



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

**EVALUACIÓN EXPERIMENTAL DE SISTEMA DE RECOMENDACIÓN PARA  
CAMPAÑAS DE EMAIL MARKETING**

**MEMORIA PARA OPTAR AL TITULO DE INGENIERO CIVIL INDUSTRIAL**

IGNACIO ARTURO LETELIER CHALMERS

PROFESOR GUÍA:  
MARCEL GOIC FIGUEROA

MIEMBROS DE LA COMISIÓN:  
LUIS ABURTO LAFOURCADE  
CAROLINA NAVARRETE CAEROLS

SANTIAGO DE CHILE  
2017

## **EVALUACIÓN EXPERIMENTAL DE CAMPAÑAS DE EMAIL MARKETING UTILIZANDO SISTEMAS DE RECOMENDACIÓN**

Una tendencia creciente dentro de la industria del retail es la de personalizar la experiencia de compra de los consumidores, y en términos de campañas de marketing, eso se traduce en poder generar estrategias de comunicación que estén pensadas en el cliente que las recibe. Es por ello que han tomado fuerza estrategias de comunicación activadas por acciones de los mismos clientes, pues estas acciones identifican oportunamente comportamientos claves del cliente, y a partir de ellos se pueden generar ofertas o promociones acordes. Este trabajo generará y evaluará distintas estrategias para lograr este objetivo. Específicamente, se identificará a clientes que durante un periodo de tiempo hayan comprado ciertos tipos de productos ligados al hogar, se les enviará un correo recomendándoles seguir equipando su casa, incentivando que compren otros productos de la tienda a través de cualquiera de sus canales

En este trabajo se evalúan tres estrategias para generar comunicaciones automáticas. En primer término, se evaluará la implementación de un algoritmo de recomendación basado en filtros colaborativos, luego se considerará el uso de reglas de asociación, y finalmente ambos sistemas de recomendación se compararán a una implementación en que solo se ofrecen categorías de manera genérica invitando al cliente a navegar dentro del sitio web. Las estrategias implementadas se evalúan experimentalmente de forma de conocer por medio de las cuáles se puede construir más valor para la compañía y para el cliente.

Los resultados de este estudio sugieren que en términos absolutos los filtros colaborativos generan más venta incremental que las demás estrategias propuestas. Pero al descomponer a nivel de categoría se concluye que los filtros colaborativos solo funcionan considerablemente mejor para el caso de los productos de línea blanca, ya que en el caso de los productos de muebles y decoración las reglas de asociación y la estrategia genérica mostraron resultados que superaban a los filtros colaborativos. Estas diferencias se explican principalmente por el tipo de productos que cada lógica de recomendación le ofrece a los clientes, ya que, las reglas de asociación tiende a recomendar productos que son de menor frecuencia de compra y de mayor precio que los filtros colaborativos que tienen a recomendar los productos más populares dentro de una comunidad de clientes con preferencias similares.

# Agradecimientos

No podría partir sin agradecer a mi Madre, a mi Hermana, y a mi Polola, quienes sin duda han sido parte importantísima de este proceso, apoyándome de distintas formas y estando conmigo en las distintas etapas. A mis mujeres más preciadas les estaré siempre agradecido por eso, y por mucho mucho más. Las amo.

En segundo lugar no puedo dejar de agradecer a mis mejores amigos de Pirque y de la Universidad, ustedes son los que llenaron de vida todos estos años de aprendizaje, le dieron alegría a mis peores momentos, e hicieron inolvidables los mejores.

Eduardo, Cristian, Julio, les agradezco la paciencia, el apoyo, y los buenos momentos, porque aunque fuera a la distancia, yo siempre supe que estaban ahí.

Ana, Belen, Catalina, no sé qué habría sido de mi estadía en la universidad si no las hubiera conocido, me siento un privilegiado de ser su amigo.

Katherine, si me pusiera a escribir todas las cosas de las que debo estar agradecido, jamás terminaría. Gracias por todo.

Por otro lado no puedo dejar pasar mis agradecimientos a Carolina Navarrete, quien me abrió las puertas para desarrollar un proyecto desafiante, interesante y entretenido, gracias por creer en mí y por darme todas las herramientas y facilidades que necesité. Me siento muy afortunado habiendo tenido una tutora y una jefa como tú.

Por último, pero en ninguna medida menos importante, agradecer a mis profesores Marcel Goic y Luis Aburto por sus comentarios asertivos, por sus ganas de enseñar, por hacerme mejorar en cada presentación, y por una disposición de oro pese a que estoy seguro, tener reuniones conmigo no debe haber sido la mejor manera de gastar su tiempo. Ustedes son docentes que tienen una pasión por enseñar a otros, y eso es algo que los que estamos en este lado, valoramos mucho.

# Tabla de contenido

EVALUACIÓN EXPERIMENTAL DE CAMPAÑAS DE EMAIL MARKETING UTILIZANDO SISTEMAS DE RECOMENDACIÓN .....	i
Agradecimientos .....	ii
Tabla de contenido .....	iii
Índice de Ilustraciones .....	v
1. Introducción .....	6
2. Descripción del Proyecto.....	7
3. Objetivos .....	10
3.1. Objetivo General.....	10
3.2. Objetivos Específicos .....	10
4. Alcances.....	11
5. Marco conceptual.....	12
5.1. Sistemas de recomendación .....	12
5.1.1. Reglas de asociación.....	14
5.1.2. Filtros Colaborativos.....	15
5.2. Fase experimental.....	17
5.2.1. Aleatorización.....	17
6. Metodología .....	19
6.1. Entrenamiento .....	22
6.2. Implementar algoritmos de recomendación.....	25
6.3. Desarrollo de plantillas dinámicas.....	26
6.4. Ejecución de los experimentos .....	26
6.5. Evaluación de resultados .....	27
7. Desarrollo de metodología .....	29
7.1. Tratamiento preliminar de datos.....	29
7.2. Entrenamiento de los modelos.....	33
7.2.1. Reglas de asociación.....	33
7.2.2. Filtros colaborativos .....	35
7.3. Generación de las recomendaciones en plantillas dinámicas.....	37
7.4. Desarrollo de los experimentos.....	40
7.5. Evaluación de resultados .....	42
7.5.1. Evaluación Venta Incremental Promedio a nivel Global .....	42

7.5.2.	Evaluación Venta Incremental Promedio para Línea Blanca .....	44
7.5.3.	Evaluación Venta Incremental Promedio para Muebles.....	45
7.5.1.	Análisis de tasas de Click y Apertura .....	46
7.5.2.	Análisis de venta incremental por cliente .....	46
7.5.3.	Análisis de temporalidad .....	47
7.5.4.	Evaluación Multicanal Venta Incremental a nivel Global.....	49
8.	Conclusiones .....	50
9.	Trabajos futuros .....	51
	Anexos.....	52
	Bibliografía .....	55

# Índice de Ilustraciones

Ilustración 1 - Ejemplo de filtro colaborativo.....	16
Ilustración 2 - Aleatorización entre grupos .....	17
Ilustración 4 - Atributos que describen la línea Comedor .....	20
Ilustración 5 - Las 5 fases de la Metodología.....	22
Ilustración 6 - Grupos de trabajo para la experimentación .....	27
Ilustración 7 - Atributos que describen a la categoría Refrigeración.....	29
Ilustración 8 - Porcentaje de clientes versus cantidad de transacciones que realizan ...	32
Ilustración 9 - Participación del grupo excluido en ventas y transacciones .....	32
Ilustración 10 - Fases de implementación de Filtros Colaborativos .....	35
Ilustración 11 - Envío según Filtros Colaborativos (izquierda) y Reglas de Asociación (derecha).....	39
Ilustración 11 - Template Mail Genérico .....	41
Ilustración 12 - Venta Incremental Promedio según tipo de Envío, Global.....	42
Ilustración 14 - Venta Incremental Promedio según tipo de Envío, Línea Blanca .....	44
Ilustración 15 - Venta Incremental Promedio según tipo de Envío, Muebles .....	45
Ilustración 16 – Respuesta del Grupo Mail (GM) según el periodo entre activación y envío .....	48
Ilustración 17 - Respuesta del Grupo Apertura (GO) según el periodo entre activación y envío .....	48
Ilustración 18 - Venta Incremental a nivel Global según línea Transada y Canal de venta .....	49

# 1. Introducción

El *retail* engloba a todos aquellos negocios que se dediquen a la venta al detalle o minorista, incluyendo a grandes cadenas de tiendas dedicadas a comercializar vestuario, medicamentos, abarrotes e incluso materiales de construcción o mejoramiento del hogar. Además las tiendas poseen diferentes formatos, según la amplitud y profundidad del surtido que ofrecen, distinguiéndose tiendas especialistas, tiendas por departamento, hipermercados o supermercados entre otras. La industria del *retail* representa uno de los sectores productivos más importantes de Chile, siendo la tercera industria que más aporta al producto interno bruto del país, después de la minería y la banca.

En particular, las tiendas por departamento, generan ventas por sobre los 14 mil millones de pesos anuales, existiendo 5 competidores locales importantes [1]. En el último tiempo, la competencia ha crecido fuertemente debido a la entrada de diversas cadenas internacionales, como *Forever 21*, *H&M* y *Top Shop*, en vestuario o *Zara Home* en decoración del hogar. Además existe la amenaza latente de que grandes retailers globales como *Amazon* o *Alibaba* consoliden su posición en Latinoamérica, donde sólo han incursionado tímidamente.

La industria es tan competitiva, que las empresas han debido implementar nuevas formas de comunicarse con sus clientes, de manera de mantenerlos fidelizados y conscientes de las oportunidades que se les ofrecen. Como consecuencia, uno de los canales de comunicación preferidos para hacer marketing directo es el correo electrónico, debido a que este medio puede ser utilizado para personalizar la comunicación que se tiene con cada cliente, de forma de seleccionar que mensaje se le ofrece a cada persona, y así, dar a conocer aquellas apuestas, ofertas o beneficios solamente a aquellos clientes que podrían estar interesados. Una dificultad que enfrenta este tipo de campañas, es que muchas veces son utilizadas como un medio de comunicación masiva, y que por lo tanto entregan un mensaje estandarizado a la población a la que va dirigido, lo que deriva en una baja tasa de aceptación y baja tasa de lectura por parte del público objetivo.

Este trabajo de título intentará evaluar la implementación de campañas de email marketing personalizadas con una componente característica, ya que serán campañas de trigger marketing que tendrán como objetivo generar venta cruzada. Por un lado trigger marketing hace referencia a las campañas de marketing directo que se gatillan por eventos o acciones particulares que realiza el cliente y que son captados por la empresa de retail como una oportunidad para ofrecer productos y servicios. Algunos ejemplos de acciones interesantes y que podrían dar luces de necesidades y deseos de los clientes podrían ser la inscripción en alguno de los 7

clubes de fidelización, como son los clubes para Novios y/o Recién nacidos, la compra de artículos durables de alto valor económico como camas y/o refrigeradores, la navegación en internet de productos específicos, la presencia física de un cliente cerca de una tienda o incluso dentro de ella en un área en particular, el aumento o disminución significativo en el gasto de un cliente en un periodo de tiempo, la compra de productos que son necesarios de manera periódica como cremas y lociones para el cuidado personal, entre muchos otros ejemplos.

Para este caso en particular, se explorará el trigger de compras de bienes durables, bajo el supuesto de que la compra de estos artículos podría dando luces de otras necesidades del cliente, ya que los clientes podrían estar comprando bienes durables ante la necesidad de vestir un nuevo hogar, o la remodelación de un espacio ya existente. Con esto, la compra de productos como línea blanca o muebles podrían estar otorgando un insight sobre que otros elementos el cliente podría estar interesado en comprar. En otras palabras, lo que se pretende es ofrecerle a un cliente que compró un producto específico, un grupo de artículos que podrían complementar esa compra. Este tipo de campañas tiene como objetivo generar venta incremental promoviendo ventas cruzadas, y el proyecto tiene por objetivo medir la efectividad de la acción.

## 2. Descripción del Proyecto

Por otro lado, la era digital ha entregado un conjunto de herramientas comunicacionales que permiten generar una experiencia lo más personalizada posible, intentando ofrecer el producto apropiado al cliente correcto en el momento adecuado, aumentando con ello, la probabilidad de que el cliente realice la compra en la empresa y no en alguna tienda de la competencia [2].

Es por esto, que las empresas han comenzado a desarrollar estrategias de venta y de marketing, basadas en *triggers*, o en acciones que los clientes realizan, que se traducen en una respuesta comunicacional por parte de la empresa. A modo de ejemplo, Amazon, exitosa empresa de la industria, genera cerca del 35% de sus ingresos utilizando estrategias de venta cruzada, es decir, haciendo recomendaciones asertivas de productos a personas que ya compraron o están comprando algún artículo [3].

Estos resultados son bastante llamativos para otras empresas del mundo del *retail*, que ven de manera auspiciosa el hecho de poder aumentar sus ventas a través de la implementación de más y mejores recomendaciones para sus clientes. La dificultad surge cuando el sistema de recomendación se debe implementar en una cadena de *retail* que trabaja con el formato de tiendas por departamento, y que además genera el 90% de sus ventas en tiendas físicas y no por medios online.

Para resolver este problema, se desea implementar campañas de marketing a través de correos electrónicos, que en primer lugar, sean gatilladas por compras específicas de los clientes, y que además, tengan un contenido personalizado para cada persona, ofreciéndole un conjunto de productos que complementen en cierta forma, la compra que se acaba de realizar.

Este tipo de campañas no es algo totalmente desconocido por la compañía, ya que durante el 2014 se realizaron 36 campañas que incentivaban ventas cruzadas, las cuales generaron una considerable venta incremental. Pese a los buenos resultados obtenidos, la empresa es consciente de que el proceso es mejorable, debido a que han sido identificadas las siguientes falencias.

- Las recomendaciones son genéricas, es decir, todos reciben las mismas recomendaciones sin importar el perfil del cliente, ni su historia de transacciones previa.
- El envío de los correos electrónicos se realiza una vez al mes, e incluye a todas aquellas personas que han activado el *trigger* durante un mes calendario, es por esto que el cliente puede recibir la campaña entre unos días después de haber realizado la compra, hasta incluso 4 semanas después. Actualmente, no se tiene claridad sobre cuál es el horizonte temporal correcto que se debe manejar en el envío de estas campañas.
- El mix de productos a recomendar sólo invita a comprar accesorios básicos de los productos, lo que genera una oportunidad a explotar interrelaciones entre categorías que podrían derivar en recomendaciones más acertadas y pertinentes.
- En el envío de un correo de ventas cruzadas se involucra el trabajo de varias personas de distintas áreas, entre ellas, un *analista de inteligencia* que selecciona las bases de clientes que gatillaron la campaña, un *diseñador* que realiza los diseños de los mails a enviar, y el *product manager* de la categoría, quien es el que establece cuáles serán las recomendaciones a incluir en el correo. Esta coordinación hace difícil que la campaña pueda ser accionada todos los días para las personas que activan los triggers, por lo que la automatización de estas campañas pareciera poder aportar en que a los clientes se les envíe el mail en un pequeño horizonte de tiempo.
- Por último, análisis preliminares demuestran que existen numerosas oportunidades en otras categorías de productos que no están siendo explotadas por las actuales campañas de ventas cruzadas, dado que solo se ofertan productos en las categorías video, computación, audio, fotografía y telefonía.

