

Universidad de Buenos Aires  
Facultad de Ciencias Económicas  
Escuela de Negocios y Administración Pública

---

CARRERA DE ESPECIALIZACIÓN EN MÉTODOS  
CUANTITATIVOS PARA LA GESTIÓN Y ANÁLISIS DE  
DATOS EN ORGANIZACIONES

---

TRABAJO FINAL INTEGRADOR

---

Gestión efectiva de campañas de retención de clientes en  
aplicaciones móviles: Un análisis del nivel de fidelización de  
los usuarios mediante el uso de Cadenas de Markov.

---

**AUTOR: FABIAN ANDRES URIBE GUERRA**

**MENTOR: MARÍA JOSÉ BIANCO**

**DICIEMBRE 2024**

---

## Resumen

Adquirir y retener clientes es un factor clave en el éxito de cualquier empresa emergente. Entender el nivel de interacción que un usuario tenga con el producto o servicio ofrecido por parte de una compañía permite a la empresa crear una relación más directa con el usuario y, así mismo, adaptarse a las necesidades del cliente final. Esto puede conducir a una mayor participación, más descargas y, en última instancia, más ingresos. Las campañas emitidas por los equipos de marketing pueden ayudar a las nuevas empresas a generar reconocimiento de marca, aumentar la lealtad de los clientes y generar negocios exitosos, por lo que se convierten entonces en un pilar fundamental para fomentar esta relación con los usuarios, así como para asegurar la viabilidad del producto, o servicio. Este artículo explora la segmentación eficiente de usuarios para la creación de campañas de retención, o promoción, de clientes en aplicaciones móviles analizando el nivel de lealtad de los mismos mediante el uso de las Cadenas de Markov.

El documento analiza cómo las aplicaciones móviles pueden usar las Cadenas de Markov para medir la probabilidad de que un cliente interactúe en mayor, o menor, proporción con la aplicación y cómo esto puede usarse para generar campañas de retención, lealtad o promoción más efectivas. Para esto, se tomarán en cuenta cinco posibles estados o categorías de fidelización según la cantidad de veces que han interactuado con la aplicación. Se implementará el uso de software R para tal desarrollo, donde se espera identificar, a partir de cada uno de los estados, que tipo de matriz es la que presenta el nivel de fidelización y la probabilidad de que un cliente pase de una categoría a otra durante un periodo específico de tiempo.

**Palabras clave:** Cadenas de Márkov, clientes, aplicaciones móviles, retención, marketing.

## Índice

Introducción .....	4
1. Análisis de factores organizacionales para predecir la fidelización de usuarios .....	6
1.1. Composición de los datos dentro de la organización .....	6
1.2. Análisis de interacción de los clientes con la aplicación .....	8
1.3. Extracción, procesamiento y control de datos organizacionales .....	9
2. Cadenas de Markov y la matriz de probabilidades de transición .....	10
2.1. Entendiendo a Markov .....	11
2.1.1 Características .....	11
2.1.2 Principios .....	12
2.2. Usos y aplicación de Cadenas de Markov dentro del contexto organizacional .....	13
2.3. Identificando patrones de interacción de los usuarios .....	16
3. Segmentación efectiva de usuarios, la clave del éxito sostenible.....	18
3.1 Uso eficiente de datos para impulsar los resultados comerciales .....	18
3.2. Midiendo el impacto de las campañas de Marketing .....	19
3.3. Más allá del producto, lo importante es el contexto .....	20
Conclusión .....	22
Referencias bibliográficas .....	23
Apéndices .....	25

## Introducción

Las fluctuaciones de índole macroeconómico, social y cultural que se han manifestado con mayor intensidad a raíz del COVID-19 han dado a lugar a una digitalización acelerada en la mayoría de las economías mundiales. La transformación digital le ha dado la bienvenida al mercado a nuevos actores que, usando como base la tecnología blockchain, pretenden romper con los esquemas tradicionales del sistema bancario a través de la creación y gobernanza descentralizada de activos virtuales.

Considerando que el tamaño del mercado global de blockchain se ha expandido desde la crisis financiera de 2008 (Zeng et al., 2020). Hoy en día, Uno de los activos virtuales de mayor popularidad son las monedas estables (también conocidas como stablecoins). La credibilidad y el valor de estos activos dependen de la confianza que el mercado tenga hacia el emisor. En general, el emisor es propietario de la criptomoneda y asegura el presente reclamo para garantizar que pueda intercambiarse al valor establecido de la unidad monetaria, lo cual hace que este sea el tipo de criptomoneda más seguro (Boja et al, 2022). Las ventajas de este tipo de unidades monetarias es que permiten movilizar recursos a menor costo y con mayor diligencia que lo que se acostumbra en el mercado financiero clásico.

En este contexto, diferentes empresas alrededor del mundo han surgido como respuesta a la demanda de nuevas tecnologías disruptivas por parte del mercado. Para efectos del presente trabajo se tomará como referencia una compañía de los Estados Unidos, que llamaremos “UBAR” por indoles relacionadas con confidencialidad y protección de la marca. Esta empresa maneja operaciones en los siguientes países latinoamericanos: Venezuela, Colombia, Perú, Panamá y Argentina. “UBAR”, es una compañía que, a través de una moneda digital, oferta el dólar USDT como un activo con paridad 1 a 1 con el dólar estadounidense. A través de la aplicación móvil permiten que usuarios, en ubicaciones permitidas para operar, puedan almacenar, recibir, y enviar dinero digital (ya sea en los miles de comercios que ahora aceptan USDT, o convirtiendo USDT en bolívares, pesos colombianos, pesos argentinos o soles) en segundos.

Considerando que el nivel de posicionamiento y adopción de una empresa de estas características es fundamental para consolidar el proyecto, surge la necesidad de promover campañas para mantener los usuarios existentes y, así mismo, incentivar el uso de la aplicación.

Con base a lo anterior, el tema del trabajo final de especialización recalca la importancia de determinar los niveles de fidelización de los clientes actuales para así identificar patrones que contribuyan a la gestión efectiva de campañas de retención, y promoción. Para el desarrollo de esta investigación es necesario entender los datos con los que actualmente cuenta la organización; de igual forma, se debe garantizar la completitud e integridad de la información. De esta manera se busca, mediante la aplicación de Cadenas de Markov, responder al siguiente interrogante: ¿Cómo evoluciona el nivel de fidelización del cliente con base en su frecuencia de uso de la aplicación?

