



Módulo 4. Experimentación y atribución moderna

☰ 1. Diseño y gestión de experimentos en entornos growth

☰ 2. Modelos actuales de atribución

☰ Referencias

1. Diseño y gestión de experimentos en entornos growth

En entornos donde las decisiones estratégicas se apoyan en datos, la posibilidad de experimentar con agilidad se vuelve una ventaja operativa relevante. El enfoque *data-driven growth*, abordado en el módulo anterior, sienta las bases para observar el comportamiento en tiempo real, identificar patrones y actuar con menor incertidumbre. Esta lógica analítica habilita un paso siguiente: no solo interpretar lo que ocurre, sino intervenir activamente para descubrir qué acciones generan impacto, en qué condiciones y con qué efectos medibles.

El diseño de experimentos se convierte así en una herramienta estructural dentro de los equipos de *growth*. Permite transformar hipótesis en pruebas concretas, establecer prioridades basadas en impacto y esfuerzo, y coordinar procesos iterativos de aprendizaje. Cada experimento no solo busca mejorar una métrica puntual, sino aportar evidencia para decidir con mayor precisión en

ciclos futuros. En contextos de alta variabilidad, donde las decisiones tradicionales resultan insuficientes, esta capacidad de prueba y ajuste continuo se vuelve parte del funcionamiento cotidiano.

El trabajo experimental requiere una lógica de gestión específica. No alcanza con tener ideas ni con ejecutar acciones aisladas. Es necesario organizar hipótesis, seleccionar criterios de evaluación, ordenar iniciativas según impacto esperado y documentar resultados para sostener un aprendizaje acumulativo. Para ello, existen modelos de priorización y estructuras operativas que permiten canalizar la experimentación como un proceso sistemático, no como una práctica espontánea o fragmentaria.

En esta unidad se abordarán los componentes fundamentales de ese proceso: la formulación de hipótesis accionables, el uso de *frameworks* como ICE y PIE para priorizar experimentos, y la construcción de un backlog que facilite su gestión. Estos recursos permiten que los equipos avancen desde la intuición hacia un sistema de decisiones que se valida en la práctica. La experimentación deja así de ser una opción eventual y se transforma en una dinámica sostenida de mejora continua.

Hipótesis de growth —

En el módulo 1 se introdujo el proceso de *growth hacking* como una secuencia de trabajo orientada a la experimentación ágil y medible. A través de cinco etapas —definir objetivos, generar ideas, formular hipótesis, ejecutar experimentos y analizar resultados—, los equipos de *growth* construyen un circuito de mejora continua que permite intervenir productos digitales con base en datos, evidencias y aprendizajes acumulados. Este marco se retoma en esta unidad para profundizar en el segundo momento del proceso: la transformación de ideas en hipótesis concretas.

El paso de una idea a una hipótesis supone un salto metodológico que permite vincular una intuición con una afirmación estructurada, pasible de ser contrastada mediante un experimento. Esta transición convierte lo que podría ser una ocurrencia aislada en una intervención diseñada para ser medida, evaluada y eventualmente escalada. En este sentido, formular hipótesis aporta claridad sobre lo que se busca lograr y permite anticipar las condiciones bajo las cuales esa acción será considerada exitosa.

Para que una hipótesis resulte operativa, debe construirse con un conjunto mínimo de componentes: **la variable que se desea intervenir, la acción que se implementará, el segmento al que se aplicará, el resultado esperado y la métrica que permitirá evaluarlo**. Cada uno de estos elementos cumple una función específica en la planificación del experimento, ya que delimita el alcance de la intervención, orienta el tipo de análisis a realizar y facilita la comparación entre distintas hipótesis en cartera.

Una forma habitual de estructurar hipótesis es mediante la siguiente fórmula:

«Si hacemos [acción] en [segmento], entonces [resultado esperado] debería mejorar, medido por [métrica]».

Por ejemplo:

«Si destacamos el beneficio principal en la pantalla inicial para nuevos usuarios del segmento X, entonces aumentará la tasa de activación, medida por el porcentaje que completa el registro».