Tabla 1 – Matriz de Ventas Cruzadas entre categorías de productos

Venta Cruzada	VIDEO	AUDIO	FOTOGRAFIA	COMPUTACION	TELEFONIA	REFRIGERACION	LAVADO	COCINA	ELECTRODOMESTICOS	CLIMATIZACION	VIDEOJUEGOS
VIDEO	100.0%	8.0%	4.0%	3.3%	2.0%	5.5%	4.3%	4.1%	2.2%	3.9%	5.5%
AUDIO	3.4%	100.0%	2.2%	1.2%	0.8%	1.2%	1.0%	1.2%	0.8%	2.0%	1.6%
FOTOGRAFIA	0.8%	1.0%	100.0%	0.7%	0.4%	0.4%	0.4%	0.3%	0.3%	0.5%	0.7%
COMPUTACION Y HOGAR	5.3%	4.6%	5.9%	100.0%	3.6%	3.2%	3.0%	3.0%	2.4%	3.5%	4.1%
TELEFONIA	5.1%	4.6%	4.6%	5.5%	100.0%	3.4%	3.5%	3.3%	3.1%	3.2%	5.3%
REFRIGERACION	2.4%	1.2%	0.9%	0.9%	0.6%	100.0%	7.8%	11.9%	1.5%	2.2%	0.6%
LAVADO	2.1%	1.1%	1.0%	0.9%	0.7%	9.2%	100.0%	10.6%	1.6%	2.4%	0.9%
COCINA	0.9%	0.6%	0.3%	0.4%	0.3%	5.9%	4.4%	100.0%	0.8%	1.4%	0.3%
ELECTRODOMESTICOS	7.0%	6.0%	5.1%	4.7%	4.0%	11.5%	10.3%	12.2%	100.0%	12.2%	4.6%
CLIMATIZACION	0.5%	0.6%	0.3%	0.3%	0.2%	0.6%	0.6%	0.8%	0.5%	100.0%	0.2%
VIDEOJUEGOS	1.9%	1.3%	1.2%	0.9%	0.7%	0.5%	0.6%	0.5%	0.5%	0.6%	100.0%
ACCESORIOS	17.8%	12.8%	35.6%	18.7%	7.7%	3.3%	3.1%	2.5%	3.2%	4.7%	14.0%

En la tabla 1, se puede observar el porcentaje de personas que compró un artículo de la categoría de las columnas, y que al mismo tiempo, compró un producto de las categorías de las filas. Se aprecia que la mayoría de las categorías de electrónica, como video, audio, fotografía, computación y telefonía, tienen un alto cruce con la categoría accesorios, lo que tiene sentido, pues estas categorías son incentivadas en las actuales campañas de venta cruzada. Aun así, se pueden ver otros cruces interesantes entre categorías, como por ejemplo:

- Video y sistemas de audio
- Video y electrodomésticos
- Refrigeración, lavado y cocina
- Climatización y electrodomésticos
- Video juegos, video y telefonía
- Telefonía y computación.

Estos cruces no están siendo explotados en la actualidad, por lo que constituyen una oportunidad para ampliar el espectro de recomendaciones que se les entregan a los clientes, debido a que existen segmentos de clientes que valoran consumir estos productos simultáneamente.

Dicho lo anterior, parece haber sospechas bien fundadas sobre la existencia de varios factores a mejorar en el proceso de la generación de estas campañas, en relación a la generación de recomendaciones más pertinentes, la automatización del proceso para que no dependa del trabajo en cadena de personas de distintas áreas, o la determinación de la ventana temporal más rentable para enviar el correo.

Por otro lado, la experiencia de la personalización y automatización de campañas de email marketing, ha probado ser exitosa en el pasado, pues existen precedentes dentro del *retailer* con campañas automatizadas que intentaban concretar la venta de clientes que navegaron por el sitio web, alcanzando muy buenos resultados, en comparación con el envío de campañas masivas y estandarizadas.

## **3. Objetivos**

### **3.1. Objetivo General**

Evaluar métodos para generar campañas de e-mail marketing personalizadas con una estrategia de ventas cruzadas en empresa de tiendas por departamento.

### **3.2. Objetivos Específicos**

- Implementar un sistema de recomendación de productos basado en filtros colaborativos utilizando data binaria de canasta.
- Implementar un sistema de recomendación de productos basado en reglas de asociación utilizando la lógica de ventas cruzadas.
- Evaluar de manera experimental el resultado de las campañas que se realicen utilizando los sistemas de recomendación, en comparación con un grupo al que se le harán recomendaciones genéricas.
- Evaluar de manera experimental el resultado las distintas campañas comparando resultados con un grupo de control a quien no se le enviara ningún tipo de estímulo.

## 4. Alcances

El estudio está circunscrito a un proyecto de las áreas de inteligencia web e inteligencia de clientes de una empresa de retail de ventas por departamento, con quienes se han negociado los alcances de esta memoria.

En particular, se deja en claro que el proyecto consiste en la implementación y en la evaluación de una estrategia de campañas para incentivar las ventas cruzadas de clientes que tienen compras importantes dentro de la tienda, en cualquiera de sus canales de venta. Estas compras son catalogadas como importantes, en el caso de que impliquen un alto desembolso de dinero para un grupo familiar, y están

- Refrigeración
- Cocinas y hornos
- Lavadoras
- Tapicería
- Muebles de comedor

Habiendo mas de 280 sub-categorías en la compañía, las 5 categorías seleccionadas representan cerca del 8% de la venta anual, lo que resalta la importancia de trabajar con ellas.

Además, se trabajará con todos los clientes de quienes se tenga su correo electrónico, y que realicen compras dentro del territorio nacional, dejando de lado los demás países de Latinoamérica. Además, se incorporarán en el análisis todas las transacciones realizadas en todos los canales de ventas disponibles, es decir tienda física, venta por atención telefónica, venta por internet, y venta en kioskos.

# 5.Marco conceptual

## 5.1. Sistemas de recomendación

Los sistemas de recomendación se agrupan en dos grandes familias, por un lado existen los sistemas basados en usuarios, y por otro, los sistemas basados en ítems [4]. Estos se diferencian principalmente en 3 aspectos:

a) El supuesto subyacente en el que se basan:

- El supuesto de los sistemas basados en usuarios es que si un grupo de personas manifestaron las mismas preferencias en el pasado, es probable que en el futuro vuelvan a estar de acuerdo en manifestar preferencias similares.
- El supuesto de los sistemas basados en ítems, por otra parte, es que si un sujeto manifestó una preferencia por un ítem que tiene determinadas características, es probable estimar las preferencias que ese sujeto podría tener por otro ítem que posee un diferente set de características.

b) El problema que intentan resolver:

- Los sistemas basados en usuarios, intentan imitar las recomendaciones que se comparten entre los individuos de una comunidad, así por ejemplo los clientes de una tienda, los usuarios de una aplicación, o los aficionados a eventos musicales, podrían recomendar a otras personas aquellos productos, servicios o eventos que más les gustaron. Así, los sistemas basados en usuarios deben generar recomendaciones que son inferidas solamente en función de la experiencia de los usuarios, y se utilizan para promover contenido que es valorado por personas que tienen un comportamiento semejante entre ellos.
- Los sistemas basados en ítem, por otro lado, intentan resolver el problema de qué ofrecer a un sujeto cuando lo importante sobre las recomendaciones radica en el contenido de los artículos que el usuario está utilizando. Esto es particularmente útil para sitios donde se ofrece contenido audiovisual como lo son libros, películas o música, y donde lo importante son las características intrínsecas del ítem. De esta

forma, un reproductor de música online podría reproducir una lista de canciones “parecidas”, donde la similitud de una canción está definida en variables como género musical, estado de ánimo, idioma, sexo del cantante, nacionalidad del grupo, tipo de instrumentos, etc.

c) La implementación de las lógicas de recomendación:

- Los sistemas basados en usuarios también suelen llamarse basados en memoria debido a que para poder computar las recomendaciones, se necesita manejar un gran número de datos en los cuales se almacena la historia de los diferentes usuarios. Con esta historia, se puede inferir cuáles son los clientes que tienen patrones de comportamiento similares, y en función de esos patrones, se recomiendan los productos más pertinentes para cada sujeto. Esto suele ser ineficiente si el número de clientes es demasiado grande, pese a ello, actualmente existen métodos que simplifican la manera en las que la información es almacenada, consultada y actualizada.
- Los sistemas basados en ítems, también conocidos como sistemas basados en modelos, almacenan toda la información de las recomendaciones en reglas simples, que son consultadas de manera muy eficiente por las aplicaciones que las utilizan. La idea central de este enfoque radica en poder comprender a través de indicadores o predictores, cuál es el nivel de similitud o sinergia que existe entre dos productos. Esto implica, a diferencia de los sistemas basados en memoria, que necesita una actualización constante por parte del administrador, ya que las preferencias de los consumidores podrían modificarse en el tiempo, o porque podrían aparecer nuevos tipos de productos (nuevos géneros musicales por ejemplo), los cuales deben ser incorporados en los modelos.

Dentro de los sistemas basados en usuarios están los filtros colaborativos en sus diversas formas, los cuales toman este nombre debido a que generan las recomendaciones en función de la acción (o colaboración) de los usuarios. Esta acción típicamente se expresa en votos entre 1 y 5 estrellas, botones “me gusta” y “no me gusta”, o a través de la sola transacción de ciertos productos y servicios que pueden ser inferidos como preferencias.

Por otro lado dentro de los basados en modelos hay varios enfoques, existen basados en similitud los cuales se enfocan en conseguir grupos de productos que sean parecidos entre ellos, de forma de recomendar elementos dentro de un rango de similitud. Además, existen los que están basados en predictores como son las reglas de asociación que intentan inferir el grado de sinergia que existen entre

productos diferentes y que son conocidas típicamente con el desarrollo de un grupo de retailers de abarrotes, que identificaron un grupo importante de clientes que compraba pañales para bebés, junto con packs de cervezas, y por lo cual era pertinente tener esos productos cerca en el layout de la tienda. En ambos casos, lo que se intenta hacer es comprender la relación o similitud entre ítems de ciertas características para poder desarrollar las recomendaciones.

### 5.1.1. Reglas de asociación

Las reglas de asociación son parte de los sistemas de recomendación basados en modelos. La versión más clásica se basa en 3 métricas, con las cuales el algoritmo “A Priori” encuentra el grado de relación y pertinencia entre distintos productos dentro de una canasta. Esta canasta puede estar definida por los productos que están dentro de una misma boleta, o los productos comprados dentro de un mismo día, un año, o las transacciones de un grupo de clientes en cualquier periodo determinado. Las métricas de las reglas de asociación son las siguientes:

- Soporte: Probabilidad de encontrar el producto A y B dentro de una misma canasta.

$$\text{Soporte}(A, B) = \mathbb{P}(A \wedge B)$$

- Confianza: Probabilidad de encontrar el producto A en la canasta, condicionado a que el producto B ya estuviera en la canasta.

$$\text{Confianza}(B \rightarrow A) = \frac{\text{Soporte}(A, B)}{\mathbb{P}(B)} = \frac{\mathbb{P}(A \wedge B)}{\mathbb{P}(B)}$$

- Elevación: Es el cociente entre la  $\text{Confianza}(B \rightarrow A)$  y el soporte de A, y representa el impacto relativo de la ocurrencia de B, en la probabilidad de ocurrencia de A.

$$\text{Elevación}(A, B) = \frac{\text{Confianza}(B \rightarrow A)}{\mathbb{P}(A)} = \frac{\mathbb{P}(A \wedge B)}{\mathbb{P}(B)\mathbb{P}(A)}$$

Finalmente el algoritmo construye las recomendaciones en función de él o los productos que tengan mayor Elevación. Es importante notar que para poder generar dichas recomendaciones, se debe utilizar toda la data disponible, y calcular las métricas en función de la totalidad de transacciones que involucren el producto A,

el producto B o ambos de manera simultánea. Además, hay que definir parámetros mínimos de soporte y confianza para poder estar trabajando con un número suficiente de datos que permitan extrapolar reglas representativas de lo que sucede en la canasta [5].

Por otro lado, las reglas se pueden calcular también entre canastas de productos, así se podría generar reglas entre la canasta {A, B, C} y la canasta {D, E, F}. Es más, se puede ampliar el uso de la técnica al calcular las métricas de interés entre los atributos que definen un producto, generalizando las reglas de recomendación no solo para los distintos SKUs que componen un mix, si no que para las distintas características que se aprecian en el mismo.

### 5.1.2. Filtros Colaborativos

Los filtros colaborativos son parte de los sistemas de recomendación que se basan en la interacción que tienen los usuarios con los productos o servicios que se le están ofreciendo. Estos han demostrado ser sistemas exitosos en términos de performance y de eficiencia computacional, sobre todo cuando se trabaja en ambientes web [6].

En este tipo de sistemas, la dificultad radica en comprender qué clientes son parecidos entre sí, de manera de construir las recomendaciones solo se considerando los clientes que demuestran preferencias similares. Una forma de hacer eso es considerando información sobre cuánto disfrutó un cliente determinado producto, por ejemplo a través de la manifestación de votos, puntuación, o “likes”, es posible utilizar el criterio del vecino más cercano para determinar qué otros clientes similares existen dentro de una “vecindad”.

Como se puede observar en la ilustración 1, los usuarios  $u_1, u_2, u_3, u_4, u_5, u_6$  han manifestado sus preferencias, que están representadas con un número entero entre 1 y 5, por los ítems  $i_1, i_2, i_3, i_4, i_5, i_6, i_7, i_8$ . Por otro lado existe un usuario activo  $u_a$ , usuario al cual se le deben realizar N recomendaciones.

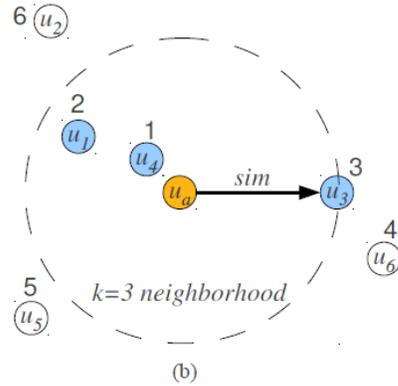
Con el método de los vecinos más cercanos, se determina que los 3 usuarios más parecidos al usuario activo son los usuarios  $u_1, u_4$  y  $u_3$ , con quienes se computa un puntaje  $r_a$  que corresponde a la valoración promedio que los vecinos tienen por los productos que el usuario activo aún no ha valorado. Este puntaje promedio permite darse cuenta que si se tuvieran que escoger las dos mejores recomendaciones en función de su propia historia y la historia de aquellos que se parecen a él, se le se

le deberían recomendar los productos  $i_1$  e  $i_2$  que tienen una valoración promedio mucho mayor que los productos  $i_7$  e  $i_5$ .

