heurística de recomendación Aleatoria tienen ventajas y desventajas que deben ser consideradas cuidadosamente en función de los objetivos específicos del sistema de recomendación y el contexto en el que se utiliza. Los autores Zhang et al. (2016) y Fouss et al. (2007) han realizado estudios empíricos que proporcionan evidencia de los resultados de estas heurísticas en sistemas de recomendación basados en data mining.

3.5 Técnicas de robustez

Para lograr que los modelos generen información, antes de aplicar el modelo, se divide el set de datos entre un set de entrenamiento (Train set) y uno de testeo (Test

set). La división de la base de datos se hace en razón 70-30, donde el 70% de la base de datos es de entrenamiento, mientras que el 30% restante corresponde al set de testeo. Al set de entrenamiento se le aplica la técnica Cross Validation, esto con el objetivo de medir la robustez de los datos, que el sistema genere conocimiento y aprenda a predecir la categoría que escoge un cliente.

Cuando entrenamos un modelo de Machine learning siempre se tiene un set de entrenamiento con cual vamos a ajustar el modelo y un set de testeo en el cual evaluamos el modelo con información que no ha visto. Para este caso, el cross validation funciona realizando iteraciones para que el set de entrenamiento de datos aprenda del modelo y en el set de testeo evaluemos la cantidad de “hit” o aciertos que se tiene. Mientras más hit se tiene, mejor evaluado está el modelo.

La técnica de validación cruzada se ha utilizado ampliamente en el desarrollo y evaluación de modelos de recomendación. Zhou, Lu, Zhang, y Sun (2018) y Kucuk y Ozkan (2020) destacan varias razones por las que la validación cruzada es una técnica importante en la evaluación del rendimiento de los modelos de recomendación. En primer lugar, la validación cruzada puede ayudar a evitar el sobreajuste de los modelos de recomendación, mejorando la capacidad de generalización del modelo en nuevos datos. En segundo lugar, al evaluar el rendimiento del modelo en múltiples iteraciones de entrenamiento-prueba, se puede obtener una estimación más acertada de la precisión del modelo, especialmente en el caso de conjuntos de datos pequeños. Finalmente, la validación cruzada puede ayudar a seleccionar el mejor modelo al comparar el rendimiento de diferentes algoritmos o configuraciones de modelos de recomendación.

Sin embargo, también existen algunas limitaciones en el uso de la validación cruzada. En primer lugar, la validación cruzada puede ser computacionalmente costosa en conjuntos de datos grandes o con modelos de recomendación complejos. En segundo lugar, aunque la validación cruzada puede ayudar a evitar el sobreajuste, no puede garantizar completamente la eliminación del sesgo en los

datos. Por último, la selección de hiperparámetros es un proceso crucial en el desarrollo de modelos de recomendación, y la validación cruzada puede ser vulnerable a la selección de hiperparámetros que estén sobre ajustados a los datos de entrenamiento y no generalicen bien a nuevos datos de prueba.

3.6 Métricas de desempeño

En lo que respecta al desempeño de los Sistemas de Recomendación podemos encontrar las siguientes métricas para determinar que tan bien lo están haciendo las recomendaciones establecidas de los cuatro modelos para los distintos carros de compra:

- Hit-Rate: Esta métrica muestra el grado de acierto que tienen las recomendaciones que genera el sistema de recomendación. En otras palabras, muestra cuantas recomendaciones acertaron respecto al total de recomendaciones generadas al Dataset (Hicieron un Hit; La recomendación acertó y el ítem es añadido al carro). Esta métrica se obtiene dividiendo el Número de aciertos entre el total de recomendaciones (13).

$$Hit\ Rate\ = \frac{Número\ de\ aciertos}{Recomendaciones\ Totales} \tag{13}$$

- Mean Reciprocal Hit-Rate: Esta métrica muestra, respecto a las recomendaciones generadas al Dataset en qué lugar/posición se encuentra el Hit. Es decir, si acertó en la primera recomendación, en la segunda o en la tercera y así sucesivamente (14).

$$Mrhr\ = \frac{1}{|Q|} * \sum_{i\,=\,1}^{|Q|} \frac{1}{Ranking\ i} \tag{14}$$

Donde Q: Número de recomendaciones al Dataset.

Ranking i: Posición en que se hizo el hit en cada recomendación

- Coverage: Esta es una métrica con orientación en el área de negocios de una compañía. Muestra cuántas categorías (pasillos) está utilizando el sistema de recomendación respecto del total de categorías disponibles en la tienda. Este valor se obtiene dividiendo cuántas categorías se utilizaron en la recomendación entre el total de categorías de la tienda (15).

$$Coverage = \frac{Cantidad\ de\ categorías\ Utilizadas}{Total\ de\ Categorías} \quad (15)$$

Las métricas de desempeño son importantes en los sistemas de recomendación porque proporcionan una manera de evaluar la efectividad y la utilidad de los modelos. El hit rate, el mean reciprocal hit rate y la cobertura (Coverage) son métricas comunes utilizadas en la evaluación de sistemas de recomendación.