El objetivo general del trabajo de especialización consiste en identificar los niveles de fidelización de los clientes con el fin de establecer los mecanismos necesarios para una gestión eficiente de retención de clientes en la aplicación a través de campañas diferenciadas. Por lo que la hipótesis principal de este trabajo es que el uso del método de Cadenas de Markov permite identificar 5 niveles de fidelización en función de la frecuencia de uso de la aplicación. Para poder resolver el objetivo planteado, el trabajo se estructura en tres apartados. En el primer apartado se extraerá la información necesaria para el análisis. Se utilizarán las bases de datos de la organización con información estructurada que se encuentran en el entorno productivo de la herramienta MixPanel. Mediante la extracción y procesamiento de información a través de una API diseñada en Python se realizarán las consultas necesarias para extraer la información referida a la fecha y hora de su última conexión, tiempo dentro de la app, y la cantidad de veces que ha abierto la misma. Esta información se procesará con diferentes cortes para posteriormente evaluar cual es el periodo más apropiado para el análisis. En un segundo apartado, se confeccionará la matriz de probabilidades de transición y se realizará un análisis aplicando Cadenas de Markov mediante el software R. Se identificarán los estados de la matriz, se clasificarán, y se definirá cada uno de ellos. Por último, en el tercer y último apartado, se buscará articular los resultados extraídos de los apartados anteriores para proponer acciones de mejora y extraer conclusiones que permitan aportar al desarrollo y crecimiento de la aplicación.

## **Análisis de factores organizacionales para predecir la fidelización de usuarios**

Las buenas relaciones con los clientes son la base de cualquier negocio exitoso. Uno de los conceptos para evaluar este tipo de relaciones con los usuarios finales es el *Customer Relationship Management* (CRM). CRM es un proceso de cuatro etapas con respecto a los clientes: identificación, atracción, desarrollo y retención. CRM ayuda a las empresas a construir y mantener relaciones con clientes actuales y potenciales. Los sistemas de CRM están diseñados para administrar los datos y las interacciones de los clientes, lo que ayuda a las empresas a comprender las preferencias y los comportamientos de los usuarios, así como a facilitar un mejor servicio. Conocer las preferencias de los clientes es fundamental para proporcionar una experiencia personalizada que satisfaga sus necesidades y ayude a fidelizarlos. Este conocimiento se puede utilizar para informar campañas de marketing, desarrollo de productos y estrategias de servicio al cliente, lo que en última instancia mejora el rendimiento comercial (Smirnov and Huchzermeier (2020)).

El objetivo del siguiente apartado es reconocer patrones en la interacción de los clientes de la organización con la aplicación. En primer lugar, se analizará la composición de los datos relacionados de los clientes, luego se tendrá en cuenta su tiempo interactuando con la aplicación y finalmente se realizará la extracción de los datos necesarios para el análisis. De esta forma, se busca exponer los tipos de clientes que posee la organización y limitar el alcance del trabajo tomando en cuenta la región de los clientes a los que queremos evaluar, para este caso Colombia.

### **1.1. Composición de los datos dentro de la organización**

En el análisis del comportamiento del usuario dentro de aplicaciones móviles, tales como “UBAR”, una métrica clave es la frecuencia de interacción o la cantidad de veces que un cliente se conecta a la aplicación. Esta métrica no sólo refleja el nivel de compromiso del usuario, sino que también proporciona información valiosa sobre su fidelidad y satisfacción con el servicio ofrecido. Entonces, analizar el número de sesiones de un usuario permite a las empresas identificar patrones de uso, segmentar su base de usuarios y desarrollar estrategias de retención más efectivas.

El uso frecuente de la aplicación por parte de los usuarios puede indicar una alta satisfacción, mientras que una disminución en el uso de la aplicación puede deberse a múltiples causas, ya sea en términos de experiencia o en términos de utilidad, que se derivan en la pérdida del cliente. Por lo tanto, la cantidad de veces que un cliente se conecta a la aplicación es un indicador esencial para monitorear la salud y el éxito de la aplicación. Estos datos son esenciales para la toma de decisiones estratégicas, tales como las mejoras en la aplicación, estrategias de retención y marketing personalizado.

Recordando que "UBAR" es una aplicación que, mediante el dólar USDT —una criptomoneda diseñada para mantener una equivalencia 1 a 1 con el dólar estadounidense—, permite movilizar fondos a través de diferentes países en Latinoamérica, resguardar estos criptoactivos dentro de la app y generar utilidades por el saldo activo de los clientes. La demanda de uso de "UBAR" se debe principalmente a la necesidad de los usuarios de movilizar fondos entre países, ahorrar y no perder poder adquisitivo, especialmente en economías inflacionarias como las de la República Bolivariana de Venezuela y la República Argentina, y generar rentabilidad. Sin embargo, aunque la aplicación abarca múltiples propósitos, el presente trabajo se enfocará exclusivamente en el nivel de compromiso y fidelización que los usuarios puedan tener con la aplicación.

En nuestra base de datos se gestionan principalmente tres categorías de información: identificación y contacto del usuario, datos de localización y actividad en la aplicación.

\$last_seen	\$country_code	\$region	\$city	\$ae_first_app_open_date	\$ae_total_app_sessions	\$phone	Username
11/30/22 16:57	Colombia	Bogota D.C.	Bogotá	undefined	275	57319762xxxx	rarevxx
11/24/22 17:35	Colombia	Bogota D.C.	Bogotá	undefined	437	57315537xxxx	yair.1xxx5

Fuente: elaboración propia con datos de MixPanel

La información de identificación y contacto incluye campos como el identificador único del usuario (`distinct_id`), nombre, correo electrónico, número de teléfono y nombre de usuario en la aplicación. Estos datos son esenciales para individualizar a cada usuario y permitir la comunicación directa con ellos. Los datos de localización comprenden el código del país, la región y la ciudad desde donde el usuario accede a la aplicación, lo que facilita la personalización de la experiencia del usuario y la segmentación geográfica. Por último, los datos de actividad en la aplicación incluyen la fecha y hora de la última vez que el usuario utilizó la aplicación (`last_seen`), la fecha de la primera apertura de la aplicación (`ae_first_app_open_date`) y el número total de sesiones realizadas por el usuario

(ae\_total\_app\_sessions). Estos datos son fundamentales para entender el comportamiento y el nivel de interacción del usuario con la aplicación. Por otra parte, cabe destacar que la frecuencia de actualización de los datos varía según el tipo de información. Los datos de identificación y contacto se actualizan principalmente cuando el usuario edita su perfil o contacta al soporte para realizar cambios. Los datos de localización pueden actualizarse cuando el usuario se conecta desde una nueva ubicación o actualiza su información de residencia. Por otro lado, los datos de actividad en la aplicación se actualizan en tiempo real cada vez que el usuario abre la aplicación, realiza una sesión o se desconecta. Esta actualización continua y en tiempo real es crucial para mantener un seguimiento preciso del uso de la aplicación y es la que nos permitirá analizar el nivel de fidelidad de cada usuario con la aplicación.

