



UNIVERSIDAD DE CHILE
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
DEPARTAMENTO DE INGENIERÍA INDUSTRIAL

ELABORACION DE UN MODELO DE RECOMENDACIÓN DE PRODUCTOS Y SERVICIOS PARA LOS CLIENTES DE UNA PLATAFORMA WEB DE TIPO MARKETPLACE

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL INDUSTRIAL

MATÍAS IGNACIO CONTRERAS DURÁN

PROFESORA GUÍA:
ALEJANDRA PUENTE CHANDIA

MIEMBROS DE LA COMISIÓN:
CAROLINA SEGOVIA RIQUELME
PEDRO URZÚA SALINAS

SANTIAGO DE CHILE
2022

RESUMEN DE LA MEMORIA PARA OPTAR AL TITULO DE:
INGENIERO CIVIL INDUSTRIAL
POR: MATÍAS IGNACIO CONTRERAS DURÁN
FECHA: 2022
PROFESOR GUÍA: ALEJANDRA PUENTE CHANDIA

ELABORACION DE UN MODELO DE RECOMENDACIÓN DE PRODUCTOS Y SERVICIOS PARA LOS CLIENTES DE UNA PLATAFORMA WEB DE TIPO MARKETPLACE

El éxito de las plataformas online de la actualidad se debe en gran parte a sus sistemas de recomendación. Tal es el caso de Netflix, que gracias a ellos mantienen a sus clientes interesados en su contenido o el de Amazon que genera el 35% de sus ingresos gracias a las recomendaciones. Y es que en el comercio electrónico los clientes van direccionados hacia los productos de su interés, por lo que se sienten comprendidos, generan lealtad con la empresa y es más probable que se conviertan en consumidores. Es por estas razones que los comercios electrónicos actuales deben tener un sistema de recomendaciones.

En este trabajo de memoria se presenta la oportunidad de elaborar un sistema de recomendación personalizado a una empresa de venta de cupones o descuentos online que actualmente tiene un sistema no personalizado (se recomiendan los mismos productos a todos los usuarios), con el fin de evaluar la venta incremental que este sistema genera, para lo cual se utilizan 2 algoritmos: Filtrado Colaborativo y Basado en Contenido.

Al elaborar el sistema se probaron diferentes versiones de los algoritmos (utilizando distintas métricas de similitud para establecer semejanzas entre usuarios y productos), siendo el sistema Basado en Contenido con similitud coseno el que mejor resultados obtuvo en las métricas de predicción de compra y a su vez el que genera recomendaciones más rentables desde el punto de vista del negocio debido a que se ajustan mejor a los diferentes tipos de clientes y a su disposición a pagar.

La evaluación se hizo mediante un experimento natural, y tuvo como resultado que aquellos clientes expuestos a productos más afines a sus gustos tienen una mayor tasa de conversión. Además, 2 de cada 3 compras en este grupo de clientes son recomendaciones generadas por el sistema, con lo cual se espera que al ser implementado se observe un efecto positivo del 4,6% en las ventas.

El trabajo concluye con la elaboración del plan de implementación del sistema, incluyendo el diseño de un A/B test. Finalmente, a futuro se recomienda recopilar más datos de los clientes y sus sesiones para mejorar la precisión de las recomendaciones y eventualmente desarrollar otros sistemas.

TABLA DE CONTENIDO

1.	INTRODUCCIÓN	1
1.1	Antecedentes Generales	1
1.1.1	Características de la Organización	1
1.1.2	Acerca de los Sistemas de Recomendación	4
1.2	Justificación del Proyecto	5
1.3	Objetivos del Proyecto	9
1.3.1	Objetivo General	9
1.3.2	Objetivos Específicos	9
1.4	Resultados Esperados	10
1.5	Alcances del Proyecto	10
2.	MARCO CONCEPTUAL	11
2.1	Clasificación de los Sistemas de Recomendación.....	11
2.1.1	No personalizados.....	11
2.1.2	Basados en Contenido	11
2.1.3	Filtrado Colaborativo (FC)	12
2.1.4	Sistemas de Recomendación Híbridos	13
2.2	Métricas de Similitud.....	13
2.2.1	Distancia Euclidiana	14
2.2.2	Distancia de Jaccard	14
2.2.3	Basada en Coseno.....	14
2.2.4	Basada en Coseno Ajustado.....	15
2.3	Métricas de Evaluación.....	15
2.3.1	MAE (Mean Absolut Error) y RMSE (Root Mean Squared Error)	15
2.3.2	Coverage.....	16
2.3.3	Precisión y Recall.....	16
2.3.4	F1 – Score.....	17
3.	METODOLOGÍA	18
3.1	Comprensión del negocio y necesidades del cliente	18
3.2	Estudio y comprensión de los datos	18
3.3	Preparación de datos y selección de variables.....	18
3.4	Modelamiento	19
3.5	Evaluación	19
3.6	Plan de implementación.....	19

4.	DESARROLLO.....	21
4.1	Comprensión de Datos.....	21
4.2	Preparación de Datos	22
4.3	Modelamiento	23
4.3.1	Filtrado Colaborativo	23
4.3.2	Basado en Contenido.....	30
4.3.3	Sistema Híbrido.....	34
4.4	Evaluación de las Recomendaciones	36
4.4.1	Experimento natural	36
4.4.2	Resultados	38
4.5	Plan de Implementación	41
4.5.1	Ejecución del Sistema de Recomendaciones	41
4.5.2	Recomendaciones al Negocio.....	44
5.	CONCLUSIONES	46
	BIBLIOGRAFÍA	48
	ANEXOS	49
	Anexo A: Ticket Medio en UF	49
	Anexo B: Análisis Exploratorio de datos	49
	Anexo C: Demostración Venta Incremental.....	54

1. INTRODUCCIÓN

1.1 Antecedentes Generales

1.1.1 Características de la Organización

Rubro e historia de la empresa

Cuponatic Latam es una empresa multinacional chilena de E-commerce cuyo origen se remonta al año 2010 cuando un grupo de amigos de la Pontificia Universidad Católica de Chile deciden importar y replicar el modelo estadounidense de Groupon [1], el cual consiste en ofrecer grandes descuentos en productos y servicios (los llamados “groupones” o “deals”), pero de manera grupal, es decir este solo es efectivo cuando se llega a cierto número de personas. Cuponatic, a diferencia de Groupon, permite acceder a los descuentos (los llamados *cupones* o *descuentos*) de manera individual, es decir no es necesario comprar en grupo.

En sus inicios, este grupo de 7 personas estaban a cargo de mantener la plataforma web y todas las aristas del negocio. Sin embargo, después de un explosivo crecimiento, en febrero de 2011 iniciaron actividades en Colombia y 3 meses después en Perú. Culminando esta expansión internacional el año 2012 al entrar al mercado mexicano, manteniendo hasta la fecha la operación en los 4 países.

En los años venideros, Cuponatic comenzó una etapa de adquisición de plataformas web de descuentos del mercado nacional: *Agrupemonos.cl* (2013) y *Urbania.cl* (2015). Y también en Perú el año 2017, cuando adquiere *Ofertop.pe*. Actualmente estas plataformas siguen operativas bajo la administración de Cuponatic desde la única oficina en Chile, ubicada en Santiago Centro.

Misión y Visión

La misión de Cuponatic es “ofrecer cada día diferentes productos y servicios a precios incomparables de la mejor calidad”, la cual se complementa perfectamente con su visión de “ser el Marketplace de servicios n°1 en Latinoamérica”. Dejando en claro que buscan ser líderes en lo que servicios respecta; buscando el mejor precio para clientes, oferentes e intereses propios sin perder la calidad de sus descuentos.

Organigrama

Cuponatic LATAM es dirigida por un directorio y administrada por el CEO Christian Real. En Chile¹, la empresa cuenta con una dotación de 46 trabajadores (24 hombres y 22 mujeres), organizados de la siguiente forma:

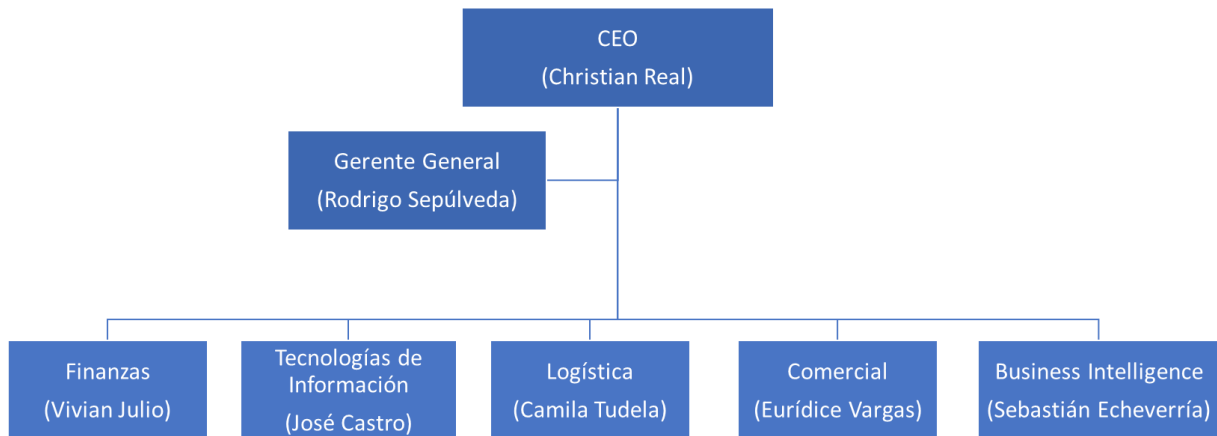


Figura 1. Organigrama de Cuponatic. Elaboración propia.

Las principales áreas involucradas en este trabajo son:

1. **Tecnologías de la información (TI):** Gestionar la base de datos de la empresa y mantener toda la estructura informática y softwares que la soportan. Además de velar por el correcto funcionamiento de la plataforma web.
2. **Business Intelligence (BI):** El principal objetivo es analizar los datos de la empresa y generar los reportes respectivos para todas las demás áreas, es decir brindar información oportuna para apoyar las decisiones de la empresa. Adicionalmente, se encarga de todo el marketing digital de Cuponatic. Es en esta área donde se desarrolla la presente memoria.

Productos y/o Servicios

Al tratarse de una empresa de Ecommerce, el principal servicio que ofrece Cuponatic es el de unir a compradores y oferentes de productos y servicios a través de su plataforma web, recibiendo una comisión por cada transacción realizada en el sitio. Sin embargo, lo que diferencia a Cuponatic es ser una página de descuentos con foco en servicios, siendo

¹ La presente memoria es para Cuponatic Chile, por lo que las siguientes secciones se enfocan en este país.

las principales categorías por nivel de ventas² en 2021: Tratamientos, Baño y aseo & Masajes.

Categoría	Ventas 2021 [MM CLP]	Porcentaje del Total de Ventas
Tratamientos	620,9	10%
Baño y aseo	620,7	10%
Masajes	440,9	7%
Dormitorio	419,7	7%
Electro hogar	375,2	6%
Sala de estar	319,6	5%
Deporte y ejercicios	276,2	4%
Cuidado personal	225,4	4%
Familiar	216,2	3%
Celulares	213,1	3%

Tabla 1. Categorías con más ventas año 2021. Elaboración propia.

Cientes

Los clientes de Cuponatic son todas aquellas personas naturales que compran un cupón o descuento a través del sitio web, los cuales, hasta la fecha, alcanzan un total de 626.613. No obstante, se observa una disminución de clientes mensuales³ en los últimos 3 años, pasando de 30.000 clientes en promedio mensuales el año 2019 a unos 15.000 en 2021.




Gráfico 1. Cantidad de clientes mensuales periodo 2017-2021

² Categorías que más ventas generan en términos monetarios, no necesariamente las que más ingresos o ganancias le generan a la empresa.

³ Clientes que registran al menos una compra durante el mes

Plataforma Web

Los clientes pueden navegar libremente por el sitio sin necesidad de estar registrados en la página, pero al momento de comprar es obligatorio haber iniciado sesión (o crearse una cuenta en caso de no tenerla). La navegación, los descuentos que se muestran en la página de inicio, las secciones y en general cualquier aspecto del sitio web es el mismo si se tiene la sesión iniciada o no, es decir tiene un sistema de recomendación no personalizado que mantiene un set de productos *más populares* (más vendidos) los cuales no cambian según el usuario, por ende, la persona no descubre nada nuevo y se mantiene viendo los mismos descuentos todo el tiempo.

1.1.2 Acerca de los Sistemas de Recomendación

La masificación del internet les ha dado a las personas acceso a gran cantidad de información, contenido audiovisual, productos y servicios, sin embargo, el usuario muchas veces se pierde entre tanto contenido y no sabe dónde o como buscar cosas que le gusten. Este problema es solucionado en parte por los sistemas de recomendación, que le sugieren a los usuarios contenido en base a sus gustos, intereses e historial de comportamiento por los sitios.

Las grandes empresas tecnológicas cuentan con este tipo de herramientas: Spotify para recomendar música, Netflix para las series y películas y Amazon productos. TikTok ha sido la última gran empresa en utilizar esta herramienta con grandes resultados pues su algoritmo es tan preciso que conoce perfectamente a sus usuarios y sus preferencias.

