



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

MODELOS DE PROPENSIÓN INTEGRADOS PARA LA OPTIMIZACIÓN DE CAMPAÑAS DE MARKETING

TESIS PARA OPTAR AL GRADO DE MAGÍSTER EN GESTIÓN DE OPERACIONES

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL INDUSTRIAL

DANIEL WILSON MATTHEY

PROFESOR GUÍA:
RICHARD WEBER HAAS

MIEMBROS DE LA COMISIÓN:
CRISTIÁN BRAVO ROMÁN
LUIS ABURTO LAFOURCADE
VERÓNICA LARA RODRIGUEZ

SANTIAGO, CHILE
SEPTIEMBRE 2013

Resumen Ejecutivo

Las campañas de marketing son una herramienta fundamental con la cual las empresas afianzan la relación con sus clientes. Mediante la realización de ofertas atractivas a través del canal apropiado, se busca incrementar la satisfacción de los consumidores y por ende la utilidad de la compañía. Sin embargo, el proceso de asignación de ofertas y canales a clientes no es trivial, debido a la existencia de restricciones del negocio tales como: presupuesto disponible, capacidad de los canales, máximo de ofertas por cliente, entre otras.

El presente trabajo de título tuvo como objetivo la construcción de un modelo de optimización para campañas de marketing, decidiendo qué ofertas realizar, a qué clientes enviarlas y a través de qué canal de venta. La metodología desarrollada se centra en la integración de modelos de propensión, que determinan la probabilidad de que un cliente responda positivamente a una oferta específica. Considerando dichas probabilidades, el modelo busca maximizar la utilidad esperada de la campaña, sujeto a restricciones del negocio.

Dado que el problema es NP-completo, se propuso un enfoque heurístico para resolver la optimización. La metodología desarrollada consiste en separar la resolución del problema en tres etapas: selección de las ofertas a activar, asignación factible de canales y asignación factible de clientes. Cada solución encontrada se somete a la búsqueda de vecinos y posteriormente a un proceso de mutación. Además se desarrolló una etapa previa de clusterización, en la cual se disminuye el tamaño de la instancia y por ende los tiempos de ejecución.

Se comparó el algoritmo propuesto con otros métodos desarrollados en la literatura, obteniéndose como resultado un mejor rendimiento en términos de la calidad de la solución y tiempos de ejecución. También se realizó una aplicación real del algoritmo a una empresa chilena perteneciente a la industria del retail financiero. En ella se comparó la metodología propuesta con otras tres más básicas, obteniéndose resultados favorables en términos de venta incremental, utilidad y clientes estimulados.

Agradecimientos

Al profesor Richard Weber por su paciencia y comprensión durante este proceso. A mi familia y amigos que me acompañaron en todo momento. A mi esposa Cecilia, pues sin ella nada de esto tendría sentido.

Tabla de contenido

Resumen Ejecutivo	I
1. Introducción	1
2. Estado del arte	3
2.1. Modelos de propensión	3
2.2. Next best offer	5
2.3. Optimización de campañas de marketing	6
3. Modelo matemático para el problema de negocio	10
3.1. Descripción	10
3.2. Modelo matemático	11
3.3. Contribuciones del presente trabajo	14
4. Algoritmo heurístico para la optimización de campañas de marketing	16

4.1. Algoritmo principal	16
4.1.1. Combinación de ofertas a activar	17
4.1.2. Asignación factible de canales	20
4.1.3. Asignación factible de clientes	21
4.1.4. Búsqueda de soluciones vecinas	23
4.2. Agrupación de clientes	26
5. Resultados	29
5.1. Experimentos computacionales	29
5.1.1. Generación de instancias	30
5.1.2. Comparación de resultados	30
5.2. Aplicación en un caso real	32
5.2.1. La empresa	32
5.2.2. Metodologías a comparar	32
5.2.3. El experimento	33
5.2.4. Resultados	34
6. Análisis de sensibilidad	37
6.1. Canal de venta fijo	37

6.2. Oferta fija	38
6.3. Tamaño de los clusters	39
6.4. Restricciones de negocio	40
6.4.1. Presupuesto global	41
6.4.2. Límite de ofertas por cliente	43
6.4.3. Capacidad de canales de venta	44
7. Conclusiones	45
Bibliografía	48

Índice de figuras

2.1. Optimización de campañas de marketing vs. <i>Next best offer</i>	7
4.1. Método de selección de vecinos	27
6.1. Utilidad esperada vs tamaño de los clusters	39
6.2. Tiempo de ejecución vs tamaño de los clusters	40
6.3. Utilidad esperada vs tamaño de los clusters	40
6.4. Tiempo de ejecución vs tamaño de los clusters	41
6.5. Utilidad esperada vs presupuesto global	42
6.6. Variaciones de la utilidad esperada y presupuesto global	42
6.7. Utilidad esperada vs máximo de ofertas por cliente	43

Índice de cuadros

5.1. GAP con respecto al óptimo	31
5.2. Tiempos de ejecución (segundos)	31
5.3. Asignación de clientes por cada metodología	34
5.4. Utilidad esperada y tiempo de ejecución	35
5.5. Resultados reales de la campaña	35
6.1. Utilidad esperada (MM\$)	38
6.2. Utilidad esperada (MM\$)	38

Capítulo 1

Introducción

Debido a los grandes avances en tecnologías de almacenamiento y transmisión de datos, hoy las empresas poseen gran cantidad de información de sus clientes, desde características generales como el perfil socio demográfico hasta el comportamiento detallado de sus compras: productos, monto, frecuencia, formas de pago, etc. Lo anterior combinado con herramientas computacionales, estadísticas y matemáticas permiten a las compañías explotar esta riquísima fuente de conocimiento con la posibilidad de maximizar el valor agregado en la relación con sus clientes.

Por otro lado, el aumento del acceso de los consumidores a la información ha intensificado la competencia debido al mayor poder de comparación entre productos y marcas. Además, la interconectividad existente gracias a las redes sociales y smartphones entrega a los usuarios la posibilidad de conocer opiniones de otros compradores, realizar reclamos o recomendaciones en línea o buscar las ofertas que más le convengan. Todo esto está inclinando cada vez más el balance de poder hacia los clientes cuya creciente exigencia hace imprescindible para las empresas el descubrimiento de sus preferencias y la satisfacción de sus expectativas.

Dado lo anterior, para que una compañía mantenga y fortalezca la relación con su cartera de clientes en el tiempo, es fundamental que el conjunto de ofertas que se realicen sean personalizadas y coherentes para cada usuario. Por esta razón, el proceso de selección del producto/servicio a ofrecer, el canal de comunicación y el cliente objetivo se hace crítico. El presente trabajo se

enfoca justamente en este último punto: la asignación óptima (oferta-cliente-canal) de campañas de marketing para fortalecer la relación cliente-empresa, maximizando la satisfacción del usuario (mediante ofertas coherentes y atractivas) y la utilidad de la firma (incrementando la probabilidad de respuestas positivas a la campaña).

El primer paso para lograr realizar ofertas afines a cada cliente consiste en la construcción de modelos de propensión o modelos de respuesta, que asignan a cada consumidor la probabilidad de responder positivamente a la oferta de un producto/servicio [1, 2, 5]. En general el uso otorgado a dichos modelos consiste en priorizar las ofertas según la probabilidad calculada, maximizando la tasa de respuesta esperada y disminuyendo el costo de la campaña (menos clientes a los cuales contactar). Sin embargo, el uso de modelos de propensión de manera individual (por producto/servicio) no es suficiente, pues se contradice con el objetivo de las organizaciones centradas en el cliente y no en los productos. La meta es ofrecer el producto correcto, al cliente correcto y a través del canal indicado. Lo anterior tiene como consecuencia directa la generación de campañas con múltiples productos/servicios en lugar de ofertas separadas e independientes. Además, las restricciones del negocio hacen compleja la decisión de qué ofrecer a cada cliente. Por ejemplo: el presupuesto asignado a las campañas, el máximo de ofertas por persona, la capacidad de los canales, entre otras. La presente tesis propone justamente una forma de resolver el problema de asignación óptima de cliente-oferta-canal, buscando maximizar la utilidad de la campaña tomando en cuenta las restricciones existentes.

El presente trabajo se estructura como sigue. En la Sección 2 se describe el estado del arte, dentro del cual se analizarán trabajos que serán utilizados posteriormente como punto de comparación al momento de realizar los experimentos computacionales. En la tercera sección se describe el problema a resolver desde el punto de vista del negocio junto con la formulación matemática del mismo. La sección 4 presenta la heurística construida para resolver el problema, aproximando la solución óptima y reduciendo el tiempo de ejecución. Los resultados experimentales se pueden ver en la quinta sección junto con la aplicación del presente algoritmo en un caso real. Finalmente se presentan las conclusiones del trabajo en la sección 7 seguidas de la bibliografía consultada.

Capítulo 2

Estado del arte

2.1. Modelos de propensión

Identificar a los clientes más propensos a responder a la oferta de un producto o servicio, es un tópico importante en marketing directo. De la manera en que se lleve a cabo dicho proceso, dependerá no sólo la efectividad de la oferta en particular, si no que la relación de largo plazo entre la empresa y sus clientes.

Modelos matemáticos predictivos han sido ampliamente utilizados en marketing con el objetivo de seleccionar clientes idóneos para una oferta ([19]). Este tipo de técnicas, conocidas como modelos de propensión, utilizan el comportamiento histórico de los usuarios (en conjunto con información demográfica y de otras fuentes) con el fin de pronosticar su comportamiento en el futuro. Tradicionalmente, métodos estadísticos de regresión han sido utilizados para construir dichos modelos ([10]). La mayoría de los trabajos usan regresiones logísticas debido a su simplicidad y buen ajuste ([11, 12, 13]). En los últimos años, se han introducido diversas técnicas de data mining tales como: Árboles de Decisión ([17, 19]), Redes Neuronales ([16, 18]), Support Vector Machines ([10, 14]), entre otras.

En el presente trabajo los modelos de propensión son un input fundamental del modelo integrado propuesto, y el éxito de la metodología desarrollada depende directamente de su calidad (dicha dependencia quedará en evidencia en las secciones siguientes). La siguiente clasificación propuesta por [19] presenta diferentes tipos de propensión que pueden ser calculadas:

1. Modelo de tenencia: consiste en caracterizar a aquellos clientes que ya poseen (o han comprado) el producto/servicio, diferenciándolos del resto. Se basa en la hipótesis de que una persona de características similares, tendrá una mayor probabilidad de adquirir el producto/servicio. Uno de los problemas de este tipo de modelos es que no consideran la causalidad entre las variables, es decir, no diferencia entre las características del cliente que motivaron la compra de aquellas que fueron afectadas por causa de la misma. Considerar el siguiente ejemplo: se quiere predecir el uso de una tarjeta de crédito en un rubro específico *A* y una variable de relevancia para el modelo de tenencia es el uso de la tarjeta en otra categoría *B*. Sin embargo, en ese caso es posible que los clientes que utilizan la tarjeta en dicha categoría lo hagan debido a que ya la utilizaban en *A* y no al revés.
2. Modelo de compra: consiste en caracterizar a aquellos clientes que adquieren el producto/servicio en un período de tiempo determinado. Luego, los clientes con similares características tendrán una mayor probabilidad de comprar el producto/servicio en el siguiente período. Una de las principales falencias de este tipo de modelos es que no consideran el efecto de la acción de marketing (oferta) que se realizará al cliente, por lo que no se diferencia entre un cliente que comprará el producto/servicio de todas maneras de aquellos que lo harán sólo si son estimulados por la empresa.
3. Modelo de respuesta: consiste en caracterizar y diferenciar aquellos clientes que adquieren el producto/servicio debido a una acción de marketing y no lo hubiesen hecho de no haber sido estimulados. La mayor complejidad de este tipo de modelos es que requieren de gran cantidad de información de campañas históricas y de la existencia de grupos de control en cada una de ellas.

Este último es el tipo de modelo ideal para el presente trabajo, debido a que se busca maximizar el efecto de las acciones de marketing en la respuesta del cliente. Sin embargo, al no contar con

información de campañas históricas, se realizaron modelos de propensión de compra (caso 2) como aproximación de la respuesta estimada de los clientes.