Ilustración 1 - Ejemplo de filtro colaborativo

	$i_1$	$i_2$	$i_3$	$i_4$	$i_5$	$i_6$	$i_7$	$i_8$
$u_1$	?	4.0	4.0	2.0	1.0	2.0	?	?
$u_2$	3.0	?	?	?	5.0	1.0	?	?
$u_3$	3.0	?	?	3.0	2.0	2.0	?	3.0
$u_4$	4.0	?	?	2.0	1.0	1.0	2.0	4.0
$u_5$	1.0	1.0	?	?	?	?	?	1.0
$u_6$	?	1.0	?	?	1.0	1.0	?	1.0
$u_a$	?	?	4.0	3.0	?	1.0	?	5.0
$r_a$	3.5	4.0			1.3		2.0	

(a)



Es fácil darse cuenta que con este método las recomendaciones son altamente personalizadas, esto, debido a que la vecindad con la que se calcula la recomendación es distinta para cada cliente. Además, es evidente que la cantidad de datos que se deben almacenar en memoria podría ser bastante alta, lo cual podría generar un problema si la cantidad de usuarios y productos es muy elevada.

Por otra parte, lo visto anteriormente es completamente válido cuando se conocen las preferencias de los usuarios por los diferentes productos, pero esto no es siempre cierto en distintos tipos de sitios web, sobre todo los sitios web que están orientados a la venta de productos y servicios. En estos casos solo se conoce si es que una persona compró o no compró un producto determinado, y no es posible conocer la valoración que se tiene sobre el mismo. Esto puede ser representado con variables binarias 1 y 0, que indiquen la compra o la no compra de un producto. El problema de este esquema es que la “no compra”, que está representada por un 0, se puede interpretar en más de un significado, por ejemplo:

- El cliente no valora el producto, y en ese caso la recomendación no sería pertinente.
- El cliente no conoce el producto, y por lo tanto si sería pertinente recomendárselo.
- El cliente no ha necesitado el producto en el pasado lo que indica que es poco probable que lo necesite en un tiempo cercano.

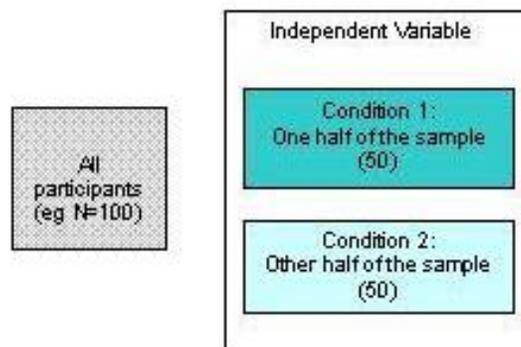
Cada interpretación tiene que ver con la definición del problema en sí mismo, ya que en el negocio aéreo, en el mundo del espectáculo, y en el mundo del retail las interpretaciones podrían diferir. Diferentes métodos son evaluados en la literatura sobre métodos de filtros colaborativos basados en data de canastas de compra (datos binarios), entre los cuales aparecen versiones simplificadas del método descrito anteriormente, utilizando la compra como una valoración.

## 5.2. Fase experimental

### 5.2.1. Aleatorización

La aleatorización de sujetos es vital en todo proyecto experimental, porque de esta forma se busca aislar todos los demás efectos que podrían influir en el desarrollo y resultado de un experimento, y dependiendo de las características del estudio debe escogerse alguna de las varias maneras de hacerlo [7]. Una de ellas es una aleatorización entre grupos, en donde a dos grupos de personas se les da un tratamiento diferente, este enfoque es conocido como “between groups” y se observa en el siguiente esquema.

Ilustración 2 - Aleatorización entre grupos



El objetivo de dividir los grupos de forma aleatoria radica en poder establecer el efecto que tiene la variable estudiada en ambos grupos, la idea es poder determinar la relación causa-efecto que tienen los distintos tratamientos en los resultados obtenidos para cada grupo.

Además, otro enfoque clásico en el mundo experimental es el de “entre sujetos” o “between subjects”, en donde a los sujetos se les asigna un grupo de tratamiento, o un grupo de control. Esta es una versión reducida del enfoque entre grupos, pero

que solo permite medir el efecto de una variable, a diferencia del enfoque entre grupos que permite controlar el efecto de distintas variables en distintos grupos.

Para el enfoque entre sujetos, el mejor método de evaluación es el uso de test estadísticos como el test de medias, que permita evaluar diferencias significativas entre los grupos de tratamiento y de control. Por otro lado, cuando se utiliza el enfoque entre grupos, además de los test estadísticos entre los distintos grupos, la evaluación de los resultados se puede realizar mediante el uso de regresiones lineales, que logran medir el efecto de los distintos tratamientos en la variable dependiente que se pretende estudiar, además de poder moderar el resultado del experimento en función de variables no controlados por el investigador.

## 6. Metodología

Para resolver el problema propuesto se implementaran dos sistemas de recomendación diferentes:

- Un sistema de recomendación basado en filtros colaborativos con data binaria resultante de las transacciones de los clientes.
- Un sistema de recomendación basado en reglas de asociación utilizando las métricas Elevación, Confianza y Soporte.

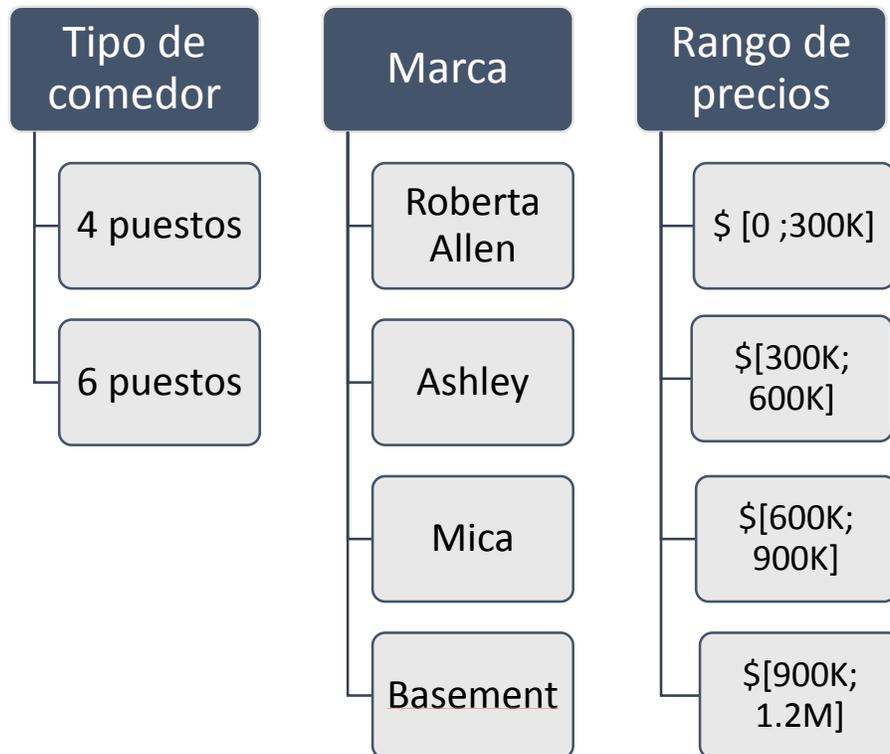
Para ello se utilizarán todas las transacciones de un año calendario, incluyendo solamente las categorías duras, es decir categorías relacionadas al hogar. Estas categorías fueron escogidas por que en general responden a un hito dentro de las compras de los clientes ya que la compra de artículos de Electro-hogar, Muebles, Decoración y Dormitorio, representan en su mayoría, un alto desembolso económico para las familias, y pueden estar relacionados a que el grupo familiar está remodelando parte del hogar, o quizás, vistiendo uno nuevo. Esto es importante porque permite deducir que esa persona, con una alta probabilidad podría necesitar productos complementarios que ayuden a llevar a cabo su objetivo. Por esta razón, se excluyen las categorías blandas como Calzado, Vestuario, Belleza, y juguetería, ya que aunque son importantes para el negocio, son productos que tienen muchísima mayor frecuencia de compra y no deberían estar relacionadas con este tipo de hito.

La implementación de estos sistemas se realizará en función de los atributos de los distintos productos, y no sobre los SKU's específicos que aparecen dentro de la canasta transaccional. Esto es una decisión que se tomó dado que los SKU's dentro de una tienda por departamento tienen alta rotación, y en un par de meses los SKU's se renuevan con tal rapidez, que se generaría un problema a la hora de operar el sistema de recomendación dado que el aprendizaje que se tuvo de los productos de tan solo unos meses atrás, ya no sirve y no aportaría a las recomendaciones del mix de SKU's actual. Para evitar este problema, se describe un SKU como un conjunto de atributos que lo describen, por ejemplo, en la ilustración 4 se observa que una mesa de comedor, puede ser caracterizada como:

- Un tamaño, que dependiendo del tipo de producto, podría ser un indicador del tamaño de la familia o del hogar.

- Una marca, que puede estar describiendo un estilo de vida, ya que cada marca intenta imprimir en sus diseños de muebles o electrodomésticos características diferenciadoras.
- Un rango de precio que es un buen indicador del poder adquisitivo del cliente.

Ilustración 3 - Atributos que describen la línea Comedor



Con esto en mente, es posible implementar una categorización para cada uno de los productos trigger, y para cada uno de los posibles productos a recomendar. Cada uno de estos productos está descrito como una combinación de un rango de precio, de una marca, de una categoría y de un tamaño (si es que corresponde). Esta clasificación debe poder funcionar con un mix de producto que va cambiando tanto en características físicas de los productos, en la incorporación y eliminación de marcas, y en la constante variación de precios de los productos, para ello es de todas formas necesario que la compañía mantenga actualizada las clasificaciones de los productos, pese a que esta actualización no debería ser tan periódica respecto a si se estuviera trabajado solo con SKU's, de todas formas se debería estar actualizando al menos de manera anual para incorporar las modificaciones del mix.

Como las recomendaciones se implementarán sobre este nivel de agregación de los productos, que es bastante desagregado, es posible que solo se puedan encontrar pocas recomendaciones para cada tipo de producto. Esto es debido a que la variedad de productos es muy alta, y la cantidad de compras por cada cliente no es demasiada, incluso dentro un año. Por lo tanto, se implementarán varios grados de agregación, que permitan a los sistemas de recomendación “subir un nivel” de agregación si es que las recomendaciones encontradas no fueran suficientes para llenar todos los espacios del correo electrónico. Una manera de pensar esto, siguiendo con el ejemplo de los comedores, es la siguiente. Supongamos que para la combinación **Comedor de seis puestos - marca Basement – Entre \$600.000 y \$900.000**, solo se pudiera encontrar 4 recomendaciones pertinentes, lo que debería hacer el sistema es buscar qué otras recomendaciones existen para un **Comedor de seis puestos - Entre \$600.000 y \$900.000**, y en el caso que aún no fuese suficiente, buscar recomendaciones para la combinación **Comedor - Entre \$600.000 y \$900.000**. Para subir de nivel se escoge De todas formas, las pruebas realizadas con la data transaccional no hicieron que fuese necesario subir más que en un solo nivel la agregación de los productos.

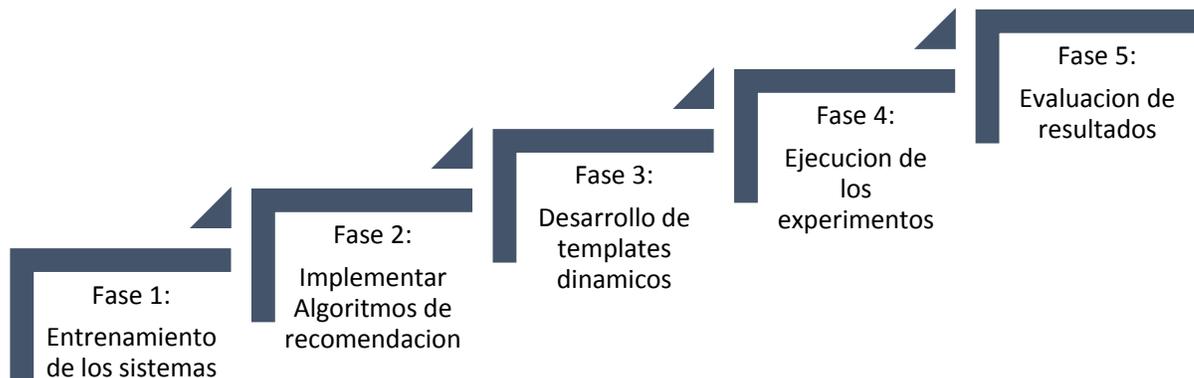
Una vez entrenados los sistemas de recomendación, se implementan en un ambiente de producción operativo, donde lo importante es que los sistemas de recomendación sean capaces de cumplir las siguientes restricciones del problema:

- Se debe recomendar solo productos con Stock en el centro de distribución.
- Se debe recomendar solo productos publicados en el sitio web de la empresa.
- No se debe recomendar productos que el cliente ya haya comprado en los últimos 6 meses.
- El template del correo electrónico debe contener 6 recomendaciones diferentes y factibles con el objetivo de mostrar variedad, pero al mismo tiempo no saturar el correo con productos.

Con todo lo anterior, se aprecia que hay etapas bien definidas del proyecto, las cuales se aprecian en la ilustración 5. Todo comienza con el entrenamiento de los sistemas propuestos, donde se obtienen las reglas que regirán las recomendaciones al nivel de agregación discutido previamente. Luego, es necesaria una segunda fase de implementación de los algoritmos de

recomendación, estos algoritmos trabajan basándose en las reglas creadas, pero tienen por objetivo transformar esas reglas que están construidas a nivel de atributos, en recomendaciones de SKUs específicos. Para eso los algoritmos deben consultar en línea a las bases de datos cuáles son los productos que en ese momento satisfacen las condiciones de ser productos publicados y de tener más que el stock de seguridad. Una vez que se tienen los productos que pueden ser recomendados, se pasa a la fase 3, la cual consiste en implementar templates dinámicos, que sean capaces de mostrar 6 recomendaciones pertinentes, sin importar que en el tiempo entre que se crearon las recomendaciones, y que el cliente recibe y abre el mail, pudieron haber habido SKUs que pasaron de tener stock a no tenerlo en el transcurso de unos días o incluso algunas horas. Una vez que los modelos y los templates están en producción, se pasa a la fase experimental, fase que pretende someter a los clientes que activaron los triggers a distintos tratamientos desarrollados, esto se hará separando a la población en grupos, y a cada grupo se le enviara un mail generado con una lógica diferente. Por último, existe una fase de evaluación que es clave para comprender el efecto de los distintos sistemas de recomendación en los clientes.

Ilustración 4 - Las 5 fases de la Metodología



## 6.1. Entrenamiento

Esta fase consiste en la elaboración de las lógicas de recomendación, de manera que se resuman en forma de tablas y que sean de fácil consulta para las siguientes fases. En el caso de las reglas de asociación, se escoge para cada antecedente, que es el producto que activó el trigger, los N mejores consecuentes según el índice de LIFT (y en caso que dos consecuentes tuvieran igual LIFT se continúa con el consecuente que tenga mayor confianza). En el ejemplo de la tabla 2, las 6 mejores recomendaciones para el antecedente, serían los consecuentes 5, 6, 7, 4, 1 y 2, y con ellos se formaría el mix de productos a recomendar.

