

# BIG DATA

## MARKETING DIGITAL Y BIG DATA

---

Nora Lado  
Daniel Peña  
(editores)





# BIG DATA

## MARKETING DIGITAL Y BIG DATA

---

Nora Lado  
Daniel Peña  
(editores)



Funcas

**PATRONATO**

ISIDRO FAINÉ CASAS  
JOSÉ MARÍA MÉNDEZ ÁLVAREZ-CEDRÓN  
MANUEL AZUAGA MORENO  
FERNANDO CONLLEDO LANTERO  
CARLOS EGEA KRAUEL  
MIGUEL ÁNGEL ESCOTET ÁLVAREZ  
AMADO FRANCO LAHOZ  
PEDRO ANTONIO MERINO GARCÍA  
ANTONIO PULIDO GUTIÉRREZ  
VICTORIO VALLE SÁNCHEZ  
GREGORIO VILLALABEITIA GALARRAGA

**DIRECTOR GENERAL**

CARLOS OCAÑA PÉREZ DE TUDELA

Impreso en España  
Edita: Funcas  
Caballero de Gracia, 28, 28013 - Madrid  
© Funcas

Todos los derechos reservados. Queda prohibida la reproducción total o parcial de esta publicación, así como la edición de su contenido por medio de cualquier proceso reprográfico o fónico, electrónico o mecánico, especialmente imprenta, fotocopia, microfilm, *offset* o mimeógrafo, sin la previa autorización escrita del editor.

ISBN: 978-84-17609-62-7  
Depósito legal: M-5426-2022  
Maquetación: Funcas  
Imprime: Cecabank



## Contenido

---

Presentación <i>Nora Lado y Daniel Peña</i>	1
Capítulo I. Importancia del <i>big data</i> en <i>marketing</i> digital <i>Daniel Peña</i>	5
Capítulo II. La tercera revolución de la comunicación. El día que dejaremos de decidir <i>Ricardo Urías</i>	31
Capítulo III. Recomendación a grupos basada en un modelo de consenso de mínimo costo <i>Raciel Yera, Álvaro Labella y Luis Martínez</i>	45
Capítulo IV. Retos de la adopción de los nuevos sistemas de recomendación basados en inteligencia artificial <i>Daniel Belanche y Carlos Flavián</i>	67
Capítulo V. Cómo conseguir tu objetivo <i>offline</i> utilizando la navegación del usuario <i>Jesús Romero Leguina</i>	85
Capítulo VI. ¿Utiliza Facebook datos sensibles con fines publicitarios? Análisis mundial e impacto del Reglamento General de Protección de Datos europeo (RGPD) <i>José González Cabañas, Ángel Cuevas y Rubén Cuevas</i>	105
Capítulo VII. RSC 2.0: La comunicación entre empresas y <i>stakeholders</i> en redes sociales <i>Pablo Gómez Carrasco y Encarna Guillamón Saorín</i>	121
Capítulo VIII. Nuevas trazas del valor de marca de entidades financieras proporcionadas por su gestión <i>online</i> <i>Nora Lado, Manuel Ceballos y Camilo de la Cruz</i>	137



## Presentación

El *big data en marketing* ofrece una estrategia que, a través del análisis de un enorme volumen de datos que están disponibles en Internet, u otras fuentes, potencia una mayor orientación al mercado de las empresas. Se abre así un amplio espectro de oportunidades de cara a comprender mejor el mercado, sus actores, competidores y clientes, y orientar a la empresa hacia oportunidades de mercado. Sus aplicaciones y objetivos son múltiples: comprender mejor las preferencias de los clientes actuales o potenciales, optimizar una estrategia de segmentación de la demanda, ofrecer sistemas de recomendación que impulsen el desarrollo de negocio, potenciar la venta cruzada de productos y servicios, crear inteligencia de mercado sobre sus diferentes actores y mejorar la orientación a la audiencia, al personalizar las acciones de comunicación y promoción de ventas, asegurando una mayor efectividad para las campañas comerciales.

La vertiginosa penetración del comercio electrónico, potenciada aún más por el contexto de la actual pandemia, la intensa utilización de redes sociales y plataformas de contenidos otorgan al *marketing* digital en conjunción con *big data* un campo de desarrollo sin límites.

En este libro se presentan diversos estudios y propuestas dirigidas a contribuir a una mejor comprensión de amplios aspectos del *marketing* digital y *big data*. Algunos de sus capítulos recogen ponencias presentadas en la *Jornada de Marketing Digital y Big Data*, organizada por nosotros y Rubén Cuevas y celebrada en Funcas el 10 de marzo de 2021. Todas las presentaciones de esta jornada fueron grabadas y están a disposición del lector interesado en: <https://www.youtube.com/watch?v=flu8QzhWDuM>. En este volumen hemos ampliado el contenido de esta jornada incluyendo, también, varios trabajos escritos especialmente para esta monografía, con la intención de ofrecer una visión panorámica de cómo el *big data* está transformando el *marketing* digital.

El libro se inicia con un trabajo preparado por **Daniel Peña** que describe como la información contenida en los nuevos datos masivos está transformando los procesos de venta *online*. En este primer capítulo se ilustran estos cambios con tres herramientas comerciales desarrolladas para este nuevo contexto: los sistemas de recomendación; el seguimiento de la lealtad mediante la estimación de la probabilidad de abandono de los clientes; y el análisis de las propiedades y características de las redes de clientes. En el siguiente capítulo, **Ricardo**

**Urías** explica las implicaciones de las dos revoluciones que se han producido en el ámbito de la comunicación y describe la tercera que tenemos en ciernes: la del *big media* y la inteligencia artificial, que cambiará de forma radical nuestra vida.

En los dos capítulos siguientes se presentan los avances recientes en los sistemas de recomendación, una de las herramientas más importantes en el *marketing* digital. En el capítulo III, **Raciel Yera, Álvaro Labella y Luis Martínez** estudian los sistemas de recomendación a grupos, orientados a productos como los programas de televisión y los paquetes de viajes turísticos, que pretenden satisfacer las preferencias globales de conjuntos de personas que pueden tener intereses distintos. Para el éxito de estos sistemas es necesario gestionar de forma adecuada el acuerdo entre los miembros del grupo, de manera que la recomendación realizada satisfaga sus intereses globales. Para ello, se propone un modelo de consenso de mínimo coste diseñado para solventar la gestión de conflictos en el grupo. En el capítulo IV, **Daniel Belanche y Carlos Flavián** analizan la progresiva introducción de *robo-advisors* (robots asesores), que no solo aconsejan sobre carteras de inversión, sino que también se encargan de la gestión automatizada de las operaciones de compra y venta. Los autores analizan las ventajas y limitaciones de estos sistemas y las barreras que se generan, que resultan especialmente importantes en sus etapas iniciales. Se analiza el importante papel que juega la preparación tecnológica de los usuarios y cómo estos sistemas están transformando los servicios financieros.

En el capítulo V, **Jesús Romero** explica cómo conseguir un objetivo *offline* utilizando la información generada por la navegación del usuario. Se estudia cómo profundizar en la creación de audiencias y su óptima activación dentro de nuestras estrategias comerciales utilizando la información de Google Analytics junto con el uso de técnicas de *machine learning*. Se describe un ejemplo de generar audiencias y cualificar aquellos usuarios de mayor valor para el negocio, integrando las ventas *offline* en nuestras estrategias digitales. El capítulo VI analiza un ejemplo de las consecuencias no previstas de utilizar información sensible con fines publicitarios, considerando el caso de Facebook. Los tres autores de este trabajo, **José González, Ángel Cuevas y Rubén Cuevas**, cuantifican el número de usuarios de Facebook en 197 países que son etiquetados con intereses publicitarios vinculados a datos personales potencialmente sensibles. Esta investigación revela que Facebook etiqueta al 67 % de los usuarios con estos intereses sensibles, e ilustra sus riesgos potenciales: por ejemplo, al etiquetar con la característica “interés en homosexualidad” en países donde esta inclinación sexual se castiga con la pena capital.

**Pablo Gómez y Encarna Guillamón** estudian en el capítulo VII si en el sistema bancario español encontramos en las redes sociales una mayor presencia de información sobre Responsabilidad Social Corporativa (RSC) Central (*Core CSR*), directamente relacionada con la actividad principal de una compañía o, por el contrario, predomina la información sobre actividades de acción social, cultural y/o medioambiental, desligadas de la actividad principal, que denominan RSC Complementaria (*Supplementary CSR*). Concluyen que la estrategia de comunicación no está adecuadamente alineada con la de los *stakeholders*, ya que éstos se interesan básicamente por el negocio principal de las compañías, mientras que las cuentas internas frecuentemente se dirigen a cuestiones complementarias. Finalmente, en el

capítulo VIII, **Nora Lado, Manuel Ceballos y Camilo de la Cruz** utilizan la comunicación *online* para encontrar medidas que reflejan los indicadores del valor de marca. Con datos de *tweets* que contenían el nombre de las marcas estudiadas han medido la popularidad *online* de una marca, estimando una asociación entre el esfuerzo generado por la marca (FCC) y la implicación del consumidor. Por otro lado, han utilizado herramientas de videos y *neuromarketing* para medir las emociones provocadas por los anuncios.

Confiamos en que este conjunto de trabajos sobre las tendencias actuales en el *marketing* digital sea de utilidad a una audiencia amplia de lectores que quiera introducirse en los grandes cambios que los datos masivos están produciendo en las estrategias comerciales de las empresas. Muchos de los trabajos incluidos dedican una atención especial al sector financiero, que es uno de los que previsiblemente tendrá grandes transformaciones en el futuro. Agradecemos a todos los autores su esfuerzo y generosidad para difundir su experiencia en beneficio de todos los lectores.

Como editores de este libro queremos agradecer el apoyo de Funcas a esta iniciativa y, especialmente a su director general, Carlos Ocaña, que ha impulsado el Área de Big Data dentro de la Fundación. Agradecemos a todo su equipo las facilidades para la realización de la jornada en un momento difícil por la pandemia, y a la responsable de publicaciones en Funcas, Myriam González, su eficaz trabajo en la publicación de esta monografía.

Febrero, 2022



## CAPÍTULO I

## Importancia del *big data* en *marketing* digital

Daniel Peña\*

Las empresas que han enfocado su actividad comercial a través de Internet recogen de forma automática información sobre sus clientes que puede utilizarse para mejorar sus estrategias de *marketing* digital. Este trabajo describe cómo los nuevos datos masivos, el *big data*, que incluye además de los datos tradicionales los basados en imágenes y sonidos digitales, está transformando los procesos de venta *online*. Estos cambios se ilustran con tres herramientas comerciales desarrolladas con datos masivos. La primera, los sistemas de recomendación, es nueva y constituye un buen ejemplo de las oportunidades que ofrece el análisis de la información sobre compras previas de los clientes. La segunda, el seguimiento de la lealtad mediante el cálculo de la probabilidad de abandono de los clientes, tiene una larga tradición, pero se ha perfeccionado y redefinido en el nuevo contexto de datos masivos. La tercera, el análisis de las características de las redes de clientes, se está introduciendo en la actualidad y tiene un amplio potencial de desarrollo. Permite describir las relaciones entre clientes y entender mejor la estructura de los usuarios, construir nuevas variables de alto valor predictivo y diseñar nuevas estrategias de comercialización en *marketing* digital. Su potencial se ilustra con un ejemplo de los resultados al analizar la red de clientes de un importante banco. El artículo concluye con una revisión de otras herramientas de *marketing* digital que van a transformarse por el uso de los datos masivos.

*Palabras clave:* nuevos datos, sistemas de recomendación, clasificación de clientes, lealtad de clientes, probabilidades de abandono, redes de clientes.

---

\* Con el apoyo parcial de la Agencia Nacional de Evaluación de la Calidad y Acreditación con referencia PID2019-109196GB-I00.

## 1. INTRODUCCIÓN

El nombre *marketing* digital comenzó asociándose a la comercialización de productos y servicios utilizando canales digitales, pero ha evolucionado para incluir todos los aspectos ligados a la venta, incorporando la colaboración con otras empresas, clientes y organizaciones para crear valor para el accionista (Kannan, 2017). Su desarrollo es relativamente reciente, ya que hasta 1990 Internet no podía utilizarse para fines comerciales y el uso de la web estaba restringida a usos científicos y militares. En 1993 la web fue adaptada para ser aprovechada por los usuarios privados para la venta y una de las primeras compañías basadas en Internet fue Amazon en 1994. Desde entonces, la importancia de Internet en los negocios ha crecido de forma espectacular. Las mayores empresas del mundo, y de mayor crecimiento, han dejado de ser las compañías petroleras o de automoción, y han sido sustituidas por las organizaciones que, a través de la web, obtienen información constante sobre sus clientes, como Google, Amazon o Facebook.

Una de las consecuencias de Internet y de los avances en tecnologías de la comunicación es la aparición de los datos masivos, los llamados *big data*. Véase Marx (2013) para su impacto general y Erevelles, Fukawa y Swayne (2016) para la transformación del *marketing*. Los nuevos datos masivos han dado lugar a mejoras en los procesos comerciales, como los sistemas de recomendación y de retención de clientes, y han surgido nuevos modelos de negocio basados en ellos, como las grandes compañías de transporte de viajeros que no tienen un solo vehículo ni medio de locomoción. Por otro lado, los mismos datos se han convertido en un producto valioso, que, en bruto o una vez procesados para convertirlos en información, pueden venderse a posibles usuarios.

Muchas organizaciones recogen hoy en día información sobre sus clientes. Los datos se generan tanto en los procesos de venta como en el resto de las interacciones entre las empresas y los usuarios de sus productos y/o servicios. También existen en Internet otros datos sobre los clientes, que provienen del uso de las redes sociales, los teléfonos móviles, sensores de varios tipos etc., donde los usuarios han ido dejando un rastro de sus actividades. Las empresas que ofrecen productos *online* y que utilizan Internet para la comunicación con sus clientes, como las empresas de servicios financieros, de seguros, de telecomunicación y ocio y, en general, de venta de productos y servicios por la red (servicios de transporte, de alojamiento y turismo etc.), pueden utilizar estos datos para mejorar la venta de sus productos y servicios, mejorando con ello su posición en el mercado (véase, por ejemplo, Ryan, 2016; Sayyad *et al.*, 2018 y Saura, 2021).

Los datos brutos disponibles, como tiempo de visita de una página web, mensajes escritos en una red social o geolocalización de una venta, pueden convertirse en activos de valor comercial sobre las preferencias y deseos de los clientes con métodos de Ciencia de los Datos, o *Data Science*. Este enfoque incluye procesos de aprendizaje automático (*machine learning*, *ML* por sus siglas en inglés) e inteligencia artificial (o *AI*, *artificial intelligence*), combinados con métodos estadísticos (Galeano y Peña, 2019a). Los datos utilizados provienen no solo de mediciones numéricas y de tablas de variables, sino, también, de imágenes, textos o

señales de audio digitalizadas. La inteligencia artificial se ha concentrado en enseñar a máquinas digitales a aprender con los sentidos humanos, como la vista (reconocimiento de imágenes y clasificación de textos) y el oído (análisis de señales) y este conocimiento se incorpora a las mediciones tradicionales para realizar predicciones o clasificaciones de los clientes.

La información obtenida de estos datos masivos nos permite: a) prever el comportamiento futuro de un cliente en función de sus datos pasados; b) clasificar clientes en grupos homogéneos por sus comportamientos y utilizar esta clasificación para personalizar las ofertas y mejorar las predicciones individuales; y c) entender las variables clave que influyen en el comportamiento de los clientes para diseñar nuevas estrategias y canales de venta. Estos nuevos datos pueden no solo ayudarnos a mejorar lo que hacemos sino, sobre todo, a diseñar nuevos productos y estrategias comerciales para: 1) atraer, retener y satisfacer a los clientes; 2) utilizar el *marketing mix* para maximizar los resultados de las inversiones; 3) personalizar las estrategias de *marketing* para cada cliente en función de sus necesidades, y 4) aumentar la seguridad y privacidad de la venta *online* (Wedel y Kannan, 2016).