2.2. Next best offer

Si bien los modelos de propensión pueden incrementar las ventas de un producto/servicio en particular, su uso individual genera una orientación de la estrategia en torno al producto, desviando el foco de la empresa en el cliente. Lo anterior puede traer como consecuencia la excesiva estimulación de un grupo acotado de clientes y la nula interacción con todo el resto de la cartera ([20, 21]).

Con el objetivo de evitar lo anterior y mantener una estrategia orientada al cliente, nace el concepto de *Next best offer*. Como su nombre lo dice, esta metodología busca determinar cuál es la mejor oferta que puede recibir un cliente, con el objetivo de maximizar la probabilidad de respuesta y la satisfacción del consumidor ([1, 2, 3, 4]).

La metodología del *Next best offer* considera como input principal el resultado de los modelos de propensión, y su enfoque tradicional puede resumirse en las siguiente secuencia de pasos ([21]):

1. Para cada producto/servicio a ofertar, desarrollar un modelo de propensión
2. Cada cliente tendrá un score (obtenido en el punto anterior) para cada oferta
3. Asignar a cada cliente las ofertas con mayor score

Por ejemplo en [5] se desarrolló un modelo Hazard multivariado para calcular la probabilidad de compra de un nuevo producto introducido por la empresa, en base a los tiempos de adquisición de diferentes categorías de productos en el pasado. Como resultado se obtiene una matriz de propensión cliente-producto que entrega la priorización de cada oferta. En [6] se propone un modelo probit multivariado que detecta patrones de adquisición de diferentes productos en el tiempo. Con esto se estima la probabilidad de que cada cliente compre un determinado producto en el siguiente período. En [7] se combinan los resultados de modelos de propensión con el score de riesgo de cada

cliente, con el fin de determinar a qué clientes realizar ofertas en una empresa financiera. En [8] se realiza un análisis factorial, combinando datos históricos del cliente y encuestas, para determinar la probabilidad de adquisición de un producto en la empresa o sus competidores. En [9] utilizan información del ciclo de vida del cliente para calcular qué producto comprará entre las alternativas existentes, utilizando un modelo de Counterpropagation network.

La principal dificultad del enfoque descrito anteriormente, es que no considera a priori las restricciones del negocio, tales como: presupuesto disponible para la campaña, política de toques por cliente, canales disponibles y su capacidad, retorno esperado de la campaña, entre otras. Dichas restricciones al ser incorporadas a posteriori en el proceso de asignación cliente-oferta, disminuyen la calidad de la solución y dificultan enormemente la gestión de la campaña. Se han aplicado muchas reglas de priorización ad hoc para satisfacer las restricciones del negocio, tales como: priorización por tasas de respuesta, por utilidad esperada, por reglas del negocio particular, entre otras. Sin embargo, ninguna de las alternativas mencionadas optimiza la asignación cliente-oferta ([21]).

2.3. Optimización de campañas de marketing

Dado las dificultades descritas anteriormente, se desarrolló un nuevo enfoque para resolver la asignación cliente-oferta en una campaña de marketing, que considera las restricciones del negocio como input junto a los modelos de propensión ([21, 20, 22]) . Dicha metodología consiste en resolver un problema de optimización matemática, y puede resumirse en la siguiente secuencia de pasos:

1. Para cada producto/servicio a ofertar, desarrollar un modelo de propensión
2. Cada cliente tendrá un score (obtenido en el punto anterior) para cada oferta
3. Resolver un problema de optimización matemática que realice la mejor asignación cliente-oferta-canal, sujeto a las restricciones del negocio
4. Asignar a cada cliente las ofertas y canales correspondientes según los resultados de la optimización

Básicamente el problema de optimización busca maximizar la utilidad de la campaña, realizando la mejor asignación cliente-oferta-canal, sujeto a las restricciones del negocio. Sin embargo, existe una gran dificultad en la resolución de este problema: el tamaño de las instancias. Para empresas con cientos de miles (o millones) de clientes, decenas de productos y varios canales de venta, se hace imposible resolver el problema de forma exacta. En [20] se demuestra que el problema es NP-completo debido a la gran cantidad de variables de decisión (que aumentan exponencialmente con el número de clientes, ofertas y canales). Por esto, es necesario buscar soluciones heurísticas que resuelvan el problema en tiempos razonables para su aplicación en un negocio real. La figura 2.1 ilustra el enfoque descrito anteriormente.

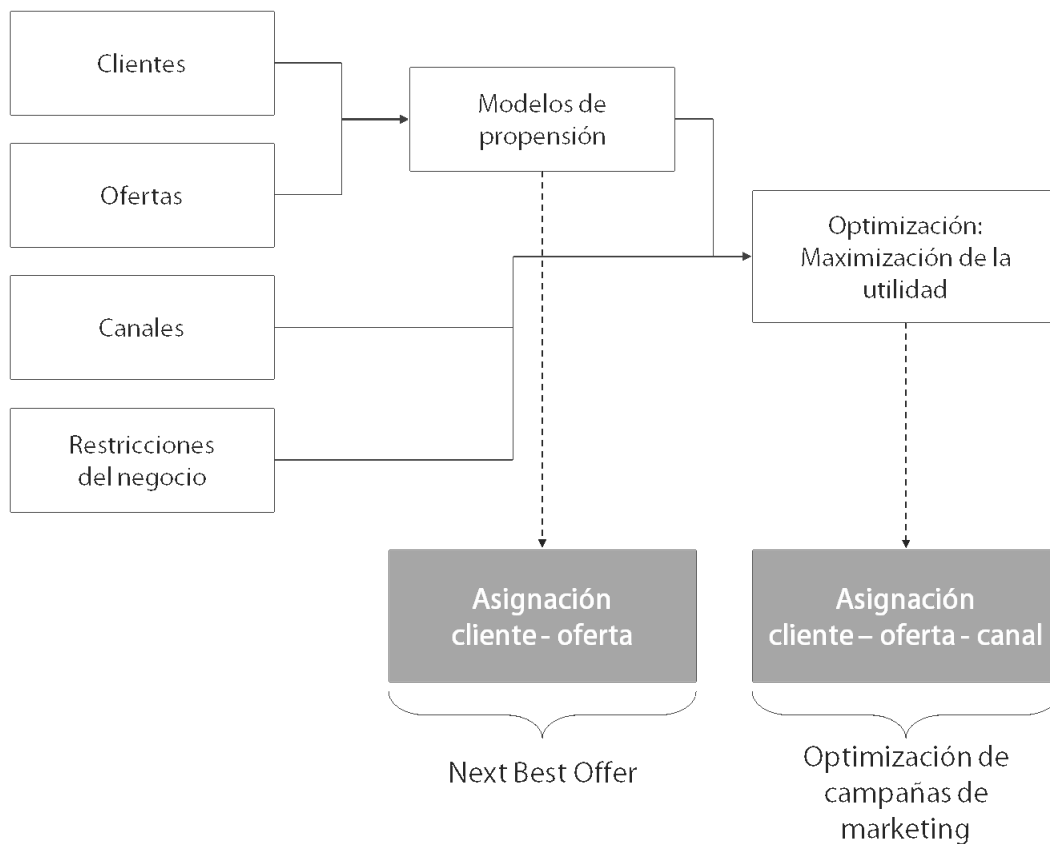


Figura 2.1: Optimización de campañas de marketing vs. *Next best offer*

En [20] se construye un modelo de optimización que busca maximizar la utilidad esperada de la asignación cliente-oferta, sujeto a las siguientes restricciones: tasa de retorno de la inversión mínima, presupuesto por oferta, máximo de ofertas por cliente y cantidad mínima de clientes por

oferta. Dicha formulación no considera un presupuesto global de la campaña (que podría ser más restrictivo que la suma de los presupuestos individuales), ni tampoco considera como variables de decisión el canal de venta de la oferta. Este último hecho no es menor, pues al agregar a la decisión los canales, se generan nuevas restricciones y el problema se complejiza. El canal de comunicación es de suma importancia al momento de entregar una oferta, tanto por las diferencias en costo, como por la efectividad que cada uno muestra según el perfil del cliente al que se está dirigiendo la oferta.

Para resolver este problema, en [20] se analizan una serie de metodologías exactas y heurísticas. Como método exacto se utiliza un algoritmo de branch and price, el cual presenta buenos resultados en instancias pequeñas (bajo número de clientes y/o pocas ofertas), pero se vuelve inaplicable en casos donde el tamaño del problema aumenta. En cuanto a las heurísticas propuestas, se construyeron ocho algoritmos diferentes utilizando distintas metodologías. Según los resultados obtenidos, el algoritmo de búsqueda tabú fue el mejor en términos de brecha con respecto al óptimo y tiempos de ejecución. Esta última metodología será utilizada como punto de comparación para el rendimiento del algoritmo propuesto en el presente trabajo.

Por otro lado, en [21] se modela el problema maximización con las siguientes restricciones: presupuesto global de la campaña, capacidad de los canales de venta, cantidad mínima de clientes por oferta, cantidad máxima de clientes por oferta y tasa de retorno de la inversión mínima. Si bien en este caso se considera la existencia de canales de venta como una variable de decisión, no se consideran una serie de factores relevantes: costo fijo por oferta, presupuestos particulares por oferta (que pueden ser más restrictivos que el presupuesto global), cantidad máxima de ofertas por canal y máximo de ofertas por cliente. Estas dos últimas restricciones son fundamentales en casos donde la cantidad de ofertas existentes es alta. Por ejemplo, canales como call center o marketing físico (impresión) poseen un límite de ofertas a gestionar al mismo tiempo. Por otro lado, si no existe una restricción para los toques por cliente, puede producirse la saturación de los mismos y por ende un deterioro de su satisfacción y lealtad.

Para resolver el problema heurísticamente, se agrupan los clientes en clusters similares según variables de ingresos y costos, resolviendo un nuevo problema utilizando dichos grupos. Con esto se reduce el número de variables, en una proporción que depende del tamaño de cada cluster (notar que existe un trade-off entre la calidad de la solución aproximada y la reducción del tamaño del

problema). Sin embargo, la metodología descrita presenta una dificultad: no entrega como resultado la asignación final, si no el número de clientes dentro de un cluster que deben recibir la oferta. Luego se resuelve un problema de asignación para cada conglomerado. Igualmente la estrategia es interesante y por tanto se utilizará un enfoque similar en el algoritmo propuesto (ver sección 4).

Finalmente, en [22] se resuelve el problema de asignación considerando segmentos de clientes y no clientes individuales. Esto afecta tanto la complejidad de resolución (instancias de menor tamaño) y el modelamiento matemático del problema (diferentes restricciones y variables de decisión). Por lo tanto, se resuelven problemas diferentes y no son comparables. Es importante destacar que en [22] se incorpora la existencia de más de un canal de venta, pero no considera la restricción de cantidad máxima de ofertas por canal, que es fundamental (como se explicó anteriormente) en casos donde la cantidad de ofertas existentes es alta.

Capítulo 3

Modelo matemático para el problema de negocio

3.1. Descripción

El escenario es el siguiente: una empresa quiere aumentar el valor agregado a su cartera de clientes, ofreciendo productos que satisfagan sus necesidades y, al mismo tiempo, maximizar la utilidad y el retorno de la inversión realizada en campañas de marketing. Para esto se tiene como input las probabilidades entregadas por los modelos de propensión (uno por oferta-canal) a cada uno de los clientes. Con lo anterior es posible calcular la utilidad esperada de ofrecer un producto en particular, a un usuario específico y a través de un canal determinado: multiplicando la probabilidad de respuesta por el ingreso estimado y restando los costos asociados a la oferta. Es importante diferenciar los costos de envío de la campaña (carta, email, etc.) de aquellos asociados a los beneficios de la oferta (descuentos, regalos, etc.), pues los segundos sólo se hacen efectivos si la respuesta del cliente es positiva. Una vez calculada la utilidad, es posible priorizar las ofertas para maximizar dicho indicador. Es trascendental mencionar que la calidad de los modelos de propensión y de las estimaciones de ingresos y costos, son fundamentales para el funcionamiento de la presente metodología, por lo que el mayor esfuerzo de implementación debería asignarse a

esta etapa. Por otro lado, existe una serie de restricciones asociadas al negocio, las cuales deben respetarse al momento de realizar la asignación de ofertas. Primero, el costo total esperado de la campaña no puede superar el presupuesto establecido por la empresa. Por otra parte, en general se exige un retorno mínimo para la inversión realizada, por lo que la utilidad esperada debe ser mayor a la tasa establecida por la compañía multiplicada por el costo total (se debe alcanzar el retorno de la inversión esperado por la empresa). Tercero, se impone un mínimo de clientes por oferta para evitar campañas poco significativas. Luego se debe evitar la saturación de los clientes, por lo que se establece un límite de ofertas asegurando que un mismo producto/servicio no se ofrezca a través de dos canales distintos. Notar que la última condición depende de las reglas de negocio, pues existe un trade off entre saturar al cliente y aumentar la efectividad de la campaña. Una opción de flexibilizar o generalizar la restricción es generalizar a N canales como máximo, pero habría que agregar el efecto en las probabilidades de enviar la oferta más de una vez (no basta simplemente con sumar las probabilidades individuales). Queda como extensión de la presente tesis. Finalmente hay que considerar la capacidad de los canales imponiendo un número máximo de clientes y un tope de ofertas para cada uno.

