



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

METODOLOGÍA PARA LA OPTIMIZACIÓN DE PRESUPUESTO PUBLICITARIO EN  
FACEBOOK A TRAVÉS DE UN MODELO VARX

MEMORIA PARA OPTAR AL TÍTULO DE  
INGENIERO CIVIL INDUSTRIAL

DIEGO ALFONSO GAJARDO GONZÁLEZ

PROFESOR GUÍA:  
MARCEL GOIC FIGUEROA

MIEMBROS DE LA COMISIÓN:  
ASTRID CONTRERAS FUENTES  
LORETO MARTÍNEZ GIMENEZ

SANTIAGO DE CHILE  
2020

RESUMEN DE LA MEMORIA PARA OPTAR  
AL TÍTULO DE INGENIERÍA CIVIL INDUSTRIAL  
POR: DIEGO ALFONSO GAJARDO GONZÁLEZ  
FECHA: 2020  
PROF. GUÍA: MARCEL GOIC FIGUEROA

## METODOLOGÍA PARA LA OPTIMIZACIÓN DE PRESUPUESTO PUBLICITARIO EN FACEBOOK A TRAVÉS DE UN MODELO VARX

El uso de canales digitales para alcanzar objetivos de marketing se ha masificado en el último par de años. Páginas web, correos electrónicos y redes sociales son algunos de los espacios que han quitado protagonismo a los medios tradicionales como la televisión. A nivel mundial, la inversión en publicidad digital ya alcanza a ser la mitad de la inversión total en medios y representa más de 300 billones de dolares. A pesar de esto, en Chile los niveles de inversión son menores, y el uso de canales digitales se limita a heurísticas sencillas y de corto plazo.

El objetivo del presente trabajo es desarrollar una metodología de optimización de presupuesto publicitario digital, basado en predicciones, específicamente para la red de aviso de Facebook. En la primera etapa, se analizan datos de campañas de anuncios para entender el carácter predictivo de este tipo de publicidad. A partir de esto, se desarrolla un modelo VARX para realizar predicciones y estudiar relaciones subyacentes entre los resultados publicitarios de un anuncio, tales como las veces que se muestra y los clics que recibe. Luego de esto, se propone una metodología retroactiva que incluye el modelo VARX y un modelo de optimización, con la cual sea posible definir una asignación óptima de presupuesto, diario según las predicciones de resultados publicitarios que se realizan. Dicha metodología es validada con un experimento al final de la investigación.

Como descubrimientos asociados al proceso anterior, se valida la posibilidad de realizar predicciones de los resultados publicitarios en Facebook. Además, se explora el hecho de que las dinámicas subyacentes entre dichos resultados están asociadas a factores gráficos del anuncio y que su predictibilidad está asociada a la segmentación. Esto representa una gran oportunidad en la industria para desarrollar modelos y metodologías que permitan el uso eficiente de los presupuestos publicitarios.



*Que tu meta hoy  
sea ganarle  
a tu mejor excusa.*



# Agradecimientos

Después de 7 años en la Facultad de Ciencias Físicas y Matemáticas logro entregar mi trabajo de título. No fueron 7 años de ramos reprobados y sufrimiento inmesurable, sino que 7 años de conocimiento y crecimiento personal, de amistades sufridas y vividas, de amores y desamores, pero por sobre todo de esfuerzo y aprendizaje.

Durante esta última etapa muchas personas estuvieron en mi vida; amigos, compañeros de 3 trabajos y de la universidad, familiares y profesores. Me gustaría poder agradecer a todos y todas, pero el espacio es acotado.

Agradezco primero a quien es mi polola al momento de escribir esto, Fernanda López. Me aguantó día y noche durante los últimos 3 años, pero con especial paciencia durante el último. Agradezco a mi madre, a mi padre y a mi hermana, a quienes vi muy poco durante este proceso final, pero que siempre estuvieron ahí para apoyarme. Agradezco sobretodo a mi padre, que siempre me ayudó en la parte económica, que lamentablemente es una barrera para muchos.

Agradezco también a Marcel Goic, mi profesor guía, por haberme guiado durante este proceso. Siempre lo admiré como profesor, pero durante este proceso aprendí a admirarlo como persona. Tampoco pueden quedar fuera Rodrigo León y Andrés Liebrecht de la Agencia WUA. Ellos tuvieron completa disposición a que pudiera trabajar con datos de su compañía, por lo que, literalmente, sin ellos no este trabajo no habría sido posible.

Espero que quien lea este trabajo pueda aprender algo nuevo, o por lo menos pique su curiosidad respecto a estadística o marketing en general. Cualquier comentario respecto al mismo será bien recibido.



# Tabla de Contenido

<b>Introducción</b>	<b>1</b>
<b>1 Marco Teórico</b>	<b>4</b>
1.1 Gestión de Presupuesto Publicitario . . . . .	4
1.2 Plataforma de Anuncios de Facebook . . . . .	6
1.3 Agencia WUA . . . . .	8
<b>2 Metodología de Trabajo</b>	<b>9</b>
<b>3 Desarrollo</b>	<b>10</b>
3.1 Análisis Previo . . . . .	10
3.1.1 Extracción y Preparación de Datos . . . . .	10
3.1.2 Análisis Estadístico . . . . .	14
3.1.3 Análisis de Predictibilidad . . . . .	17
3.1.4 Análisis de Dinámicas Subyacentes . . . . .	20
3.2 Metodología de Optimización Propuesta . . . . .	22
3.3 Validación . . . . .	25
3.3.1 Experimento Propuesto . . . . .	25
3.3.2 Desarrollo y Resultados . . . . .	28
3.3.3 Discusión . . . . .	29
<b>Conclusión</b>	<b>37</b>
<b>Bibliografía</b>	<b>39</b>
<b>Anexo</b>	<b>42</b>





# Índice de Tablas

3.1	Métricas exploratorias de anuncios de la primera etapa . . . . .	14
3.2	Criterios Hannan-Quinn para VARX de la primera etapa . . . . .	18
3.3	Métricas de ajuste para distintos niveles de lag en el VARX de la primera etapa	19
3.4	Inversión propuesta para la semana 2 del experimento . . . . .	28
3.5	Inversión propuesta para la semana 3 del experimento . . . . .	29
3.6	Inversión propuesta para la semana 4 del experimento . . . . .	29
3.7	Resultados acumulados del experimento . . . . .	30
3.8	Resultados acumulados ajustados del experimento . . . . .	30
3.9	Resultados acumulados del experimento en semana 3 y 4 para anuncios generales	32
3.10	Resultados acumulados del experimento en semana 3 y 4 para anuncio sello .	33
3.11	Ajuste de las predicciones durante el experimento . . . . .	33



# Índice de Ilustraciones

3.1	Descripción de los anuncios de la primera etapa . . . . .	12
3.2	Desglose diario de métricas de los anuncios de la primera etapa . . . . .	13
3.3	Estimación de inversión utilizando medias móviles . . . . .	13
3.4	PACF para anuncios de la primera etapa . . . . .	16
3.5	Funciones de respuesta a impulsos para anuncio de video . . . . .	20
3.6	Funciones de respuesta a impulsos agrupadas por segmentación . . . . .	21
3.7	Transformación ortogonal de las funciones de respuesta a impulsos . . . . .	22
3.8	Diagrama de la metodología de gestión propuesta . . . . .	24
3.9	Descripción de anuncios del experimento . . . . .	26
3.10	Configuración del experimento en la plataforma de anuncios de Facebook . . . . .	27
3.11	Evolución de clics obtenidos para anuncios generales . . . . .	31
3.12	Evolución de clics obtenidos para anuncio sellos . . . . .	32
3.13	Funciones de respuesta para anuncios del experimento . . . . .	34
3.14	Comparación de IRF según segmentación . . . . .	36



# Introducción

Desde la apertura pública de internet en los años 90, organizaciones de todo el mundo han tenido que adaptar sus esfuerzos de marketing a un contexto digital. En la actualidad, dicho fenómeno se conoce como marketing digital, y es una forma de marketing directo que conecta consumidores y vendedores de manera electrónica, a través de herramientas tales como páginas web y correos electrónicos. Esta práctica no solamente permite interactuar de manera directa con consumidores finales, sino que también permite medir con mayor facilidad los esfuerzos realizados. Esto se añade al hecho de que el acceso a internet se ha masificado fuertemente en el siglo 21. Según Datos de la International Telecomms Union (2018), para fines del 2019 el 53 % de la población mundial tendría acceso a internet, lo que corresponde a más de 4 billones de personas. Todo esto representa una oportunidad atractiva para utilizar estrategias y acciones de marketing digital, sobretodo en organizaciones con operaciones de escala mundial.

Respecto a publicidad digital, su uso aumenta año tras año. Según la empresa investigadora de mercados eMarketer (2019), el año 2018 la inversión en publicidad digital alcanzó el 45 % del presupuesto total de medios a nivel mundial. Para el año 2020, se proyecta que dicho monto sea cercano al 53 %, que corresponde a más de 380 billones de dolares. En el mismo estudio, se destaca que los principales vendedores de espacios publicitarios son Google y Facebook, cuyos ingresos por anuncios llegarían a 103 y 67 billones de dolares, respectivamente, para finales del 2019. La proyección indica que año tras año aumentaría la inversión publicitaria digital, quitando cada vez más espacio a medios tradicionales como la radio y la televisión.

En Chile, el uso de marketing digital es menor. Según la Asociación de Agencias de Medios (AMM), la inversión en publicidad digital en el país fue cercana a los 199 mil millones de pesos durante el 2018. Dicho monto corresponde al 26 % de la inversión total en medios del mismo año y al doble de la inversión del año 2014. Esto refleja el aumento en la importancia del canal digital en las acciones de marketing en el país. Lo anterior se refuerza con el estudio Data-Driven Marketing, realizado por la Facultad de Economía y Negocios (FEN) de la Universidad de Chile y la Asociación de Marketing Directo y Digital de Chile (AMDD). En dicho estudio, profesionales de marketing del país señalan que los esfuerzos en canales digitales son los que generan mayor impacto en sus negocios. Además, los respondentes proyectan aumentar la inversión en estos canales para el año 2019. A pesar de esto, existe una importante brecha en cuanto al manejo y uso de datos. Según el mismo estudio, los participantes se muestran de acuerdo con que el buen uso de datos representa una ventaja competitiva, y el 35 % de la inversión en marketing lo destinan a recolección y análisis de datos. Pese a lo anterior, solamente el 28 % de los profesionales declara tener capacidades para tomar decisiones basadas

en datos. Esto quiere decir que, si bien se considera importante el uso de datos en las áreas de marketing, y en particular en áreas digitales, estos no están siendo aprovechados del todo.

Un problema de marketing recurrente, cuya solución se puede apoyar en el uso de datos, es la asignación eficiente del presupuesto publicitario. En el contexto digital, las plataformas de anuncios permiten optimizar de manera automática el presupuesto de campañas, utilizando datos generados por la herramienta y la campaña misma. A través de esto, y según reglas definidas por la plataforma, el anunciante espera que su presupuesto sea utilizado de la mejor manera para obtener los resultados que busca. Bajo este contexto, el presente trabajo busca mejorar dicha forma de gestión. Para esto se propone aplicar reglas definidas por el propio anunciante por sobre las optimizaciones que realizan las plataformas. En una primera etapa se estudiará la predictibilidad de los resultados publicitarios de anuncios digitales, las dinámicas subyacentes entre las distintas métricas asociadas a estos y, finalmente, se propondrá un modelo de gestión mejorado. La plataforma que se utilizará es la de anuncios de Facebook, por lo que se analizarán datos de campañas en dicha red social. Por simplicidad, se dejarán afuera las redes de Instagram y Messenger, pertenecientes a la misma compañía.

De esta forma, la investigación se realiza en base a la siguiente hipótesis:

*“Es posible mejorar los resultados de anuncios en Facebook utilizando reglas definidas por el anunciante, basadas en el comportamiento de las dinámicas subyacentes de los resultados publicitarios y de la predictibilidad de los mismos.”*

Para validar o descartar la afirmación anterior, se plantea el siguiente objetivo:

*“Desarrollar una metodología que utilice predicciones de resultados publicitarios en Facebook y permita optimizar la inversión publicitaria en la plataforma.”*

Como objetivos secundarios del trabajo se definen los siguientes:

- a Identificar la predictibilidad de los resultados publicitarios en Facebook.
- b Analizar las dinámicas subyacentes entre los resultados publicitarios en Facebook.
- c Establecer un modelo de predicción de resultados publicitarios.
- d Proponer una metodología de gestión de presupuesto publicitario en Facebook.
- e Validar la metodología propuesta con un experimento práctico.

Estos objetivos se logran utilizando datos proporcionados por la agencia de marketing WUA, empresa especializada en la gestión de anuncios publicitarios. Los datos que comparte para esta investigación corresponden a resultados publicitarios de campañas ya finalizadas. Por un asunto de privacidad, no se realiza una identificación detallada del cliente anunciante, pero esto no tiene mayor incidencia en la investigación.

Para estudiar el carácter predictivo de los anuncios y entender las dinámicas existentes entre sus resultados, se utiliza un modelo de vectores autorregresivos con variable exógena. Como resultado principal, se tiene que la predictibilidad de los anuncios dependerá del público

objetivo al cuál se dirijan y que la influencia de variables como impresiones e interacciones no se prolonga en el tiempo, sino que producen efectos principalmente contemporáneos a un cambio en las mismas. Con lo anterior, se propone una metodología para incluir dichos hallazgos en la optimización de presupuesto publicitario.



# Capítulo 1

## Marco Teórico

### 1.1. Gestión de Presupuesto Publicitario

La incorporación de canales digitales a las estrategias de marketing, dado el uso masivo de las redes sociales y motores de búsqueda, ha dado paso a numerosos estudios que buscan determinar la efectividad y rentabilidad de las acciones publicitarias en dichos espacios. Algunos de estos hablan sobre la implementación eficiente de los canales digitales en las estrategias de marketing, así como otros buscan evidenciar casos de éxito de dichas prácticas. Este trabajo no pretende apoyar o contradecir los estudios anteriores demostrando la eficacia o rentabilidad de anunciar en una red social. De manera complementaria, busca aportar por el lado del manejo óptimo de presupuesto publicitario y de la predictibilidad de anuncios. Considerando esto, el análisis de este trabajo se realiza con datos de la entrega de los anuncios y no previa a ésta, como se ha realizado en otras investigaciones con el fin de mejorar la calidad de la entrega misma.

Este estudio se enfoca en el problema de asignación óptima de presupuesto publicitario, que ha sido trabajado ampliamente en la publicidad tradicional y hace referencia a qué nivel o intensidad de publicidad se utilizará en cada periodo, con el fin de obtener los mejores resultados posibles a un menor costo. El análisis se puede realizar para uno o más periodos, conocido como análisis multietapa, y para uno o más productos, conocido como análisis multiproducto. Además, podría contener soluciones determinísticas o estocásticas. Un mayor desarrollo al problema puede encontrarse en el trabajo de Danaher y Rust de 1996, en el cual también se analizan otras soluciones planteadas hasta ese momento. Al considerar canales digitales, el problema de optimización de presupuesto adquiere un rol cada vez mayor dado los crecientes niveles de inversión publicitaria digital. Además, los medios digitales entregan nuevos desafíos al problema ya que poseen flexibilidad en su configuración que los medios tradicionales no, como segmentaciones más específicas, niveles de frecuencia, inversiones con mínimos bajos y prácticamente sin máximos, entre otras. Junto a esto, se debe considerar la rápida retroalimentación entregada por las plataformas que gestionan los anuncios (resultados por hora). El presente trabajo se centra en la plataforma de anuncios de Facebook, que se utiliza para gestionar anuncios en las redes sociales Facebook e Instagram. Se plantea una heurística para resolver el problema de optimización de presupuesto publicitario, la cual se

basa en predicciones de los resultados de los mismos anuncios. Esto quiere decir que la heurística sugiere niveles de inversión, en la plataforma de anuncios, en base a los resultados diarios que se van registrando. De esta forma, se clasifica como un análisis multietapa, ya que se evaluará la inversión publicitaria en más de un periodo. Limitarse a Facebook enmarca el alcance de la investigación pues se analizarán anuncios de display y no de búsqueda. Además, no se estudia la ubicación eficiente de estos en distintos sitios, si no que los datos post-impresión de los mismos. De esta forma, el trabajo se podría considerar como complemento a análisis pre-impresión de anuncios, como el de Paulson et al. (2018). En dicho estudio, se plantea un algoritmo para definir montos de inversión sobre un set de sitios y espacios publicitarios. En la presente investigación, se asumirá dicho problema como resuelto y se trabajará en función de los resultados de los anuncios posterior a la decisión de dónde mostrarlos.

Las predicciones se realizan a través de un modelo de vectores autorregresivos con variable exógena, en adelante mencionado como VARX por sus siglas en inglés. Este modelo tiene la ventaja de capturar la interdependencia entre series de tiempo y de incorporar variables externas en el proceso, además de considerar efectos autorregresivos. Mayores detalles del modelo son explicados en la sección *Análisis de Predictibilidad*. Un trabajo importante en el área es el de Nijs, Dekimpe, Steenkamps y Hanssens (2001) para medir el efecto de cambios de precios en la demanda por categorías. En dicho trabajo se utilizó un modelo VARX para estimar efectos tanto de corto como de largo plazo. También es importante el trabajo de Goic, Álvarez y Montoya (2018), quienes utilizaron un modelo VARX para estimar los efectos de anuncios publicitarios dentro del mismo sitio web del anunciante. La última referencia con respecto a modelos VARX es el trabajo de Dekimpe y Hanssens (2003), en el que sistematizan el uso de VARX en el análisis de desempeño de estrategias de marketing. De esta forma, los modelos VARX han sido utilizados en contextos de marketing tradicional y digital, y la presente investigación los utiliza en redes sociales. Además, los trabajos anteriores se desarrollan bajo un marco de trabajo en torno a modelos VARX, el cual se tomará como la base del presente estudio.

Finalmente, al momento de modelar y predecir resultados publicitarios se dejarán de lado algunos factores y elementos que se han estudiado en contexto de publicidad tradicional y digital. En este último, distintos estudios han considerado el efecto de adstock (Archak et al., 2010) y wearout (Havlena and Graham, 2004), pero dichos efectos no se incluirán de manera explícita en el presente trabajo. Es posible que estos se capturen de manera implícita en el modelo VARX, pero no serán objeto de estudio. Tampoco se considerarán elementos cuyo control estén fuera del alcance de la plataforma de anuncios, como las dinámicas de mercado, competencia y consumidor (Pauwels, 2004) o el efecto de la frecuencia en posteriores compras (Hussain et al., 2018). Por último, tampoco se considerarán elementos propios de los anuncios mostrados, como el efecto de tener varios diseños de anuncios (Braun and Moe, 2013) o efectos psicológicos que podrían influir en los resultados publicitarios (Lee and Hong, 2016). Por lo tanto, el alcance de la investigación está limitado por los resultados publicitarios que entrega la plataforma de anuncios de Facebook, sin considerar explícitamente efectos o elementos externos a ella, tales como dinámicas de mercado, competencia o consumidor, estacionalidades, contextos sociales o económicos, o los mencionados efectos visuales y psicológicos de un anuncio. La única variable que se considerará externa y que se utilizará en el modelo VARX es la inversión configurada por el anunciante.

## 1.2. Plataforma de Anuncios de Facebook

Dado que la base del presente trabajo son los anuncios en Facebook, se hace necesario entender cómo funciona la compra y venta de espacios publicitarios en la red social. De esta forma, es posible comprender mejor aspectos tales como el alcance de la investigación o el planteamiento metodológico. A continuación se explicará brevemente el funcionamiento de la publicidad programática para luego detallar el funcionamiento de la plataforma de anuncios de Facebook.