Tabla 2 - Ejemplo de lógica de recomendación

REGLA ID	ANTECEDENTE	CONCECUENTE	LIFT
1	CATEGORIA - MARCA - PRECIO	CATEGORIA - MARCA - PRECIO	1,8
2	CATEGORIA - MARCA - PRECIO	CATEGORIA - MARCA - PRECIO	1,7
3	CATEGORIA - MARCA - PRECIO	CATEGORIA - MARCA - PRECIO	1,4
4	CATEGORIA - MARCA - PRECIO	CATEGORIA - MARCA - PRECIO	2,1
5	CATEGORIA - MARCA - PRECIO	CATEGORIA - MARCA - PRECIO	3,6
6	CATEGORIA - MARCA - PRECIO	CATEGORIA - MARCA - PRECIO	3,6
7	CATEGORIA - MARCA - PRECIO	CATEGORIA - MARCA - PRECIO	3,6
8	CATEGORIA - MARCA - PRECIO	CATEGORIA - MARCA - PRECIO	0,1
9	CATEGORIA - MARCA - PRECIO	CATEGORIA - MARCA - PRECIO	0,1
10	CATEGORIA - MARCA - PRECIO	CATEGORIA - MARCA - PRECIO	1,6

Para el caso de los filtros colaborativos también se crea una tabla que indique, para cada perfil de compras, un puntaje de pertinencia sobre la recomendación de un producto que contenga cierto set de características. Este puntaje debe ser computado para cada combinación “perfil-producto”, y se hace considerando el total de personas de perfiles de compra similares, que también compraron dicho productos de atributos determinados. Esta similitud se determina utilizando el método del vecino más cercano entre perfiles de compra.

Así un cliente puede tener un perfil de compra determinado por los productos que ha comprado durante un año. En la tabla 3, se pueden observar cuatro perfiles de compra diferentes de una canasta con cuatro productos, esta responde a una canasta de data binaria donde se muestran las combinaciones en la que los distintos tipos de productos fueron comprados por los 29 clientes que conforman el universo con el que se está trabajando. Se aprecia que 12 personas tienen el perfil A y que 9 personas tienen el perfil D.

Tabla 3 - Ejemplo de la determinación de los perfiles de compra de los clientes

PERFIL ID	PROD 1	PROD 2	PROD 3	PROD 4	NUMERO CLIENTES
A	1	0	1	1	12
B	1	1	0	0	6
C	0	1	1	1	2
D	0	1	0	1	9
					29

Con el método de los vecinos más cercanos, y utilizando la medida de distancia euclidiana, es posible no solo obtener información de los clientes que tienen un perfil de compra idéntico, que de hecho, no aportan a las recomendaciones, por razones obvias, si no que, se flexibiliza para incorporar la información de compra de los clientes que tienen un perfil de compra similar. En la tabla 3 se puede observar que para este ejemplo en particular el vecino más cercano del perfil A es el perfil C y que para el perfil B es el perfil D.

$$d_E(P, Q) = \sqrt{(p_1 - q_1)^2 + (p_2 - q_2)^2 + \dots + (p_n - q_n)^2} = \sqrt{\sum_{i=1}^n (p_i - q_i)^2}.$$

Tabla 4 Matriz de Distancias entre perfiles

PERFIL ID	A	B	C	D	Vecino más cercano
A	0	1,73	1,41	1,73	C
B	1,73	0	1,73	1,41	D
C	1,41	1,73	0	1	D
D	1,73	1,41	1	0	C

Resuelta las vecindades, que en este caso particular están compuestas solamente por 1 vecino más cercano, es posible construir una tabla que contenga los puntajes para de cada producto y para cada perfil de compra. Así por ejemplo para el perfil de compra A se les debería recomendar el producto 2, mientras que a los clientes del perfil B, habría que recomendarles el producto 4.

Tabla 5 - Ejemplo del funcionamiento de filtros colaborativos

PERFIL ID	PRODUCTO	PUNTAJE
A	PROD 1	0
A	PROD 2	2
A	PROD 3	0
A	PROD 4	0
B	PROD 1	0
B	PROD 2	0
B	PROD 3	0
B	PROD 4	9

Es interesante reflexionar sobre el hecho de que cada sistema de recomendación debería generar muy distintas recomendaciones, esto se debe a que los filtros colaborativos aquí implementados intentan encontrar los productos populares entre su vecindad, que podría estar relacionado a productos de bajo costo pero que se transan mayor cantidad. En cambio las reglas de asociación, con el uso de la métrica LIFT, intentan hacerse cargo de esta situación, tratando de recomendar productos que tengan mayor sinergia mutua, es decir, que la ocurrencia de uno promueva la ocurrencia del otro. Esto debería eliminar el problema del producto popular, pero eso también implica que las recomendaciones podrían tener precios considerablemente más altos.

## **6.2. Implementar algoritmos de recomendación**

Una vez almacenados en tablas las lógicas de recomendación con sus puntajes o métricas de elevación, el siguiente paso es transformar esas reglas en recomendaciones de productos específicos.

Para ello, se planteó un algoritmo que puede resolver este problema, asegurándose de que se cumplan las restricciones de stock y publicación. El algoritmo se puede reducir a lo siguiente:

1. Consultar productos que estén publicados en el sitio web.
2. Filtrar productos que al momento de generar las recomendaciones no tienen más de 6 unidades en el centro de distribución y se almacena en una tabla que contiene los posibles productos a recomendar
3. Consultar clientes que activaron el trigger en los últimos 2 meses.
4. Si el cliente activo más de un trigger, se conserva el de mayor valor.
5. Se calcula el nivel de agregación del trigger y el perfil de ventas del último año del cliente
6. Se cruza el perfil de ventas con la tabla de filtros colaborativos, y se almacena en una tabla temporal
7. Se cruza el nivel de agregación del trigger con la tabla de reglas de asociación, y se almacena en una tabla temporal
8. Se cruzan las tablas de puntajes de filtros colaborativos y de reglas de asociación, con la tabla de posibles productos a recomendar.

9. Para cada método de recomendación, se obtienen los códigos SKU de las mejores 18 recomendaciones.

### **6.3. Desarrollo de templates dinámicos**

Cada template tiene espacio para recomendar 6 productos, esta es una restricción del negocio debido a que una de las cosas que se quiere lograr es mostrar variedad de productos, pero al mismo tiempo se estima que mas de 6 productos podrían ser demasiados y podrían entorpecer la experiencia del cliente. Para lograr rellenar exitosamente estos 6 espacios se le entrega al template 18 recomendaciones con el objetivo de asegurarse de que el cliente a la hora de abrir el correo electrónico, efectivamente vea productos publicados y con stock. El tener 18 opciones para 6 casilleros hace altamente improbable el que un casillero quede vacío.

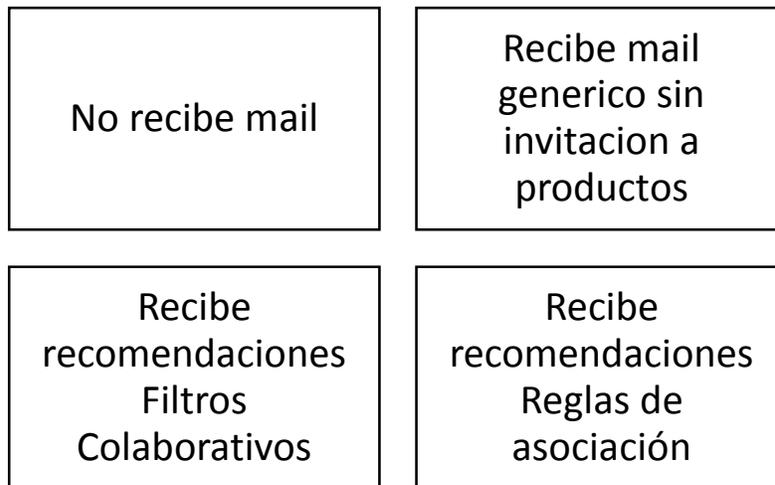
Para ello, se desarrolló un código que fue embebido en el template del correo electrónico, el algoritmo se detalla a continuación:

1. Consultar el estado del SKU en el sitio web.
2. Si está OK, entonces recomendar,
  - a. Si se va a recomendar, consultar en el sitio web:
    - i. Precio normal
    - ii. Precio oferta
    - iii. Fotografía
    - iv. Descripción
  - b. Si no está OK, pasar al siguiente SKU
3. Parar cuando se hayan llenado los 6 espacios

### **6.4. Ejecución de los experimentos**

Con los templates listos y las recomendaciones generadas se procede a separar la población que activó el trigger en 4 grupos de personas, esto se realiza de manera completamente aleatoria. Con esto, se construyen grupos según la distribución que se puede observar en la ilustración 6:

Ilustración 5 - Grupos de trabajo para la experimentación



El objetivo de esta separación es medir de manera independiente 2 efectos. En primer lugar lo que interesa es conocer el efecto que tiene el efecto mail, por sobre el grupo de control, esto se hará comparando los resultados de los 3 envíos respecto al grupo al que no se le envía ningún mail. Por otro lado, se pretende conocer el efecto de los mails con recomendaciones de productos generados por los 2 sistemas de recomendaciones, por sobre el efecto de la invitación genérica a categorías. Con esto se podrá medir independientemente el efecto mail, y por otro lado el efecto recomendación y con ello evaluar si es que el esfuerzo de construir, aplicar y mantener actualizados los sistemas de recomendación, vale la pena.

La medición de los resultados de los experimentos se hará midiendo la venta incremental que generan las acciones de email marketing, esta venta incremental se observa desde 2 efectos, un efecto asistencia y un efecto monto. El efecto asistencia mide el aumento en la proporción de personas que compran comparado con el grupo de control. Por otro lado el efecto monto compara la cantidad promedio que gastan los clientes de los distintos grupos y mide cuando aumenta el promedio del gasto de un grupo respecto al grupo de control.

## 6.5. Evaluación de resultados

La evaluación se hará mediante el uso de test estadísticos de media que midan si es que las ventas promedio entre grupos permite inferir estadísticamente que existe venta incremental, desde el grupo que recibe recomendaciones, por sobre los grupos de control. Además se espera conocer si es que la proporción de personas que asisten a la tienda también es mayor en un grupo que en el otro, por lo que también la asistencia incremental se medirá con test de proporciones.

Otras métricas de evaluación que son de interés son:

- Tasa de apertura
- Tasa de click
- Venta por el canal web
- Venta por el canal físico
- Venta en las categorías recomendadas
- Venta en categorías no recomendadas (Venta cruzada en líneas blandas)

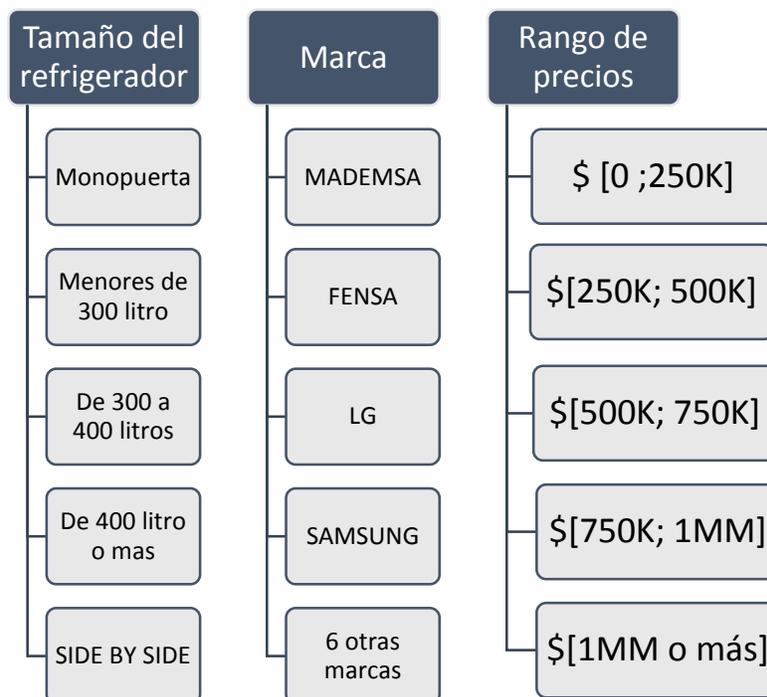
# 7.Desarrollo de metodología

## 7.1. Tratamiento preliminar de datos

Para cada categoría en estudio, se determinaron los diversos grados de agregación con los que se van a manejar los distintos productos. Esto es vital debido a que este es el formato con el cual se implementara todo el mecanismo de recomendación. Esta sección se refiere a la preparación que necesitan los datos para el entrenamiento de los sistemas de recomendación.

Así, para el caso de los productos de la categoría refrigeración, los diversos grados de agregación que describen se pueden observar en la ilustración 7. El tratamiento de las variables para las otras categorías que generan las campañas trigger, y también para aquellas categorías de productos que son sujeto a ser recomendaciones es el mismo y siempre se sigue la misma estructura descrita, con excepción de las categorías donde el tamaño no es relevante para describir al producto, tal como sucede en situaciones como en el caso de las categorías de decoración, menaje y algunos tipos de muebles, donde lo relevante es el tipo de producto, y no su tamaño.

Ilustración 6 - Atributos que describen a la categoría Refrigeración



Esto tiene un gran impacto en dos aspectos vitales para el desarrollo del proyecto, el primero es que se logra disminuir considerablemente la dimensionalidad del problema, debido a que ya no es necesario trabajar con la data a nivel de SKU, los que son demasiados a lo largo de un año calendario. Esto se puede apreciar en la tabla 5, donde se observa la cantidad de SKU distintos que se transaron por cada una de las categorías triggers, las cuales son cerca de 4 veces la cantidad de elementos que se consideran a la hora de trabajar con el nivel de agregación 1, que recordemos es el nivel más desagregado con el que se puede trabajar cada producto. Cuando se pasa al nivel de agregación 2, es decir, cuando se excluye la marca para trabajar solo con los demás atributos, la cantidad de elementos a considerar disminuye aún más. Esto será vital para que los sistemas de recomendación puedan encontrar sugerencias incluso cuando un elemento del nivel de Agregación 1 no aparezca muchas veces dentro de las transacciones, y en consecuencia no se puedan generar muchas recomendaciones a ese nivel a menos que se considere el nivel de Agregación 2 que como se verá más adelante, asegura tener suficientes apariciones dentro de la data transaccional.

Tabla 6 - Agregación de SKUs para las diferentes categorías triggers

	NUMERO SKU's	AGREGACION 1	AGREGACION 2
REFRIGERACION	837	153	34
LAVADO	829	133	29
COCINA	605	129	20
COMEDOR	643	117	23
TAPICERIA	1397	279	56

Las diferencias de magnitud entre niveles de agregación son similares en otras categorías como en decoración, menaje y electrodomésticos, donde se manejan muchos SKUs por cada categoría.