Resumiendo, el escenario en cuestión puede modelarse como un problema de programación lineal entera, en el que se maximiza la utilidad esperada de la campaña decidiendo a qué cliente asignar qué oferta a través de qué canal de venta. Todo esto respetando las restricciones del negocio mencionadas anteriormente.

3.2. Modelo matemático

A continuación se presenta el modelo de programación lineal entera que representa el escenario descrito anteriormente. El objetivo del modelo es maximizar la utilidad de la empresa distribuyendo N ofertas entre M clientes a través de K canales de venta diferentes, considerando una serie de restricciones de negocio.

- Se define p_{ijk} como la probabilidad de que el cliente i responda positivamente a la oferta j a través del canal k . El valor de dicho parámetro es entregado por modelos de propensión que

serán considerados como un dato conocido en el presente trabajo. Notar que la probabilidad de contacto está implícita en este valor (canales con menor contactabilidad tendrán una menor tasa de respuesta).

- Se denota I_{ij} al ingreso obtenido si es que el cliente i responde positivamente a la oferta j , mientras que C_{ij} corresponde al costo asociado (descuento, regalo, etc.).
- El costo de envío de la oferta a través del canal k se define como CE_{ijk} . Además, cada oferta tiene definido un costo fijo CF_j y un número mínimo de clientes a estimular $MINC_j$. También se define el presupuesto global PT y particular de cada oferta P_j . Notar que para el presente trabajo se consideraron sólo costos unitarios por canal. Costos por tramo (como impresión de piezas de marketing o call center) quedan como extensiones de la presente tesis.
- En cuanto a la capacidad de los canales de venta, existen dos parámetros: $CAPC_k$ establece la cantidad máxima de clientes que permite el canal k , mientras que el límite de ofertas se denota $CAPO_k$.
- Para cada cliente i se define el límite de ofertas que puede recibir $MAXO_i$, evitando la saturación.
- Finalmente se denota r a la mínima tasa de retorno de la inversión aceptada por la empresa.

Las variables de decisión utilizadas son las siguientes: y_j es igual a 1 si se *activa* la oferta j (es asignada a algún cliente) y 0 en caso contrario; w_{jk} vale 1 si es que la oferta j es asignada al canal k y 0 si no; x_{ijk} es igual a 1 si la oferta j es enviada al cliente i a través del canal k . Con esto la formulación del modelo se puede expresar como:

$$Max \quad \sum_{i,j,k} x_{ijk} \cdot [p_{ijk} \cdot (I_{ij} - C_{ij}) - CE_{ijk}] - \sum_j y_j \cdot CF_j \quad (3.1)$$

$$s.a. \quad \sum_{i,j,k} x_{ijk} \cdot p_{ijk} \cdot I_{ij} \geq (1+r) \cdot \sum_{i,j,k} x_{ijk} \cdot [p_{ijk} \cdot C_{ij} + CE_{ijk}] + \sum_j y_j \cdot CF_j \quad (3.2)$$

$$\sum_{i,j,k} x_{ijk} \cdot [p_{ijk} \cdot C_{ij} + CE_{ijk}] + \sum_j y_j \cdot CF_j \leq PT \quad (3.3)$$

$$\sum_{i,k} x_{ijk} \cdot [p_{ijk} \cdot C_{ij} + CE_{ijk}] + CF_j \leq P_j \quad j = 1, \dots, N \quad (3.4)$$

$$\sum_{i,k} x_{ijk} \geq y_j \cdot MINC_j \quad j = 1, \dots, N \quad (3.5)$$

$$\sum_k x_{ijk} \leq 1 \quad i = 1, \dots, M \quad j = 1, \dots, N \quad (3.6)$$

$$\sum_{j,k} x_{ijk} \leq MAXO_i \quad i = 1, \dots, M \quad (3.7)$$

$$\sum_j w_{jk} \leq CAPO_k \quad k = 1, \dots, K \quad (3.8)$$

$$\sum_{i,j} x_{ijk} \leq CAPC_k \quad k = 1, \dots, K \quad (3.9)$$

$$\sum_k w_{jk} \leq y_j \cdot K \quad j = 1, \dots, N \quad (3.10)$$

$$\sum_i x_{ijk} \leq w_{jk} \cdot CAPC_k \quad j = 1, \dots, N \quad k = 1, \dots, K \quad (3.11)$$

La función objetivo (3.1) corresponde a la maximización de la utilidad esperada obtenida al asignar las ofertas a los clientes a través de los distintos canales, restando el costo fijo de las ofertas *activas*. La restricción (3.2) indica que el ingreso esperado debe ser por lo menos igual al retorno mínimo de la inversión. Esta última restricción es importante para descartar soluciones con una alta utilidad pero que requieren demasiada inversión. Sin embargo basta con asignar el valor cero a la tasa de retorno para omitir la restricción. La restricción (3.3) establece que el costo total no puede superar el presupuesto total, mientras que el conjunto de restricciones (3.4) limita la inversión por oferta. Esto último tiene sentido cuando las ofertas dependen de diferentes unidades de negocio de la empresa, cada una con presupuestos individuales. El set de restricciones (3.5) obliga

a estimular a un mínimo de clientes, si es que la oferta está *activa*. El conjunto de restricciones (3.6) establece que no es posible asignar una oferta a un mismo cliente por más de un canal. Esta última restricción (como se mencionó anteriormente) es cuestionable y depende de las reglas del negocio, pues mientras para algunos sería redundante y una pérdida de dinero, para otros podría ser interesante reforzar una oferta enviándola a través de dos canales diferentes. Como extensión del modelo descrito es posible asignar un parámetro que indique el máximo de veces que un cliente puede recibir una misma oferta, pero habría que agregar el efecto en las probabilidades de enviar la oferta más de una vez (no basta simplemente con sumar las probabilidades individuales). Las restricciones (3.7) limitan el número de ofertas por cliente para evitar saturación, mientras que los conjuntos de restricciones (3.8) y (3.9) impiden superar la capacidad de los canales en términos de ofertas y clientes respectivamente. Finalmente, los conjuntos de restricciones (3.10) y (3.11) establecen compatibilidad entre las variables de decisión.

3.3. Contribuciones del presente trabajo

El presente trabajo toma en consideración las debilidades existentes en la literatura actual evidenciadas anteriormente. En primer lugar, la formulación del problema es más robusta y cercana a la realidad, pues considera como variable de decisión el canal de comunicación de la oferta y todas las restricciones pasadas por alto en los casos anteriores: cantidad máxima de ofertas por cliente y canal, presupuesto global, presupuesto particular y costo fijo de cada oferta.

Por otro lado, para la resolución del problema se desarrolló un algoritmo heurístico que considera aspectos de la búsqueda tabú, pero que fue modificado y adaptado para resolver el problema de optimización particular descrito en el presente trabajo. Se mostrará en la sección de resultados, que el algoritmo propuesto supera en tiempo de ejecución y brecha con respecto al óptimo a la metodología desarrollada en [20]. Además se incorporó una segunda etapa de clusterización similar a la utilizada en [21], que permite disminuir aún más los tiempos de ejecución. La ventaja de esta etapa adicional con respecto a [21], es que la solución es traspasable al problema original (antes de agrupar), sin necesidad de resolver un nuevo problema de asignación.

Las contribuciones de la presente tesis se pueden resumir en:

1. La formulación del problema de optimización es una extensión de los modelos propuestos en la literatura, pues incorpora más restricciones de negocio haciéndolo más cercano a la realidad.
2. La inclusión de canales de venta como variable de decisión, incluyendo todas las restricciones asociadas
3. El desarrollo de una heurística que resuelve el problema en menores tiempos que en la literatura y alcanzando mejores resultados
4. La aplicación del modelo desarrollado a un caso real

Capítulo 4

Algoritmo heurístico para la optimización de campañas de marketing

En [20] se demuestra que una versión simplificada del problema formulado en la sección anterior es NP-completo, por lo que el modelo construido en la presente tesis también lo será. Este hecho justifica el uso de heurísticas para encontrar una solución no trivial que respete las restricciones del negocio [20, 21]. A continuación se presenta un enfoque heurístico para resolver el problema en cuestión. Primero se describe el algoritmo principal y luego una variación del mismo que pretende disminuir los tiempos de ejecución.

4.1. Algoritmo principal

Una de las diferencias fundamentales con los trabajos descritos en la sección 2, es la descomposición del problema en cuatro etapas:

1. Selección del subconjunto de ofertas a activar
2. Encontrar una asignación no trivial factible (según restricciones del negocio) de canales a la

combinación de ofertas seleccionadas en la etapa anterior

3. Encontrar una asignación no trivial factible (según restricciones del negocio) de clientes a las combinaciones oferta-canal seleccionadas en la etapa anterior
4. Buscar mejores soluciones en un vecindario de aquellas obtenidas en el punto anterior

En la primera etapa se realiza una preselección de potenciales buenas combinaciones de ofertas, realizando una evaluación rápida que será descrita en detalle más adelante. Luego se escoge una combinación de ofertas activas y se realiza una asignación no trivial factible de canales y clientes buscando utilizar al máximo los recursos disponibles (presupuesto, capacidad de canales, etc.). Este último hecho es relevante para la siguiente etapa (que consiste en buscar vecinos a la solución obtenida), pues mientras más compleja es la solución más modificaciones pueden hacerse. La tercera etapa consiste sólo en modificar la asignación de canales y clientes, dejando fija la combinación de ofertas seleccionadas en la primer paso. Estas tres etapas se repiten para todas las combinaciones potenciales en el conjunto preseleccionado. Finalmente se realizan diferentes mutaciones (cambios de ofertas activas) a las combinaciones preseleccionadas, cada una de las cuales es sometida igualmente a los tres pasos mencionados. A continuación se detalla cada uno de los algoritmos utilizados para resolver los tres sub-problemas.