Este trabajo comienza describiendo cómo las imágenes y audios se convierten en ficheros digitales para ser transformados en información utilizable en el *marketing* digital. A continuación, se analizan tres herramientas comerciales de contrastada eficacia basadas en aprovechar la información sobre los clientes. Su estructura es la siguiente. En la sección 2 describimos brevemente cómo las imágenes y vídeos, así como las señales de audio, se convierten en datos digitales utilizables para la clasificación y la predicción. En la sección 3 analizamos una de las herramientas de *marketing* digital más conocidas y utilizadas: los sistemas de recomendación. La sección 4 presenta las nuevas técnicas de retención de clientes basadas en el cálculo de probabilidades de abandono y la toma de decisiones para garantizar su continuidad. La sección 5 está dedicada a una nueva herramienta para el *marketing* digital: al análisis de los clientes en red. Las redes de clientes permiten medir mejor la importancia relativa de cada uno, entender las relaciones entre ellos, desarrollar nuevas estrategias comerciales y predecir mejor variables clave para la rentabilidad del negocio. Finalmente, la sección 6 incluye algunas conclusiones finales.

## 2. LOS NUEVOS DATOS EN *MARKETING* DIGITAL: IMÁGENES Y SEÑALES

La vista y el oído son dos de las fuentes principales de recogida de información del ser humano y el *marketing* digital ha incorporado los datos conseguidos con estos sentidos como posibles herramientas comerciales. Es previsible que los otros tres sentidos adicionales, olfato, tacto y gusto, tengan también un impacto creciente en el *marketing* digital del futuro y el llamado *marketing* sensorial (Hultén, 2017; Hussain, 2019) se vislumbra como una nueva oportunidad en muchas áreas.

Las imágenes han sido una herramienta fundamental de venta para mostrar un producto de forma atractiva para el consumidor y desde el comienzo de la fotografía en el

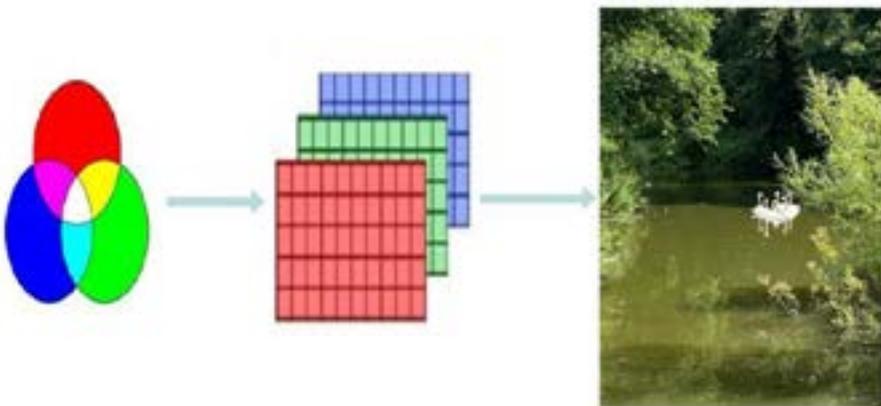
siglo XIX se han utilizado en publicidad. Si una imagen vale más que mil palabras, una adecuada presentación visual de un producto o servicio puede ser mucho más efectiva que una detallada descripción de sus propiedades o características. Por esta razón, durante el pasado siglo la fotografía ha sido una importante herramienta comercial y su uso generalizado para estimular las ventas ha contribuido a su gran desarrollo. En la actualidad, una adecuada imagen del producto es decisiva en los portales de compra y tiendas virtuales a las que se accede por Internet.

El desarrollo de las técnicas de análisis de imágenes digitales a finales del siglo XX ha abierto otras oportunidades para el uso de las fotografías y los vídeos en la promoción y venta de productos y servicios. Por ejemplo, Velasco *et al.* (2015) encontraron que una correspondencia entre el color del envase y el producto contenido estimula la venta en supermercados: cuando el color del paquete era congruente con el producto que contiene (rojo/tomate) el cliente lo encontraba más fácilmente, potenciando su venta, mientras que esta ventaja no aparecía sin esta congruencia (amarillo/tomate). Este resultado ilustra que medir la percepción que produce una imagen en un posible cliente puede ayudar a mejorar su etiquetado y su diseño.

Las imágenes hoy son una fuente de información frecuente sobre el consumidor y se están utilizando para desarrollar nuevas estrategias de venta. Fotos de los productos comprados o de las páginas visitadas por un cliente o grabación por vídeo de su comportamiento en el punto de venta, proporcionan datos valiosos sobre las personas que eligen un producto o servicio. Su análisis puede descubrir patrones de comportamiento de ciertos tipos de cliente, utilizables luego comercialmente. Otro uso de importancia creciente de las imágenes es para identificar y localizar productos: subiendo a un buscador o plataforma de compra una foto

Figura 1.

### Construcción de una imagen digital con el sistema RGB



Fuente: Elaboración propia.

de un producto, por ejemplo de un vestido, el buscador puede automáticamente identificar el producto y ofrecer su venta. Para ello, se requiere la capacidad de reconocer y clasificar imágenes mediante técnicas de inteligencia artificial.

Una imagen digital es un conjunto de muchos números dispuestos en filas y columnas en una estructura rectangular que llamamos matriz. Cada uno de estos números indica el color de una diminuta superficie cuadrada de la imagen que llamamos píxel. Estas imágenes digitales se denominan de mapa de bits, o *bitmap* y su resolución se define por el número de píxeles que contienen, bien en densidad, píxeles por pulgada (ppi) o por centímetro (pcm), o bien en número de píxeles totales. Por ejemplo, una resolución de un megapíxel equivale a un millón de píxeles, o a un cuadrado con 1.000 píxeles en cada lado.

Una imagen de un tamaño dado será tanto más nítida cuantos más píxeles contenga, y si aumentamos su tamaño, manteniendo el mismo número de píxeles, comenzará a verse borrosa. El ojo humano, como el de otros seres vivos, tiene un límite en la cantidad de píxeles que puede apreciar, aunque este límite es muy alto con relación a las cámaras actuales. El ojo no toma imágenes fijas, como una cámara, sino que está en continuo movimiento. Se estima que el ojo humano promedio tiene alrededor de 576 megapíxeles de resolución.

Cada píxel tiene un color uniforme y la sensación de color en la imagen se forma como resultado de integrar visualmente, en la retina, las variaciones de color y luminosidad entre píxeles vecinos. El color de cada píxel puede definirse de dos formas principales. En las figuras en blanco y negro, o en tonos de grises, el color se define por una matriz que contiene un número asociado para cada píxel, que es la intensidad de gris. En las figuras en color el método más utilizado, llamado RGB, es utilizar la intensidad de tres colores básicos, rojo (*red*), verde (*green*), y azul (*blue*) para generar mediante la combinación de estos tres colores cualquier otro. Para ello, se utilizan tres matrices del mismo tamaño y el número que contienen en cada casilla representa la intensidad de uno de los tres colores R, G y B. La combinación de estos tres números define el color asociado a cada píxel de la imagen. La figura 1 ilustra esta representación.

Para clasificar imágenes se utilizan sus píxeles, que pueden ser muchos, y normalmente los archivos *bitmap* se comprimen para procesarlos. Entre los sistemas de compresión más utilizados están el formato jpg, que desecha primero información no visible y el formato png que crea archivos algo mayores que el jpg.

## 2.1. Clasificación de imágenes

La clasificación de imágenes digitales consiste en asignar cada imagen a una clase. Estas clases pueden estar definidas *a priori*, por ejemplo, hombre o mujer, y entonces hablamos de clasificación supervisada o de discriminación. En estos casos las imágenes disponibles para construir el clasificador han sido previamente asignadas a los grupos y llevan cada una la etiqueta del grupo al que pertenecen. El objetivo es clasificar en uno de los grupos estableci

dos una nueva imagen que llega sin etiqueta. Por ejemplo, tenemos muchos datos de compras previas de personas que hemos identificado como hombres o mujeres y dado un conjunto de compras sin etiqueta queremos clasificar al comprador como un hombre o una mujer. Un problema diferente aparece cuando los datos disponibles no tienen etiquetas, de manera que los posibles grupos no están definidos *a priori*. El objetivo es ahora encontrar los grupos, si existen, a partir de los datos y hablamos entonces de clasificación no supervisada o análisis clúster. Una tercera situación, mezcla de las dos anteriores, es cuando tenemos datos híbridos, que es el caso de la clasificación semisupervisada. Algunos de los datos disponibles para construir el clasificador llevan etiquetas y otros carecen de ellas. Hay, por lo tanto, ya unos grupos definidos, como en la clasificación supervisada, pero nos planteamos la posibilidad de ampliar su número considerando nuevos grupos analizando los datos, como en el análisis clúster.

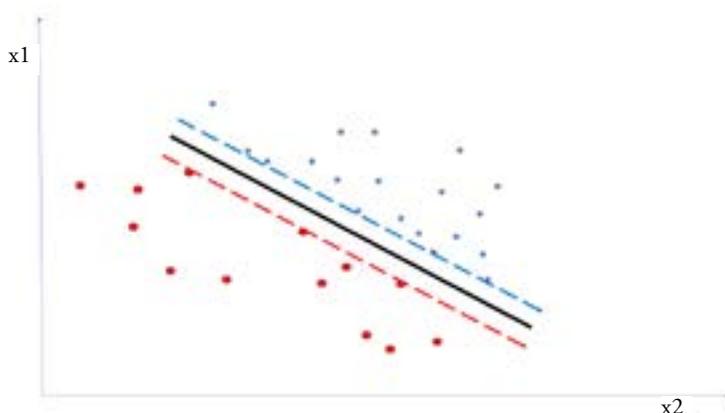
Consideremos inicialmente el problema de clasificación supervisada, o análisis discriminante, entre un grupo de clases previamente definido. Por ejemplo, clasificar una fotografía como incluyendo a personas o no. Para ello, los valores de los píxeles de la imagen se colocan formando un vector de tantos componentes como píxeles, de manera que el vector contiene en orden los valores de las filas (o de las columnas). Otra alternativa es resumir este vector en un conjunto de valores numéricos representativos de la imagen, como la media de los valores de los píxeles, la varianza o la correlación espacial entre los píxeles, y formar un vector de características asociado a cada imagen  $x$ , que tendrá habitualmente una dimensión mucho menor que el número total de píxeles en la imagen. Dada una nueva imagen calculamos su vector de características y lo comparamos con los de las imágenes en los grupos existentes.

La comparación puede hacerse de dos maneras: de forma global, comparando las características de la imagen con las medias de las características de cada grupo, o de forma local, comparando la imagen con las más similares de cada uno de los grupos. En ambos casos, la clasificación final se realiza calculando una medida de distancia entre el vector de características de la imagen a clasificar y las imágenes incluidas en cada uno de los grupos, asignando la imagen al grupo más próximo con un cierto criterio. Además de realizar la clasificación, podemos calcular una probabilidad de que la imagen pertenezca al grupo fijado, lo que nos define la incertidumbre en la clasificación.

Para concretar, supongamos el caso más simple de dos grupos. Disponemos de una muestra de entrenamiento con  $n_1$  elementos del primer grupo y  $n_2$  del segundo. Cada imagen se representa por un vector de dimensión  $p$  que contiene los valores de los píxeles de la imagen. Llamaremos  $\mathbf{x}_1, \dots, \mathbf{x}_{n_1}$  a los vectores del primer grupo y  $\mathbf{y}_1, \dots, \mathbf{y}_{n_2}$  a los del segundo. Tenemos una nueva imagen  $\mathbf{z}$  que queremos clasificar. Los métodos globales, que son los más utilizados tradicionalmente, calculan una medida de distancia entre los valores de la nueva imagen y las medias de los grupos, pero este procedimiento puede no ser muy útil para clasificar imágenes. Por ejemplo, la media de los píxeles puede ser un valor poco relevante para entender la separación entre los grupos y sería mucho más efectivo comparar los valores de un conjunto de píxeles determinados de ambos grupos. Por ejemplo, supongamos que las imágenes de la muestra no presentan separación entre los píxeles salvo para las dos primeras coordenadas,  $x_1, x_2$ , donde se observa la representación de la figura 2. Un análisis basado en todos los

Figura 2.

### Línea de separación de dos grupos de datos con máquinas de vector soporte (SVM)



Fuente: Elaboración propia.

píxeles y su valor medio, u otro resumen del conjunto de píxeles, no será efectivo para separar las imágenes, pero una combinación lineal de las dos variables representadas en la figura 2 permite separar ambas poblaciones. En este caso será más efectiva una separación local. Una técnica que utiliza este enfoque para realizar esta separación es una máquina de vector soporte o *support vector machine* (SVM). Este procedimiento trata de buscar el plano frontera entre los dos conjuntos de puntos que maximiza la separación entre ambos grupos. En la figura 2 el plano es una recta y representa la separación óptima que puede encontrarse entre ambos conjuntos de puntos.

Un tercer procedimiento es transformar el problema de la clasificación en un problema de predicción de la clase. Por ejemplo, con dos clases podemos representar la primera con la variable respuesta 0 y la segunda con la variable respuesta 1 y el problema es, conocidos los valores de las características, prever la clase. Definimos una variable a predecir,  $y$ , que puede tomar los valores cero y uno. Para predecir esta variable disponemos de una muestra de entrenamiento de imágenes con datos del valor de la respuesta  $y$  en cada imagen y de un vector de variables  $x$  que representa los píxeles de cada imagen. Los modelos de predicción tradicionales, como la regresión logística, suponen que, en el caso particular de dos clases, la probabilidad de pertenecer a la clase  $y = 1$  viene dada por una función del tipo:

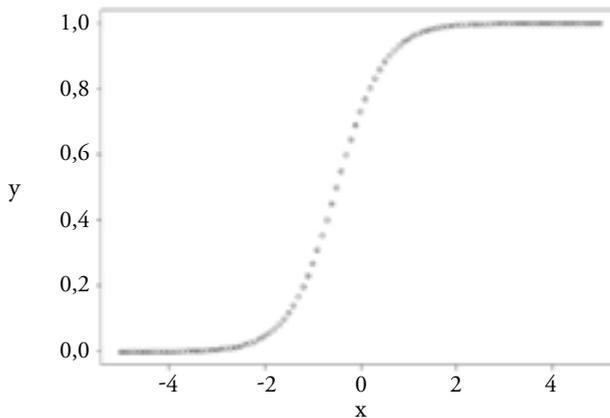
$$p(y = 1) = g(\mathbf{x}'\mathbf{b}) = g(b_0 + x_1b_1 + \dots + x_pb_p) \quad [1]$$

donde  $(x_1, \dots, x_p)$  son las variables explicativas, los píxeles de la imagen, y los coeficientes  $(b_0, b_1, \dots, b_p)$  tienen que estimarse con los datos. La probabilidad de la otra clase se obtiene con  $p(y = 0) = 1 - p(y = 1)$ , y  $g$  es una función no lineal que suele tomarse como la función logística, que aparece representada para el caso de una única variable explicativa en la figura 3. El gráfico muestra que la probabilidad de pertenecer a la clase  $y = 1$  aumenta con los valores

de  $x$ , primero lentamente, casi linealmente en un intervalo, y esta probabilidad se estabiliza a partir de valores altos de  $x$ . Con muchas variables el efecto reflejado en la figura 3, puede interpretarse como el de cada variable cuando el resto de las otras variables toma valores fijos. La pendiente en la zona de crecimiento depende del coeficiente de la variable,  $b_i$ , y será en general distinto para las diferentes variables.

Figura 3.

### Modelo logístico entre dos variables



Fuente: Elaboración propia.

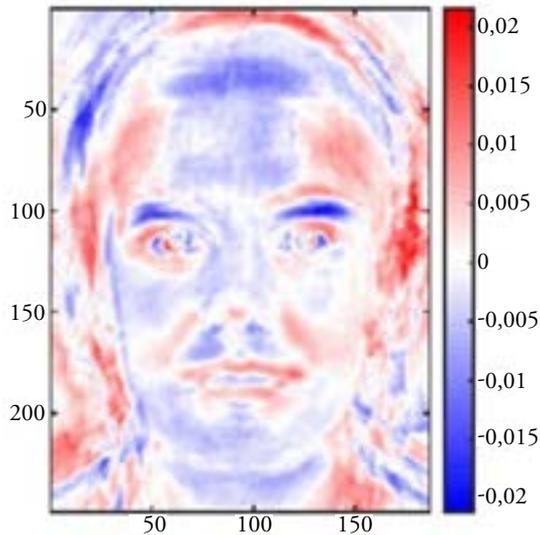
Este modelo puede generalizarse de forma que la relación entre la variable respuesta y la variable  $x$  sea más compleja utilizando redes neuronales. Una red neural supone muchas capas de modelos similares al [3], de manera que el efecto total se representa como superposición de muchas respuestas de tipo [3]. De esta manera puede demostrarse que es posible aproximar cualquier relación compleja entre la variable respuesta,  $y$ , y las explicativas  $x$ . Los métodos de clasificación mediante redes neuronales con varias capas se conocen como métodos de aprendizaje profundo. Véase, por ejemplo, Levi y Hassner (2015) para la clasificación de género y edad con redes neuronales.