El uso público de internet hizo atractivo el uso de banners (imágenes clickeables con un enlace a otro sitio) para promocionar sitios web. Editores (quienes tienen espacios para banners) y anunciantes (quienes pagan porque sus banners se muestren) conversaban uno a uno para llegar a un acuerdo monetario que permitiera suplir sus necesidades. Cuando la proliferación de páginas web hizo insostenible esta práctica, la creación de distintas tecnologías permitieron continuar el crecimiento de la publicidad online. Primero se logró la entrega masiva de anuncios en distintos sitios web, a través de los llamados *ad servers* (servidores de anuncios), para luego crear redes de distribución mayores, o *ad networks*, y posteriormente refinarse en un ecosistema de compra y venta de espacios publicitarios en tiempo real, conocido como *Real-Time Bidding* (RTB). En este sentido, la publicidad programática corresponde a la entrega de publicidad en internet a través del ecosistema RTB, que funciona con un sistema de pujas en el momento en que una persona visita una página web. Ahí, mediante la conexión de tecnologías que componen el RTB, ocurre una subasta de cada espacio publicitario del sitio web, en la cual participan distintos anunciantes. En el espacio publicitario se mostrará el anuncio del anunciante que gane esa subasta. De esta forma, y de manera automática e inmediata, anunciantes de todo el mundo compiten para mostrar su anuncio a una persona específica. Esto se logra mediante el uso de tecnologías tales como *ad servers*, *ad networks*, *Supply Side Platforms* (SSP, tecnologías que agrupan editores), *Demand Side Platforms* (DSP, tecnologías que agrupan anunciantes), *Data Management Platform* (DMP, proveedores de información), entre otras, las cuales interactúan en el RTB. Además, las subastas que se realizan en el RTB permiten estructuras de costo para los anunciantes tales como *Cost Per Click* (CPC, se paga por cada click en el anuncio), *Cost Per Mile* (CPM, se paga por cada mil anuncios mostrados), *Cost Per Acquisition* (CPA, se paga por cada una acción específica en el sitio web del anunciante), entre otras.

La plataforma de anuncios de Facebook, como empresa, es la solución de publicidad programática propia de la compañía. Al igual que con la publicidad en sitios web, la publicidad programática permitió a Facebook escalar los acuerdos con anunciantes de todo el mundo y mejorar la entrega de sus anuncios. A esta herramienta se accede a través de la plataforma de gestión de negocios de Facebook, o *Business Manager* (BM), y se mencionarán ambas indistintamente.

Respecto al alcance y limitaciones del Business Manager, si bien en los inicios de la plataforma la entrega de anuncios se limitaba a espacios específicos dentro de Facebook como red social, al año 2019 es posible mostrar anuncios también en la red social Instagram, en la aplicación Messenger, y en otras aplicaciones y sitios web con los que la compañía mantiene contratos de avisaje, lo que se conoce como *Audience Network*. De esta forma, los espacios publicitarios que Facebook tiene a su disposición permiten suplir la demanda de los anun-

cientes que utilizan el Business Manager. Así mismo, los formatos de anuncios posibles son imágenes y anuncios de videos de variadas especificaciones. El esquema con el cual Facebook ordena esta información es el de *campañas* que agrupan *conjuntos de anuncios*, siendo estos últimos una agrupación de *anuncios*. Además, la plataforma permite realizar segmentaciones de públicos en base a su comportamiento en la red social, una de las principales motivaciones para los anunciantes. Esto hace que los anuncios puedan mostrarse a personas con comportamientos específicos, en horas y días específicos, según la necesidad del anunciante.

Considerando lo anterior, la plataforma de anuncios de Facebook replica el ecosistema RTB dentro de la red de la compañía, actuando como *ad network*, *DSP* y como otras tecnologías mencionadas. Por lo mismo, a través de la plataforma se pueden configurar los objetivos de cada anuncio, lo que dará paso al sistema de pujas que se utilice en el RTB. Por ejemplo, un anuncio podría tener el objetivo *Mensajes*, con lo cual se le cobrará al anunciante cada vez que un usuario de la red inicie una conversación con él. Para lograr lo anterior, hay dos etapas de vital importancia para la plataforma de anuncios: la fase de aprendizaje y las subastas. Respecto a la primera, sitios de información oficiales de Facebook (2019) informan lo siguiente:

*“Cada vez que se muestra un anuncio, nuestro sistema de entrega de anuncios obtiene más información sobre las personas y los lugares más adecuados para mostrarlo. Mientras más se muestre un anuncio, mejor será la optimización del rendimiento que realice el sistema de entrega.*

*La fase de aprendizaje es el período durante el cual el sistema todavía tiene mucha información por obtener sobre un conjunto de anuncios. Durante esta fase, el sistema de entrega explora el mejor método de entrega del conjunto de anuncios, por lo que es posible que el rendimiento sea menos estable y el costo por acción (CPA) sea peor. (...).*

*(...) Si bien el sistema de entrega nunca deja de obtener información sobre el mejor método para entregar un conjunto de anuncios, la fase de aprendizaje finaliza cuando el rendimiento se estabiliza (normalmente, después de 50 conversiones).”*

Respecto a las subastas, el sistema de RTB de Facebook determina la entrega de los anuncios según el valor total del anuncio, el cuál depende de 3 parámetros. Según las páginas oficiales de Facebook (2019), estos parámetros son:

- La puja que realiza un anunciante.
- Los porcentajes de acciones estimadas, es decir, una aproximación de las acciones que realizará la persona que vea el anuncio.
- La calidad del anuncio, que dependerá de características propias del anuncio tales como los comentarios de las personas que lo ven, si hay demasiado texto en la imagen, lenguaje utilizado, entre otras.

De esta forma, distintos elementos determinan la entrega y resultados de un anuncio, desde configuraciones que decide el anunciante hasta factores que define la plataforma. Dependiendo del objetivo escogido, es posible definir reglas respecto a la puja, como el monto máximo a pujar o el valor promedio de las pujas. Recordando que en la subasta participan otros anunciantes, el costo promedio de mostrar cada anuncio podría variar de anunciante en anunciante e, incluso, de campaña en campaña para el mismo anunciante. Además, según las especificaciones declaradas por Facebook, se esperaría que las series de tiempo que describen la entrega de los anuncios mostraran una tendencia a incrementar debido al aprendizaje que realiza la plataforma. Por esto mismo, la predictibilidad de los resultados podría ser baja, ya que la plataforma va ajustando sus parámetros de entrega a medida que avanzan los días, de manera dinámica. Entender estas dinámicas y utilizarlas en favor de optimizar el uso del presupuesto es lo que motiva y justifica la presente investigación.

### 1.3. Agencia WUA

A continuación se realiza una caracterización de la empresa WUA, con el propósito de contextualizar el origen de los datos utilizados en esta investigación.

WUA SpA (en adelante mencionada simplemente como WUA) es una agencia especializada en la creación de estrategias de marketing digital para aumentar las ventas de sus clientes. Se formalizó como empresa en Enero de 2016 y ha estado en actividad constante hasta la fecha de redacción de este trabajo. Los servicios que ofrece están relacionados con las necesidades de marketing de sus clientes, por lo que suelen adaptar las labores que realizan. A pesar de esto, el 80 % de sus ingresos por venta provienen de la gestión de anuncios en Google y en redes sociales como Facebook, Instagram y LinkedIn. Otras actividades que han realizado son capacitaciones a equipos de marketing que lo soliciten, envío de correos masivos y diseño de automatizaciones en plataformas web.

El 80 % de los clientes de WUA pertenecen a empresas business-to-business (B2B), mientras que el 20 % restante pertenece a empresas business-to-client (B2C). Esta proporción se debe, en parte, a una decisión estratégica en la cuál se decidió incorporar solamente nuevos clientes B2B. El detalle de ingresos por venta de la agencia se ha solicitado mantenerlo en secreto, pero reporta un crecimiento anual de 30 % en su facturación anual.

WUA no tiene alianzas ni acuerdos de ningún tipo con otras agencias o asociaciones de marketing, pero cuenta con la certificación Google Partners otorgada por Google. Esta certificación demuestra que la agencia cuenta con conocimientos actualizados para gestionar anuncios a través de la plataforma Google Ads. En cuanto a Facebook, la agencia no posee ningún tipo de convenios, pero sus trabajadores poseen certificaciones y experiencia en la gestión de anuncios en dicha red.

La motivación de WUA en participar de esta investigación es detectar oportunidades en la gestión de anuncios que realizan de manera regular. En este sentido, buscan entregar mejores resultados para sus clientes a un menor costo, a la vez de poder declarar el uso de métodos basados en datos para realizar la gestión de anuncios. Por esta razón, se espera que los hallazgos realizados en este trabajo puedan ser aplicados en sus labores y que potencie el nombre de la empresa.

# Capítulo 2

## Metodología de Trabajo

Para cumplir con los objetivos propuestos en este trabajo, se analizan campañas de anuncios en Facebook para entender su comportamiento estadístico y establecer modelos de predicción. Como se mencionó en el capítulo *Marco Teórico*, se espera utilizar un modelo de vectores autorregresivos con variables exógenas, o VARX. Así, en la primera parte de esta investigación se utilizan datos de campañas de anuncios finalizadas. Estos se utilizan para detectar variables relevantes para el modelo VARX y otras características del mismo, como el nivel de lag. Dado que se busca estudiar los resultados publicitarios de los anuncios, trabajar con campañas ya finalizadas permite tener a disposición todos los resultados posibles. Además, al dividir los datos en un conjunto de pruebas y en uno de validación, se podrá corroborar la calidad de las predicciones. En la segunda parte, se valida el uso de las predicciones del modelo VARX en un algoritmo de optimización. Para esto se realizan predicciones y optimizaciones en campañas de anuncios nuevas, por lo que los modelos se alimentarán de datos que semana a semana entrega la plataforma.

Los datos a utilizar serán facilitados por la agencia de marketing digital WUA. Esta agencia se dedica a realizar acciones de marketing digital en negocios bussines-to-bussines (B2B), siendo Facebook una de las redes que utiliza para mostrar anuncios de sus clientes. La gestión cotidiana de los anuncios de WUA se realiza principalmente en base a inspección visual de las métricas que entrega la plataforma. En este sentido, la agencia no realiza gestiones en base a predicciones de los resultados publicitarios de sus anuncios o en base a las dinámicas subyacentes en los mismos. Por esto, se espera que los hallazgos de este trabajo promuevan mejoras en la gestión que realizan y en los resultados que entregan a sus clientes. Además, entregaría un grado de flexibilidad mayor al momento de optimizar los presupuestos de inversión con los que trabajan. Considerando lo anterior, los datos de la primera parte de esta memoria corresponden a campañas gestionadas por WUA entre los años 2018 y 2019, mientras que los de la segunda parte corresponden a campañas que la agencia creó específicamente para esta investigación. De esta manera, la validación corresponde a un experimento en el cual se compara la gestión de anuncios de tres fuentes: el algoritmo propio de Facebook, el encargado de WUA y la metodología propuesta en este trabajo. Mayores detalles son presentados en la sección *Validación*.

# Capítulo 3

## Desarrollo

### 3.1. Análisis Previo

#### 3.1.1. Extracción y Preparación de Datos

Para el primer análisis se estudian datos facilitados por la agencia WUA de campañas que gestionaron y que ya finalizaron. Los anuncios pertenecen a campañas publicitarias de un mismo cliente y de un mismo producto. A pesar de esto, no todos los anuncios se mostraron al mismo público, lo que implica que fueron vistos por personas con características demográficas distintas. La Figura 3.1 muestra una descripción de cada anuncio y una vista previa de los mismos. El objetivo publicitario de dichas campañas fue *Tráfico*, es decir, que las personas hagan clic en el anuncio y entren a la página del anunciante. Así, la métrica clave para medir el desempeño de los anuncios es la de *Clics en el enlace*, la cual se explica a continuación. Las campañas estuvieron activas entre diciembre de 2018 y julio de 2019, pero ninguna lo estuvo durante todo el periodo. Por lo anterior, algunos anuncios poseen una menor cantidad de datos que otros. Toda esta información se extrajo de la plataforma de anuncios de Facebook y no se le aplicó ningún tipo de transformación. Las variables seleccionadas para este análisis son:

- Alcance: Número de usuarios que vieron el anuncio a lo menos 1 vez.
- Impresiones: Número de veces que se mostró el anuncio en alguno de los espacios que contienen los anuncios.
- Interacciones: Comentarios y reacciones que las personas realizan en el anuncio.
- Clics en el enlace: Clics totales que las personas realizaron en el enlace del anuncio. Es una medida cercana a las visitas que se hacen a la página de destino del anuncio.
- Costo por clic (CPC): Costo promedio, para el anunciante, de cada clic realizado en el enlace del anuncio.
- Gasto: Monto total, en pesos chilenos, que la plataforma utilizó en el sistema de pujas y que podría ser menor al presupuesto diario configurado.

Se escogieron estas variables ya que representan bien el comportamiento de los anuncios en la red de Facebook y fueron las que más aportaban a explicar la varianza de los datos en análisis previos. Además, capturan información de otras posibles métricas que entrega la plataforma, como clics e interacciones únicas, frecuencia, costo por mil impresiones, entre otras. Por lo mismo, son también métricas que podrían presentar dinámicas e interacciones subyacentes entre sí, que permitan entender mejor el comportamiento de cada anuncio y sus posibles resultados futuros. El desglose de los datos es diario, que es la apertura mínima que permite la plataforma. La Tabla 3.1 muestra datos exploratorios de cada anuncio que se analiza en esta etapa. A pesar de que cada uno posee su propia configuración, en algunos casos es similar, por lo que el comportamiento de las métricas podría también serlo. La Figura 3.2 muestra un resumen visual del comportamiento de cada métrica para cada anuncio. Ya que los conjuntos de datos son extraídos directamente de la plataforma de anuncios de Facebook, no existen valores perdidos o mal registrados, por lo que no es necesario realizar ningún tipo de imputación.

En cuanto al presupuesto configurado por el anunciante, su valor es distinto a la métrica *Gasto* mencionada anteriormente. La primera corresponde al monto que el anunciante escoge para que la plataforma utilice, mientras que la segunda corresponde al monto efectivo que la plataforma utiliza, el cuál podría ser mayor o menor dependiendo de las subastas que ocurran al momento de la entrega. De esta manera, la plataforma no registra los cambios de presupuesto establecidos por el anunciante, sino que solamente los gastos realizados. Por este motivo, para simular los cambios de presupuesto establecidos por la agencia WUA se utiliza la media móvil del gasto en la plataforma. Como el tema central de la investigación es el problema de gestión de presupuesto, se hace necesario contar con una variable que describa la definición de presupuesto por parte del anunciante. De esta forma, es posible distinguir niveles de inversión que el anunciante realiza, donde el gasto efectivo sería ruido asociado a dicha inversión. La Figura 3.3 permite visualizar la transformación realizada para simular la inversión del anunciante. Con esto, se incluye una nueva variable al análisis bajo el nombre de *Inversión*.



Anuncio	Segmentación
Ad 01 General, Ad 06 Oficina y Ad 07 Manualidades	<ul style="list-style-type: none"> <li>• Edad: 18 a 50 años</li> <li>• Intereses: Pegatina, Calcomanía, Impresión digital, Office Space, Máquinas de oficina, Impresora, Small office/home office, Impresión.</li> <li>• Cargo: Kindergarten, Art Teacher o Nursery School Teacher</li> </ul>
Ad 04 Emprendedores y Ad 08 Emprendedores	<ul style="list-style-type: none"> <li>• Edad: 18 a 50 años</li> <li>• Intereses: Pequeñas empresas, Espíritu empresarial o Negocio familiar</li> <li>• Comportamientos: Pequeños empresarios</li> <li>• Empresas: Small Business owner o Independiente</li> <li>• Cargo: Independiente</li> </ul>
Ad 06 Escolar	<ul style="list-style-type: none"> <li>• Edad: 18 a 50 años</li> <li>• Cargo: Kindergarten, Preschool teacher, Docente de educación inicial, Profesora de educación primaria, educadora infantil, Kindergarten Teacher, Educador.</li> <li>• Padres: Padres con hijos en edad preescolar (3-5 años) o en la primera etapa escolar (6-8 años)</li> </ul>

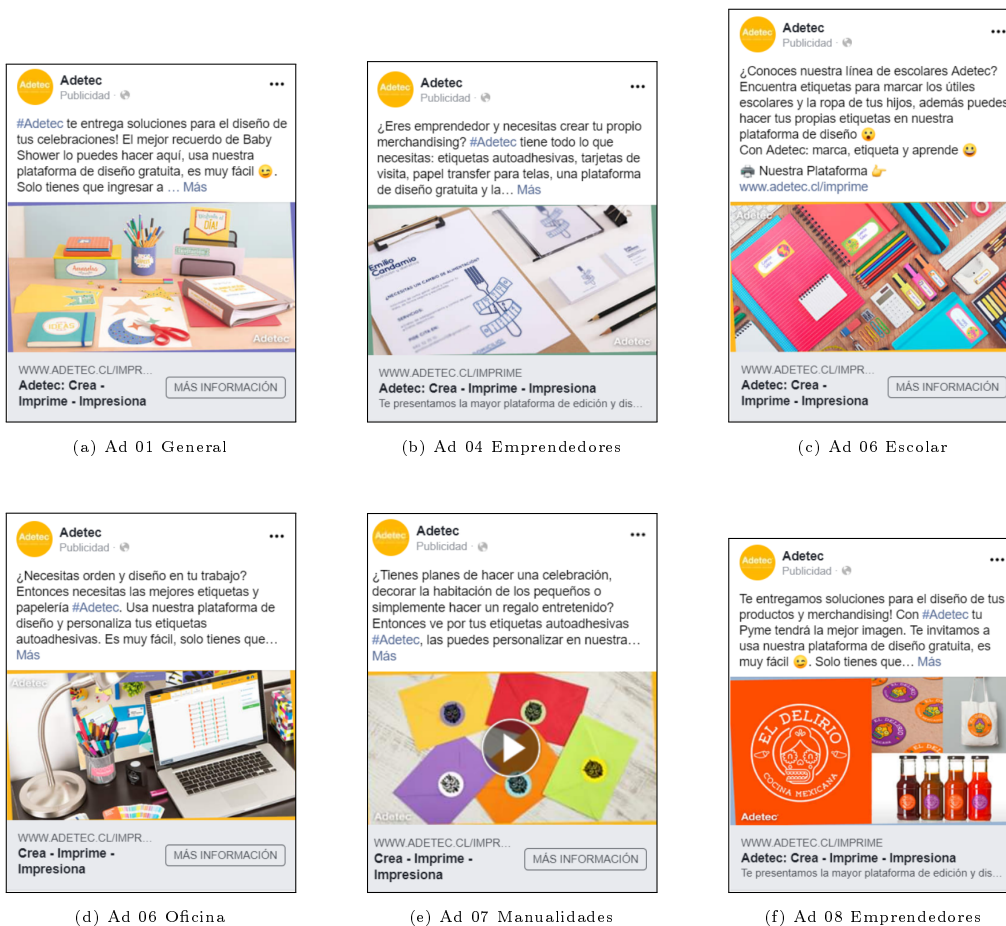


Figura 3.1: Descripción de los anuncios de la primera etapa. En la tabla se detalla la segmentación de cada anuncio y de (a) a (f) se muestra una vista previa de cada uno. Solamente el anuncio (e) posee tiene un formato de video, por lo que se espera ver un comportamiento distinto en sus resultados publicitarios.