4.1.1. Combinación de ofertas a activar

Si el número de ofertas es N , existen 2^N posibles combinaciones de ofertas a realizar. En ese grupo existen combinaciones que a priori no son factibles debido a las restricciones existentes, por ejemplo: la suma de los costos fijos es superior al presupuesto. El primer paso para seleccionar un subconjunto de combinaciones factibles es determinar una cota superior para el número máximo de ofertas a realizar. La siguiente secuencia de pasos explica el procedimiento para hacerlo:

1. Iniciar el máximo de ofertas y el costo total en cero: $MO=0, C=0$
2. Para cada oferta j en $\{1, \dots, N\}$ determinar costo mínimo factible CM_j :

- a) Iniciar asignando costo fijo $CM_j = CF_j$ y contador de clientes $CONT_j = 0$
 - b) Para cada cliente i en $\{1, \dots, M\}$ se selecciona el canal k^* de menor costo CE_{ijk^*} y se define el costo mínimo $cm_{ij} = CE_{ijk^*}$
 - c) Ordenar clientes i en $\{1, \dots, M\}$ según cm_{ij} de menor a mayor en el conjunto C^*
 - d) Sea i^* el cliente con menor costo mínimo en C^*
 - e) Si $CONT_j < MINC_j$ entonces $CM_j = CM_j + cm_{ij}$, $CONT_j = CONT_j + 1$ y $C^* := C^* \setminus \{i^*\}$, si no termina
 - f) Si $C^* = \emptyset$ termina, si no vuelve a (d)
3. Ordenar ofertas por su costo mínimo de forma ascendente en el conjunto O^*
 4. Sea j^* la oferta con menor costo mínimo en O^*
 5. Si $C = C + CM_{j^*} < PPTO$ entonces $MO = MO + 1$ y $O^* = O^* \setminus \{j^*\}$, si no termina
 6. Si $O^* = \emptyset$ termina, si no vuelve a 4

Una vez determinado el límite de ofertas a activar, se procede a seleccionar un conjunto de combinaciones factibles y potencialmente cercanas al óptimo. Este último hecho fue muy importante para la convergencia del algoritmo en los experimentos computacionales, pues al iniciar las iteraciones con una solución más cercana al óptimo, los tiempos de convergencia se redujeron considerablemente. El siguiente pseudo-código detalla el procedimiento descrito:

1. Seleccionar un grupo aleatorio de N_1 combinaciones factibles:
 - a) Iniciar conjunto de combinaciones factibles $OF := \emptyset$
 - b) Iniciar combinación factible y^* con $y_j^* = 0$ para todo j en $\{1, \dots, N\}$, el contador de ofertas activas $CONT = 0$ y calcular el número de ofertas a activar NA como un número entero aleatorio entre 1 y MO
 - c) $y_j^* = 1$ para j aleatorio en $\{1, \dots, N\}$, $CONT = CONT + 1$
 - d) $y_l^* = 1$ para l aleatorio en $\{1, \dots, N\} \setminus \{j\}$

- e) si y^* es factible $CONT=CONT+1$, si no $y_i^* = 0$ y volver a (d)
 - f) si $CONT=NA$ entonces $OF:=OF \cup \{y^*\}$
 - g) Repito desde b a f hasta completar las N_1 combinaciones
2. Pre-evaluar cada una de las N_1 combinaciones seleccionadas en el punto anterior y seleccionar las N_2 mejores
- a) Sea y^* la combinación a pre-evaluar
 - b) Iniciar la utilidad estimada para y^* : $u^* = 0$
 - c) Sumar costo fijo de las ofertas activas: $u^* = u^* - \sum_j y_j^* \cdot CF_j$
 - d) Realizar asignación factible de canales a las ofertas activas: w^* (se explicará en detalle más adelante)
 - e) Para todo $w_{jk}^* = 1$, para todo cliente i :
 si $u_{ijk} = p_{ijk} \cdot (I_{ij} - C_{ij}) - CE_{ijk} > 0$, entonces $u^* = u^* + u_{ijk}$

Notar que N_1 y N_2 son valores que el algoritmo recibe como input e influirán directamente en los tiempos de ejecución y en la calidad de la solución. Si se quiere obtener mejores soluciones se debe incrementar el valor de dichos parámetros, caso contrario si se desea disminuir los tiempos de ejecución.

Cada una de las combinaciones preseleccionadas se someterá a las dos siguientes etapas descritas al inicio de esta sección, dando origen a N_2 soluciones no triviales factibles. Luego comienza el proceso de mutación de las combinaciones encontradas, el cual consiste básicamente en modificar las ofertas activas como se explica a continuación:

1. Iniciar el conjunto de soluciones a mutar SM como las N_2 combinaciones seleccionadas en la etapa anterior
2. Considerar solución s en SM . Sea y , w y x las variables de *ofertas*, *canales* y *clientes* de s respectivamente
3. Realizar M mutaciones de dos tipos, si y^* es la mutación de y :

- a) Tipo 1: para j aleatorio si $y_j = 1$ entonces $y_j^* = 0$, si $y_j = 0$ entonces $y_j^* = 1$
 - b) Tipo 2: para j_1, j_2 aleatorios si $y_{j_1} = 1, y_{j_2} = 0$ entonces $y_{j_1}^* = 0, y_{j_2}^* = 1$, si $y_{j_1} = 0, y_{j_2} = 1$ entonces $y_{j_1}^* = 1, y_{j_2}^* = 0$
4. Pre-evaluar las M mutaciones y seleccionar la mejor y^*
 5. Asignar canales y clientes para y^* obteniendo la solución mutada m^* , si hay mejora: $SM = SM \cup \{m^*\}$, si no eliminar solución s de SM con probabilidad p
 6. Terminar cuando: se cumplen las iteraciones establecidas, no hay cambios durante un número de iteraciones o el conjunto de soluciones para mutar es vacío

El método descrito anteriormente es una combinación entre un *Algoritmo Genético* ([24]) y *Simulated Annealing* ([25]). En primer lugar se selecciona una solución *padre*, de la cual se obtiene descendencia mediante la mutación de la misma. Luego, en vez de desechar la solución *padre* como se procede en un *Algoritmo Genético* estándar ([24]), se introduce el concepto de temperatura similar al utilizado en *Simulated Annealing* ([25]). En cada iteración el parámetro p corresponde a la probabilidad de desechar la solución *padre* para el resto del proceso. El valor que dicho parámetro tendrá en cada iteración depende del número de iteraciones que han transcurrido hasta el momento: al comienzo del algoritmo el valor es mayor, permitiendo el crecimiento del conjunto de soluciones para mutar, pero al avanzar las iteraciones el valor disminuye acelerando la convergencia ([25]).

4.1.2. Asignación factible de canales

Una vez seleccionada la combinación de ofertas, se procede a realizar una asignación factible de canales. En la siguiente sección se explicará cómo mejorar dicha asignación. La restricción que debe respetarse en esta etapa es el máximo número de ofertas por canal. Inicialmente se asignan todos los canales a cada oferta y luego, para aquellos casos en que se viola la restricción mencionada anteriormente, comienza la poda de ofertas hasta obtener una asignación factible. El siguiente pseudo-código explica el proceso descrito:

1. $w_{jk} = 1$ para todo k en $\{1, \dots, K\}$ para todo j en $\{1, \dots, N\}$ tal que $y_j = 1$

2. Iniciar el contador de ofertas para cada canal k : $CONT_k = N$ para todo k en $\{1, \dots, K\}$
3. Si $CONT_k \leq CAPO_k$ para todo k en $\{1, \dots, K\}$ termina
4. Si no, sea k^* tal que $CONT_{k^*} > CAPO_{k^*}$
5. Se calcula la capacidad asignada a cada oferta j :

$$CA_j = \sum_k w_{jk} \cdot CAPC_k$$
6. Se ordenan las ofertas según holgura de capacidad ($CA_j / MINC_j$) en el conjunto O^*
7. Sea j^* la oferta con mayor holgura en O^* , entonces:

$$w_{j^*k^*} = 0, CA_{j^*} = CA_{j^*} - CAP_{k^*}, CONT_{k^*} = CONT_{k^*} - 1$$
8. Si $CONT_{k^*} \leq CAPO_{k^*}$ volver a paso 3, si no $O^* = O^* \setminus \{j^*\}$ y volver a paso 7

4.1.3. Asignación factible de clientes

Al obtener la combinación de ofertas con sus respectivos canales asignados, se procede a la asignación de clientes. Este proceso consiste en asignar a cada oferta las combinaciones cliente-canal de menor costo para asegurar factibilidad presupuestaria, hasta completar el mínimo de clientes requerido. Posteriormente se corrigen los casos particulares de canales saturados por capacidad o clientes saturados por el máximo de ofertas superado. A continuación se presenta un pseudo-código que describe el proceso:

1. Sean y , w las combinaciones de ofertas y oferta-canal respectivamente. Sea OA el conjunto de ofertas activas en y .
2. Para toda oferta j en OA :
 - a) Iniciar contador de clientes $CONT_j = 0$
 - b) Ordenar las combinaciones canal-cliente (considerando sólo canales activos) por costo CE_{ijk} de manera ascendente en CC^*

- c) Sea i^*, k^* la combinación de menor costo de CC^* , entonces:
 $x_{i^*j^*k^*} = 1, CONT_j = CONT_j + 1, CC^* := CC^* \setminus \{(i^*, k^*)\}$
- d) Si $CONT_j = MINC_j$ termina, si no volver a paso (c)
3. Sea $CONT_k$ el número de clientes asignados al canal k .
Si $CONT_k \leq CAPC_k$ para todo k en $\{1, \dots, K\}$ ir a paso 4, si no:
- a) Ordenar canales saturados por nivel de saturación:
 $CONT_k / CAPC_k$
- b) Sea k el canal con mayor saturación
- c) Ordenar ofertas asignadas a k por holgura de presupuesto disponible ($PDISP_j$) descendente en el conjunto O^*
- d) Sea j^* la oferta de mayor holgura en O^*
- e) Seleccionar cliente i tal que $x_{ij^*k} = 1$
- f) Seleccionar combinación cliente-canal de menor costo (i^*, k^*) en CC^* tal que $w_{j^*k^*} = 1$ y $x_{i^*j^*l} = 0$ para todo l en $\{1, \dots, K\}$
- g) $x_{i^*j^*k^*} = 1$ y $x_{ij^*k} = 0$. Si es factible: $CONT_k = CONT_k - 1, CC^* := CC^* \setminus \{(i^*, k^*)\}$, actualizar $PDISP_{j^*}$
- h) repetir hasta que $CONT_k \leq CAPC_k$ para todo k en $\{1, \dots, K\}$ o hasta cumplir el límite de iteraciones
4. Sea $CONT_i$ el número de ofertas asignados al cliente i .
Si $CONT_i \leq MAXO_i$ para todo i en $\{1, \dots, M\}$ termina, si no:
- a) Ordenar clientes saturados por nivel de saturación:
 $CONT_i / MAXO_i$
- b) Sea i el cliente con mayor saturación
- c) Ordenar ofertas asignadas a i por holgura de presupuesto disponible ($PDISP_j$) descendente en conjunto O^*
- d) Sea j^* la oferta de mayor holgura en O^*
- e) Seleccionar canal k tal que $x_{ij^*k} = 1$

- f) Seleccionar combinación cliente-canal de menor costo (i^*, k^*) en CC^* tal que $w_{j^*k^*} = 1$ y $x_{i^*j^*l} = 0$ para todo l en $\{1, \dots, K\}$
- g) $x_{i^*j^*k^*} = 1$ y $x_{ij^*k} = 0$. Si es factible: $CONT_i = CONT_i - 1$, $CC^* := CC^* \setminus \{(i^*, k^*)\}$, actualizar $PDISP_{j^*}$
- h) repetir hasta que $CONT_i \leq MAXO_i$ para todo i en $\{1, \dots, M\}$ o hasta cumplir el límite de iteraciones

4.1.4. Búsqueda de soluciones vecinas

Finalmente, dada la combinación de ofertas seleccionada con su respectiva asignación factible de canales y clientes, se procede a la búsqueda de soluciones vecinas. Este procedimiento es utilizado en heurísticas del tipo *búsqueda tabú* con el argumento de que en el vecindario de soluciones es posible encontrar óptimos locales.

En este caso se considera vecina a una solución donde se modifica únicamente la asignación de clientes y canales, manteniendo intacta la combinación de ofertas activas. En el presente trabajo se utilizan cuatro tipos de vecinos:

1. Intercambio de clientes de una oferta activa con clientes no asignados a ninguna oferta
2. Intercambio de clientes entre canales para una misma oferta
3. Intercambio de clientes entre ofertas para un mismo canal
4. Intercambio de clientes entre ofertas y canales

Notar que en los cuatro tipos de vecinos mencionados, ninguno interviene directamente en la asignación de canales. Sin embargo, si es que todos los clientes asignados a un canal se cambian a otro, éste es desactivado automáticamente. La figura 4.1 ilustra las diferentes metodologías utilizadas.