En la sección siguiente presentamos un ejemplo simple de clasificación del género de una persona a partir de una imagen fotográfica.

#### 2.1.1. Un ejemplo de clasificación por sexo

La clasificación de un rostro humano correspondiente a un hombre o una mujer se utiliza frecuentemente en *marketing* en el análisis de vídeos que representan transacciones comerciales en puntos de venta. Este proceso requiere primero la identificación de los píxeles correspondientes al rostro en la imagen digital y, después, la clasificación de la cara como hombre o como mujer. Nos centraremos solo en este segundo aspecto, que ha sido muy estu-

Figura 4.

**Importancia de los píxeles para la discriminación entre hombres y mujeres**

*Fuente:* Elaboración propia.

diado desde el inicio de la estadística. Uno de los primeros trabajos en esta línea fue debido a Galton (1910), el inventor de la idea de regresión, que utilizó variables como ángulos y distancias entre las características de los rasgos faciales, (nariz, boca, etc.) para clasificar nuevas caras. Galton obtuvo para cada rostro un conjunto de medidas que comparaba con una base de datos de estas medias en rostros de hombres y mujeres. Desde entonces, este problema ha sido muy estudiado en distintos contextos, véase por ejemplo Zhao *et al.* (2003) y Kawulok, Celebi y Smolka (2016). Un problema importante cuando se trabaja con muchas imágenes es reducir la dimensión de cada matriz de píxeles sin perder información relevante para la clasificación. Existen procedimientos generales para comprimir imágenes, pero el proceso puede hacerse de manera más efectiva si tenemos en cuenta el tipo de imágenes que queremos comprimir y las características a mantener, vease Benito y Peña (2005) para la reducción de la dimensión en imágenes digitales de rostros.

Benito *et al.* (2017) han comparado distintos métodos de clasificación para rostros humanos y determinado las zonas de la cara humana más importantes para esta clasificación. La figura 4, tomada de Benito *et al.* (2017), muestra estas zonas: las zonas de mayor color son las de mayor poder discriminante y las zonas blancas las que tienen poca utilidad para la discriminación. El color azul indica zonas importantes en el rostro femenino y el rojo en el masculino. Las zonas más interesantes para la discriminación son las cejas, los ojos, la nariz, los labios, el mentón y la forma de la cabeza, donde la presencia de pelo corto o largo tiene un importante papel.

Shan (2012) presenta otras estructuras para la clasificación de género y Khan *et al.* (2020) aplican redes neuronales a este problema.

## 2.2. Análisis de señales de audio

La voz es una fuente importante de información en *marketing* digital. Por ejemplo, la atención telefónica actual se realiza habitualmente utilizando un programa de reconocimiento de voz, que clasifica el tipo de llamada para proporcionar la información solicitada. Si la información requerida es simple, se activa una respuesta codificada, en otro caso, la llamada se transfiere a un operador humano. La clasificación de las llamadas por su contenido requiere su análisis digital para comprender la voz humana. Para ello, el sonido captado por un micrófono, que recoge las vibraciones sonoras a través de una membrana, se convierte en señales eléctricas que son enviadas a un ordenador que las digitaliza, es decir, convierte estas señales en datos digitales como secuencias de ceros y unos, a través de la placa de sonido. El resultado obtenido puede representarse como una serie temporal o una función a lo largo del tiempo. Estas secuencias digitales se convierten de nuevo en sonido mediante altavoces, como indica la figura 5.

Figura 5.

### Representación digital del sonido



Fuente: Elaboración propia.

El reconocimiento de voz requiere definir los fonemas o sonidos básicos de un idioma, generalmente asociados a las letras que lo forman y a las combinaciones de letras, e identificarlos en la secuencia para formar palabras. Para reconocer cada fonema se utiliza, en primer lugar, su forma digital habitual. Cada fonema se transforma en una secuencia específica de ceros y unos en su representación digital que caracteriza su sonido y se busca esta secuencia en un archivo de sonidos digitales. Este es un problema de clasificación similar al estudiado para clasificar los rostros humanos, pero ahora en lugar de dos clases, hombre y mujer, tenemos que clasificar cada sonido en uno de los numerosos fonemas del idioma.

La mayoría de los idiomas tienen entre 20 y 35 fonemas. Por ejemplo, el español tiene 24 fonemas (5 vocales y 19 consonantes) y es uno de los idiomas latinos más simples: por ejemplo, el italiano tiene 34 fonemas y el francés, 37. Los idiomas del norte de Europa son más complejos que los derivados del latín: el inglés tiene 44 fonemas y el danés llega hasta 50 (30 vocales y 20 consonantes), y existen idiomas en África con 85 fonemas. Un problema adicional es que es frecuente que en el idioma existan distintos acentos, o forma de pronun-

ciación, por lo que distintas personas lo emiten de forma diferente. Por tanto, hay que definir la clase de sonidos que corresponden a cada fonema, que a veces es muy amplio, y que llamaremos la clase de sonidos del fonema. El objetivo es, por tanto, clasificar las señales digitales en estas clases de fonemas.

La clasificación de sonidos se realiza de forma más efectiva con métodos locales, utilizando una amplia base de datos de pronunciaciones del idioma. Estos diccionarios de palabras (*speech database*), se construyen grabando previamente a muchos locutores de un idioma. El sistema clasifica los conjuntos de fonemas dentro de ese diccionario para identificar, o escuchar, las palabras pronunciadas. Estos métodos mejoran además con la experiencia de su uso, porque se puede ir ampliando la base de datos de sonidos al aplicar el clasificador cuando es posible comprobar si esta ha sido correcta y se ha clasificado con éxito. Por esta razón, es frecuente que la máquina pida la confirmación al cliente sobre su comprensión, de manera que puede etiquetar los sonidos escuchados en la clase correcta e incorporarlos a la base de datos, mejorando su funcionamiento con la experiencia. En este sentido el sistema aprende con su uso, propiedad muy deseable en un clasificador. Por ejemplo, si utilizamos una metodología de clasificación como las máquinas de vector soporte que se describieron en la sección anterior, la base de elementos con etiqueta bien clasificados aumenta continuamente mejorando la precisión del clasificador.

La clasificación inicial de los sonidos, cuando la base de datos disponible no es muy grande, puede mejorarse utilizando, además, las probabilidades de transición entre fonemas del idioma, es decir, la frecuencia con la que cada fonema aparece a continuación de uno dado. El reconocimiento de voz puede hacerse más preciso cuando es posible añadir un sistema de vídeo que analiza los labios del emisor para identificar los fonemas que utiliza. La evidencia demuestra que mezclando ambos métodos, el visual y el auditivo, se obtiene un sistema más potente. Véase Gong (1995), Padmanabhan y Premkumar (2015) y Nassif *et al.* (2019) para una descripción de los procedimientos utilizados en el reconocimiento de voz.

Los sistemas de reconocimiento de voz han dado lugar a los asistentes digitales, que, además de contestar preguntas de los usuarios, como Alexa de Amazon o Siri de Apple, pueden realizar acciones de asistencia como poner música, encender las luces o buscar el significado de una palabra en un diccionario. También comienzan a incorporarse en los sistemas de recomendación, que describimos en la sección siguiente.

### 3. SISTEMAS DE RECOMENDACIÓN

La selección de productos por un cliente dentro de una amplia oferta de los mismos se simplifica con ayuda de los sistemas de recomendación. Estos sistemas ofrecen al usuario productos que pueden interesarle y le ayudan a encontrar otros artículos atractivos para su perfil entre los disponibles. El rápido crecimiento de Internet y del comercio electrónico han propiciado la proliferación de estos sistemas de *marketing* digital. Véase Smith y Linden (2017) para

un análisis de la experiencia de Amazon, pionera en este campo y Kumar y Thakur (2018) para una revisión amplia de estos sistemas.

Los sistemas de recomendación (SR) pueden clasificarse en tres categorías dependiendo del procedimiento utilizado para construirlos: 1) por contenido; 2) filtros de colaboración, y 3) métodos híbridos. Los SR por contenido se basan en la historia pasada de compras similares del cliente, por ejemplo, recomendar una película histórica a clientes que en el pasado han elegido este tipo de películas. Es el procedimiento más simple y el que utilizaría un vendedor familiarizado con las compras previas de un cliente. Se aplica frecuentemente en las páginas web y en las recomendaciones de noticias. Los SR por filtros de colaboración requieren más información, porque utilizan para hacer la recomendación las compras realizadas por otros clientes con características similares al actual, o de productos similares a los que el cliente ha comprado, y pueden, por tanto, proponer artículos en los que el cliente no ha pensado y que desconoce. Este método trata, por tanto, de anticiparse a los deseos del cliente y de hacerle recomendaciones de productos cuya existencia ignora. Los sistemas híbridos combinan la historia de compras del cliente con las de otros clientes similares para generar las recomendaciones.

Los filtros colaborativos comenzaron a utilizarse en los años noventa cuando los científicos de datos de Amazon propusieron un sistema de recomendación, Linden *et al.* (2003), que ha tenido gran difusión. Los métodos más utilizados inicialmente se basaban en asociar a cada cliente un conjunto de “vecinos” definidos como personas con compras similares a las suyas. A cada vecino de un cliente se le asigna un número que mide su grado de afinidad, que depende de su distancia entre su vector de compras y el del cliente para el que construimos la recomendación, utilizando distintas medidas de proximidad para asociarles. La recomendación se hace considerando el grupo de clientes más próximos al actual y recomendando primero los productos más frecuentemente comprados en ese grupo y que no han sido todavía adquiridos por el cliente.

La idea de Linden, Smith y York (2003) para construir el SR de Amazon fue buscar similitudes, no entre los clientes, sino entre los productos. Partiendo de los datos de compras, se construye una matriz donde aparecen todos los productos y clientes y sus compras. Con esta matriz podemos calcular probabilidades de compra de productos y de pares de productos. Dos productos,  $X$ ,  $Y$ , están relacionados cuando su probabilidad de compra conjunta  $P(X, Y)$  es mucho mayor que el producto de las probabilidades de sus compras individuales  $P(X)P(Y)$ . Con esta idea básica se establece una asociación entre productos. Naturalmente esta idea de asociación requiere ajustes para tener en cuenta los tiempos de compra, disponibilidad etc., pero es la base del método. De esta manera, para cada cliente se crea una base de productos “vecinos” a los ya comprados, que es la base de las recomendaciones.

La ventaja de este enfoque es que el énfasis del procedimiento es fijarse en los productos comprados, no en los compradores, con lo que se capta mejor la esencia del impulso de compra. Por ejemplo, dos personas pueden compartir su afición a la pesca y muchos de los aficionados a la pesca compran automóviles, que utilizan para ir a pescar. Por tanto, es natural que un sistema basado en la asociación pesca/coche recomiende a un pescador

que no conduce artículos para vehículos. Esto no ocurre al utilizar los artículos comprados por la persona objeto de la recomendación. El método tiene además la ventaja de que los cálculos intensivos, las probabilidades de compra y las medidas de asociación, se realizan *offline*, con lo que puede aplicarse de forma rápida en el momento de hacer la sugerencia. La aplicación después a millones de clientes puede hacerse de manera muy rápida, así como la actualización de las recomendaciones con nuevos datos.

Los sistemas de recomendación han sido criticados por el uso de información confidencial. Desde 2006 a 2009, Netflix estableció un premio de 1.000.000 de dólares al equipo que con una base de datos consistente en un conjunto de 100 millones de evaluaciones anónimas de películas pudiese generar recomendaciones que superasen al menos en un 10 % a su sistema de recomendación, basado en filtros colaborativos. El mejor sistema premiado en 2007 utilizaba una combinación de 107 métodos distintos. Sin embargo, ese mismo año investigadores de la Universidad de Texas identificaron a los usuarios supuestamente anónimos que habían dado las evaluaciones de las películas cruzando los datos de Netflix, que efectivamente eran anónimos, con los abiertos del Internet Movie Database de Amazon. Esto llevó a una demanda contra Netflix por difundir información privada y a la cancelación del premio. Desde entonces, la privacidad de los sistemas de recomendación ha sido objeto de polémica, especialmente en el campo de la salud, donde este tema es especialmente sensible, véase por ejemplo Katzenbeisser y Petkovic (2008).

A pesar de estas críticas, el éxito de estos sistemas ha contribuido a su difusión. Amazon estima, Smith y Linden (2017), que un 30 % de sus ventas se generan por los sistemas de recomendación y Netflix ha estimado que el 80 % de las películas que ven sus usuarios son consecuencia de sus sugerencias. Los sistemas híbridos son muy utilizados en la actualidad, combinando métodos de predicción basados en modelos con técnicas de clúster y asociación para clientes y productos. Los sistemas de recomendación se han demostrado además útiles para desarrollar la lealtad del cliente. Por ejemplo, Wang *et al.* (2009) han propuesto un procedimiento de sugerencias para empresas de redes inalámbricas para evitar la deserción de clientes, un problema que estudiaremos en la sección siguiente.

Los sistemas de recomendación están incorporando el uso de voz y combinándose con los asistentes digitales para proporcionar sugerencias y asistencia de forma verbal a solicitudes varias del cliente, como encontrar un restaurante vegetariano, reservar una habitación en un hotel o comprar las entradas de un espectáculo.

#### 4. SEGUIMIENTO DE LA LEALTAD DE LOS CLIENTES

En un entorno de alta competencia y con clientes bien informados las empresas necesitan retener a sus clientes: un cliente no satisfecho puede expresar las razones de su abandono en Internet y las redes sociales dañando la imagen de la empresa y disminuyendo su probabilidad de captar nuevos clientes en el futuro y de retener los actuales. Comprender la perspectiva de los clientes y su grado de satisfacción es clave para la supervivencia de la empresa y la mejor

estrategia de *marketing* es la centrada en retener a los clientes y evitar su fuga (*customer churn*, en inglés) a la competencia (Kim y Yoon, 2004).

Existen dos tipos principales de estrategias ante el abandono de clientes: la conservadora y la proactiva. Una estrategia conservadora espera a que los clientes manifiesten su deseo de abandonar para ofrecerles incentivos para quedarse, como rebajas de tarifas o servicios especiales. La segunda, que es más efectiva, es identificar clientes descontentos y ofrecerles incentivos para quedarse, antes de que decidan abandonar. Para ello, es imprescindible establecer un sistema para reconocer a los clientes que comienzan a estar descontentos y estimar sus probabilidades de deserción. Es posible, entonces, diseñar una buena estrategia acoplando los incentivos a las probabilidades de abandono de manera que se maximice el beneficio esperado a largo plazo (Burez y Van den Poel, 2007).

El objetivo es disponer de una ecuación

$$p_i(t) = f(\mathbf{x}_i) \quad [2]$$

que nos permita prever la probabilidad de que un determinado cliente definido por un vector de características  $\mathbf{x}_i$  continúe utilizando los servicios de la compañía durante un periodo  $t$ . Las variables explicativas que pueden utilizarse son su historial de compras y relaciones con la empresa (quejas o reclamaciones, en su caso) y sus características personales. Para poder estimar esta ecuación necesitamos una base de datos de clientes que han permanecido fieles y, también, de exclientes que han abandonado el sistema. Estos datos son más fáciles de recoger en sectores donde el cliente y su actividad de compra de productos o servicios están bien identificados, como en las compañías telefónicas o de servicios de ocio por Internet, en empresas financieras etc., y la mayoría de los estudios realizados corresponden a estos sectores. Sin embargo, progresivamente otras empresas han tratado de recoger esta información buscando la fidelización de los clientes con tarjetas-cliente para descuentos, como las que han introducido muchos supermercados y superficies comerciales.

