

Módulo 3. Etapa 2.

Experimentación

Unidad 3.1. Diseño del experimento

La fase de experimentación en un proceso de CRO es central porque es la manera de establecer fehacientemente que un camino es más óptimo que otro.

¿Cómo podemos elegir el camino correcto si no tenemos información fidedigna?
¿Cómo seleccionar cuál de los caminos tomar en una bifurcación?

Figura 1. El experimento como función de selección



Fuente: elaboración propia.

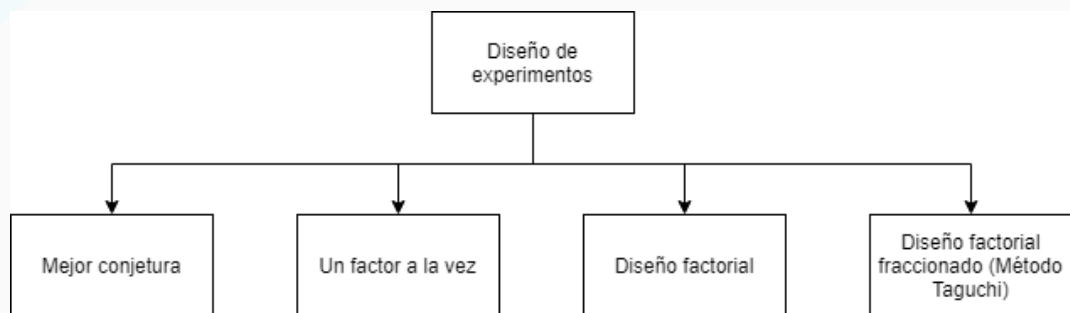
Imaginemos que nos encontramos en un programa de juegos en televisión y debemos seleccionar la puerta ganadora. Detrás de una de ellas se encuentra el premio mayor: un coche nuevo. Detrás de las otras puertas, un cartel con una cara triste que dice que hemos perdido. Tenemos una chance en cuatro posibles de ganar. Ahora bien, si pudiéramos experimentar, y nos permitieran abrir dos de las puertas, antes de tomar nuestra decisión, las chances de éxito aumentarían hasta en un cincuenta por ciento, e inclusive, hasta en un cien por ciento. Esa es la función de la experimentación en un proceso de optimización: darnos soporte en la toma de decisiones de manera concreta al aumentar notoriamente nuestras chances de éxito.

El objetivo de la experimentación en CRO es estudiar la importancia que tienen los distintos elementos del sitio en la tasa final de conversiones. Montgomery (2019) denomina **estrategia de experimentación** al enfoque general del planeamiento y la implementación del experimento. La definición de esta estrategia o diseño “solidifica el objetivo del test, delimita la estructura del experimento, fija un control válido y evita errores comunes” (Goward, 2013, p. 273).

Existen distintas estrategias que el experimentador puede usar. Supongamos que se quiere testear el impacto que tienen en la tasa de conversión:

- La ubicación del botón de CTA (*call to action* o llamado a la acción).
- El color del botón de CTA.
- La forma del botón de CTA.
- El tamaño del botón de CTA.
- El texto del botón de CTA: “Reserve su lugar” en comparación con “Reserve ahora”.

Figura 2. Enfoques de experimentación



Fuente: elaboración propia.

Un enfoque podría ser seleccionar arbitrariamente alguna combinación de niveles de esos factores y testarlos. Inicialmente, podría probarse la ubicación en la parte superior del sitio, el color azul, la forma rectangular con puntas redondeadas, el tamaño de 70 por 25 píxeles y el texto “Reserve ahora”. Luego, habría que probar los mismos niveles de los factores excepto que el botón sea de color naranja. Esta estrategia se llama **enfoque de la mejor conjetura** (Montgomery, 2019). Puede ser un buen enfoque si el experimentador tiene la suficiente experiencia y base teórica como para hacer esa primera elección. Sin embargo, si los resultados que se obtienen en la primera conjetura son aceptables, se corre el riesgo de creer que es la opción óptima sin haber probado otras alternativas (Montgomery, 2019).

Otro enfoque podría ser probar **un factor a la vez** (Montgomery, 2019). Este método consiste en seleccionar un punto de partida con una determinada combinación de factores e ir cambiando los niveles de uno a la vez mientras los otros se mantienen constantes. El inconveniente con este enfoque es que puede pasarse por alto un efecto de interacción entre los distintos factores. Por ejemplo, que el botón de color naranja solo incremente la tasa de conversión en un 10 % y que el texto “Reserve ahora” la incremente en un 12 %, pero que la combinación de ambos genere una caída del 8 %.

Cuando hay varios factores, el enfoque correcto es un **diseño factorial** (Montgomery, 2019). En un diseño de este tipo, se va haciendo variar a los factores de forma simultánea. Un diseño factorial 2^2 es un diseño con dos factores, dos niveles cada factor. En este caso, podrían probarse las variantes:

- Botón azul + texto “Reserve ahora”.

- Botón naranja + texto “Reserve ahora”.
- Botón azul + texto “Reserve su lugar”.
- Botón naranja + texto “Reserve su lugar”.

Un diseño de este tipo permitirá al experimentador analizar los efectos individuales de cada factor, así como los posibles efectos de la interacción entre estos.

Se puede observar que en esta clase de diseño el número de variantes a testear escala rápidamente a medida que aumenta la cantidad de factores. Por ejemplo, un experimento con diez factores a dos niveles cada uno requeriría testear 1024 variantes (resultado que se consigue al elevar 2^{10}). Montgomery (2019) afirma que, si hubiera cuatro o más factores, puede resultar innecesario testear todas las combinaciones. En estos casos, se emplea un **diseño factorial fraccionado** (método Taguchi), en el que dieciséis variantes a testear (2^4) pueden transformarse en ocho (2^{4-1}). Sin embargo, esta alternativa de diseño factorial deberá aplicarse cuidadosamente ya que sus resultados son aproximados.