El primer tipo de vecinos consiste en activar clientes que no han sido asignados a ninguna oferta, realizando un intercambio con algún cliente activo de menor utilidad. El siguiente pseudo-código detalla el procedimiento:

1. Para cada oferta activa j
2. Para cada canal k asignado a j
3. Sea CA_{jk} el conjunto de clientes asignados a la oferta j y el canal k y CD el conjunto de clientes disponibles (sin asignar a ninguna oferta)
4. Calcular utilidad $U_i = p_{ijk} \cdot (I_{ij} - C_{ij}) - CE_{ijk}$ para todo i en CA_{jk} y en CD
5. Si $CA_{jk} := \emptyset$ terminar. Si no, sea i_1 el cliente con menor utilidad en CA_{jk}
6. Si $CD := \emptyset$, $CA_{jk} := CA_{jk} \setminus \{i_1\}$, reiniciar CD e ir a paso 5. Si no, sea i_2 el cliente con mayor utilidad en CD
7. Si $U_{i_2} > U_{i_1}$ y es factible: $x_{i_1jk} = 0$ y $x_{i_2jk} = 1$, $CA_{jk} := CA_{jk} \setminus \{i_1\}$, reiniciar CD e ir a paso 5. Si no $CD := CD \setminus \{i_2\}$ ir a paso 6

En el segundo tipo se intercambian clientes asignados a una misma oferta pero a diferentes canales, tal como se muestra en la figura 4.1. El detalle del procedimiento es el siguiente:

1. Para cada combinación de ofertas activas j_1 y j_2
2. Para cada combinación de canales k_1 y k_2 asignados ambos a j_1 y j_2
3. Sea $CA_{j_1k_1}$ el conjunto de clientes asignados a la oferta j_1 y el canal k_1 y $CA_{j_2k_2}$ el conjunto de clientes asignados a la oferta j_2 y el canal k_2
4. Calcular utilidades del cambio:

$$U_i = p_{ij_1k_2} \cdot (I_{ij_1} - C_{ij_1}) - CE_{ij_1k_2} - (p_{ij_1k_1} \cdot (I_{ij_1} - C_{ij_1}) - CE_{ij_1k_1}),$$

$$i \text{ en } CA_{j_1k_1}$$

$$U_i = p_{ij_2k_1} \cdot (I_{ij_2} - C_{ij_2}) - CE_{ij_2k_1} - (p_{ij_2k_2} \cdot (I_{ij_2} - C_{ij_2}) - CE_{ij_2k_2}),$$

$$i \text{ en } CA_{j_2k_2}$$

5. Si $CA_{j_1k_1} := \emptyset$ terminar. Si no, sea i_1 el cliente con menor utilidad en $CA_{j_1k_1}$
6. Si $CA_{j_2k_2} := \emptyset$, $CA_{j_1k_1} = CA_{j_1k_1} \setminus \{i_1\}$, reiniciar $CA_{j_2k_2}$ e ir a paso 5. Si no, sea i_2 el cliente con mayor utilidad en $CA_{j_2k_2}$
7. Si $U_{i_2} > U_{i_1}$ y es factible: $x_{i_1j_1k_1} = 0$, $x_{i_2j_2k_2} = 0$, $x_{i_1j_1k_2} = 1$ y $x_{i_2j_2k_1} = 1$, $CA_{j_1k_1} = CA_{j_1k_1} \setminus \{i_1\}$, reiniciar $CA_{j_2k_2}$ e ir a paso 5. Si no $CA_{j_2k_2} = CA_{j_2k_2} \setminus \{i_2\}$ ir a paso 6

El tercer caso es muy similar al anterior. La única diferencia es el intercambio de ofertas en lugar de canales como se muestra a continuación:

1. Para cada combinación de ofertas activas j_1 y j_2
2. Para cada combinación de canales k_1 y k_2 asignados ambos a j_1 y j_2
3. Sea $CA_{j_1k_1}$ el conjunto de clientes asignados a la oferta j_1 y el canal k_1 y $CA_{j_2k_2}$ el conjunto de clientes asignados a la oferta j_2 y el canal k_2

4. Calcular utilidades del cambio:

$$U_i = p_{ij_2k_1} \cdot (I_{ij_2} - C_{ij_2}) - CE_{ij_2k_1} - (p_{ij_1k_1} \cdot (I_{ij_1} - C_{ij_1}) - CE_{ij_1k_1}),$$

i en $CA_{j_1k_1}$

$$U_i = p_{ij_1k_2} \cdot (I_{ij_1} - C_{ij_1}) - CE_{ij_1k_2} - (p_{ij_2k_2} \cdot (I_{ij_2} - C_{ij_2}) - CE_{ij_2k_2}),$$

i en $CA_{j_2k_2}$

5. Si $CA_{j_1k_1} := \emptyset$ terminar. Si no, sea i_1 el cliente con menor utilidad en $CA_{j_1k_1}$
6. Si $CA_{j_2k_2} := \emptyset$, $CA_{j_1k_1} = CA_{j_1k_1} \setminus \{i_1\}$, reiniciar $CA_{j_2k_2}$ e ir a paso 5. Si no, sea i_2 el cliente con mayor utilidad en $CA_{j_2k_2}$
7. Si $U_{i_2} > U_{i_1}$ y es factible: $x_{i_1j_1k_1} = 0$, $x_{i_2j_2k_2} = 0$, $x_{i_1j_2k_1} = 1$ y $x_{i_2j_1k_2} = 1$, $CA_{j_1k_1} = CA_{j_1k_1} \setminus \{i_1\}$, reiniciar $CA_{j_2k_2}$ e ir a paso 5. Si no $CA_{j_2k_2} = CA_{j_2k_2} \setminus \{i_2\}$ ir a paso 6

Finalmente, el cuarto tipo de vecinos consiste en intercambiar clientes tanto de oferta como de canal, tal como se ilustra en la figura 4.1. El procedimiento sería como sigue:

1. Para cada combinación de ofertas activas j_1 y j_2
2. Para cada combinación de canales k_1 y k_2 asignados a j_1 y j_2 respectivamente
3. Sea $CA_{j_1k_1}$ el conjunto de clientes asignados a la oferta j_1 y el canal k_1 y $CA_{j_2k_2}$ el conjunto de clientes asignados a la oferta j_2 y el canal k_2
4. Calcular utilidades del cambio:

$$U_i = p_{ij_2k_2} \cdot (I_{ij_2} - C_{ij_2}) - CE_{ij_2k_2} - (p_{ij_1k_1} \cdot (I_{ij_1} - C_{ij_1}) - CE_{ij_1k_1}),$$

$$i \text{ en } CA_{j_1k_1}$$

$$U_i = p_{ij_1k_1} \cdot (I_{ij_1} - C_{ij_1}) - CE_{ij_1k_1} - (p_{ij_2k_2} \cdot (I_{ij_2} - C_{ij_2}) - CE_{ij_2k_2}),$$

$$i \text{ en } CA_{j_2k_2}$$
5. Si $CA_{j_1k_1} := \emptyset$ terminar. Si no, sea i_1 el cliente con menor utilidad en $CA_{j_1k_1}$
6. Si $CA_{j_2k_2} := \emptyset$, $CA_{j_1k_1} = CA_{j_1k_1} \setminus \{i_1\}$, reiniciar $CA_{j_2k_2}$ e ir a paso 5. Si no, sea i_2 el cliente con mayor utilidad en $CA_{j_2k_2}$
7. Si $U_{i_2} > U_{i_1}$ y es factible: $x_{i_1j_1k_1} = 0, x_{i_2j_2k_2} = 0, x_{i_1j_2k_2} = 1$ y $x_{i_2j_1k_1} = 1$, $CA_{j_1k_1} = CA_{j_1k_1} \setminus \{i_1\}$, reiniciar $CA_{j_2k_2}$ e ir a paso 5. Si no $CA_{j_2k_2} = CA_{j_2k_2} \setminus \{i_2\}$ ir a paso 6

4.2. Agrupación de clientes

Uno de los objetivos principales del presente trabajo es resolver el problema en tiempos razonables para su aplicación en empresas reales. Como se verá en la próxima sección, la metodología descrita anteriormente cumple con el objetivo, pero sólo para instancias de tamaño moderado (decenas de miles de clientes) en comparación con las instancias reales (cientos de miles de clientes). Por esta razón, es necesario realizar un paso adicional para reducir los tiempos de ejecución. Tal como se mencionó en la sección 2, se utilizará un algoritmo de agrupación de clientes similar al utilizado en [21]. Con esto es posible reducir el tamaño del problema según el número de clientes por cluster. Notar que existe un trade-off entre la calidad de la solución y el tiempo de ejecución al momento de seleccionar el tamaño de los grupos. A diferencia del procedimiento utilizado en

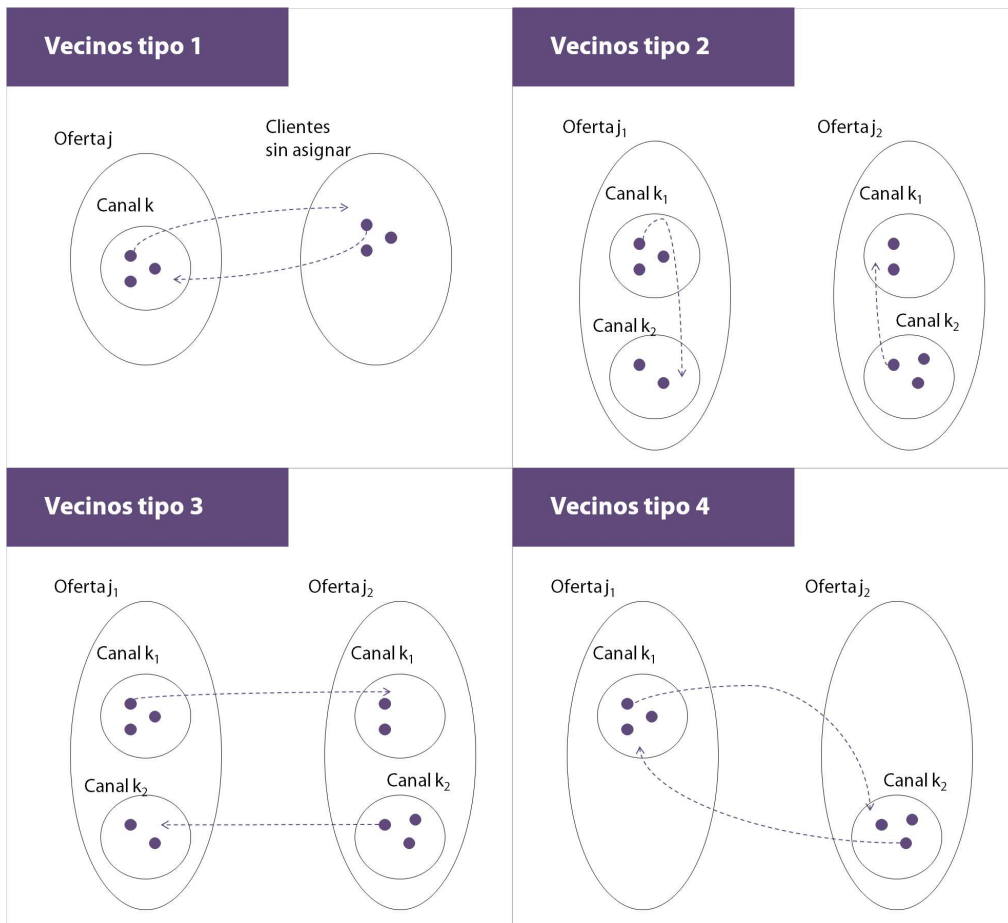


Figura 4.1: Método de selección de vecinos

[21], en el cual se modifica el problema a resolver, en el presente estudio se mantendrá intacta la estructura original del problema y se resolverá tal como se describió anteriormente en esta sección. Una vez obtenida la solución, simplemente se replicará la asignación oferta-canal a cada cliente perteneciente al grupo. Para lograrlo deben agruparse clientes con el mismo límite de ofertas, pues si esto no ocurre pueden encontrarse soluciones no factibles al momento de replicar las asignaciones a los clientes. Una vez segmentado el universo de clientes según la variable $MAXO_i$, se utiliza el algoritmo de k-medias para obtener los grupos de clientes, en base a las variables de ingresos y costos esperados. Cada cliente tendrá $N \cdot K$ coordenadas, donde la coordenada asociada a la oferta j y el canal k será: $p_{ijk} \cdot (I_{ij} - C_{ij}) - CE_{ijk}$. De esta manera quedarán agrupados clientes con igual límite de ofertas y similar función de utilidad. Como una medida de simplificación se impone que el tamaño de todos los grupos debe ser el mismo. Finalmente, para resolver el problema utilizando los clusters en lugar de clientes, deben recalcularse los parámetros. Los ingresos y costos de cada grupo serán la suma de los valores individuales, mientras que el límite de ofertas por cluster será el mismo que el de los clientes que lo forman. Por otro lado, la capacidad de los canales y la cantidad mínima de clientes por oferta se divide por el tamaño de los grupos.