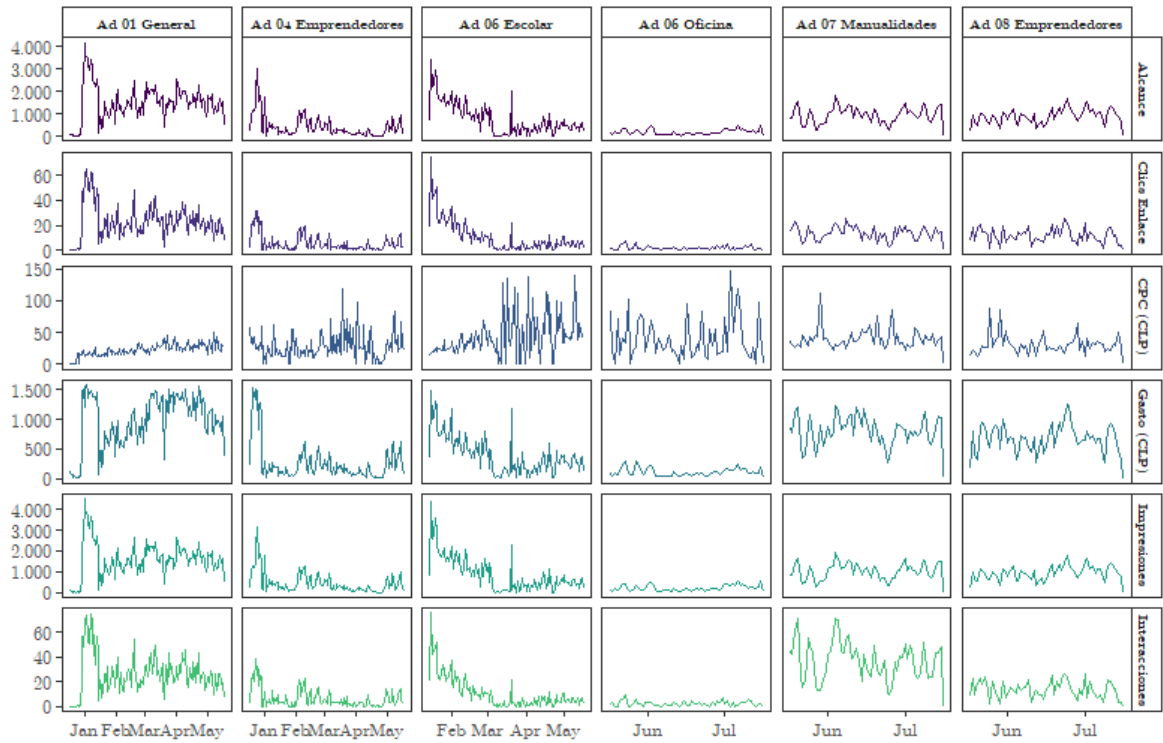


Figura 3.2: Desglose de métricas de los anuncios de la primera etapa. Se observan comportamientos distintos para cada métrica de cada anuncio, debido principalmente por la segmentación. Se aprecia que algunos anuncios logran que sus métricas se estabilicen antes que otros, por lo que se espera que sean más predecibles. Por ejemplo, *Ad 06 Escolar* llega a un nivel estable mucho más lento que *Ad 08 Emprendedores*.

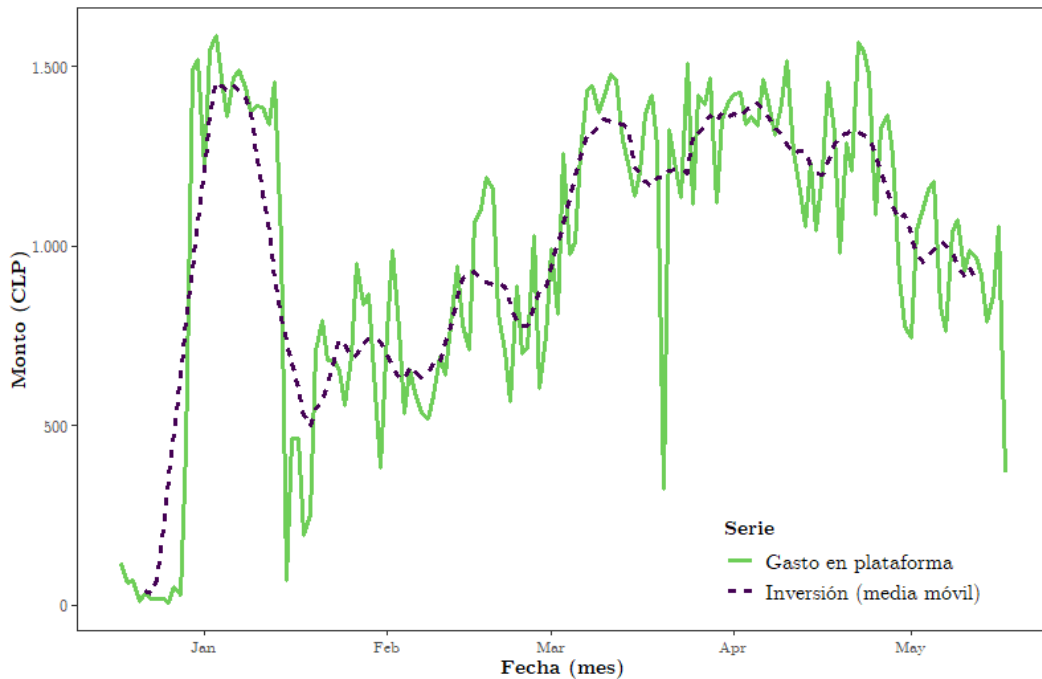


Figura 3.3: Estimación de inversión utilizando medias móviles. Al hacer esto, es posible utilizar una variable que simule el presupuesto establecido por el anunciante. De esta manera, el gasto efectivo en la plataforma se puede interpretar como ruido asociado a los niveles de inversión que define el anunciante.

Tabla 3.1: Métricas exploratorias de los anuncios de la primera etapa. Es posible entender que los resultados publicitarios no están definidos por una única variable como el dinero utilizado. El gasto del *Ad 01 General* es 1,9 veces mayor que el de *Ad 06 Escolar*, pero recibió 2,2 veces la cantidad de clics. Esto indica que la interacción entre variables es distinta por anuncio.

Ad 01 General

N = 151

Variable	Promedio	Desv	Min	Max
Alcance	1.524	758	13	4.185
Impresiones	1.604	806	13	4.502
CPC (CLP)	22,7	9,12	0	50,9
Interacciones	26,7	15,2	0	75
Clics Enlace	23,4	13,6	0	65
Gasto (CLP)	980	429	8	1.585

Ad 04 Emprendedores

N = 151

Variable	Promedio	Desv	Min	Max
Alcance	424	458	16	3.022
Impresiones	443	476	16	3.139
CPC (CLP)	26,8	19,6	0	119
Interacciones	6,27	7,52	0	39
Clics Enlace	5,46	6,65	0	32
Gasto (CLP)	261	322	7	1.532

Ad 06 Escolar

N = 124

Variable	Promedio	Desv	Min	Max
Alcance	779	687	10	3.399
Impresiones	867	810	12	4.342
CPC (CLP)	43,0	30,4	0	141
Interacciones	10,8	12,5	0	76
Clics Enlace	10,5	12,1	0	75
Gasto (CLP)	393	312	11	1.481

Ad 06 Oficina

N = 61

Variable	Promedio	Desv	Min	Max
Alcance	194	115	25	492
Impresiones	219	133	25	556
CPC (CLP)	39,8	32,3	0	147
Interacciones	2,34	2,12	0	10
Clics Enlace	1,89	1,65	0	7
Gasto (CLP)	108	69,1	49	304

Ad 07 Manualidades

N = 61

Variable	Promedio	Desv	Min	Max
Alcance	941	371	7	1.812
Impresiones	1.010	401	9	1.955
CPC (CLP)	39,8	16,0	0	112
Interacciones	36,5	15,9	0	72
Clics Enlace	13,4	5,52	0	25
Gasto (CLP)	792	255	5	1.231

Ad 08 Emprendedores

N = 61

Variable	Promedio	Desv	Min	Max
Alcance	883	333	7	1.686
Impresiones	927	352	9	1.787
CPC (CLP)	30,6	15	0	88
Interacciones	13,4	6,86	0	27
Clics Enlace	11,5	5,8	0	25
Gasto (CLP)	666	243	2	1.260

### 3.1.2. Análisis Estadístico

Según el trabajo de Dekimpe y Hansseens mencionado en el capítulo *Marco Teórico*, el análisis de los datos de los anuncios sigue los siguiente pasos: análisis de raíz unitaria, diferenciación de series y modelo VARX.

En cuanto al análisis de raíz unitaria, éste se realiza con el propósito de determinar si una serie de tiempo es estacionaria o no. La presencia de la raíz unitaria da un carácter evolutivo a la media de la serie, por lo que su predictibilidad sería menor. Para determinar la existencia de una raíz unitaria se utilizará el test Augmented Dickey-Fuller (ADF). Este test

es el mismo test de Dickey-Fuller utilizado en el trabajo de Goic, Álvarez y Montoya, pero expandido para acomodarlo a un modelo más complejo, donde además existan problemas de correlación. Esta última propiedad es la principal motivación para el uso de este test ya que las variables a trabajar presentan una alta correlación. Mientras más se muestre un anuncio (impresiones) debería aumentar el alcance del mismo y la cantidad de clics e interacciones que reciba. El Anexo A muestra las matrices de correlación de cada set de datos a trabajar y el Anexo B Los resultados del test ADF. A partir de los resultados del test, se determina que algunas series no presentan raíz unitaria, por lo que su comportamiento es estacionario. Esto evidencia que el aprendizaje realizado por la plataforma de anuncios, según lo descrito en en capítulo *Marco Teórico*, no implica mejoras aditivas en el tiempo, sino que mejoras hasta un nivel estable. Por lo mismo, es un primer indicador de que los resultados futuros de un anuncio podrían ser predecidos, en parte, a partir de su comportamiento pasado. Para los casos en que sí existe una raíz unitaria, se calcula la primera diferencia de las series. Esto quiere decir que se realizará una transformación sobre las series que presentan una raíz unitaria, la cual corresponde a  $y'_t = y_t - y_{t-1}$ , creando así una nueva serie,  $y'$ . El valor de cada periodo  $t$  corresponderá a la diferencia entre el valor en  $t$  y el valor en  $t - 1$  de la serie original. Con las series ya diferenciadas, se aplica nuevamente el test ADF, obteniendo que todas las series son ahora estacionarias. Los resultados del segundo test se muestran en la Anexo C.

Luego de esto, para entender mejor el aporte de los valores pasados en el valor actual, se utiliza la función de autocorrelación parcial (PACF) de cada serie. Esta función se muestra gráficamente en la Figura 3.4. Además, en el Anexo D se muestra la función de autocorrelación (ACF) de cada serie, la cual permite entender la relación entre los valores presentes y pasados de cada métrica. A partir de los gráficos se aprecia que la mayor autocorrelación está dada por niveles bajos de lags, de no más de 3 días. Este hecho varía entre los anuncios, pero hace sentido en cuanto al comportamiento esperado: según el aprendizaje que realiza la plataforma, es esperable que los resultados de un día alteren, en cierta magnitud, los resultados del día siguiente, ya que la plataforma ajusta los parámetros con los que define la entrega de sus anuncios. Dicho ajuste debería ser para pocos días en adelante porque puede existir variabilidad entre un día y otro. Así, tiene sentido que los resultados de un día se vean afectados por los resultados de un par de días en el pasado, lo cual se evidencia en algunos gráficos de la Figura 3.4.

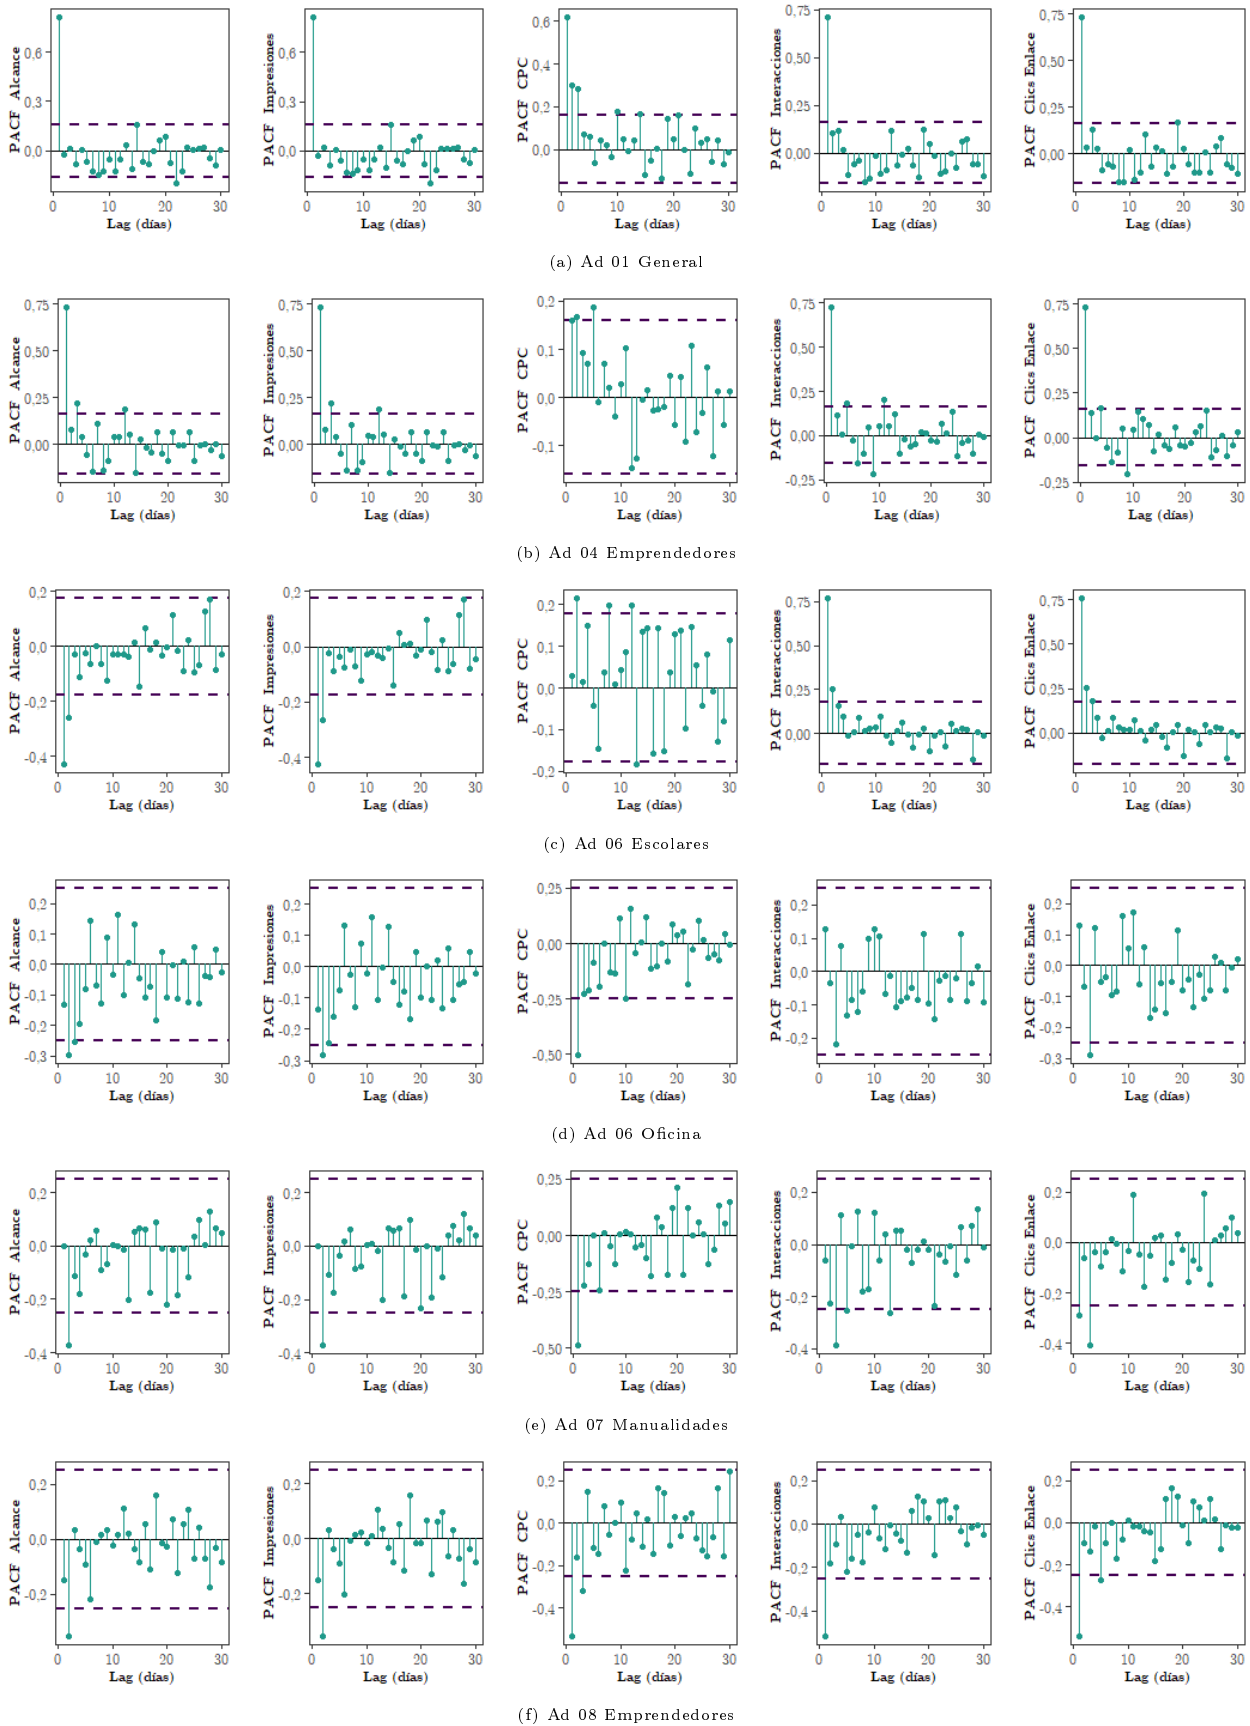


Figura 3.4: PACF para anuncios de la primera etapa. Los valores fuera de las líneas punteadas son significativos en cada visualización y representan el aporte del nivel de lag en términos auto regresivos. De esta manera, el aporte de niveles bajos de lags suele ser más significativo que niveles altos, en todos los anuncios.

### 3.1.3. Análisis de Predictibilidad

Con las series ya preparadas, el siguiente paso corresponde a realizar el modelo VARX. Este modelo y sus beneficios fueron introducidos en el capítulo *Marco Teórico*. A continuación se detallan aspectos matemáticos relacionados al mismo.