## **1.2. Análisis de interacción de los clientes con la aplicación**

La interacción del cliente con una aplicación se puede analizar de varias maneras. En primer lugar, se puede observar la cantidad de veces que un cliente abre la aplicación (o app), la cantidad de transacciones que realiza a través de la plataforma, así como el tiempo que pasa en la misma. Esto puede ayudar a identificar cualquier área de la aplicación que pueda necesitar mejoras o que esté causando confusión a los usuarios. En segundo lugar, se pueden ver los comentarios de los clientes o los datos de las encuestas para comprender mejor cómo se recibe la solicitud. Esto puede ayudar a identificar las características que les gustan o no a los clientes, así como las áreas que podrían mejorarse. Finalmente, se pueden analizar los datos recopilados de las interacciones de los clientes con la aplicación. Esto puede proporcionar información sobre cómo los clientes utilizan la aplicación y qué características se utilizan más.

Para el propósito del presente trabajo se tomará como referencia la cantidad de veces que un cliente interactúa con la aplicación (o app). Esta información será entonces utilizada para categorizar a los usuarios en base a las definiciones que se mencionan a continuación:

1. Cliente inactivo: un cliente inactivo es un usuario que descargó la aplicación, pero aún no completó el proceso de incorporación ni interactuó con la misma. Es posible que estos usuarios hayan perdido el interés o se hayan olvidado de la aplicación y ya no interactúen con ella.

2. Cliente Ocasional: este tipo de cliente usa la aplicación financiera de vez en cuando, pero no participa de manera regular. Es posible que tengan algunas transacciones o interacciones con la aplicación, pero no lo suficiente como para considerarse leales. Son clientes que abren la aplicación a lo sumo una vez al mes, pero más de una vez al año.
3. Cliente activo: un cliente activo es un usuario que interactúa con la aplicación regularmente y realiza algunas transacciones u otras interacciones cada mes. Es posible que aún no sean completamente leales a la aplicación, pero la usan con regularidad. Son clientes que abren la aplicación una vez a la semana.
4. Cliente frecuente: este tipo de cliente es un usuario que usa constantemente la aplicación financiera y ha ganado confianza en el producto. Es probable que lo recomienden a otros y comprendan bien cómo funciona. Son clientes que abren la app varias veces a la semana.
5. Cliente habitual: un cliente habitual ha convertido a la aplicación en parte de su día a día. Interactúa constantemente con ella y comparte activamente sus opiniones y experiencias con los demás. Son un activo valioso para la aplicación, ya que generan un crecimiento orgánico a través de su promoción. Son clientes que abren la aplicación al menos una vez al día.
6. Embajador de la marca: un embajador de la marca es un cliente que va más allá para promover la aplicación. Pueden aparecer en campañas de marketing, escribir publicaciones en blogs y organizar eventos para difundir el producto. Su lealtad y entusiasmo son invaluable para el éxito de la app. son clientes que abren la aplicación varias veces al día y son los usuarios más activos de la aplicación.

### **1.3.Extracción, procesamiento y control de datos organizacionales**

En base a los conceptos introducidos en los apartados anteriores, en esta sección se analizan los periodos que se deben tener en cuenta para el análisis de fidelización de los clientes. Los cortes



1821 Universidad  
de Buenos Aires

temporales se definen de forma mensual ya que la tabla principal de la que se obtiene la información se carga con esa periodicidad. Si bien existen datos desde el período de enero de 2018 hasta la actualidad, se tomarán para el análisis los meses comprendidos entre enero a noviembre de 2021 y enero a noviembre de 2022. A continuación, se definirán las razones que justifican esta elección. Debido a que la empresa empezó a tener operaciones en Colombia desde 2020 la información anterior a esta fecha puede estar distorsionada. Finalmente, se consolidarán los datos por año y se procederá a hacer el respectivo análisis.

Para extraer los datos se iterará en diferentes períodos mediante consultas sobre la base de datos de MixPanel a través de lenguaje Python. Durante el procedimiento se toman, para un período en particular, todos los clientes ubicados en Colombia. Luego se observa la frecuencia de conexión de cada cliente en el período inmediatamente posterior.

## Cadenas de Márkov y la matriz de probabilidades de transición

En esta sección se busca desarrollar una matriz de probabilidades de transición basada en las Cadenas de Markov que se puede utilizar para analizar los datos históricos de la cantidad de veces que el usuario ha interactuado con la aplicación. Para comprender las implicaciones de este análisis, se requiere un conocimiento básico de las Cadenas de Markov. Por lo tanto, esta sección ofrecerá una breve descripción de los conceptos teóricos de las Cadenas de Markov, seguida de un examen de su implementación y, finalmente, una discusión sobre cómo identificar patrones predeterminados para la gestión de la fidelización de los usuarios. Además, se espera que las áreas encargadas dentro de la organización puedan utilizar esta matriz para plantear campañas de retención, promoción y lealtad, que tengan un mayor impacto a un menor coste.

### 2.1. Entendiendo a Markov

Las cadenas de Markov son modelos matemáticos fundamentales para describir procesos estocásticos, en los que el comportamiento futuro de un sistema depende exclusivamente del estado en el que se encuentra en el momento presente, sin considerar eso si la secuencia de eventos previos. Esta característica ayuda a simplificar el análisis de procesos complejos al centrarse solo en el estado actual para predecir el futuro, lo que facilita la modelización de sistemas dinámicos en los que intervienen elementos randomizados.

La característica clave de las cadenas de Markov es la propiedad de Markov, que establece que el futuro de un proceso es independiente del pasado, dado el estado actual. Es decir, el conocimiento sobre el pasado no proporciona información adicional sobre lo que ocurrirá a continuación, más allá de lo que ya se puede inferir a partir del presente. Esta independencia entre el futuro y el pasado, dada la información del presente, es crucial para entender la dinámica de los sistemas descritos por estas cadenas (Grinstead & Snell, 1997).