Estos sistemas permiten personalizar y adaptar el contenido ofrecido en los sitios o plataformas web según cada usuario. Son sistemas que organizan la información para mostrar lo más relevante para cada usuario lo cual es una gran ventaja que poseen los ecommerce por sobre el clásico retail físico donde la disposición de la tienda y los productos ofrecidos son iguales para todos. Por tanto, aquel ecommerce que no cuente con un sistema como este, está perdiendo no solo una ventaja competitiva si no que ingresos potenciales ya que según la consultora McKinsey [2] el 35% de los ingresos de Amazon provienen de la recomendación de productos y en el caso de Netflix, el 75% de lo visto en la plataforma proviene de estos mismos algoritmos.

1.2 Justificación del Proyecto

Desde el área de BI de la empresa se detectó una baja y posterior estancamiento del ticket medio, es decir del monto gastado por cliente en cada compra. Si se observa el grafico 2, es claro que desde el 2018 se ha mantenido entre los 15.000 y 20.000 CLP, muy lejos de los 30.000 CLP promedio del año 2017 (en Anexo 1 se encuentra este grafico ajustado a la UF mensual). Y si bien se proyectaba una recuperación a fines de 2019, la pandemia y posterior confinamiento en los primeros meses de 2020 tuvo un efecto negativo en las ventas.

Si bien el valor promedio de los descuentos también ha variado en estos años (grafico 2), la relación entre ambas no es tan directa. Se observa que en 2018 los precios de los descuentos mantenían un nivel similar a 2017; no obstante, el ticket medio se redujo en un 33% aproximadamente entre esos años. Luego, en 2019 y 2020, existe cierta relación ya que ni el valor promedio ni el ticket medio tuvieron gran variación (salvo marzo 2020 que marca el inicio del confinamiento en Chile). En 2021 se observa un alza en el valor de los descuentos ofrecidos, pero el ticket medio se mantiene en el mismo nivel de los 3 años anteriores.




Gráfico 2. Evolución del ticket medio mensual y del valor (precio) promedio de los cupones - periodo 2017-2021.

Junto con esto, la cantidad de compras por parte de los clientes (grafico 3) ha disminuido drásticamente durante el año 2021. Si bien el comportamiento de compras presenta picos estacionales, en promedio se tenían 60.000 compras mensuales incluso en el primer año de pandemia (2020), sin embargo, entrando en 2021 se observa una clara tendencia a la baja, llegando a las 30.000 compras mensuales.

Una de las razones se debe al boom del comercio electrónico del 2020 en Chile [3] y que para la empresa se comienza a reflejar en 2021. En el primer año de pandemia muchas tiendas físicas se vieron obligadas a crear una tienda virtual y las plataformas ya existentes se vieron obligadas a mejorar su sistema y experiencia de usuario, por lo que para el año siguiente había mucha más competencia en el rubro y por consiguiente los clientes al tener más ofertas, demandan un mejor nivel de servicio o experiencia de compra a las plataformas de e-commerce.




Gráfico 3. Evolución de la cantidad de compras mensuales en el periodo 2017-2021.

Para intentar revertir esta situación e impulsar las ventas se han hecho campañas de marketing digital (Google y Facebook Ads) para atraer nuevos clientes, email marketing para impulsar la recompra de los clientes ya registrados y un club de lealtad que premia a los clientes cada vez que compran, acumulando puntos que luego pueden usar como dinero en sus próximas compras.

Ahora bien, el activo más valioso de Cuponatic es sin duda su plataforma web, razón por la cual es importante mantenerla actualizada en cuanto a contenido y funcionalidades para atraer, retener e inducir la compra de los clientes. Como se mencionó en la sección anterior, la página de inicio y el sitio en general es el mismo si se tiene o no la sesión abierta; se observa en primera instancia un carrusel promocionando algunos descuentos,

debajo se tienen ofertas especiales junto a los iconos de las categorías principales y por último el set de productos destacados (ver Ilustración 1). En cuanto a las secciones, estas van rotando de acuerdo a la época del año, por ejemplo, en abril de 2022 se tiene una sección especial para semana santa (ver Ilustración 2).

Personalizar todo el sitio o la disposición de este a cada usuario puede ser costoso, no obstante, se puede generar cierto grado de personalización si se muestran ofertas o cupones adaptados a cada cliente según sus gustos y preferencias. De esa forma los clientes entran al sitio, saben que buscar y se genera un mayor nivel de compromiso con la página.

Actualmente la página tiene un sistema de recomendación no personalizado, es decir se les recomienda lo mismo a todos: los productos o servicios más vendidos del momento o “populares”, y por ende no considera los gustos de cada persona. Esta situación no es un problema, pero es una oportunidad de mejora para aumentar el ticket medio y la fidelidad de los clientes (la que se traduce en ventas [4]), ya que con un motor de recomendaciones personalizado se busca mantener a un cliente interesado en la plataforma y despertar su atención por otros productos o servicios que, aunque no los compre inmediatamente, pueden quedar en su lista de deseos.

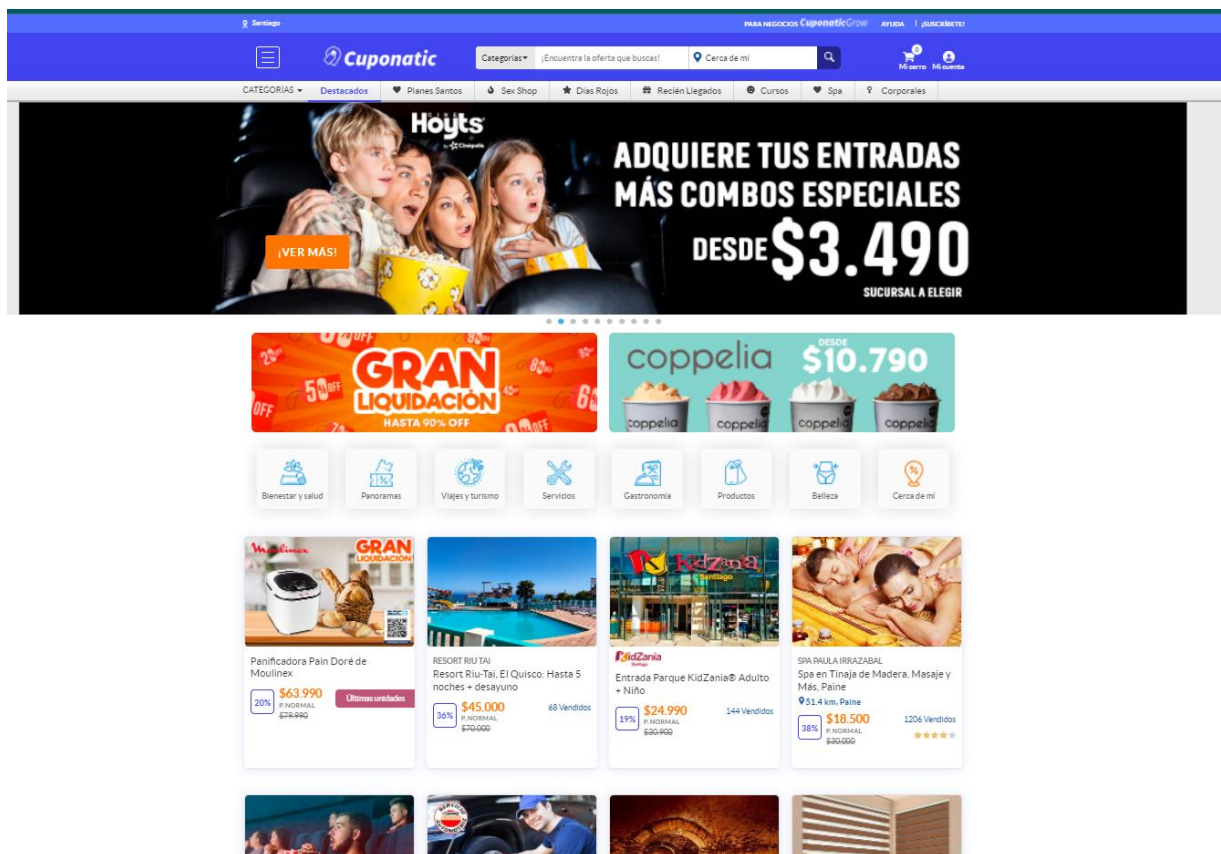


Ilustración 1. Página de inicio de Cuponatic.com

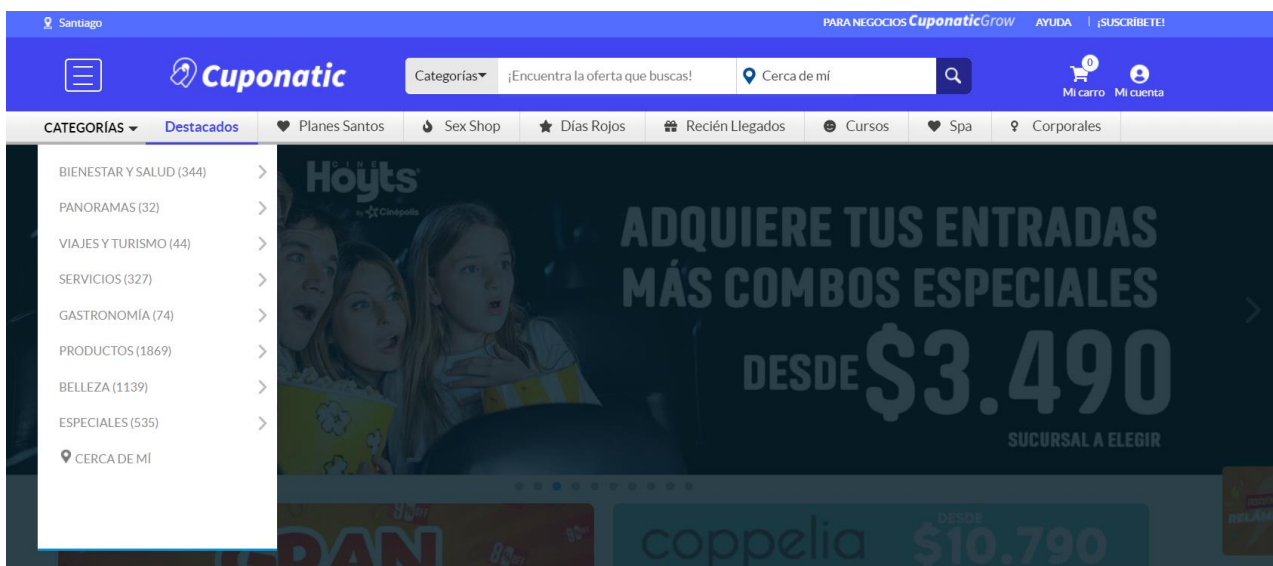


Ilustración 2. Secciones principales de la página en abril 2022

Para medir el impacto esperado de la oportunidad, se debe tener en cuenta los resultados que los sistemas de recomendación han obtenido en distintos comercios. Ya se conoce el caso de Amazon y su potente motor de recomendaciones, pero ¿Qué efecto tienen en comercios más pequeños? En el trabajo de título de Rodrigo López [5], se implementó un sistema de recomendación personalizado por segmentos en un sitio de comercio electrónico que no contaba con uno y en cuyos resultados se obtuvo un aumento del gasto promedio por sesión del 0.5% pese a que la tasa de conversión se mantuvo (compras por sesión), esto bajo condiciones poco favorables ya que el experimento se realizó en una sección de la página que tenía la menor visualización (solo un 8%), concluyendo que los resultados se pueden considerar como una cota inferior del efecto real que este sistema pudiese lograr en el sitio. También entre sus resultados se indica que los clientes expuestos a las recomendaciones personalizadas tuvieron un 14% más de tasa de clics que el grupo de control, demostrando así el mayor interés que despierta en los clientes este tipo de recomendaciones. Si se llevan esos resultados a este caso, considerando mostrar las recomendaciones en un sitio con un 30% de visualización, se estima un aumento del gasto por sesión (o aumento en los ingresos) cercano al 2%.

Por otro lado, se debe estimar la cantidad de usuarios a los que se espera impactar con este proyecto. Los clientes deben obligatoriamente registrarse al momento de pagar los descuentos que están en el carrito de compras, lo cual genera 2 tipos de usuarios: aquellos que navegan por el sitio con la sesión abierta, independiente de si compran o no, y aquellos que únicamente se registran para comprar. Esta distinción es importante ya que la única forma de identificar a cada usuario (y por tanto conocer sus preferencias) es a través de su sesión. En marzo de 2022 se iniciaron un total de 11.647 sesiones, de las cuales al menos 6.009 se consideran "sesiones de navegación" ya que habían pasado 2 días o más entre la última compra y la última conexión, es decir actualmente al menos

6.000 personas al mes entran al sitio a mirar las ofertas y por tanto a quienes van dirigidas las recomendaciones.

Sesiones Totales	Sesiones Compra	Sesiones Navegación
11.647	5.638	6.009

Tabla 2. Detalle Sesiones Iniciadas en marzo 2022.

1.3 Objetivos del Proyecto

1.3.1 Objetivo General

Desarrollar un sistema de recomendación que permita sugerir productos y servicios a los clientes de la plataforma web de manera personalizada, con el fin de evaluar la venta incremental que generan las alternativas de recomendación.

1.3.2 Objetivos Específicos

1. Seleccionar las variables clave que representen las preferencias de los usuarios.
2. Elaborar tres prototipos de sistemas de recomendación.
3. Evaluar y comparar el rendimiento de cada sistema, considerando complejidad y capacidad predictiva de cada uno, con el fin de escoger el que mejor se adapte a la empresa.
4. Diseñar un plan de implementación del sistema escogido.