Esta estructura no solo estandariza la formulación, sino que facilita la lectura colectiva y la toma de decisiones dentro del equipo. Además, permite construir documentación útil para futuras etapas del proceso: los experimentos implementados, sus condiciones y sus resultados pueden registrarse de manera consistente y compararse en retrospectiva, incluso si cambian las personas que integran el equipo.

En el abordaje de *growth*, trabajar con hipótesis permite intervenir el producto de forma deliberada y basada en suposiciones explícitas. Este enfoque resulta especialmente útil cuando se requiere evaluar múltiples caminos posibles para resolver un mismo problema o cuando se busca priorizar acciones de alto impacto con recursos limitados. En lugar de desplegar múltiples cambios simultáneos sin foco claro, se testean hipótesis puntuales que permiten identificar qué funciona, en qué condiciones y para quién.

Un experimento de *growth* no comienza cuando se lanza la prueba, sino en el momento en que se formula la hipótesis. Esa formulación es la que define qué variable se manipula, qué comportamiento se espera observar y qué dato permitirá tomar decisiones al

respecto. Por eso, cuanto más preciso y específico sea el enunciado, mayor será su capacidad para orientar el diseño experimental, delimitar el análisis y facilitar aprendizajes aplicables.

Existen diferentes formas de clasificar las hipótesis según el momento del recorrido del usuario al que apuntan. Algunas se orientan a mejorar la adquisición (atraer nuevos usuarios), otras a optimizar la activación (lograr que esos usuarios tengan una primera experiencia satisfactoria), otras a fomentar la retención (incrementar la recurrencia de uso), otras a estimular la viralidad (promover que los usuarios compartan el producto) y otras a mejorar la monetización (aumentar ingresos por usuario).

También es posible categorizar las hipótesis por su foco táctico. Algunas buscan intervenir el contenido (como modificar un mensaje, una imagen o un llamado a la acción), otras modifican aspectos de diseño (como el orden de una pantalla o el tamaño de un botón), otras exploran alternativas de canal (como testear una campaña en una red nueva), y otras proponen cambios de segmentación (como dirigirse a usuarios que cumplan determinados criterios de comportamiento reciente).

La siguiente tabla organiza ejemplos frecuentes de hipótesis según estas categorías, con formulaciones operativas que pueden adaptarse a diferentes contextos de trabajo. Esta organización permite visualizar cómo se aplican en la práctica y qué variables se consideran al momento de diseñarlas.

Tabla 1. Tipos de hipótesis de *growth* con ejemplos operativos

Tipo de hipótesis	Variable a modificar	Acción específica	Resultado esperado	Métrica de éxito	Segmento objetivo
Adquisición	Canal de tráfico	Activar campaña en TikTok con targeting por intereses	Aumentar el tráfico calificado	Sesiones desde campaña	Usuarios nuevos segmento Z
Activación	Experiencia inicial	Simplificar formulario de registro	Aumentar tasa de activación	Porcentaje que completa el registro	Usuarios móviles segmento Y

Retención	Comunicación	Enviar recordatorios personalizados por correo	Incrementar usuarios activos semanales	WAU (<i>weekly active users</i>)	Usuarios que realizaron 1 compra
Viralización	Incentivo de referidos	Ofrecer beneficio por invitar a un amigo	Aumentar tasa de recomendación	Porcentaje de usuarios que generan referidos	Usuarios activos últimos 30 días
Monetización	Pantalla de precios	Destacar planes anuales con descuento	Aumentar upgrades a planes pagos	Conversión a plan pago	Usuarios activos en el último mes

Fuente: elaboración propia

El uso de esta estructura no solo ordena el diseño de experimentos, sino que mejora la calidad de los aprendizajes. Cuando se trabaja con hipótesis explícitas, es más fácil identificar si una acción tuvo el efecto esperado, si el resultado se explica por una variable externa o si conviene reformular la intervención para futuras iteraciones. Esto fortalece la lógica de prueba y ajuste que sustenta el enfoque de *growth*.