Capítulo 5

Resultados

En esta sección se muestran los resultados de la aplicación del algoritmo desarrollado en el presente trabajo. En primer lugar se realizaron experimentos computacionales utilizando las mismas instancias que en [20], comparando el rendimiento de las metodologías propuestas en términos de la calidad de la solución y el tiempo de ejecución. Luego, se realizó una aplicación del algoritmo a una empresa real comparándolo con cuatro diferentes métodos que serán descritos más adelante.

5.1. Experimentos computacionales

Tal como se comentó en la sección 2, en [20] se resuelve un caso particular del problema tratado en este trabajo: el canal de venta no se considera como variable. Sin embargo, es razonable pensar que los resultados de la comparación son generalizables al caso con más de un canal. A continuación se describen las instancias utilizadas en [20] y luego se presenta la discusión de los resultados obtenidos.

5.1.1. Generación de instancias

Para testear diferentes escenarios se construyen instancias en base a:

- Diferentes valores para el número de clientes: 300, 1.000, 2.000 y 10.000
- Diferentes valores para el número de ofertas: 5, 10 y 15

Además se realizan pruebas modificando los valores de la tasa de retorno, el máximo de ofertas por cliente y presupuesto. En total se generaron 972 instancias de testeo. El resto de los parámetros utilizados en [20] para los experimentos computacionales fueron generadas aleatoriamente en base a datos reales utilizados en [21]. Por ejemplo los costos C_{ij} toman un valor aleatorio en $\{1, 2, 3\}$ y la utilidad esperada toma valores enteros aleatorios entre 0 y 16. Todos los valores fueron escogidos con la precaución de obtener instancias factibles y consistentes.

5.1.2. Comparación de resultados

Se comparará la metodología propuesta en el presente trabajo con el algoritmo de búsqueda tabú desarrollado en [20], dado que fue la heurística de mejor rendimiento (en términos de tiempos de ejecución y calidad de la ejecución). La tabla 5.1 resume los resultados obtenidos en términos del GAP con respecto al óptimo para la búsqueda tabú de [20] (BT), el algoritmo propuesto original (AL) y el algoritmo modificado utilizando clusters de clientes (ALC). Por otro lado, la tabla 5.2 muestra los tiempos de ejecución. Como dato a tener en cuenta, en los experimentos realizados en [20] se utilizó un computador Dell Optiplex GX620 con procesador de 2.8 GHz y 1.49 GB RAM, equipado con Windows XP, mientras que en el presente estudio se utilizó un Notebook HP Pavilion dv7 con procesador Intel Core i5 de 2.67 GHz y 7.8 GB RAM.

Se observa de las tablas 5.1 y 5.2 que la heurística desarrollada en el presente trabajo supera en todas las instancias al algoritmo de búsqueda tabú propuesto por [20], tanto en la calidad de la solución como en los tiempos de ejecución. Es interesante notar que dicha diferencia se acentúa al

Tabla 5.1: GAP con respecto al óptimo

Ofertas	Clientes	BT	AL	ALC
5	300	6,7%	2,7%	14,9%
5	1.000	7,2%	3,4%	8,3%
5	2.000	9,8%	3,0%	6,6%
5	10.000	10,9%	3,5%	7,9%
10	300	6,5%	5,2%	23,3%
10	1.000	8,5%	5,2%	17,9%
10	2.000	9,6%	5,0%	13,9%
10	10.000	11,0%	3,5%	9,6%

Tabla 5.2: Tiempos de ejecución (segundos)

Ofertas	Clientes	BT	AL	ALC
5	300	1,2	0,2	0,0
5	1.000	16,1	0,7	0,1
5	2.000	56,6	2,0	0,3
5	10.000	1.268,3	36,0	2,1
10	300	0,6	0,5	0,1
10	1.000	11,6	3,1	0,3
10	2.000	50,3	9,2	0,9
10	10.000	1.347,2	229,0	11,8

crecer el tamaño de las instancias, sobre todo por el aumento exponencial del tiempo de ejecución de la búsqueda tabú cuando el número de clientes aumenta a diez mil. Por otro lado, se observa que la incorporación de clusters al algoritmo original, permite una reducción de un 90% promedio en los tiempos de ejecución. Más aún, el GAP con respecto al óptimo sigue siendo mejor que el obtenido en [20] para las instancias de mayor tamaño. Este último punto es fundamental para la aplicación de la metodología propuesta en casos reales, donde el número de clientes asciende a los cientos de miles. En este caso se utilizó un tamaño de tres clientes por cluster, pues se disminuye ampliamente el tiempo de ejecución sin perjudicar en demasía la calidad de la solución. El tamaño se mantiene para la aplicación real que se describirá a continuación.

5.2. Aplicación en un caso real

A continuación se presenta la aplicación del algoritmo desarrollado en el presente estudio, en una empresa Chilena perteneciente a la industria del retail financiero. El objetivo de esta aplicación es determinar si efectivamente la metodología propuesta puede ser útil en la práctica, disminuyendo los tiempos de gestión de campañas, realizando ofertas que hagan sentido a los clientes e incrementando la utilidad de la compañía. Primero se describe brevemente a la empresa en cuestión para contextualizar el análisis. En segundo lugar se detallan las diferentes metodologías a ser comparadas en el experimento, que será descrito más abajo. Finalmente se muestran los resultados obtenidos.

5.2.1. La empresa

El presente trabajo fue aplicado a una empresa del retail financiero de Chile. La compañía se dedica a entregar servicios financieros tales como tarjetas de crédito, créditos de consumo, seguros, etc. Por razones de confidencialidad no se revelará el nombre de la empresa.

El negocio principal de la compañía consiste en otorgar financiamiento a clientes para compras de bienes y servicios en todos los comercios del país y del mercado internacional.

5.2.2. Metodologías a comparar

Con el objetivo de testear la eficiencia del algoritmo propuesto en el presente estudio, se comparará el rendimiento del mismo con otras tres metodologías. Cada una de ellas utilizará diferentes mecanismos para seleccionar las ofertas a activar, a qué clientes asignarlas y a través de qué canal de venta. Las alternativas a testear son:

1. Selección aleatoria (RND)

2. Selección por principalidad (PRIN)
3. Selección por propensión (PROP)
4. Selección por algoritmo propuesto (AL)
5. Selección por algoritmo propuesto + clusters (ALC)

RND consiste en seleccionar ofertas, canales y clientes al azar. En segundo lugar, PRIN selecciona ofertas en orden según utilidad esperada, luego asigna canales al azar y finalmente los clientes según principalidad. La principalidad es un indicador que mide la lealtad de un cliente a la tarjeta. A mayor principalidad, mayor probabilidad de que el cliente compre con la tarjeta. La tercera metodología selecciona ofertas en orden según utilidad esperada y luego escoge clientes y canales según propensión, independiente de los costos. Obviamente esta última metodología requiere que la empresa cuente con modelos de propensión desarrollados para cada oferta. Finalmente, AL y ALC son los algoritmos propuestos ya descritos en el presente trabajo. Notar que todas las metodologías deben respetar las restricciones del problema (presupuesto, límite de ofertas por clientes, capacidad de canales, etc.).

5.2.3. El experimento

El experimento llevado a cabo para testear cada una de las metodologías descritas anteriormente, consistió en asignar tres ofertas a 40.000 clientes a través de dos canales de venta distintos. Las ofertas consideradas fueron estímulos para utilizar la tarjeta en el rubro de combustibles, restaurantes y supermercados. Mientras que los canales disponibles fueron: correo electrónico e insertos en el estado de cuenta. Este último consiste en publicidad enviada físicamente junto con el estado de cuenta mensual de la tarjeta. El primer canal tiene como ventaja su bajo costo y rapidez de llegada, pero la fracción de clientes con email registrado es bajo y las tasas de rebote y no lectura son considerables. El inserto tiene la desventaja de ser varias veces más caro que el correo electrónico, pero permite una mayor cobertura (todos los clientes que reciben estado de cuenta físico) y una mayor tasa de lectura. En cuanto a los clientes utilizados, se realizaron filtros previos: inactividad (24 meses sin compra) en los tres rubros mencionados.

Tres modelos de propensión fueron desarrollados para este experimento: uno para cada rubro en oferta. Debido a la falta de historia de respuesta a campañas históricas, se desarrollaron modelos de propensión de compra y no de respuesta a un estímulo. La desventaja de lo anterior, es que la respuesta y venta incremental con respecto al grupo control podría ser baja si es que se estimula a clientes que comprarían de igual manera si no recibieran la oferta. Sin embargo, el hecho de que los clientes sean inactivos en los rubros ofertados, disminuye la probabilidad de encontrar clientes que comprarían sin estímulo. Las restricciones fueron definidas para el experimento en conjunto con expertos del negocio. Para cada una de las metodologías se consideró como máximo una oferta por cliente, no se estableció límite de capacidad de clientes ni ofertas por canal y no se exigió un mínimo de clientes por oferta. La tasa de retorno utilizada fue fijada en 10%. Finalmente el presupuesto total disponible se estableció estimando que el número de clientes estimulados en promedio fuera 5.000. No se definió un presupuesto particular por oferta.

5.2.4. Resultados

Para realizar los experimentos se utilizó un Notebook HP Pavilion dv7 con procesador Intel Core i5 de 2.67 GHz y 7.8 GB RAM. La tabla 5.3 resume los resultados de la asignación cliente-oferta-canal para cada metodología. Notar que tanto el número de ofertas como el de clientes activos es mayor en los casos AL y ALC, principalmente porque los tres primeros métodos asignan más clientes al canal inserto, por lo que la restricción presupuestaria se satura rápidamente.

Tabla 5.3: Asignación de clientes por cada metodología

	Total	Combustibles		Restaurantes		Supermercados	
		Email	Inserto	Email	Inserto	Email	Inserto
RND	4.145	1.600	2.545				
PRIN	4.734			2.220	2.514		
PROP	3.708			1.140	2.568		
AL	11.160			2.016	301	6.969	1.874
ALC	10.245			1.941	231	6.081	1.992

Por otro lado, la tabla 5.4 muestra los resultados obtenidos en términos de utilidad esperada y tiempos de ejecución. Se aprecia que AL y ALC generan una mayor utilidad esperada que el

resto. Si bien las diferencias con respecto a PRIN y PROP son considerables, se espera que para escenarios más complejos (más ofertas, canales y restricciones) la brecha se acentúe. En cuanto a los tiempos de ejecución, se observa una clara diferencia entre AL y el resto. Lo anterior es lógico pues las tres primeras metodologías son iterativas y no realizan optimización de ningún tipo. Finalmente, es destacable la diferencia en tiempo entre AL y ALC, sobre todo considerando que las utilidades generadas son similares.

Tabla 5.4: Utilidad esperada y tiempo de ejecución

	Utilidad (MM\$)	Tiempo (s)
RND	1,0	51
PRIN	3,1	50
PROP	4,4	35
AL	7,1	2.175
ALC	6,7	308

Con lo anterior queda demostrado que tanto AL como ALC tienen un mejor rendimiento, en términos de utilidad esperada y tiempos de ejecución, con respecto a las metodologías más básicas. Sin embargo, aún no se ha probado su contribución real a la compañía en términos de venta incremental de las ofertas. Para realizar lo anterior deben analizarse los resultados de la campaña. Notar que el rendimiento de AL y ALC depende directamente de la calidad e los modelos de propensión, pues si éstos predicen bien quiénes reaccionarán a los estímulos, entonces la asignación realizada según la utilidad esperada cobra sentido y, por lo tanto, se obtendrán resultados similares a los vistos en la tabla 5.4. Por otro lado, si los modelos no logran su objetivo, la utilidad esperada pierde sentido y por tanto también la asignación obtenida por AL y ALC. La tabla 5.5 resume los resultados obtenidos en términos de tasa de respuesta, venta incremental y utilidad.