1.4 Resultados Esperados

Elaborar un sistema de recomendación adaptado a la empresa, que les permita a los usuarios descubrir descuentos nuevos de acuerdo a sus gustos e intereses y a su vez le permita a la empresa conocer mejor a sus clientes (si compra o no un descuento sugerido, es información importante sobre sus gustos).

Junto con ello, la realización de un plan de implementación de este sistema y en línea con ello, sugerir mejoras para la plataforma que apunten a mejorar el sistema desarrollado.

1.5 Alcances del Proyecto

El alcance de este proyecto de Data Science es elaborar un sistema de recomendación adaptado a la información disponible en la empresa, considerando los siguientes puntos que limitan el alcance:

- No se cuenta con el historial de navegación de los clientes (la información de cada sesión se guarda en las cookies y se borra diariamente) y por tanto no se considera a los clientes que no registren compras pues no se tiene data histórica de ellos.
- Las recomendaciones se hacen a nivel de descuentos y no segmentos, es decir no se consideran las versiones de los productos (color, tamaño, etc.). Esto porque el cliente elige la versión cuando se agrega al carrito, antes de eso solo se muestra la oferta a nivel de descuento.
- No se hace diferencia entre producto y servicio, por lo que todo se trabaja nivel de deal o descuento sin distinción. De esta forma los sistemas tienen libertad de recomendar las ofertas más afines a cada cliente y no se les fuerza a recomendar cierto tipo de descuento.
- Como el sistema se entrenará con la data histórica de la empresa, si un evento no ha sucedido en el pasado, no hay como predecirlo. Esta limitante se debe a que los sistemas intentan replicar patrones pasados hacia el futuro y también por la información utilizada, ya que solo se tiene como fuente los datos de la empresa, los cuales podrían complementarse con data externa de comportamiento de compra de la población.

2. MARCO CONCEPTUAL

Para comenzar con la elaboración de un sistema de recomendación, primero se debe revisar el estado del arte de ellos; los diferentes tipos que existen, las métricas de similitud y evaluación con las cuales se medirá su rendimiento.

2.1 Clasificación de los Sistemas de Recomendación

El objetivo de cualquier sistema de recomendación es predecir la valoración que le darían los usuarios al contenido o ítems, de tal forma de recomendar los N elementos que con mayor probabilidad le gusten al usuario. Los sistemas entonces se clasifican [4] según la forma en que realizan esta predicción.

2.1.1 No personalizados

Son aquellos en que las recomendaciones no toman en cuenta la información del usuario ni su interacción con el sitio [6]. Mas bien se basa en la *popularidad* de los ítems, ya sea los más vendidos, los más vistos o los mejor calificados por los usuarios. Este es el sistema que tiene actualmente la empresa.

2.1.2 Basados en Contenido

En este tipo de sistemas, los atributos de los ítems o contenido son el eje principal para realizar las recomendaciones [6]. Los perfiles de cada usuario se elaboran en base a las características de los elementos que ha visitado, comprado o calificado sin considerar la información de los demás usuarios, con lo cual la persona recibirá sugerencias de contenido similar al que ya ha visto.

Para generar las recomendaciones, este tipo de sistema consta de 3 etapas:

- i. **Análisis del Contenido:** este es el preprocesamiento de la información que se tiene de los ítems (atributos, categorías, precios, valoraciones), especialmente cuando está en formato de texto (descripciones de productos, reseñas u opiniones de un servicio), por lo que el objetivo es obtener las principales palabras clave de cada ítem.
- ii. **Creación de Perfiles:** los perfiles de usuario se crean a partir de la generalización de los datos obtenidos del análisis anterior. El sistema puede crear estos perfiles en base a información explícita o implícita de los usuarios. La primera es cuando un usuario da a conocer su valoración por un ítem de forma explícita (generalmente por una puntuación de 1 a 5 y un breve comentario) y la segunda se infiere a partir del comportamiento del usuario

(historial de navegación, productos en la *lista de deseos*, tiempo de permanencia en cierta página).

- iii. **Filtrado del Contenido:** Teniendo el perfil del usuario, se busca en la base de datos de contenido, ítems similares que coincidan con las preferencias del perfil creado, utilizando alguna métrica de similitud. El resultado es una lista de elementos potencialmente interesantes para el usuario en base a su perfil.

Para utilizar un sistema de recomendación basado en contenido, se necesita una base de datos en la que los elementos sean descritos mediante varios atributos para poder evaluar si 2 ítems son similares o no. Por otro lado, se necesita que los usuarios hayan manifestado cierta preferencia por algún contenido o bien haber interactuado de alguna manera con el sitio para que el sistema comience a sugerirle elementos similares (problema del *usuario nuevo*, ¿que se les recomienda?). A cambio, el sistema permite recomendar productos o elementos nuevos, aunque no hayan sido comprados o calificados por algún usuario.

Otro aspecto para tener en cuenta es que rara vez un sistema como este podrá recomendar algo “novedoso” a los usuarios ya que siempre sugerirá contenido similar al que ya se ha visto, lo cual dependiendo de las reglas del negocio esto puede ser una ventaja o desventaja (TikTok mantiene a sus usuarios dentro de la aplicación mostrándoles contenido similar al que usualmente consumen).

2.1.3 Filtrado Colaborativo (FC)

Estos sistemas [7] se basan en las calificaciones que los usuarios han hecho del contenido, y en base a la similitud con otros usuarios, el sistema genera las recomendaciones. La idea es encontrar elementos que el usuario aún no ha calificado (o comprado), pero que les han gustado a los usuarios con quienes tiene cierto grado de similitud en base a variables observables.

Estos sistemas utilizan toda la base de valoraciones, historial y en general cualquier información disponible del usuario (o ítems) para generar las recomendaciones. Dependiendo del enfoque, éstos pueden ser basados en el usuario o en ítems.

2.1.3.1 FC basado en usuarios

Este sistema se basa en la premisa de que si a una persona le gusta X y otra persona le gusta X e Y entonces si los usuarios son similares de acuerdo con alguna métrica, al primer usuario muy probablemente también le guste Y.

Al ser un FC basado en memoria se utiliza toda la información de compras, calificaciones, clics, tiempos de permanencia en cierta página y cualquier dato del usuario para establecer similitudes con otros. Por lo tanto, si la base de datos es pobre en cantidad de valoraciones (los usuarios califican un porcentaje bajo del total de elementos), será difícil para el sistema generar similitudes entre 2 usuarios.

Para generar la lista de recomendaciones, se determina un vecindario de los k-usuarios similares (se aconseja entre 25 y 100 pero no hay una regla exacta) y en caso de que los últimos vecinos estén muy lejos se puede definir un mínimo de similitud para ser considerado vecino. Esta similitud o distancia entre usuarios puede variar bastante a lo largo del tiempo, por lo que se deben computar con relativa frecuencia.

2.1.3.2 FC basado en ítems

Este sistema es parecido al de usuarios, pero viéndolo desde la perspectiva de los elementos. Se toman 2 ítems, y en base a los usuarios que los han calificado se determina que tan similares son y de acuerdo al grado de similitud que tengan serán recomendados a los usuarios que solo hayan calificado o comprado uno de los dos. Entonces si un usuario ha valorado o comprado el ítem 1 pero no el 2, el cual es muy similar al 1 en base a las valoraciones de los usuarios que han puntuado ambos, entonces el ítem 2 debiese ser recomendado a este usuario.

La ventaja de un FC basado en ítems, es que la similitud entre objetos es menos variable que la de entre usuarios (las preferencias y gustos de las personas cambian constantemente), por lo cual se puede reentrenar el sistema con menor frecuencia.

2.1.4 Sistemas de Recomendación Híbridos

Estos sistemas son una combinación de Filtrado Colaborativo y en Base a Contenido. Se puede emplear una ponderación de las recomendaciones o predicciones generadas por ambos para obtener una lista final de elementos o bien utilizar un sistema *tándem* en que en algunos casos se active el Filtrado Colaborativo y en otros en Base a Contenido, de esta forma se pueden cubrir las desventajas de un sistema con las ventajas del otro.

2.2 Métricas de Similitud

Los sistemas anteriormente mencionados, se basan en cuan similares son los usuarios o ítems entre sí, dicho de otra forma, se puede entender como la distancia que hay entre 2 elementos de la base de datos. Es por esto que a continuación se presentan las principales métricas:

2.2.1 Distancia Euclidiana

Mide la distancia en el *plano* entre dos elementos [8], en este caso se computa la diferencia entre las valoraciones de los usuarios a los ítems para establecer la similitud entre ellos.

$$d(X, Y) = \sqrt{\sum_{i=1}^N (x_i - y_i)^2} \quad (1)$$

2.2.2 Distancia de Jaccard

El coeficiente de Tanimoto o Distancia de Jaccard [8] es la razón entre los elementos en común que tienen 2 usuarios (en su canasta de compras, por ejemplo) y el total de elementos entre ambos. Dicho de otro modo, mide la probabilidad de que 2 usuarios compartan los mismos ítems.

Esta distancia se puede utilizar como métrica de similitud ya que tiene valores entre 0 y 1, además solo se puede utilizar para comparar usuarios respecto de sus compras o visitas en la página web ya que no considera las calificaciones que estos han hecho.

$$J(A, B) = \frac{|A \cap B|}{|A \cup B|} \quad (2)$$

2.2.3 Basada en Coseno

Para calcular esta métrica, se debe pensar en las calificaciones de cada usuario o ítem como si fueran vectores en el espacio, de tal manera que el coseno del ángulo que formen indicará que tan similares son [8]. Si los vectores apuntan en la misma dirección, el coseno es 1, es decir son perfectamente similares, en el caso opuesto en que los vectores apunten en la dirección contraria, el coseno será 0, indicando que son absolutamente distintos.

Como se puede intuir, esta métrica revela la tendencia de 2 usuarios a calificar los elementos de manera similar, aunque las magnitudes sean muy diferentes (un usuario que califica todo con 10 y otro todo con 5, esta métrica indica que son perfectamente similares).

$$\cos(X, Y) = \frac{\vec{X} \cdot \vec{Y}}{\|\vec{X}\| \|\vec{Y}\|} \quad (3)$$

$$\cos(X, Y) = \frac{\sum_{i=1}^N x_i y_i}{\sqrt{\sum_{i=1}^N x_i^2 \sum_{i=1}^N y_i^2}}$$

2.2.4 Basada en Coseno Ajustado

Para solucionar el problema de la magnitud que tiene la similitud basada en coseno, existe esta métrica de coseno ajustado que busca normalizar las calificaciones de cada usuario, restándole el promedio de las calificaciones del usuario a cada una de las calificaciones que este ha hecho [8]. Quedando entonces la fórmula como sigue:

$$\text{sim}(u1, u2) = \frac{\sum_{i \in I} (R_{i,u1} - \overline{R_{u1}})(R_{i,u2} - \overline{R_{u2}})}{\sqrt{\sum_{i \in I} (R_{i,u1} - \overline{R_{u1}})^2} \sqrt{\sum_{i \in I} (R_{i,u2} - \overline{R_{u2}})^2}} \quad (4)$$

Donde $\overline{R_{uu}}$ es el promedio de las calificaciones hechas por el usuario u_j y $R_{i,u1}$ es la calificación del objeto i hecha por el usuario u_j

2.3 Métricas de Evaluación

Para poder evaluar el grado de certeza de las recomendaciones hechas por los sistemas es necesario contar con métricas que indiquen que tan cerca estuvieron los valores predichos de los reales.

2.3.1 MAE (Mean Absolut Error) y RMSE (Root Mean Squared Error)

Ambas métricas calculan el promedio de la distancia absoluta entre el valor predicho y el real [8]. La diferencia entre ambas radica en que el RMSE penaliza en mayor medida los

errores grandes (como se puede ver en las fórmulas), lo cual se quiere evitar en un sistema de recomendación.

$$\text{MAE} = \frac{1}{n} \sum_{j=1}^n |y_j - \hat{y}_j| \quad (5)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2} \quad (6)$$

2.3.2 Coverage

Esta métrica indica el porcentaje de cobertura que alcanza el sistema en cuanto a recomendaciones, ya que no a todos los usuarios se logran hacer recomendaciones o no todos los ítems logran ser recomendados debido a las propias limitaciones de cada sistema [9].

2.3.3 Precisión y Recall

Estas métricas son muy similares ya que apuntan a determinar la calidad de las recomendaciones [9]. La *precisión* indica el porcentaje de recomendaciones relevantes hechas por el sistema sobre el total de ítems recomendados, en cambio el *Recall* indica el porcentaje de recomendaciones relevantes del total de ítems relevantes para el usuario.

$$\text{Precision} = \frac{|Recomendados \cap Relevantes|}{|Recomendados|} \quad (7)$$

$$\text{Recall} = \frac{|Recomendados \cap Relevantes|}{|Relevantes|} \quad (8)$$

2.3.4 F1 – Score

Esta métrica se define como la media armónica entre la *Precisión* y *Recall* [9], y se utiliza para poder combinar ambas métricas en una sola y así poder comparar de mejor manera los sistemas de recomendación.

$$F1 = 2 \cdot \frac{Presicion \cdot Recall}{Presicion + Recall} \quad (9)$$

3. METODOLOGÍA

Para el desarrollo de este proyecto se utilizará la metodología CRISP – DM [7], ampliamente conocida en proyectos de minería de datos y que consta de 5 etapas principales:

3.1 Comprensión del negocio y necesidades del cliente

En esta primera etapa se busca conocer las reglas del negocio y la visión y objetivos que la empresa tiene, los cuales pueden derivar en restricciones a la hora de generar las recomendaciones. Se busca entender la situación actual de la empresa y la dirección que tiene, de esta forma se podrá entregar un producto (modelo) acorde a sus necesidades.