Además, la formulación de hipótesis permite establecer prioridades de forma objetiva. En lugar de elegir acciones por consenso o urgencia, se puede construir un backlog de hipótesis ordenado por su impacto estimado, facilidad de implementación o grado de riesgo. Esto facilita una gestión más eficiente del tiempo y de los recursos disponibles, al enfocarse en las pruebas con mayor potencial de aprendizaje.

En los equipos maduros en esta práctica, el uso de hipótesis se extiende más allá del diseño experimental. También permite estructurar retrospectivas, comunicar decisiones estratégicas y construir conocimiento colectivo. Cuando se documentan las hipótesis validadas (o invalidadas) y se comparten con otras áreas del equipo, se fortalece la capacidad de aprendizaje organizacional.

Incluso cuando una hipótesis no se confirma, el resultado sigue siendo útil. El experimento permite descartar una vía de acción, detectar patrones no previstos o reformular el

problema original desde una nueva perspectiva. En este sentido, el foco no está en tener razón, sino en generar información confiable que permita avanzar con mayor claridad.

Trabajar con hipótesis habilita un ejercicio sistemático de prueba y evaluación en el que cada afirmación se convierte en una oportunidad de aprendizaje. Esta forma de operar permite medir el impacto de una intervención, interpretar sus efectos y priorizar acciones con base en evidencia. A partir de esta lógica, se hace necesario contar con **criterios estructurados para comparar y priorizar hipótesis**, de modo que los recursos y esfuerzos se concentren en las iniciativas con mayor potencial de impacto. Los *frameworks* ICE y PIE son modelos conceptuales que apoyan esta priorización, facilitando la organización de experimentos y la toma de decisiones en entornos de *growth*.

Frameworks ICE y PIE

Una vez formuladas las hipótesis, el paso siguiente consiste en determinar cuáles deben ejecutarse primero. En contextos de *growth*, donde los recursos son limitados y el tiempo de validación es un factor estratégico, priorizar se vuelve una práctica clave. Para resolver esta necesidad, distintos equipos adoptan *frameworks* de decisión que permiten comparar hipótesis con criterios objetivos. Entre los más utilizados se encuentran ICE y PIE, dos modelos conceptuales que facilitan la organización del backlog y la

selección de experimentos con mayor probabilidad de generar impacto.

Ambos *frameworks* funcionan como matrices de puntuación que asignan valores a cada hipótesis según criterios específicos. Aunque comparten algunos fundamentos, difieren en sus ejes de análisis y en la forma de ponderar las variables consideradas. Estas diferencias impactan directamente en el orden de ejecución de las pruebas, por lo que resulta importante conocer las características de cada uno y evaluar su aplicabilidad según el contexto.

Tabla 2. Comparación entre los *frameworks* ICE y PIE para la priorización de hipótesis

Criterio	ICE	PIE
¿Qué mide?	Impacto esperado, grado de certeza y facilidad de ejecución	Potencial de mejora, relevancia del área y facilidad técnica
¿Para qué sirve?	Ordenar hipótesis según beneficio, evidencia previa y esfuerzo	Ordenar hipótesis según urgencia de mejora, valor estratégico y viabilidad

Fuente: elaboración propia

A continuación, se desarrollará cada *framework* por separado, con el objetivo de comprender cómo se aplican sus criterios, qué ventajas ofrecen y en qué

contextos resultan más adecuados para priorizar hipótesis dentro de un proceso de *growth*.

Modelo ICE: priorización ágil basada en impacto, certeza y ejecución

El modelo ICE es una herramienta utilizada para priorizar hipótesis o iniciativas dentro de procesos de crecimiento continuo. Su lógica permite ordenar propuestas de acción en función de tres variables:

Figura 1. Variables del modelo ICE



Esta metodología resulta especialmente útil cuando los equipos deben elegir entre múltiples caminos posibles y necesitan tomar decisiones basadas en

comparaciones consistentes.