Los vectores autoregresivos (VAR, por sus siglas en inglés) se utilizan para caracterizar las relaciones simultáneas existentes en un grupo de variables. En el caso de un fenómeno descrito por más de una serie de tiempo en el que el valor de cada serie depende del valor de las otras, se puede utilizar un VAR para obtener un modelo multivariado de series de tiempo. De esta forma, sean  $y_1(t)$  e  $y_2(t)$  dos series de tiempo como las descritas anteriormente, se puede definir la siguiente relación:

$$y_1(t) = a_1 + w_{1,1} * y_1(t - 1) + w_{1,2} * y_2(t - 1) + e_1(t) \quad (3.1)$$

donde  $a_1$  corresponde al intercepto,  $w_{1,1}$  y  $w_{1,2}$  a efectos de los valores pasados de  $y_1$  e  $y_2$  sobre el valor actual de  $y_1$  y  $e_1$  corresponde a un término de error. Análogamente para  $y_2(t)$ :

$$y_2(t) = a_2 + w_{2,1} * y_1(t - 1) + w_{2,2} * y_2(t - 1) + e_2(t) \quad (3.2)$$

Si la cantidad de series aumenta a un número  $k$  cualquiera y se permite un nivel de lag  $p$ , la relación anterior puede escribirse como:

$$\begin{bmatrix} y_1(t) \\ y_2(t) \\ \cdot \\ \cdot \\ y_k(t) \end{bmatrix} = \begin{bmatrix} a_1 \\ a_2 \\ \cdot \\ \cdot \\ a_k \end{bmatrix} + \begin{bmatrix} w_{1,1} & \cdot & w_{1,k} \\ w_{2,1} & \cdot & w_{2,k} \\ \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot \\ w_{k,1} & \cdot & w_{k,k} \end{bmatrix} \begin{bmatrix} y_1(t - 1) \\ y_2(t - 1) \\ \cdot \\ \cdot \\ y_k(t - 1) \end{bmatrix} + \dots + \begin{bmatrix} w'_{1,1} & \cdot \\ w'_{2,1} & \cdot \\ \cdot & \cdot \\ \cdot & \cdot \\ w'_{k,1} & \cdot \end{bmatrix} \begin{bmatrix} y_1(t - p) \\ y_2(t - p) \\ \cdot \\ \cdot \\ y_k(t - p) \end{bmatrix} + \begin{bmatrix} e_1(t) \\ e_2(t) \\ \cdot \\ \cdot \\ e_k(t) \end{bmatrix} \quad (3.3)$$

De esta forma, se puede establecer una relación directa entre una serie y las demás, siendo esta una de las ventajas de los vectores autorregresivos. Esta característica es fundamental para la investigación, ya que, como se estableció anteriormente, los valores de una serie podrían afectar directamente a las otras. Además, la flexibilidad del VAR permite añadir variables exógenas al sistema que podrían afectar las series. Para esta investigación, se añadirá la variable *Inversión*, definida anteriormente, como exógena. Ésta se considera como tal porque su valor no es manejado por la plataforma, sino que corresponde a una decisión del anunciante. En este sentido, la cantidad de dinero que el anunciante decida invertir no depende directamente de los resultados obtenidos sino que corresponde a una decisión o regla de negocio. Además, cómo se busca optimizar esta decisión, es necesaria incluir esta variable. Así, el VAR pasa a ser un vector autorregresivo con variable exógena y permite modelar las interacciones entre las métricas claves de cada anuncio y el presupuesto del anunciante.

Con el modelo especificado, se utiliza el criterio de información de Hannan-Quinn (HQC) para determinar la cantidad de lags a utilizar. Este criterio también se utilizó en el trabajo de Goic, Álvarez y Montoya para evaluar el nivel de lag de su modelo VARX. Los resultados de dicho análisis se muestran en la Tabla 3.2. Para algunos anuncios el criterio sugiere niveles altos de lag y para otros niveles bajos. Dado el comportamiento observado también en la Figura 3.4, se opta por utilizar niveles bajos de lag. Además, por simplicidad del modelo, el

nivel de lag a utilizar para la variable exógena será 0, bajo la lógica de que no es la inversión pasada la que afecta los resultados publicitarios sino que el comportamiento endógeno de las variables.

Con las definiciones anteriores, se estima el modelo utilizando 1, 2, 3 y 4 días de lag. La Tabla 3.3 resume distintas métricas de ajuste. Una de ellas corresponde al *error absoluto promedio* (MAE, por sus siglas en inglés) e indica la magnitud del error de las predicciones. Para la mayoría de los anuncios, a medida que aumenta el nivel de lag disminuye el MAE. En el nivel 4 de lag, para algunos anuncios el MAE empeora. Considerando esto y las otras métricas de ajuste, la cantidad de lag a utilizar podría variar según el anuncio que se esté analizando. De esta manera, es posible realizar predicciones de los anuncios publicitarios, con niveles de error variable según la serie que se analice. Al observar los valores de la métrica clave *ClicsEnlace*, si bien estos errores pueden ser cercanos al 10 % en algunos casos, se debe recordar que la alternativa a la predicción es el juicio experto del anunciante, cuyos niveles de error podrían tener una mayor variabilidad, sobretodo con anuncios que nunca antes ha realizado. Este hecho se pondrá a prueba en las siguientes secciones.

Tabla 3.2: Criterios de información Hannan-Quinn para modelo VARX de la primera etapa. En la mitad de los anuncios se muestran preferencias por niveles bajos de lag y en la otra mitad por niveles altos. Dado lo observado en otras figuras, finalmente se opta por utilizar niveles bajos.

Anuncio	Lag Preferido	Valor Criterio Hannan-Quinn
Ad 01 General	1	26,2617
Ad 04 Emprendedores	1	22,8162
Ad 06 Escolar	3	27,0581
Ad 06 Oficina	9	13,5936
Ad 07 Manualidades	9	18,6936
Ad 08 Emprendedores	9	16,9289

Tabla 3.3: Métricas de ajuste para distintos niveles de lag en el VARX de la primera etapa. Los valores de MAPE fueron calculados en base a los valores predichos, para evitar valores cercanos a infinito. El error absoluto, MAE, suele mejorar a mayores niveles de lag, empeorando para el lag 4 en algunos casos. Esto indica que el modelo podría considerar distintos niveles de lag según el anuncio que se estudie.

	MAE				MAPE*				RMSE			
	$p = 1$	$p = 2$	$p = 3$	$p = 4$	$p = 1$	$p = 2$	$p = 3$	$p = 4$	$p = 1$	$p = 2$	$p = 3$	$p = 4$
Ad 01 General												
Alcance	66,68	66,15	70,42	65,55	3,74%	3,74%	3,91%	3,83%	190,96	188,02	199,63	183,27
Impresiones	70,01	69,54	74,07	68,76	3,74%	3,74%	3,90%	3,82%	16,10	15,87	16,88	15,48
CPC	2,00	1,00	1,00	1,00	6,83%	6,60%	6,46%	6,25%	0,35	0,35	0,35	0,34
Interacciones	2,00	2,00	2,00	2,00	5,69%	5,56%	5,52%	5,24%	0,40	0,39	0,39	0,36
ClicsEnlace	2,00	2,00	2,00	1,00	5,85%	5,72%	5,72%	5,39%	0,35	0,34	0,34	0,32
Ad 04 Emprendedores												
Alcance	41,68	41,91	41,48	41,60	11,61%	11,55%	11,27%	10,90%	108,94	110,28	112,90	115,96
Impresiones	43,76	44,01	43,62	43,75	11,65%	11,60%	11,34%	11,00%	9,19	9,30	9,52	9,77
CPC	3,00	3,00	3,00	3,00	11,84%	11,93%	12,26%	12,20%	0,76	0,77	0,79	0,79
Interacciones	1,00	1,00	1,00	1,00	13,03%	13,08%	12,64%	12,79%	0,15	0,15	0,16	0,16
ClicsEnlace	1,00	1,00	1,00	1,00	12,50%	12,45%	12,68%	13,83%	0,13	0,13	0,13	0,13
Ad 06 Escolar												
Alcance	36,24	35,75	34,37	37,17	266,42%	384,44%	2.390,53%	947,84%	106,00	105,07	103,38	106,54
Impresiones	39,99	39,07	37,57	41,19	213,92%	305,88%	2.083,06%	1.007,89%	10,63	10,47	10,37	10,71
CPC	3,53	3,68	3,57	3,49	7,77%	8,26%	7,91%	7,85%	1,19	1,21	1,15	1,15
Interacciones	0,54	0,52	0,51	0,50	8,26%	8,25%	8,13%	7,76%	0,13	0,12	0,12	0,12
ClicsEnlace	0,52	0,50	0,49	0,49	8,25%	8,22%	8,15%	7,67%	0,12	0,12	0,12	0,12
Ad 06 Oficina												
Alcance	26,02	23,98	27,39	33,81	808,32%	567,87%	79,31%	50,27%	78,04	78,52	83,74	99,33
Impresiones	29,09	27,26	30,89	44,22	577,26%	791,23%	79,24%	26,24%	10,83	10,97	11,80	16,84
CPC	6,59	6,36	9,24	16,58	1.033,22%	487,75%	56,32%	75,62%	2,35	2,23	3,28	5,63
Interacciones	0,32	0,35	0,43	0,61	11,90%	13,28%	16,09%	131,96%	0,11	0,11	0,14	0,19
ClicsEnlace	0,25	0,28	0,35	0,49	11,82%	13,07%	23,22%	31,01%	0,09	0,09	0,12	0,16
Ad 07 Manualidades												
Alcance	61,40	61,81	58,49	67,74	2.115,88%	656,63%	241,47%	248,37%	211,83	210,98	202,16	221,45
Impresiones	66,03	66,49	61,21	73,70	1.440,42%	1.124,64%	3.957,64%	280,63%	28,11	27,98	26,64	29,40
CPC	2,51	2,55	2,88	3,12	8.910,77%	1.833,54%	49,82%	71,94%	0,93	0,93	1,03	1,18
Interacciones	2,41	2,40	2,81	2,85	3.469,09%	2.458,06%	91,47%	1.005,40%	0,98	0,98	1,01	1,05
ClicsEnlace	0,96	0,97	1,13	1,24	2.794,29%	1.761,42%	174,16%	1.234,52%	0,33	0,33	0,38	0,39
Ad 08 Emprendedores												
Alcance	51,58	71,69	66,57	112,59	443,11%	291,00%	99,69%	18,26%	151,75	199,40	178,28	306,26
Impresiones	54,98	76,90	71,50	122,44	464,23%	96,34%	313,23%	18,39%	19,97	26,56	23,98	41,30
CPC	2,50	4,38	1,85	4,50	286,89%	207,50%	1.109,79%	100,25%	0,84	1,41	0,70	1,39
Interacciones	1,04	1,21	1,20	1,84	177,24%	46,21%	99,97%	24,13%	0,35	0,44	0,41	0,65
ClicsEnlace	0,89	1,01	1,11	1,56	252,66%	129,39%	219,46%	23,44%	0,30	0,35	0,36	0,52

\*Calculado en base a valores predichos

De esta forma, el modelo VARX a utilizar se describe con la siguiente ecuación:

$$\begin{pmatrix} Alcance_{s,t} \\ Impresiones_{s,t} \\ CPC_{s,t} \\ Interacciones_{s,t} \\ ClicsEnlace_{s,t} \end{pmatrix} = a_{s,0} + \sum_i^3 w_{s,t} \begin{pmatrix} Alcance_{s,t-i} \\ Impresiones_{s,t-i} \\ CPC_{s,t-i} \\ Interacciones_{s,t-i} \\ ClicsEnlace_{s,t-i} \end{pmatrix} + \beta_s Inversion_{s,t} + e_{s,t} \quad (3.4)$$

donde  $s$  representa un anuncio y  $t$  los periodos. Siguiendo la nomenclatura de la ecuación 3.1,  $a_{s,0}$  representa los interceptos de cada anuncio y  $w_{s,t}$  corresponde a la matriz de coeficientes



que acompaña los valores pasados de cada serie de tiempo. Además, dado que se añade una variable exógena,  $\beta_s$  corresponde al coeficiente de dicha variable para cada anuncio  $s$ . Por último,  $e_{s,t}$  corresponde al término de error.

### 3.1.4. Análisis de Dinámicas Subyacentes

Dada las distintas relaciones que se dan entre las variables de un modelo VARX, los parámetros a estimar suelen ser demasiados como para entregar una interpretación clara de los mismos. Por este motivo, suelen utilizarse las *función de respuesta a impulsos* para entender las distintas dinámicas subyacentes entre las variables del modelo. Estas IRF, por sus siglas en inglés, se estudian en los trabajos asociados a modelos VARX mencionados en el capítulo *Marco Teórico* y permiten interpretar efectos de corto y largo de un *shock* en las variables.

Para las campañas estudiadas, se observan efectos principalmente de corto plazo que no se sostienen más allá de una semana. Esto quiere decir que cualquier incremento repentino de una variable no provoca una alteración sostenible en los valores de las demás. Un caso particular es el anuncio *Ad 07 Manualidades*, que al evaluar el efecto de un shock de impresiones sobre la cantidad de interacciones recibidas, la variación es positiva y mucho mayor a la de los demás anuncios. Estas dinámicas se observan en la Figura 3.5. El anuncio *Ad 07 Manualidades* es el único en formato de video, lo que podría ser la razón de lo observado. Dicha conclusión queda fuera del alcance de esta investigación ya que requiere un análisis más detallado sobre la componente visual de los anuncios. Sin embargo, este comportamiento podría utilizarse para tomar decisiones y optimizar la entrega de los anuncios: si el objetivo de la campaña es conseguir más clics en el enlace al sitio web, potenciar las impresiones de *Ad 07 Manualidades* no será lo óptimo ya que otros anuncios responden con mayores incrementos de clics. Por otro lado, si el objetivo es conseguir más interacciones, potenciar este anuncio de video sería una buena decisión.

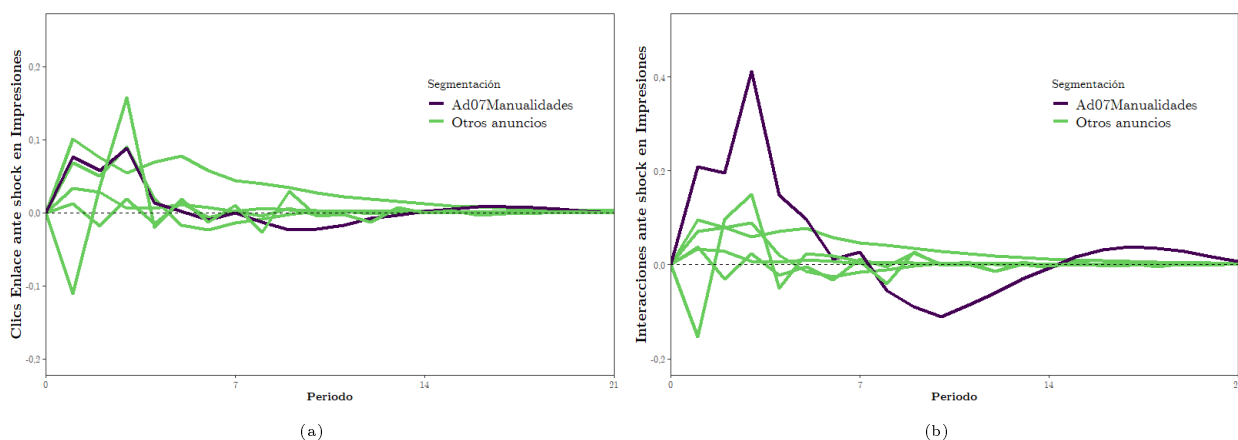


Figura 3.5: Funciones de respuesta a impulsos para anuncio de video. En ambas figuras se aprecia un crecimiento de corto plazo en la métrica estimulada por el shock, pero en el caso de (b) es mucho mayor que en otros anuncios. Este hecho podría deberse a una componente visual del anuncio, ya que éste corresponde a un anuncio con video.

Al separar las funciones de respuesta según la segmentación de los anuncios, no se detectan patrones definidos. Igual que en la observación anterior, es posible que existan otros factores, más allá de la configuración en la plataforma, que afecten las respuestas ante shocks. Estos factores podrían ser propios de la parte visual de un anuncio, como su mensaje, colores, tamaño, entre otras cosas, o incluso variables contextuales, como el periodo del año y contingencias nacionales. En la Figura 3.6 se observan funciones de respuesta agrupadas por segmentación.

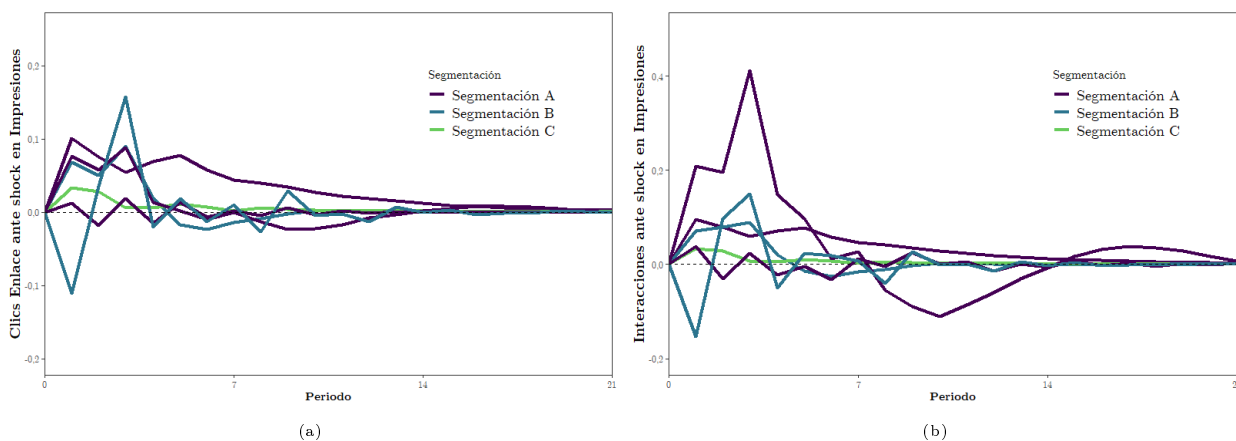


Figura 3.6: Funciones de respuesta a impulsos agrupadas por segmentación. No se observa una diferencia importante entre segmentaciones, lo que hace creer que las dinámicas subyacentes entre variables no dependerán del tipo de público al cuál se muestra el anuncio.

Recordando que los anuncios en Facebook podrían mostrarse, editarse y potenciarse a todas horas del día, hace sentido revisar la transformación ortogonal de las funciones de respuesta, que permite observar variaciones contemporáneas a un shock (en  $t = 0$ ). Al realizar esto, los hallazgos más interesantes aparecen en los gráficos de la Figura 3.7. Por un lado, tenemos que un shock en la cantidad de interacciones de un anuncio aumenta la cantidad de impresiones en el mismo periodo. Esto hace sentido con la premisa de Facebook de mostrar contenido relevante para sus usuarios. Mientras más personas interactúen con un anuncio, Facebook mostrará más veces el mismo, ya que el contenido genera reacciones. Así mismo, el shock de interacciones provoca un aumento contemporáneo en la cantidad de clics, lo que podría ser un efecto apalancado por el aumento de impresiones. De todos modos, para un único anuncio se genera una variación negativa en la cantidad de clics, por lo que lo anterior no se asumirá como un efecto global.

Con los análisis anteriores, se trabajará el resto de la investigación considerando los siguientes hallazgos:

- a Las respuestas ante shocks no dependen necesariamente de la configuración en plataforma de cada anuncio.
- b Los shocks en una variable no generan efectos sostenibles en el largo plazo sobre las otras.
- c Los efectos de un shock positivo en alguna variable no necesariamente son beneficiosos para el objetivo de campaña.




Figura 3.7: Transformación ortogonal de las funciones de respuesta a impulsos. Esta transformación permite observar cambios contemporáneos a un shock, y en este caso un shock de interacciones provoca un efecto inmediato en la cantidad de impresiones recibidas por el anuncio. Esto tiene relación con el funcionamiento orgánico de Facebook.