Estas métricas permiten evaluar el rendimiento y efectividad del sistema de recomendación, lo que es vital para permitir su mejora continua y garantizar que sea útil y relevante para los usuarios reales. (Zhang et al., 2014)

3.7 Diferencia de medias

Para determinar la significancia de las métricas de desempeño entre los diferentes modelos, emplearemos el test t de Student de una cola. Esta elección se basa en su amplio uso en la literatura y su reconocimiento como un método robusto para evaluar si las diferencias en los resultados son estadísticamente significativas o no. En este estudio, realizamos pruebas unilaterales de diferencia de medias en el hit rate y el mean reciprocal hit rate. Utilizamos niveles de significancia de 0,05, 0,01 y 0,001 en el valor p para evaluar la relación entre las reglas de asociación y sus respectivos benchmarks.

4. Resultados

La hipótesis planteada en esta investigación propone que el modelo basado en las reglas de asociación simples (algoritmo Apriori) tiene una mejor performance en términos de predicción que las recomendaciones heurísticas (Top k y Aleatorio) y modelos secuenciales (Redes neuronales secuenciales GRU4Rec).

A continuación, se comparan los resultados de los modelos para dar respuesta a la hipótesis. Para compararlos, se utilizaron distintas métricas comunes de evaluación de sistemas de recomendación (Ver punto 3.6), las cuales son:

- Hit rate
- Mean reciprocal hit rate.
- Coverage

Cabe recalcar que para cada modelo se realizaron las recomendaciones en la base de datos de entrenamiento y testeo con el fin de dar cuenta si los modelos estaban sobreentrenados o no, esto se puede observar en la baja diferencia de los resultados entre la base de datos de entrenamiento y testeo.

En la **Tabla 3, Tabla 4 y Tabla 5** se encuentra detallado los resultados que se mencionan en los siguientes puntos.

Tabla 3*: Resultados Heurísticas*

		Métricas de desempeño		
Heurísticas	**Dataset**	**Hit rate**	**Mean reciprocal Hit rate**	**Coverage**
Top K	Test	0.2484	0.1921	0.0820
	Train	0.2512	0.1951	0.0821
	Validation	0.2511	0.1949	0.0821
Aleatorio	Test	0.0066	0.0042	0.6194
	Train	0.0231	0.0141	1.0000
	Validation	0.0233	0.0143	1.0000

Nota: Esta tabla muestra los resultados de las heurísticas

-Tipo de recomendación: Representan el modelo de la investigación

-Dataset: Representa la base de datos de entrenamiento que se divide en testeo y validación y la base de datos de testeo

-Hit Rate: Métrica de desempeño que mide cuantas veces acertó en la predicción

-Mean reciprocal hit rate: Métrica de desempeño que mide la calidad de la recomendación

-Coverage: Métrica de desempeño que muestra ratio de pasillos recomendados

Fuente: Elaboración propia

Por el lado de las Heurísticas mencionadas en la investigación da cuenta, como se puede apreciar en la tabla, en el Modelo Aleatorio, donde se recomiendan ítems aleatoriamente, el Hit Rate dio como resultado 0.0066. En mean reciprocal hit rate el resultado fue de 0.0042, lo que indica que acertó muy pocas veces en la recomendación. En cuanto al coverage da un resultado de 0.6194, lo que indica que es altamente variado en cuanto a ítems recomendados, ahora bien, este modelo se ocupa como benchmark respecto a los modelos de reglas de asociación y modelos secuenciales.

En el modelo de Top k, donde las recomendaciones se hicieron dado los ítems más recurrentes de la base de datos, el hit rate dio como resultado 0.2484. En mean reciprocal hit rate el resultado fue de 0.1921, lo que indica que acertó el 24,8% de las recomendaciones realizadas. En cuanto al coverage da un resultado de 0.0082,

lo que indica que es muy poco variado en cuanto a las recomendaciones realizadas, esto se explica porque sólo recomienda los ítems más recurrentes de la base de datos. Estos resultados dan cuenta que es mucho mejor que el modelo aleatorio, generando un nuevo benchmark para los siguientes modelos a testear.

Tabla 4*: Resultados reglas de asociación*

	Hiperparámetros				Métricas de desempeño		
Dataset	**Rules Qty**	**Apriori Metric**	**Sort by Metric**	**Min Support**	**Hit rate**	**Mean reciprocal Hit rate**	**Coverage**
Train	14960	Lift	Conviction	0.003	0.2583	0.1982	0.4701
Validation	14910	Lift	Conviction	0.003	0.2615	0.1968	0.4701
Test	14948	Lift	Conviction	0.003	0.2564	0.1953	0.3731

Nota: Esta tabla muestra los resultados del modelo reglas de asociación.

- Rules Qty: Muestra la cantidad de reglas de asociación que genera el modelo

Fuente: Elaboración propia

En el modelo de reglas de asociación se hicieron 45 combinaciones posibles para determinar qué hiperparámetros son los que mejor resultado tienen. Estas combinaciones están dadas por todos los hiperparámetros del Apriori Metric, los cuales son *"Confidence"," Lift"," Conviction"*, los hiperparámetros de él Sort by Metric, los cuales son *"Support", "Confidence"," Lift"," Leverage"," Conviction"* y diferentes niveles de soporte (min sup) con los siguientes valores "*0.009", "0.006", "0.003"*. Logrando así generar entre 100 y 15000 reglas de asociación aproximadamente.