Cada propuesta se puntúa del 1 al 10 según su potencial en cada una de estas dimensiones. El impacto evalúa cuánto puede contribuir la iniciativa a un objetivo concreto del negocio, como aumentar conversiones, mejorar la activación o reducir el abandono. La certeza considera cuánta evidencia hay disponible para respaldar la hipótesis: datos, pruebas anteriores o aprendizajes de otras experiencias. Finalmente, la facilidad estima el nivel de complejidad operativa: tiempo, esfuerzo técnico, recursos y dependencias involucradas.

A diferencia de otros modelos, ICE no propone una fórmula compleja, sino un criterio práctico de comparación. Las tres variables se **multiplican entre sí para obtener una puntuación total**. Es decir:

Puntuación ICE = Impacto × Certeza × Facilidad

Cuanto mayor sea ese puntaje, mayor será la prioridad relativa de esa idea en el *backlog*. Esto permite enfocar el trabajo en aquellas iniciativas con mejor combinación de impacto potencial, validación previa y viabilidad operativa.

Por ejemplo, si se plantea incorporar un tutorial al flujo de registro en una aplicación, podría asignarse un impacto de 9 (por su potencial de mejorar la activación), una certeza de 8 (basada en *feedback* y datos históricos) y una facilidad de 7 (porque el equipo ya ha implementado soluciones similares). Su puntuación sería **9 × 8 × 7 = 504**. En cambio, una propuesta para integrar un chatbot con inteligencia artificial podría tener impacto 8, certeza 6 y facilidad 4, resultando en un puntaje de **192**. En este escenario, el modelo sugiere avanzar con la primera iniciativa (Amoeboids, s.f.).

Este tipo de priorización permite identificar oportunidades que combinan alto valor con buena viabilidad. Su aplicación no requiere herramientas complejas ni grandes volúmenes de datos: basta con que el equipo acuerde criterios y puntúe de manera consistente. Por eso, resulta útil en procesos iterativos, donde se testean múltiples hipótesis en ciclos breves.

Utilizar el modelo ICE ayuda a reducir la subjetividad, facilitar conversaciones más claras y enfocar los recursos del equipo en aquellas acciones con mayor potencial de aprendizaje y resultados. En el siguiente apartado se presentará el modelo PIE, una alternativa complementaria para organizar y evaluar hipótesis cuando se busca intervenir sobre partes específicas del recorrido del usuario.

Modelo PIE para priorizar hipótesis de manera estructurada

El modelo PIE permite ordenar iniciativas de forma comparativa, asignando un puntaje a cada una según tres dimensiones evaluables. Esta lógica resulta especialmente valiosa en contextos de trabajo ágil, donde los equipos necesitan decidir con rapidez qué hipótesis testear, en qué orden y con qué nivel de esfuerzo. PIE ofrece una guía clara para tomar decisiones alineadas con el impacto esperado, la relevancia del punto de intervención y la viabilidad de ejecución.

Cada hipótesis se analiza según tres variables: **potencial**, **importancia** y **facilidad**. Al igual que el modelo ICE, estas dimensiones se puntúan en una escala del 1 al 10 y se consideran conjuntamente al momento de establecer prioridades. La fuerza del modelo PIE radica en su simplicidad y en su capacidad para reducir la carga subjetiva de las decisiones. A continuación, se presenta un esquema con la descripción de cada una de estas variables:

Figura 2. Variables del modelo PIE



La combinación de estas tres variables permite establecer una puntuación comparativa entre distintas propuestas. Si bien no existe una fórmula obligatoria, una práctica habitual es sumar o promediar los valores asignados para obtener una referencia general. Esta puntuación no pretende ser exacta, sino ofrecer una base objetiva para decidir con mayor claridad entre múltiples opciones viables.

Por ejemplo, si una hipótesis recibe puntajes de 8 en potencial, 9 en importancia y 7 en facilidad, se obtiene un total de 24 puntos. Si otra propuesta suma 21, la primera podría priorizarse en el backlog del sprint. Este método permite evitar debates abstractos o decisiones arbitrarias y, en su lugar, adoptar un enfoque basado en comparación sistemática (Sánchez, 2024).