Tabla 5.5: Resultados reales de la campaña

	Respuesta incremental	Venta incremental (M\$)	Utilidad (M\$)
RND	0,00 %	0	-103
PRIN	0,19 %	180	77
PROP	0,71 %	403	300
AL	0,32 %	2.321	2.217
ALC	0,14 %	1.903	1.800

Los resultados demuestran la superioridad de AL y ALC con respecto al resto de las metodologías, generando utilidades ampliamente mayores. El único punto en el cual PROP es superior es en la tasa de respuesta. Esto tiene sentido si se considera que PROP se basa totalmente en la propensión de los clientes, por lo que detecta a aquellos con la mayor probabilidad de responder. Sin embargo, para conseguirlo asigna las ofertas al canal más costoso (que posee una mayor tasa de lectura), incrementando en demasía los costos de la campaña y por ende disminuyendo la utilidad.

Capítulo 6

Análisis de sensibilidad

A continuación se presenta el análisis de sensibilidad del algoritmo propuesto, con el objetivo de estudiar el comportamiento del modelo al cambiar ciertos supuestos. Además se muestran análisis útiles que la empresa puede usar para la planificación táctica y estratégica de campañas.

6.1. Canal de venta fijo

Una de las ventajas de AL con respecto a PROP es la utilización del canal email (más barato) en desmedro del inserto (más caro), por lo que activa a una mayor cantidad de clientes utilizando el mismo presupuesto, por lo que resulta interesante analizar qué ocurre si es que se fija la elección del canal. La tabla 6.1 muestra que al fijar el canal email la diferencia entre AL y PROP disminuye de 61 % a 12 %, lo que demuestra que, si bien es menor, sigue existiendo un mejor rendimiento del algoritmo propuesto. Por otro lado, al fijar el canal inserto la diferencia es aún menor, alcanzando sólo el 0,8 %. Esto último tiene sentido pues al ser un canal más caro son menos los clientes que se pueden activar y ambos algoritmos dan prioridad a aquellos con mayor utilidad esperada. Finalmente, hay que recordar que se trata de un ejemplo simplificado pues sólo se consideran 3 ofertas, y es de esperar que en un caso más complejo (con más ofertas y canales) la diferencia sea mayor.

Tabla 6.1: Utilidad esperada (MM\$)

Canal fijo	PROP	AL	Dif. %
Ninguno	4,4	7,1	61,4 %
Email	3,2	3,7	12,6 %
Inserto	4,1	4,1	0,8 %

6.2. Oferta fija

También es posible analizar qué sucede al eliminar la elección de la oferta como un grado de libertad. Para esto se modificó el problema asignando a cada oferta un presupuesto igual a un tercio del presupuesto global, de esta manera cada algoritmo debe asignar de la mejor manera los pares cliente-canal a cada una de las ofertas por separado. La tabla 6.2 muestra los resultados obtenidos. Se aprecia una disminución de la función objetivo para los dos algoritmos cuando no hay un canal fijo. Por otro lado, al fijar el email como canal de ventas no se aprecian diferencias pues la cantidad de clientes con email disponible multiplicado por el costo del envío no superan el presupuesto individual de una oferta, por lo que la restricción impuesta de separar el presupuesto en tres no aplica en este caso (la leve diferencia en el caso de AL se debe a los factores aleatorios del algoritmo). Finalmente, las diferencias también son leves al fijar el inserto como canal de venta, lo cual indica que la utilidad esperada de los clientes más propensos no varía demasiado entre ofertas. Se esperaría que estas diferencias sean mayores en un escenario más complejo (con más ofertas y canales). Al comparar AL y PROP sigue existiendo una diferencia tanto al fijar un canal como al no hacerlo. Esto muestra que cuando PROP debe decidir en qué oferta asignar a un cliente, no piensa en el beneficio global si no que escoge la oferta con la cual el cliente presenta una mayor utilidad esperada. Al igual que en el punto anterior, estas diferencias debiesen ser aún mayores en un escenario más complejo.

Tabla 6.2: Utilidad esperada (MM\$)

Canal fijo	PROP	AL	Dif. %
Ninguno	4,2	7,0	66,1 %
Email	3,2	3,8	15,5 %
Inserto	4,0	4,2	4,6 %

6.3. Tamaño de los clusters

Uno de los pasos importantes del algoritmo desarrollado en el presente trabajo es la agrupación de clientes para la disminución de los tiempos de ejecución. Como se mencionó en el capítulo 4, existe un trade-off entre la disminución del tiempo y el empeoramiento de la solución obtenida. Las figuras 6.1 y 6.2 muestran la variación con respecto al tamaño de los clusters de la función objetivo y el tiempo respectivamente para el caso de la aplicación al caso real descrito en el capítulo 5. Si bien el tiempo disminuye exponencialmente, la FO se mantiene prácticamente constante. Esto puede deberse a la simplicidad del escenario utilizado en el experimento: tres ofertas y dos canales implica sólo seis propensiones por cliente. Por otro lado, todos los clientes poseen la misma restricción de máximo de ofertas, por lo que no es necesaria una diferenciación con respecto a dicha variable. Para ver el efecto de la agrupación de clientes en un escenario más complejo, se consideró como ejemplo una de las instancias del paper de comparación utilizada en el capítulo 5, en la cual existen 10 ofertas y diferentes restricciones de ofertas por cliente. Las figuras 6.3 y 6.4 muestran los resultados obtenidos. Efectivamente se produce una disminución cercana al 20% al agrupar de a 10 clientes. Queda como trabajo futuro el desarrollo de una metodología para determinar el tamaño de clusters a utilizar.

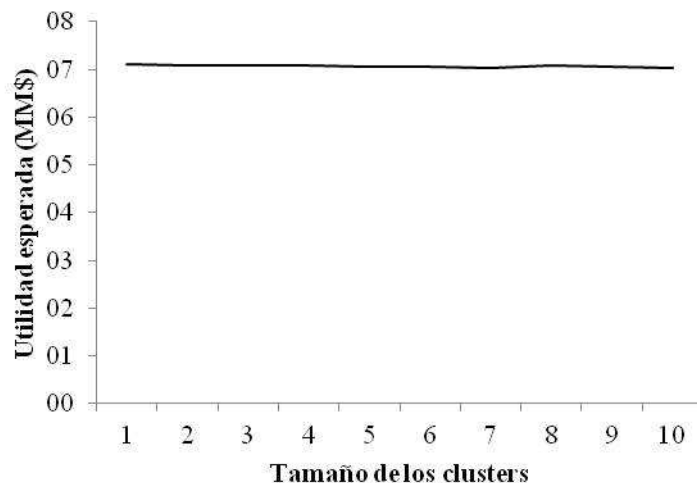


Figura 6.1: Utilidad esperada vs tamaño de los clusters

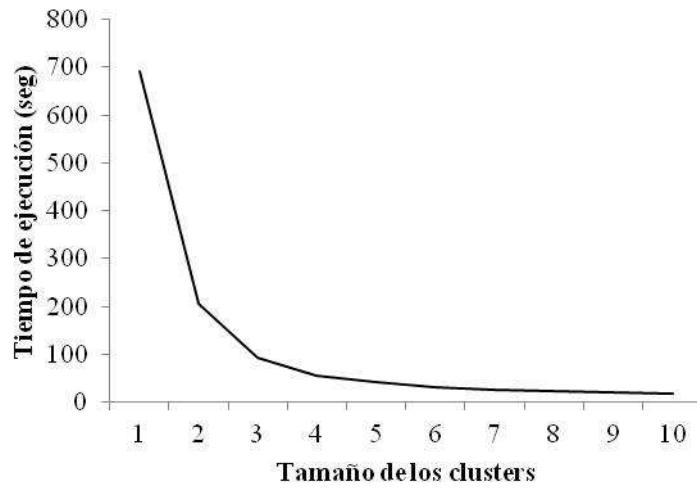


Figura 6.2: Tiempo de ejecución vs tamaño de los clusters

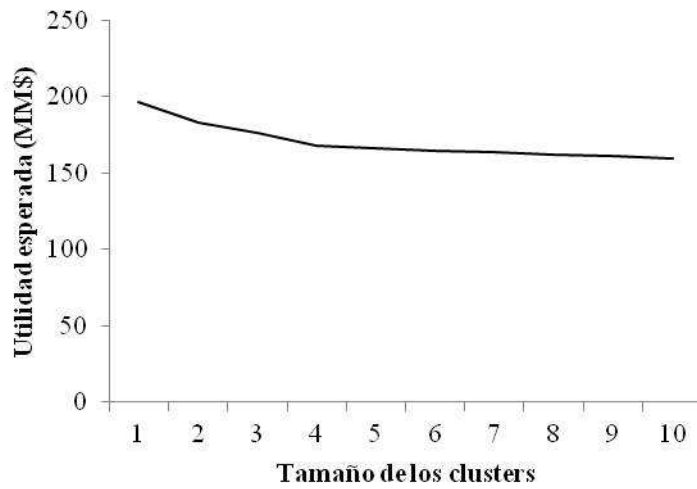


Figura 6.3: Utilidad esperada vs tamaño de los clusters

6.4. Restricciones de negocio

La resolución del problema de asignación de ofertas como un modelo de optimización permite a la empresa realizar análisis de sensibilidad con respecto a las diferentes restricciones. Esto puede




Figura 6.4: Tiempo de ejecución vs tamaño de los clusters

ser utilizado para la planificación táctica y estratégica de las campañas, decidiendo cuánto presupuesto asignar, definiendo la estrategia de toques por cliente (máximo de ofertas) y modificando la capacidad de canales como call center. A continuación se muestra un análisis de sensibilidad de la función objetivo con respecto a estas tres restricciones mencionadas: presupuesto global, máximo de ofertas por cliente y capacidad de canales. La instancia utilizada será la aplicación al caso real descrito en el capítulo 5.

6.4.1. Presupuesto global

La figura 6.5 muestra la variación de la función objetivo al modificar el presupuesto global asignado a la campaña. Se aprecia un alza prácticamente constante de la utilidad esperada al aumentar el presupuesto hasta \$115.000. Hasta ese punto la función objetivo aumenta en promedio \$250.000 por cada \$10.000 adicional en el presupuesto. Luego, se produce un quiebre en la curva que se debe a un cambio en la combinación de ofertas activadas (en el primer tramo se mantienen las ofertas y sólo se activan clientes adicionales). Por otro lado, la figura 6.6 muestra la variación porcentual del presupuesto versus el incremento de la utilidad, de lo cual se infiere que el retorno de cada peso adicional es decreciente. Esto último tiene sentido si se considera que al activar a más clientes se

toca a aquellos que poseen una menor utilidad esperada y por lo tanto un menor retorno (pues en este caso los costos no dependen del cliente). Un análisis de este tipo puede ayudar a la empresa a establecer el presupuesto global de una campaña en un cierto período.