Los hiperparámetros que mejor nos dieron resultados son:

En Apriori Metric, el Lift. En Sort by Metric (Métrica maximizada en la recomendación), fue Conviction. En min Sup, fue un 0.003, generando 14948 reglas de asociación.

En cuanto a las métricas de desempeño de las reglas de asociación, el hit rate dio un 0.2564 superando los modelos benchmark generado con el modelo aleatorio y el modelo Top k. El mean reciprocal hit rate nos dio un resultado de 0.1953, lo cual es mayor que los Benchmark, pero no por mucho, esto se explica por el bajo acierto de las recomendaciones, es decir, si bien es mejor que el benchmark, sigue siendo bajo. Por otro lado, en cuanto al coverage da un resultado de 0.3731 lo que da cuenta que si bien en cuanto a hit rate y mean reciprocal hit rate está bastante cerca del Top k, es mucho más variado a la hora de realizar recomendaciones, es decir, es más personalizado.

Es importante tener en cuenta que el desempeño de estos modelos puede variar según la base de datos y los hiperparámetros seleccionados. En este caso, se encontró que el Lift fue la mejor métrica de Apriori Metric, mientras que Conviction fue la mejor métrica para Sort by Metric. Además, el min sup se fijó en 0.003 y se generaron alrededor de 15000 reglas asociadas.

Con respecto a los modelos secuenciales (MS), en la **Tabla 5** se presenta un resumen de los resultados obtenidos.

Tabla 5*: Resultados modelo secuencial*

Dataset	Hiperparámetros				Métricas de desempeño		
	Epochs	Loss function	Patience	Embedding dim.	Hit rate	Mean reciprocal Hit rate	Coverage
Train	100	cross-entropy loss	5	16	0.1261	0.0905	1
Test	100	cross-entropy loss	5	16	0.0946	0.0657	0.9925

Nota: Esta tabla muestra los resultados del modelo secuencial

-Embedding dim: Hiperparámetro que especifica el tamaño de la nueva representación vectorial de los pasillos

Fuente: Elaboración propia

A continuación, se muestra la estructura del modelo de Redes neuronales GRU4Rec, utilizada para la programación la red neuronal:

En primer lugar, se encuentra la capa de entrada (input layer), donde se ocupa la capa stringlookup la cual se encarga de definir el diccionario de la red. En segundo lugar, se encuentra la capa de embedding, la cual define la dimensión del vector (en este caso 16). En tercer lugar, están las capas ocultas, donde se generan 3 capas GRU. Si bien Tensor Flow, que es la biblioteca de códigos para el aprendizaje automático y redes neuronales recomiendan utilizar 1 capa GRU, en esta investigación se ocupan 3, dado que con solo una capa GRU el modelo presentaba sobre entrenamiento. Finalmente, en la capa de salida se vuelve a ocupar la capa stringlookup para traducir lo aprendido en las capas GRU y la capa embedding para observar el vector de salida, y de esta forma recomendar dependiendo del basket.

Los hiperparámetros utilizados para el modelo de Red Neuronal son:

La tasa de aprendizaje es posiblemente el hiperparámetro más importante. En general, la tasa de aprendizaje óptima es aproximadamente la mitad de la tasa de aprendizaje máxima. Un enfoque simple para ajustar la tasa de aprendizaje es comenzar con un gran valor que hace que el algoritmo de entrenamiento diverja, luego divida este valor por 3 e inténtelo de nuevo, y repita hasta que el algoritmo de entrenamiento deje de divergir. En ese momento, usted generalmente no estará muy lejos de la tasa de aprendizaje óptima. Dicho esto, a veces es útil para reducir la tasa de aprendizaje durante la capacitación. El tamaño del lote también puede tener un impacto significativo en el rendimiento de su modelo y el tiempo de entrenamiento. En general, el tamaño óptimo del lote será inferior a 32 (Gerón, 2019)

De acuerdo con lo que plantea el autor anteriormente, el hiperparámetro learning rate determina la magnitud en la que se ajustan los pesos de la red al momento de entrenarse, Si el learning rate es muy alto los pesos de la red cambiarán mucho en cada época de aprendizaje (epochs). Por otro lado, un learning rate muy pequeño asegura encontrar el óptimo de la función de costo, sin embargo, deberán paras muchas épocas (iteraciones) para encontrarlo, es decir, se demorará mucho más en entrenarse. Un learning rate óptimo encontrará rápidamente el mínimo de la función de costo (Set de pesos óptimo-asociados a cada neurona). Para esta investigación el learning rate es de 0.1

Adicionalmente, si bien el autor plantea que en general el óptimo del tamaño del lote óptimo es inferior a 32, el tamaño del lote afectará a cuánto demora la red en entrenarse. En este caso, solo afectará al tiempo de entrenamiento, porque dado el hiperparámetro patience (cuantas épocas que espera sin mejora en la función de costo la red para detener el entrenamiento). En otras palabras, en esta investigación el tamaño del lote (batch size) tendrá poca incidencia en el rendimiento del modelo. En esta investigación se utilizó un batch de 128.