3.1.1. Test de hipótesis

Básicamente, una hipótesis es una explicación anticipada de un fenómeno o de una situación a la que nos enfrentamos. Cuando ha sido testeada y confirmada, se puede transformar en una tesis y, por ende, se transforma en una conclusión.

Es por ello que normalmente decimos que la hipótesis es el interrogante que queremos verificar, aunque enunciado como una conclusión.

En ese sentido, veamos un ejemplo sumamente sencillo de un proyecto de *marketing*. Queremos establecer la respuesta a la pregunta sobre cómo influye la atención al cliente sobre la posible recompra.

Para desarrollar una hipótesis, debemos plantear una conclusión que queremos verificar. Podríamos decir entonces: los clientes que han recibido una atención satisfactoria tienen más posibilidades de volver a comprar que aquellos que no la recibieron.

Como vemos, ya tenemos la posibilidad de verificar, a través de un experimento, si esa hipótesis se confirma o se rechaza.

Barrionuevo (2020) sigue las propuestas de Kerlinger y Lee (2002) para establecer algunas características de una buena hipótesis:

- Siempre se presentan como enunciados declarativos y relacionan variables con variables (independientes y dependientes).
- Debe expresarse una relación entre variables.
- Debe ser enunciada de manera clara y sin ambigüedades.
- Debe poder someterse a una prueba empírica.
- Contiene implicaciones claras para probar las relaciones enunciadas.
- Importancia de problemas e hipótesis.
- Es posible someter a pruebas a la hipótesis y demostrar que es probablemente verdadera o falsa. No se prueban hechos aislados sino relaciones.
- Pueden probar ser probablemente correctas o incorrectas de manera independiente a los sesgos de las personas. (Barrionuevo, 2020, p. 36).

Para desarrollar de manera apropiada una hipótesis sobre nuestros planes de investigación, debemos seguir ciertos pasos que nos facilitarán el trabajo en el momento de la verificación.

Figura 3. Desarrollo de hipótesis



Fuente: Paz, 2020, p. 64.

En un test de hipótesis, se parte de una teoría por defecto (Wasserman, 2004). La teoría por defecto en CRO es que el cambio que se propone no generará modificaciones en la tasa de conversiones.

Por ejemplo, si se desea probar que determinado tamaño de CTA mejora la tasa de conversión, la teoría por defecto será que todos los posibles tamaños de CTA generan igual tasa de conversión. Esta teoría es llamada hipótesis nula. La hipótesis alternativa será, entonces, que existe algún tamaño de CTA que genera una tasa de conversión distinta.

El test será una regla que determine si los datos reunidos presentan evidencia suficiente para rechazar la hipótesis nula. Si la evidencia no fuera suficiente, se

retiene la hipótesis nula (Wasserman, 2004). Ahora bien, cabe preguntarse: ¿cuánta evidencia es suficiente?

3.1.2. Tipos de error, significancia estadística y potencia del test

En la decisión de rechazar o no la hipótesis nula, existe una probabilidad de cometer error. La siguiente figura muestra las cuatro situaciones posibles.

Figura 4. Tipos de error

	La hipótesis nula es verdadera	La hipótesis nula es falsa
No se rechazó la hipótesis nula	No hay error	Error de tipo 2
Se rechazó la hipótesis nula	Error de tipo 1	No hay error

Fuente: adaptado de Boente y Yohai, 2006.

Según Boente y Yohai (2006), se puede incurrir en dos tipos de error:

Error de tipo 1: es el que se comete al rechazar la hipótesis nula, siendo esta verdadera. La probabilidad de cometer este error se llama **nivel de significancia** y se denota con la letra griega alfa (α).

En CRO, la hipótesis nula generalmente queda definida como "la variante A y la variante B generan igual tasa de conversión". En este sentido, el nivel de significancia será la probabilidad de que, siendo esto cierto, es decir, que ambas realmente consigan igual tasa de conversión, el resultado del test conduzca a rechazar dicha teoría. Es decir que, cuando se rechace la hipótesis nula y cuanto

más pequeño sea el nivel de significancia con el que se rechaza, menor será la probabilidad de haber cometido un error.

Su complemento ($1-\alpha$) se denomina **nivel de confianza** y es la probabilidad de que no haya error, es decir, de que no se rechace la hipótesis nula cuando esta sea verdadera.

Error de tipo 2: es el que se comete al no rechazar la hipótesis nula, siendo esta falsa. La probabilidad de cometer este error se denota con la letra griega beta (β).

Su complemento ($1-\beta$) se denomina **potencia del test** y es la probabilidad de que no haya error, es decir, de que se rechace la hipótesis nula siempre que esta sea falsa.


Boente y Yohai (2006) afirman que un buen test requiere tener errores de tipo 1 y 2 bajos. Sin embargo, los autores agregan que ambos errores no pueden hacerse pequeños de forma simultánea. Para que la probabilidad de que ocurra un error de tipo 1 sea menor, se deberá aumentar la probabilidad de cometer un error de tipo 2 (disminuir la potencia). Si se quiere que ambos sean pequeños, la solución será aumentar el tamaño de la muestra (Boente y Yohai, 2006).

¿Cuál de los dos errores es más grave? Según la teoría clásica de test de hipótesis, será más grave cometer un error de tipo 1, es decir, rechazar la hipótesis nula cuando esta sea verdadera. Para evitar esta situación, se buscará tener mucha evidencia antes de rechazar la hipótesis.