## 3.2. Metodología de Optimización Propuesta

Dado que la presente investigación se enmarca en el problema de gestión de presupuesto publicitario, es mandatorio dirigir los análisis realizados hacia el mismo. En este sentido, el modelo VARX descrito anteriormente tiene el objetivo de guiar una solución a dicho problema. Para esto, se utiliza la capacidad predictiva del modelo para entender el comportamiento futuro de los anuncios y en base a ello definir la inversión a realizar. De esta forma, entendiendo cómo cambian los resultados publicitarios según el nivel de inversión definida, se podría determinar la cantidad óptima a invertir para lograr los mayores resultados a un menor costo. Si, a su vez, se considera dicho ejercicio para una serie de anuncios, es posible definir la distribución óptima de presupuesto entre los anuncios. Así, es posible elaborar distintas heurísticas para determinar el monto a invertir en la plataforma de anuncios:

- Modelo de optimización lineal: es posible definir un modelo de optimización entera utilizando restricciones y una función objetivo específica según las necesidades del anunciante. Además, es posible tomar en consideración todos los anuncios publicados si se utilizan las restricciones adecuadas. Por ejemplo, se podría buscar maximizar la cantidad total de clics recibidos a través de cambios limitados en el presupuesto de distintos anuncios. De esta forma, el modelo de optimización utilizaría las predicciones del modelo VARX para simular resultados publicitarios a partir de distintos montos de inversión para cada anuncio. En este mismo sentido, es importante utilizar restricciones apropiadas, ya que el modelo podría presentar una solución en la cual siempre sugiere incrementar la inversión en la plataforma.
- Algoritmos avaros: en el caso de optimizar presupuesto para un único anuncio, definiendo cambios de presupuesto en un periodo dado es posible predecir los resultados publicitarios para dicho periodo. De esta forma, por ejemplo, se podrían simular los resultados para una semana en la que el presupuesto se aumenta dos días específicos y se disminuye otros dos. Así, existirían 393 combinaciones posibles de incrementos y disminuciones de inversión, por lo que bastaría con escoger una de las combinaciones que maximice un resultado específico.

- Juicio experto: las predicciones del VARX pueden utilizarse para entender comportamientos de incremento o disminución en los resultados publicitarios. Dicho comportamiento podría utilizarlo la persona que esté gestionando los anuncios para realizar los cambios que crea pertinente. Si bien esto podría no optimizar la inversión utilizada, apoyaría en el uso eficiente de la misma.

Bajo la premisa anterior, se tiene una estructura de gestión que consta de dos acciones principales: predecir resultados publicitarios y distribuir presupuesto utilizando dichos resultados. Según lo analizado en la sección *Análisis Previo*, los resultados publicitarios en Facebook son predecibles, pero para cada anuncio presentan un comportamiento particular. Por lo mismo, la propuesta de solución al problema de gestión de presupuesto publicitario en Facebook es utilizar una metodología que posea un carácter retroactivo. Esto quiere decir, que cuente con una etapa de retroalimentación en la cual deban ajustarse los parámetros de predicción a utilizar. De esta forma, la metodología no se entiende como una acción específica a realizar durante la gestión de anuncios, sino que como una serie de análisis y cambios a realizar durante la duración completa de la campaña. Por el lado de la agregación temporal de datos, se podría utilizar cualquier tipo (diaria, semanal, mensual, anual), pero se espera que se utilice una agregación diaria dada la flexibilidad que esto aporta a quien gestiona los anuncios. Para estructurar y entender mejor la idea, se propone dividir la metodología en 5 etapas:

1. *Extracción y Preparación de Datos*: Se extraen datos de la plataforma de anuncios de Facebook y se transforman según las necesidades de los modelos. Estas necesidades dependen de las métricas que se requieran utilizar, los periodos de tiempo a analizar y los tipos de anuncio a gestionar. Además, es recomendable que se establezca un objetivo claro a optimizar antes de comenzar a aplicar la metodología, el cual dependerá directamente de los objetivos de los anuncios.
2. *Análisis Estadístico*: El hecho de que los anuncios se muestren en una misma plataforma, o incluso que pertenezcan al mismo anunciante, no implica que posean las mismas propiedades estadísticas o que presenten resultados similares en el futuro. Además, dependiendo del grado de complejidad de los modelos a utilizar se deben aplicar distintas pruebas estadísticas para evitar errores de ajustes o mejorar la capacidad predictiva de los mismos.
3. *Ajuste de Modelo*: En esta etapa se debe ajustar un modelo que prediga los resultados publicitarios a futuro. El modelo a escoger puede variar, pasando por modelos autorregresivos o de aprendizaje de máquinas, pero la decisión de cuál se debe utilizar dependerá de factores tales como cantidad de datos, capacidad de procesamiento y capacidad de aplicación (es decir, quién gestione los anuncios debe ser capaz de entender y modificar el modelo en caso de ser necesario).
4. *Predicciones e IRFs*: En esta etapa deben realizarse las predicciones a futuro de los resultados publicitarios, para un intervalo de tiempo determinado. Dichas predicciones deben hacerse en función de cambios de presupuesto, ya sean porcentuales o absolutos, con lo cual se alimentará un modelo de optimización en la etapa siguiente. Además, en esta etapa se puede realizar el análisis de las IRFs generadas a partir del modelo VARX para apoyar las decisiones de optimización.

5. *Optimización de Presupuesto*: Las predicciones realizadas en la etapa anterior establecerán posibles configuraciones de presupuesto que harán variar los resultados publicitarios de los anuncios. Así, se debe utilizar un modelo de optimización que permita encontrar la configuración presupuestaria de anuncios que entregue los mejores resultados posibles. Junto a esto, dependiendo del caso, se deben considerar restricciones adicionales. Por ejemplo, puede darse el caso en que se requiera limitar el presupuesto utilizado o la cantidad de cambios realizados. Además, la función objetivo de este modelo podría ser modificada si así se amerita, como podría ser en el caso de obtener una cantidad determinada de resultados minimizando el presupuesto. El resultado del modelo de optimización deberá entregar indicaciones a seguir para lograr los objetivos propuestos.
6. *Gestión de Resultados*: El resultado del modelo de optimización de la etapa anterior debe ser configurado en la plataforma de anuncios de Facebook para obtener los resultados esperados.
7. *Retroalimentación*: Luego de un periodo a definir, los nuevos resultados publicitarios de cada anuncio se utilizan para volver a ajustar el modelo de la etapa de predicciones. De esta manera, se refina dicho modelo y se mejoran las predicciones realizadas. Con las nuevas predicciones se encuentra una nueva configuración óptima en el modelo de optimización, con lo que a su vez se obtienen nuevos resultados. Este ciclo puede repetirse cuantas veces se requiera y es recomendable realizarlo de manera periódica, ya que así es posible capturar variaciones en los resultados publicitarios que se deban a variables externas a la plataforma de anuncios de Facebook, como por ejemplo días festivos.

La estructura general del modelo puede observarse en la Figura 3.8:

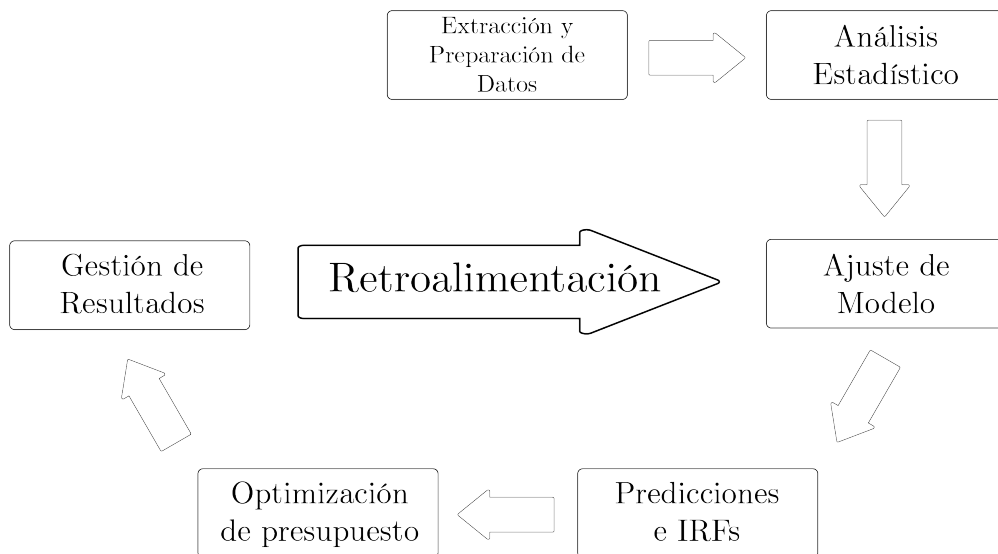


Figura 3.8: Diagrama de la metodología de gestión propuesta. La idea central es ajustar constantemente un modelo de predicción, a partir de los resultados publicitarios que se obtienen.

La metodología presenta los siguientes beneficios a la hora de gestionar anuncios en Facebook:

1. Permite trabajar cada anuncio de manera individual y a la vez entrega direcciones sobre campañas distintas. La plataforma de anuncios de Facebook actualmente cuenta con una opción para optimizar el presupuesto a nivel de campaña conocida como *Campaign Budget Optimization*. La opción permite que la plataforma distribuya automáticamente el presupuesto de una campaña, entre sus anuncios, para optimizar una estrategia de puja. Está limitada a optimizar presupuestos de campañas individuales, siempre en función de la estrategia de puja definida, pero la metodología propuesta en este trabajo permite optimizar presupuestos que se distribuyen entre distintas campañas, logrando una flexibilidad mayor. Además, no solo se podría optimizar en función de estrategias escogidas sino que en función de otro tipo de configuraciones como segmentaciones, presupuestos u horarios.
2. Los modelos matemáticos de predicción y optimización son independientes entre sí, lo que implica que un cambio o mejora en uno no afectará directamente la definición del otro. En este sentido, el modelo predictivo puede someterse a constantes mejoras sin que esto modifique el modelo de optimización. A su vez, el modelo de optimización puede adaptarse a las distintas necesidades de gestión, pero eso no implicaría necesariamente un cambio en las predicciones.
3. Considera una retroalimentación constante, lo que permite refinar tanto las predicciones como los resultados de la optimización. Además, los resultados publicitarios no dependen solamente de la configuración escogida en la plataforma de anuncios sino que de factores externos a los anuncios en sí, tales como estacionalidades, mayor presencia de competidores, entre otros, y esta información podría ser capturada a través de la retroalimentación.

A su vez, la metodología presenta las siguientes limitantes:

1. Requiere cierto nivel de desglose de datos para poder alimentar los modelos matemáticos. En el caso que Facebook decida restringir el acceso a los resultados publicitarios, los modelos podrían entregar predicciones con alto nivel de error o incluso podría no ser posible predecir.
2. Podría requerir un tiempo de configuración mayor que el que le tomaría a un profesional montar una campaña según su conocimiento. En este sentido, la metodología podría no ser una alternativa cuando se necesiten realizar campañas de carácter urgente.

## 3.3. Validación

### 3.3.1. Experimento Propuesto

Para validar la metodología propuesta en la sección anterior se lleva a cabo un experimento consistente en comparar la gestión de anuncios realizada por WUA, la metodología planteada en esta memoria y el algoritmo propio de la plataforma de anuncios de Facebook. En adelante se mencionarán como *gestores* a cada una de las entidades antes mencionadas. Para armar el experimento, se configura una campaña de anuncios y se replica tres veces. De esta forma, cada gestor maneja la misma configuración en la plataforma, la cual incluye

la segmentación de cada anuncio, los tipos de puja y el presupuesto diario destinado. Los anuncios pertenecen al mismo cliente de la etapa anterior, por lo que son similares a los ya analizados. Una descripción detallada de cada uno y una vista previa se muestra en la Figura 3.9. Este experimento se planificó para durar cuatro semanas, con el objetivo de realizar la metodología de optimización propuesta al final de cada una. Finalmente, debido al estallido social ocurrido en Chile en el mes de octubre de 2019, el experimento se pausó y fue retomado días más tarde<sup>1</sup>. Los detalles y efectos de esta pausa se describen más adelante. Al término del experimento, se toma como métrica clave los clics en el enlace que los anuncios recibieron, ya que las campañas se configuraron con ese objetivo. Se analizan también métricas asociadas a los clics como el CPC. Un esquema resumen de la configuración del experimento se muestra en la Figura 3.10.

Anuncio	Segmentación
Ad 01 General y Ad 02 General	<ul style="list-style-type: none"> <li>• Edad: 18 a 50 años</li> <li>• Intereses: Pegatina, Calcomanía, Impresión digital, Office Space, Máquinas de oficina, Impresora, Small office/home office, Impresión o Impresora de inyección</li> <li>• Cargo: Kindergarten, Art Teacher o Nursery School Teacher</li> </ul>
Ad 01 Sellos	<ul style="list-style-type: none"> <li>• Edad: 18 a 50 años</li> <li>• Intereses: Pequeñas empresas, Espíritu empresarial o Negocio familiar</li> <li>• Comportamientos: Pequeños empresarios</li> <li>• Empresas: Small Business owner o Independiente</li> <li>• Cargo: Independiente</li> </ul>



(a) Ad 01 General



(b) Ad 02 General



(c) Ad 01 Sellos

Figura 3.9: Descripción de anuncios del experimento. Se tienen 2 anuncios con videos, por lo que se esperan ver comportamientos especiales para estos.

<sup>1</sup>Puede verse una breve cronología del hecho la página web <https://www.dw.com/es/la-cronología-del-estallido-social-de-chile/a-51407726>

Respecto a la forma en que cada gestor maneja los anuncios, se tiene lo siguiente:

- Gestor WUA: realiza los cambios que crea pertinente, en base a su experiencia y conocimiento. En este sentido puede pausar anuncios o agregar nuevos, cambiar modelos de puja y presupuestos diarios, entre otros posibles cambios.
- Gestor Memorista: al final de las semanas 1, 2 y 3 aplica la metodología de optimización descrita en la sección *Metodología de Optimización Propuesta*. Esto quiere decir que, al final de dichas semanas, se ajusta el modelo VARX, se predicen resultados y se determina el presupuesto a utilizar durante la semana siguiente. Los cambios de presupuesto que realizará corresponden a aumentos o disminuciones del 10 % de la inversión diaria. Esta elección se realiza en base a ilustrar una situación conservadora en la cual la agencia no tenga permitido realizar cambios demasiado grandes en el presupuesto publicitario. Este gestor no realiza cambios a nivel de segmentación o puja ni tampoco pausa o agrega anuncios.
- Gestor Facebook: no realiza ningún tipo de cambio a nivel de plataforma de anuncios. Básicamente, este gestor corresponde a dejar que la plataforma de anuncios realice la optimización que declara en sus guías de uso. Puede considerarse como una estrategia de inversión en la cual no se realiza ningún tipo de cambio ni optimización durante la duración de las campañas.

Gestor	Campaña	Grupo de Anuncios	Presupuesto	Anuncio
Facebook	Tráfico	Grupo A	\$1400	Ad 01 General Ad 02 General
		Grupo B	\$700	Ad 01 Sellos
WUA	Tráfico	Grupo A	\$1400	Ad 01 General Ad 02 General
		Grupo B	\$700	Ad 01 Sellos
Memoria	Tráfico	Grupo A	\$700	Ad 01 General
		Grupo B	\$700	Ad 02 General
		Grupo C	\$700	Ad 01 Sellos

Figura 3.10: Configuración del experimento en la plataforma de anuncios de Facebook. En el experimento se compara los resultados de tres gestiones de anuncios, una realizada por la plataforma por defecto, una realizada por la agencia WUA y una realizada según la metodología. Cada una debe gestionar tres anuncios, los cuales se pueden mostrar a un público A o a un público B, definido por el grupo de anuncios. Cada gestión utiliza la misma cantidad de presupuesto.



### 3.3.2. Desarrollo y Resultados

Durante la primera semana del experimento, en la Gestión Memorista se realizaron cambios de inversión diarios para lograr establecer una relación entre la variable exógena y las variables endógenas del modelo VARX. De no realizar estos cambios, la variable exógena correspondería a un vector constante, pero la idea es que su valor cambie en el tiempo y que esos cambios afecten a las variables endógenas. Los días específicos que se aumentó o disminuyó la inversión se escogieron de manera aleatoria. Dichos cambios se muestran en el Anexo E.

Dada la baja cantidad de datos que se generan en una semana, no es posible realizar los test estadísticos de manera regular, por lo que no se analizará la raíz unitaria de las series. Además, hace sentido asumir que no existe una raíz unitaria en los datos dado que las series son cortas. De todos modos, los resultados del test Dickey-Fuller aplicado a los datos se encuentran en el Anexo F. Junto a lo anterior, la baja cantidad de datos no permiten estimar todos los coeficientes del modelo planteado en la Ecuación 3.4, por lo que se utilizan solamente cuatro variables en el modelo VARX: Impresiones, Clics en el Enlace, CPC e Interacciones. Respecto al nivel de lag, se utiliza un único periodo. Los coeficientes estimados del modelo VARX para la semana 2 se muestran en el Anexo G. Con las predicciones realizadas a partir del modelo, se determinan los cambios de inversión diaria a realizar durante la semana 2. Para esto, se utiliza un algoritmo de maximización simple que considera todos los posibles escenarios de inversión. Dicho algoritmo se utiliza en cada anuncio por separado. De esta manera, se busca el escenario que presente la mayor cantidad de clics totales a recibir durante la semana 2. No se utiliza un modelo de programación lineal, ya que no se definieron restricciones en la gestión. Ejemplo de lo anterior, podría ser el caso en que las campañas comparten un mismo presupuesto o que en días específicos se deba maximizar la inversión. Con esto, los cambios de inversión determinados para la semana 2 se muestran en la Tabla 3.4.

Tabla 3.4: Inversión propuesta para la semana 2 del experimento. *Ad 01 General* y *Ad 02 General* seguirán la misma dinámica de inversión, según el modelo. Esto puede deberse a que comparten la segmentación de público.

	$t = 8$	$t = 9$	$t = 10$	$t = 11$	$t = 12$	$t = 13$	$t = 14$
Ad 01 General	-10 %	-10 %	-10 %	0 %	+10 %	+10 %	+10 %
Ad 01 Sellos	-10 %	-10 %	+10 %	-10 %	+10 %	+10 %	0 %
Ad 02 General	-10 %	-10 %	-10 %	0 %	+10 %	+10 %	+10 %

Antes de terminar la semana 2 del experimento, la contingencia social en Chile provocó que la agencia WUA pausara todas sus campañas de anuncios. Esta decisión se tomó en base al uso inusual de redes sociales por parte de los públicos objetivos durante el periodo, lo que pudo causar comportamientos anómalos en la entrega de los anuncios. Así, el experimento se mantuvo en receso durante aproximadamente 10 días. Además, en estos días el gestor de WUA realizó un recambio de anuncios en una de esas campañas. El bajo desempeño que los anuncios habían obtenido gatilló una alerta en el gestor, por lo que éste procedió a pausar

sus anuncios del grupo de segmentación general y a agregar dos anuncios nuevos, los cuales se muestran en el Anexo H. El mismo gestor también pauso el anuncio con segmentación de emprendedores, bajo la misma lógica anterior. Este anuncio no se mostró más durante el resto del experimento. Cuando la agencia retomó la inversión publicitaria, los resultados publicitarios se dispararon en todas las campañas. A pesar de esto, el experimento se retomó donde se había pausado, por lo que al completar la segunda semana de experimento se realizó un nuevo ajuste del modelo VARX. Se utilizan las 4 métricas de la semana 1, pero en esta ocasión se utilizan dos niveles de lag. El ajuste del modelo se muestra en el Anexo G. Los análisis de raíz unitaria se encuentran en el Anexo F. Con lo anterior, los cambios de inversión determinados para la semana 3 se muestran en la Tabla 3.5.

Tabla 3.5: Inversión propuesta para la semana 3 del experimento. Al igual que en la semana 2, *Ad 01 General* y *Ad 02 General* comparten el mismo patrón de inversión.

	$t = 15$	$t = 16$	$t = 17$	$t = 18$	$t = 19$	$t = 20$	$t = 21$
Ad 01 General	+10 %	+10 %	+10 %	0 %	-10 %	-10 %	-10 %
Ad 01 Sellos	+10 %	0 %	+10 %	+10 %	-10 %	-10 %	-10 %
Ad 02 General	+10 %	+10 %	+10 %	0 %	-10 %	-10 %	-10 %

Al término de la semana 3, se realizó nuevamente el ajuste del modelo VARX y se determinó los cambios de inversión para la semana 4. Los análisis de raíz unitaria se muestran en el Anexo F. Para las predicciones de la semana 4, se utilizaron las cuatro variables de las semanas anteriores y 3 niveles de lag. Con esto, los ajustes de modelo se muestran en el Anexo G y los cambios de inversión diaria se muestran en la Tabla 3.6.