El procedimiento inicialmente utilizado para estimar una ecuación de lealtad del tipo [2] con pocas variables es el denominado modelo logístico, que hemos descrito brevemente en la sección 2 y cuya respuesta para una única variable explicativa se ha representado en la figura 3. Supongamos, por ejemplo, que la única variable explicativa,  $x$ , corresponde al consumo diferencial del cliente de un sistema de pago TV en un periodo determinado y que el consumo diferencial se calcula por la diferencia entre el tiempo de uso del cliente y el tiempo medio de uso de este sistema del cliente promedio. Si la relación entre la probabilidad de permanencia y el uso diferencial se explica por un modelo logístico la figura 3 indica que la probabilidad de permanencia es tanto mayor cuanto mayor sea su tiempo relativo de utilización. Con muchas variables la interpretación para cada una es similar y llamando  $p_i$  a la probabilidad de permanencia, y  $1 - p_i$  a la de abandono, la ecuación de un modelo logístico es del tipo:

$$g_i = \log \frac{p_i}{1 - p_i} = \beta_0 + \beta_1 x_{1i} + \dots + \beta_k x_{ki} \quad [3]$$

La ecuación [3] nos dice que en un modelo logístico el efecto de las variables sobre el logaritmo de la ratio entre las probabilidades de continuar y abandonar es lineal. Como comentamos en la sección 2, podemos estimar relaciones más complicadas de forma no lineal utilizando redes neuronales, que pueden considerarse la generalización no lineal de un modelo logístico (véase Caro y Peña [2021], para una explicación simple de estas redes para la predicción, y Peña y Tsay [2021] para un análisis más amplio aplicado a variables que evolucionan con el tiempo). Alternativamente, podemos utilizar un sistema de clasificación, como explicamos en la sección 2. Verbeke *et al.* (2011) han abordado este problema con máquinas de vector soporte que proporcionan el plano de separación entre las dos categorías de clientes y permiten también identificar las variables más importantes para la predicción.

En muchos casos la base de clientes de que disponemos no contiene siempre la información de si el cliente ha abandonado o no el sistema. Podemos entonces utilizar un sistema semisupervisado, donde tenemos la información completa para unos clientes, pero nos faltan las etiquetas para los otros. Esto supone realizar el estudio en dos pasos: primero clasificamos a todos los clientes sin etiqueta en uno de los dos grupos y luego, tomando como resultado la probabilidad asignada a cada uno, obtenemos la ecuación para el cliente de interés. En la sección siguiente describimos con más detalle el procedimiento de estimación de estas probabilidades en un sector muy competitivo, con muchas ofertas y productos similares: el sector de los grandes centros de distribución y venta de alimentos.

#### 4.1. Tipos de clientes y probabilidades de abandono

Los tipos de clientes pueden clasificarse por su frecuencia o intensidad de uso y por su actitud ante la empresa. Dick y Basu (1994), en un influyente artículo, propusieron cuatro tipos de clientes resultado de cruzar su intensidad de uso con la actitud ante la empresa. De esta forma podemos tener clientes leales (alta frecuencia y buena actitud), con lealtad latente (baja frecuencia, buena actitud), con lealtad espuria (alta frecuencia, baja actitud) y no leales (baja frecuencia y actitud). Heiens y Pleshko (1996) han estudiado la frecuencia de estos cuatro tipos de clientes en el mercado de hamburguesas de comida rápida encontrando una frecuencia similar en todas ellas, con la categoría más frecuente, no lealtad, del 32 % y las menos frecuentes, las lealtades espuria (20 %) y latente (18 %). Los leales representaban el 26 %.

Muchos estudios han relacionado la satisfacción del cliente con la lealtad y otros han puesto el énfasis en las relaciones emocionales y de identificación del cliente con la marca. Por ejemplo, Yu y Dean (2001) argumentan que la contribución de la satisfacción emocional es mejor predictor de la lealtad que la satisfacción cognitiva o racional. Knox y Denison (2000) han estudiado la lealtad al supermercado en el Reino Unido y los tipos de comportamiento del consumidor.

En el campo específico de estimación de probabilidad de abandono en un supermercado, Galeano y Peña (2019b) describen un ejemplo aplicado a una cadena de supermercados en España. Para detectar cuándo un cliente muestra signos prematuros de abandono, como

disminuir su frecuencia de compra o su intensidad de gasto, utilizan la existencia de una tarjeta de descuentos con la que se recoge información inmediata sobre sus compras. Con estos datos es posible generar para cada cliente una serie de actividad, que tiene el valor uno cuando el cliente realiza una compra o devolución y una serie de importes que recoge el coste de las compras, o devoluciones realizadas. Suponiendo que se elige un periodo fijo de análisis de un mes, en ese periodo para cada cliente  $i$  existe una probabilidad de actividad  $p_i$ . Esta probabilidad puede estimarse como el cociente entre los meses con actividad y los meses totales y clasificar a los clientes por su actividad. Típicamente, en los supermercados se detectan tres tipos de clientes:

- Clientes que tienen actividad todos los meses, o *clientes fieles*. La proporción de clientes fieles depende de cada supermercado pero varía entre el 10 % y el 30 % de los clientes totales. Además estos clientes son los que más gastan, del orden de un 100 % más que los frecuentes y del 150 % más que los ocasionales.
- Clientes con mucha actividad, o *clientes frecuentes*. Los clientes frecuentes son los que tienen una frecuencia de actividad menor del 100 %, pero superior a la mediana. Suelen representar entre el 20 % y el 50 % de los totales.
- Clientes con poca actividad, o *clientes ocasionales*. Los clientes ocasionales son los que tienen una frecuencia menor o igual a la mediana. Suelen representar entre el 40 % y el 60 % del total.

Existe evidencia (véase, por ejemplo, Galeano y Peña, 2019a) que en el sector de la alimentación el abandono se produce de forma gradual, de manera que se comienza probando la compra en otro centro que, si presenta ventajas competitivas, va sustituyendo poco a poco al actual. Por tanto, aunque por supuesto existen casos de abandono brusco por problemas concretos o cambios de domicilio, el abandono habitual de un cliente se manifiesta prematuramente en la disminución de la frecuencia de compra o de la intensidad de gasto en ella. Su comportamiento depende del tipo de cliente: un cliente fiel puede dejar de comprar todos los meses, pasando a la categoría de clientes frecuentes o puede disminuir el importe de sus compras, continuando como cliente fiel. Si deja de comprar en un mes dejará de pertenecer a la clase de fieles y será estudiado como cliente frecuente. Por tanto, para clientes fieles el único identificador de un posible abandono es una disminución en la magnitud de sus compras. Para los clientes frecuentes y ocasionales una disminución de actividad puede traducirse en un aumento del tiempo entre compras, un aumento de las rachas sin actividad, o en una disminución de los importes de compra.

Se puede construir un modelo que estime la probabilidad de abandono en función de su historia pasada de compras y de las variables que describen sus características personales. Su historial de compras puede representarse con variables como el nivel relativo actual de compras respecto al pasado, el número de cambios de nivel, positivos y negativos que han ocurrido en sus compras, su frecuencia de compra etc. Las variables personales pueden ser el sexo, la edad, el número de personas en el hogar, la antigüedad como cliente, el tipo de medios de pago utilizado, etcétera.

## 5. ANÁLISIS DE LOS CLIENTES EN RED

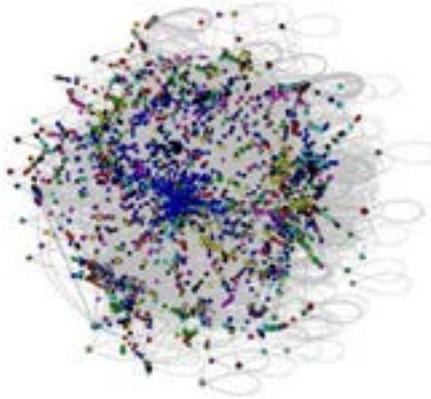
Una estructura potencialmente muy útil para el *marketing* digital es la consideración de los clientes en red. Una red, o grafo, puede representarse como un objeto matemático formado por vértices, o nodos, y aristas, o flechas. En su aplicación al *marketing* digital los nodos representan habitualmente clientes y las aristas transacciones o relaciones entre ellos. Por ejemplo, una red social, como Facebook o Instagram, está formada por nodos, que son las personas con cuenta en la red, y aristas, que representan las conexiones por relaciones de amistad entre las personas. Estas conexiones pueden ser todas iguales o podemos diferenciarlas, indicando en cada arista un número que representa la fuerza o intensidad de la relación. Por ejemplo, la intensidad puede definirse por el número de interacciones en la web entre las dos personas en un período de tiempo.

Una red de clientes se construye con la información disponible sobre las relaciones entre ellos. Por ejemplo, en un club deportivo o en un gimnasio se establecerán conexiones entre los usuarios que realizan actividades conjuntas. En una institución financiera podemos estar interesados en dos redes distintas: primero, de relaciones económicas entre los clientes; segundo, de relaciones personales. Cada cliente (que puede ser una persona o una empresa) será un nodo o vértice y las aristas representan relaciones o flujos entre dichos clientes, que suelen ser de distinta intensidad. Las relaciones pueden ser de parentesco o económicas. Por ejemplo, ser avalista de un crédito establece una relación económica entre los clientes, mientras que una transferencia recibida con un mensaje de felicitación indica, además, una relación de amistad o parentesco entre las dos personas. La representación gráfica de una red es útil con pocos clientes, véase por ejemplo la red representada en la figura 9 que comentaremos después, pero se vuelve muy compleja cuando este número es grande. Por ejemplo, la figura 6 representa una red de clientes en una institución bancaria con varios miles de personas y donde los colores indican distintos tipos de clientes. Es claro que el análisis de esta red requiere herramientas analíticas para su comprensión.

Para realizar un análisis descriptivo de una red se utilizan varias características, incluyendo medidas que midan la centralidad (importancia) de los clientes con el objetivo de cuantificar las relaciones de poder, protagonismo, confianza, etc., y la detección de comunidades específicas que puedan tener características interesantes a estudiar. Se denomina componente conexas de una red a una subred, es decir, una parte de la red, en la que todos sus vértices están conectados y a la que no se pueden añadir más vértices que cumplan dicha propiedad. Si un grafo tiene solo un componente conexo que incluye a todos los miembros, eso indica que siempre es posible llegar de un cliente a otro a través de un camino en la red. Si la red tiene varias componentes conexas puede dividirse en diversas redes separadas entre sí y donde los clientes no se comunican con los de otras redes. Habitualmente en redes de clientes la mayor componente conexas incluye una fracción muy significativa del mismo y se la denomina componente gigante. El resto de componentes se denominan componentes aisladas.

Un aspecto importante de las redes es obtener medidas de centralidad de los clientes. Por ejemplo, las figuras 7 y 8 representan distintos subgrupos en una red que no forman

Figura 6.

**Una red con muchos clientes**

*Fuente:* Elaboración propia.

componentes conexas porque están conectados unos con otros por clientes claves que hacen de puente entre estos subgrupos de clientes. En la figura 7 los grupos están identificados por colores distintos y hay varios clientes que juegan este papel de puente entre los subgrupos. Sin embargo, en la figura 8 se representan dos grandes grupos de clientes que solo están conectados por un nodo central que representa, en consecuencia, un cliente de gran valor estratégico.

Las medidas de importancia de los miembros de una red pueden calcularse de varias formas. Un primer enfoque es juzgar la importancia de un cliente por el número de relaciones o vértices que llegan a él y, si estas tienen distinta intensidad, ponderadas por su importancia relativa. Este método tiene la ventaja de que permite calcular la importancia de cada cliente aisladamente, y el inconveniente es que solo utiliza la información de las relaciones directamente conectadas al cliente. Una segunda opción más compleja es definir la centralidad de un cliente por la importancia media de los clientes a los que está conectado. Este método utiliza toda la información de la red para definir la importancia de cada cliente, pero requiere obtener todas las importancias de los clientes simultáneamente.

Este segundo enfoque fue el utilizado por Google para definir la importancia de las páginas web en su buscador (Page *et al.*, 1999). Para explicar su construcción, consideremos una red con  $N$  vértices de clientes y definamos la importancia del cliente  $i$ , que llamaremos  $I(i)$ , como un promedio de la importancia de los clientes a los que está conectado, es decir:

$$I(i) = c \sum_{j \rightarrow i} I(j) / N_i \quad [4]$$

donde el sumatorio afecta a todos los vértices que están conectados con el vértice  $i$  y  $N_i$  es el número total de vértices que están conectados al vértice  $i$ . Tendremos una ecuación con

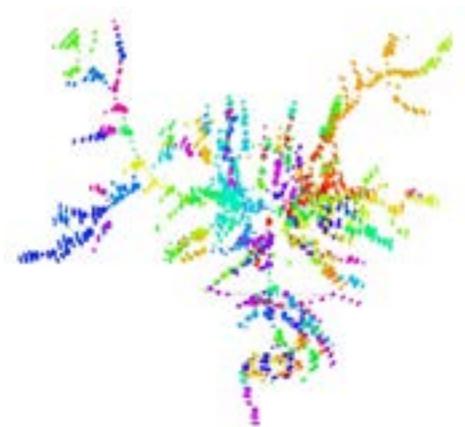
esta forma para cada uno de los  $N$  clientes en la red. Para resolver este sistema de ecuaciones llamemos  $I$  al vector con  $N$  componentes que representan la importancia de cada uno de los  $N$  vértices de la red. Definamos ahora una matriz  $A$  de conexiones entre vértices, que tiene coeficientes  $a_{ij}$  que tomarán el valor 0 si los nudos  $i$  y  $j$  no están conectados y el valor  $1/N_i$  cuando lo están. Es decir, la fila de la matriz  $i$  que corresponde a este vértice tiene  $N - N_i$  elementos iguales a cero, para los vértices no conectados al  $i$ , y  $N_i$  vértices para los conectados al  $i$ , con valores  $1/N_i$ . La suma de los elementos de las filas de la matriz es, por tanto, siempre igual a uno, es decir, llamando  $\mathbf{1}$  al vector de unos se verifica que el producto de la matriz de conexiones,  $A$ , por el vector de unos,  $\mathbf{1}$ , es otro vector de unos, es decir:

$$A\mathbf{1} = \mathbf{1} \quad [5]$$

Esta condición implica que el vector de unos no se modifica al multiplicarlo por la matriz  $A$ . Se denominan vectores característicos o propios de una matriz aquellos que solo se modifican por una constante al multiplicarlos por la matriz.

Figura 7.

**Una red con varios grupos de clientes (los colores indican diferentes tipos de clientes)**



Fuente: Elaboración propia.

El conjunto de las  $N$  ecuaciones [4] puede escribirse utilizando la notación de vectores y matrices como:

$$I = cAI \quad [6]$$

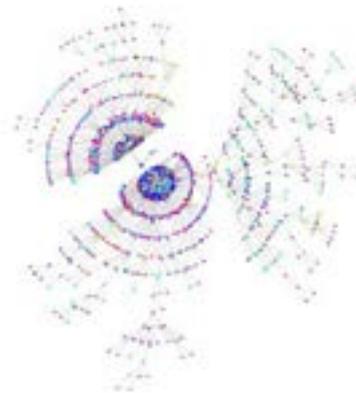
y el vector de importancias que buscamos,  $I$ , debe ser un vector propio de la matriz de conexiones  $A$ , multiplicado por una constante, que se denomina valor propio,  $c$ . Esta ecuación tiene la solución trivial  $I = \mathbf{1}$  y  $c = 1$  donde todos los vértices tienen la misma importancia y corresponde a la condición que hemos establecido de que las filas de la matriz de conexiones

sumen la unidad. La solución que buscamos es aquella que hace máxima  $c < 1$  y el vector propio asociado será el que define la importancia de cada vértice. Esta solución puede obtenerse con un método iterativo general para obtener vectores y valores propios de una matriz. Este criterio se conoce a veces como la centralidad por valor propio o centralidad Pagerank, y fue desarrollado por Page *et al.* (1999) para medir la importancia de las páginas web en el buscador inicial desarrollado por Google. Las páginas de la web forman una red donde cada una está conectada a otras por links y la importancia de una página depende de la importancia de sus conexiones a otras. Este método ha sido utilizado extensamente a partir del éxito alcanzado por el buscador de Google.

La red de clientes de una empresa es una fuente de información muy importante para el *marketing* digital en varios aspectos. En primer lugar, permite entender y medir la importancia de cada cliente analizando su posición en dicha red. Tradicionalmente, se ha medido la importancia de un cliente por el valor de sus compras o de sus activos. Sin embargo, una mejor medida es el coste que supone su pérdida. Un cliente aislado deja de serlo y las consecuencias negativas son su retirada. La deserción de un cliente muy conectado puede producir consecuencias negativas por su influencia negativa sobre otros clientes. El coste de perder un cliente depende de su importancia estratégica dentro de la red de clientes, que puede hacer que esta pérdida se multiplique.