### 2.1.1 Características

Las Cadenas de Markov son un tipo específico de proceso estocástico que modela sistemas que evolucionan en el tiempo de manera probabilística. La característica fundamental de las Cadenas de Markov es su propiedad de "memoria limitada" o "memoria de primer orden". Esto significa que la probabilidad de que el sistema se encuentre en un estado dado en el futuro depende únicamente del estado actual, sin necesidad de considerar los estados anteriores por los que ha pasado el sistema. Esta propiedad se puede expresar matemáticamente, mostrando que la probabilidad de transición a un estado futuro es independiente de la historia previa del sistema.

$$P\{X_{t_n} = x_n | X_{t_{n-1}} = x_{n-1}, \dots, X_{t_0} = x_0\} = P\{X_{t_n} = x_n | X_{t_{n-1}} = x_{n-1}\}$$

En el contexto de una cadena de Markov, los eventos se categorizan en estados, y la probabilidad de transición de un estado a otro se define por una matriz de transición. Esta matriz es una herramienta clave para trabajar con cadenas de Markov, ya que especifica las probabilidades de moverse entre diferentes estados en un solo paso (Norris, 1997).

Para describir cómo el sistema cambia de un estado a otro, se utiliza la matriz de probabilidades de transición, que es una matriz estocástica que contiene las probabilidades de transición entre los estados de la cadena.

$$P = \begin{pmatrix} p_{11} & p_{12} & \cdots \\ p_{21} & p_{22} & \cdots \\ \vdots & \vdots & \vdots \end{pmatrix}$$

Cada elemento de esta matriz representa la probabilidad de que el sistema pase de un estado a otro en un determinado paso de tiempo. Esta matriz debe cumplir ciertas propiedades: todas sus entradas son no negativas y la suma de las probabilidades en cada fila debe ser igual a 1

Ahora, es menester mencionar que los estados pueden ser recurrentes, transitorios o absorbentes. Un estado recurrente es aquel al que el sistema regresará inevitablemente; es decir, la probabilidad de retorno es 1. En contraste, un estado transitorio es aquel del que el sistema puede salir y nunca volver, con una probabilidad de retorno menor que 1. Por su parte, un estado

absorbente es aquel en el que, una vez que el sistema entra, no puede salir, siendo la probabilidad de permanencia en ese estado igual a 1.

### 2.1.2 Principios

Las Cadenas de Markov se fundamentan en el principio de que la probabilidad de transición a un estado futuro depende únicamente del estado actual, lo que simplifica enormemente el análisis de sistemas complejos. La evolución de una cadena de Markov en el tiempo se describe multiplicando la matriz de transición por un vector de estado, que representa las probabilidades de que el sistema se encuentre en cada uno de los estados en un momento dado. Este enfoque permite predecir la probabilidad de que el sistema esté en un estado particular en el futuro, utilizando la relación entre el vector de estado y la matriz de transición.

Otro principio para resaltar es el concepto de distribución estacionaria, que describe el comportamiento del sistema a largo plazo. En muchas cadenas de Markov, las probabilidades de estado tienden a converger a una distribución estacionaria después de muchas iteraciones. Esta distribución indica las probabilidades a largo plazo de que el sistema se encuentre en cada uno de los estados, independientemente del estado inicial.

Finalmente, en cadenas de Markov que incluyen estados absorbentes, se analiza no sólo la probabilidad de que el sistema termine en un estado absorbente, sino también el número esperado de pasos que tomará para que esto ocurra. Este análisis es crucial para la presente investigación ya que determinará el nivel de esfuerzo que se debe realizar por parte del equipo de fidelización para alcanzar los objetivos de la compañía.

En este trabajo, examinaremos cómo las cadenas de Markov pueden aplicarse para analizar y prever la frecuencia de interacción de los usuarios con una aplicación. Esto nos permitirá obtener datos valiosos para optimizar la experiencia del usuario y maximizar la retención de clientes.

## 2.2. Usos y aplicación de Cadenas de Markov dentro del contexto organizacional

Para el presente caso de estudio, se propone la utilización de Cadenas de Markov para realizar la matriz de probabilidades de transición que contendrán 6 filas y 6 columnas. Allí se agrupa a

la cantidad de veces que los clientes abrieron la aplicación, según las definiciones realizadas en los apartados anteriores, en las siguientes categorías: “Cliente Inactivo”, “Cliente Ocasional”, “Cliente Activo” y “Cliente Frecuente”, “Cliente Habitual” y “Embajador”. Las categorías se han puesto en base a lo expuesto en el cuadro siguiente:

**Tabla 1: Categorías**

Cantidad de veces que el usuario abrió la aplicación (al año)	Categorías	Referencia
0 a 9	1-CI	Cliente Inactivo
10 a 39	2-CO	Cliente Ocasional
40 a 119	3-CA	Cliente Activo
120 a 399	4-CF	Cliente Frecuente
400 a 3999	5-CH	Cliente Habitual
Más de 4000	6-CE	Embajador

Fuente: Elaboración propia con datos de la organización

En base a las categorías anteriormente descritas se ha procedido a determinar la matriz de probabilidades de transición. Esta matriz ha sido construida usando como base el comportamiento histórico de la cantidad de veces que los usuarios se han conectado a la aplicación. Los resultados se muestran a continuación:

**Tabla 2: Matriz de Transición**

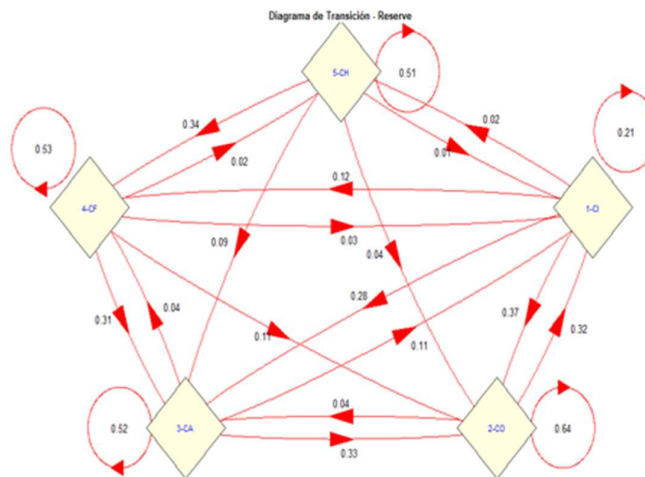
	1-CI	2-CO	3-CA	4-CF	5-CH
1-CI	0.21215686	0.36849673	0.27869281	0.12000000	0.02065359
2-CO	0.31938559	0.63665254	0.04396186	0.00000000	0.00000000
3-CA	0.11030429	0.33367911	0.51728907	0.03872752	0.00000000
4-CF	0.03383298	0.11134904	0.30920771	0.52505353	0.02055675
5-CH	0.01234568	0.03978052	0.09190672	0.34156379	0.51440329

Fuente: Elaboración propia con datos de la organización en el software R

Como se observa en la matriz de la tabla 2, allí está determinada la probabilidad de pasar por cada uno de los estados definidos previamente. De tal manera, que se puede observar que partiendo desde el estado de “cliente activo” existe un 51.7% de probabilidad de mantenerse en ese estado, un 3.8% de probabilidad de convertirse en un “cliente frecuente” y un 33.36% de convertirse en un “cliente ocasional”. Por su parte, también se puede identificar que un cliente que parte como “cliente ocasional” no tiene probabilidad de convertirse en “cliente frecuente” o “cliente habitual” por lo que es necesario que primero pase a ser un “cliente activo” para posteriormente ser un cliente frecuente, o habitual y así poder acceder a mejores beneficios.