3.1.3. Determinación del objetivo y el área a testear

En el diseño del experimento, lo primero es establecer el **objetivo a testear**. El mismo debe ser coherente con los objetivos de CRO previamente identificados (Goward, 2013).

Figura 5. Objetivos a testear



Fuente: elaboración propia.

Como vemos en la figura anterior, debemos analizar cuáles serán los objetivos de negocio para luego detectar las oportunidades de optimización, las métricas que nos permiten validar resultados y las variables que debemos testear.

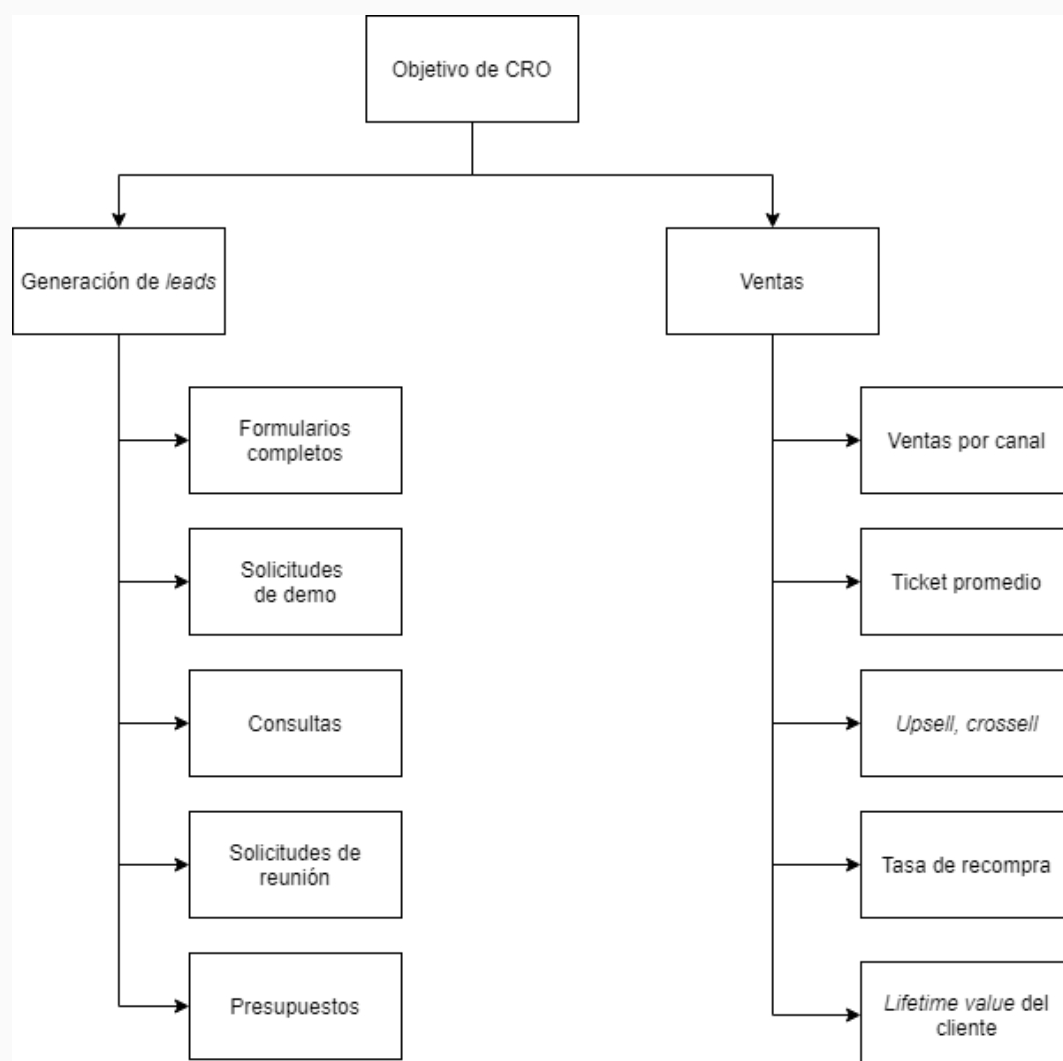
Los objetivos que se fijan pueden ser muy diversos. Goward (2013) explica que, si el objetivo de CRO es la generación de *leads*, las métricas de las pruebas pueden ser el conteo de formularios de contacto completados, de solicitudes de demo, llamada o reunión; conteo de registros para una conferencia o para un *webinar*; conteo de descargas de un caso de estudio, *e-book* o folleto digital; cantidad de encuestas completadas; y número de nuevos suscriptores a un *newsletter*, entre otros.

Por otro lado, si el objetivo de CRO es de comercio electrónico, el autor recomienda testear métricas como la tasa de conversiones por dicho canal de venta, el valor medio de una transacción, el retorno de la inversión (ROI) o el ingreso por usuario. Goward (2013) también menciona como posibilidad la de incluir métricas que indiquen que el usuario estuvo a punto de realizar la compra, como puede ser añadir un producto a la lista de deseos o añadir un producto al carro. También podría considerarse que los usuarios están interesados en una

futura compra si realizan alguna de las acciones mencionadas en los objetivos de generación de *leads*.

Además de estos objetivos comunes, pueden ser objetivos del test las métricas más específicas de cada negocio y de cada sitio.

Figura 6. Ejemplos de métricas a testear



Fuente: elaboración propia.

Una vez establecidos los objetivos, es necesario definir el **área a testear**. Goward (2013) explica que el test puede ser tanto en una única página del sitio como en

una sección que se repita en varias páginas, en un micrositio o en una serie de páginas.