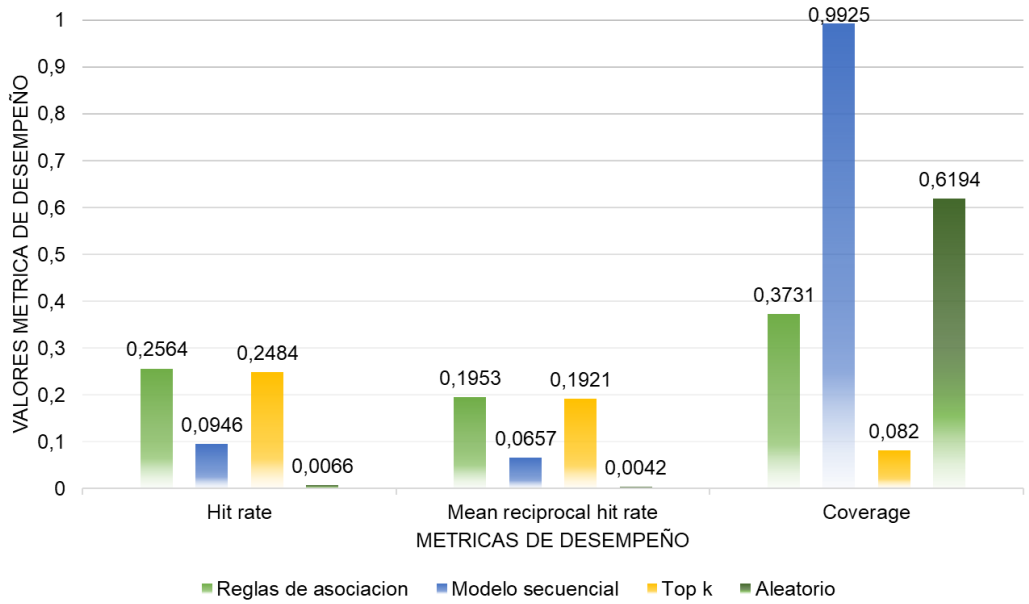
En cuanto a las métricas de desempeño del modelo secuencial (GRU4Rec), el hit rate dio un 0.0946, observando que el modelo está ligeramente sobre ajustado (Hit rate de entrenamiento 0.1261), pero aun así superando el benchmark generado con el modelo Aleatorio, sin embargo, no supera el benchmark del modelo Top k. El mean reciprocal hit rate dio un resultado de 0.0657.

Por último, en cuanto al coverage da un resultado de 0,9925 lo que es bastante interesante, esto se explica porque al momento de realizar recomendaciones el modelo aprende de patrones de orden de ingreso al carro que pareciera ser aleatorios, siendo indiferente a la frecuencia de los ítems en la base de datos.

Es importante destacar que, para la programación de este modelo, se utilizaron los hiperparámetros de referencia, recomendados por TensorFlow (biblioteca de códigos para el aprendizaje automático y redes neuronales).

A continuación, se presenta en la **Figura 4** un gráfico con el resumen de los resultados de las métricas por modelo de recomendación.

Figura 4: *"Resultados métricas de desempeño por modelo"*



Fuente: Elaboración propia

4.1 Análisis estadístico de los resultados

Para robustecer los resultados se realizó un test estadístico de diferencia de medias entre las reglas de asociación y sus respectivos benchmark (Modelo secuencial, Top k y Aleatorio) en cuanto al desempeño de hit rate y mean reciprocal hit rate.

Las pruebas de hipótesis que se evalúan son las siguientes:

$$H_{01}: Hr_{Reglas\ de\ asociación} \leq Hr_{Modelo\ secuencial}$$

$$H_{02}: Hr_{Reglas\ de\ asociación} \leq Hr_{Top\ k}$$

$$H_{03}: Hr_{Reglas\ de\ asociación} \leq Hr_{Aleatorio}$$

$$H_{04}: Mrhr_{Reglas\ de\ asociación} \leq Mrhr_{Modelo\ secuencial}$$

$$H_{05}: Mrhr_{Reglas\ de\ asociación} \leq Mrhr_{Top\ k}$$

$$H_{06}: Mrhr_{Reglas\ de\ asociación} \leq Mrhr_{Aleatorio}$$

Donde Hr = Hit rate; Mrhr = Mean reciprocal hit rate

Se establece como umbral de significancia un p value de 0.05 para rechazar las hipótesis nulas.

Tabla 6*: Test de diferencia de medias entre métricas de reglas de asociación contra benchmarks.*

Benchmark	Métricas	Reglas de asociación
Modelo secuencial	Hit rate	**53.3361***** (0.000)
	Mean reciprocal hit rate	**52.8886***** (0.0000)
Top k	Hit rate	**2.265*** (0.0118)
	Mean reciprocal hit rate	1.1176 (0.1319)
Aleatorio	Hit rate	**97.3928***** (0.0000)
	Mean reciprocal hit rate	**90.263***** (0.0000)

Nota: Esta tabla muestra los resultados obtenidos de la t de student de una cola entre reglas de asociación y los otros modelos

-p value entre paréntesis

-p value < 0.001 ***

-p value < 0.01 **

-p value < 0.05*

Fuente: Elaboración propia

Se rechazan las hipótesis nulas, para la comparación de hit rate entre reglas de asociación y los benchmark establecidos, por lo tanto, se concluye que las reglas de asociación tienen un mejor desempeño a nivel de hit rate que los benchmark Modelo secuencial (t-statistic:53.3361, p-value<0.0), Top k (t-statistic: 2.265, p-value<0.05), y Aleatorio (t-statistic: 97.3928, p-value<0.05). Dado que las diferencias son estadísticamente significativas en favor del modelo de reglas de asociación.