El modelo PIE también resulta útil para alinear al equipo en torno a criterios compartidos. No se trata solo de evaluar propuestas, sino de generar un lenguaje común para discutir las. En vez de preguntarse «¿qué hacemos ahora?», se pregunta «¿qué tiene más potencial, mayor impacto estratégico y podemos ejecutar más fácilmente?». Esto facilita la coordinación y acelera los procesos de decisión.

Su aplicación no requiere herramientas especiales ni grandes volúmenes de datos. Alcanza con establecer pautas internas de puntuación y revisar con frecuencia los criterios utilizados. Por eso, el modelo PIE es ideal para equipos de producto, *marketing* o *growth* que operan en ciclos de mejora continua y necesitan priorizar sin fricción. En el próximo apartado, avanzaremos hacia el uso de estos criterios en la construcción y gestión de un backlog de experimentos.

Backlog y priorización de experimentos —

En procesos de *growth*, la generación constante de hipótesis alimenta un sistema iterativo de mejora continua. Estas hipótesis se organizan y priorizan dentro de una estructura operativa llamada *backlog* de experimentos. Este recurso permite concentrar las iniciativas en un solo lugar, establecer un orden claro para su ejecución y facilitar una conversación compartida sobre lo que se va a testear, por qué y en qué momento. De este modo, el *backlog* se convierte en un soporte clave para gestionar la experimentación de manera ágil, coordinada y basada en criterios objetivos.

El *backlog* funciona como una lista activa de ideas o hipótesis que aún no fueron ejecutadas, pero que se encuentran disponibles para ser priorizadas. Cada propuesta que se suma al *backlog* debe incluir información estructurada que permita evaluarla de forma comparativa. Por ejemplo, una descripción breve de la hipótesis, el objetivo que busca alcanzar, el segmento al que se dirige, la métrica principal que se utilizará para evaluarla, el canal o punto de contacto involucrado y el modelo de priorización que se aplicará para puntuarla. Esta estandarización asegura que el equipo pueda analizar múltiples iniciativas con una lógica común y actuar con rapidez frente a los resultados.

Uno de los beneficios centrales del *backlog* es que permite tomar decisiones fundamentadas sin depender de criterios subjetivos. Para lograrlo, los equipos utilizan modelos como ICE o PIE, que asignan puntajes a cada iniciativa en función de variables como impacto potencial, certeza o facilidad de ejecución. Estos modelos ofrecen una forma concreta de ordenar ideas según su valor estratégico y operativo. A partir de estas puntuaciones, se establece un orden de prioridad que permite avanzar primero con las iniciativas que combinan mayor proyección de resultado con menor complejidad de implementación.

A continuación, se presenta una tabla que ejemplifica cómo podría verse un *backlog* priorizado utilizando el modelo ICE. En este caso, cada hipótesis se evalúa según sus valores de impacto, certeza y facilidad, y se calcula una puntuación total que sirve como indicador de prioridad relativa.

Tabla 3. Ejemplo de *backlog* priorizado con modelo ICE

Hipótesis	Impacto	Certeza	Facilidad	Puntaje
-----------	---------	---------	-----------	---------

				ICE
«Si cambiamos el CTA en la página de producto para usuarios móviles, las conversiones deberían aumentar, medido por la tasa de clics»	8	7	9	504
«Si enviamos notificaciones push personalizadas a usuarios inactivos del segmento frecuente, la reactivación debería mejorar, medida por la tasa de retorno»	7	6	8	336
«Si testeamos dos versiones nuevas de la landing para nuevos visitantes, el porcentaje de registros debería incrementarse, medido por la tasa de conversión»	6	5	6	180
«Si personalizamos la home para mostrar primero la categoría más visitada por cada usuario, el tiempo promedio de sesión debería aumentar, medido en minutos»	9	6	7	378

Fuente: elaboración propia

Más allá del puntaje, el **backlog** también permite hacer seguimiento del estado de avance de cada iniciativa. Por eso, muchas versiones incorporan etiquetas que identifican si la hipótesis está pendiente de testeo, en curso, en análisis de resultados o ya fue descartada. Esta organización dinámica facilita el trabajo del equipo, asegura visibilidad sobre el flujo de experimentos y evita que se pierdan aprendizajes en el camino. Además, permite generar documentación valiosa para futuras decisiones, acumulando evidencia concreta sobre qué funcionó, en qué contexto y con qué resultados.