Gráficamente, tenemos el siguiente diagrama de transición, en donde se puede identificar con mayor detalle cómo se distribuyen las probabilidades de mantenerse, o no, en un estado determinado.

Grafico 1: Diagrama de Transición



Fuente: Elaboración propia con datos de la organización en el software R

También, podemos entrar a analizar la clasificación de los estados resultantes de aplicar Cadenas de Márkov a los datos de la organización.

**Gráfico 2: Clasificación de estados**

```

Unnamed Markov chain Markov chain that is composed by:
Closed classes:
1-CI 2-CO 3-CA 4-CF 5-CH
Recurrent classes:
{1-CI,2-CO,3-CA,4-CF,5-CH}
Transient classes:
NONE
The Markov chain is irreducible
The absorbing states are: NONE

```

*Fuente: Elaboración propia con datos de la organización, software R.*

Como se puede apreciar en el gráfico anterior, se tiene que siempre es posible retornar al estado de partida ya que existen estados recurrentes y no se observan estados transitorios. Así mismo, se analiza que, aunque existan 6 categorías, con los datos actuales, no existen estados absorbentes. Por lo que existe suficiente evidencia para afirmar que siempre es posible salir de cualquier estado. Y finalmente, siendo la matriz irreducible, siempre es posible llegar a cualquier estado independientemente del Estado del cual se parte. Por lo que, es necesario mantener campañas constantes de promoción y lealtad para mantener la atención del consumidor final en la aplicación.

**Gráfico 3: Vector de estado estacionario**

```

      1-CI      2-CO      3-CA      4-CF      5-CH
[1,] 0.2208428 0.4576818 0.2251011 0.0834487 0.0129256

```

*Fuente: Elaboración propia con datos de la organización, software R.*

Por su parte, en el gráfico 3 se puede observar que aproximadamente el 22% de los clientes se categorizarán como inactivos, el 45,76% serán interacciones de clientes ocasionales, el 22.51% de las veces serán clientes activos; 8.3% harán referencia a clientes frecuentes y aproximadamente el 1.2% de las interacciones serán clientes habituales.

**Gráfico 4: Tiempo Medio al primer retorno**

```

      1-CI      2-CO      3-CA      4-CF      5-CH
[1,] 4.528108 2.184924 4.442448 11.98341 77.36582

```

*Fuente: Elaboración propia con datos de la organización, software R.*

Finalmente, analizando el tiempo medio al primer retorno, se puede inferir que dentro de 4 días y medio el cliente volverá a categorizarse como inactivo o activo, dentro de 12 días el cliente tendrá una cantidad de interacciones tal que volverá a considerarse como frecuente, y el último y no menos importante, dentro de 77 días el cliente volverá (o será) un cliente habitual. Por lo

que, es posible afirmar, que el tiempo medio de duración para fidelizar un cliente es como mínimo de dos meses.

### 2.3. Identificando patrones de interacción de los usuarios

En el análisis realizado utilizando Cadenas de Markov, se construyó una matriz de probabilidades de transición con seis estados que representan distintos niveles de interacción de los clientes con la aplicación: “Cliente Inactivo”, “Cliente Ocasional”, “Cliente Activo”, “Cliente Frecuente”, “Cliente Habitual” y “Embajador”. Esta matriz fue creada a partir del comportamiento histórico de los usuarios, y permite entender la probabilidad de que un cliente transite entre estos diferentes estados en el tiempo..

Los resultados obtenidos muestran una dinámica interesante en la relación de los usuarios con la aplicación. Por ejemplo, un "Cliente Activo" tiene una probabilidad del 51.7% de mantenerse en su estado actual, un 3.8% de avanzar a "Cliente Frecuente", y un 33.36% de retroceder a "Cliente Ocasional". Este tipo de información es crucial para diseñar estrategias de retención, ya que indica qué tan estable es la relación de los usuarios con la plataforma en su estado actual y qué probabilidades tienen de cambiar su nivel de interacción.

Otro hallazgo importante es que los "Clientes Ocasionales" no tienen probabilidades de avanzar directamente a estados más comprometidos como "Cliente Frecuente" o "Cliente Habitual". Esto sugiere que para que un cliente ocasional se convierta en un cliente más fiel, primero debe pasar por la fase de ser un "Cliente Activo". Este patrón de transición resalta la importancia de fomentar la actividad constante de los usuarios para facilitar su progresión hacia estados de mayor fidelización.

Al analizar la clasificación de los estados, se observó que no hay estados absorbentes, lo que significa que es posible que los usuarios transiten de cualquier estado a otro, independientemente del punto de partida. Esta característica es fundamental para las estrategias del equipo de fidelización ya que indica que todos los clientes tienen potencial de ser activados o reactivados a través de campañas adecuadas y beneficiosas para el usuario final.

El análisis también muestra que, en promedio, el 22% de los usuarios se categorizarán como inactivos, mientras que el 45.76% serán ocasionales, el 22.51% serán activos, el 8.3% serán



1821 Universidad  
de Buenos Aires

**.UBAeconómicas | posgrado**

**ENAP** Escuela de Negocios y Administración Pública

frecuentes, y solo el 1.2% alcanzará el nivel de cliente habitual. Este desglose sugiere que una gran mayoría de los usuarios interactúan con la aplicación de manera esporádica, lo que subraya la necesidad de intervenciones estratégicas para aumentar su nivel de compromiso.

Finalmente, el análisis del tiempo medio al primer retorno indica que los usuarios suelen volver a ser inactivos o activos dentro de aproximadamente 4.5 días, que se convierten en frecuentes en 12 días, y que se consolidan como habituales en unos 77 días. Estos tiempos proporcionan un marco temporal para evaluar la efectividad de las estrategias de fidelización implementadas.