En tanto a nivel de mean reciprocal hit rate no existe evidencia estadística de un mejor desempeño de las reglas de asociación sobre el benchmark Top k, sin embargo, si comparamos el modelo reglas de asociación con el modelo aleatorio (t-statistic: 90.263, p-value<0.05) y el Modelo secuencial (t-statistic: 52.8886, p-value<0.0) si existe diferencia estadísticamente significativa.

4.2 Análisis económico de los resultados

Los sistemas de recomendación desempeñan un papel crucial en el comercio electrónico y los modelos de esta investigación han demostrado ser efectivos en el aumento de las ventas. Sin embargo, es necesario realizar un análisis económico para determinar qué modelo puede generar mayores ingresos y ser más rentable en términos de costos de implementación. Cabe destacar que tanto los ingresos como los costos son referente a los datos de la App de Instacart de EE. UU., es decir, que están evaluados en dólares y bajo el contexto de dicho país. Por ejemplo, los costos de mano de obra de implementación son en base a la remuneración de este último en EE. UU. También que este análisis se consideran datos mensuales, pero en la **Tabla 7** se muestran anualmente.

Por una parte, relacionado con los ingresos se obtuvieron tomando en cuenta:

- el precio promedio de cada pasillo de la aplicación que hizo *Hit* en base a la métrica de desempeño Hit rate.
- Un estimado según Similarweb (2023), señala que de 30.000.000 de visitas anuales que tiene Instacart solo 44% se queda en la App para generar una compra real.
- Tres escenarios, ingreso optimista (10%), moderado (5%) y pesimista (1%) del total de personas que quedan realizando una compra real.

Por otra parte, relacionado a los costos de implementación de los modelos se tomaron en cuenta:

- Los costos de la máquina que facilitó el procesamiento de los algoritmos de los 4 modelos con 30.000 recomendaciones corresponden a Vertex AI Training de USD $260 anuales, el servicio de nube almacenamiento tanto para las reglas de asociación como los modelos secuenciales de USD $4,856 anuales (Cloud SQL GCP) y servicio que conecta las predicciones con la App de USD $18,772 anuales (Cloud Run GCP), todas herramientas de Google.
- Según indeed (2023), un Data scientist y Data engineer de New York gana un salario promedio mensual de USD $9,014 y USD $9,073 respectivamente. Para las heurísticas (Top k y Aleatorio), por tratarse de heurísticas simples no se consideran los costos de Data scientist.

Tabla 7*: Análisis Económico*

	Tipo de Ingreso	Ingresos	Costo	Utilidad
Reglas de Asociación	Optimista	USD $13.358.115	USD $245.697	USD $13.112.419
	Moderado	USD $6.679.058	USD $245.697	USD $6.433.361
	Pesimista	USD $1.335.812	USD $245.697	USD $1.090.115
Aleatorio	Optimista	USD $726.505	USD $131.704	USD $594.800
	Moderado	USD $363.252	USD $131.704	USD $231.548
	Pesimista	USD $72.650	USD $131.704	USD -$59.054
Top K	Optimista	USD $11.795.300	USD $131.704	USD $11.663.596
	Moderado	USD $5.897.650	USD $131.704	USD $5.765.946
	Pesimista	USD $1.179.530	USD $131.704	USD $1.047.826
Modelos Secuenciales	Optimista	USD $5.596.391	USD $245.697	USD $5.350.694
	Moderado	USD $2.798.195	USD $245.697	USD $2.552.499
	Pesimista	USD $559.639	USD $245.697	USD $313.943

Fuente: Elaboración propia

Para este contexto (set de datos, mercado e industria) el modelo que presenta mejores ingresos consistentemente en los 3 escenarios (optimista, moderado y pesimista) es el de reglas de asociación, con utilidades sobre 80% de la venta incremental.

5. Limitaciones

La investigación se encuentra limitada por la base de datos utilizada, ya que los modelos y metodologías propuestos en la investigación están diseñados y optimizados exclusivamente para adaptarse a las características y estructura de dicha base de datos en particular. Por lo tanto, si se desea aplicar el sistema de recomendación a una base de datos diferente, se requerirán modificaciones sustanciales en los hiperparámetros para lograr una adaptación adecuada. Estas modificaciones implicarán la reconfiguración y recalibración de los modelos de reglas de asociación y modelos secuenciales.

La presente investigación dado su carácter fundamentalmente de negocio obvió la optimización y ajuste de la arquitectura y set de hiperparámetros de la red neuronal utilizada para modelar el enfoque secuencial. Por lo tanto, se deben considerar los resultados comparativos del modelo secuencial sólo bajo el contexto de la arquitectura y set de hiperparámetros detallados en el cuerpo de la investigación.

Asimismo, el sistema de recomendación está altamente condicionado por la disponibilidad de los elementos en la base de datos. En caso de que se añada un nuevo item al inventario, será necesario realizar ajustes en el sistema para considerar este elemento adicional (*"the cold start problem"*).