Tabla 3.6: Inversión propuesta para la semana 4 del experimento. Se repite el patrón de inversión en los anuncios de segmentación general.

	$t = 22$	$t = 23$	$t = 24$	$t = 25$	$t = 26$	$t = 27$	$t = 28$
Ad 01 General	-10 %	-10 %	-10 %	0 %	+10 %	+10 %	+10 %
Ad 01 Sellos	+10 %	+10 %	+10 %	-10 %	0 %	-10 %	-10 %
Ad 02 General	-10 %	-10 %	-10 %	0 %	+10 %	+10 %	+10 %

### 3.3.3. Discusión

Concluida la semana 4, el experimento se da por terminado y se procede a comparar los resultados obtenidos con cada gestión. La Tabla 3.7 muestra un resumen del acumulado de métricas que cada gestor obtuvo. En cuanto a resultados netos, Facebook obtuvo la mayor cantidad de clics, pero se debe considerar el presupuesto utilizado por dicho gestor, cantidad

que fue la mayor de todas. Invirtiendo 5,13% menos, Gestión Memorista obtuvo 7,08% menos clics que Gestión Facebook. Del mismo modo, invirtiendo 24,60% menos, Gestión WUA obtuvo solamente 17,26% menos clics. De esta forma, Gestión WUA vendría a ser más rentable, lo que se puede apreciar también en el CPC promedio obtenido. En cuanto a la tasa de clics sobre impresiones (CTR), la diferencia se explica por los anuncios de recambio que utilizó Gestión WUA. Ya que Gestión Facebook y Gestión Memorista utilizaron los mismos anuncios durante todo el experimento, era esperable un CTR similar. En cuanto a la inversión neta, Gestión Memorista fue la que más se acercó a utilizar el presupuesto total destinado de \$58.800. Esto puede explicarse porque en los momentos en que Gestión Facebook se sobrepasaba del gasto diario, Gestión Memorista podía sobrepasarlo sin comprometer el presupuesto total. En este sentido, las disminuciones diarias amortiguaban las subidas. El Anexo I muestra la evolución del gasto de las gestiones de Facebook y Memorista. La diferencia en los valores de algunas métricas pueden explicarse porque WUA no utilizó los mismos anuncios durante todo el periodo. Aún así, un análisis interesante es extrapolar los resultados según las métricas obtenidas por Gestión Facebook. Recordando que en Gestión Facebook los anuncios no sufrieron ningún tipo de intervención, si se suman los resultados que dicha gestión obtuvo en el anuncio que Gestión WUA pausó, se podría simular cuáles hubiesen sido los resultados si el anuncio no se hubiese pausado. Al hacer esto, se obtienen los resultados de la Tabla 3.8, que muestran que los resultados de Gestión WUA son similares a los de Gestión Memorista.

Tabla 3.7: Resultados acumulados del experimento. Dado el objetivo de los anuncios, la métrica clave a analizar es la cantidad de clics. Junto a esto, CPC indica el costo de cada clic para el anunciante. Considerando la relación entre la cantidad de clics y lo invertido, Gestión Profesional sería la mejor.

Gestión	Clics	Alcance	Impresiones	CTR	CPC (CLP)	Inversión (CLP)
Facebook	1.582	181.023	273.987	0,58 %	39	61.606
Memorista	1.470	169.788	259.764	0,57 %	40	58.444
Profesional	1.309	186.073	281.412	0,47 %	35	46.448

Tabla 3.8: Resultados acumulados ajustados del experimento. Dado que las últimas semanas Gestión Profesional no mostró un anuncio, se podría aproximar los resultados de dicho anuncio utilizando los datos de Gestión Facebook. Con esto, los resultados de Gestión Memorista y Gestión Profesional son similares.

Gestión	Clics	Alcance	Impresiones	CTR	CPC (CLP)	Inversión (CLP)
Facebook	1.582	181.023	273.987	0,58 %	39	61.606
Memorista	1.470	169.788	259.764	0,57 %	40	58.444
Profesional	1.476	215.544	325.094	0,45 %	40	58.451

Al analizar los datos de manera parcializada por anuncios y por periodos, se observan comportamientos distintos a los observados en las tablas anteriores. La Figura 3.11 muestra la

evolución de clics totales en el tiempo para los anuncios con segmentación general. La semana 1 no tiene sentido compararla, ya que no se realizó ningún tipo de cambio según la metodología propuesta. La semana 2 está interrumpida por el estallido social en Chile y, cuando se retomó, se presentó un peak en las métricas de todos los anuncios. Las semanas 3 y 4 no sufrieron intervenciones externas, por lo que presentan comportamientos más comparables. Con esto, la Tabla 3.9 muestra las métricas obtenidas durante las semanas 3 y 4 para los anuncios de segmentación general. En esta comparación, Gestión Memorista aparece como ganadora, obteniendo la mayor cantidad de clics y la mejor rentabilidad, también medido por el CPC promedio. Al hacer el mismo tipo de análisis con el anuncio de segmentación emprendedores, se obtiene un resultado similar, siendo Gestión Memorista la más rentable. En este caso, se debe recordar que Gestión WUA no mostró este último anuncio durante la semana 3 y 4. La Figura 3.12 muestra la evolución diaria de clics para el anuncio con segmentación emprendedores y la Tabla 3.10 muestra los resultados acumulados de las semanas 3 y 4. Se intuye que el resultado anterior se da por la mejora en la capacidad predictiva del modelo VARX a medida que aumentan los datos. Al contar con una mayor cantidad de datos, se logra capturar mejor los efectos de una variable sobre la otra. Además, es posible agregar complejidad al modelo, como los niveles de lag. Al repetir el análisis incluyendo la semana 2 se obtiene un resultado similar, pero, como se mencionó anteriormente, no es una comparación justa. Dichos resultados se muestran en el Anexo J.

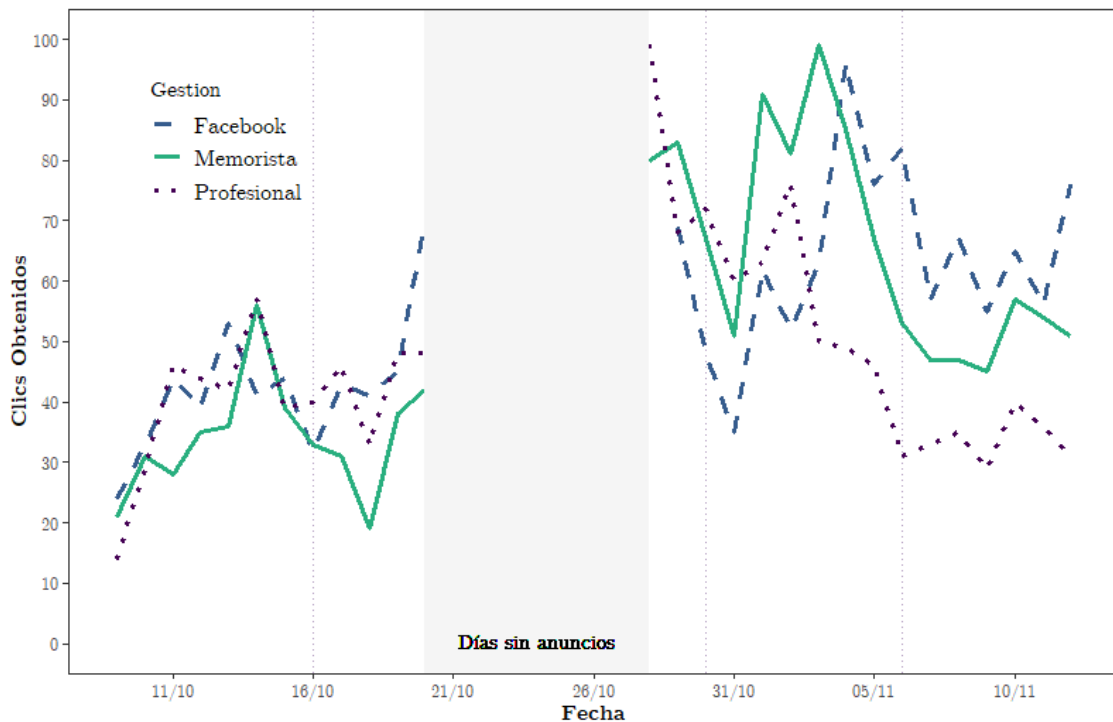


Figura 3.11: Evolución de clics obtenidos para anuncios generales. Las guías verticales indican separan las semanas del experimento. Se observa que las últimas dos semanas, Gestión Memorista obtuvo un performance mejor que Gestión Profesional.

Tabla 3.9: Resultados acumulados del experimento en semana 3 y 4 para anuncios generales. Estas últimas semanas son importantes porque las condiciones para comparar son las mejores, dado que se tenían más datos para predecir y los peaks de la semana 2 ya habían pasado. Los resultados obtenidos por Gestión Memorista son los mejores, siendo los más importantes la cantidad de clics y el CPC promedio.

Gestión	Clics	Alcance	Impresiones	CTR	CPC (CLP)	Inversión (CLP)
Facebook	752	125.643	129.535	0,58 %	28	20.731
Memorista	761	119.957	123.787	0,61 %	26	19.892
Profesional	651	169.697	173.929	0,37 %	32	20.734




Figura 3.12: Evolución de clics obtenidos para anuncio sellos. Al inicio de la semana 2, Gestión Profesional decide pausar su anuncio debido a que consideró que no estaba dando los resultados que esperaban. Por lo mismo, no es posible realizar una comparación con las otras gestiones.

En cuanto al ajuste de las predicciones del modelo VARX, la Tabla 3.11 muestra métricas de ajuste para cada anuncio y cada semana. Se aprecia que, en general, las métricas de ajuste van mejorando a medida que avanzan las semanas. Esto se atribuye a la mayor cantidad de información disponible, lo que concuerda también con el análisis anterior respecto a las métricas acumuladas en la semana 3 y 4. El error absoluto medio es la métrica más interesante en este caso. La magnitud de la predicción es la que determina el nivel de presupuesto a invertir, ya que el tamaño de los valores futuros indicará cómo ajustar la inversión. Esta métrica mejora a medida que avanza las semanas. A pesar de lo anterior, es importante considerar el error cuadrático medio (RMSE, por sus siglas en inglés), ya que si bien las grandes diferencias entre valores predichos y valores reales afectarán la metodología, también podría nublar el juicio experto de un gestor humano que utilice la información de las predicciones. En este caso, el RMSE también fue mejorando a medida que avanzaban las semanas. En cuanto a la dirección de las predicciones (aumento o disminución), a través de un test de medias se validó que ésta

Tabla 3.10: Resultados acumulados del experimento en semana 3 y 4 para anuncio sello. En este caso la comparación solamente puede hacerse entre dos gestiones, siendo Gestión Memorista la mejor debido a la cantidad de Clics obtenidos para el presupuesto invertido.

Gestión	Clics	Alcance	Impresiones	CTR	CPC (CLP)	Inversión (CLP)
Facebook	138	36.538	37.950	0,36 %	75	10.391
Memorista	134	32.108	33.169	0,40 %	73	9.760
Profesional	–	–	–	–	–	–

fuera significativamente correcta para cada anuncio. Dicha hipótesis se rechaza con un nivel de significancia del 1%, por lo que no se puede concluir que, en promedio, las predicciones fueron en la dirección correcta. Si bien este hecho es importante, no invalida los resultados de la metodología, ya que al momento de definir el nivel de inversión diario, el algoritmo de optimización se basaba en las magnitudes de las predicciones más que en las direcciones. En el Anexo K se resume el test realizado.

Tabla 3.11: Ajuste de las predicciones durante el experimento. El valor MAPE está calculado en base a las predicciones, al igual que en la Tabla 3.3. Los valores *Inf* se dejaron para ilustrar un desvío demasiado grande en la predicción. A medida que avanzan las semanas, los ajustes son mejores, exceptuando en el MAPE de la semana 4 para el anuncio *Ad 02 General*.

	MAE	MAPE	RMSE
Ad 01 General			
Semana 2	<i>Inf</i>	99,62 %	<i>Inf</i>
Semana 3	19,80	69,05 %	24,57
Semana 4	14,30	28,83 %	17,64
Ad 01 Sellos			
Semana 2	3,94	230,25 %	4,90
Semana 3	19,90	67,06 %	26,03
Semana 4	10,32	63,75 %	12,90
Ad 02 General			
Semana 2	1126,72	103,05 %	2.055,85
Semana 3	16,95	50,53 %	17,78
Semana 4	14,58	675,78 %	15,66

Analizar los anuncios por separado, se destaca que *Ad 01 Sellos*, que está segmentado hacia emprendedores, obtuvo el menor MAE para la última semana de experimento. Esto tiene relación con la intuición de que una mejor segmentación permite diseñar y entregar anuncios más específicos, que sean de interés de dicho segmento. De esta forma, el público objetivo interactúa mejor con el anuncio. Si bien lo anterior tiene sentido cualitativo, los resultados obtenidos entregan un sentido cuantitativo respecto a la predictibilidad de los

segmentos. De esta manera, un público objetivo bien segmentado suele ser más homogéneo, por lo que su comportamiento en Facebook sería más predecible. Al contrario, un público heterogéneo tendría un comportamiento menos predecible, ya que se compone de personas con actitudes distintas en redes sociales. Este hecho ayuda a que las predicciones del modelo VARX sean mejores, haciendo que la metodología completa funcione mejor.

Al observar las dinámicas subyacentes entre las variables utilizando las funciones de respuesta a impulsos, éstas son similares a las analizadas en la sección *Análisis de Dinámicas Subyacentes*. Las respuestas a shocks no son sostenibles en el largo plazo, exceptuando para el anuncio *Ad 02 General*. Este anuncio presenta respuestas sostenibles en el tiempo que son anómalas en relación a lo observado anteriormente, lo que se aprecia en la Figura 3.13. Si bien el comportamiento podría ser correcto, no se asumirá como tal dado que dista demasiado del comportamiento de los anuncios similares analizados en la sección antes mencionada.

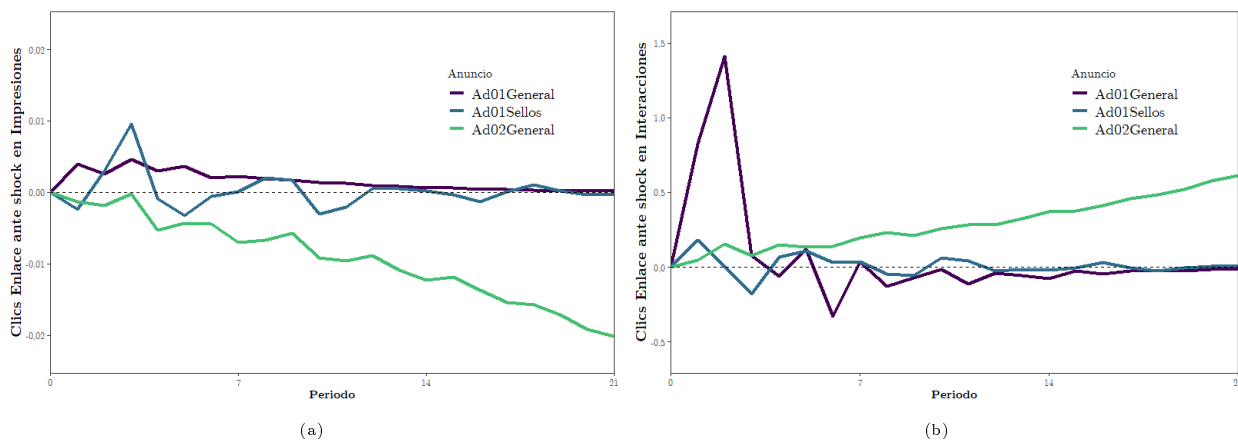


Figura 3.13: Funciones de respuesta para anuncios del experimento. El anuncio *Ad 02 General* muestra un comportamiento totalmente distinto a lo observado en la sección *Análisis de Dinámicas Subyacentes*, por lo que se asumirá como un comportamiento anómalo asociado únicamente al experimento.

Al comparar por segmentación, se observan similitudes en algunas funciones de respuesta, como se muestra en la Figura 3.14. Esto ocurre en la minoría de los casos, por lo que no se asumirá que la segmentación define un patrón de respuesta. Este comportamiento es similar al observado en la sección *Análisis de Dinámicas Subyacentes* respecto a la segmentación.

Todos los análisis anteriores permiten concluir lo siguiente:

1. Es posible predecir resultados publicitarios en Facebook y utilizar dicha información en una mejor utilización del presupuesto publicitario. En el caso de la metodología propuesta, utilizando un modelo sencillo, que se alimenta solamente con datos de los propios anuncios, logró resultados similares a los de una gestión humana basada en la experiencia.
2. La segmentación de los anuncios no define el comportamiento intrínseco entre los resultados que obtendrá, pero si la magnitud de la predictibilidad de los mismos.
3. En la metodología propuesta hay muchas oportunidades que explorar para mejorar la calidad de las predicciones y potenciar la gestión de anuncios digitales. En este mismo sentido, algunas propuestas son:

- Utilizar datos de campañas pasadas para gestionar campañas futuras: Es un hecho que a medida que aumentaban los datos disponibles el modelo VARX predecía con mayor certeza. La metodología propuesta en esta investigación podría ser de mayor utilidad si se utiliza para gestionar campañas de anuncios nuevas considerando datos de anuncios pasados similares. En este sentido, los datos de campañas anteriores permitirían hacer análisis más pulcros. Por ejemplo, se podría mejorar el análisis de raíz unitaria o incluir análisis de componentes principales. También permitirían añadir complejidad al modelo, a través de mayores niveles de lag o de variables exógenas, como fines de semana y festivos. De esta manera, se propone utilizar la metodología para analizar campañas de anuncios pasadas, ajustar un modelo VARX y utilizar dicho ajuste para gestionar una campaña futura similar.
- Aplicar un algoritmo de optimización más completo: En el experimento realizado se utilizó un algoritmo de maximización simple, cuya función era encontrar el valor máximo de una métrica dentro de una cantidad finita de resultados predefinidos. Esta etapa de la metodología puede mejorarse no solamente para considerar restricciones en un anuncio único, sino que para considerar restricciones en varias campañas a la vez. Así, es posible diseñar un algoritmo que tome en consideración las predicciones realizadas para cada campaña y que distribuya de manera óptima un presupuesto común, por ejemplo.
- Utilizar ciclos temporales más cortos: En el experimento se realizaron predicciones y ajustes de inversión al término de cada semana. Esto provocó una irregularidad cuando ocurrió el estallido social en Chile. Al conectarse directamente con la API de Facebook, es posible automatizar la metodología para que se realice en periodos de tiempo menores. Por ejemplo, se podría extraer datos de cada hora que se muestre el anuncio. De esta forma, sería posible predecir si efectivamente se debe tomar una acción frente a eventualidades como la sucedida o si el comportamiento regular no ha cambiado.