Con el paso del tiempo, el **backlog** deja de ser solo una lista de ideas y se transforma en una fuente de inteligencia operativa. No solo orienta qué hacer ahora, sino que refleja la

historia reciente de lo aprendido. Esta perspectiva evolutiva lo convierte en una herramienta estratégica que combina acción con reflexión. Al integrar documentación de hipótesis, puntajes, resultados y decisiones, el *backlog* se convierte en una base para seguir mejorando, ajustando y explorando nuevas oportunidades.

Por último, diversas plataformas digitales permiten sistematizar y escalar esta lógica. Herramientas como Notion, Trello, Airtable o Jira pueden adaptarse fácilmente como tableros de experimentación, integrando visualizaciones, criterios de priorización y campos personalizables según las necesidades del equipo. Esta flexibilidad tecnológica refuerza la cultura de experimentación continua, potencia la colaboración entre perfiles diversos y facilita que las decisiones respondan a evidencias concretas en lugar de suposiciones. En el siguiente apartado se abordará cómo medir el impacto de estas decisiones: el enfoque de atribución moderna.

CONTINUAR

2. Modelos actuales de atribución

Medir el impacto real de las acciones es una de las capacidades más valiosas dentro de cualquier estrategia de *growth*. Cuando una organización despliega múltiples iniciativas en simultáneo —como campañas de adquisición, mejoras en la conversión o estrategias de retención—, entender cómo cada una contribuye al resultado final no es solo una cuestión técnica: es una base necesaria para decidir con criterio. Por eso, los modelos de atribución se transforman en herramientas clave para orientar la inversión, ajustar el diseño de experiencias y aprender de lo que funciona.

La atribución busca responder una pregunta concreta: ¿qué acciones tuvieron más peso en la conversión de un usuario? A lo largo del recorrido, las personas interactúan con distintos canales, contenidos y puntos de contacto. Cada una de esas interacciones puede influir en mayor o menor medida en su decisión final. Analizar esa influencia permite no solo entender el pasado, sino también proyectar acciones futuras con mayor efectividad.

Durante años, muchos equipos operaron bajo el modelo de «último clic», que asigna todo el valor a la última interacción antes de una conversión. Si bien ese enfoque ofrecía simplicidad y rapidez, también dejaba fuera de análisis buena parte del recorrido real del usuario. En contextos de mayor complejidad —con recorridos fragmentados, múltiples dispositivos y decisiones menos lineales—, se vuelve necesario adoptar modelos que representen mejor esa realidad.

Hoy, los modelos de atribución más usados incluyen enfoques multicanal, algoritmos de asignación ponderada y pruebas específicas para aislar el efecto incremental de cada acción. Este paso hacia una mirada más integradora no implica mayor complejidad por sí misma: implica una lógica distinta para mirar el dato. Atribuir no es solo asignar mérito, sino entender cómo se construye un resultado.

En esta unidad vamos a explorar dos enfoques complementarios: por un lado, la lógica de *incrementality*, que permite evaluar qué parte del resultado se habría logrado igual sin determinada acción; y por otro, los límites del modelo «last click», que aún persiste en muchas herramientas pero ofrece una visión parcial del recorrido. Este análisis permite no solo medir mejor, sino también planificar con más precisión en contextos reales de experimentación y mejora continua.

Atribución moderna: *incrementality* y límites del *last click*


Medir correctamente qué canales, campañas o acciones generan valor es una condición fundamental para tomar decisiones informadas en cualquier estrategia de *growth*. Sin embargo, atribuir con precisión qué intervención produjo una conversión específica se vuelve cada vez más complejo. En un ecosistema digital saturado de

estímulos, con múltiples puntos de contacto entre usuario y producto, la relación entre causa y efecto ya no es lineal ni directa. Esto desafía los modelos tradicionales de medición y obliga a adoptar criterios más ajustados al comportamiento real de las personas.