Otra limitación relevante es la falta de consideración de eventos estacionales o períodos específicos, como Navidad, Black Friday o días festivos, los cuales ejercen un impacto significativo en los patrones de compra y las preferencias de los usuarios en el ámbito del comercio electrónico. En consecuencia, el sistema de recomendación bajo el contexto descrito en esta investigación puede no ser capaz

de adaptarse adecuadamente a estos cambios estacionales, lo que compromete su consistencia durante tales períodos.

Es esencial tener presente estas limitaciones al implementar y utilizar el sistema de recomendación propuesto. Aunque ofrece valiosos beneficios para mejorar la precisión de las recomendaciones en el comercio electrónico, es crucial comprender y evaluar las restricciones mencionadas para tomar decisiones fundamentadas sobre su aplicación y considerar ajustes posibles en diversos contextos.

Para finalizar, se concluye que los resultados obtenidos en esta investigación comprueban el mejor desempeño de los modelos de reglas de asociación frente a modelos secuenciales y heurísticas básicas en términos de predicción del siguiente ítem a ingresar a la canasta. Las reglas de asociación podrían ser una alternativa más efectiva frente a los modelos secuenciales y heurísticas para la implementación de sistemas de recomendaciones, esto dado la capacidad de las reglas de asociación para detectar patrones y relaciones ocultas en los datos de compra en línea, lo que conduce a una mayor precisión y eficiencia en la recomendación de productos frente a las redes neuronales, que aprenden de manera más complejas esas relaciones y no están siendo efectivas en la recomendación del siguiente ítem a ingresar a la canasta.

6. Conclusiones

El propósito de esta investigación es estudiar el desempeño que tienen los sistemas de recomendación para predecir la categoría de productos que agrega a la canasta un consumidor al momento de la compra, y mostrar cómo impacta en el incremento al valor promedio de la canasta de comercio electrónico.

En este estudio se demuestra que si bien empresas chilenas, presentan distintas estrategias de marketing y tipos recomendación de productos al cliente, estas recomendaciones no se encuentran en la canasta de compra al agregar el producto, quedando atrás de las referentes mundialmente conocidas (ver **Tabla 1**).

Los sistemas de recomendación son una herramienta poderosa para las organizaciones dado que se centran en extraer información relevante sobre el comportamiento de compra del consumidor, ayudan a generar recomendaciones personalizadas para los clientes y encuentran relaciones entre los productos de la compañía. Al ofrecer productos que sean altamente probable que los clientes quieran adquirir, dada sus preferencias, estos sistemas aumentan la tasa de conversión de las ventas up-sell y cross-sell, el valor promedio de la canasta de compra electrónica, aumentan la fidelización del cliente dado la mejora de la experiencia de compra y aportan al negocio en términos económicos.

Para esta investigación se utilizó la base de datos de una aplicación de comercio electrónico estadounidense (*'Instacart'*), donde se implementaron cuatro modelos a ser comparados bajo métricas de desempeño.

Los resultados del estudio han demostrado que el sistema de recomendación basado en reglas de asociación tiene un mejor performance que los modelos de las Heurísticas (Top k y aleatorio) y los modelos secuenciales (GRU4Rec). Esto medido en términos de precisión y calidad de la recomendación por las métricas de desempeño (Hit- rate, Mean reciprocal Hit rate). Además, se realizó un análisis estadístico que muestra significancia en la diferencia de los resultados en las métricas de Hit-rate demostrando así que las Reglas de asociación tienen una performance significativamente mejor en cuanto a Hit rate contra todos los benchmark y mejor en cuanto Mean reciprocal Hit rate contra modelo secuencial y aleatorio. En términos de Coverage, el modelo aleatorio y secuencial presentan una clara superioridad con respecto a las reglas de asociación y heurística Top k.

Según el análisis económico, las reglas de asociación tienen mejor desempeño en relación con la venta incremental (Ingresos) que el resto de los modelos, alcanzando un beneficio extra de USD $1.090.115 en un escenario pesimista bajo los supuestos descritos en el cuerpo de esta investigación. ¿Pero, cuál sistema de recomendación es el más adecuado para la industria?, la respuesta depende de varios factores.

Según el análisis económico se muestra que las reglas de asociación generan mayores ingresos que otros modelos. Sin embargo, la elección del sistema de recomendación adecuado depende de la industria, el mercado, la métrica de desempeño, el tamaño de la empresa y el conjunto de datos. En algunos casos, empresas con recursos económicos limitados que deseen maximizar una métrica de desempeño específica, como el Coverage (hacer más conocidos sus productos), pueden optar por utilizar un sistema de recomendación aleatorio que, a diferencia del modelo secuencial, no requiere entrenamiento. Por otro lado, empresas de gran tamaño que manejan conjuntos de datos masivos (Big Data) podrían requerir modelos más complejos, como modelos secuenciales o reglas de asociación que aporten inteligencia en las recomendaciones. En conclusión, la elección del sistema de recomendación óptimo depende de una serie de factores y esta investigación abre la puerta a discusiones sobre cuál sistema se ajusta mejor a cada caso de negocio.