El autor explica que un micrositio es un sitio web con entre tres y diez páginas creadas con un objetivo puntual como puede ser presentar un grupo de productos o una campaña de *marketing* que requiera un diseño diferente al del resto del sitio. Los micrositos pueden resultar excelentes oportunidades de testeo (Goward, 2013).

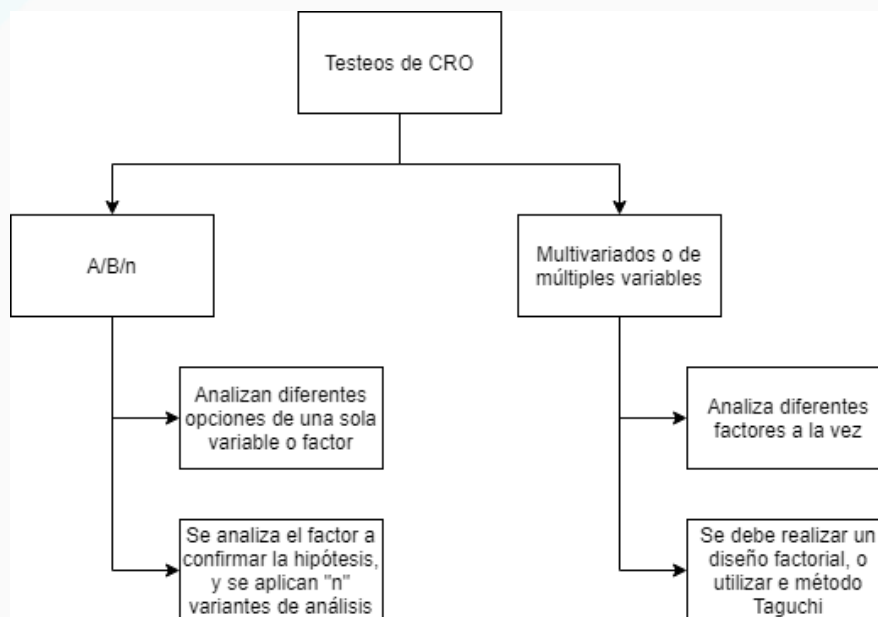
Cuando se quiere evaluar la claridad de la disposición de los elementos en el sitio en general o la propuesta de valor global, el test se lleva a cabo al nivel de la **plantilla del sitio** (*template*). Goward (2013) destaca que estas pruebas se completan con mayor rapidez porque un gran volumen de visitantes está expuesto a la plantilla y, por lo tanto, puede formar parte de la muestra. Además, agrega que, si todas las páginas se basan en la misma plantilla y tienen la misma disposición de elementos, la experiencia en el sitio tendrá mayor consistencia.

Por otro lado, si se desea evaluar la *performance* de una página individual con mucho tráfico y cuyo contenido es único, convendrá limitar el área del test a dicha página. Si bien el volumen de tráfico puede ser menor a una página individual, se trata de un test más directo que permitirá evaluar el contenido específico de un producto, servicio o de algún tema puntual (Goward, 2013).

3.1.4. Tipo de test: multivariado vs. A/B/n testing

En CRO se suelen llevar a cabo test A/B/n y test multivariados (MVT por sus siglas en inglés).

Figura 7. Test de CRO



Fuente: elaboración propia.

Los test A/B/n son aquellos en los que se analiza una única variable. Por ejemplo, si se quiere corroborar la hipótesis nula "el tamaño del CTA no afecta a la tasa de conversión", la variable a testear será el tamaño del CTA. Podrían analizarse dos tamaños distintos: A y B. Si se testean cinco tamaños como A, B, C, D y E, la prueba seguirá siendo un test A/B/n.

En un test multivariado, en cambio, se testean dos o más variables (factores). Se trata de un diseño factorial que considera los distintos niveles de cada factor y sus posibles interacciones. Por ejemplo, si se quiere testear la hipótesis nula "el tamaño y el color del CTA no afectan a la tasa de conversión", las variables a testear son tamaño y color de CTA. Si se testean dos tamaños y dos colores (dos niveles de factor en cada caso), las variantes a testear tendrán que ser cuatro (diseño factorial 2²) para contemplar todas las posibles interacciones.

Cabe preguntarse entonces, ¿cuál de los dos tipos de test es mejor? Para dar respuesta a esta pregunta, Chris Goward (2013) recomienda considerar principalmente el volumen mensual del tráfico al sitio. Si es bajo, será preferible tener pocas variantes por test para obtener conclusiones en menos tiempo. El autor explica que, para alcanzar la significancia estadística, como regla general, se requerirán entre 100 y 400 conversiones por variante. En este sentido, un diseño

factorial (MVT) presenta el inconveniente de que a medida que se agregan factores y niveles de factor, las variantes a testear escalan con rapidez, volviéndose el test lento y complejo de efectuar (Goward, 2013).

Una variante del MVT es el método Taguchi. Se trata de un diseño fraccional factorial que reduce el número de variantes a testear, procurando alcanzar conclusiones similares a las del método factorial completo. Para ello, el programa testeará algunas de las combinaciones y realizará suposiciones acerca de cómo se comportarán las que no sean sometidas al test (Goward, 2013). El autor recomienda que este método se aplique con sumo cuidado y que sus resultados se apoyen con otros test A/B/n.

Para Goward, algunas ventajas del MVT (completo) incluyen:

- Permite comprender fácilmente los efectos individuales de pequeños elementos aislados del sitio en la tasa de conversión.
- Facilita la identificación de efectos compuestos resultantes de la interacción entre elementos independientes.
- Representa un camino más conservador hacia un CRO incremental.
- Devuelve información estadística que avala la existencia de efectos de interacción entre los elementos.