Figura 8.

### Dos grupos de clientes conectados por una única persona



Fuente: Elaboración propia.

Por ejemplo, consideremos el efecto de una persona muy influyente en las redes sociales que envía informaciones poco favorables sobre la empresa. El coste de su marcha puede ser mucho mayor que la pérdida de los ingresos que aportaba, si su comportamiento arrastra a otros usuarios a seguir su ejemplo. Conociendo las relaciones entre los clientes en forma de red, podemos medir la importancia de cada una de forma mucho más precisa. Por ejemplo,

en la figura 8, dos grandes grupos de clientes están conectados por una persona. Si esta desaparece las consecuencias de su marcha pueden ser muy importantes.

En segundo lugar, la red de clientes es una pieza fundamental para captar la presencia de grupos de clientes cohesionados (con fuertes relaciones entre ellos). Conocer la presencia de estos grupos es muy relevante para orientar determinadas políticas comerciales. Por ejemplo, podemos analizar las características de estos grupos y crear productos específicos apropiados para ellos, como en los sistemas de recomendación. Sin embargo, la ventaja de la red es poder localizar a los clientes centrales dentro de la subred creada por cada grupo para mejorar la distribución de la información sobre dichos productos. Determinar la presencia de grupos de clientes fuertemente enlazados se conoce con el nombre de detección de comunidades. El problema consiste en obtener una partición de la red en varias subredes, de tal manera que los miembros de cada una de las subredes tengan una fuerte relación entre ellos y escasa con los miembros de otras. Una medida de la calidad de una partición es la modularidad, que se define como la suma para cada una de las subredes de las diferencias entre el número de relaciones dentro de la subred con respecto al esperado si no existiese tal estructura de comunidades. Cuanto mayor sea el valor de la modularidad de una red, más significativa será la presencia de los grupos.

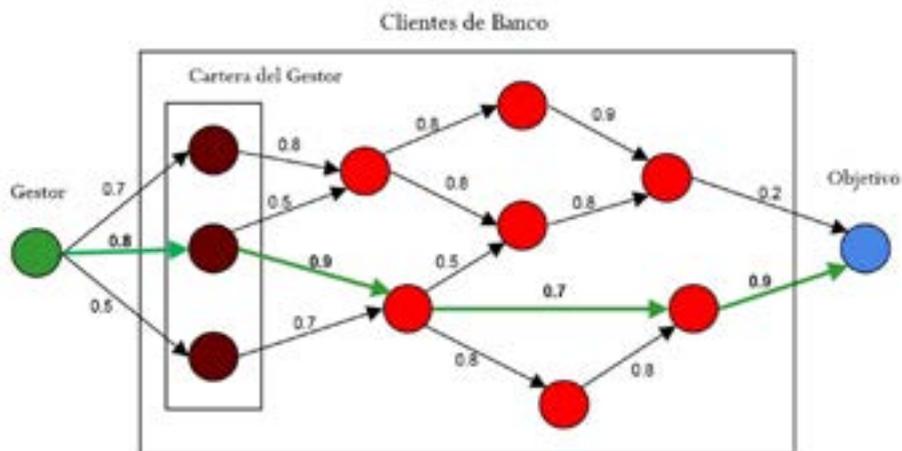
En tercer lugar, la red de clientes puede ser utilizada para explicar y predecir determinados comportamientos de los clientes y prever las consecuencias de sucesos económicos. Por ejemplo, en una red de clientes de una institución bancaria podemos estudiar el efecto de que una empresa que paga sus nóminas a sus trabajadores, que son miembros de la red, entre en suspensión de pagos. Esto desencadena un efecto que puede seguirse a lo largo de la red y que afecta a sus proveedores, pero también a muchos otros, como por ejemplo a los propietarios de viviendas alquiladas por los trabajadores de esa empresa.

En cuarto lugar, las variables de la red pueden ser útiles para explicar otras variables de interés. Por ejemplo, Galeano y Peña (2019a) y (2019b) detectaron que la red de clientes de un banco contiene variables importantes para la predicción de la morosidad. Prever que un cliente va a entrar en mora es *a priori* un problema complicado. Una opción es utilizar su información personal, como su edad, su estado civil, su salario y patrimonio etc. Sin embargo, se detectó que la variable más importante para prever la morosidad es el número de relaciones a un paso que tiene el cliente en la red con otros clientes que han entrado en mora. *A posteriori* este hecho parece muy razonable, ya que si una persona tiene sus relaciones con personas sin problemas económicos es más fácil suponer que tampoco los tendrá. Sin embargo, estas variables solo pueden medirse cuando se construye la red.

En quinto lugar la red puede ser importante para desarrollar nuevas políticas comerciales. Por ejemplo, las relaciones entre los clientes pueden ayudar a los comerciales a captar o influir en otros. Como ejemplo, la figura 9 muestra un ejemplo de una red diseñada para captar clientes a través de gestores que utilizan las relaciones de los clientes para conectar con otros. Los valores que aparecen en las aristas son las probabilidades de éxito. Véase Quijano-Sanchez y Liberatore (2017) para una descripción de este tipo de redes en el sector financiero.

Figura 9.

**Ejemplo de una red para captar clientes (los números en las aristas representan la probabilidad de que la interacción del nudo origen al destino representada por la arista que los une tenga éxito)**



Fuente: Elaboración propia.

Por último, se está iniciando el estudio de las redes dinámicas, donde las relaciones entre los nodos se representan como series temporales, es decir, con una secuencia de valores a lo largo del tiempo. Por ejemplo, en una red social podemos representar la relación mensual entre dos personas por la secuencia de sus intercambios diarios, que forman una serie temporal. El análisis de la red implica ahora entender cómo unas relaciones influyen sobre otras a lo largo del tiempo, lo que permitirá generar predicciones futuras.

## 6. CONCLUSIONES

Las ventas a través de Internet tendrán una importancia creciente en el futuro, impulsando las herramientas de *marketing* digital basadas en la información recogida sobre los clientes. Además, incorporarán cada vez más datos obtenidos de audios y vídeos, y, en algunos sectores específicos, provenientes de otros sentidos digitalizados, como el olor, en perfumería, el gusto, en alimentación, y el tacto, en telas, muebles o vestidos.

En este trabajo hemos comentado tres herramientas de *marketing* digital basadas en los datos masivos, pero su disponibilidad y creciente desarrollo tendrá un efecto muy amplio. Por ejemplo, en la detección del fraude, que es un problema central para hacer las compras seguras. Disponer de la historia completa de los pagos con tarjeta de una persona puede hacer

muy fácil la identificación de una operación fraudulenta y avisar al usuario de forma inmediata. Además, permitirá clasificar los tipos de fraude más habituales y prevenirlos, con lo que la seguridad de las actividades en Internet puede experimentar mejoras muy importantes (véase Galeano y Peña, 2019b).

La transformación digital que estamos experimentando abarca muchas dimensiones (Kanan, 2017): afecta al comportamiento de los consumidores, a la información disponible para la compra, a las plataformas que pueden utilizarse y a la interacción entre estos aspectos y el contexto del cliente. Por ejemplo, el comportamiento del consumidor digital respecto a la información ha cambiado. En primer lugar, su opinión se forma no solo con la que publicita la empresa, sino, también, con la experiencia de otros usuarios que comparten opiniones en Internet. En segundo lugar, el mismo cliente se convierte en generador de valoraciones de un producto o servicio al comentar su experiencia en las redes sociales y webs de intercambio de opiniones de consumidores. También su experiencia de compra se ha transformado. Ahora es posible comprar en el marco tradicional de empresa/cliente pero también en el de relaciones cliente/cliente, como por ejemplo en Ebay y otras plataformas. Además, grandes intermediarios, como Amazon, conectan al cliente con muchas empresas, formando relaciones cliente/empresas. Finalmente, aunque los productos se ofrezcan a un mercado mundial su venta digital está afectada por fenómenos de piratería o de regulaciones nacionales, que varían mucho con el contexto geográfico y cultural.

La comprensión de todos estos fenómenos requiere el análisis de los datos que los describen, que se van acumulando a gran velocidad a medida que se generalizan las transacciones comerciales por Internet, generando grandes bases de datos masivos sobre todos estos aspectos. Su conversión en información mediante tratamientos analíticos va a ofrecer enormes posibilidades para perfeccionar las estrategias comerciales de *marketing* digital en el futuro y hacer nacer otras nuevas.

## Referencias

- BENITO, M., GARCÍA-PORTUGUÉS, E., MARRON, J. S. y PEÑA, D. (2017). Distance-weighted discrimination of face images for gender classification. *Stat*, 6(1), pp. 231-240.
- BENITO, M. y PEÑA, D. (2005). A fast approach for dimensionality reduction with image data. *Pattern Recognition*, 38(12), pp. 2400-2408.
- BRUCE, V. (1988). *Recognising Faces, Essays in cognitive psychology*. Hillsdale, NJ: Lawrence Erlbaum Associates.
- BRUCE, V., BURTON, A. M. y CRAW, I. (1992). Modelling face recognition. *Philosophical Transactions of the Royal Society, Series B*, 335(1273), pp. 121-127.
- BUREZ, J. y VAN DEN POEL, D. (2007). CRM at a pay-TV company: Using analytical models to reduce customer attrition by targeted marketing for subscription services. *Expert Systems with Applications*, 32(2), pp. 277-288.
- CARO, Á. y PEÑA, D. (2021). Predicción de series temporales económicas con datos masivos: perspectiva, avances y comparaciones. En: D. PEÑA, P. PONCELA y E. RUIZ (eds.), *Nuevos métodos de Predicción Económica con datos masivos*. Madrid: Funcas. <https://www.funcas.es/articulos/prediccion-de-series-temporales-economicas-con-datos-masivos-perspectiva-avances-y-comparaciones/>

- CHAFFEY, D. y ELLIS-CHADWICK, F. (2019). *Digital marketing*. UK: Pearson.
- DICK, A. S. y BASU, K. (1994). Customer loyalty: toward an integrated conceptual framework. *Journal of the Academy of Marketing Science*, 22(2), pp. 99-113.
- EREVELLES, S., FUKAWA, N. y SWAYNE, L. (2016). Big Data consumer analytics and the transformation of marketing. *Journal of Business Research*, 69(2), pp. 897-904.
- GALEANO, P. y PEÑA, D. (2019a). Data science, big data and statistics. *Test*, 28(2), pp. 289-329.
- GALEANO, P. y PEÑA, D. (2019b). Las nuevas oportunidades del Big Data para las instituciones financieras. *Papeles de Economía Española*, 78(162), pp. 78-176. Madrid: Funcas. <https://www.funcas.es/articulos/las-nuevas-oportunidades-de-big-data-para-las-instituciones-financieras-la-gestion-de-la-informacion-en-banca-de-las-finanzas-del-comportamiento-a-la-inteligencia-artificial-2019-n-162/>
- GALTON, F. (1910). Numeralized profiles for classification and recognition. *Nature*, 83, pp. 127-130.
- GONG, Y. (1995). Speech recognition in noisy environments: A survey. *Speech communication*, 16(3), pp. 261-291.
- HEIENS, R. A. y PLESHKO, L. P. (1996). Categories of customer loyalty: An application of the customer loyalty classification framework in the fast food hamburger market. *Journal of Food Products Marketing*, 3(1), pp. 1-12.
- HULTÉN, B. (2017). Branding by the five senses: A sensory branding framework. *Journal of Brand Strategy*, 6(3), pp. 281-292.
- HUSSAIN, S. (2019). Sensory Marketing Strategies and Consumer Behavior: Sensible Selling Using All Five Senses. *IUP Journal of Business Strategy*, 16(3).
- KANNAN, P. K. (2017). Digital marketing: A framework, review and research agenda. *International Journal of Research in Marketing*, 34(1), pp. 22-45.
- KATZENBEISSER, S. y PETKOVIC, M. (2008). Privacy-preserving recommendation systems for consumer healthcare services. En: *2008 Third International Conference on Availability, Reliability and Security*, pp. 889-895.
- KAWULOK, M., CELEBI, ME and SMOLKA, B (2016). *Advances in Face Detection and Facial Image Analysis*, Springer Publishing Company, Inc.
- KHAN, K., ATTIQUE, M., KHAN, R. U., SYED, I. y CHUNG, T. S. (2020). A multi-task framework for facial attributes classification through end-to-end face parsing and deep convolutional neural networks. *Sensors*, 20(2), p. 328.
- KIM, H. S. y YOON, C. H. (2004). Determinants of subscriber churn and customer loyalty in the Korean mobile telephony market. *Telecommunications Policy*, 28(9-10), pp. 751-765.
- KNOX, S. D. y DENISON, T. J. (2000). Store loyalty: its impact on retail revenue. An empirical study of purchasing behaviour in the UK. *Journal of Retailing and Consumer Services*, 7(1), pp. 33-45.
- KUMAR, P. y THAKUR, R. S. (2018). Recommendation system techniques and related issues: A survey. *International Journal of Information Technology*, 10(4), pp. 495-501.
- LEVI, G. y HASSNER, T. (2015). Age and gender classification using convolutional neural networks. En: *Proceedings of the IEEE conference on computer vision and pattern recognition workshops* (pp. 34-42).
- LINDEN, G., SMITH, B. y YORK, J. (2003). Amazon.com Recommendations: Item-to-Item Collaborative Filtering. *IEEE Internet Computing*, vol. 7(1), pp. 76-80.
- MARX, V. (2013). The big challenges of big data. *Nature*, 498(7453), pp. 255-260.
- NASSIF, A. B., SHAHIN, I., ATTILI, I., AZZEH, M. y SHAALAN, K. (2019). Speech recognition using deep neural networks: A systematic review. *IEEE access*, 7, pp. 19143-19165.
- PADMANABHAN, J. y JOHNSON PREMKUMAR, M. J. (2015). Machine learning in automatic speech recognition: A survey. *IETE Technical Review*, 32(4), pp. 240-251.

- PAGE, L., BRIN, S., MOTWANI, R. y WINOGRAD, T. (1999). The PageRank citation ranking: Bringing order to the web. *Stanford InfoLab*.
- PEÑA D. (2015). Big data, Ciencia y Estadística. *Revista de Ciencia y Humanidades*, 14, pp. 97-106. Fundación Ramón Areces.
- QUIJANO-SANCHEZ, L. y LIBERATORE, F. (2017). The BIG CHASE: A decision support system for client acquisition applied to financial networks. *Decision Support Systems*, 98, pp. 49-58.
- RYAN, D. (2016). *Understanding digital marketing: marketing strategies for engaging the digital generation*. Kogan Page Publishers.
- SAURA, J. R. (2021). Using data sciences in digital marketing: Framework, methods, and performance metrics. *Journal of Innovation and Knowledge*, 6(2), pp. 92-102.
- SAYYAD, S. et al. (2018). Digital Marketing Framework Strategies Through Big Data. En: *International conference on Computer Networks, Big data and IoT*, pp. 1065-1073. Cham: Springer.
- SHAN, C. (2012). Learning local binary patterns for gender classification on real-world face images. *Pattern Recognition Letters*, 33(4), pp. 431-437.
- SMITH, B. y LINDEN, G. (2017). Two decades of recommender systems at Amazon. *IEEE Internet Computing*, 21(3), pp. 12-18.
- TRAN, S., DU, M., CHANDA, S., MANMATHA, R. y TAYLOR, C. (2019). Searching for Apparel Products from Images in the Wild. arXiv preprint arXiv:1907.02244.
- VELASCO, C., WAN, X., KNOEFERLE, K., ZHOU, X., SALGADO-MONTEJO, A. y SPENCE, C. (2015). Searching for flavor labels in food products: the influence of color-flavor congruence and association strength. *Frontiers in Psychology*, 6, p. 301.
- VERBEKE, W., MARTENS, D., MUES, C. y BAESENS, B. (2011). Building comprehensible customer churn prediction models with advanced rule induction techniques. *Expert Systems with Applications*, 38(3), pp. 2354-2364.
- WANG, Y. F., CHIANG, D. A., HSU, M. H., LIN, C. J. y LIN, I. L. (2009). A recommender system to avoid customer churn: A case study. *Expert Systems with Applications*, 36(4), pp. 8071-8075.
- WEDEL, M. y KANNAN, P. K. (2016). Marketing analytics for data-rich environments. *Journal of Marketing*, 80(6), pp. 97-121.
- YU, Y. T. y DEAN, A. (2001). The contribution of emotional satisfaction to consumer loyalty. *International journal of service industry management*.
- ZHAO, W., CHELLAPPA, R., PHILLIPS, P. J. y ROSENFELD, A. (2003). Face recognition: a literature survey. *ACM Computing Surveys*, 35(4), pp. 399-458.