3.2 Estudio y comprensión de los datos

Acceder y obtener la data de la empresa, realizando una búsqueda exhaustiva en la base de datos para conseguir la mayor cantidad de información posible que sea relevante para un sistema de recomendación (información de clientes, compras, características de los productos, etc.), con el fin de tener claro que es lo que hay (o no) en la base de datos.

Realizar un análisis exploratorio de datos (EDA) para conocer la distribución de las características de los clientes, la relación entre los atributos clave de los productos y en general cualquier análisis estadístico que permita entender de mejor manera los datos que se tiene.

Por último, verificar la calidad de los datos, es decir comprobar que se tienen todos los casos que se necesitan, la existencia de *nulls* o datos faltantes y que porcentaje representan del total de la data. El objetivo es analizar si existen problemas con los datos, y en caso de haberlos listar las posibles soluciones.

3.3 Preparación de datos y selección de variables

Decidir qué datos se utilizarán para elaborar el sistema, esto implica seleccionar los atributos (columnas) más relevantes según el objetivo y los registros (filas) de mayor calidad, considerando también que se debe tener un mínimo volumen de datos.

Luego viene la limpieza de datos que se utiliza para eliminar casos conflictivos o con información incompleta, incluyendo los criterios propios del sistema como por ejemplo dejar solo los clientes que tengan más de x compras o los ítems que tengan más de y

calificaciones. De ser necesario, también se pueden construir algunos atributos a partir de los existentes (ejemplo Área = Largo * Ancho) o crear registros a partir de la data (una columna que indica los ítems que no registran ventas los últimos 3 meses). Por último, darle el formato necesario a la data según el sistema a utilizar.

3.4 Modelamiento

Habiendo estudiado los distintos sistemas de recomendación y un análisis preliminar de la información que se tiene en la base de datos, se definen como modelos a elaborar un Filtrado Colaborativo en base a usuarios, un Filtrado en base a contenido y un sistema híbrido entre ambos

En esta etapa también se separa la base en 2: *train* y *test*. La primera se utiliza para construir y entrenar el sistema y la segunda para estimar su calidad en cuanto a estimaciones.

Luego se construyen los sistemas y miden los resultados utilizando las métricas de evaluación expuestas en el marco conceptual. Según la evaluación, se revisan y ajustan los parámetros del sistema hasta encontrar el mejor posible.

3.5 Evaluación

En esta etapa se evalúa el sistema en base a las reglas y objetivos del negocio, es decir evaluar si el sistema es útil para la empresa considerando complejidad, factibilidad de implementación, tiempo que demora en generar recomendaciones y si estas cumplen con las reglas expuestas por la empresa.

Se incluye un experimento natural del sistema elegido para evaluar el efecto en las métricas que la implementación de este pudiese generar.

En este punto también se realiza una revisión del proceso general de la elaboración del sistema para chequear que no se haya considerado alguna variable relevante, que los análisis estén bien hechos, que el sistema haya sido construido de manera correcta, entre otros.

3.6 Plan de implementación

Adicionalmente se considera una etapa de elaboración de un plan de implementación del sistema adaptado a la empresa, considerando la gestión del cambio al incorporar un sistema de recomendación (¿cómo afecta a los colaboradores que deberán supervisar el

sistema?) y dejando en claro los aspectos más relevantes como cada cuanto tiempo se debe reentrenar el sistema.

Esto también incluye el diseño de un experimento de tipo A/B test, con el fin de evaluar las diferencias entre las métricas en los grupos de control y tratamiento con un grado tal de significancia que los resultados puedan ser interpretables.

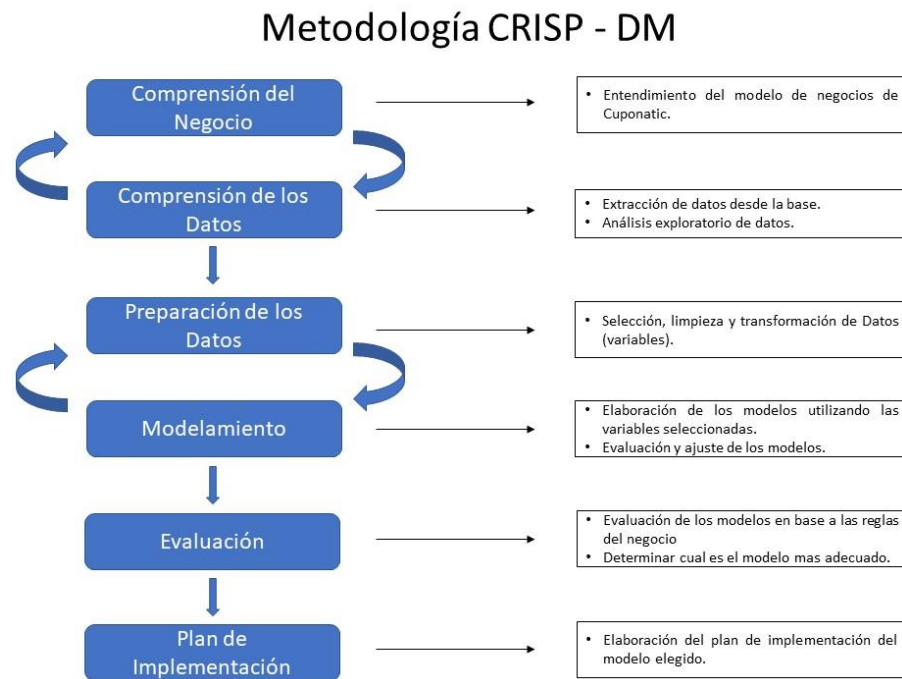


Ilustración 3. Metodología CRISP-DM aplicada al proyecto

4. DESARROLLO

La primera parte de la metodología consta de la comprensión del negocio, lo cual no se presenta en esta sección, sino que se aborda a lo largo del documento, principalmente en la *Introducción*.

4.1 Comprensión de Datos

Comenzando por la selección de datos, se exploró la base en busca de información relevante para los sistemas. Para este caso se cuenta con la siguiente data:

1. Clientes

Esta base guarda la información y características de los clientes:

- i. Id cliente: identificador único de cada cliente.
- ii. Género: variable categórica binaria del género del cliente.
- iii. Fecha de Nacimiento: fecha de nacimiento del cliente.
- iv. Ciudad: ciudad de residencia del cliente.
- v. Last Login: fecha de la última vez que el cliente inicia sesión.

2. Transacciones

Esta base guarda el registro de transacciones (compras) hechas por los clientes.

- i. Id compra: identificador único de la transacción.
- ii. Id cliente: cliente asociado a la compra.
- iii. Id descuento: Identificador del descuento comprado.
- iv. Fecha de compra: fecha de la transacción.
- v. Monto: precio total de la compra.
- vi. Rating: puntuación del cliente a la compra.

3. Descuentos

Esta base guarda la información relacionada con los descuentos que han sido publicados en la plataforma.

- i. Id descuento: Identificador único del descuento.
- ii. Categoría 1: categoría de primer nivel del descuento.
- iii. Categoría 2: categoría de segundo nivel del descuento.

- iv. Fecha de inicio: fecha en que comienza a publicarse el descuento en la página.
- v. Fecha de termino: fecha en que termina de publicarse el descuento en la página.

Para ver los gráficos y análisis exploratorio de datos dirigirse al Anexo 2.

4.2 Preparación de Datos

Se selecciona los clientes que hayan registrado al menos una compra en 2020 o 2021, esto para separar a los clientes activos pre y post pandemia, con lo cual se tiene una base de 194.607 registros.

La base de transacciones se transforma a una base de frecuencia de compra (ilustración 4) donde los registros cliente-descuento son únicos; se agrega la columna “cantidad” para indicar las veces que este cliente ha comprado dicho descuento y el rating observado en caso de existir.

	id_cliente	id_descuento_comun	cantidad	rating_obs
0	2721448	187380	151	NaN
1	2903105	224761	129	9.0
2	45166	131368	125	9.0
3	419983	117295	93	9.0
4	2561188	187380	73	10.0

Ilustración 4. Frecuencia de Compra

La base de calificaciones cuenta con un total de 270.636 registros, correspondientes al 22% de las transacciones, es decir solo un 22% de las ventas tienen una calificación asociada⁴ y en su mayoría (69%) corresponden a un puntaje de 9 o 10, lo que se significa que al cliente le ha gustado el producto o está conforme con el servicio (detalle en Anexo B).

De la base de descuentos se obtiene la base de descuentos disponibles, que son aquellos descuentos que siguen vigentes en enero 2022 y tienen una duración de más de 7 días, es decir son los descuentos recomendables, mientras que la base de descuentos histórica se utiliza para generar las similitudes entre los usuarios.

⁴ Nota de investigación: Se intentó encontrar una relación entre la cantidad de veces que un cliente compraba un descuento y la calificación con el fin de cubrir los valores faltantes, sin embargo, los resultados no fueron favorables.

Para entrenar y evaluar los sistemas, se separa la base de frecuencia de compra en 2, dejando las compras realizadas durante los primeros 3 meses de 2022 para la evaluación. Esto da el número de clientes a los que realizar recomendaciones, siendo estos 10.650.

Un resumen de la cantidad de datos disponibles para entrenar los sistemas se muestra en la tabla 2.

Tabla	Registros
Cientes	194.607
Transacciones	1.219.923
Frecuencia Compra	1.000.505
Frecuencia Compra (train)	986.963
Frecuencia Compra (test)	17.984
Ratings	270.636
Descuentos	58.747
Descuentos Disponibles 2022	5.611

Tabla 3. Cantidad de Registros por Tabla

4.3 Modelamiento

Con los datos recopilados de la parte anterior se elaboran los distintos sistemas de recomendación expuestos en el Marco Conceptual. Estos son: Filtrado Colaborativo, Basado en contenido e Híbrido. Para cada sistema se evalúa que métrica de similitud se adapta mejor según su rendimiento y finalmente se analiza la calidad de las recomendaciones generadas por cada uno desde el punto de vista del negocio, con el fin de escoger el que mejor se ajusta a la empresa.

4.3.1 Filtrado Colaborativo

Este sistema se basa en encontrar similitudes entre los clientes, a fin de recomendar productos más novedosos. Al solo tener información de compras y calificación de las mismas como indicadores de preferencia de los clientes, se decide realizar 2 filtros colaborativos: uno utilizando información explícita (rating) y otro en base a la implícita (compras), utilizando distintas métricas de similitud en ambos casos, para luego comparar.

4.3.1.1 Rating

Como se explica en la sección *Marco Conceptual*, este tipo de algoritmo de recomendación se basa en encontrar similitudes entre los usuarios utilizando el rating hecho por parte de los clientes a los descuentos comprados.

Para este caso se eliminan los registros sin rating y se filtran los clientes que solo han evaluado una compra, esto porque para poder recomendar algún ítem al menos se debe haber calificado 2, y por otro lado con solo un ítem la métrica de similitud no es muy verosímil. Aplicando estos filtros, queda una base de 196.942 registros de rating realizados por 44.097 clientes.

Con la información disponible se decide utilizar las métricas de Coseno y Coseno Ajustado (fórmulas 3 y 4 del *Marco Conceptual*) para calcular similitud y generar las recomendaciones.

4.3.1.2 Compras

Al utilizar solo el historial de compras de los clientes como información de sus preferencias, la métrica empleada es la distancia de Jaccard (fórmula 2 del *Marco Conceptual*) y al igual que en el caso anterior se filtran los clientes que registran solo una compra, quedando así una base de 917.109 registros de compras cliente-descuento únicos, para un total de 124.751 clientes.

4.3.1.3 Evaluación de métricas de similitud

Por cada métrica de similitud implementada en el algoritmo (Jaccard, Coseno y Coseno Ajustado) se generan un set de 3, 6, 9 y 12 recomendaciones por cliente para evaluar su rendimiento mediante la Precisión, Recall, F1- Score y Coverage, comparándolas a su vez con el sistema actual de la empresa (No personalizado).

	id_cliente	id_descuento_comun	recommendation_rating	nombre	monto
0	2621853	194067	10.0	Funda Cobertor de Sillón para Mascotas 2 Cuerpos.	10990.0
1	2621853	276673	10.0	Pack 3 Lysol desinfectante multisuperficies ta...	12190.0
2	2621853	122830	10.0	¡Llena tu cocina de color! Paga \$4.290 por set...	4290.0
3	2621853	271200	10.0	Pack de 3 unidades de aerosol desinfectante Ly...	17690.0
4	2621853	236558	9.0	¡Elige tu sabor favorito! Suplemento 100% Wome...	17490.0
5	2621853	265189	9.0	Pack de 2 Frascos de Vitamina C + Zinc Mastica...	12790.0
6	2621853	258194	9.0	Macetero Negro de 7 u 11 Litros, a elección	5890.0
7	2621853	248458	9.0	Display 48 Braunichoc Nutra Bien/r/n	10990.0
8	2621853	230739	9.0	Pack 4 Dawn Lavalozas Botella 709ml	12890.0
9	2621853	265193	9.0	¡MEJORA TU SISTEMA INMUNE! Pack de 2 Frascos ...	12490.0
10	2621853	219443	9.0	Plumon de pluma AF Liso Pluma 2 plazas	17390.0
11	2621853	217363	9.0	Pack de 24 latas de Canada Dry Ginger Ale o Ag...	11990.0

Ilustración 5. Ejemplo de Recomendaciones utilizando un Filtro Colaborativo

Comenzando por la precisión (fórmula 7 del *Marco Conceptual*), que indica el porcentaje de recomendaciones que fueron relevantes para el cliente, destaca el Coseno Ajustado (con cerca de un 3% de precisión), aunque en términos absolutos no hay una diferencia

significativa entre las 3; la precisión de un Filtro Colaborativo es baja (entre 1 y 3%). No obstante, la precisión del sistema actual ronda el 2%, por lo que el sistema propuesto exhibe una mejor predicción de compra. Esto quiere decir que las recomendaciones son más relevantes para los clientes, lo que se traduce en una mayor probabilidad de conversión o compra.