Las limitaciones identificadas en esta investigación se basan en la dependencia de la base de datos utilizada, la necesidad de ajustes en caso de la incorporación de nuevos elementos y la falta de consideración de eventos estacionales o períodos específicos. Estas limitaciones deben tenerse en cuenta al implementar el sistema de recomendación propuesto ya que, podrían requerir modificaciones y consideraciones adicionales para su adaptación en diferentes contextos.

Para futuras investigaciones una mejora del modelo de reglas de asociación podría ser setear un umbral de confianza de la regla de asociación (hiperparámetro *'Sort by Metric': 'Lift mínimo'*) a partir del cual se recomiende pasillos provenientes del modelo Apriori, es decir, si la regla no cumple el mínimo Lift recomendar según heurística Top k. Además, existe gran potencial de mejora en el rendimiento del modelo secuencial propuesto en esta investigación con una correcta optimización y ajuste de arquitectura e hiperparámetros.

Los resultados de esta investigación eran esperables dado que la literatura lo avala, un artículo científico publicado en la revista "Expert Systems with Applications" por los autores Cheng, Yang y Zhou en 2019, comparó el rendimiento de los modelos secuenciales y las reglas de asociación en la recomendación de productos. Los resultados mostraron que las reglas de asociación superaron a los modelos secuenciales en términos de precisión y eficiencia en la recomendación de artículos.

Además, un estudio publicado en la revista "Journal of Computational Science" por los autores Gaurav y Tanwar en 2020, examinó la capacidad de los modelos secuenciales y las reglas de asociación para predecir las compras de los clientes en línea. Los resultados demostraron que las reglas de asociación superaron significativamente a los modelos secuenciales en la performance de la recomendación.

Esta investigación proporciona información valiosa y relevante para las empresas insertas en el comercio electrónico, y específicamente para aquellas que quieren hacer la transición a plataformas digitales y necesitan saber qué sistema de recomendación de productos implementar en su compañía, que buscan mejorar la experiencia del usuario y aumentar los ingresos provenientes de las ventas electrónicas a través de recomendaciones personalizadas a los clientes.

En conclusión, cada sistema de recomendación analizado en esta investigación presenta costos y beneficios asociados. Esto es sumamente importante a la hora de escoger un modelo u otro y determinar cuál es mejor para la compañía. Todos se centran en mejorar la experiencia de compra del cliente, ofrecer productos de manera personalizada, pero se diferencian en su manera de trabajar, su eficiencia en los aciertos, sus costos, complejidad y beneficios.

7. Referencias

BlackSip. (2022). Reporte de industria: el Ecommerce en Chile 2021-2022.

Cheng, X., Yang, Y., & Zhou, W. (2019). A comparative study of sequential models and association rules for product recommendation. Expert Systems with Applications, 116, 194-207. https://doi.org/10.1016/j.eswa.2018.08.045

Cho, Kyunghyun, van Merrienboer, Bart, Bahdanau, Dzmitry, and Bengio, Yoshua. (2014) ¨On the proper ties of neural machine translation: Encoder-decoder approaches. arXiv preprint arXiv:1409.1259, 2014.

Chui, K.T.; Gupta, B.B.; Liu,R.W.; Zhang, X.; Vasant, P.; Thomas,J.J. (2021). Extended-Range Prediction ModelUsing NSGA-III OptimizedRNN-GRU-LSTM for Driver Stressand Drowsiness.https://doi.org/10.3390/s21196412.

De Trabajo, D., & Arana, C. (2021). REDES NEURONALES RECURRENTES: ANÁLISIS DE LOS MODELOS ESPECIALIZADOS EN DATOS SECUENCIALES. UNIVERSIDAD DEL CEMA Buenos Aires Argentina Serie. www.cema.edu.ar/publicaciones/doc_trabajo.html

Dehning, B., Richardson, V. J., Urbaczewski, A., & Wells, J. D. (2004). Reexamining the value relevance of E-Commerce initiatives. Journal of Management Information Systems, 21(1), 55–82. https://doi.org/10.1080/07421222.2004.11045788

Duchi, J., Hazan, E., & Singer, Y. (2011). Adaptive subgradient methods for online learning and stochastic optimization. Journal of Machine Learning Research, 12(7), 2121-2159.

Ester, M., Amaris, M., Enrique, J., & Rodríguez, R. (2003.). LA CONTRIBUCIÓN DE LAS REGLAS DE ASOCIACIÓN A LA MINERÍA DE DATOS.

Fouss, F., Pirotte, A., Renders, J. M., & Saerens, M. (2007). Random walks in recommender systems: exact computation and simulations. In Proceedings of the 2007 IEEE/WIC/ACM International Conference on Web Intelligence and Intelligent Agent Technology-Volume 01 (pp. 657-660). IEEE Computer Society.

Gaurav, S., & Tanwar, S. (2020). A comparative study of sequential models and association rules for predicting customer online purchases. Journal of Computational Science, 44, 101175. https://doi.org/10.1016/j.jocs.2020.101175

Hidasi, B., Karatzoglou, A., Baltrunas, L., & Tikk, D. (2015). Session-based recommendations with recurrent neural networks. arXiv preprint arXiv:1511.06939.