## **Segmentación efectiva de usuarios, la clave del éxito sostenible**

El concepto de segmentación fue introducido por Smith (1956) como una manera de identificar subgrupos homogéneos de clientes dentro del mercado, en función de un criterio determinado. Este concepto ha sido ampliamente adoptado en la industria del marketing, ya que permite a las empresas adaptar su oferta a las necesidades específicas de cada segmento y reducir la competencia mediante la oferta de productos diferenciados que permite obtener ventajas competitivas (Cahill, 1997). A partir de los resultados obtenidos y expuestos anteriormente, se puede inferir que la segmentación efectiva de usuarios es clave para lograr un éxito sostenible. La segmentación nos permite identificar y tratar de manera diferenciada a los usuarios según su comportamiento y potencial de fidelización. Dado que los usuarios transitan entre diferentes niveles de compromiso, una segmentación precisa puede guiar el diseño de campañas específicas que respondan a las necesidades y características de cada segmento.

### **3.1. Uso eficiente de datos para impulsar los resultados comerciales**

El uso eficiente de datos se ha convertido en un componente esencial para impulsar los resultados comerciales en un entorno cada vez más competitivo. Los datos proporcionan una base sólida para tomar decisiones informadas, permitiendo a las empresas identificar patrones, predecir comportamientos futuros y adaptar sus estrategias en tiempo real. Al aprovechar herramientas analíticas avanzadas, como las Cadenas de Markov, las empresas pueden modelar el comportamiento de sus clientes con mayor precisión, lo que a su vez permite desarrollar estrategias de marketing más efectivas y focalizadas. Según Davenport y Harris (2007), las organizaciones que utilizan datos de manera efectiva logran mejores resultados comerciales al basar sus decisiones en información confiable y actualizada.

Además, la capacidad de segmentar a los usuarios de manera efectiva permite a las empresas identificar y priorizar oportunidades de crecimiento. Las Cadenas de Markov, tal como se ha explicado a lo largo de este trabajo, permiten mapear las transiciones de los usuarios entre diferentes estados de compromiso, facilitando la creación de campañas personalizadas que responden a las necesidades y comportamientos específicos de cada segmento. Como señalan Waller y Fawcett (2013), la segmentación basada en datos no solo mejora la efectividad de las

estrategias de marketing, sino que también optimiza el uso de los recursos, dirigiendo los esfuerzos hacia los clientes con mayor potencial de retorno.

Finalmente, la integración de datos en las estrategias comerciales permite a las empresas no sólo reaccionar a las tendencias actuales, sino también anticiparse a futuras demandas del mercado.

### 3.2. Midiendo el impacto de las campañas de Marketing

Medir el impacto de las campañas de marketing es esencial para determinar su efectividad y justificar la inversión realizada. Las herramientas analíticas basadas en datos, como las Cadenas de Markov, permiten a las empresas evaluar con precisión cómo las campañas influyen en el comportamiento de los clientes a lo largo del tiempo. Estas cadenas permiten modelar las transiciones de los usuarios entre diferentes estados de compromiso, ofreciendo una visión clara de cómo una campaña específica puede mover a los clientes desde un estado menos comprometido, como "Cliente Ocasional", hacia un estado de mayor fidelización, como "Cliente Frecuente" o "Embajador". Este enfoque proporciona métricas cuantificables que van más allá de los indicadores tradicionales, como el retorno de la inversión (*Return of Investment* 'ROI'), para incluir también el cambio en la probabilidad de que un cliente avance a un estado de mayor valor.

Además, la capacidad de segmentar a los usuarios y analizar su comportamiento mediante Cadenas de Markov facilita la identificación de las campañas más efectivas para cada segmento de clientes. Al comparar las probabilidades de transición antes y después de la implementación de una campaña, las empresas pueden identificar cuáles estrategias son más exitosas en fomentar la lealtad y aumentar la retención de clientes. Este tipo de análisis también permite ajustar las campañas en tiempo real, optimizando los resultados y maximizando el impacto de las estrategias de marketing en el comportamiento de los clientes.

Por último, medir el impacto de las campañas de marketing a través de estos métodos avanzados no solo ayuda a evaluar su éxito, sino que también proporciona información valiosa para futuras iniciativas. Los *insights* obtenidos permiten a las empresas refinar sus tácticas, enfocando los esfuerzos en áreas con mayor potencial de mejora. Según Berger y Nasr (1998), el análisis detallado del comportamiento del cliente es fundamental para desarrollar estrategias de

marketing efectivas que no solo atraen a nuevos clientes, sino que también fortalecen la relación con los existentes, incrementando así el valor de la vida del cliente (CLV) y, por ende, el rendimiento general de la empresa.

### **3.3. Más allá del producto, lo importante es el contexto.**

En el análisis del comportamiento del usuario y la efectividad de las campañas de marketing, es crucial comprender que el éxito no se basa únicamente en la calidad del producto, sino en cómo este se posiciona y se contextualiza dentro de la vida de los usuarios. La clave radica en entender el contexto en el que los clientes interactúan con la aplicación o el servicio, lo que va más allá de las características intrínsecas del producto.

El uso de Cadenas de Markov para modelar la fidelización y la segmentación de usuarios ha demostrado que los patrones de comportamiento no son lineales ni aislados; están profundamente influenciados por factores externos y por las experiencias previas de los usuarios. Por ejemplo, un usuario puede ser "Activo" no solo por las características del producto, sino porque la aplicación se adapta bien a su rutina diaria o porque las campañas de marketing lograron resonar con su situación particular en un momento dado. De esta manera, el contexto, que incluye tanto los aspectos personales del usuario como el entorno en el que usa el producto, se convierte en un factor determinante en su lealtad y en la progresión a través de los diferentes estados de compromiso.

Además, al segmentar a los usuarios y analizar sus transiciones entre estados de fidelidad, se evidencia que el contexto no solo afecta la interacción actual del usuario, sino que también condiciona las probabilidades de futuras interacciones. Un cliente que recibe un mensaje personalizado en el momento adecuado tiene una mayor probabilidad de avanzar a un estado de mayor compromiso, lo que subraya la importancia de considerar el contexto en el diseño de estrategias de marketing. Este enfoque permite a las empresas no solo mejorar la experiencia del usuario, sino también anticiparse a sus necesidades, creando un valor añadido que va más allá del producto en sí.