Gráfico 4. Precision de las Métricas de Similitud de un Filtro Colaborativo

Siguiendo por el Recall (fórmula 7 del *Marco Conceptual*) que indica el porcentaje de ítems relevantes del cliente que le fueron recomendados, es claro que la métrica Jaccard obtiene el mejor rendimiento con un máximo de 15 %, muy superior a las otras 2 (que no obtienen más allá de un 2%). Sin embargo, el sistema No personalizado tiene el doble de Recall que un Filtro Colaborativo, es decir el sistema actual cubre de mejor manera los ítems relevantes de los clientes.




Gráfico 5. Recall de las Métricas de Similitud de un Filtro Colaborativo

Ahora bien, mientras un sistema con mayor Precisión realiza recomendaciones más relevantes, un sistema con mayor Recall cubre de mejor manera los ítems relevantes del cliente. Esta situación genera un *trade-off* entre ambas métricas ya que la Precisión valora la relevancia de las recomendaciones (que cada recomendación sea interesante para el cliente) y el Recall valora que todos los ítems relevantes del cliente sean recomendados (sin importar la cantidad de recomendaciones), entonces mientras más ítems se recomiendan es más probable que el Recall mejore, pero a la vez es más probable que la Precisión baje. Dependiendo del caso y del negocio se optará por un sistema que tenga mejor una métrica o la otra. Sin embargo, existe una métrica que combina las dos anteriores de manera armónica, el F1-Score (fórmula 9 del *Marco Conceptual*), permitiendo así elegir un sistema más equilibrado en cuanto a relevancia de recomendaciones.

En el gráfico 6 se observa que las recomendaciones No personalizadas tienen un mejor F1-Score (cerca del 4%) que cualquier variante de un Filtro Colaborativo (en el mejor caso llega a un 3%), lo cual quiere decir que el sistema actual genera recomendaciones precisas y relevantes para los clientes. Esto se debe, en parte, a que un sistema no personalizado se basa en mostrar productos que la mayoría compra y por ende es probable que a cualquier persona le guste, en cambio el Filtro Colaborativo se basa en mostrar productos novedosos, que tienen cierta probabilidad de ser afín a los gustos de cada cliente y por lo cual influya en su decisión de compra. Sin embargo, dicho efecto solo es posible observarlo de manera empírica implementando el Filtro y evaluar resultados.




Gráfico 6. F1 - Score de las Métricas de Similitud de un Filtro Colaborativo

Por último, la métrica Coverage indica el porcentaje de clientes a los que se pueden generar recomendaciones. Dadas las diferencias de información disponible entre una versión de Filtro y otro, es esperable que tanto Coseno como Coseno Ajustado tengan peor desempeño en Coverage ya que con este tipo de algoritmos solo se puede recomendar productos a los clientes que hayan evaluado al menos 2 compras, en cambio Jaccard pudo generar recomendaciones para prácticamente todos los clientes ya que solo necesita que estos registren al menos 2 compras. Esta métrica viene a reafirmar que un Filtro Colaborativo utilizando la distancia de Jaccard es el que mejor rendimiento tiene como motor de recomendaciones.




Gráfico 7. Coverage de las Métricas de Similitud de un Filtro Colaborativo

4.3.1.4 Calidad de las Recomendaciones

Para evaluar las recomendaciones en base a los intereses del negocio, se analiza el valor promedio de éstas por cliente, es decir en que tramo (Tabla 3) se ubica el promedio del precio de los descuentos recomendados para cada cliente.

Tramo	Rango [CLP]
1	0-5.000
2	5.000-10.000
3	10.000-15.000
4	15.000-20.000
5	20.000-25.000
6	25.000-30.000
7	30.000-35.000
8	35.000-40.000
9	40.000-45.000
10	45.000 o más

Tabla 4. Rango de Valores por Tramo

Para poder comparar los valores obtenidos por cada sistema de recomendación, se exhibe primero la distribución del precio de los descuentos disponibles (grafico 8).

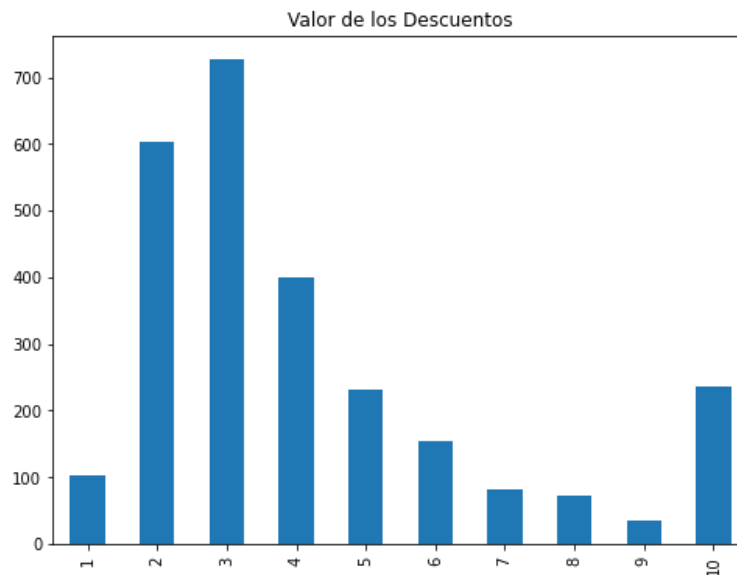


Gráfico 8. Distribución del Precio de los Descuentos Disponibles en 2022

Ahora bien, si la comparamos con la distribución generada a partir del Filtro Colaborativo Jaccard (grafico 9), se nota claramente que el valor promedio de las recomendaciones en su mayoría corresponde al tramo 3 (entre los \$10.000 y \$15.000) seguido del tramo 4 y en menor medida los tramos 5 y 6, es decir las recomendaciones van en torno a los

\$10.000 y \$30.000, lo cual tiene sentido ya que el 56% de los descuentos se encuentra entre dicho rango por lo que el valor promedio de las recomendaciones tiende a irse a estos valores.

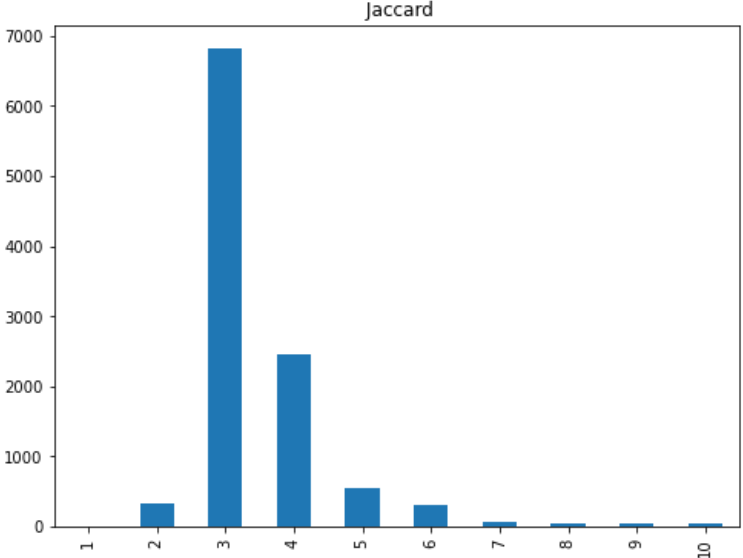


Gráfico 9. Valor Promedio de las Recomendaciones por Filtro Colaborativo - Jaccard

Otro análisis interesante es ver si se están recomendando los descuentos más vendidos, lo cual no tendría diferencia alguna con un sistema de recomendaciones No personalizado. Al observar el grafico 10, sobre frecuencia de recomendaciones versus compra, no se evidencia relación lineal alguna, lo que quiere decir que los descuentos más vendidos no necesariamente son los más recomendados, lo cual les da espacio a los descuentos menos comprados de ser exhibidos ante los clientes realmente interesados en ellos.

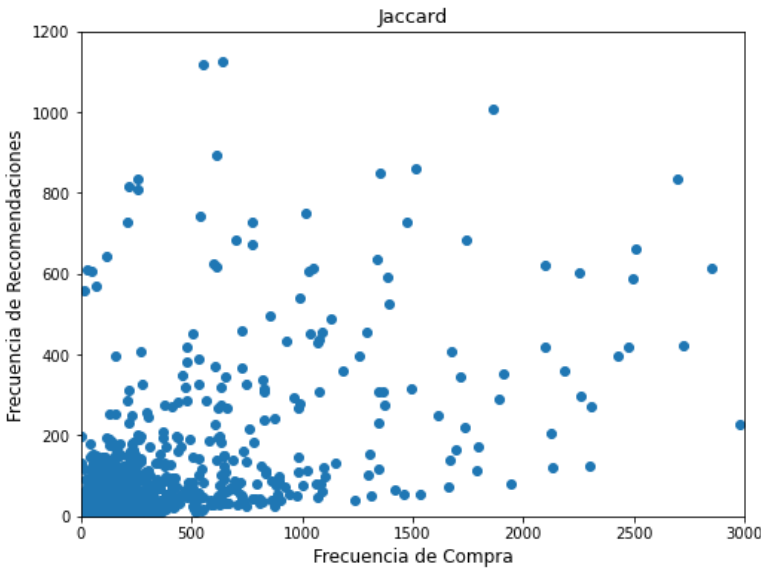


Gráfico 10. Frecuencia de compra versus recomendación de un Filtro Colaborativo – Jaccard

4.3.2 Basado en Contenido

Este segundo algoritmo se basa en encontrar similitudes entre el contenido con el que el usuario ha interactuado y la base de ítems, con el fin de encontrar los elementos más similares de acuerdo al perfil del usuario.

En este caso el contenido queda descrito o representado por una serie de *keywords* o palabras clave de cada ítem, y el perfil del cliente en base a las palabras clave de los descuentos que haya comprado. De esta forma, y mediante alguna métrica, se establecen los descuentos más similares al cliente los cuales se traducen en elementos a recomendar.

	abdomen	abdominal	abeja	abierta	abierto	abogados	absorbente	academia	academy	...	zona	zonas	zoo
id_descuento_comun													
106309	0	0	0	0	0	0	0	0	0	0 ...	0	0	0
106545	1	0	0	0	0	0	0	0	0	0 ...	0	0	0
106547	0	0	0	0	0	0	0	0	0	0 ...	0	0	0
106924	0	0	0	0	0	0	0	0	0	0 ...	0	0	0
106925	0	0	0	0	0	0	0	0	0	0 ...	0	0	0
106926	0	0	0	0	0	0	0	0	0	0 ...	0	0	0
107323	0	0	0	0	0	0	0	0	0	0 ...	0	0	0
111645	0	0	0	0	0	0	0	0	0	0 ...	0	0	0
111903	1	0	0	0	0	0	0	0	0	0 ...	0	0	0
111905	0	0	0	0	0	0	0	0	0	0 ...	1	0	0
111916	0	0	0	0	0	0	0	0	0	0 ...	0	0	0
112299	0	0	0	0	0	0	0	0	0	0 ...	0	0	0
113855	0	0	0	0	0	0	0	0	0	0 ...	0	0	0
114111	0	0	0	0	0	0	0	0	0	0 ...	1	0	0

Ilustración 6. Base Descripción del Contenido

	abdomen	accesorios	acondicionado	acondicionador	action	adornos	after	agua	aguas	aire	...	viscoelásticas	viscoelástica	white	wifi	windsor
	0	3	2	2	1	1	1	1	2	1	4 ...	1	1	2	2	2

Ilustración 7. Ejemplo de perfil de un cliente

En este sistema de recomendación, solo basta que los clientes hayan realizado una compra para poder generar recomendaciones, con lo cual no es necesario filtrar clientes y por ende se obtendrá un 100% de Coverage con cualquier métrica empleada.

4.3.2.1 Evaluación de métricas de similitud

En base a la información que se tiene, se decide utilizar como métricas de similitud el coseno y la distancia euclidiana (fórmulas 1 y 3 del *Marco Conceptual*), y al igual que en el caso anterior se generan un set de 3, 6, 9 y 12 recomendaciones por cliente para evaluar su rendimiento mediante la Precisión, Recall, F1- Score y Coverage.

Lo primero a destacar de este algoritmo es que tiene una precisión promedio del 5%, siendo superior a la de un Filtro Colaborativo (cerca de un 3%) y a la del sistema No personalizado (cerca de un 2%). Esto se debe a que las recomendaciones van en línea con lo que el cliente ya compró y por tanto es razonable pensar que seguirá teniendo gustos parecidos en el corto plazo. Lo segundo, es que si bien tiene una alta precisión cuando se tienen pocas recomendaciones (8%), esta cae rápidamente si la cantidad de recomendaciones aumenta (se llega al punto de "saturación" del cliente, donde ya no seguirá comprando las mismas cosas), a diferencia de un Filtro que si bien tiene una precisión baja esta se mantiene constante.