Entre las desventajas que este diseño tiene frente a un test A/B/n, el autor distingue:

- Más variantes a testear.
- Mayor volumen de tráfico requerido para alcanzar resultados estadísticamente significativos.
- Imposibilidad de realizar cambios más grandes en la disposición de los elementos.
- Debido a que se pondrán a prueba todas las combinaciones posibles, cada nivel de los factores debe guardar coherencia o sentido con todos los

niveles de los factores restantes. De esta forma, las posibilidades del experimentador se encuentran limitadas.

En relación al test A/B/n, Goward (2013) destaca que se trata de un diseño menos dependiente de tecnología avanzada para su implementación. Entre sus ventajas, el autor distingue:

- Libertad en los distintos niveles del factor a testear.
- Posibilidad de realizar cambios grandes de disposición de los elementos o de la propuesta de valor.
- Mayor velocidad para completar el test.
- Los incrementos obtenidos en la tasa de conversión suelen ser más grandes.
- Permite utilizar herramientas avanzadas de análisis para cada variante.
- En este tipo de test, los elementos individuales pueden ser separados del resto, así como sus interacciones (aunque con mayor dificultad).

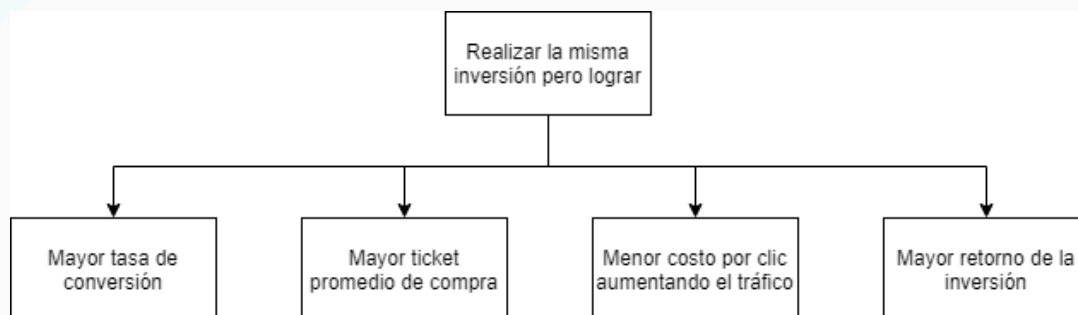
El autor manifiesta que, si bien lo óptimo es llevar a cabo ambos tipos de pruebas, el énfasis debe estar puesto en el test A/B/n.

Unidad 3.2. Implementación

La implementación de un test de optimización de conversiones hace unos años requería de elevados conocimientos en estadística, sin embargo, “hoy las herramientas disponibles hacen que los encargados de *marketing* solamente requieran de un sitio web para optimizar y de grandes ideas” (Goward, 2013).

A la hora de implementar nuestro plan de CRO y de generar los test, nuestro ideal puede implicar alguna de las opciones que se ven en la figura siguiente.

Figura 8. Ideales del CRO



Fuente: elaboración propia.

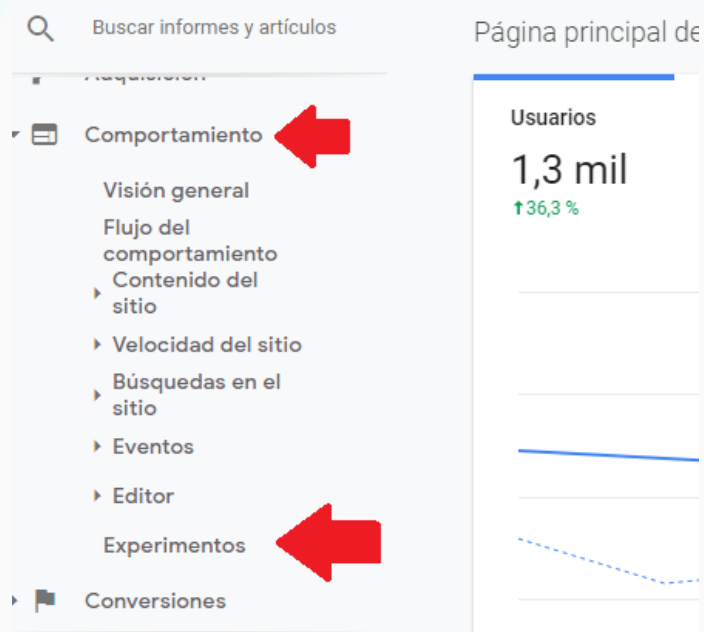
Es muy lógico esperar mayores resultados cuando invertimos más dinero. Ahora bien, el ideal del CRO es lograr mejores resultados sin mover la inversión o crecer exponencialmente en los resultados al mover la inversión.

3.2.1. Test A/B en Google Analytics

Para realizar el test A/B, Google Analytics pone a disposición un módulo de experimentos. Este módulo lleva a cabo un test de tipo A/B/n que permite evaluar la *performance* de hasta diez páginas (variantes) en un mismo test.

La figura siguiente muestra dónde se encuentra el menú para configurar el experimento en una cuenta de Google Analytics. La misma se realiza desde la pestaña "informes", en el menú "comportamiento, experimentos".