## CAPÍTULO II

# La tercera revolución de la comunicación. El día que dejaremos de decidir

Ricardo Urías

En este capítulo se explican las implicaciones de las tres revoluciones de la comunicación que, hasta la fecha, ha vivido o vivirá de forma inminente, la humanidad. Nos detendremos un poco más en la tercera, que está a punto de llegar, la del *big* media y la inteligencia artificial, previendo cómo se irá desarrollando y cambiará de forma radical nuestras vidas.

*Palabras clave:* *big* media, inteligencia artificial, comunicación.

## 1. INTRODUCCIÓN

El ser humano es comunicativo por naturaleza. De hecho, su mayor capacidad para comunicarse ha demostrado ser una ventaja evolutiva, que nos ha convertido en la especie dominante. Si esto es así, la historia de la Humanidad podría explicarse en base a las revoluciones en la comunicación que, como humanos, hemos tenido.

De esto trata este capítulo, y para ello, se recurre a una tabla en la que representamos a los emisores de los mensajes en las abscisas (horizontales), y a los receptores en las ordenadas (verticales). Esto nos genera cuatro cuadrantes. En el primer cuadrante, pocos emisores y pocos receptores, el ser humano se pasa la mayor parte de su existencia. Es la época del *no media* y del conocimiento elitista, solo al alcance de unos pocos (las élites gobernantes), por lo que la mayor parte de la Humanidad vive en un estado de seudoesclavitud o pseudoanimalidad (es el conocimiento el que nos hace humanos y libres). Un avance tecnológico, la imprenta, hace 600 años (unos cuantos cientos de años más en China) nos cambia de cuadrante, al de pocos emisores y muchos receptores. Con ello, llegan los *mass media* y el conocimiento colectivo controlado por élites. Ya cualquiera puede acceder al conocimiento, pero siguen siendo unos pocos los que deciden lo que se difunde. En este cuadrante, nacen el *marketing*, los movimientos políticos y la propiedad intelectual, que han configurado nuestra forma de pensar, especialmente durante el siglo XX, y que siguen determinando muchos de nuestros paradigmas.

Un nuevo avance tecnológico, en este caso Internet, inicia la segunda revolución de la comunicación y nos vuelve a cambiar de cuadrante, llevándonos al de muchos emisores y muchos receptores. Entramos en la época de los *social media* y de la inteligencia colectiva. Una etapa en la que todavía estamos inmersos, y que está cambiando todos los paradigmas a los que estábamos acostumbrados. Pero cuando aún no se ha llegado a implantar del todo el tercer cuadrante, de nuevo un avance tecnológico, el *big data* y la inteligencia artificial, va a iniciar la tercera revolución de la comunicación, y nos cambiará al cuarto cuadrante, el de muchos emisores y pocos receptores, en el que delegaremos nuestra capacidad de decisión.

## 2. LA COMUNICACIÓN: NUESTRA PRINCIPAL VENTAJA EVOLUTIVA

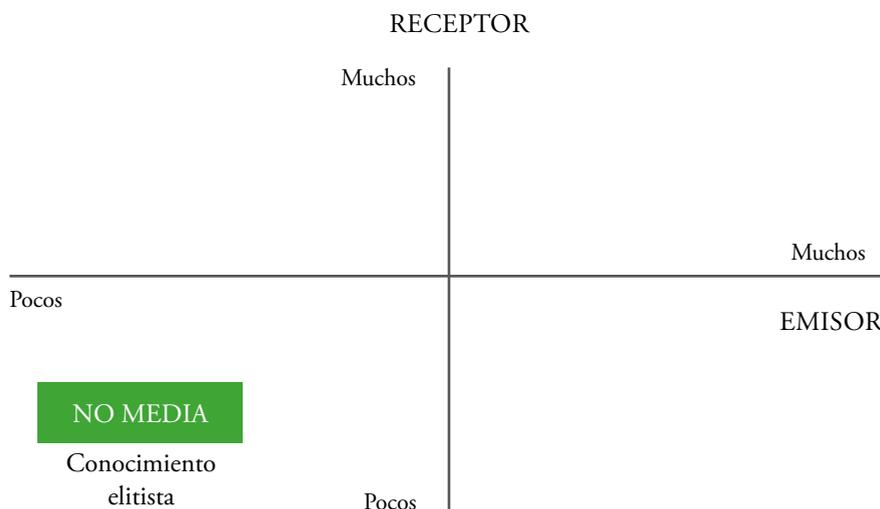
Somos afortunados. Al menos así pensarán los que, como yo, se sienten fascinados por los cambios. Porque muy pocos en la historia de la Humanidad han tenido el privilegio de vivir en primera persona un cambio tan trascendente como la segunda revolución de la comunicación. Y muy probablemente vivamos también la tercera. El cambio es trascendente porque afecta a la comunicación, algo consustancial con nosotros, que nos ha hecho ser *humanos* y que es –posiblemente– nuestro principal factor de diferenciación con los animales. Porque, efectivamente, el *Homo Sapiens Sapiens* se caracteriza, entre otras cosas, por su capacidad superior para comunicarse (Ferretti y Adornetti, 2020). Al principio, con pinturas (en las cuevas y en el cuerpo), con abalorios, con lenguajes muy básicos, ...; y después de

forma mucho más elaborada. Esta capacidad comunicativa nos hizo prevalecer sobre el *Homo Neardenthalensis* y llegar a ser la especie dominante sobre la Tierra.

Pues bien, desde que somos humanos, la comunicación –nuestra comunicación– ha pasado solo por dos revoluciones: la primera hace casi 600 años (unos cientos de años más en China), y la segunda ahora. ¿Por qué? ¿Cuáles son estas revoluciones? Como la cabra tira al monte, y yo soy ingeniero de formación, no puedo evitar utilizar, para explicarlo, un par de ejes: en el eje horizontal de las abscisas, pongo los EMISORES, de forma que la parte de la derecha correspondería a “Muchos emisores” y la de la izquierda a “Pocos emisores”. En el eje vertical de las ordenadas, sitúo los RECEPTORES, y así abajo encontramos “Pocos receptores”, mientras que arriba tendremos “Muchos receptores”.

Una vez dibujados nuestros ejes, nos situamos en el cuadrante inferior izquierdo, el que corresponde a “Pocos emisores y pocos receptores” (ver figura 1). En este cuadrante pasa el ser humano desde que surge sobre la faz de la tierra hasta hace algo más de 550 años. Es decir, más de 100.000 años. Es la época del *no media*, en la que el conocimiento únicamente se transmitía de unos pocos a unos pocos (pocos emisores y pocos receptores). Este conocimiento era privativo de unos poquísimos privilegiados, y se transfiere solo dentro de esas élites (nobleza, sacerdotes, chamanes, filósofos...). De hecho, estos pocos con acceso al conocimiento eran los únicos que vivían, realmente, como seres humanos completos; el resto de la población se encontraba en un estado de “seudoesclavitud” intermedio entre la “animalidad” y la “humanidad”. Esas élites con acceso al conocimiento lo tenían muy fácil para mantener

Figura 1.



Fuente: Elaboración propia.

el poder: si alguien pensaba de forma distinta a ellos, lo máximo que podía hacer era comunicarlo de forma oral a un grupo reducido de personas (no más de cien...). El procedimiento era simple: se “eliminaban” a esos 101 disidentes, se acababa con el pensamiento diferente, y se mantenía el *statu quo*.

La escritura fue, desde luego, una mejora muy importante, pero no permitió “un cambio de cuadrante”. La comunicación seguía siendo de pocos emisores a pocos receptores, solo que ahora la información se transmitía de forma más fidedigna, no se deterioraba al pasar de unos a otros. Pero, como se indicaba más arriba, continuaba siendo privativa de las élites que accedían a ella, dado que el conocimiento en forma escrita estaba limitado a la labor de escribas y amanuenses y, por tanto, era escasa.

Por ello también he llamado a esta época, que dura casi 150.000 años de la historia del ser humano, la del *conocimiento elitista*.

Los grandes cambios que se fueron produciendo durante esta época están siempre provocados por luchas de poder entre diferentes *statu quo*, es decir, aquellos que poseían el conocimiento. El cambio de la civilización griega o egipcia a la romana, o la implantación del cristianismo (que vino de la mano del Imperio romano), o la invasión de los bárbaros (eran en realidad un *statu quo* diferente al que entonces detentaba el poder) fueron solo eso: diferentes enfoques de la vida de aquellos que poseían la información y el conocimiento. Pero no había movimientos que emergieran de las masas. Sobre todo porque, al no poseer canales de acceso y transmisión de la información, estaban imposibilitados para ello (Humphreys, 1996).

En esta extensísima época, encontramos el comercio y el poder político, pero no existía ni el *marketing* –algo que por deformación profesional he estudiado profusamente– ni los movimientos políticos. Es lógico. El requerimiento indispensable para ambos mecanismos transformadores es la posibilidad de que unos pocos emisores se comuniquen, e influyan, a muchos, cuantos más mejor, receptores. Cuando hablamos de *marketing* o de movimientos políticos a todos nos viene a la cabeza un anuncio, en una valla o en televisión, o un debate televisado (si los partidos dependieran de los votos de los que acuden a los mítines políticos, mal les iría). En ambos casos, medios que permiten que unos pocos emisores, que controlan dichos soportes mediáticos, manden mensajes a muchos, muchísimos receptores.

Pero en la época del *conocimiento elitista* y del *no media* esto no era posible. Por eso no existían los movimientos políticos a escala global, ni el *marketing*, ni las tendencias musicales, ni la moda en la forma de vestir, ni las corrientes de pensamiento que mueven masas.

### 3. LA PRIMERA REVOLUCIÓN DE LA COMUNICACIÓN: LA ÉPOCA DE LOS *MASS MEDIA*

La primera revolución surge en el siglo XV (un siglo antes en Oriente), de la mano de una innovación tecnológica: la imprenta. Esto posibilita que la Humanidad cambie de cua-

drante y se sitúe en el superior izquierdo: “Pocos emisores” pero “Muchos receptores” (ver figura 2). Empieza la época del *mass media*. Como su nombre indica, nacen los medios que permiten que el conocimiento llegue a todos, a las masas. Eso sí, controlado por unos pocos: las élites que tienen capacidad para ser emisoras. Por eso he llamado también a esta época la del *conocimiento colectivo controlado por élites*. Las cosas cambian de forma radical. Ahora sí puede haber cambios impulsados por alguien ajeno al *statu quo*... siempre que, de alguna forma, tenga acceso a los canales de comunicación de masas (es decir, sea élite en el manejo de la información).

El poder establecido empieza a tenerlo más difícil, porque, si alguien piensa de forma diferente, quizás tenga la capacidad de contárselo a 100.000 personas, y es mucho más difícil eliminar a 100.001 que a 101. Por eso el pensamiento disidente que emerge de las masas –por ejemplo, Lutero y el protestantismo– empieza a triunfar por primera vez (Ramírez Alvarado, 2009). Lógicamente, el *statu quo* de la época anterior, del cuadrante del *no media*, se rebela contra el monstruo del *mass media* que traerá el apocalipsis: se inicia la quema de libros, se crean las listas de libros prohibidos y permitidos... Pero el cambio de cuadrante ya se ha producido, es irreversible, y empieza a tener consecuencias de gran calado social y económico. Porque, con el nuevo cuadrante de los *mass media*, nace el *marketing*, los movimientos políticos y las tendencias globales dirigidas. Cambios nada gratos para quienes querían que todo permaneciese inmutable.

Desde luego, en la época del *no media*, existía el comercio. Incluso a distancia y a gran escala, como lo hicieron, entre otros muchos, los fenicios. Pero se comerciaba con productos,

Figura 2.



Fuente: Elaboración propia.

materias primas y elaborados, y el concepto marca no existía. A lo sumo, el origen de los productos podía llegar a ser una cierta garantía de calidad, pero sin que hubiese forma suficientemente fidedigna de comprobar dicho origen. El *marketing*, y el concepto marca en sí mismo, depende de que unos pocos –los gestores de la marca– tengan la capacidad de comunicarse con muchos, como comentábamos antes, cuantos más mejor: los consumidores.

Algo similar sucede con los movimientos políticos e ideológicos a escala global. Dependen de que unos pocos –ideólogos, activistas políticos, candidatos– conecten con muchos: sus seguidores, partidarios y votantes.

Y, si bien es verdad que el *marketing*, los movimientos ideológicos y políticos y las tendencias globales, desde el *rock & roll* a la minifalda y el fútbol, son propios de los últimos 150 años, no es menos cierto que se alcanzan tras una evolución, primero lenta y luego más acelerada, que se inicia con la imprenta, germina con el Renacimiento, florece con la Ilustración y la Revolución francesa, y finalmente eclosiona desde finales del siglo XIX y durante todo el siglo XX. Y la tónica de todos ellos es siempre la misma: movimientos transformadores, inspirados y controlados por unos pocos, que llegan y motivan a muchos. Bien lo saben Procter & Gamble, Coca-Cola, el marxismo, demócratas y republicanos, el nazismo y los fascismos, The Beatles, The Rolling Stones, el Real Madrid y el Barça (a pesar de ser muchos de ellos tan radicalmente distintos).

Este es también el cuadrante de la propiedad intelectual. De hecho, este concepto, propiedad intelectual, no es ni más ni menos que parafrasear “Conocimiento colectivo controlado por élites”, uno de los nombres con los que había denominado el segundo cuadrante. Nuestro mundo, al menos hasta hace muy poco, está construido en gran medida sobre la propiedad intelectual (patentes, libros, música, cine, ...), algo que solamente tiene sentido económico cuando los dueños de esa propiedad (élites) pueden hacer que muchos (los consumidores) paguen por disfrutarla.

La época del *mass media*, con todos los cambios que acabo de mencionar, eclosiona durante el siglo XX, y configura la mayor parte de los paradigmas con los que nos hemos educado y que, todavía, siguen, al menos parcialmente, controlando el mundo.

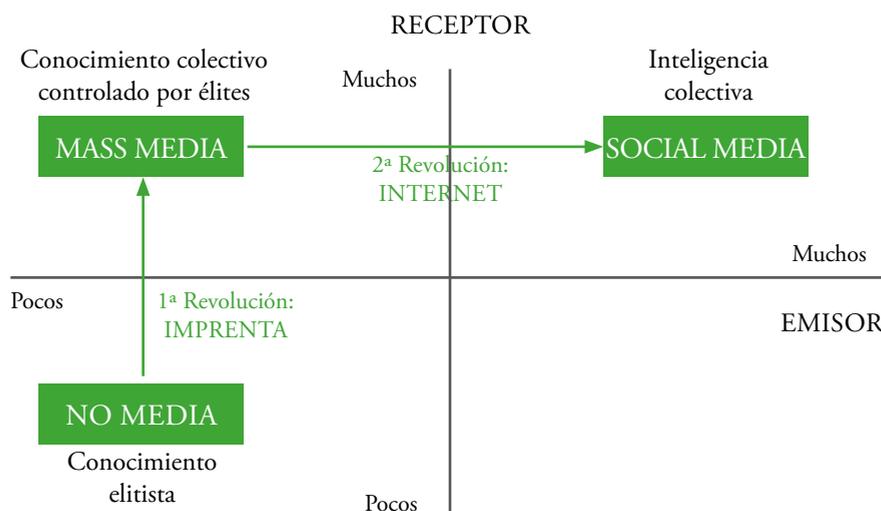
Y, de la misma forma que con la llegada de la escritura no se abandonó el primer cuadrante, con la llegada de la radio y la televisión, aunque sea 3D y de alta definición, no se abandona el segundo cuadrante. Solo se añaden algunos sentidos a la comunicación que pocos emisores realizan a muchos receptores.