Gráfico 11. Precisión de las Métricas de Similitud de un SR Basado en Contenido.

En cuanto al Recall de este sistema, se observa que al utilizar el Coseno se tiene un Recall de entre 20 y 30 %, siendo incluso superior al sistema actual de recomendaciones. Sin embargo, una diferencia importante a recalcar es que la tasa de crecimiento de Recall de un sistema Basado en Contenido es menor que la de uno No personalizado que recomienda los más vendidos. Esto se traduce en que a medida que la cantidad de recomendaciones aumenta, la probabilidad de cubrir los ítems relevantes de los clientes es mayor si se recomiendan los productos más populares.




Gráfico 12. Recall de las Métricas de Similitud de un SR Basado en Contenido.

Tanto en Precisión como en Recall la métrica coseno se adapta mejor a un sistema basado en contenido, teniendo mejor rendimiento incluso que el sistema actual. De igual forma se calcula el F1-Score para una comparación final, el cual corrobora que las recomendaciones basadas en el contenido son más precisas y relevantes. Por último, cabe mencionar que, si bien ambos sistemas tienen un Coverage del 100% para estos clientes, el sistema No Personalizado puede ser utilizado con todos los usuarios (incluso aquellos que nunca han comprado en el sitio o navegan sin tener la sesión iniciada).




Gráfico 13. F1 - Score de las Métricas de Similitud de un SR Basado en Contenido.




Gráfico 14. Coverage de las Métricas de Similitud de un SR Basado en Contenido.

4.3.2.2 Calidad de las Recomendaciones

Al analizar el gráfico del valor promedio de las recomendaciones para este sistema (Basado en Contenido utilizando el coseno), se evidencia una distribución más expandida y no concentrada en el tramo 3 y 4 como lo hace el Filtro Colaborativo. Esto es más atractivo desde el punto de vista del negocio ya que las recomendaciones de mayor precio podrán ser mostradas a los clientes realmente interesados en ellas (considerando que el giro del negocio es ofrecer productos y servicios con descuentos, es complejo vender o mostrar elementos de un precio elevado).

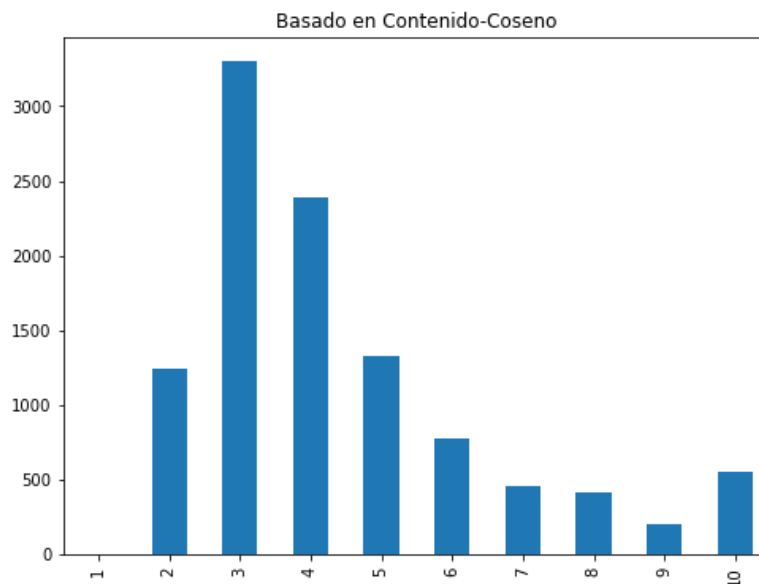


Gráfico 15. Valor Promedio de las Recomendaciones de un SR Basado en Contenido - Coseno

Al observar el gráfico de frecuencia de recomendación y compra, tampoco se evidencia relación lineal alguna, lo que indica que los descuentos más comprados no son necesariamente los más recomendados, es más, la mayoría de los descuentos (92,3%) son recomendados a menos de 200 personas lo que refleja la variabilidad de gustos que tienen los clientes de la empresa.




Gráfico 16. Frecuencia de compra versus recomendación de un SR Basado en Contenido - Coseno.

4.3.3 Sistema Híbrido

Dados los resultados de los sistemas anteriores, es claro que uno Basado en Contenido tiene mejor rendimiento en todas las métricas de evaluación (más del doble de Precisión y Recall) que un Filtro Colaborativo, con lo cual al combinarlos y hacer un sistema híbrido se espera que como modelo predictivo (al evaluarlo con las mismas métricas) tendrá un rendimiento intermedio.

Sin embargo, la ventaja de los sistemas híbridos es que aprovechan las fortalezas de cada sistema y las combinan de tal forma de conseguir resultados mejores que incluso el mejor sistema. En este caso el Basado en Contenido recomienda descuentos similares a los que ya se han visto y el Filtrado Colaborativo descuentos "novedosos" pero con una gran probabilidad de que sean de interés para el cliente. La combinación de ambos permite mayor flexibilidad a la hora de recomendar y adaptarse a los clientes (aquellos que solo quieren ver cierto tipo de descuentos o aquellos que entran a la página buscando algo nuevo). La única forma de evaluar esto es de manera empírica y en la práctica, ya que por ejemplo plataformas como YouTube cuando se tiene activada la reproducción automática, se recomienda contenido similar al principio y en cierto punto comienza a recomendar videos distintos (por filtro colaborativo) para que el usuario expanda sus

gustos o descubra nuevos intereses en base a otros usuarios que presentan un comportamiento similar.

Con lo cual probar un sistema híbrido es una decisión más estratégica de la empresa y escapa del alcance de este trabajo⁵. De todas formas, y dados los resultados de los sistemas elaborados, se sugiere experimentar con sets de descuentos donde las primeras recomendaciones sean en Base al Contenido (al menos las primeras 6 u 8) y las demás por Filtro Colaborativo, para no perder esta componente “novedosa” en las recomendaciones.

Por estas razones, y como también se observó que el sistema basado en contenido es más interesante desde el punto de vista del negocio ya que el precio promedio de las recomendaciones es mayor y su distribución es más dispersa entre los distintos tramos (abarcando así de mejor forma los diferentes tipos de clientes y sus disponibilidades a pagar por ciertos descuentos), es que se escoge este sistema para ser empleado.

⁵ No fue posible llegar a implementar un experimento con recomendaciones en la página debido a factores internos de la empresa.

4.4 Evaluación de las Recomendaciones

4.4.1 Experimento natural

Para evaluar el efecto que puede tener la implementación del sistema de recomendación elegido, se elaboró un experimento natural con el fin de evaluar el comportamiento de compra de los clientes en base a los 4 primeros descuentos que se muestran en el sitio y según cuantos de estos coinciden con las recomendaciones personalizadas de cada uno (Ilustración [8]).

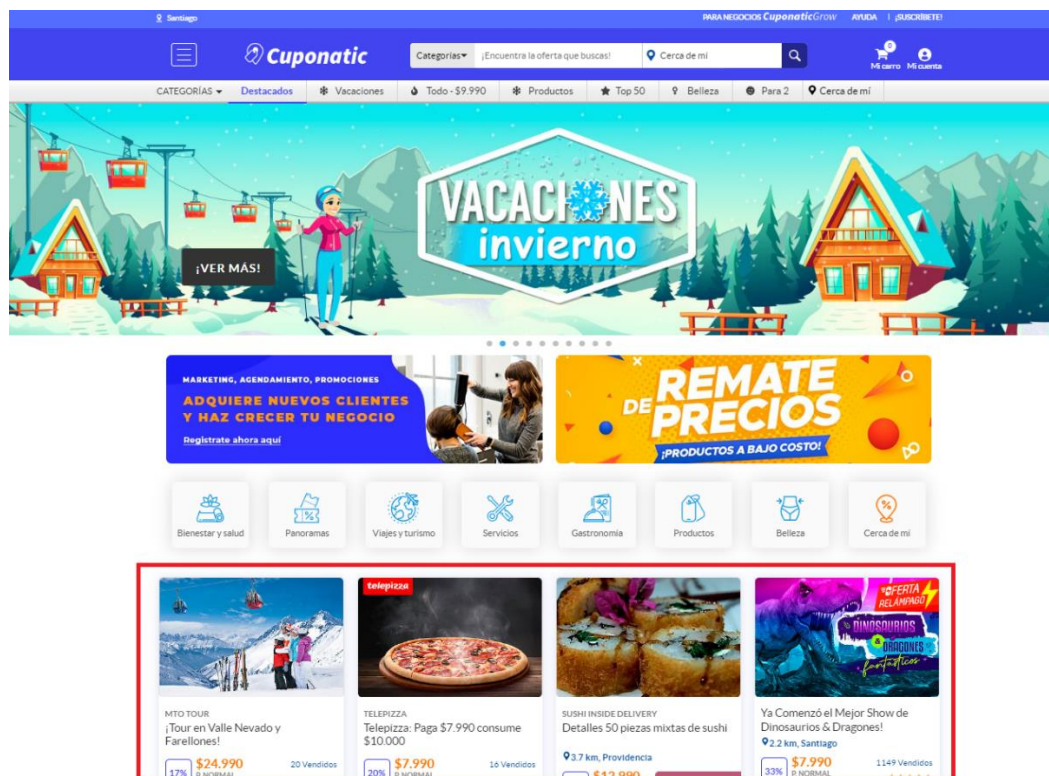


Ilustración 8. Página Principal de la Empresa donde se marcan los Descuentos para el Experimento.

El experimento consistió en registrar durante 2 semanas a los clientes que entraban cada día con la sesión iniciada⁶, las compras, y los primeros 4 descuentos de la página a los cuales estuvieron expuestos dicho día (cualquier cliente que entra a la página ve estos descuentos, no así los que están por debajo puesto que se requiere navegar por la página, lo cual no ocurre con total certeza).

⁶ Se seleccionaron solo a estos clientes ya que es la única forma de identificarlos y hacerles seguimiento.

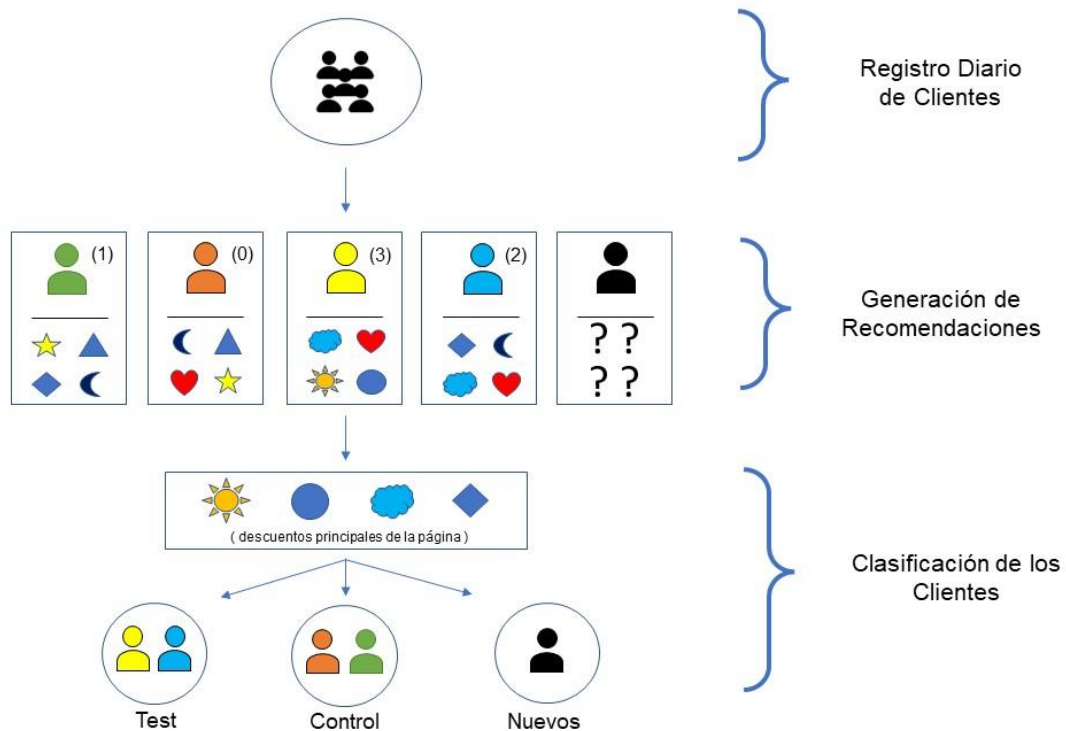


Ilustración 9. Experimento Natural. Clasificación de los clientes. Elaboración Propia.

Los clientes se separan en 3 grupos: “Nuevos”, aquellos que no registraban ninguna compra previa al experimento o su cuenta fue creada durante este, “Control”, aquellos que registraban al menos una compra y la categoría de las recomendaciones coincidían con 0 o 1 descuento de los 4 y “Test”, aquellos que registraban al menos una compra y las recomendaciones coincidían con 2 o 3 descuento (el caso ideal, 4, solo ocurrió una vez durante el experimento). El proceso de clasificación se muestra en la ilustración 9.

La evaluación consistió en comparar las tasas de conversión de cada grupo y en analizar la efectividad de las recomendaciones en las compras de los clientes. Se espera que el grupo de Test obtenga una mejor tasa de conversión que el grupo de Control y a su vez que las compras del primer grupo hayan sido recomendadas por el sistema. Es importante mencionar que la evaluación se realizó a nivel de las categorías (65 en total) y no de descuentos específicos, ya que la probabilidad de que coincidieran exactamente los descuentos de la página con los recomendados por el sistema para cada cliente es muy baja.