1821 Universidad  
de Buenos Aires

**.UBAeconómicas | posgrado**

**ENAP** Escuela de Negocios y Administración Pública

En resumen, en el contexto de la fidelización de usuarios y el marketing, lo que realmente impulsa el éxito sostenible es la capacidad de entender y adaptar el producto y las campañas al contexto de uso del cliente. Este entendimiento profundo permite crear experiencias más relevantes y personalizadas, lo que refuerza la relación con el cliente y maximiza el valor de cada interacción, tal como se ha evidenciado en los análisis realizados con Cadenas de Markov en el presente trabajo.

## Conclusión

A lo largo de este trabajo se ha explorado cómo las Cadenas de Markov pueden ofrecer una visión detallada y dinámica del comportamiento de los usuarios, permitiendo a las empresas no solo medir la fidelización, sino también desarrollar estrategias efectivas de segmentación y marketing. También, se ha expuesto que el éxito comercial depende tanto de la comprensión profunda del contexto en el que los usuarios interactúan con un producto como de la capacidad de adaptar las estrategias a este contexto.

Por ejemplo, para los "Clientes Ocasionales", que tienen un alto riesgo de regresar a un estado inactivo, se pueden desarrollar campañas de *re-engagement* que ofrezcan incentivos para aumentar la frecuencia de uso. Para los "Clientes Activos", que ya muestran un mayor nivel de compromiso, se podrían implementar programas de lealtad que recompensen la consistencia, incentivando la transición hacia los estados de "Cliente Frecuente" o "Cliente Habitual".

Además, la segmentación efectiva permite a la organización priorizar sus recursos en los segmentos con mayor potencial de crecimiento, como aquellos usuarios que están en la fase de transición entre "Activo" y "Frecuente". Estos usuarios son particularmente importantes, ya que representan una oportunidad para consolidar una base de clientes leales que contribuirán significativamente al éxito a largo plazo de la empresa.

En conclusión, los resultados del análisis mediante Cadenas de Markov no solo nos proporcionaron un mapa detallado de cómo los usuarios interactúan con la aplicación, sino que también nos señalan la importancia crítica de la segmentación efectiva como un factor determinante para un éxito sostenible. Al integrar estrategias de segmentación con el análisis de transiciones de los usuarios, es posible desarrollar enfoques más personalizados y efectivos, que no solo mantendrán a los usuarios comprometidos, sino que también fomentarán su progresión hacia niveles de fidelización más altos.

## Referencias bibliográficas

M.M. Boja et al (2022). Forecasting macroeconomic effects of stablecoin adoption: A bayesian approach. Recuperado de: [10.1016/j.econmod.2022.105792](https://doi.org/10.1016/j.econmod.2022.105792)

T. Zeng, M. Yang, Y. Shen (2020). Fancy Bitcoin and conventional financial assets: measuring market integration based on connectedness networks. Recuperado de Econ. Modell., 90 (2020), pp. 209-220, [10.1016/j.econmod.2020.05.003](https://doi.org/10.1016/j.econmod.2020.05.003)

E. Raposo (2021). Identificación de patrones de morosidad de clientes en una organización bancaria Argentina. Recuperado de:

Z. Soltani, N.J. Navimipour (2016). Customer relationship management mechanisms: a systematic review of the state-of-the-art literature and recommendations for future research Comput. Hum. Behav., 61 (Aug. 2016), pp. 667-688

S.E. Schaeffer, S.V.R. Sanchez (2020). Forecasting client retention - A machine-learning approach Journal of Retailing and Consumer Services, 52 (2020), pp. 1-9

Grinstead, C. M., & Snell, J. L. (1997). Introduction to Probability. American Mathematical Society. Recuperado de: <https://www.ams.org/publications/authors/books/postpub/gsm-71-abstract>

Norris, J. R. (1997). Markov Chains. Cambridge University Press. Recuperado de: <https://www.cambridge.org/core/books/markov-chains/ABCC8A0AA31D7112B60DCBD20B3BC678>

Meyn, S. P., & Tweedie, R. L. (2009). Markov Chains and Stochastic Stability. Cambridge University Press. Recuperado de: <https://www.cambridge.org/core/books/markov-chains-and-stochastic-stability/743509C84C500D07C8D47F0E1D2D3E5B>

Bremaud, P. (1999). Markov Chains: Gibbs Fields, Monte Carlo Simulation, and Queues. Springer. Recuperado de: <https://www.springer.com/gp/book/9780387985094>

Waller, M. A., & Fawcett, S. E. (2013). Data Science, Predictive Analytics, and Big Data: A Revolution That Will Transform Supply Chain Design and Management. Journal of Business Logistics, 34(2), 77-84. Recuperado de: <https://onlinelibrary.wiley.com/doi/abs/10.1111/jbl.12010>

LaValle, S., Lesser, E., Shockley, R., Hopkins, M. S., & Kruschwitz, N. (2011). Big Data, Analytics and the Path From Insights to Value. MIT Sloan Management Review, 52(2), 21-32. Recuperado de: <https://sloanreview.mit.edu/article/big-data-analytics-and-the-path-from-insights-to-value/>

Berger, P. D., & Nasr, N. I. (1998). *Customer Lifetime Value: Marketing Models and Applications*. Journal of Interactive Marketing, 12(1), 17-30. Recuperado de: <https://www.sciencedirect.com/science/article/abs/pii/S1094996898701031>



1821 Universidad  
de Buenos Aires

**.UBAeconómicas | posgrado**

**ENAP** Escuela de Negocios y Administración Pública

Davenport, T. H., & Harris, J. G. (2007). Competing on Analytics: The New Science of Winning. Harvard Business Review Press. Recuperado de:  
<https://www.hbr.org/product/competing-on-analytics-the-new-science-of-winning/10047E-KND-ENG>