Figura 6.5: Utilidad esperada vs presupuesto global

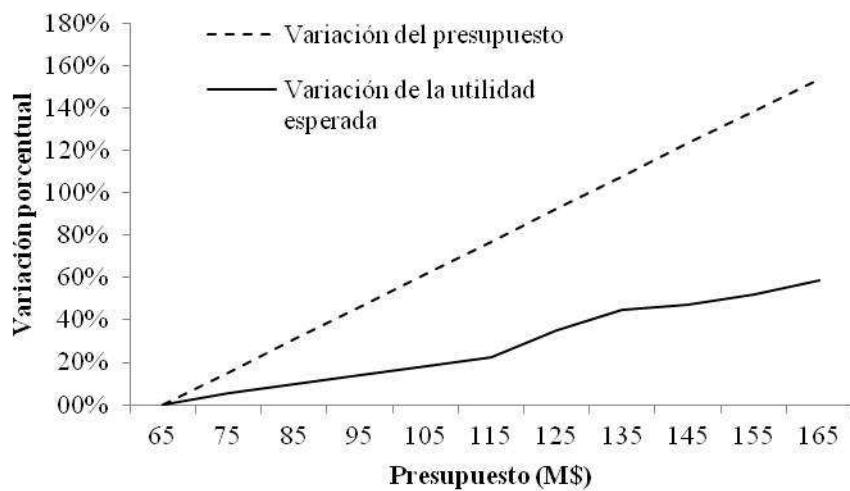


Figura 6.6: Variaciones de la utilidad esperada y presupuesto global

6.4.2. Límite de ofertas por cliente

La política de toques es un tema cada vez más importante para las empresas debido al incremento en las tasas de rechazo de publicidad por parte de los clientes. Para esto se puede realizar un análisis de sensibilidad similar al anterior, pero con consideraciones. Primero, el algoritmo propuesto no considera el efecto cruzado de las ofertas (la probabilidad cruzada puede ser mayor o menor que la individual dependiendo del caso). Por otro lado, tampoco se considera el efecto de saturación del cliente, que implicaría una disminución de la probabilidad de respuesta marginal desde un cierto número de toques. Por lo tanto, es necesario realizar un análisis adicional para determinar el límite óptimo de ofertas. La figura 6.7 muestra la variación de la función objetivo al modificar el máximo de ofertas por cliente. Se aumenta hasta tres ofertas por cliente pues en el ejemplo sólo existe esa cantidad de ofertas disponibles. Al incrementar el límite a dos ofertas la utilidad crece un 35%, mientras que al cambiar a tres sólo aumenta un 8%. Esto quiere decir que los retornos marginales son decrecientes y puede interpretarse como si las propensiones más altas no estuviesen concentradas en los mismos clientes, por lo que hay un punto en que es más rentable para la empresa balancear la activación de clientes y no realizar demasiadas ofertas a un mismo grupo de personas.

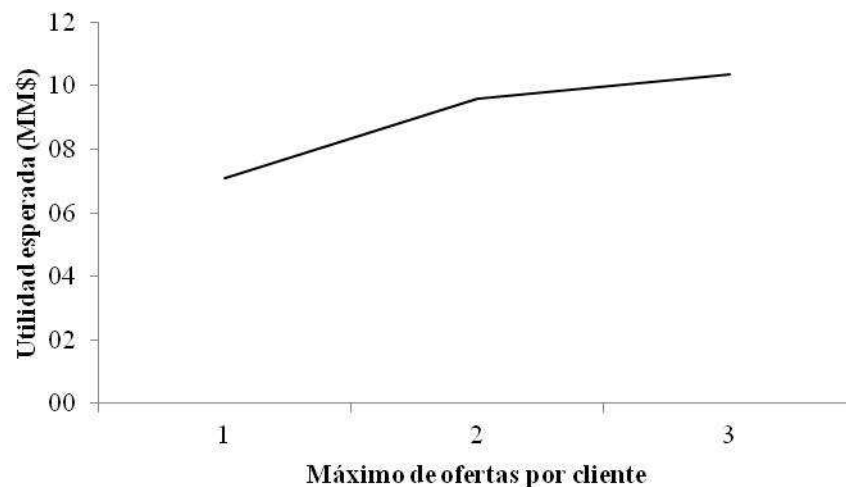


Figura 6.7: Utilidad esperada vs máximo de ofertas por cliente

6.4.3. Capacidad de canales de venta

En el ejemplo la capacidad de los canales nunca es alcanzada, pues ambas alternativas no pueden superar su límite: el número de clientes con email es muy inferior a la cantidad de envíos que pueden realizarse, mientras que todo cliente que tenga facturación en un mes puede recibir un inserto. Por esto no tiene sentido realizar un análisis de sensibilidad en este caso. Sin embargo, para canales de venta más restrictivos en capacidad (por ejemplo call center) es muy útil este tipo de análisis. En dicha situación la empresa podría calcular la utilidad esperada adicional que implica contratar un nuevo ejecutivo para el centro de llamados y el costo asociado, con lo cual podría obtenerse la capacidad óptima del canal.

Capítulo 7

Conclusiones

En el presente trabajo se resolvió el problema de optimización de campañas de marketing, decidiendo qué ofertas activar, a qué clientes enviarlas y a través de qué canal de venta. Además se consideraron las restricciones del negocio tales como el presupuesto disponible, la capacidad de los canales, el máximo de oferta por cliente, etc. Lo anterior beneficia a la empresa en diversos aspectos, tales como:

- Aumentar la venta incremental de las campañas con respecto a las metodologías más básicas utilizadas actualmente
- Realizar ofertas que agreguen más valor a los clientes y por tanto incrementar su lealtad
- Distribuir de manera más eficiente los recursos, llegando a más clientes sin incrementar el presupuesto
- Mejorar la gestión de campañas al manejar automáticamente las restricciones, sin tener que ajustar las asignaciones manualmente por el no cumplimiento de las mismas

Se comparó el algoritmo propuesto con otros métodos desarrollados en la literatura ([20]), obteniéndose como resultado un mejor rendimiento (en términos de la calidad de la solución y

de los tiempos de ejecución) por parte de la metodología desarrollada en la presente tesis. Las contribuciones de la presente tesis se pueden resumir en:

1. La formulación del problema de optimización es una extensión de los modelos propuestos en la literatura, pues incorpora más restricciones de negocio haciéndolo más cercano a la realidad.
2. La inclusión de canales de venta como variable de decisión, incluyendo todas las restricciones asociadas.
3. El desarrollo de una heurística que resuelve el problema en menores tiempos que en la literatura y alcanzando mejores resultados.
4. La aplicación del modelo desarrollado a un caso real.

También se realizó una aplicación real del modelo construido en una empresa chilena perteneciente a la industria del retail financiero. En ella se comparó la metodología propuesta con otras tres más básicas, obteniéndose resultados favorables en términos de venta incremental, utilidad y clientes estimulados.

Se discutió también sobre la importancia de los modelos de propensión para lograr la implementación del algoritmo. Es un requisito básico el desarrollo y mantención de este tipo de modelos, siendo fundamental para obtener venta incremental, la predicción de la respuesta a estímulos y no la compra natural de los clientes.

Es interesante mencionar el potencial táctico-estratégico que posee la metodología desarrollada en el presente trabajo. Dado que se resuelve un problema de optimización sujeto a restricciones, es posible realizar análisis de sensibilidad de la solución. Por ejemplo, puede estudiarse cómo aumenta la utilidad esperada si se incrementa el presupuesto o la capacidad de los canales. También sería interesante analizar la disminución de la utilidad al restringir la cantidad de ofertas por cliente. En resumen, esta metodología puede utilizarse para planificación de presupuestos, capacidad, estrategia de toques por cliente, etc. Finalmente, vale la pena considerar las posibles complicaciones de la implementación en una empresa real. Primero que todo se requiere de una cantidad considerable de

información para el desarrollo de modelos de propensión, sobre todo de campañas históricas que rara vez se almacena. Segundo, se necesita desarrollar modelos de calidad pues de ellos depende el rendimiento del algoritmo.

Finalmente, una de las mayores complicaciones es la cultura empresarial. La metodología propuesta requiere de una visión de cliente y no de producto/servicio, pues se quiere entregar a los clientes las mejores ofertas y no al revés, por lo que podrían haber productos/servicios postergados en alguna campaña. Dado que lo anterior implica un cambio cultural de largo plazo, es recomendable iniciar la aplicación con pilotos de menor escala, que permitan la implementación paulatina de esta nueva metodología.

Como extensión de la presente tesis se consideran los siguientes temas:

1. Flexibilizar la cantidad máxima de veces que un cliente puede recibir una oferta, considerando el efecto en las probabilidades.
2. Incluir costos por tramos para los canales de venta que corresponda (impresión de piezas de marketing o call center).
3. Discusión sobre la complejidad y convergencia del algoritmo (Se puede asegurar?).
4. Profundizar en la metodología de clustering de clientes (Cómo afecta a la complejidad? Cuál es la sensibilidad de la solución con respecto al número de clusters? K medias versus métodos jerárquicos?)

Bibliografía

- [1] I. Bose and X. Chen, “Quantitative models for direct marketing: A review from a system perspective”, *European journal of operational research*, 195:1-5, 2009.
- [2] D.M. Hanssens, P.S.H. Leeflang, and D.R. Wittink. “Market response models and marketing practice”, *Applied Stochastic Models in Business and Industry*, 21:423-434, 2005.
- [3] A. Knott, A. Hayes, and S.A. Neslin. “Next-product-to-buy models for cross-selling applications”, *Journal of Interactive Marketing*, 16:59-75, 2002.
- [4] S. Li, B. Sun, and R.T. Wilcox. “Cross-selling sequentially ordered products: An application to consumer banking services”, *Journal of Marketing Research*, XLII:233-239,2005.
- [5] Kamakura Wagner A., Bruce S. Kossar, Michel Wedel. “Identifying Innovators for the Cross-Selling of New Products”, *Management Science*. 50 (8) 1120-33, 2004.
- [6] Baohong Sun, Ronald T. Wilcox. “Cross-Selling Sequentially Ordered Products: An Application to Consumer Banking Services”, *Journal of Marketing Research*, XLII, May, 233-239, 2005.
- [7] Cao Yong, Thomas S. Gruca. “Reducing Adverse Selection Through Customer Relationship Management”, *Journal of Marketing* , 69 (4), 219-229, 2005.
- [8] Kamakura Wagner A, Michel Wedel, Fernando de Rosa, Jose A. Mazzon. “Crossselling through Database Marketing: A Mixed Data Factor Analyzer for Data Augmentation and Prediction”, *International Journal of Research in Marketing* 20, 45-65, 2003.

- [9] Liu Chaohua, Shuqin Cai. “Customer Cross-Selling Model Based on Customer Maturity and Product Grade”, *International Management Review* Vol. 3 No. 4, 2007.
- [10] HyunJung Shin, Sungzoon Cho, “Response modelling with support vector machines”, *Expert Systems with Applications*, 30:746-760, 2006.
- [11] Hosmer D. W., Lemeshow S. “Applied logistic regression”, London: Wiley, 1989.
- [12] Sen A., Srivastava M. “Regression analysis: Theory, method, and applications”, (Springer texts in statistics). New York: Springer, 1990.
- [13] Malthouse E. C. “Ridge regression and direct marketing scoring models”, *Journal of Interactive Marketing*, 13(4), 1023, 1999.
- [14] Viaene S., Baesens B., Gestel T., Suykens J.A.K., Van den Poel D., Vanthienen J., De Moor B., Dedene G., “Knowledge discovery in a direct marketing case using least squares support vector machines”, *International Journal of Intelligent Systems* 16, 1023-1036, 2001.
- [15] Wang K., Zhou S., Yang Q., Yeung J.M.S. “Mining customer value: from association rules to direct marketing”, *Data Mining and Knowledge Discovery* 11, 57-79, 2005.
- [16] Ha K., Cho S., MacLachlan D. “Response models based on bagging neural networks”, *Journal of Interactive Marketing* 19(1), 17-30, 2005.
- [17] Haughton D., Oulabi S. “Direct marketing modeling with CART and CHAID”, *Journal of Direct Marketing* 11(4), 42-52, 1997.
- [18] Moutinho L., Curry B., Davies F., Rita P. “Neural network in marketing”, New York: Routledge, 1994.
- [19] Nicholas J. Radcliffe, Patrick D. Surry. “Real-World Uplift Modelling with Significance-Based Uplift Trees”, Portrait Technical Report, 2011
- [20] Fabrice Talla Nobibon, Roel Leus, Frits C.R. Spijksma “Optimization models for targeted offers in direct marketing: Exact and heuristic algorithms”, *European journal of operational research*, 210:670-683, 2011.

- [21] M. D. Cohen “Exploiting response models - optimizing cross-sell and up-sell opportunities in banking”, *European Information systems*, 29:327-341, 2004.
- [22] S Delanote, R Leus, F Talla Nobibon “Optimization of the annual planning of targeted offers in direct marketing”, *Journal of the Operational Research Society*, 1-10, 2012.
- [23] Weintraub et al, “A tabu search approach for solving a difficult forest harvesting machine location problem”, *European journal of operational research*, 179:788-805, 2007.
- [24] Yongzhong Wu, Ping Ji, “Solving the Quadratic Assignment Problems by a Genetic Algorithm with a New Replacement Strategy”, *World Academy of Science, Engineering and Technology* 30, 2007.
- [25] Alfonsas Misevicius, “A modified simulated annealing algorithm for the Quadratic Assignment Problem”, *Informtica*, vol. 14, 4:497-514, 2003.