Tabla 7 - Agregación de SKUs para categorías triggers con gran cantidad de SKUs

	NUMERO SKU's	AGREGACION 1	AGREGACION 2
DECO HOGAR	6931	1110	352
ELECTRO HOGAR	5418	1316	413
TOTAL	12349	2426	765

Otra ventaja sustancial de utilizar un manejo de datos en base a atributos, no solo está ligado a la reducción de la dimensionalidad a la hora de generar los modelos de recomendación, sino que es una ventaja que flexibiliza la operación de los sistemas, y los hace menos dependientes de actualizaciones constantes. Esto es debido a que en retail los SKU's aparecen y desaparecen con muchísima frecuencia, principalmente porque en las tiendas por departamento se trabaja por temporada y los productos cambian desde una temporada a la otra, esto sumado a

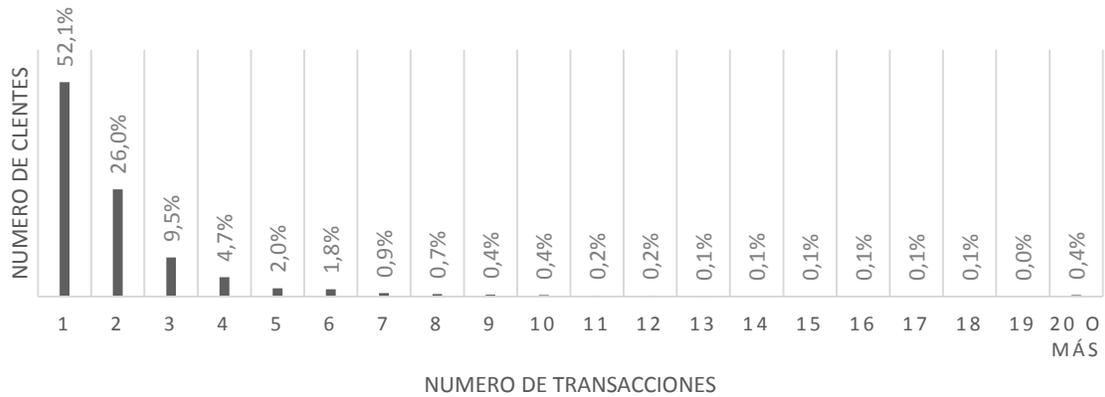
que los proveedores siempre están actualizando su apuesta de cara a los consumidores y tratan de sorprender con nuevos productos, a costa de discontinuar otros. Si es que los sistemas de recomendación estuvieran entrenados a nivel de SKU, obligaría a eliminar recomendaciones que ya no sean parte del mix, lo cual no es tan grave en comparación con el efecto que se tiene sobre los productos nuevos, con los cuales no se tiene ninguna historia previa. Al utilizar los enfoques a nivel de atributos esto ya no es un problema, ya que los modelos están basados en variables que son mucho más persistentes en el tiempo, y en consecuencia provocando que la actualización periódica sea menos necesaria. Es más, si apareciera una marca nueva, el modelo aún podría generar recomendaciones desde lo que ha aprendido del nivel de agregación 2.

Finalmente, para cada cliente se computa una serie de variables binarias que contienen 1 y 0 en función de si ese cliente compro o no algún sku correspondiente a alguno de los niveles de agregación definidos en alguna de las categorías en estudio. Por otra parte, con el objetivo de poder aprovechar mejor la información que enriquezcan las recomendaciones, solo se trabajará con clientes que cumplan las siguientes condiciones:

- Deben tener 2 o más variables activas dentro de alguna de las 2705 alternativas del nivel de agregación 1 (y en consecuencia debe tener también al menos 2 variables activas en el segmento de agrupación 2).
- Una de las variables activas debe ser una variable perteneciente a las categorías que gatillaran el envío del correo, y en consecuencia debe ser una variable de refrigeración, lavado, cocina, comedor o tapicería

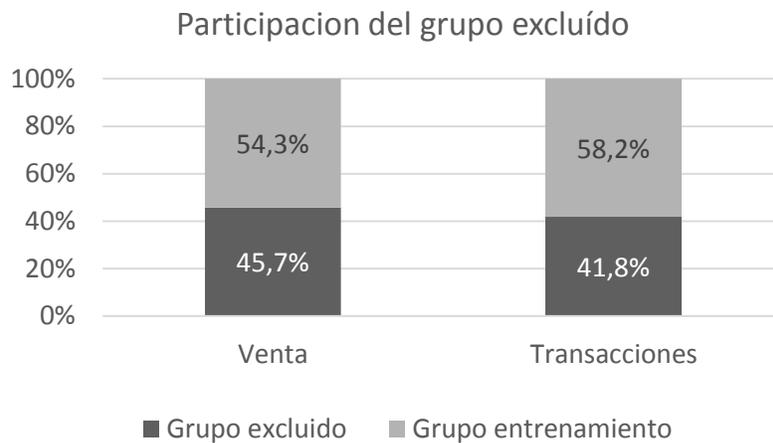
Estas condiciones permiten asegurar que los registros con los que se trabajará sean aquellos que aportan valor a las recomendaciones. Esto es debido a que clientes que solo han realizado solo una compra, no permiten conocer mayormente el resto de sus preferencias y necesidades, y por lo tanto su inclusión dentro la data solo tendría como consecuencia el empobrecimiento de las recomendaciones. Esto no es muy grave para el caso de los filtros colaborativos, que solo compara el numero apariciones dentro de un conjunto de datos independiente del total de datos que existan. Pero por otro lado las reglas de asociación se pueden ver afectadas debido a que se deben exigir niveles mínimos de soporte, que como habíamos visto, expresa la probabilidad de que un producto aparezca dentro del conjunto de datos. Y si los productos están dispersos entre una mayor cantidad de transacciones “vacías”, sus soportes solo se hacen más pequeños corriendo el riesgo de dejar de estar dentro del rango mínimo aceptado.

Ilustración 7 - Porcentaje de clientes versus cantidad de transacciones que realizan



Como se puede observar en la ilustración 8, lo anterior significa que se debe renunciar al 52% de los clientes que se tienen como potenciales datos de entrenamiento. Aun así, como ya habíamos dicho, estos clientes no aportan en nada en la generación de recomendaciones, y en términos económicos son los clientes que tienen menos valor, ya que pese de ser el 52% de los clientes, representan solo el 45% de la venta, y el 41% de las transacciones, lo que quiere decir que el grupo que finalmente si se utilizará, contiene casi el 60% de las transacciones, lo que es suficiente para construir recomendaciones robustas.

Ilustración 8 - Participación del grupo excluido en ventas y transacciones



## 7.2. Entrenamiento de los modelos

Utilizando los datos de la forma descrita anteriormente, se proceden a generar las lógicas de recomendación con los métodos propuestos.

### 7.2.1. Reglas de asociación

Utilizando el algoritmo a priori del software SPSS Modeler, se crearon 16.067 reglas de asociación solamente para el nivel de agregación 1, y 2541 reglas para el nivel de agregación 2.

A modo de ejemplo, se muestra en la tabla 7, las primeras 12 recomendaciones, según el criterio de la elevación, que se les deberían hacer a una persona que se compra una Cocina de 5 o 6 quemadores, marca BOSCH, y del quinto rango de precio o dicho de otra forma, superior a los CH\$900.000.

Tabla 8 - 12 primeras recomendaciones a la compra de una cocina Bosch

SOPORTE	CONFIANZA	ELEVACION	GRADO	CONSECUENTE
0.6	2.2	90.5	1	COCINA - CAMPANAS - BOSCH - 2
0.6	1.2	19.9	1	COCINA - CAMPANAS - TEKA - 2
0.6	8.8	12.9	1	LAVADO - LAVAVAJILLA - BOSCH - 2
0.6	1.2	11.5	1	COCINA - CAMPANAS - URSUS TROTTER - 2
0.6	2.2	9.5	1	REFRIGERACION - SIDE BY SIDE - BOSCH - 5
0.6	1.1	7.5	1	ELECTRODOMESTICOS - TOSTADOR ELECTRICO - TOYOTOMI - 2
0.6	2.2	7.03	1	REFRIGERACION - DE 300 LTS HASTA 400 LTS - BOSCH - 4
0.6	1.1	6.7	1	ELECTRODOMESTICOS - TOSTADOR ELECTRICO - URSUS TROTTER - 2
0.6	1.6	6.5	1	LAVADO - LAVAVAJILLA - G.ELECTRIC - 2
0.6	1.8	3.5	1	ELECTRODOMESTICOS - BATIDORAS DE PEDESTAL - KITCHENAID - 4
0.6	1.1	3.2	1	ELECTRODOMESTICOS - HERVIDOR ELECTRICO - TOYOTOMI - 3
0.6	1.1	3.1	1	COCINA - BATERIAS ACERO - TEFAL - 5

Se aprecia que las recomendaciones para este tipo de cocina, son marcas en general muy caras, como lo son BOSCH, URSUS TROTTER, KITCHENAID, etc. Lo cual hace sentido desde una perspectiva comercial, dado que el antecedente es una cocina grande, de una marca como BOSCH, y del rango de precios más alto, por lo que parece coherente que existan recomendaciones a elementos de características similares.

Por otro lado, para el caso de una cocina de 4 platos marca DAEWOO, del rango de precio más bajo, es decir menor a \$100.000, el caso es completamente diferente, y como se puede observar en la tabla 8, el nivel de Agregación 1 no alcanza a generar suficientes recomendaciones para un producto de estas características, y la razón radica en el soporte.

Como se puede observar para el nivel de agregación 1, el nivel de soporte, es de apenas un 0,002% de las transacciones, lo que implica que las reglas se basan en tan solo unos pocos casos. Es en este tipo de ejemplos, donde se puede ver el poder que tienen las recomendaciones basadas en atributos, ya que pasando el nivel de agregación 2, donde permitimos no incorporar la marca del antecedente, que en este caso es DAEWOO, surgen nuevas recomendaciones basadas en la compra de cualquier cocina de 4 platos del rango de precio más bajo, sin importar su marca.

Tabla 9 - Recomendaciones para una cocina marca Daewoo

SOPORTE	CONFIANZA	ELEVACION	GRADO	CONSECUENTE
0,002	50,0	37,3	1	COCINA - SARTEN ANTIADHERENTE - TEFAL - 1
0,002	50,0	34,6	1	ELECTRODOMESTICOS - LICUADORA - OSTER - 3
0,002	25,0	27,7	1	COCINA - ESPECIALIDAD - 1
0,002	25,0	17,9	1	COCINA - SARTEN ANTIADHERENTE - 1
0,002	50,0	12,1	1	ELECTRODOMESTICOS - LICUADORA - 3
0,674	1,3	25,8	2	REFRIGERACION - MENORES DE 300 LTS - FENSA - 1
0,674	2,6	16,5	2	REFRIGERACION - MENORES DE 300 LTS - 1
0,674	1,8	11,8	2	COCINA - CAMPANAS - SINDELEN - 1
0,674	1,1	8,8	2	REFRIGERACION - FRIGOBAR - RECCO
0,674	1,5	7,9	2	COCINA - CAMPANAS - MABE - 1
0,674	2,1	7,1	2	COCINA - CAMPANAS - MADEMSA - 1
0,674	1,1	3,4	2	ELECTRODOMESTICOS - FREIDOR ELECTRICO - SOMELA - 3
0,674	4,2	3,1	2	REFRIGERACION - FRIGOBAR
0,674	2,0	2,7	2	REFRIGERACION - FREEZER/CONGELADORA - 1
0,674	1,2	1,3	2	ELECTRODOMESTICOS - SANDWICHERA - 2
0,674	4,2	1,2	2	ELECTRODOMESTICOS - MICROONDAS - 1

El ejemplo anterior también arroja insights sobre el comportamiento del tipo de clientes que compra las cocinas más baratas, en primer lugar destaca que las reglas con mayor elevación, tienden a ser productos que son baratos dentro de su categoría, como por ejemplo el refrigerador marca FENSA, o la campana SINDELEN, que están en el rango de precios más bajos. Al mismo tiempo, un resultado no tan intuitivo es que las personas que se compraron una cocina barata y pequeña, también necesitan un frigo bar, lo cual en primera instancia pareciera no

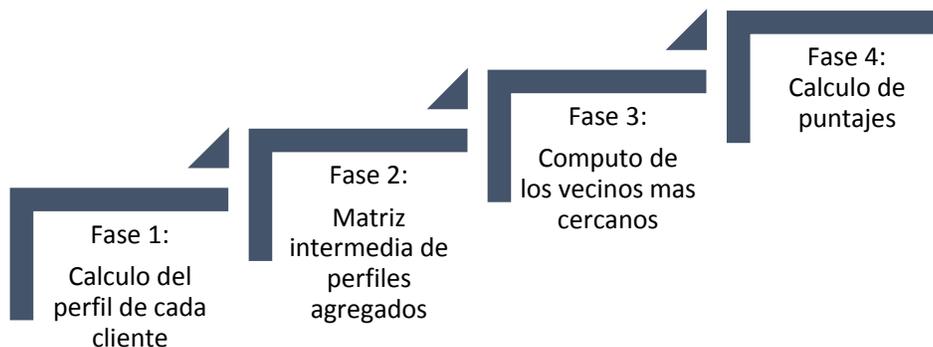
ser un elemento de primera necesidad, pero quizá lo que está detrás de esa regla es que personas con una limitación de espacio en sus hogares, ocupan el frigo bar como un refrigerador, y que por lo tanto la recomendación pudiera ser pertinente.

Se definió un nivel mínimo de soporte del 0,01 para poder incorporar la mayor cantidad de reglas posible, sin perder representatividad en la cantidad de clientes, además solo se consideraron reglas con elevación mayor que 1, para solo recomendar productos que generan sinergia. Con lo anterior se “pierde” el 38% de las reglas de recomendación, pero se gana por otro lado pertinencia a la hora de sugerir a un cliente un producto determinado.

### 7.2.2. Filtros colaborativos

Como se dijo en la sección 6.1 la tabla que resumirá la información de las recomendaciones de filtro colaborativo, relaciona un perfil de compra determinado con un producto específico, esto se hace en función de la vecindad de clientes que comparten un perfil de compra similar, y que con los productos adicionales que esos perfiles también han comprado. Esto significa que hay 4 claros pasos para generar las recomendaciones.

Ilustración 9 - Fases de implementación de Filtros Colaborativos



El perfil de los clientes ya se calculó en la sección anterior en la matriz de variables binarias, pero se le suma una variable que define el decil de gasto de la persona, esto se hace para que las vecindades se aglutinen alrededor de personas de gasto similar.

Con esto, es posible agregar la matriz de clientes en una matriz que cuente la cantidad de clientes que comparten un perfil determinado, tal como se mostró en la tabla 3 de la sección 6.1. Esto sirve para reducir la dimensionalidad del problema,

dado que se puede pasar de tener cientos de miles de clientes a “solo” unas decenas de miles, aun así, dado que en las tiendas por departamentos las personas no tienden a comprar muchas veces en el año, y como ya vimos la mayor parte de los clientes con los que estamos trabajando tiene solo 2 compras, la potencialidad de reducción parece poco prometedora. Aun así se logró reducir la dimensionalidad de la matriz en un 38%.