## Apéndices

```
library(readxl)
```

```
DIAS <- read_excel("../Desktop/TFI_PAPERS/GRado_Markov.xlsx", sheet = 4, col_names = TRUE)
```

```
DIAS_1 <- as.data.frame(c( DIAS[4], DIAS[5]))
```

```
matrizD <- as.matrix(DIAS_1)
```

```
probtransD <- createSequenceMatrix(stringchar = matrizD, toRowProbs = TRUE)
```

```
probtransD
```

```
##### Aplicacion de Cadenas de Markov
```

```
# Se crea el objeto Markov chain
```

```
TclienteD <- new("markovchain", transitionMatrix = probtransD)
```

```
## diagrama de transición
```

```
par(mar=c(1,1,1,1))
```

```
plotmat(round(t(TclienteD@transitionMatrix), 2),
```

```
  box.type = 'diamond', shadow.size = 0, txt.col = "blue", txt.font = 1,
```

```
  box.lwd = 1.55, box.size = 0.06, box.col = 'light yellow', box.cex = 0.7,
```

```
  arr.col = 'red', arr.width = 0.2, arr.length = 0.4,
```

```
  arr.type = 'triangle', arr.lwd = 0.7, arr.lcol = 'red',
```

```
  cex.txt = 0.8, curve = 0.05,
```

```
  self.cex = 0.8,
```

```
  self.shiftx = c(+0.05, +0.1, -0.1, -0.07, +0.1),
```

```
  self.shifty = c(+0.09, -0.00, -0.00, +0.07, +0.00),
```

```
  main = "Diagrama de Transición - Reserve", cex = 0.8)
```

```
## Clasificación de Estados
```

```
summary(TclienteD)
```

```
# A través de los pasos
```

```
TclienteD^2
```

```
TclienteD^3
```

```
TclienteD^4
```

```
## Pase a Riesgo alto en o antes del mes 3
```

```
# Transición en tres pasos
```

```
P3 = TclienteD^3
```

```
P3@transitionMatrix["2-RB", "4-RA"]
```

```
P3@transitionMatrix["3-RM", "4-RA"]
```



1821 Universidad  
de Buenos Aires

```
P3@transitionMatrix["4-RA","4-RA"]
```

```
##### An?lisis de largo plazo
```

```
#vector de estado estacionario  
steadyStates(TclienteD)
```

```
#cantidad de pasos promedio esperados hasta  
1/steadyStates(TclienteD)
```

```
# Convergencia: se busca por ejemplo observa la convergencia de si  
# se parte hoy de una BAJA, cuando volver? a SUBIR
```

```
EstadoInicial = c(1,0,0,0)
```

```
CI = c()
```

```
CO = c()
```

```
CA = c()
```

```
CF = c()
```

```
CH = c()
```

```
n = 10
```

```
for(k in 1:n){  
  paso = EstadoInicial*TclienteD^k #Calculo el k-esimo d?a  
  CI[k] <- paso[1,1] # Leo fila 1, columna 1  
  CO[k] <- paso[1,3] # Leo fila 1, columna 3  
}
```

```
plot(CI, col='red', ylim=c(0,1), type="l",ylab="Probabilidades",  
      xlab="Paso", main="Probabilidades partiendo de CI")  
lines(CO,col='blue',type="l")  
abline(h=steadyStates(TclienteD)[1],lty=2)  
abline(h=steadyStates(TclienteD)[3],lty=2)  
legend(n*0.5,1,legend=c("BAJO", "SUBIO"),col=c("red", "blue"),lty=1,cex=0.5)
```



1821 Universidad  
de Buenos Aires

<b>Solicitud de evaluación de TRABAJO FINAL DE ESPECIALIZACIÓN</b>		Código de la Especialización
Nombre y apellido del alumno Fabian Andres Uribe		Tipo y N° de documento de identidad 1010220656
Año de ingreso a la Especialización – Ciclo 2022	Fecha de aprobación de la última asignatura rendida 12.2022	
Título del Trabajo Final  Gestión efectiva de campañas de retención de clientes en aplicaciones móviles: Un análisis del nivel de fidelización de los usuarios mediante el uso de Cadenas de Markov.		
Solicitud del Tutor de Trabajo Final  Comunico a la Dirección de la Especialización que el Trabajo Final bajo mi tutoría se encuentra satisfactoriamente concluido. Por lo tanto, solicito se proceda a su evaluación y calificación final.  Firma del Tutor de Trabajo Final .....		
Aclaración: MARÍA JOSÉ BIANCO  Lugar y fecha.....		
<b>Datos de contacto del Tutor</b>		
Correo electrónico 13mb16765705@campus.economicas.uba.ar	Teléfonos	
Se adjunta a este formulario: <ul style="list-style-type: none"><li>• Archivo del Proyecto de Trabajo Final en formato digital (versión Word y PDF) a <a href="mailto:graduacion@posgrado.economicas.uba.ar">graduacion@posgrado.economicas.uba.ar</a></li></ul>		
Fecha 05/12/2024	Firma del alumno Fabian Uribe Guerra	

Buenos Aires, 4 de diciembre de 2024

## **Reporte Trabajo Final Integrador de Especialización**

### **“Gestión efectiva de campañas de retención de clientes en aplicaciones móviles: Un análisis del nivel de fidelización de los usuarios mediante el uso de Cadenas de Markov”**

**Autor: Fabián Andrés URIBE GUERRA**

En mi carácter de mentora del Trabajo Final Integrador de Especialización del Lic. Fabián Andrés Uribe Guerra, me dirijo a ustedes con el objetivo de transmitirle mi opinión sobre la investigación realizada.

El análisis de la gestión de campañas de retención de clientes en aplicaciones móviles es un tema relevante para Especialización ya que este trabajo ilustra cómo los conceptos estudiados en las distintas asignaturas pueden aplicarse para resolver problemas empresariales concretos, utilizando datos y herramientas analíticas para optimizar las estrategias de marketing y fidelización.

En primer lugar, el estudio demuestra la importancia de un enfoque basado en datos para la toma de decisiones. El análisis de la frecuencia de interacción de los usuarios con la aplicación "UBAR" permite identificar patrones de comportamiento y segmentar a los clientes de manera efectiva. Este enfoque es esencial para el éxito en el entorno empresarial actual, donde la información es un activo estratégico.

El estudio también destaca la aplicación de técnicas avanzadas de análisis de datos, como las Cadenas de Markov, para modelar la probabilidad de transición de los usuarios entre diferentes estados de fidelización. La construcción de una matriz de probabilidades de transición, basada en datos históricos, y la clasificación de los estados resultantes son ejemplos concretos del uso de herramientas analíticas para comprender la dinámica de la fidelización de clientes.

La segmentación de clientes, basada en el análisis de su comportamiento, se presenta como una estrategia fundamental para el éxito sostenible. Permite a las empresas diseñar campañas de marketing personalizadas que se ajusten a las necesidades y características de cada segmento, optimizando la inversión y maximizando el retorno.

En resumen, este estudio evidencia la aplicación práctica de los principios de la gestión y análisis de datos para la resolución de un problema empresarial real. La metodología utilizada, el análisis realizado y las conclusiones obtenidas son relevantes para cualquier profesional que busque desarrollar habilidades en el manejo e interpretación de datos para la toma de decisiones informadas en el ámbito empresarial.

Por estas razones doy mi expresa conformidad a la entrega de este Trabajo Final Integrador de Especialización

Sin otro particular, saludo cordialmente.

  
Dra. María José Bianco