Hidasi, B., Karatzoglou, A., Baltrunas, L., & Tikk, D. (2015). Session-based Recommendations with Recurrent Neural Networks. En Proceedings of the International Conference on Learning Representations (ICLR). Recuperado de https://arxiv.org/abs/1511.06939.

Hidasi, J. (2016). Reinforcement learning for music recommendation. In Proceedings of the 10th ACM Conference on Recommender Systems (pp. 301-304). ACM.

Huang, Y., Chai, Y., Liu, Y., & Shen, J. (2019). Architecture of Next-Generation E-Commerce Platform (Vol. 24, Issue 1).

Instacart. (2022). Instacart Market Basket Analysis. Kaggle. Retrieved 2022, from https://www.kaggle.com/competitions/instacart-market-basket-analysis/overview

Kucuk, I., & Ozkan, I. (2020). A Comparative Analysis of Collaborative Filtering-Based Recommender Systems Using Cross-Validation. IEEE Access, 8, 195704-195716. doi: 10.1109/ACCESS.2020.3034540

Lan, W., Ma, Y., Zhao, J., Wang, H., & Tsai, C. L. (2018). Sequential model averaging for high dimensional linear regression models. Statistica Sinica, 28(1), 449–469. https://doi.org/10.5705/ss.202016.0122

Li, L., & Xiaoming, M. (2022). Study on the exploration of poverty index's association rules based on CBCM-Apriori algorithm. Annals of Operations Research. https://doi.org/10.1007/s10479-022-04607-5

Martínez, F.; Pernia, A.; Fernández, R.; Escribano, R.; Guillén, P.; Conti, D. (2009). "Proyecto CONOCER". Obtenido de http://api.unirioja.es/conoser.

Matich, DJ (2001) Redes Neuronales: Conceptos Básicos y Aplicaciones. [Redes Neuronales: Conceptos Básicos y Aplicaciones.] Universidad Tecnológica Nacional—Facultad Regional Rosario, Departamento de Ingeniería Química, Argentina.

Muñoz, A. (2021, February 18). *Cómo los sistemas de recomendación potencian las ventas | Sales Layer*. Sales Layer Blog. Retrieved April 9, 2023, Obtenido de https://blog.saleslayer.com/es/sistemas-recomendacion-ecommerce

Nasdaq. (2017) .UK Online Shopping and E-Commerce Statistics for 2017.Nasdaq.com. Recuperado el 17 de noviembre de 2022, de https://www.nasdaq.com/articles/uk-online-shopping-and-e-commerce-statistics-2017-2017-03-14

Pozzi, A. (2013). E-commerce as a Stockpiling Technology: Implications for Consumer Savings E-commerce as a Stockpiling Technology: Implications for Consumer Savings *.

Prechelt, L. (1998). Early Stopping - But When?. En G. Tesauro, D. Touretzky, & T. K. Leen (Eds.), Advances in Neural Information Processing Systems 10 (pp. 55-61). MIT Press.

Ramirez, M. J. (2022,). *Top 10: los mejores eCommerce de Chile*. Marketing 4 Ecommerce. Retrieved May 3, 2023, from https://marketing4ecommerce.cl/los-10-mejores-ecommerce-de-chile/

Rybaczewska, M., & Sparks, L. (2022). Ageing consumers and e-commerce activities. Ageing and Society, 42(8), 1879–1898. https://doi.org/10.1017/S0144686X20001932

Sarwar, B., Karypis, G., et al. (2000). Analysis of Recommendation Algorithms for E-Commerce.

Sanchez - Herrera, T. (2017, January 3). *Sistemas de recomendación en eCommerce: claves para potenciar tus ventas*. Marketing 4 Ecommerce. Retrieved April 9, 2023, obtenido de: https://marketing4ecommerce.net/sistemas-de-recomendacion-en-ecommerce/

Shen, Y., Ou, B., & Li, R. (2022). MBN: Towards Multi-Behavior Sequence Modeling for Next Basket Recommendation. ACM Transactions on Knowledge Discovery from Data, 16(5). https://doi.org/10.1145/3497748

Wu, S., Tang, Y., Zhu, Y., Wang, L., & Xie, X. (2017). Recurrent Recommender Networks. En Proceedings of the 10th ACM International Conference on Web

Search and Data Mining (WSDM), 495-503. Recuperado de https://dl.acm.org/doi/10.1145/3018661.3018691.

Zhang, S., Yao, L., Sun, A., & Tay, Y. (2016). Top-N Recommendation Algorithms - A Survey. arXiv preprint arXiv:1604.04508.

Zhang, S., Yao, L., Sun, A., & Tay, Y. (2014). Evaluation Metrics for Recommender Systems. Proceedings of the Fourth International Conference on Social Networks Analysis, Management and Security.

Zhou, M., Ding, Z., Tang, J., & Yin, D. (2018). Micro behaviors: A new perspective in E-commerce recommender systems. WSDM 2018 - Proceedings of the 11th ACM International Conference on Web Search and Data Mining, 2018-Febuary, 727–735. https://doi.org/10.1145/3159652.3159671

Zhou, J., Lu, X., Zhang, G., & Sun, G. (2018). Comparing the performance of recommendation algorithms in the context of active learning using cross-validation. Expert Systems with Applications, 92, 428-437. doi: 10.1016/j.eswa.2017.10.035