4.4.2 Resultados

Durante el periodo del experimento, se registraron 11.406 clientes con un promedio diario de 815 sesiones. En el grafico 17 se observa la cantidad total de clientes por día, diferenciados por grupo, y en la tabla 5 se muestra el porcentaje de clientes por grupo donde se destacan aquellos días donde el grupo de test representa más de un 10% del total. En 6 de los 14 días se tiene un porcentaje considerable del grupo test para analizar y comparar resultados.




Gráfico 17. Cantidad de clientes por grupo durante el periodo experimental.

Día	1	2	3	4	5	6	7	8	9	10	11	12	13	14
Nuevos	32%	31%	31%	35%	45%	45%	50%	42%	41%	43%	44%	47%	45%	86%
Grupo Control	48%	56%	62%	50%	48%	54%	45%	39%	58%	56%	55%	35%	33%	8%
Grupo Test	20%	13%	7%	15%	7%	1%	5%	19%	1%	1%	1%	18%	22%	6%

Tabla 5. Porcentaje de clientes por grupo durante el experimento.

En el gráfico 18 se muestra la tasa de conversión diaria y diferenciada por grupo, donde en todos los días en que el grupo de test representa un porcentaje significativo de los clientes (más de un 10% del total diario) la tasa de conversión es mayor (en promedio cerca de un 10% más). Este resultado es acorde a lo esperado, ya que si los clientes entran a la página y ven inmediatamente productos de su interés es más probable que naveguen un tiempo por el sitio y finalmente se traduzca en una compra. Caso contrario a si un cliente entra y su primera impresión de la página es que nada le llame la atención; es probable que el cliente cierre la página o navegue poco por el sitio.




Gráfico 18. Tasa de conversión diaria por grupo durante el periodo experimental.

Ahora bien, para analizar de mejor forma el efecto de las recomendaciones en la tasa de conversión del grupo de test, se elabora el grafico de efectividad de las recomendaciones que indica el porcentaje de compras que fueron recomendadas ese día, es decir si la categoría de la compra del cliente coincide con alguno de los 4 primeros descuentos y a su vez este fue sugerido por el sistema de recomendación.

Durante el periodo experimental las recomendaciones tuvieron incidencia en el 66% de las compras del grupo test, es decir la recomendación de productos o servicios afines a las preferencias de los clientes incide en 2 de cada 3 compras. Si se acota el análisis a los días en que el grupo test representa cerca del 20% de clientes (días 1, 8, 12 y 13), las recomendaciones incidieron en más del 90% de las compras en prácticamente todos los días. Con lo cual se concluye que, de implementarse este sistema de recomendación, se podría observar un aumento en la tasa de conversión de los clientes lo que se traduce en un aumento en las ventas.




Gráfico 19. Efectividad de las recomendaciones en las compras de los clientes.

4.5 Plan de Implementación

4.5.1 Ejecución del Sistema de Recomendaciones

En primer lugar, se debe implementar el sistema de recomendaciones personalizado en la plataforma web, por lo cual es el área de T.I. la encargada de esta parte del proceso pues es la que da soporte a la página velando por su correcto funcionamiento; realizando los cambios correspondientes de contenido y funcionalidades. Para ello deberá reprogramar el código de la página para incorporar las recomendaciones personalizadas.

En cuanto a la ubicación de las recomendaciones, se sugiere incorporar un botón en la barra de secciones de la página principal que redirija a los clientes a otra página donde encontrarán sus recomendaciones. Esta ubicación es llamativa para los clientes y a su vez no es invasiva en el diseño de la página; de esta forma los clientes siempre podrán ver que hay una sección personalizada para ellos.

Si por algún motivo (técnico, decisión de la empresa, tiempo) no es posible implementar la primera opción, se sugiere una segunda ubicación debajo de los 16 descuentos principales del día donde los clientes tendrían que navegar un poco por el sitio para poder ver sus recomendaciones. La ventaja de esta opción es que su implementación es más sencilla, pero la desventaja es que la evaluación se dificulta bastante ya que se requieren herramientas de analítica web para identificar los clientes que efectivamente ven las recomendaciones, no así la primera opción donde el seguimiento se realiza por el accionar de un botón. En la ilustración 9 se observa un bosquejo de la disposición de la página principal de la empresa y las 2 opciones para implementar las recomendaciones.



Ilustración 10. Diseño de la distribución del sitio web destacando las 2 opciones para ubicar las recomendaciones personalizadas.

A fin de establecer causalidad entre el sistema de recomendación y el efecto esperado, se realiza un diseño experimental consistente en un A/B test utilizando un enfoque frecuentista para evaluar resultados [5].

Esto quiere decir que, al implementar las recomendaciones, en una primera etapa, se mostraran dos versiones de la página a dos grupos distintos de clientes: la que existe actualmente (A) y otra en la que se incorporen las recomendaciones (B), generando así un grupo de control (A) y otro de tratamiento (B).

La asignación de clientes a los grupos de control y tratamiento en un experimento en línea se realiza de manera aleatoria a medida que ocurre el experimento, ya que a priori no es posible saber quién entrará al sitio. Con esto se originan muestras independientes de clientes, donde las variables observables y no observables se espera tengan igual distribución debido a la asignación aleatoria y la única diferencia entre grupos sea el tratamiento (mostrar recomendaciones personalizadas).

Al utilizar el enfoque frecuentista, se establece como hipótesis nula “implementar un sistema de recomendaciones personalizado al sitio web no tendrá ningún efecto en la tasa de conversión de los clientes” y por tanto la hipótesis alternativa es que si se aprecia un efecto en la tasa de conversión.

Para determinar el tamaño de muestra necesario y los días en que se logra, se realiza un análisis de poder estadístico considerando un nivel de significancia del 5%, un poder estadístico del 80%, igual tamaño entre los grupos y un test *t* de una cola. También, en base a los resultados del experimento natural, se considera una tasa de conversión base de 37,6% y un promedio diario de 490 clientes que pueden participar de la evaluación (el sistema puede generar recomendaciones). Con estos datos se genera la siguiente tabla:

Aumento esperado	N (tamaño muestral)	Días
1,0%	17.481	73
1,25%	11.188	47
1,5%	7.769	32
1,75%	5.708	24
2,0%	4.371	18
2,25%	3.453	14
2,5%	2.797	12
3,0%	1.943	8
Tasa de Conversión Base		37,6%

Tabla 6. Tamaño muestral y tiempo en que se alcanza.

De la tabla 6 se observa que mientras menor es el aumento esperado en la tasa de conversión, se necesita un tamaño muestral mayor y por consiguiente un periodo experimental más largo. Como no es factible para la empresa destinar recursos durante tanto tiempo, se sugiere realizar el experimento durante 18 o 24 días, para concluir sobre un aumento en la tasa de entre un 1,75 y 2%. Cabe recalcar que un aumento de 1,75% en la tasa de conversión, se traduce en un aumento del 4,6% en las ventas (demostración en el anexo C).

El área de B.I. estará a cargo de la evaluación y análisis de los resultados de este experimento, pues son ellos quienes manejan las bases de datos y generan los reportes de rendimiento de la empresa en general, sin embargo, es el área de T.I. la que debe programar este experimento asignando de manera aleatoria las distintas versiones de la página a los usuarios. Si pasado el tiempo experimental los resultados no son concluyentes, se detectan errores de procedimiento, en la calidad de los datos o cualquier otro problema relacionado con el experimento, el área de B.I. debe solicitar repetir el experimento a fin de obtener resultados concluyentes y confiables.

Algunas métricas complementarias para evaluar la efectividad del sistema, suponiendo que se ha optado por la opción 1 para ubicar las recomendaciones, son la tasa de clics en la sección “mis recomendaciones”, tasa de conversión post-clic (habiendo entrado a

la sección), monto promedio gastado por sesión y post-clíc, y la efectividad de las recomendaciones (compras que fueron recomendadas).

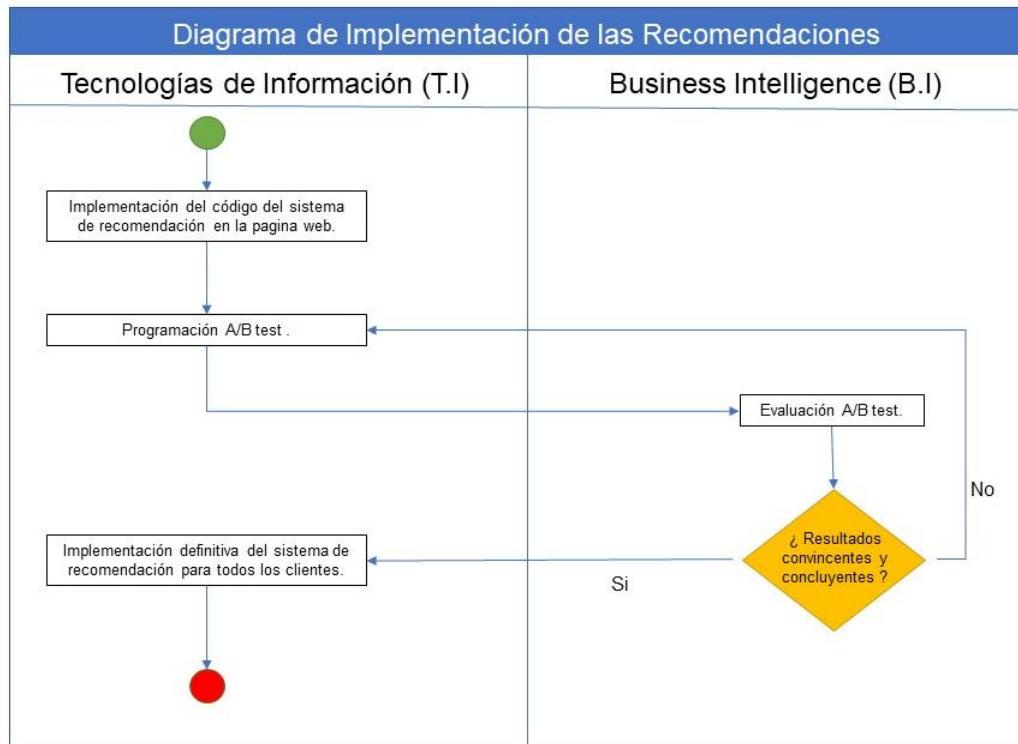


Ilustración 11. Diagrama de Flujo del Proceso de Implementación del Sistema de Recomendaciones.

4.5.2 Recomendaciones al Negocio

Una vez realizado el trabajo de memoria, se detallan algunas observaciones como sugerencias para la empresa. La primera es buscar mecanismos para instar a los clientes a evaluar los descuentos ya que eso les brinda información explícita y de calidad acerca de las preferencias de sus clientes, por lo cual se puede mejorar el grado de precisión de los algoritmos de recomendación.

La segunda es contar con un formulario o similar donde los clientes expresen sus preferencias, por ejemplo, donde se pueda dar a conocer que se está más interesado en los servicios de masaje, los productos de hogar y tecnológicos, de esa forma se podrían elaborar algoritmos en base al conocimiento o enriquecer los ya propuestos en este trabajo.

Por último, se sugiere guardar el historial de los últimos n descuentos vistos por los clientes ya que esta información se relaciona directamente con las preferencias en tiempo

real de las personas y por lo tanto se puede utilizar para realizar recomendaciones más certeras.

Siguiendo estas recomendaciones, se puede plantear el desarrollo de sistemas más complejos de recomendaciones de aprendizaje automático.

5. CONCLUSIONES

Este trabajo abre la posibilidad de implementar en la página web de la empresa una función que la mayoría de los ecommerce medianos y grandes poseen: un sistema de recomendación personalizado, permitiendo adaptar el contenido que se ofrece a cada cliente según sus preferencias y cuyo éxito incidiendo en el aumento de ventas o tasas de conversión ha sido probado en numerosos casos (como se ha documentado a lo largo de este informe).

El objetivo del proyecto era desarrollar alternativas de recomendación al sistema actual no personalizado y evaluar la venta incremental de aquellas alternativas, para lo cual se elaboraron 2 principales sistemas: un Filtro Colaborativo y uno Basado en Contenido.

El primer sistema se plantea como opción para ofrecerle productos novedosos a los clientes y con alta probabilidad de que sean de su interés. Al no contar con una cantidad de datos óptima de los clientes, el sistema no obtuvo los resultados esperados ya que al tener información limitada el Filtro Colaborativo pierde precisión, por lo cual obtuvo un rendimiento menor al sistema No personalizado en cuanto a métricas de evaluación.

El segundo sistema se propone como alternativa para recomendar productos similares a los gustos de cada clientes, es decir se busca reforzar los actuales intereses de ellos. Como en este sistema lo esencial es contar con una base de datos robusta en información de los productos que se ofrecen, se pudieron generar recomendaciones más precisas y por tanto obtuvo un mejor rendimiento que el sistema No personalizado en todas las métricas de evaluación.

Adicionalmente se planteó la elaboración de un sistema híbrido en base a los 2 anteriores, no obstante, el Basado en Contenido tuvo un rendimiento tal que al combinarlo con un filtro colaborativo solo disminuiría. Sin embargo, esta forma de recomendar busca aprovechar las ventajas de ambos sistemas, al mismo tiempo que cubre los puntos débiles de cada uno y así obtener un rendimiento incluso mejor que el mejor de los sistemas. Este efecto solo es posible observarlo de manera empírica y por lo cual se deja planteada una eventual experimentación con un sistema híbrido a fin de evaluar cómo se comportan los clientes ante el contenido novedoso de un filtro colaborativo combinado al semejante de uno basado en contenido.