#### 4. LA SEGUNDA REVOLUCIÓN DE LA COMUNICACIÓN: LLEGAN LOS SOCIAL MEDIA

Estábamos tan a gusto, viviendo en el segundo cuadrante hasta finales del siglo XX o principios del siglo XXI, cuando hace alrededor de 20 años, nos llega, de la mano de otra

innovación tecnológica, Internet, la segunda revolución de la comunicación, que supone un nuevo cambio de cuadrante, en esta ocasión al superior derecho: muchos emisores –y cualquiera puede emitir, no solo los privilegiados propietarios de los *mass media*– y muchos receptores (figura 3).

Figura 3.



Fuente: Elaboración propia.

Comienza la época del *social media* (Sharma y Verma, 2018; Killian y McManus, 2015), y, con ello, de la inteligencia colectiva. Porque, por primera vez en la historia, el conocimiento es generado por todos, no solo por una élite, y llega a todos. Y, de la misma forma que sucedió con la primera revolución, estamos asistiendo a una resistencia del *status quo* de la época del *mass media*, que se había acostumbrado a que sus ideas fuesen acogidas sin rechistar: se demoniza Internet, se trata de legislar contra determinados “sites”, se exageran los riesgos... Una reacción natural, porque los elementos paradigmáticos que nacieron en el segundo cuadrante mueren en el tercer cuadrante.

Estamos, en la actualidad, viviendo la agonía del *marketing*, de los movimientos políticos y de la propiedad intelectual. El *marketing* ha muerto (aunque “él” no lo sepa, lo que le convierte en un “zombi”). Y prueba de ello es que las iniciativas empresariales más exitosas de los últimos años han violado, haciendo además gala de ello, todas las leyes del *marketing*. Empresas como Google, WhatsApp, Amazon, Wallapop, etc., jamás hubieran nacido si hubieran sido juzgadas con los criterios del *marketing* convencional. Pero no solo sucede con el *marketing*. Los movimientos políticos están muriendo y serán sustituidos pronto por una nueva forma de hacer política. Y la propiedad intelectual, por más que les pese a las socieda-

des de autores, son cosa del pasado. ¡Si estamos en la época de la inteligencia colectiva, esta no puede ser privativa!

Cuando afirmo que estamos en el cuadrante de la inteligencia colectiva, puede que a más de un lector le parezca que estoy exagerando. A fin de cuentas, si miramos YouTube, Instagram o Facebook, más que inteligencia colectiva lo que encontramos es “estupidez colectiva”. Pero esta reflexión no sería correcta. De hecho, lo que hacen los medios sociales no es sino replicar a la sociedad, una sociedad para la que esta mal llamada “estupidez colectiva” no es más que un catalizador de la información. Me explico: imaginad por un momento dos científicos, o investigadores, o artistas que están trabajando en el mismo tema. Ambos se han perdido la pista o simplemente ninguno de los dos repara o se acuerda del otro. Pero, por casualidad, están en un mismo grupo de WhatsApp, en el que reciben enlaces a la última “tontería” de moda, ya sea esta el vídeo de “Despacito”, que fue visionado más de 3.000 millones de veces, o un montaje de TikTok. Y, gracias a ello, reparan el uno en el otro y se activa la inteligencia colectiva. Esta reflexión no es baladí, ya que justifica la circulación masiva de informaciones “estúpidas” pero atractivas, por su capacidad para poner en contacto a las personas, y que puedan trabajar juntas en temas más “nobles”.

El cambio de paradigma del tercer cuadrante ha modificado radicalmente las reglas del juego que teníamos a finales del siglo XX, y nos ha traído otras nuevas:

- *Transparencia*: estamos en la era de la transparencia. Todo se sabe (o se termina sabiendo), por lo que más vale que tengas poco que ocultar. ¿Qué consecuencias tiene la transparencia para las marcas, las empresas y las instituciones? Todas. A partir de ahora va a ser muy difícil que, si no se ofrece un valor real a los individuos y no se tiene un comportamiento razonablemente honesto, la marca, empresa o institución sea respetada, apreciada y valorada. Si la situación es de monopolio u oligopolio, mantendrá su posición durante algún tiempo, pero, aun así, tarde o temprano terminará cayendo.
- *Inteligencia colectiva y poder social*: ya en el segundo cuadrante los individuos tenían el poder de elegir entre las opciones que les proponía el *statu quo*. Pero en el tercer cuadrante los individuos quieren TODO el poder. Y demandan a las marcas, empresas o instituciones que les otorguen la capacidad de decidir, de crear, que les faciliten información, que les permitan llegar más lejos. Y con ello se abre un fascinante repertorio de posibilidades, si hemos sido capaces de cambiar nuestros paradigmas.
- *Las ideas no son propiedad de nadie*: si tienes una buena idea, más vale que la llesves a la práctica lo antes y de la mejor manera posible. Si no, alguien lo hará por ti. Y no valen quejas. Hay quien dice que las ideas cada vez tienen menos valor. No es cierto. Una buena idea sigue siendo valiosísima... pero si la llevas a la práctica. Nadie va a pagar por la idea etérea, sobre un papel, pero podrán pagarte una fortuna en el momento en el que demuestre mínimamente su capacidad para generar valor.

- *Rapidez en los cambios (¡vertiginosa!)*: lo siento por aquellos a los que les gusta pensárselo dos veces. Probablemente se queden fuera de juego en el paradigma de este tercer cuadrante. Tenemos que actuar rápido, o alguien lo hará por nosotros. Como sucede ante cualquier cambio radical, se produce un efecto acelerador que nos obliga a tomar muchas más decisiones en mucho menos tiempo. Hay un ejemplo que no puede ser más contundente: si miramos el tiempo medio que las empresas del Standard & Poor's 500 permanecen en el mencionado índice, veremos que en el año 2000 era de algo más de 28 años, y en la actualidad... ¡es de 14 años! Google, Facebook, Amazon o el propio Inditex son responsables de ello. Pero el caso es que, con muchas probabilidades, dentro de 10 o 15 años, muchas de esas empresas ya no estarán en el S&P 500. Una consecuencia de la rapidez vertiginosa en los cambios.

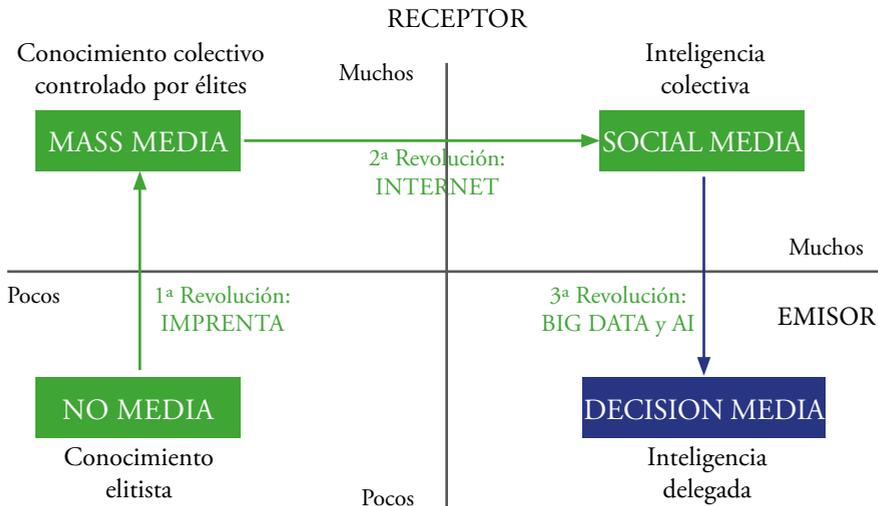
¿Cuánto tiempo vamos a estar en el tercer cuadrante? No hay una respuesta exacta. Lo que sí es verdad es que los medios sociales actuales son aún torpes y defectuosos y evolucionarán hacia soluciones mucho mejores y sofisticadas. Pero el tiempo de permanencia en el tercer cuadrante no será de 600 años, como sucedió en el segundo, sino de unas decenas de años, dado el carácter acelerado de esta evolución. Podríamos decir que alrededor de 2050 los medios sociales estarán en su momento óptimo de sofisticación. Pero quizás antes tengamos que enfrentarnos a otro cambio tecnológico que nos meta de lleno en el cuarto cuadrante...

## 5. LA TERCERA REVOLUCIÓN DE LA COMUNICACIÓN: EL DÍA QUE DEJAREMOS DE DECIDIR

Aún no tenemos *social media* tan sofisticados como para afirmar que el tercer cuadrante ha dado de sí todo su potencial. Pero un nuevo adelanto tecnológico, la inteligencia artificial alimentada por el *big data*, nos está introduciendo ya en el cuarto cuadrante: el cuadrante de los *decision media* (dudo que algún día este término llegue a implantarse) y de la inteligencia, y con ella la toma de decisiones, delegada (ver figura 4). En realidad, la inteligencia artificial no es más que la capacidad de computación y el desarrollo de algoritmos cada vez más sofisticados. Pero esto cambiará la forma en la que el mundo funciona.

¿Qué significa entrar en el cuarto cuadrante? Los muchos emisores somos todos nosotros, todos los seres humanos que vamos dejando un rastro de datos allá por donde pasamos en Internet. Ya sea con el uso de las redes sociales, con el comercio electrónico, con los sitios visitados o con las búsquedas que realizamos, vamos entregando información acerca de cómo somos, nuestros gustos, nuestras necesidades, nuestros intereses... incluso sobre nuestro futuro. Y no solamente las personas dejamos datos: las máquinas, desde nuestro automóvil o electrodomésticos, hasta las líneas de producción que fabrican lo que consumimos, van dejando también un rastro de datos que dice mucho sobre nosotros. Y los pocos receptores son los sistemas de inteligencia artificial, ya sea en empresas, o entidades públicas y privadas, con capacidad para almacenar y procesar todos esos datos y convertirlos en decisiones inteligentes, más acertadas que las decisiones que, de forma convencional, nosotros seríamos capaces de tomar.

Figura 4.



Fuente: Elaboración propia.

Este es un proceso que, como comento, no ha hecho más que comenzar. Todavía la inteligencia artificial es muy torpe y muy básica. Haciendo un símil, la inteligencia artificial hoy tendría un desarrollo equivalente al de Internet a principios de la década de 1990, cuando la velocidad de navegación era extremadamente lenta y ni siquiera había buscadores. Todavía estamos en fases muy incipientes, y aun así los logros que se están alcanzando nos parecen enormes. Pero tendremos que esperar unos 25 o 30 años para empezar a notar –de verdad– los efectos de la entrada en este cuarto cuadrante.

¿Qué implicaciones tendrá la *decisión delegada*? Ya cuando hablaba de la entrada en el tercer cuadrante mencionaba que eso implicaba la “muerte” del *marketing*, al menos tal y como lo entendíamos en la época de los *mass media*, de los movimientos políticos y de la propiedad intelectual, entre otras cosas. Pues con la entrada en el cuarto cuadrante, el *marketing* será sustituido por la compra automática, de acuerdo con nuestras necesidades y experiencias como consumidores. La política convencional dará paso a las votaciones asistidas (que tendrán en cuenta nuestras necesidades reales, nos recomendarán la propuesta más afín a nuestra ideología (y de hecho nos ayudarán a aclararnos sobre cuál es nuestra ideología) y nos preservará de la demagogia. Y la propiedad intelectual será poco menos que imposible, ya que los sistemas de inteligencia artificial incluirán en cualquier desarrollo intelectual (libro, música, patente, etc.) tal cantidad de interacciones con otros desarrollos y colaboradores que la autoría única será una quimera (en todo caso, el verdadero autor será la inteligencia artificial que ha elaborado esa mezcla óptima). Este escenario que he descrito es, no se me escapa, totalmente optimista y utópico. Soy consciente de ello y lo asumo, ya que puestos a predecir el futuro prefiero alegrarme y esperanzarme a temerme lo peor. Pero sé que la realidad podría

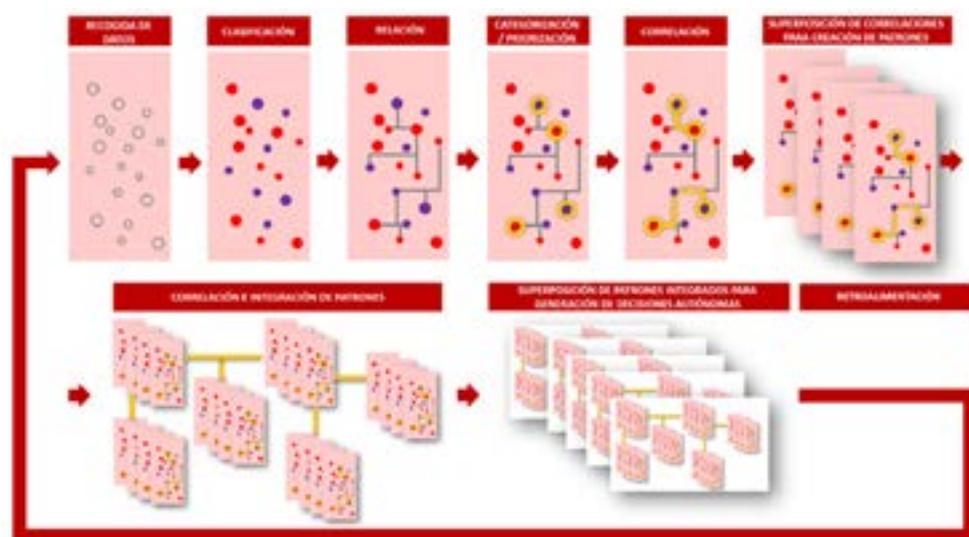
llegar a ser profundamente distópica: que las empresas utilicen la inteligencia artificial para maximizar sus ventas, aun en contra de nuestros intereses, que los políticos se sirvan de los algoritmos para su demagogia, y que la propiedad de todo lo intelectual termine en manos de contadísimas corporaciones. Lo más probable es que suceda un escenario intermedio, y espero que esté más cerca del utópico que del distópico.

Lo que sí parece claro es que, en un futuro más cercano de lo que nos parece, la inteligencia artificial y los algoritmos tendrán mucho que decir sobre qué compramos, qué votamos, con quién nos casamos, cuántos hijos tenemos, cómo está nuestra salud, cómo nos tenemos que medicar... Incluso es posible que nuestro jefe, o nuestro líder, termine siendo una inteligencia artificial (llevándolo a un extremo que aunque ahora nos parece excesivo, no es tan descabellado; la inteligencia artificial, ahora, ya nos ordena qué hacer, por ejemplo, en el caso de un piloto automático o una cirugía asistida).

Para entender un poco mejor dónde estamos y qué nos espera, he hecho algunos cambios en una imagen muy difundida y que probablemente hayáis visto en alguna ocasión. Los visuales son parecidos, pero he añadido alguno nuevo y la definición de cada uno de los distintos pasos se adapta más a la realidad actual y a lo que está por venir. Podemos verlo en la figura 5.

En el desarrollo de una inteligencia artificial, comenzamos con la recolección de datos. El siguiente paso es la clasificación de los mismos. Esto, en ocasiones, reviste de cierta com-

Figura 5.



Fuente: Elaboración propia.

plejidad, ya que hay que establecer los criterios de clasificación que no siempre son obvios. A continuación, se establecen relaciones entre los datos clasificados. El análisis de estas relaciones, y la mayor o menor contribución de cada uno de los datos recogidos, clasificados y relacionados, a los efectos que de ellos se derivan, nos llevarán a hacer una categorización y priorización de los mismos. Esta es una fase compleja, que exige, en muchas ocasiones, disponer de sistemas de análisis y modelización sofisticados. El siguiente paso será la correlación, en donde empezamos a establecer vínculos causa–efecto, lo que nos puede llevar a predicciones elementales.

A partir de aquí el proceso se hace más complejo, y suele requerir de algoritmos que permitan que la propia inteligencia artificial empiece a evolucionar y aprender por sí misma. La superposición de correlaciones permite la creación de patrones (que se identifican con conceptos que permiten reclasificar a su vez todos los datos recogidos). Las correlaciones entre patrones, y las integraciones de varios de ellos de forma simultánea permiten la creación de patrones mucho más complejos. Y a su vez, la superposición de estos patrones complejos lleva a que la inteligencia artificial desarrolle un pensamiento predictivo sofisticado.

El proceso se retroalimenta y se va depurando paulatinamente, ajustando cada uno de los pasos para que las predicciones realizadas se ajusten cada vez más a la realidad observada.