Con esto, el modelo de los vecinos más cercanos permite encontrar los N perfiles más cercanos, o parecidos, a cualquier perfil de un cliente activo que se le ingrese como input. Para esto también se utilizó el software SPSS Modeler, y cabe señalar que computacionalmente es muchísimo más costoso desarrollar este modelo en comparación con las reglas de asociación debido a que se debe almacenar en memoria una matriz de distancia que se calcula con variables (aunque la mayoría son ceros), entre aproximadamente 55.000 perfiles diferentes. Estos perfiles agrupan aproximadamente 1,63 clientes en promedio, muchos de ellos contienen la información de solo un cliente, y tienen un número de variables activas promedio en torno a las 3,4, considerando la restricción de que tiene que tener al menos dos variables activas distintas, y al menos una de ellas debe ser de alguna de las categorías que activan el trigger.

Tabla 10 - Características de los perfiles encontrados

	MINIMO	MAXIMO	PROMEDIO
Número de clientes por perfil	1	279	1.6
Nº variables activas por perfil	2	41	3.4

Para este caso en particular, se utilizó una vecindad de 100 perfiles para calcular los puntajes que cada perfil tiene para cada nivel de Agregación 1 y 2. A modo de ejemplo se muestran tabla 10, los puntajes para el caso de un perfil que solo compró una lavadora de 12kg, marca Whirlpool.

Tabla 11 - Puntajes para perfil que compró una Lavadora de 12Kg marca Whirlpool

PUNTAJE	CONSECUENTE
17	LAVADO - SECADORAS - WHIRLPOOL - 2
11	ELECTRODOMESTICOS - MICROONDAS - SAMSUNG - 1
10	LAVADO - SECADORAS - WHIRLPOOL - 3
8	ELECTRODOMESTICOS - LIMPIEZA - SOMELA - 2
7	ELECTRODOMESTICOS - PLANCHA VAPOR – WHIRLPOOL - 2
7	ELECTRODOMESTICOS - MICROONDAS - SOMELA - 1
6	LAVADO - SECADORAS - FENSA - 2
5	ELECTRODOMESTICOS - LICUADORA - OSTER - 3
4	ELECTRODOMESTICOS - MICROONDAS - SAMSUNG - 2
4	ELECTRODOMESTICOS - PICADOR ELECTRICO - 3
3	COCINA - 4 PLATOS - WHIRLPOOL 4
3	ELECTRODOMESTICOS - PICADOR ELECTRICO - MOULINEX - 3
3	REFRIGERACION - DE 300 A 400 LTS - SAMSUNG - 5

Se aprecia que las recomendaciones tienen una lógica que invita a comprar electrodomésticos, muchos de ellos ligados a la limpieza del hogar o para el uso en la cocina. Lo más interesante es que el perfil de las recomendaciones de filtros colaborativos es muy distinto al tipo de recomendaciones que ofrecían las reglas de asociación, las cuales ofrecen grandes productos de línea blanca, como refrigeradores, congeladores, cocinas y lavadores, pero en este caso se ofrecen productos que tienen un valor mucho menor, como lo son licuadoras, aspiradoras, planchas o microondas.

### 7.3. Generación de las recomendaciones en templates dinámicos

La puesta en marcha del proyecto exige que se implemente un template web que pueda ser rellenado con contenido personalizado y único para cada persona. Esto exige la programación de un código cuya lógica fue descrita en la sección 6.3.

Esta etapa resultó ser en gran medida dificultosa porque exige que datos del mundo off-line se trabajen de manera simultánea con datos del mundo on-line, lo que se traduce con frecuencia en:

- Faltas de compatibilidad: El mundo on-line muchas veces funciona con data menos estructurada que el mundo off-line lo que implica que no siempre es inmediato cruzar información entre ambos mundos.
- Errores y mala calidad de la información: Muchas veces existen descoordinación entre la información, por ejemplo, existen casos de discrepancias sobre el estado de los productos que se tienen en el sitio web, y en el registro de stock que se obtiene desde el sistema de distribución.

Se tuvo que invertir gran cantidad de horas de trabajo para poder solucionar y trabajar con estas discrepancias, especialmente porque el sistema de recomendación, recomendaba a menudo productos que según la data off-line estaba con stock y publicado, pero que el sitio no tenía en sus registros.

Finalmente, con el código propuesto anteriormente, se logró desarrollar un algoritmo que funciona detrás del código del template y que soluciona tanto el problema de la discordancia de registros entre ambos mundos, como también el problema de que la información se podría actualizar durante el tiempo que pasa entre que el mail es enviado, y que el cliente finalmente lo abre en su celular o computador.

En la ilustración 11, se puede ver el template funcionando para ambas lógicas de recomendación, donde además se puede observar lo descrito en la sección anterior respecto a las diferencias entre el tipo de artículos y sus precios. Es bueno recordar que esto es causa de que los filtros colaborativos funcionan buscando productos populares, y que la métrica del lift, busca en cambio que dos productos se lleven juntos, limpiando los productos populares.

Ilustración 10 - Envío según FilTROS Colaborativos (izquierda) y Reglas de Asociación (derecha)

VISTE TU HOGAR  
CON LOS  
PRODUCTOS QUE  
SELECCIONAMOS  
PARA TI

VER TODO »



VISTE TU HOGAR  
CON LOS  
PRODUCTOS QUE  
SELECCIONAMOS  
PARA TI

VER TODO »



**Kitchenaid**  
Batidora Artisan Blanca  
**\$299.990**  
P. Normal: \$329.990

Comprar »



**Microplane**  
Rallador Shaver Largo Negro  
**\$15.990**  
P. Normal: \$15.990

Comprar »



**General Electric**  
Horno Empotrable Eléctrico  
Hge9020ei  
**\$599.990**  
P. Normal: \$599.990

Comprar »



**Ursus Trotter**  
Campana Kristalo 90  
**\$284.990**  
P. Normal: \$284.990

Comprar »



**Thomas**  
Horno Eléctrico 60 Lt  
**\$99.990**  
P. Normal: \$109.990

Comprar »



**Oster**  
Licuadora 4855 Cromada  
**\$49.990**  
P. Normal: \$49.990

Comprar »



**Bosch**  
Lavavajillas Smv68m70eu  
**\$569.990**  
P. Normal: \$569.990

Comprar »



**Electrolux**  
Side By Side Efr659g5mms  
470 Lt  
**\$899.990**  
P. Normal: \$999.990

Comprar »



**Tefal**  
Sartén 28 Cm Sensation  
**\$12.990**  
P. Normal: \$25.990

Comprar »



**Oster**  
Sandwichera / Waflera 3892  
**\$24.990**  
P. Normal: \$24.990

Comprar »



**Kitchenaid**  
Batidora De Pedestal Heavy  
Duty Bowl 6.9 Lt  
**\$639.990**  
P. Normal: \$639.990

Comprar »



**Sindelen**  
Freezer Vertical Sfv-210sil185  
Lt  
**\$199.990**  
P. Normal: \$199.990

Comprar »

## 7.4. Desarrollo de los experimentos

Finalmente, para llevar a cabo los experimentos, se dividió la base de personas que activaron un trigger en 4 grupos divididos de manera aleatoria, esta distribución se puede observar en la tabla 11 que indica cuantas personas estuvieron en cada grupo, y para cada trigger. Lo más relevante aquí es notar que pese a que en un comienzo los grupos eran de tamaños similares, después de los envíos los grupos nos son completamente parejos en proporción. Esto se debe, en primera instancia, a que hay un grupo de personas a los cuales no les llega el correo electrónico, ya sea porque están en listas de exclusión, o porque tienen el buzón lleno (error común en mails corporativos), o porque simplemente hubo algún rebote asociado a otros factores, dejando claro el por qué todos los grupos mails son de menor tamaño que el grupo de control.

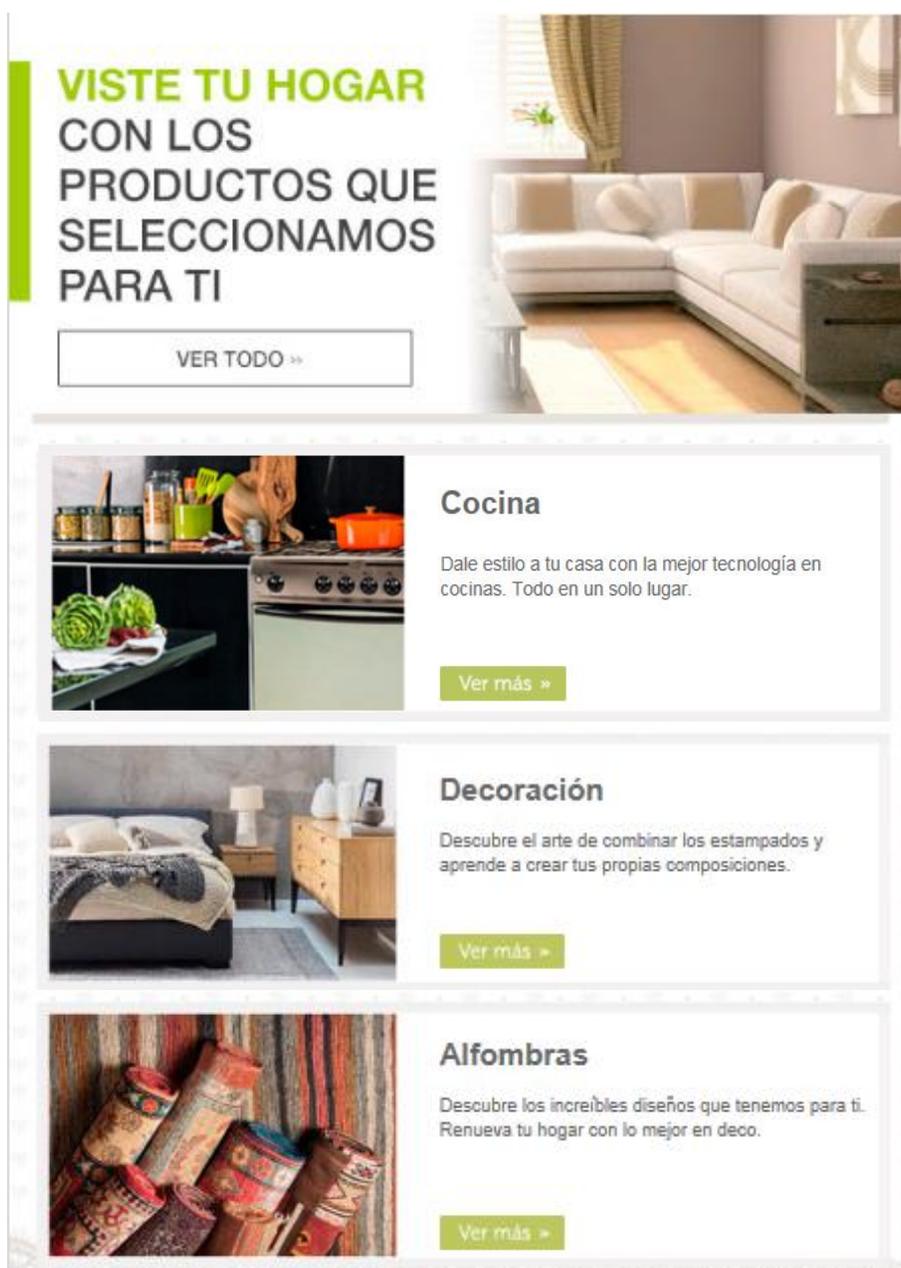
Tabla 12 - Distribución de los grupos de tratamiento

Línea de Evaluación	FILTRO COLABORATIVO	MAIL GENÉRICO	REGLAS DE ASOCIACIÓN	GRUPO CONTROL
Cocina	1024	1029	1141	1357
Lavado	2495	2811	2848	3584
Refrigeración	1399	1696	1666	2150
<b>Total Línea Blanca</b>	<b>4918</b>	<b>5536</b>	<b>5655</b>	<b>7091</b>
Comedor	428	398	417	547
Tapicería	1140	1176	1211	1531
<b>Total Muebles</b>	<b>1568</b>	<b>1574</b>	<b>1628</b>	<b>2078</b>
<b>Total</b>	<b>6486</b>	<b>7110</b>	<b>7283</b>	<b>9169</b>

Otra razón, es algo que ya se discutió en la sección 7.3, y es que existen problemas en la implementación de estos mails dinámicos que hicieron que algunos correos de los filtros colaborativos no se enviaran debido a incongruencias en los productos publicados. Existe razón para pensar que estos problemas radican en que los productos recomendados por filtros colaborativos, al ser productos más populares y de mayor rotación, tienden a tener más discrepancias y quiebres de stock que aquellos productos de mayor precio y que tienen menor rotación. Aun así estos problemas parecieran invalidar los experimentos dado que son problemas que suceden de manera aleatoria dentro del grupo, y no deberían estar induciendo errores de selección.

Por otro lado, hay que especificar que el envío genérico corresponde a un mail con una gráfica idéntica a la que aparece en la ilustración 12, donde lo que se pretende es invitar a navegar dentro del sitio web para ver el mix de productos, a diferencia de los mails anteriores donde se invita a ver directamente los productos en el mail. El objetivo de este mail es entender si es que el efecto mail es suficiente para gatillar la compra, y no es necesario invertir tiempo en utilizar un sistema de recomendación que podría estar solo dando una complejidad innecesaria.

Ilustración 11 - Template Mail Genérico



**VISTE TU HOGAR  
CON LOS  
PRODUCTOS QUE  
SELECCIONAMOS  
PARA TI**

[VER TODO »](#)

**Cocina**  
Dale estilo a tu casa con la mejor tecnología en cocinas. Todo en un solo lugar.  
[Ver más »](#)

**Decoración**  
Descubre el arte de combinar los estampados y aprende a crear tus propias composiciones.  
[Ver más »](#)

**Alfombras**  
Descubre los increíbles diseños que tenemos para ti. Renueva tu hogar con lo mejor en deco.  
[Ver más »](#)

## 7.5. Evaluación de resultados

### 7.5.1. Evaluación Venta Incremental Promedio a nivel Global

Lo primero es evaluar la campaña a nivel global, es decir, si las distintas lógicas de recomendación generan ventas incrementales por sobre el grupo de control. Esta venta incremental se calcula como la diferencia entre las medias de venta de los distintos grupos en análisis, es decir, se compara la media entre el grupo mail, cualquiera esta sea, respecto a la media de venta del grupo de control.

Lo que se ve en la Ilustración 13 es que la lógica que genera mayor venta incremental es la de filtros colaborativos, seguidas de reglas de asociación y por último el mail genérico. Lo destacable es que las 3 lógicas generan venta incremental, lo cual significa que efectivamente la idea de estimular a un cliente que se acaba de comprar un producto de estas categorías más duras es rentable.