Figura 9. Configuración del experimento

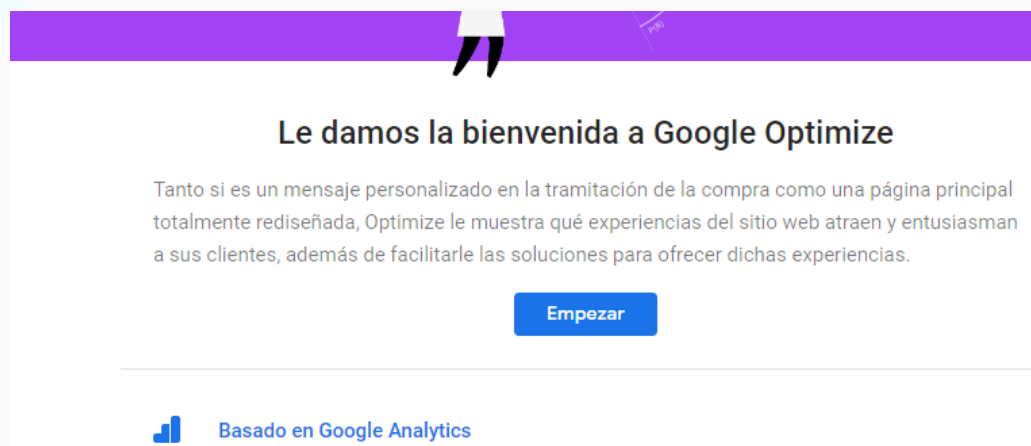


Fuente: captura de pantalla de Google Analytics, 2020, <https://n9.cl/krml>

En esta instancia, se supone que el experimentador ya identificó el objetivo del test, seleccionó la página que quiere mejorar, creó las variantes, se aseguró de que el código está correctamente incluido en las páginas que van a formar parte del test y determinó el porcentaje de visitantes que formarán parte de la prueba.

El experimento se configura en la herramienta Google Optimize. Podemos acceder a esta herramienta desde el mismo panel de Analytics o desde la plataforma específica <https://optimize.google.com/optimize/home>.

Figura 10. Experimentos en Google Optimize




Fuente: captura de pantalla de Google Optimize, 2020, <https://n9.cl/avy1z>

En el menú de experimentos, Google muestra un listado con todos los experimentos guardados, ya sea que estén en configuración, activos, detenidos o que hayan finalizado. Haciendo clic en los nombres de los experimentos se podrá hacer un seguimiento más detallado de estos. Allí se presenta un gráfico de la métrica objetivo para las variantes testeadas y una tabla resumen con las métricas de interés. Analytics indicará cuando se identifique una ganadora (en caso de que la encuentre).






El proceso en general es sencillo de implementar desde Optimize.

Figura 11. Menú de Google Optimize

Nombre * 0 / 255

¿Qué URL de la página quiere usar? Se denomina **página del editor**. * 
p. ej., <http://www.example.com> o www.example.com

¿Qué tipo de experiencia quiere crear?

-  **Prueba A/B**
Prueba dos o más variantes de una página. También se conoce como prueba A/B/n. [Más información](#)
-  **Prueba multivariable**
Prueba variantes con dos o más secciones diferentes. [Más información](#)
-  **Prueba de redirección**
Prueba páginas web diferentes identificadas por URL o rutas distintas. [Más información](#)
-  **Personalización**
Personalice su página para los visitantes objetivo. [Más información](#)
-  **Plantilla de banner**
Añada un banner de notificaciones a la parte superior de su sitio web. [Más información](#)

Fuente: captura de pantalla de Google Optimize, 2021, <https://n9.cl/avy1z>

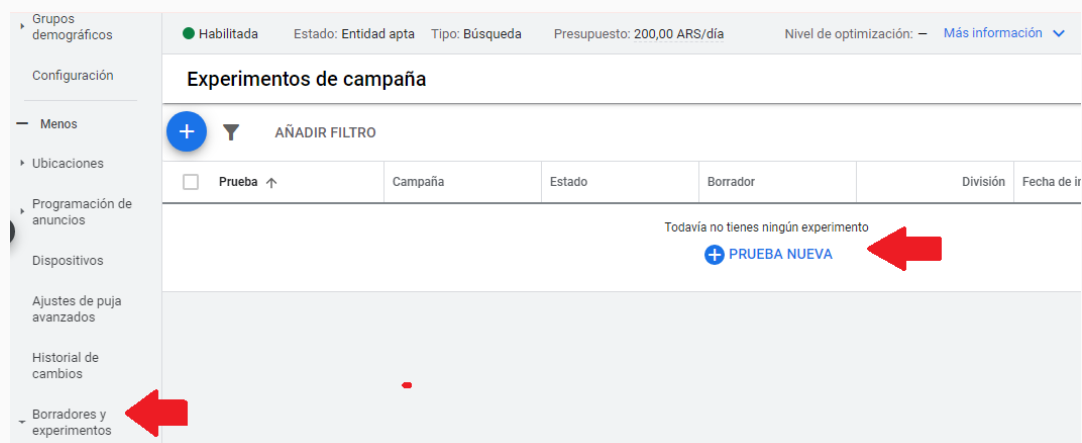
Como vemos en las opciones, Google nos permite realizar experimentos con pruebas A/B, multivariables, de redirección y otras opciones de personalización del contenido.

3.2.2. Test A/B en Google Ads

Google Ads será apropiado como herramienta de testeo cuando se busque optimizar la tasa de conversión de este canal de pago. De lo contrario, se estarán excluyendo del análisis los canales de tráfico no pagos. Esta omisión puede conducir a conclusiones erradas, especialmente cuando nuestro tráfico orgánico es relevante.

En caso de ser apropiado, la configuración de un experimento en Google AdWords inicia desde la campaña en la que se realizará la prueba, en la pestaña de "configuración" y el apartado "configuración avanzada". La figura siguiente muestra las opciones de configuración avanzada.

Figura 12. Configuración avanzada de campaña



Fuente: captura de pantalla de Google Ads, 2020, <https://n9.cl/98p9q>

Los cambios experimentales se pueden llevar a cabo sobre las pujas, las palabras clave, los grupos de anuncios y los anuncios de la campaña.