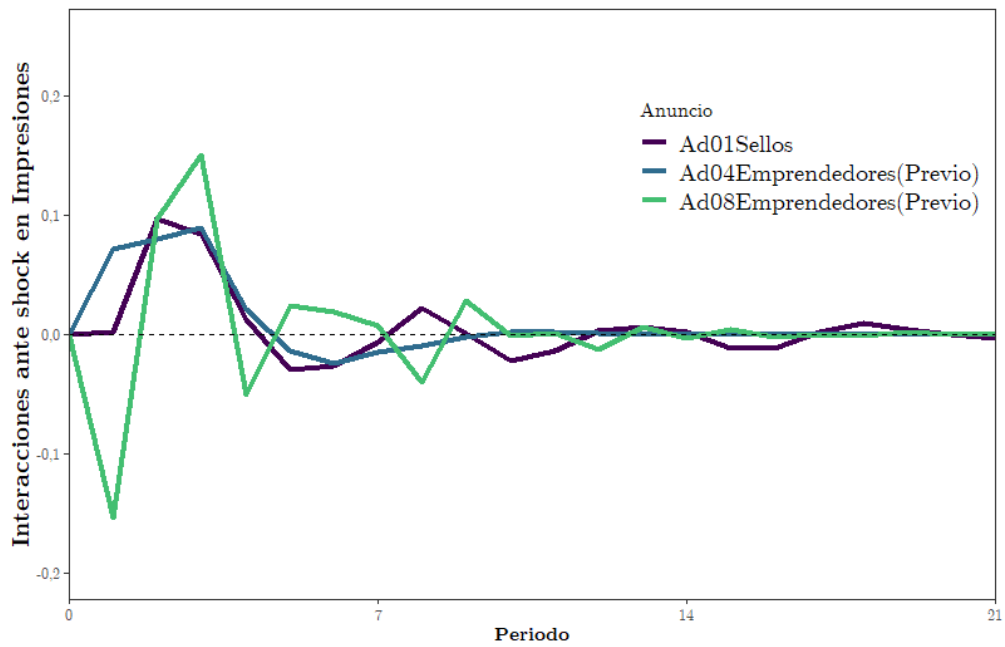


Figura 3.14: Comparación de IRF según segmentación. Al agrupar los anuncios según su segmentación, se observan patrones similares en sus funciones de respuesta. En este caso, se toman 2 anuncios de la sección *Análisis Previo* y se compara con un anuncio del experimento con la misma segmentación. La similitud observada ocurre en algunas funciones de respuesta y segmentaciones, por lo que no se concluirá que la segmentación define las respuestas del anuncio ante shocks.

# Conclusión

En base a los resultados y análisis presentados, y en relación directa a la hipótesis planteada al comienzo de esta memoria, se concluye que es posible utilizar predicciones de los resultados de anuncios en Facebook para optimizar la inversión publicitaria. Esto se evidencia al considerar los resultados obtenidos durante la semana 3 y 4 del experimento, fechas en las que la rentabilidad de la metodología planteada es cerca de un 5% mayor a la rentabilidad que por defecto entregó la plataforma de anuncios. Además, los resultados generales no estuvieron alejados de la gestión realizada por un profesional del área. En este mismo sentido, se cumple el objetivo principal de la presente memoria de desarrollar una metodología que prediga resultados y optimice el presupuesto de las campañas publicitarias en Facebook. Los objetivos secundarios se cumplieron para lograr lo anterior.

La metodología desarrollada en la presente memoria posee amplios espacios de mejora que podrían platearse como futuros trabajos asociados a éste. Por un lado se tiene el mayor desarrollo del modelo predictivo. Como se mencionó en un principio, por temas de simplicidad, se excluyeron del análisis algunas variables tales como adstock, wearout, días de la semana y factores visuales de los anuncios. A su vez, podría utilizarse un modelo distinto en la predicción. Si bien para esta investigación se utilizó un modelo VARX, se podría utilizar modelos VAR o autoregresivos. Dado que se detectó un nivel de predictibilidad, el modelo mismo puede adaptarse. Cada uno de estos elementos podría aportar una nueva dimensión al problema planteado a la vez que mejorar la capacidad predictiva del modelo que se utilice. Por otro lado está el desarrollo del modelo de optimización. Un modelo de optimización complejo, que utilice más o mejores restricciones, asociadas a reglas de negocio o intuición profesional podría mejorar los resultados obtenidos. Además, dependiendo de las restricciones, se podría adaptar la metodología para ser utilizada en la gestión de múltiples campañas simultáneas. Por último, es posible expandir las ideas planteadas hacia otras redes de anuncios, como la de Google, ya que la estructura de datos que ésta provee es similar a la utilizada en esta memoria.

Como se mencionó en un principio, el uso de medios digitales en los objetivos de marketing aumenta año a año, por lo que hace sentido desarrollar nuevo conocimiento en el área. De esta forma, la presente investigación es un aporte en el estudio de publicidad en redes sociales. Se demostró que incluso con pocos datos, generados sobre la marcha, es posible obtener nociones relevantes respecto a los anuncios que se muestran en la avisaje de Facebook. Si bien el alcance se limitó a una única red social, es replicable a otros espacios tales como Instagram, LinkedIn o YouTube. A pesar de que las dinámicas en cada espacio pueden ser distintas, la capacidad de generar y extraer datos está bien desarrollada en cada plataforma. Es posible

aprovechar dichos datos y darles un uso que permite cumplir los objetivos de marketing de cada anunciante. A partir de ello, es posible generar conocimiento tan vasto como se generó en el pasado respecto al marketing y publicidad tradicional. Este conocimiento hablará respecto a actitudes de uso de redes sociales, sitios web, respuestas de corto y largo plazo a la publicidad, efectos emocionales en espacios digitales, distribución de presupuesto en canales digitales, entre muchos otros. La invitación final de este trabajo es a seguir investigando el espacio digital y a prepararse para cuando el marketing y la publicidad sea, en su mayoría a través de internet.

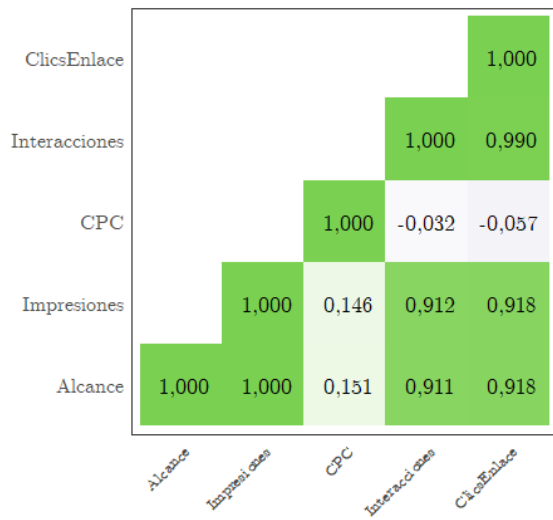
# Bibliografía

- N. Archak, V. Mirrokni, and S. Muthukrishnan. Budget optimization for online advertising campaigns with carryover effects. In *Sixth Ad Auctions Workshop*. Citeseer, 2010.
- Asociación Chilena de Agencias de Medios en conjunto con IAB Chile y Admetricks. Inversión digital Chile 2018, 2019. URL <https://aam.cl/wp-content/uploads/2019/08/Inversio%CC%81n-Publicidad-Digital-Chile-2018.pdf>.
- M. Braun and W. W. Moe. Online display advertising: Modeling the effects of multiple creatives and individual impression histories. *Marketing Science*, 32(5):753–767, 2013.
- P. J. Danaher and R. T. Rust. Determining the optimal return on investment for an advertising campaign. *European Journal of Operational Research*, 95(3):511–521, 1996.
- M. G. Dekimpe and D. M. Hanssens. Persistence modeling for assessing marketing strategy performance. 2003.
- eMarketer. Global digital ad spending 2019, 2019. URL <https://www.emarketer.com/content/global-digital-ad-spending-2019>.
- Facebook. Información sobre la fase de aprendizaje, 2019. URL <https://es-la.facebook.com/business/help/112167992830700?id=155026355167038>.
- M. Goic, R. Álvarez, and R. Montoya. The effect of house ads on multichannel sales. *Journal of Interactive Marketing*, 42:32–45, 2018.
- W. J. Havlena and J. Graham. Decay effects in online advertising: Quantifying the impact of time since last exposure on branding effectiveness. *Journal of Advertising Research*, 44(4):327–332, 2004.
- R. Hussain, A. S. Ferdous, and G. S. Mort. Impact of web banner advertising frequency on attitude. *Asia Pacific Journal of Marketing and Logistics*, pages 00–00, 2018.
- International Telecommunication Union. Itu releases 2018 global and regional ict estimates, Diciembre 2018. URL <https://www.itu.int/en/mediacentre/Pages/2018-PR40.aspx>.
- J. Lee and I. B. Hong. Predicting positive user responses to social media advertising: The roles of emotional appeal, informativeness, and creativity. *International Journal of Information Management*, 36(3):360–373, 2016.

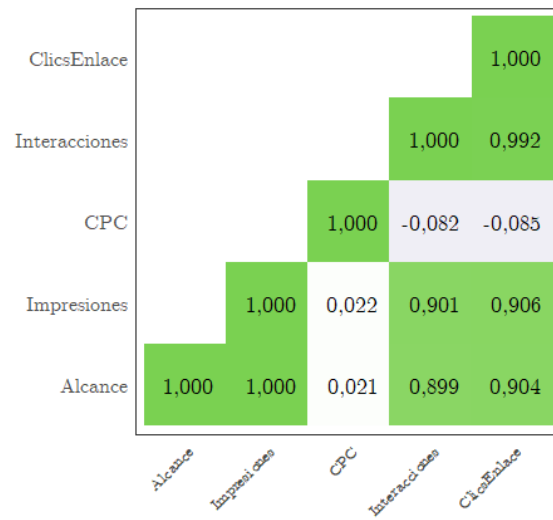
- V. R. Nijs, M. G. Dekimpe, J.-B. E. Steenkamps, and D. M. Hanssens. The category-demand effects of price promotions. *Marketing Science*, 20(1):1–22, 2001.
- Observatorio de Sociedad Digital de la Facultad de Economía y Negocios de la Universidad de Chile en colaboración con la Asociación de Marketing Directo y Digital AMDD. Data-driven marketing 2019, 2019.
- C. Paulson, L. Luo, and G. M. James. Efficient large-scale internet media selection optimization for online display advertising. *Journal of Marketing Research*, 55(4):489–506, 2018.
- K. Pauwels. How dynamic consumer response, competitor response, company support, and company inertia shape long-term marketing effectiveness. *Marketing Science*, 23(4):596–610, 2004.

# Anexo


# A. Matrices de correlación




(a) Ad 01 General




(b) Ad 04 Emprendedores




(c) Ad 06 Escolar



(d) Ad 06 Oficina



(e) Ad 07 Manualidades



(f) Ad 08 Emprendedores

Correlación entre métricas de anuncios de la primera etapa. Mientras más verde sea el cuadro, mayor correlación positiva habrá. Mientras más oscuro sea, mayor correlación negativa habrá.



## B. Primer test de Dickey-Fuller para anuncios de la primera etapa.

El test de Dickey-Fuller se utiliza para identificar estacionalidad en series de tiempos. En este caso, 5 series se identificaron como no estacionarias, por lo que fueron diferenciadas para su posterior análisis.


	Estadístico Dickey-Fuller	p-valor	Resultado		Estadístico Dickey-Fuller	p-valor	Resultado
Ad 01 General				Ad 06 Oficina			
Alcance	-3,79	0,02	Estacionaria	Alcance	-2,37	0,43	No Estacionaria
Impresiones	-3,78	0,02	Estacionaria	Impresiones	-2,24	0,48	No Estacionaria
CPC	-4,73	0,01	Estacionaria	CPC	-3,25	0,09	No Estacionaria
Interacciones	-3,94	0,01	Estacionaria	Interacciones	-3,84	0,02	Estacionaria
Clics Enlace	-3,86	0,02	Estacionaria	Clics Enlace	-4,03	0,01	Estacionaria
Ad 04 Emprendedores				Ad 07 Manualidades			
Alcance	-3,83	0,02	Estacionaria	Alcance	-2,88	0,22	No Estacionaria
Impresiones	-3,81	0,02	Estacionaria	Impresiones	-2,84	0,23	No Estacionaria
CPC	-3,45	0,05	Estacionaria	CPC	-3,38	0,07	No Estacionaria
Interacciones	-4,54	0,01	Estacionaria	Interacciones	-2,91	0,21	No Estacionaria
Clics Enlace	-4,44	0,01	Estacionaria	Clics Enlace	-3,01	0,17	No Estacionaria
Ad 06 Escolar				Ad 08 Emprendedores			
Alcance	-2,81	0,24	No Estacionaria	Alcance	-2,99	0,17	No Estacionaria
Impresiones	-3,17	0,1	No Estacionaria	Impresiones	-2,97	0,18	No Estacionaria
CPC	-5,36	0,01	Estacionaria	CPC	-2,95	0,19	No Estacionaria
Interacciones	-3,91	0,02	Estacionaria	Interacciones	-3,31	0,08	No Estacionaria
Clics Enlace	-3,92	0,02	Estacionaria	Clics Enlace	-3,40	0,06	No Estacionaria

## C. Segundo test de Dickey-Fuller para anuncios de la primera etapa


Segundo test de Dickey-Fuller realizado para anuncios de la primera etapa, luego de la diferenciación. Ninguna serie presenta un comportamiento no-estacionario luego de la diferenciación.

	Estadístico Dickey-Fuller	p-valor	Resultado		Estadístico Dickey-Fuller	p-valor	Resultado
Ad 01 General				Ad 06 Oficina			
Alcance	-3,79	0,02	Estacionaria	Alcance	-5,91	0,01	Estacionaria
Impresiones	-3,78	0,02	Estacionaria	Impresiones	-5,6	0,01	Estacionaria
CPC	-4,73	0,01	Estacionaria	CPC	-5,33	0,01	Estacionaria
Interacciones	-3,94	0,01	Estacionaria	Interacciones	-3,84	0,02	Estacionaria
ClicsEnlace	-3,86	0,02	Estacionaria	ClicsEnlace	-4,03	0,01	Estacionaria
Ad 04 Emprendedores				Ad 07 Manualidades			
Alcance	-3,83	0,02	Estacionaria	Alcance	-5,86	0,01	Estacionaria
Impresiones	-3,81	0,02	Estacionaria	Impresiones	-5,75	0,01	Estacionaria
CPC	-3,45	0,05	Estacionaria	CPC	-4,78	0,01	Estacionaria
Interacciones	-4,54	0,01	Estacionaria	Interacciones	-4,69	0,01	Estacionaria
ClicsEnlace	-4,44	0,01	Estacionaria	ClicsEnlace	-5,47	0,01	Estacionaria
Ad 06 Escolar				Ad 08 Emprendedores			
Alcance	-7,96	0,01	Estacionaria	Alcance	-4,33	0,01	Estacionaria
Impresiones	-8,13	0,01	Estacionaria	Impresiones	-4,38	0,01	Estacionaria
CPC	-5,36	0,01	Estacionaria	CPC	-4,55	0,01	Estacionaria
Interacciones	-3,91	0,02	Estacionaria	Interacciones	-4,35	0,01	Estacionaria
ClicsEnlace	-3,92	0,02	Estacionaria	ClicsEnlace	-4,63	0,01	Estacionaria


## D. Función de autocorrelación graficada




Ad 01 General




Ad 04 Emprendedores




Ad 06 Escolares



Ad 06 Oficina



Ad 07 Manualidades



Ad 08 Emprendedores

Funciones de autocorrelación graficada para cada anuncio de la primera etapa. Las figuras ilustran la relación lineal entre una observación y sus valores pasados. De esta manera, las relaciones significativas (fuera de los límites punteados) se dan para los primeros niveles 2 de lag en todos los casos. Para algunos anuncios, los niveles significativos se dan incluso entre 10 y 20, lo que entrega indicios de una tendencia cíclica.

## E. Inversión de Presupuesto Semana 1

Cambios de inversión definidos para la primera semana de experimentación. Estos cambios se decidieron de manera aleatoria y se utilizaron para establecer una relación entre las variables endógenas y exógenas. De no haber aplicado estos cambios, la variable exógena se habría definido como constante para esta primera semana.

	$t = 15$	$t = 16$	$t = 17$	$t = 18$	$t = 19$	$t = 20$	$t = 21$
Ad 01 General	0 %	+10 %	-10 %	-10 %	0 %	+10 %	0 %
Ad 01 Sellos	0 %	+10 %	-10 %	-10 %	0 %	+10 %	0 %
Ad 02 General	0 %	+10 %	-10 %	-10 %	0 %	+10 %	0 %

## F. Tests Dickey-Fuller para el Experimento

Test Dickey-Fuller para la semana 1 del experimento. Como los datos utilizados acá son pocos, no hace sentido diferenciar para lograr la estacionalidad, ya que esa misma característica no es evidenciable.

	Estadístico DF	p-valor	Resultado
Ad 01 General			
Alcance	-0,90	0,94	No Estacionaria
Impresiones	-0,88	0,94	No Estacionaria
CPC	-11,00	0,01	Estacionaria
Interacciones	-0,89	0,94	No Estacionaria
ClicsEnlace	-1,52	0,76	No Estacionaria
Ad 02 General			
Alcance	-5,01	0,01	Estacionaria
Impresiones	-5,93	0,01	Estacionaria
CPC	-9,83	0,01	Estacionaria
Interacciones	-6,91	0,01	Estacionaria
ClicsEnlace	-7,74	0,01	Estacionaria
Ad 01 Sellos			
Alcance	-2,00	0,57	No Estacionaria
Impresiones	-2,05	0,55	No Estacionaria
CPC	-34,40	0,01	Estacionaria
Interacciones	-4,24	0,01	Estacionaria
ClicsEnlace	-1,61	0,72	No Estacionaria

Primer test Dickey-Fuller para la semana 2 del experimento. Las series no estacionarias se diferencian para buscar su estacionalidad.

	Estadístico DF	p-valor	Resultado
Ad 01 General			
Alcance	-3,90	0,03	Estacionaria
Impresiones	-3,92	0,03	Estacionaria
CPC	-1,88	0,62	No Estacionaria
Interacciones	-2,45	0,40	No Estacionaria
ClicsEnlace	-2,24	0,48	No Estacionaria
Ad 02 General			
Alcance	-0,88	0,94	No Estacionaria
Impresiones	-0,87	0,94	No Estacionaria
CPC	-0,71	0,96	No Estacionaria
Interacciones	-0,91	0,93	Estacionaria
ClicsEnlace	-1,44	0,78	No Estacionaria
Ad 01 Sellos			
Alcance	-2,33	0,45	No Estacionaria
Impresiones	-2,24	0,48	No Estacionaria
CPC	-2,88	0,24	No Estacionaria
Interacciones	-2,04	0,56	No Estacionaria
ClicsEnlace	-2,97	0,20	No Estacionaria

Segundo test Dickey-Fuller para la semana 2 del experimento. Luego de la diferenciación, las series no estacionarias no se vuelven a diferenciar, dada la poca cantidad de datos.

	Estadístico DF	p-valor	Resultado
Ad 01 General			
Alcance	-3,90	0,03	Estacionaria
Impresiones	-3,92	0,03	Estacionaria
CPC	-1,51	0,76	No Estacionaria
Interacciones	-1,69	0,69	No Estacionaria
ClicsEnlace	-1,37	0,81	No Estacionaria
Ad 02 General			
Alcance	-1,65	0,71	No Estacionaria
Impresiones	-1,64	0,71	No Estacionaria
CPC	-2,08	0,54	No Estacionaria
Interacciones	-1,51	0,76	No Estacionaria
ClicsEnlace	-1,95	0,59	Estacionaria
Ad 01 Sellos			
Alcance	-2,86	0,24	No Estacionaria
Impresiones	-2,77	0,28	No Estacionaria
CPC	-2,72	0,30	No Estacionaria
Interacciones	-2,15	0,51	No Estacionaria
ClicsEnlace	-1,92	0,60	No Estacionaria



Primer test Dickey-Fuller para la semana 3 del experimento. Nuevamente, las series no estacionarias se diferencian para buscar su estacionalidad.