Se concluye en base a métricas de evaluación de predicción de compra y un análisis de las recomendaciones en base a los intereses del negocio, que el sistema Basado en Contenido es el más óptimo para la empresa, siendo sus principales ventajas recomendar contenido similar al que los clientes ya han mostrado cierta preferencia, generar recomendaciones a todos los clientes que registren al menos una compra, la capacidad de sugerir productos o servicios que son nuevos en la página y la posibilidad de mostrarle los productos de mayor precio a los clientes con mayor interés ellos y con mayor probabilidad de comprarlos.

Como estos algoritmos son de recomendación y no de predicción de compra, se elabora un experimento natural para evaluar el efecto que puede tener la implementación del sistema elegido. Durante el experimento, los clientes expuestos a un contenido más afín a sus preferencias mostraron una mayor tasa de conversión que el grupo de control (cerca de un 10% más) y al observar detenidamente las compras del grupo de test, se concluye que las recomendaciones inciden en 2 de cada 3 compras. Con lo cual de ponerse en marcha este sistema se espera un efecto incremental en las ventas.

Finalmente se elabora el plan de implementación del sistema de recomendación con su respectivo diseño experimental de A/B test para la evaluación, con el fin de encontrar diferencias estadísticamente significativas entre el grupo de control y tratamiento. Se espera encontrar un aumento del 2% en la tasa de conversión lo cual llevaría a un aumento del 4,6% en las ventas de la empresa. Dada la escala del negocio en cuanto a clientes y descuentos ofrecido, se concluye que un algoritmo básico de recomendaciones como el propuesto en este trabajo es suficiente para encontrar resultados positivos en las principales métricas de rendimiento de la empresa.

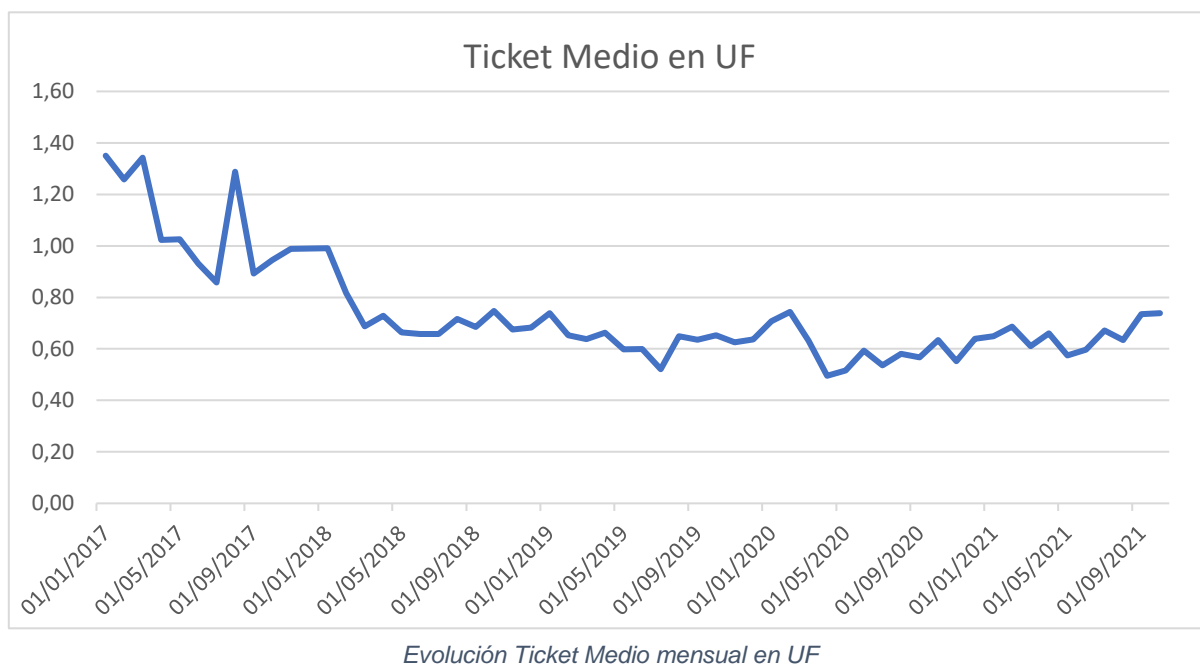
BIBLIOGRAFÍA

- [1] Eldridge, Alison. (2021,23 diciembre) *Groupon*. Enciclopedia Británica. <https://www.britannica.com/topic/Groupon>.
- [2] Ian MacKenzie, Chris Meyer, and Steve Noble (2018, 14 febrero). *How retailers can keep up with consumers*. Recuperado de: <https://www.mckinsey.com/industries/retail/our-insights/how-retailers-can-keep-up-with-consumers>.
- [3] Cámara de Comercio de Santiago (2021, 23 abril). *CCS proyectó ventas online de US\$11.500 millones este año*. <https://www.ccs.cl/2021/04/23/ccs-proyecto-ventas-online-por-mas-de-us11-500-millones-este-ano/>.
- [4] Frederick F. Reichheld and W. Earl Sasser, Jr. (1990). *Zero Defections: Quality Comes to Services*
- [5] Rodrigo López (2020). *Diseño y Evaluación experimental de un sistema de recomendación de productos para un sitio de comercio electrónico*.
- [6] Paloma Pérez (2016). *Recomendaciones en Tiempo Real Mediante Filtrado Colaborativo Incremental y Real-Time Big Data*.
- [7] Sergio Galán (2017). *Filtrado Colaborativo y Sistemas de Recomendación*.
- [8] G. Mendoza, Y. Laureano, M. Pérez (2019). *Métricas de Similitud y Evaluación para Sistemas de Recomendación de Filtrado Colaborativo*.
- [9] Saavedra, Juan (2017, 15 noviembre) *Sistemas de recomendación, parte 4: métricas de evaluación*. Medium. Recuperado de: <https://medium.com/@eng.saavedra/sistemas-de-recomendaci%C3%B3n-parte-4-evaluaciones-cfd1f96b887a>
- [10] P. Chapman, J. Clinton, R. Kerber, T. Khabaza, T. Reinartz, C. Shearer, R. Wirth (2000). *CRISP-DM 1.0: Step-by-step data mining guide*.

ANEXOS


Anexo A: Ticket Medio en UF

Al llevar el gráfico de Ticket Medio al valor de la uf mensual se evidencia más su estancamiento; en los últimos 4 años oscila entre las 0.6 y 0.8 UF, muy lejos de las 1,1 que promediaba en 2017.

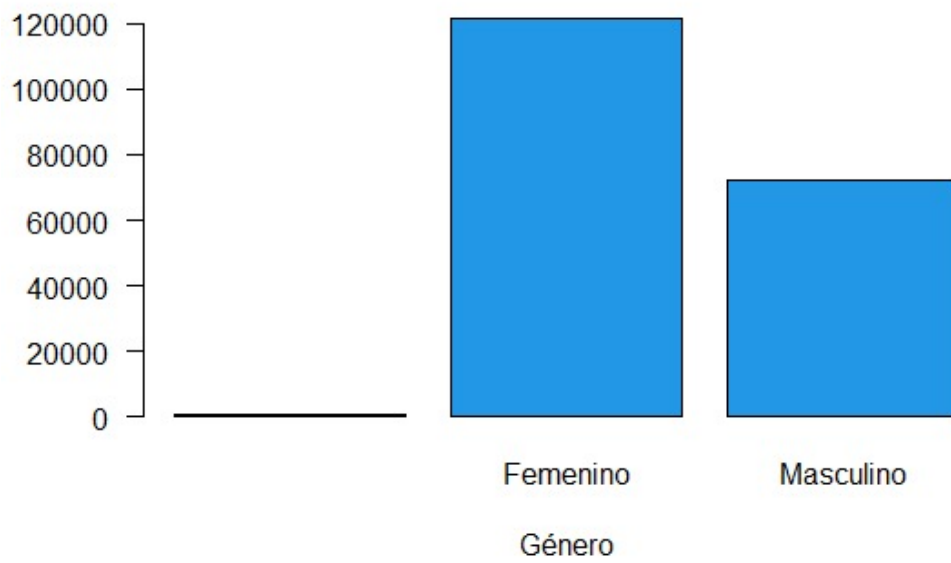


Anexo B: Análisis Exploratorio de datos


La caracterización de los clientes corresponde en su mayoría al segmento de jóvenes y adulto-joven entre 25 y 40 años (49%), residentes de Santiago (85%) y de género femenino principalmente (2 de cada 3 clientes).



Distribución etaria de los clientes.




Distribución del género de los clientes.

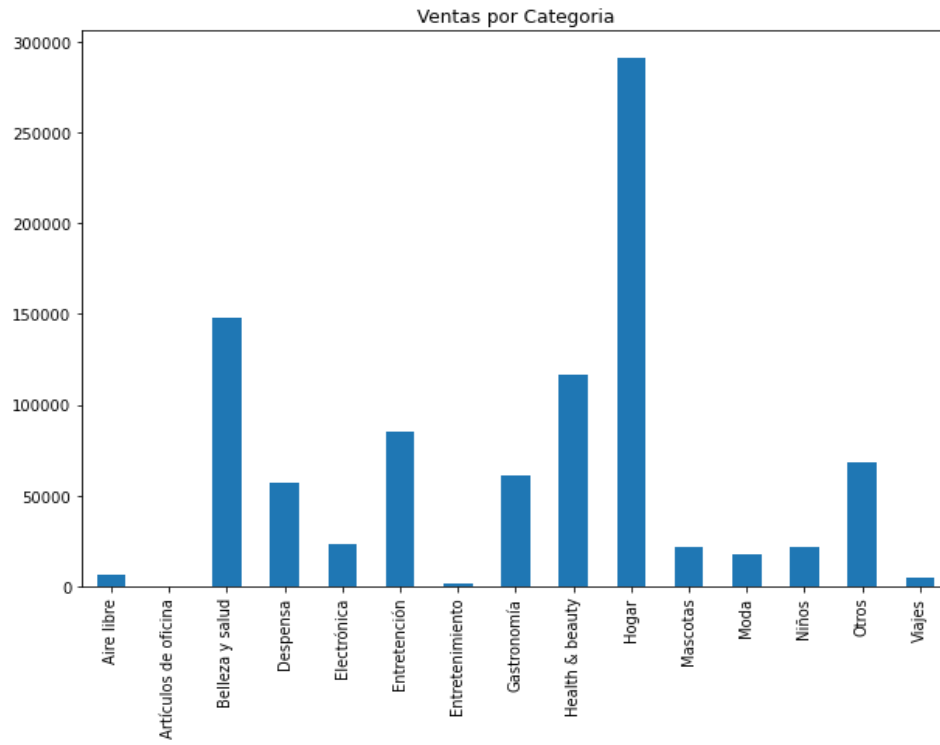


Distribución de la ciudad de residencia de los clientes.


Existe una relación lineal de oferta – venta en las categorías de primer nivel de los descuentos, es decir a mayor cantidad de descuentos mayor cantidad de ventas registra esa categoría. Las categorías con mayor presencia (oferta) son: Hogar, “Health & Beauty” y “Belleza y Salud”, siendo las con más ventas, en orden: Hogar, “Belleza y Salud” y “Health & Beauty”.



Análisis Oferta -Venta de los descuentos.




Distribución de las Ventas por categoría.



Distribución de la Oferta por categoría.

El rating es la única información explícita de los gustos del cliente en la base de datos. Su distribución está muy desbalanceada hacia los puntajes 9 y 10, por lo que en general la gente califica cuando un descuento es muy de su preferencia. Si bien el 7% corresponde a un puntaje de 1 se debe principalmente a problemas con las condiciones de los cupones (esto se da en los servicios cuando por ejemplo es válido para ciertas horas del día y el cliente va en otro horario) y no porque realmente el descuento sea de total desagrado.



Histograma de las calificaciones de las compras.

Rating	Frecuencia	Porcentaje
1	19.924	7%
2	1.578	1%
3	6.835	3%
4	2.355	1%
5	16.562	6%
6	2.499	1%
7	25.928	10%
8	8.091	3%
9	139.702	52%
10	47.162	17%
Total	270.636	100%

Detalle Distribución Rating

Anexo C: Demostración Venta Incremental

El ingreso diario actual de la empresa se puede expresar de la siguiente forma:

$$Ingreso = N \cdot tc \cdot G$$

Donde N es el numero de clientes diarios que entran a la página, tc la tasa de conversión de los clientes y G el gasto promedio de los clientes.

Por lo que para aumentar el ingreso se puede atraer a más clientes, hacer que estos gasten más o aumentar la tasa de conversión en consumidores. En este caso se propone un aumento del 1,75% en dicha tasa, la cual es de un 37,6% actualmente. Por lo que la venta incremental de la empresa sería:

$$Venta Incremental = \frac{\Delta I}{I} = \frac{N \cdot tc_2 \cdot G - N \cdot tc_1 \cdot G}{N \cdot tc_1 \cdot G}$$

Simplificando y reemplazando los valores de las tasas de conversión:

$$Venta Incremental = \frac{tc_2 - tc_1}{tc_1} = \frac{39,35\% - 37,6\%}{37,6\%} = \frac{1,75\%}{37,6\%} = 4,6\%$$