La variante o versión mejorada que se quiere contrastar con la versión actual (control) se define seleccionando la opción "experimento solo" en las pujas, las palabras clave, los grupos de anuncios o los anuncios que se desee testear. Si, por ejemplo, se piensa que añadir tres palabras claves a un grupo de anuncios puede modificar la *performance* general del grupo, entonces se configuran estas tres como "experimento solo" y se evalúan los resultados del grupo de anuncios de control (sin estas tres palabras) versus el grupo experimental (que sí las incluye).

Para indicar si hay o no significancia estadística en las diferencias encontradas entre control y experimento, Google Ads utiliza flechas hacia arriba o hacia abajo. Dos flechas de color gris en direcciones opuestas indican que los resultados no son estadísticamente relevantes.

Cuando las diferencias son significativas, Google Ads utiliza flechas de color azul hacia arriba o hacia abajo, según si el experimento aumentó o disminuyó para

cada métrica. Más flechas en la misma dirección indican más evidencia disponible para afirmar que las variantes “control” y “experimento” son diferentes: habrá una, dos o tres flechas en la misma dirección cuando el nivel de significancia sea del 5 %, 1 % o del 0.1 % respectivamente.

Cabe destacar que “cuanta más relevancia estadística tengan los resultados, mayor será la probabilidad de que los resultados del experimento perduren en caso de aplicar los cambios experimentales a la campaña” (Google Ads, 2020, <https://n9.cl/98p9q>).

El experimento demorará más o menos en obtener resultados estadísticamente relevantes de acuerdo al volumen de tráfico generado por las palabras claves, anuncios o grupos de anuncios.

Una limitación de esta herramienta es que analiza siempre un control y un experimento, sin poder añadir más variantes en el test. Tampoco admite la posibilidad de implementar test multivariantes que contemplen las interacciones entre los factores.

3.2.3. Test A/B en Facebook Ads

El Business Manager de Facebook es una herramienta que permite gestionar diversos activos de nuestro comercio relacionados a la plataforma de Facebook e Instagram.

Como la misma empresa lo define:

El administrador comercial es una solución integral para administrar todas tus actividades de *marketing* y publicidad en Facebook. Está diseñado para empresas de todos los tamaños, te permite crear anuncios, administrar varios activos, como páginas de Facebook y perfiles de Instagram, y compartir fácilmente esos activos con tu equipo y socios externos. (Facebook, 2020, <https://n9.cl/s0rmy>).

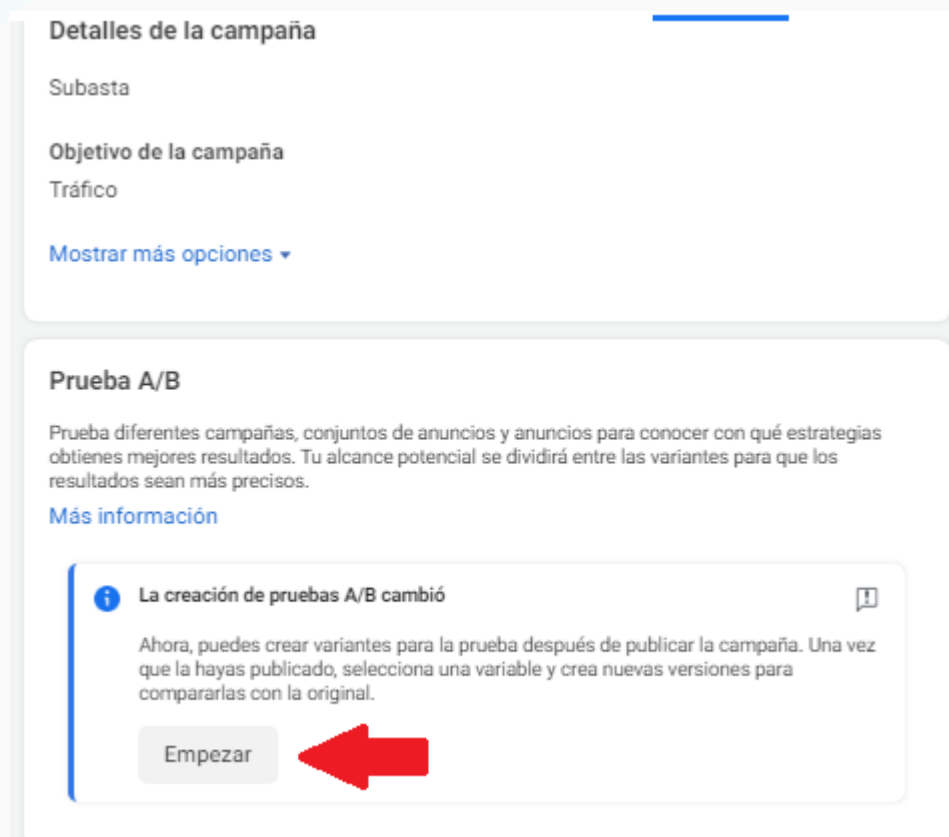
Este administrador incluye una gran variedad de herramientas de trabajo para promocionar nuestro negocio.

Nos permite acceder al ámbito de los experimentos (el espacio que nos permite crear pruebas A/B y otros experimentos) para conocer qué anuncios dan mejores resultados para nuestro negocio.

Las pruebas A/B te permiten modificar variables del anuncio, como el contenido, el público y la ubicación, para determinar qué estrategia tiene mejor rendimiento y mejorar las campañas a futuro. Por ejemplo, quizá tengas la hipótesis de que una estrategia de público personalizado tendrá un mejor rendimiento en tu negocio que una de público basado en intereses. La prueba A/B te permite comparar rápidamente las estrategias para determinar cuál funciona mejor.