	Estadístico DF	p-valor	Resultado
Ad 01 General			
Alcance	-1,58	0,73	No Estacionaria
Impresiones	-1,53	0,75	No Estacionaria
CPC	-2,69	0,31	No Estacionaria
Interacciones	-2,05	0,55	No Estacionaria
ClicsEnlace	-2,24	0,48	No Estacionaria
Ad 02 General			
Alcance	-1,74	0,67	
Impresiones	-1,75	0,67	No Estacionaria
CPC	-2,26	0,47	No Estacionaria
Interacciones	-1,46	0,78	No Estacionaria
ClicsEnlace	-3,43	0,07	No Estacionaria
Ad 01 Sellos			
Alcance	-2,47	0,39	Estacionaria
Impresiones	-2,46	0,40	Estacionaria
CPC	-4,35	0,01	Estacionaria
Interacciones	-2,61	0,34	No Estacionaria
ClicsEnlace	-3,31	0,09	No Estacionaria

Segundo test Dickey-Fuller para la semana 3 del experimento. A las series que no son estacionarias luego de este test se les aplica la segunda diferencia para volverlas estacionarias.

	Estadístico DF	p-valor	Resultado
Ad 01 General			
Alcance	-2,99	0,20	No Estacionaria
Impresiones	-2,97	0,20	No Estacionaria
CPC	-2,60	0,34	No Estacionaria
Interacciones	-1,78	0,66	No Estacionaria
ClicsEnlace	-2,07	0,55	No Estacionaria
Ad 02 General			
Alcance	-2,26	0,47	No Estacionaria
Impresiones	-2,30	0,46	No Estacionaria
CPC	-2,61	0,34	No Estacionaria
Interacciones	-2,05	0,55	No Estacionaria
ClicsEnlace	-3,78	0,04	Estacionaria
Ad 01 Sellos			
Alcance	-2,63	0,33	No Estacionaria
Impresiones	-2,70	0,30	No Estacionaria
CPC	-4,35	0,01	Estacionaria
Interacciones	-2,76	0,28	Estacionaria
ClicsEnlace	-3,17	0,13	No Estacionaria

Tercer test Dickey-Fuller para la semana 3 del experimento. Aquellas series no estacionarias no se volvieron a diferenciar.

	Estadístico DF	p-valor	Resultado
Ad 01 General			
Alcance	-5,40	0,01	Estacionaria
Impresiones	-5,63	0,01	Estacionaria
CPC	-3,47	0,07	No Estacionaria
Interacciones	-2,05	0,55	No Estacionaria
ClicsEnlace	-2,40	0,42	No Estacionaria
Ad 02 General			
Alcance	-3,89	0,03	Estacionaria
Impresiones	-3,91	0,03	Estacionaria
CPC	-3,91	0,03	Estacionaria
Interacciones	-3,62	0,05	Estacionaria
ClicsEnlace	-3,78	0,04	Estacionaria
Ad 01 Sellos			
Alcance	-3,40	0,08	No Estacionaria
Impresiones	-3,51	0,06	No Estacionaria
CPC	-4,35	0,01	Estacionaria
Interacciones	-3,57	0,05	No Estacionaria
ClicsEnlace	-3,20	0,12	Estacionaria

## G. Ajustes Semanales del Modelo VARX

Ajuste del modelo VARX para la semana 2 del experimento. Cada tabla muestra los coeficientes que acompañan a cada variable del modelo, en combinación fila y columna

### Ad 01 General

	Impresiones	CPC	Interacciones	ClicsEnlace
$a_0$	67.1350,50	-2416,07	6.291,22	5.498,68
Impresiones	165,76	-0,61	1,56	1.361,00
CPC	4.024,16	-14,26	36,45	31.903,00
Interacciones	103.029,41	-379,49	969,98	846,31
ClicsEnlace	-130.090,92	479,66	-1.226,30	-1.069,87
Inversión	-1.281,86	4,66	-11,96	-10,45
AIC : -114,58		BIC : -115,42		

### Ad 02 General

	Impresiones	CPC	Interacciones	ClicsEnlace
$a_0$	-5.159,39	628,22	-1.848,60	-219,57
Impresiones	1,08	-0,03	0,32	0,00
CPC	14,29	-2,62	5,79	1,23
Interacciones	0,33	-0,36	-0,04	0,34
ClicsEnlace	-39,60	-7,22	6,99	1,69
Inversión	6,83	-0,44	1,67	0,16
AIC : -185,76		BIC : -186,60		

### Ad 01 Sellos

	Impresiones	CPC	Interacciones	ClicsEnlace
$a_0$	1.894,19	-30,14	85,30	-32,16
Impresiones	-2,67	0,08	-0,12	-0,01
CPC	50,06	-1,66	3.158,00	0,46
Interacciones	87,82	-2,35	4,17	0,37
ClicsEnlace	-133,70	3,29	-9,57	-0,25
Inversión	-9,04	0,30	-0,40	0,00
AIC : -203,09		BIC : -203,92		

Ajuste del modelo VARX para la semana 3 del experimento. Se muestran coeficientes para los dos niveles de lag utilizado, diferenciados por  $p$

Ad 01 General				
	Impresiones	CPC	Interacciones	ClicsEnlace
$a_0$	7.274,05	46,74	-71,06	-47,23
$p = 1$				
Impresiones	0,89	0,00	0,01	0,01
CPC	66,69	-0,12	-0,93	-1,06
Interacciones	453,71	1,19	1,07	2,02
ClicsEnlace	-498,03	-1,37	-2,82	-4,02
$p = 2$				
Impresiones	-1,24	0,00	-0,01	-0,01
CPC	-18,87	-0,15	-0,74	-0,99
Interacciones	405,56	2,44	-1,61	0,44
ClicsEnlace	-371,72	-3,30	1,75	-0,92
Inversión	-4,05	-0,08	0,10	0,06
		AIC : -47,41	BIC : -46,51	

Ad 02 General				
	Impresiones	CPC	Interacciones	ClicsEnlace
$a_0$	-7.275,51	188,96	-553,88	-47,98
$p = 1$				
Impresiones	0,77	0,01	0,03	0,00
CPC	10,28	-1,31	1,09	0,19
Interacciones	-9,67	-0,17	-0,70	0,03
ClicsEnlace	-5,93	-0,47	2,79	-0,33
$p = 2$				
Impresiones	-1,85	0,02	-0,11	0,00
CPC	38,51	-0,78	3,77	0,02
Interacciones	14,50	-0,13	0,78	0,00
ClicsEnlace	48,05	-0,59	7,93	-0,36
Inversión	11,01	-0,29	0,83	0,07
		AIC : -46,46	BIC : -45,01	

## Ad 01 Sellos

	Impresiones	CPC	Interacciones	ClicsEnlace
$a_0$	-9.186,01	-96,17	-581,11	-10,16
$p = 1$				
Impresiones	1,62	0,00	0,11	0,00
CPC	-56,03	-0,49	-2,64	0,29
Interacciones	-37,80	-0,40	-2,49	0,07
ClicsEnlace	-294,31	3,21	-18,24	-0,67
$p = 2$				
Impresiones	-1,20	0,04	-0,04	-0,01
CPC	19,69	-0,27	0,68	0,21
Interacciones	20,81	-0,84	0,79	0,21
ClicsEnlace	55,59	2,51	0,69	-0,75
Inversión	13,61	0,14	0,86	0,01
	AIC : -49,96		BIC : -48,35	

Ajuste del modelo VARX para la semana 4 del experimento. Se muestran los coeficientes para los 3 niveles de lag utilizados.

Ad 01 General				
	Impresiones	CPC	Interacciones	ClicsEnlace
$a_0$	-1.694,70	8,57	18,96	23,39
$p = 1$				
Impresiones	-0,03	0,00	0,00	0,00
CPC	-5,57	-0,29	-0,66	-0,70
Interacciones	11,44	0,67	-0,50	0,83
ClicsEnlace	-25,24	-0,58	-0,97	-2,33
$p = 2$				
Impresiones	-0,83	0,00	0,00	0,00
CPC	-110,33	-0,08	-0,41	-0,60
Interacciones	102,08	0,76	1,79	2,68
ClicsEnlace	-61,95	-0,90	-2,16	-3,14
$p = 3$				
Impresiones	-0,24	0,00	0,00	0,00
CPC	13,55	-0,36	0,38	0,06
Interacciones	-35,93	0,33	3,03	2,86
ClicsEnlace	4,63	-0,33	-2,90	-2,77
Inversión	2,25	-0,01	-0,03	-0,03
		AIC : 22,14		BIC : 24,91

## Ad 02 General

	Impresiones	CPC	Interacciones	ClicsEnlace
$a_0$	-2.833,92	29,68	-233,15	-4,86
$p = 1$				
Impresiones	-2,31	0,02	-0,11	-0,01
CPC	74,98	-0,26	4,27	0,67
Interacciones	27,76	-0,34	0,93	0,21
ClicsEnlace	-21,18	-0,61	2,50	-1,08
$p = 2$				
Impresiones	-2,05	0,00	-0,08	0,00
CPC	64,77	0,43	3,46	0,16
Interacciones	35,38	-0,12	1,22	0,21
ClicsEnlace	-50,47	0,22	-1,86	-1,17
$p = 3$				
Impresiones	-1,99	0,01	-0,12	-0,01
CPC	-59,55	-0,12	-3,40	-0,15
Interacciones	32,67	-0,14	1,76	0,16
ClicsEnlace	-27,01	-0,92	0,03	-0,28
Inversión	1,29	-0,01	0,18	-0,02
AIC : 21,02		BIC : 23,79		

## Ad 01 Sellos

	Impresiones	CPC	Interacciones	ClicsEnlace
$a_0$	-1.826,09	29,10	-69,75	-25,45
$p = 1$				
Impresiones	-1,30	0,00	-0,04	0,00
CPC	-21,06	-1,24	-1,47	0,25
Interacciones	16,01	-0,10	0,51	0,07
ClicsEnlace	-86,86	3,02	-7,28	-0,42
$p = 2$				
Impresiones	0,11	0,01	0,02	0,00
CPC	-37,94	-0,74	-2,31	0,23
Interacciones	-10,56	-0,63	-0,08	0,13
ClicsEnlace	-90,92	0,14	-1,33	-0,12
$p = 3$				
Impresiones	0,16	0,00	0,04	0,00
CPC	-2,97	-0,19	-0,85	0,01
Interacciones	8,16	0,29	-0,59	-0,04
ClicsEnlace	38,07	-2,30	-0,54	0,47
Inversión	2,56	-0,04	0,10	0,04
AIC : 23,10		BIC : 25,87		



## H. Anuncios Adicionales en Gestión Profesional



Adetec Publicidad

Estas nuevas etiquetas de #PapelKraft pueden darle un look único a tus proyectos. Usa el tamaño #Carta para crear afiches ... Ver más

GRAN KERMESSE

En estas de tus gran variedad de actividades para grandes y chicos, todas las unidades distribuidas de un evento distendido, alegre y muy divertido que nunca olvidaras.

WWW.ADETEC.CL/IMPRIME  
Crea - Imprime - Impresiona

MÁS INFORMACIÓN

(a) Ad 03 General



Adetec Publicidad

#Adetec te entrega soluciones para el diseño de tus celebraciones! El mejor recuerdo del cumpleaños de tus hijos lo puedes ... Ver más

KING ANDY

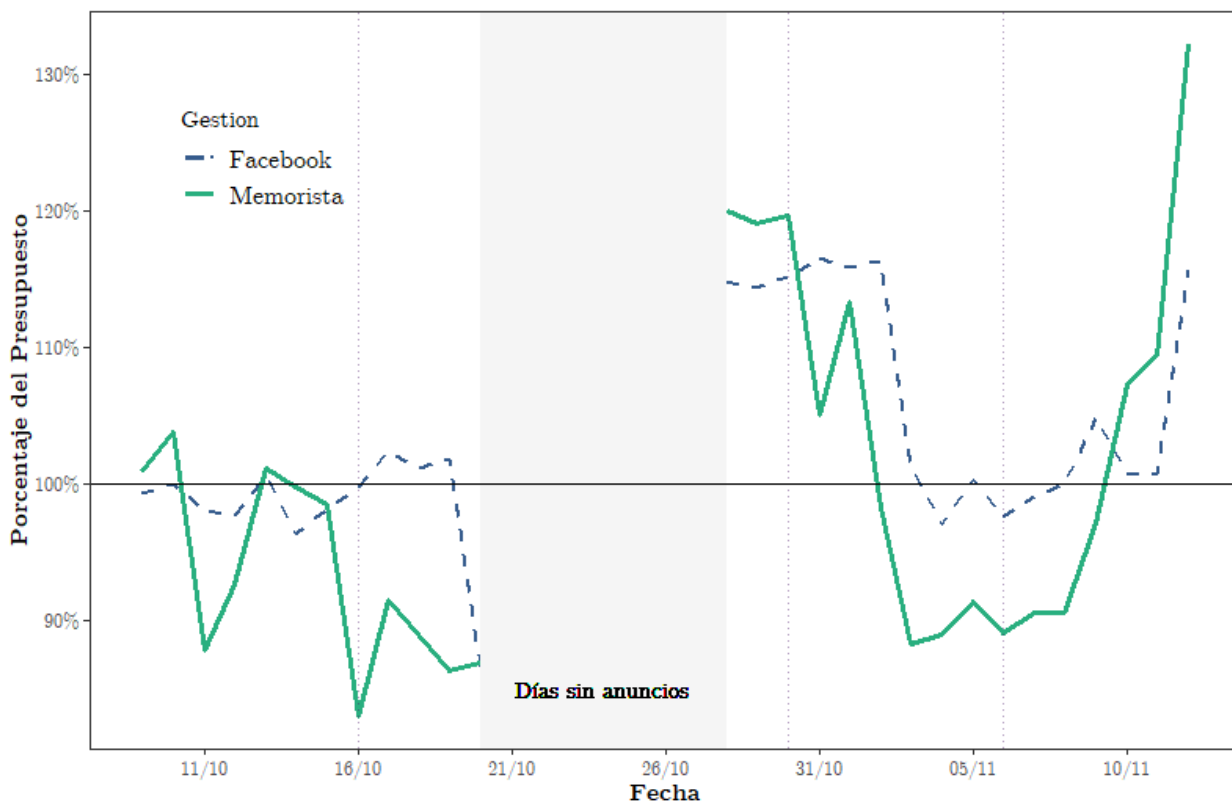
WWW.ADETEC.CL/IMPRIME  
Crea - Imprime - Impresiona

MÁS INFORMACIÓN

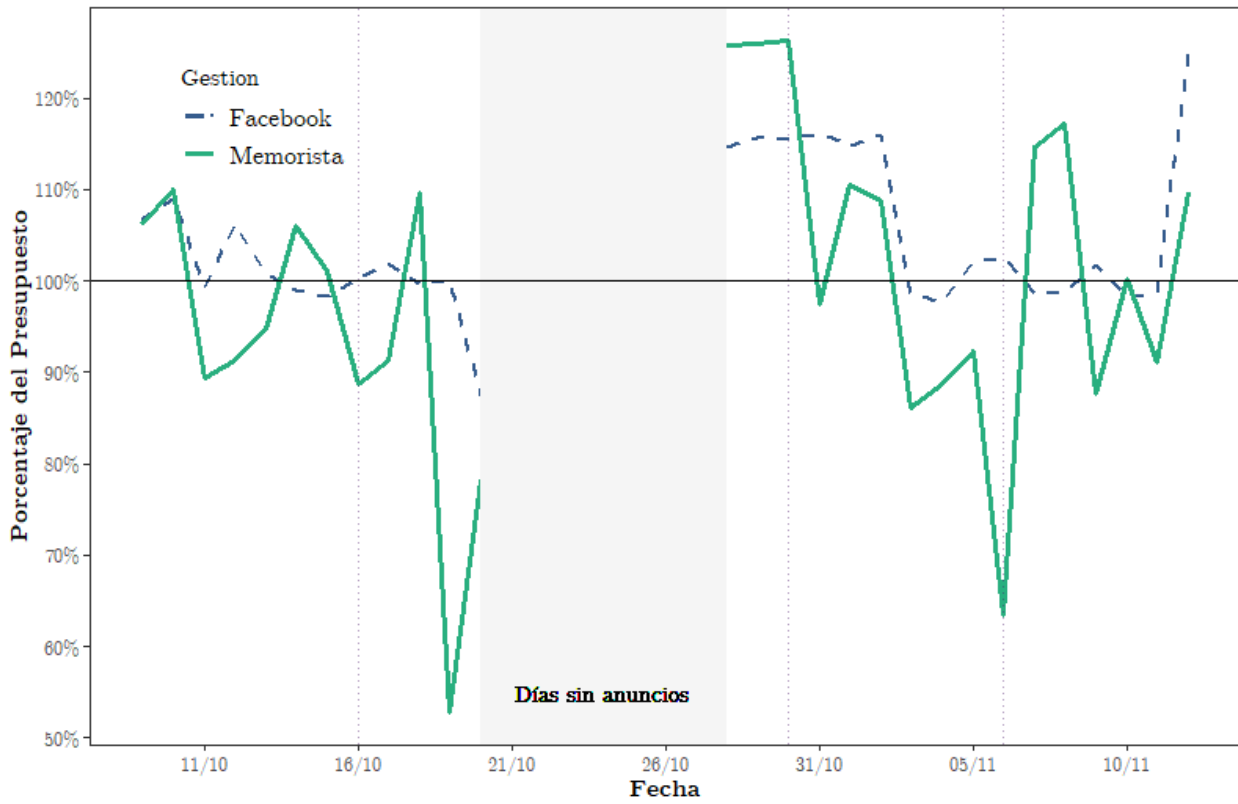
(b) Ad 04 General

Anuncios adicionales que Gestión Profesional añadió en las campañas. Ambos se incluyeron en el conjunto de anuncios con segmentación general.

# I. Gasto de Presupuesto Experimento



Gasto porcentual del presupuesto de inversión, para los anuncios de segmentación general. Las guías verticales delimitan las semanas del experimento. La lógica del algoritmo de Facebook busca gastar el presupuesto diario que fue configurado. Con la metodología propuesta, Gestión Memorista disminuye el gasto cuando los resultados serán menores, según las predicciones que realiza. Esto provoca que las subidas de gasto no comprometan el límite de presupuesto total.



Gasto porcentual del presupuesto de inversión, para los anuncios Sellos. Al igual que en la figura anterior, las bajas que realiza la Gestión Memorista permiten amortiguar los futuros aumentos de inversión.

## J. Resultados Experimento Acumulados

Resultados acumulados desde, la semana 2, de los anuncios Generales. Corresponden solamente a las semanas en las que se realizó predicciones.

Gestión	Clics	Alcance	Impresiones	CTR	CPC (CLP)	Inversión (CLP)
Facebook	1.104	180.762	186.376	0,59 %	28	30.820
Memorista	1.028	166.772	171.941	0,60 %	29	29.347
Profesional	1.032	239.371	244.650	0,42 %	30	30.823

Resultados acumulados desde, la semana 2, de los anuncios Sellos. Al igual que la tabla anterior, solamente incluye los resultados de las semanas con predicciones.

Gestión	Clics	Alcance	Impresiones	CTR	CPC (CLP)	Inversión (CLP)
Facebook	194	50.251	52.321	0,37 %	80	15.428
Memorista	193	45.196	46.817	0,41 %	75	14.469
Profesional	1	309	316	0,32 %	237	237

## K. Test de Medias

Test de medias realizado para evaluar la cantidad de aciertos en la dirección (aumento o disminución de clics) de las predicciones. Si una predicción se realizaba en la dirección correcta, se consideraba como 1 y como 0 en caso contrario.

Test de Medias con  $H_0 : Media = 1$

	Media	Desv. Est.	t-test
Ad 01 General	0,52	0,57	-4,26
Ad 02 General	0,38	0,50	-5,70
Ad 01 Sellos	0,57	0,51	-3,87

\*\*\* $p < 0,001$ .  $N = 21$