El segundo detalle es que los filtros colaborativos se disparan por sobre la media de los otros dos envíos, dando la sensación de que esa fuera la estrategia que más beneficios podría traer a la compañía, pero estadísticamente hablando no existe suficiente evidencia que indique que una estrategia es mejor que la otra, aunque lo que si es estadísticamente significativo, es que los 3 grupos de clientes que recibieron el mail, tuvieron mayor gasto, en promedio, que el grupo de control. Los test estadísticos se pueden observar en las tablas 12 a 17.

Ilustración 12 - Venta Incremental Promedio según tipo de Envío, Global

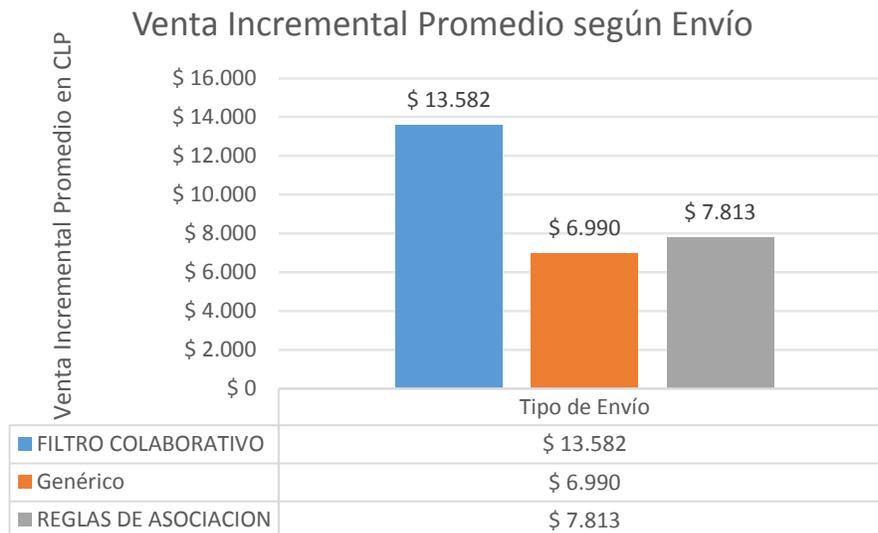


Tabla 13 - Estadísticos descriptivos de los GC y Filtros Colaborativos

			Gasto Promedio		Test de igualdad de varianzas		Test de igualdad de Medias	
Envío	N Resp	N GC	Media envío	Media GC	F	Significancia	t	Significancia
FC	483	696	\$32.205	\$18.623	13,919	0,000	-2,265	0,024
RA	556	696	\$26.436	\$18.623	7,444	0,006	-1,952	0,051
Genérico	528	696	\$25.614	\$18.623	8,023	0,005	-2,006	0,045

La importancia de estos test estadísticos radica, en primer lugar en poder asegurar que realmente el efecto mail genera venta incremental y que las variaciones observadas no responden a solamente a la varianza de los datos. El test de medias tiene el supuesto de que las varianzas son las mismas en ambos grupos, y para testear esta hipótesis se incluye el test de Levene, el cual es significativo para todos los casos.

En términos de respuesta incremental, que se entiende como la proporción de clientes que efectuaron una compra en comparación con la misma proporción del grupo de control, se observa que no existen diferencias significativas y estadísticamente tampoco es posible asegurar que más clientes fueron a comprar debido al mail, lo que indica que la totalidad de la venta incremental es fundamentalmente explicada en términos de aumento del gasto por persona.

Tabla 14 - Tasa de respuesta de los distintos experimentos

Medida	Global	Línea Blanca	Muebles
Promedio de respuesta	7,51%	7,33%	8,07%
Desviación Estándar	0,10%	0,26%	0,63%

Tabla 15 - Tasas de respuesta según tipo de Envío, para cada Línea

Tipo de Envío	Global	Línea Blanca	Muebles
FILTRO COLABORATIVO	-0,15%	-0,49%	0,87%
Mail Genérico	-0,17%	-0,04%	-0,62%
REGLAS DE ASOCIACION	0,03%	0,10%	-0,19%

## 7.5.2. Evaluación Venta Incremental Promedio para Línea Blanca

Por otro lado, en la ilustración 14 se analiza la venta incremental solo para los tres envíos de línea blanca, y se aprecia que se acentúan las diferencias encontradas entre los filtros colaborativos, y las demás lógicas de recomendación, esto se puede deber a que sea más atractivo para el cliente el hecho de que se le ofrezcan productos que son más accesibles para él o ella, lo que genera una buena disposición a comprar independiente de si compra o no alguno de los productos ofrecidos. Esto puede contraponerse con el hecho de que las reglas de asociación ofrecían productos más caros, que son más difíciles de promover en una venta compulsiva. Por último, la invitación a la categoría requiere un mayor esfuerzo del cliente, ya que obliga al usuario a navegar por la página web para ver un producto que le podría servir.

Como era de esperarse, el test de media de la ilustración 15, sugiere que la diferencia de medias entre filtros colaborativos y el grupo de control es significativa, pero no se puede decir lo mismo de los otros dos tratamientos, los cuales no logran generar ventas incrementales que sean significativas estadísticamente.

Ilustración 13 - Venta Incremental Promedio según tipo de Envío, Línea Blanca

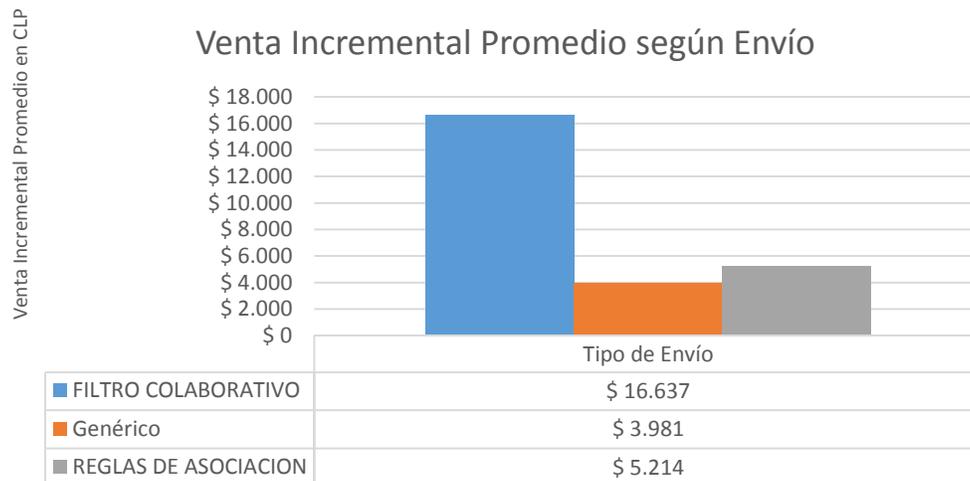


Tabla 16 - Test de significancia estadística para los experimentos de línea blanca

Envío	N Resp	N GC	Gasto Promedio		Test de igualdad de varianzas		Test de igualdad de Medias	
			Media envío	Media GC	F	Significancia	t	Significancia
FC	343	696	\$36.658	\$20.021	15,382	0,000	-2,178	0,030
RA	428	696	\$25.235	\$20.021	5,55	0,019	-1,149	0,251
Genérico	411	696	\$24.003	\$20.021	9,94	0,002	-1,299	0,194

### 7.5.3. Evaluación Venta Incremental Promedio para Muebles

Adicionalmente, en la ilustración 15 se puede observar el efecto contrario al descrito para el caso de línea blanca, y esto se puede explicar por qué el mundo de decoración es muy diferente al mundo Electro Hogar. Aun así en la tabla 16 se aprecia que ninguna de los tratamientos genera diferencias significativas respecto al grupo de control. Aun así se observa leve tendencia a que el mail genérico funciona mejor que las otras dos alternativas. Esto puede deberse a que en el mundo Deco es importante que el producto se vea bien dentro del hogar, y para ello la invitación a productos particulares puede ser demasiado específica, y difícil de estimar con la cantidad de transacciones registradas por cada cliente. Por lo tanto, para categorías donde la tendencia, el estilo, y el diseño juegan un rol importante, lo más sensato sería invitarlo a navegar, y que sea el cliente quien decida el producto, a menos de que se tenga una noción muy certera respecto a los estilos y los gustos de los clientes.

Ilustración 14 - Venta Incremental Promedio según tipo de Envío, Muebles



Tabla 17 - Test de significancia estadística para los experimentos de línea blanca

Envío	N Resp	N GC	Gasto Promedio		Test de igualdad de varianzas		Test de igualdad de Medias	
			Media envío	Media GC	F	Significancia	t	Significancia
FC	140	167	\$21.294	\$14.195	0.11	0,74	-0.891	0,374
RA	128	167	\$30.453	\$14.195	1.78	0,18	-1,713	0,087
Genérico	117	167	\$31.273	\$14.195	1.28	0,25	-1,533	0,126

### 7.5.1. Análisis de tasas de Click y Apertura

Se puede observar en la ilustración 16 que las tasas de apertura son estables para los distintos tratamientos, lo cual tiene mucho sentido dado que el cliente es ciego a lo que se le está enviando. Ahora bien, en termino de tasa de click la historia es diferente, ya que el envío genérico que invitaba a navegar en la tiene sistemáticamente mejores tasas de click, categoría desata la curiosidad de los clientes en mayor medida que los mails con invitación a productos, lo cual tampoco reviste una sorpresa dado que en la empresa es bien sabido que la invitación a la categoría tiene mejor tasa de click que la invitación al producto, técnica que es utilizada para aumentar tasa de click de algunas campañas específicas.

Lo interesante del resultado anterior es que es contra intuitivo pensando que generó menos venta incremental que los demás tipos de mails, pero como ya lo habíamos discutido antes, obligar al cliente a navegar no implica necesariamente influenciar su tendencia a la compra.

Tabla 18 Numero de mails enviados, tasas de apertura, y tasas de clicks

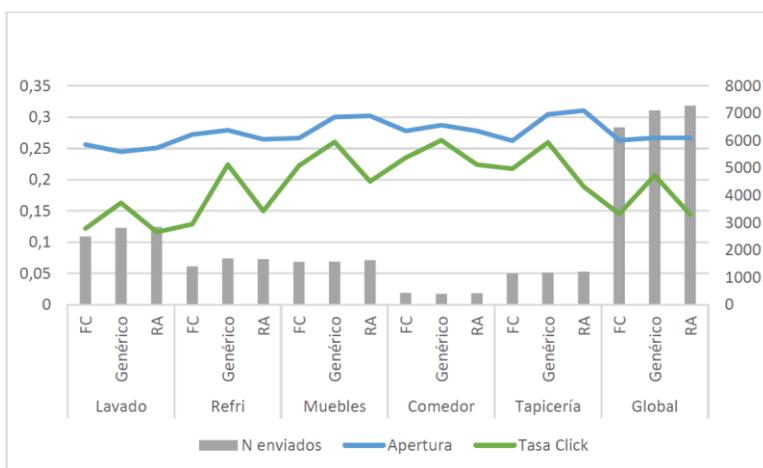


Tabla 19 Tasa de Apertura y Clicks para cada envío

### 7.5.2. Análisis de venta incremental por cliente

Otra forma de evaluar campañas de email marketing es a través del cálculo de cuanta venta incremental son capaces de generar por cada persona que fue contactada mediante correo electrónico, esta medida es útil para poder comparar la efectividad de distintas campañas independiente de la cantidad de clientes contactados. En comparación con el estándar de la empresa estas campañas destacan en la cantidad de venta incremental por cliente.

Tabla 20 venta incremental por envío y por categoría de producto

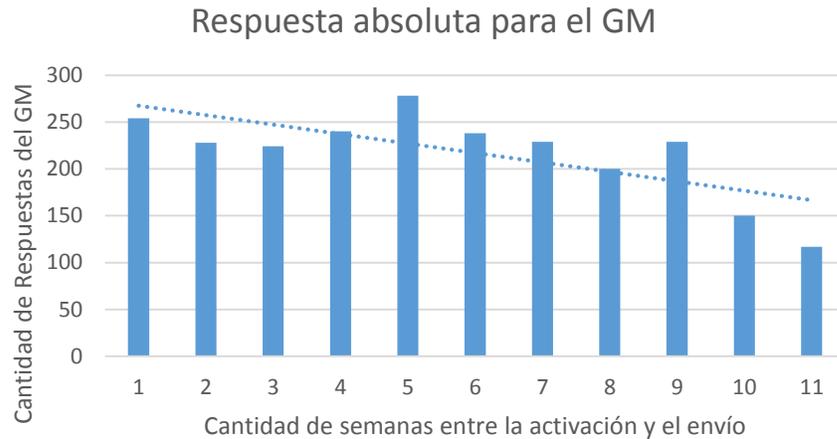
Tipo de Envío	Global		Línea Blanca		Muebles	
	Venta Incremental	Venta por Mail	Venta Incremental	Venta por Mail	Venta Incremental	Venta por Mail
FILTRO COLABORATIVO	\$ 6.559.907	\$ 1.012	\$ 5.706.434	\$ 1.161	\$ 993.940	\$ 634
Genérico	\$ 3.690.895	\$ 519	\$ 1.636.262	\$ 296	\$ 1.998.174	\$ 1.270
REGLAS DE ASOCIACION	\$ 4.344.119	\$ 597	\$ 2.231.563	\$ 395	\$ 2.081.046	\$ 1.278
TOTAL	\$ 14.594.921	\$ 699	\$ 9.574.259	\$ 595	\$ 5.073.160	\$ 1.064

A lo largo del año, son unos 180.000 mil clientes los que activarían alguna de estas campañas de email marketing en todo el territorio nacional, considerando las ventas por cliente que se obtuvieron en este ejercicio sean \$699, es fácil estimar que este tipo de campañas podrían generar ventas incrementales por sobre los \$120 millones de pesos al año. Ahora bien, si se utilizan las mejores prácticas en cada mundo, y se usan filtros colaborativos en línea blanca, e invitación a categoría y/o reglas de asociación en muebles, esa cifra aumenta a más de \$210 millones de pesos al año. Si es que además se considera que se pudieran automatizar con tareas programadas, el único trabajo adicional sería para el ingeniero de inteligencia, mantener los modelos actualizados, y sometidos a una mejora continua.

### 7.5.3. Análisis de temporalidad

La idea de este análisis es identificar cuánto tiempo habría que esperar para enviar el mail de modo de generar el mayor impacto. En la ilustración 18, se observa la tasa de respuesta en función de las semanas transcurridas desde que la persona compró el artículo que gatilló la campaña. Se aprecia que no existe una tendencia clara respecto a la cantidad de semanas a esperar, y esto se puede explicar debido que el proceso de vestir o renovar un hogar probablemente dura más semanas de lo que este experimento fue capaz de evaluar. Con esto en consideración, pareciera tener sentido explorar la alternativa de realizar campañas sucesivas a los clientes que activen los triggers, invitando en varias oportunidades a comprar un mix diferente de productos, y aumentando la probabilidad de acertar con los productos recomendados.