Una vez que elijas la variable que quieres poner a prueba, dividiremos el presupuesto para mostrar de manera uniforme y aleatoria cada versión del contenido, el público o la ubicación. La prueba A/B medirá el rendimiento de cada estrategia en términos de costo por resultado o de costo por aumento de las conversiones con una exclusión. (Facebook, 2020, <https://n9.cl/s0rmy>).

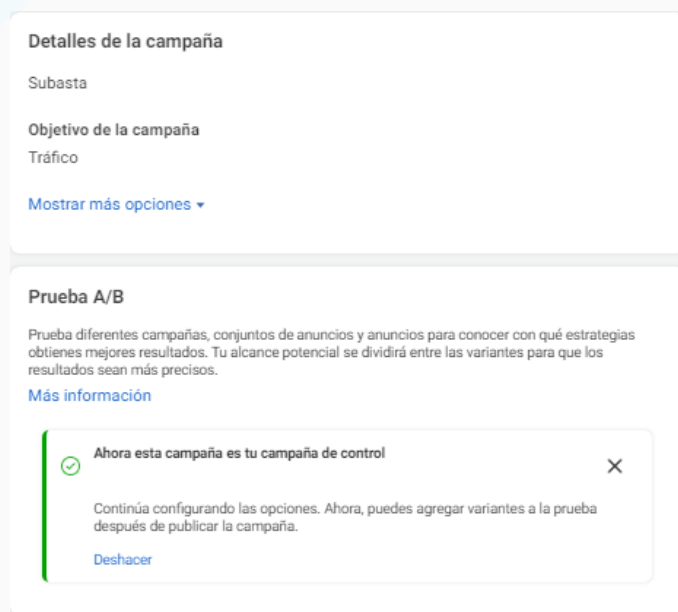
Figura 13. Pruebas A/B en el administrador de anuncios



Fuente: captura de pantalla de Facebook for Business, 2020, <https://n9.cl/s0rmy>

A nivel de campaña, seleccionamos la opción de empezar una prueba A/B. Luego, esto nos permitirá generar variantes y testeos para poder analizar qué variante logra mejor *performance*.

Figura 14. Pruebas A/B. Campaña de control



Fuente: captura de pantalla de Facebook for Business, 2020, <https://n9.cl/s0rmy>

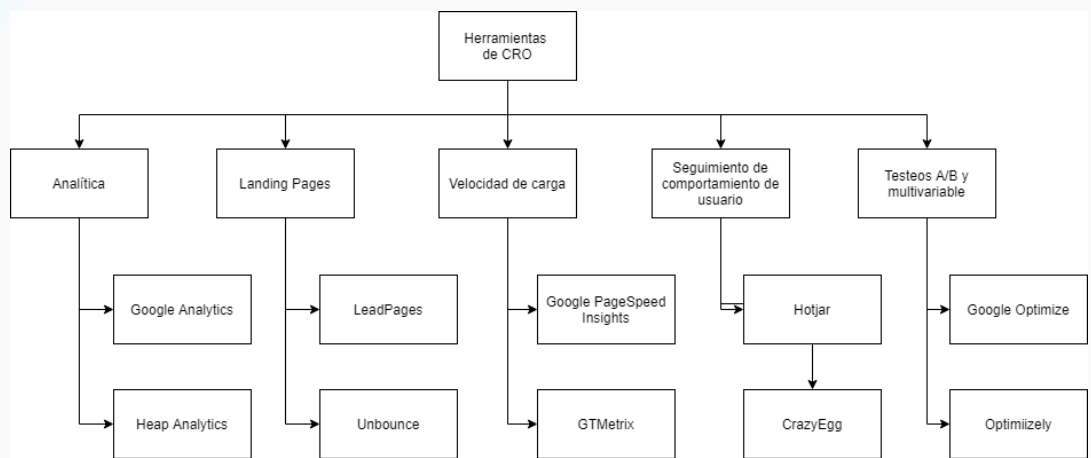
3.2.4. Otras herramientas de CRO

En algunos casos, bastará experimentar usando herramientas gratuitas. Sin embargo, cuando se incremente la complejidad de las pruebas, puede que sea conveniente realizar una inversión. En ese caso, la decisión de la herramienta apropiada cobrará mayor importancia.

Esta decisión estará relacionada al campo de aplicación: un sitio web, una campaña de *email marketing*, un anuncio en buscadores, etcétera.

Existen múltiples herramientas para trabajar. En la mayoría de los casos, la selección dependerá de lo que buscamos optimizar.

Figura 15. Herramientas de CRO



Fuente: elaboración propia.

Referencias

Barrionuevo, D. (2020). *La importancia de los datos para tomar decisiones*. Unquillo: Social Media Trends.

Boente, J. y Yohai, V. (2006). *Notas de estadística*. Buenos Aires: UTN.

Facebook for Business (2020). Servicio de ayuda para empresas. Recuperado de:
<https://www.facebook.com/business/help/2343035149322466?id=1077620002609475>

Google (2021). **Google Optimize**. Recuperado de:
<https://optimize.google.com/optimize/home>

Goward, C. (2013). *You should test that: conversion optimization for more leads, sales and profit or the art and science of optimized marketing*. New York: Wiley.

Kerlinger, F. y Lee, H. (2002). *Investigación del comportamiento*. México: McGraw Hill.

Montgomery, D. (2019). *Design and analysis of experiments*. Nueva York: Wiley.

Paz, G. (2020). *Marketing intelligence*. Córdoba: Capabilia.

Wasserman, L. (2004). *All of statistics: a concise course in statistical inference*. Nueva York: Springer.