La atribución busca responder una pregunta concreta: ¿qué contribuyó realmente a que una persona tomara una decisión? En un entorno donde los recorridos de usuario combinan dispositivos, canales y momentos distintos, esa pregunta no tiene una única respuesta. La decisión final puede ser el resultado de múltiples estímulos: un anuncio en redes, una búsqueda en Google, una campaña de *email*, una visita previa al sitio, una conversación con un chatbot o una recomendación externa. Ante esa diversidad de trayectorias, usar un modelo simplificado puede distorsionar gravemente el análisis.

Uno de los modelos más difundidos —y a la vez más problemáticos— es el modelo de atribución por «último clic». Este enfoque asigna el 100% del mérito de la conversión al último canal con el que el usuario interactuó antes de concretar una acción (por ejemplo, una compra o un registro). Aunque su lógica es sencilla y fácil de implementar, se basa en una suposición limitada: que el paso final fue el único determinante del resultado. En la práctica, esto deja fuera una parte significativa del recorrido. La siguiente imagen ilustra esta limitación.

Figura 3. Lógica del modelo de atribución por «último clic»



Fuente: Shopify, s.f., <https://goo.su/t4dx>

En este caso, un usuario primero interactúa con un anuncio en Facebook, luego realiza una búsqueda en Google, más tarde recibe un correo electrónico (por ejemplo, un *reminder* de carrito abandonado) y finalmente concreta la conversión. El modelo de último clic ignora completamente los dos primeros pasos y atribuye el 100% del resultado al *email*. Como resultado, los canales que ayudaron a generar conciencia o interés en etapas previas quedan invisibilizados.

Este sesgo tiene implicancias estratégicas. Las campañas de *awareness* suelen ser penalizadas en la medición, ya que no aparecen asociadas a resultados directos inmediatos. Del mismo modo, los canales de soporte, como *remarketing*, quedan sobrerrepresentados. Esto puede llevar a desinversiones en acciones que sí aportan valor real al recorrido, pero que no se registran en el último paso. El modelo, lejos de informar con precisión, termina reforzando decisiones subóptimas.

Frente a este escenario, muchos equipos de *growth* empiezan a cuestionar la lógica de asignar mérito y proponen otro enfoque: entender contribuciones. En lugar de preguntarse «¿qué canal cerró la conversión?», se preguntan «¿qué combinación de estímulos facilitó que esta persona avanzara en el recorrido?». Este cambio de mirada no implica abandonar la medición, sino adoptarla con mayor inteligencia. Los modelos modernos apuntan a representar mejor la complejidad real del comportamiento y a permitir decisiones basadas en evidencia más rica y contextualizada.

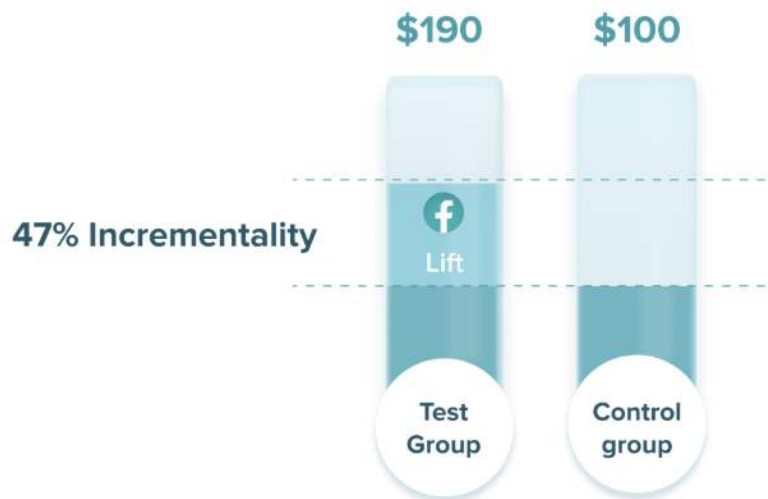
Modelo de atribución por *incrementality*: medir el verdadero impacto de cada canal