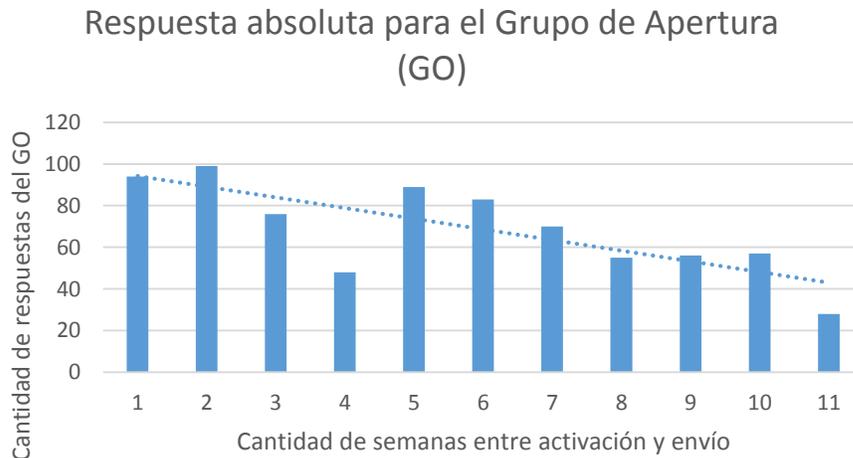
Ilustración 15 – Respuesta del Grupo Mail (GM) según el periodo entre activación y envío



En la Ilustración 17, se grafica lo mismo que en la ilustración 16, pero la diferencia es que esta graficada sobre la base de personas que si abrieron el mail, donde se ve que la tendencia es incluso más notoria.

A modo de recomendación para la empresa, lo que se podría hacer es una campaña “inmediata” que a lo más se demore 1 semana en hacer el envío, y una campaña de refuerzo para aquellos que no respondieron a la primera, esta segunda campaña podría tomarse hasta un mes de plazo, ya que a simple vista las respuestas en ambos gráficos no bajan demasiado durante las primeras 4 o 5 semanas

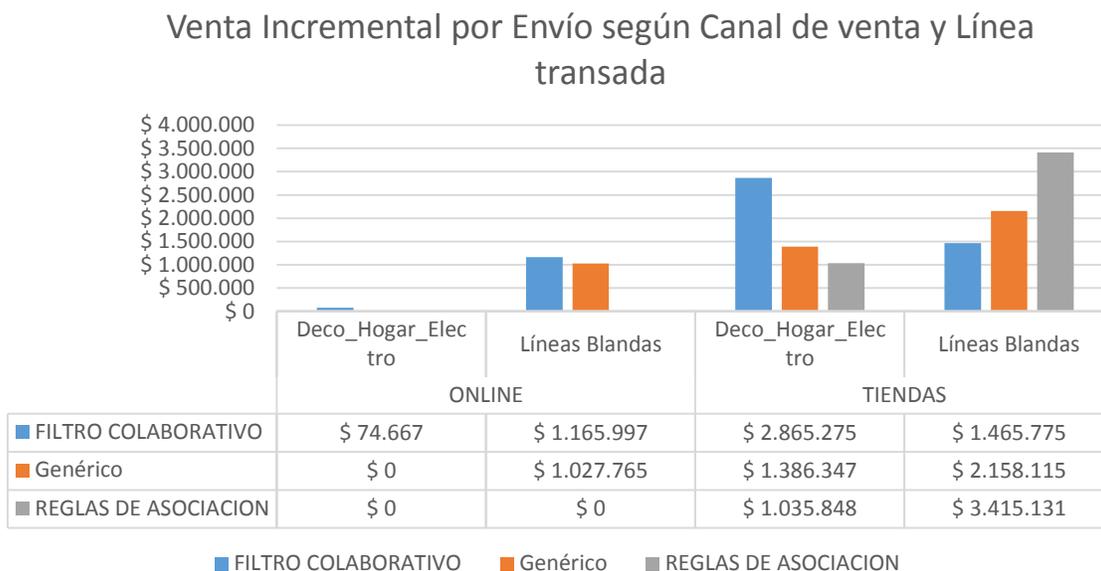
Ilustración 16 - Respuesta del Grupo Apertura (GO) según el periodo entre activación y envío



### 7.5.4. Evaluación Multicanal Venta Incremental a nivel Global

Por último, es interesante entender en que líneas de productos, y en que canales de venta se generó la venta incremental. Esto se puede ver en la ilustración 18, que muestra dos grandes categorías de productos, una es la línea Deco hogar y la otra son las líneas blandas, además existen dos canales de venta clásicos que son las ventas por internet, y por otro lado las ventas en tienda física.

Ilustración 17 - Venta Incremental a nivel Global según línea Transada y Canal de venta



Se aprecia claramente que la mayor parte de la venta incremental fue generada en tiendas físicas y no por el canal online, de hecho la venta incremental en el sitio web representa un 14% del total. Este porcentaje es mayor que el 11% que representa el canal online dentro de la venta de la compañía, lo que implica que se está llevando flujo de ventas al sitio web.

También se observa que más del 50% de la venta incremental no se generó en las líneas promocionadas de decoración y electro hogar. Este resultado no es sorprendente debido a la naturaleza multicategoría de la tienda, donde debido a la comunicación de un producto en particular, es posible llevar tráfico y ventas cruzadas a categorías diferentes.

## 8. Conclusiones

La primera y más importante conclusión es que efectivamente los estímulos de venta cruzada sirven para incentivar la venta en aquellos clientes que han comprado bienes durables en las categorías de línea blanca, por otro lado los resultados en la categorías de muebles aunque los resultados no son concluyentes se sugiere continuar la experimentación de forma de ganar mayor validez estadística en los resultados.

El resultado de los experimentos sugiere que la mejor estrategia ya que para la categoría de línea blanca resultó ser considerablemente más rentable promover la compra de electrodomésticos menores como microondas, sartenes eléctricos, batidoras, y otros utensilios de cocina, como lo hace la lógica de filtros colaborativos, en vez de la de grandes electrodomésticos como freezers, campanas, y otros grandes elementos de línea blanca como lo hacían las reglas de asociación.

Por otro lado, aquellos clientes que compraron muebles, fueron mucho más atraídos por las lógicas genéricas que por las recomendaciones de filtros colaborativos, esto puede ser explicado debido a que las categorías que están ligadas más al diseño y a la estética, podrían tener una dinámica diferente de venta, y puede ser más atractivo invitar al cliente a navegar dentro de un gran número de opciones y al mismo tiempo, hacerlo imaginar cómo remodelar un espacio de su hogar. Las reglas de asociación por otra parte, que invitan a los compradores de muebles a comprar otros muebles como repisas, mesas, pisos y sillones, parecieran tener mejor resultado con los clientes que las recomendaciones generadas mediante filtros colaborativos que consistentemente recomendaban elementos de menaje y decoración, como set de cuchillos, ollas, lámparas, alfombras.

Además, la estrategia de venta tiene un impacto incremental en el canal de venta online, logrando generar venta incremental en una proporción mayor que la que típicamente se observa en la empresa en estudio, esto puede estar indicando la migración de flujo desde el canal de venta físico al web. Por otra parte el 86% de la venta incremental se genera en el canal tradicional de venta física lo cual habla de un efecto fidelización de los clientes, que los hace volver a la tienda, algo que es muy valioso en un ambiente que como se dejó claro en el principio de este documento, tiene abundantes competidores en todas las categorías en las que compete.

Esta venta incremental tiene un efecto tanto en las categorías duras de Electro hogar y Deco Hogar, como en las categorías blandas de vestuario, calzado, belleza y perfumería. Es interesante notar que el 50% de la venta se realiza en las líneas

promocionadas, dándole un peso muy significativo a las ventas cruzadas en categorías blandas.

Por último, el estudio no es capaz de concluir cuanto tiempo debe pasar entre que se activa el trigger, y se envía la campaña de email marketing, se sugiere continuar la investigación considerando varios horizontes de tiempos, enviándole al cliente campañas secuenciales que den más luces sobre cuantos mails se deben enviar, con qué frecuencia, y cuanto demorarse al reaccionar a un mail.

## **9. Trabajos futuros**

La continuación de este trabajo apunta principalmente en dos direcciones, la primera tiene que ver con el aumento de categorías que podrían desarrollar dinámicas similares de recomendación, entendiendo que categorías como camas podrían generar campañas que busquen vestir el dormitorio con decoración, cortinas, muebles, televisiones, etc. También en el caso de los compradores de televisiones podrían gatillar campañas que busquen complementar su experiencia con accesorios de audio, video, o muebles de televisión.

Incluso esto podría extrapolarse a categorías blandas como belleza, y accesorios de mujer, comprendiendo que los tratamientos de belleza y de cuidado facial también podrían estar dando insights sobre los intereses de las clientas sobre sus preocupaciones e intereses, y podrían gatillar acciones invitándolas a comprar productos complementarios.

Otras alternativas de triggers que podrían explorarse con enfoques similares hacen referencia a los eventos de regalos que existen durante el año, tales como los días del niño, del padre, y/o de la madre, o incluso navidad, donde podrían encontrarse patrones en la compra de regalos y que podrían también generar información sobre que otros regalos podrían estar interesados en comprar en determinados momentos.

Desde la perspectiva más técnica y menos comercial, sistemas de recomendaciones usando redes Bayesianas, o cadenas de Markov también son discutidos en la literatura, y podrían generar un nuevo enfoque desde donde abordar las recomendaciones. Estos enfoques permiten predecir los posibles estados que un cliente podría adoptar y modelan la transición entre estos estados, en este caso particular la compra de un producto específico determina un posible estado del cliente, y se podría calcular la probabilidad con la que un cliente podría transitar al estado siguiente.

Por último, aprovechando que la experiencia de compra multicanal es muy importante hoy en día y que va en alza, se podrían implementar sistemas de recomendación en tiempo real para las personas que están en la tienda, utilizando su historial de compras, sugiriéndole ofertas y productos que estén en otros pisos de la tienda, y que si no es por el aviso, el cliente podría no enterarse de su existencia.

## Anexos

Anexo 1 Estadísticos de las pruebas de Levene y T entre el GC y Filtros Colaborativos

Grupo		N	Media	Desviación típ.	Error típ. de la media
VENTA	Grupo Control	696	18623,29	44578,263	1689,735
	Filtros Colaborativos	483	32204,88	148877,525	6774,162

Anexo 2 Estadísticos de las pruebas de Levene y T entre el GC y Filtros Colaborativos

		Prueba de Levene para la igualdad de varianzas		Prueba T para la igualdad de medias		
		F	Sig.	t	gl	Sig. (bilateral)
VENTA	Se han asumido varianzas iguales	13,919	,000	-2,265	1177	,024

Anexo 3- Estadísticos descriptivos de GC y Reglas de Asociación

Grupo		N	Media	Desviación típ.	Error típ. de la media
VENTA	Grupo Control	696	18623,29	44578,263	1689,735
	Reglas de Asociación	556	26436,45	93075,044	3947,261

Anexo 4 - Estadísticos de las pruebas de Levene y T entre el GC y Reglas de Asociación

		Prueba de Levene para la igualdad de varianzas		Prueba T para la igualdad de medias		
		F	Sig.	t	gl	Sig. (bilateral)
VENTA	Se han asumido varianzas iguales	7,444	,006	-1,952	1250	,051

Anexo 5 - Estadísticos descriptivos de GC y Grupo Mail Genérico

Grupo		N	Media	Desviación típ.	Error típ. de la media
VENTA	Grupo Control	696	18623,29	44578,263	1689,735
	Grupo Mail Genérico	528	25613,62	76369,119	3323,539

Anexo 6 - Estadísticos de las pruebas de Levene y T entre el GC y Grupo Mail Genérico

	Prueba de Levene para la igualdad de varianzas		Prueba T para la igualdad de medias		
	F	Sig.	t	gl	Sig. (bilateral)
VENTA Se han asumido varianzas iguales	8,023	,005	-2,006	1222	,045

Anexo 6 - Estadísticos de las pruebas de Levene y T entre el GC y Grupo Mail Genérico

		<b>CLICK</b>	<b>OPEN</b>	<b>Enviados</b>	<b>Apertura</b>	<b>Tasa Click</b>
Global	FILTRO COLABORATIVO	248	1706	6482	26,32%	14,54%
	Genérico	392	1896	7106	26,68%	20,68%
	REGLAS DE ASOCIACION	280	1943	7282	26,68%	14,41%
Línea Blanca	FILTRO COLABORATIVO	155	1288	4914	26,21%	12,03%
	Genérico	269	1424	5533	25,74%	18,89%
	REGLAS DE ASOCIACION	183	1451	5654	25,66%	12,61%
Cocina	FILTRO COLABORATIVO	28	268	1023	26,20%	10,45%
	Genérico	51	263	1029	25,56%	19,39%
	REGLAS DE ASOCIACION	34	296	1141	25,94%	11,49%
Lavado	FILTRO COLABORATIVO	78	639	2492	25,64%	12,21%
	Genérico	112	688	2811	24,48%	16,28%
	REGLAS DE ASOCIACION	83	714	2847	25,08%	11,62%
Refrigeración	FILTRO COLABORATIVO	49	381	1399	27,23%	12,86%
	Genérico	106	473	1693	27,94%	22,41%
	REGLAS DE ASOCIACION	66	441	1666	26,47%	14,97%
Muebles	FILTRO COLABORATIVO	93	418	1568	26,66%	22,25%
	Genérico	123	472	1573	30,01%	26,06%
	REGLAS DE ASOCIACION	97	492	1628	30,22%	19,72%
Comedor	FILTRO COLABORATIVO	28	119	428	27,80%	23,53%
	Genérico	30	114	397	28,72%	26,32%
	REGLAS DE ASOCIACION	26	116	417	27,82%	22,41%
Tapicería	FILTRO COLABORATIVO	65	299	1140	26,23%	21,74%
	Genérico	93	358	1176	30,44%	25,98%
	REGLAS DE ASOCIACION	71	376	1211	31,05%	18,88%

## Bibliografía

- [1] Centro de estudios del retail, «CERET,» [En línea]. Available: <http://www.ceret.cl/indicadores-tiendas-por-depto/2012-2/>
- [2] C. Twogood, «The Power of Event-Based Marketing,» Teradata, 2011
- [3] Flow20, [En línea]. Available: <http://www.flow20.com/what-most-online-retailers-can-learn-from-amazon-co-uk/>
- [4] M. Hahsler, «A Framework for Developing and Testing Recommendation Algorithms,» 2011.
- [5] S. A. Alvarez, «Efficient Adaptive-Support Association Rule Mining for Recommender Systems,» Boston College, USA, 2015
- [6] C.-H. J. J. L. S. K. Jong-Seok Lee, «Classification-based collaborative filtering using market basket data,» Department of Industrial Engineering, Pohang University of Science and Technology, 2005.
- [7] R. G. Esther Duflo, «USING RANDOMIZATION IN DEVELOPMENT ECONOMICS RESEARCH: A TOOLKIT,» *Handbook of development economics*, 2007
- [8] A. Rojas, ESTUDIO EXPERIMENTAL DE AUTOMATIZACIÓN DE EMAIL MARKETING EN UN RETAIL ONLINE, 2014.
- [9] M. Hahsler, «Introduction to arules - A computational environment for mining association rules and frequent item sets»