La *incrementalidad* es una metodología que busca responder una pregunta clave: «¿Cuánto del resultado que obtuvimos se debe realmente a nuestra acción de

marketing y cuánto habría sucedido de todos modos?». A diferencia de los modelos de atribución tradicionales, que muchas veces asumen que toda conversión posterior a un clic se debe a ese estímulo, este enfoque introduce una perspectiva más rigurosa, basada en el principio de causalidad. Para medirla, se utiliza una metodología experimental: se divide a la audiencia en dos grupos comparables. Al grupo de tratamiento se le muestra el anuncio o la intervención, mientras que el grupo de control no recibe ningún estímulo. Al comparar los resultados de ambos, se puede estimar el efecto neto, es decir, cuántas conversiones o acciones adicionales se generaron gracias a la campaña.

La imagen ilustra un caso típico: mientras el grupo de control generó 100 dólares en compras, el grupo expuesto al anuncio generó 190 dólares.

Figura 4. Medición de la incrementalidad con grupo de control y grupo de tratamiento



La diferencia de 90 dólares representa el incremento atribuible a la campaña, lo que implica una *incrementalidad* del 47%. En otras palabras, sin la campaña, se habrían generado igualmente 100 dólares en ventas; la acción de marketing sumó 90 adicionales. Esta lógica permite tomar decisiones basadas en evidencia concreta y no en suposiciones. Por ejemplo, una marca que lanza una campaña en redes sociales puede descubrir que gran parte de sus ventas proviene de clientes frecuentes que habrían comprado igual, sin ver el anuncio. O bien, que una campaña de *retargeting* no está generando nuevas conversiones, sino capturando usuarios que ya estaban por completar la acción. Al medir la incrementalidad, se priorizan las acciones que efectivamente cambian comportamientos, lo cual es esencial para una gestión eficiente del presupuesto.

Este enfoque se vuelve aún más relevante en estrategias multicanal o en entornos donde los usuarios tienen múltiples puntos de contacto antes de decidir. En lugar de asumir que el último clic se lleva todo el crédito, la *incrementalidad* obliga a mirar qué estímulos realmente movieron la aguja. Por eso, se utiliza tanto en campañas de awareness como en etapas de conversión. Además, permite testear no solo canales, sino también tipos de mensajes, audiencias y formatos creativos. Por ejemplo, una empresa puede evaluar si una nueva pieza de video es más efectiva que una imagen estática para generar compras adicionales. La clave está en definir hipótesis claras, construir el experimento con rigurosidad y analizar los resultados comparativamente. En contextos de incertidumbre o presupuestos limitados, este tipo de evidencia ayuda a enfocar esfuerzos donde realmente se obtienen retornos.

Comprender y aplicar el enfoque de la incrementalidad implica avanzar hacia una medición más precisa, estratégica y centrada en el valor real de las acciones de marketing. No se trata simplemente de observar correlaciones o sumar resultados, sino de identificar con claridad qué intervenciones tienen un impacto causal concreto en el comportamiento del usuario. Este cambio de mirada, basado en experimentación controlada y evidencia comparativa, permite tomar mejores decisiones en escenarios cada vez más complejos, fragmentados y competitivos. En definitiva, medir la *incrementalidad* no solo optimiza campañas: fortalece la capacidad del equipo para aprender, justificar inversiones y construir estrategias con mayor efectividad.

CONTINUAR

Referencias

Amoeboids, (s.f.). *What Is ICE Scoring Model: Framework to Prioritize Features Effectively*. <https://amoeboids.com/blog/ice-scoring-model/>

Sánchez, C. (2024). *Cinco métodos de priorización de ideas que puedes usar ya mismo*. <https://crissanchez.substack.com/p/cinco-metodos-de-priorizacion-de>

Segmentstream, (s.f.). *A guide to incrementality measurement: approaches, benefits and challenges*. <https://segmentstream.com/blog/articles/incrementality-measurement-guide>

Shoppify, (s.f.). *Marketing de atribución: definición y tipos (2025)*. <https://www.shopify.com/es/blog/marketing-de-atribucion>

CONTINUAR