En el fondo, este proceso es muy similar al aprendizaje que lleva a cabo el cerebro humano. El cerebro del niño recién nacido busca acumular todo tipo de datos sobre su entorno, cuantos más mejor, explorando con sus sentidos todo lo que le rodea. Clasifica, establece relaciones, categoriza, correlaciona y finalmente crea patrones en los que “encajar” el mundo que le rodea. Al principio patrones simples y luego cada vez más complejos. Empieza a realizar predicciones y a chequear con la realidad su nivel de acierto. Y, a medida que los patrones que va creando son más complejos, llega un momento en el que, inevitablemente, se incluye a sí mismo como un patrón más, y esto le lleva a la toma de conciencia de sí mismo.

¿Significa esto que la inteligencia artificial podría llegar a tomar conciencia de sí misma? Si la generación de patrones es cada vez más compleja y los procesos de autoaprendizaje más sofisticados, probablemente sí (ya lo predijo Ray Kurzweil en “La Singularidad está cerca”). Pero esto, que casi seguro llegará, no debería preocuparnos por ahora. La cantidad de cambios que se nos vienen, que se derivarán de la evolución de este proceso que he relatado, trastocarán tantos paradigmas, traerán tantas nuevas tecnologías transformadoras, que probablemente nos capacitarán para afrontarlo. Sobre todo, porque todos estos cambios revolucionarán también otras disciplinas, tales como la medicina, la biotecnología y la genética, la neurología, la gerontología, etcétera.

## 6. CONCLUSIONES

¿Dónde estamos ahora y cuál será el ritmo del cambio? No sería del todo correcto decir que estamos en las tres primeras fases (recogida de datos, clasificación y relación) y que aún no

hemos empezado en el resto. Si bien es verdad que en muchos casos y en muchos sectores esto es así, y aún casi no se ha pasado de la fase de relación, hay otros muchos sectores y empresas que están llevando a cabo todo el proceso completo, pero los algoritmos de aprendizaje no son muy sofisticados (y, por lo tanto, el acierto es limitado), o el ritmo de aprendizaje es lento, o la capacidad para interrelacionar patrones, de forma que se desarrollen patrones más complejos, es limitada y torpe. Pero sin duda, todo ello irá cambiando de forma acelerada en los próximos veinte o treinta años, sobre todo porque los avances que se vayan consiguiendo en el entrenamiento y aprendizaje de la inteligencia artificial repercutirán en una mayor sofisticación de la misma, lo que iniciará un círculo virtuoso, como anunciaba al principio, que reducirá casi a cero nuestra capacidad de decisión. Y llegaremos a ello de forma voluntaria, sencillamente porque las decisiones de la inteligencia artificial serán mejores que las nuestras.

¿No os parece fascinante ser una de las generaciones que va a vivir un cambio así?

### Referencias

- FERRETTI, F. y ARDONETTI, I. (2020). *Persuasive conversation as a new form of communication in Homo sapiens*. The Royal Society. <https://doi.org/10.1098/rstb.2020.0196>
- HUMPHREYS, P. J. (1996). *Mass media and media policy in Western Europe* (Vol. 2). Manchester University Press.
- KILLIAN, G. y McMANUS, K. (2015). A marketing communications approach for the digital era: Managerial guidelines for social media integration. *Business horizons*, 58(5), pp. 539-549.
- RAMÍREZ ALVARADO, M. D. M. (2009). Información y contrainformación: la evolución de la imprenta en el período de la Reforma luterana y de la Contrarreforma. *Anàlisi: Quaderns de Comunicació i Cultura*, 39, p.149.
- SHARMA, S. y VERMA, H. V. (2018). Social media marketing: Evolution and change. En: *Social media marketing* (pp. 19-36). Singapore: Palgrave Macmillan.



## CAPÍTULO III

## Recomendación a grupos basada en un modelo de consenso de mínimo costo

Raciel Yera  
Álvaro Labella  
Luis Martínez

Los sistemas de recomendación a grupo (SRG) han atraído recientemente la atención tanto del mundo académico como de la industria. Estos se enfocan en la recomendación de ítems que satisfacen las preferencias globales de un grupo de personas, siendo los programas de televisión y los paquetes de viajes turísticos ejemplos típicos de estos ítems. En este sentido, a pesar de estar actualmente bien establecidos varios enfoques básicos para construir los SRG, también se han identificado limitaciones relacionadas con la existencia de conflictos entre las preferencias de los usuarios a la hora de generar las recomendaciones. Por tanto, se hace necesario gestionar de forma adecuada el acuerdo entre los miembros del grupo, para obtener una recomendación grupal que satisfaga los intereses globales del grupo. Esta contribución se enfoca en la propuesta de la aplicación de un modelo de consenso de mínimo costo en un escenario de recomendación a grupos, para solventar la gestión de conflictos en el grupo. Además, se presenta un estudio experimental que muestra la positiva influencia de este modelo en la satisfacción del grupo en relación con las recomendaciones generadas.

*Palabras clave:* sistemas de recomendación a grupo, modelo de consenso de mínimo costo, resolución de conflictos.

## 1. INTRODUCCIÓN

En los últimos años, los sistemas de recomendación (SR) se han convertido en una herramienta necesaria en varios escenarios en línea con vistas a solventar la sobrecarga de información asociada a la selección de las mejores opciones en espacios de búsqueda masivos (Adomavicius y Tuzhilin, 2005; Yera y Martínez, 2017a). Por tanto, los SR son frecuentemente utilizados en varios dominios como el comercio electrónico (Guo, Wang y Li, 2017), el aprendizaje electrónico (Yera y Martínez, 2017b), la salud (Yera, Alzahrani y Martínez, 2019), entre otros.

Además, entre los distintos tipos de ítems a recomendar existe una clase bastante habitual como es, la de los llamados ítems sociales, que suelen ser usualmente consumidos por un grupo de usuarios y no por un usuario de forma individual (Castro, Yera y Martínez, 2017; De Pessemier, Dooms y Martens, 2014). Los programas de televisión y los paquetes de viaje turísticos son típicos ejemplos de este tipo de ítems (Dara, 2020), en los que a pesar de ser consumidos en grupo, los intereses individuales de los usuarios dentro del grupo aún pueden divergir y causar conflictos. Con vistas a generar recomendaciones apropiadas en estos escenarios, los sistemas de recomendación a grupos (SRG) han atraído recientemente la atención de académicos y de la industria para recomendar ítems que satisfagan las preferencias globales de los grupos (Dara, 2020).

Específicamente, los métodos de recomendación a grupo han sido tradicionalmente clasificados en dos categorías fundamentales resultantes de la extensión de la recomendación individual (De Pessemier, Dooms y Martens, 2014): 1) el enfoque de agregación de *ratings*, donde las preferencias individuales de los usuarios se combinan para obtener un perfil unificado que representa las preferencias del grupo, y 2) el enfoque de agregación de recomendaciones, en las que las recomendaciones individuales son inicialmente generadas y posteriormente son agregadas para obtener la lista final de recomendaciones.

A pesar de que estos dos paradigmas de recomendación grupal han sido utilizados ampliamente en los últimos años, algunos trabajos han apuntado que resulta necesario el desarrollo de nuevos métodos que vayan más allá de estos enfoques básicos de agregación (Tran *et al.*, 2018). La agregación por sí sola puede generar pérdida de información y recomendaciones sesgadas, dando lugar a una limitada satisfacción del grupo con las sugerencias generadas. A raíz de lo anterior, el presente estudio tiene como premisa que el logro de un mayor “acuerdo” entre los miembros del grupo, puede dar lugar a una mejor eficacia en la generación de recomendaciones a grupo para producir una mayor satisfacción del mismo con dichas recomendaciones.

La presente contribución se centra en este objetivo para lo que, entre los distintos métodos de consenso presentes en la literatura (Ben-Arieh y Easton, 2007; Labella *et al.*, 2020), se centrará en explorar el efecto de aplicar un modelo de consenso de mínimo costo (Ben-Arieh y Easton, 2007) sobre las preferencias individuales de los usuarios, con vistas a obtener recomendaciones a grupo más satisfactorias. El trabajo se estructura de la siguiente manera. La

sección 2 revisa brevemente los conceptos fundamentales relacionados con los SRG y procesos de alcance de consenso. La sección 3 presenta dos métodos que integran el mencionado modelo de consenso de costo mínimo en un modelo de recomendación a grupo. Estos métodos son evaluados en la sección 4. Finalmente, la sección 5 concluye el trabajo, apuntando a líneas futuras de investigación.

## 2. CONCEPTOS FUNDAMENTALES

Esta sección revisa brevemente los conceptos fundamentales necesarios para el desarrollo del presente trabajo. Específicamente, se presentan conceptos relacionados con sistemas de recomendación, sistemas de recomendación a grupo, y con modelos de consenso de costo mínimo.

### 2.1. Sistemas de recomendación

Los sistemas de recomendación son herramientas centradas en proporcionar a los usuarios aquella información que mejor se corresponde con sus necesidades y preferencias en un espacio de búsqueda sobrecargado de posibles opciones (Adomavicius y Tuzhilin, 2005).

Acorde a su principio de funcionamiento, los sistemas de recomendación se agrupan en cuatro categorías fundamentales (Adomavicius y Tuzhilin, 2005): los sistemas de recomendación basados en contenido (Lops, De Gemmis, y Semeraro, 2011), de filtrado colaborativo (Ekstrand, Riedl, y Konstan, 2010), demográficos (Al-Shamri, 2016), e híbridos (Burke, 2002).

Los sistemas de recomendación basados en el contenido (Lops, De Gemmis, y Semeraro, 2011) se centran en la descripción del ítem y en el perfil de usuario para realizar las recomendaciones. Están conformados por un modelo de los ítems a recomendar, un modelo del perfil de los usuarios del sistema, y una función para calcular la similitud entre los perfiles de los ítems y de los usuarios. Este valor de similitud es la base para la generación de la lista de recomendaciones para el usuario actual.

Por otra parte, los sistemas de recomendación basados en filtrado colaborativo (Ekstrand, Riedl y Konstan, 2010), se basan fundamentalmente en las preferencias de los usuarios sobre los ítems en cuestión. Están conformados a su vez por dos familias de métodos, que son los basados en vecindario y los basados en modelos. Los métodos basados en vecindario (Aggarwal, 2016), en los que para el usuario activo se determinan aquellos usuarios más similares acorde a su patrón de preferencias sobre los ítems del sistema. A continuación, la generación de recomendaciones para este usuario se hace basándose en las preferencias de sus usuarios vecinos (aquellos más similares). En otra dirección, los métodos basados en modelos (Koren, Bell y Volinsky, 2009) utilizan las preferencias de los usuarios para construir un modelo predictivo apoyado en técnicas de aprendizaje automático e inteligencia

computacional, que permita predecir el valor de las preferencias de los usuarios por ítems desconocidos y con este generar las recomendaciones.

De manera paralela y a veces integrada con estas dos categorías previas, han sido desarrollados los sistemas de recomendación demográficos (Al-Shamri, 2016), los cuales explotan los atributos personales de los individuos, tales como país, edad, género, con vistas a generar las recomendaciones.

Finalmente, los sistemas de recomendación híbridos (Burke, 2002) se centran en combinar los paradigmas anteriores, usualmente consolidando información de diferentes fuentes para dar lugar a un mejor desempeño. Entre las técnicas básicas de hibridación indicadas por Burke (2002) se encuentra el intercambio, donde en dependencia de la naturaleza del usuario activo se utiliza uno u otro enfoque de recomendación; la utilización de pesos, donde la salida de varios sistemas de recomendación son directamente combinadas utilizándose determinada ponderación; y la cascada, donde la salida de un sistema de recomendación es refinada por un segundo sistema.

## 2.2. Sistemas de recomendación a grupo

Los sistemas de recomendación a grupo (SRG) se centran en extender los sistemas de recomendación individuales para proporcionar recomendaciones a grupos de usuarios ( $G = \{g_1, \dots, g_m\} \subseteq U$ ) (De Pessemier, Dooms y Martens, 2014). Formalmente, los SRG se enfocan en encontrar el ítem (o el conjunto de ítems) que maximizan la preferencia predicha para los miembros del grupo:

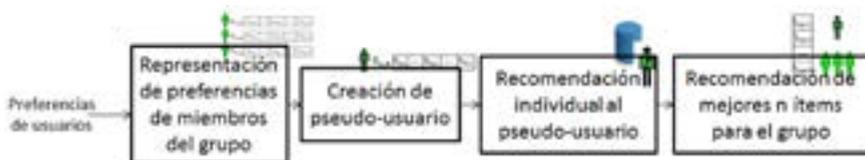
$$\text{Recomendación}(I, G_a) = \arg \max_{i_k \in I} \text{Pr edicción}(i_k, G_a) \quad [1]$$

Actualmente se desarrollan dos paradigmas fundamentales de recomendación grupal, contruidos sobre métodos de recomendación individual:

- Agregación de *ratings*, basado en la creación del perfil de un seudousuario que se obtiene a través de la agregación de las preferencias individuales del grupo. Este

Figura 1.

### Esquema general de la recomendación grupal basada en la agregación de *ratings*



nuevo perfil es usado para generar las recomendaciones destinadas al grupo de usuarios (figura 1).

- Agregación de recomendaciones, el cual agrega las recomendaciones individuales realizadas a cada uno de los miembros del grupo, con vistas a obtener la recomendación grupal (figura 2).

Figura 2.

### Esquema general de la recomendación grupal basada en la agregación de recomendaciones



### 2.3. Modelo de consenso de costo mínimo

En la literatura especializada existe una gran cantidad de modelos de alcance de consenso (Ben-Arieh y Easton, 2007; Labella *et al.*, 2020), los cuales pueden ser clasificados atendiendo a sus diferentes características (Palomares *et al.*, 2014). Entre estas características destaca la capacidad de generar valores de consenso automático o con necesidad de retroalimentación por parte de los miembros del grupo. Debido a las necesidades computacionales y de generación de recomendación de los SRG, en el presente trabajo se emplea el modelo de consenso automático de mínimo costo propuesto por Ben-Arieh y Easton (2007), el cual representa una de las primeras propuestas desarrolladas en esta dirección. Este modelo se enfoca a minimizar el costo asociado a la modificación de las opiniones independientes de los expertos, necesaria para alcanzar un consenso entre los mismos. Este costo mínimo es obtenido a través de la resolución de un modelo de programación matemática cuya función objetivo es:

$$\min \sum_{u=1}^n c_u |\bar{o}_u - o_u| \quad [2]$$

Sujeta a las siguientes restricciones:

$$\bar{o} = \sum_{u=1}^n w_u \bar{o}_u \quad [3]$$

$$|\bar{o}_u - \bar{o}| \leq \varepsilon, u = 1, 2, \dots, n \quad [4]$$

El modelo posee los siguientes parámetros:

- $c_u$ , como el costo de modificar las preferencias del experto  $u$ .
- $o_u$ , como las preferencias iniciales del experto  $u$ .
- $\bar{o}_u$ , como las preferencias finales del experto  $u$ , tras el alcance del consenso.
- $\bar{o}$ , como la preferencia colectiva del grupo de expertos.
- $\epsilon$ , como la máxima posible distancia entre la preferencia colectiva y la individual.
- $w_u$ , como el peso del experto  $u$ .

### 3. CONSENSO DE MÍNIMO COSTO EN UN MÉTODO DE RECOMENDACIÓN A GRUPO

En la presente sección se propondrá la incorporación de un modelo de consenso de mínimo costo en dos escenarios diferentes dentro de un contexto de recomendación a grupos. En un primer momento, se propondrá la utilización del consenso de mínimo costo como método de preprocesamiento de datos (sección 3.1), enfocado en lograr consenso entre las preferencias iniciales de los usuarios del grupo, pudiendo dar lugar a preferencias más eficaces (figura 3). En adelante, este método será referido como consenso enfocado en las preferencias de los usuarios.

En segundo lugar, se utilizará el consenso para refinar las recomendaciones generadas individualmente para cada usuario, como etapa previa a la generación de recomendaciones grupales (figura 4). Este método será referido en lo adelante como consenso enfocado en las recomendaciones individuales.

#### 3.1. Recomendación a grupos con consenso enfocado en las preferencias de los usuarios

La utilización de un modelo de consenso de mínimo costo en el contexto de la recomendación grupal para lograr un alto nivel de consenso en las preferencias de los usuarios y mejorar la eficacia de las recomendaciones, viene dado por las siguientes etapas: 1) análisis del consenso de mínimo costo entre las preferencias de los usuarios, 2) generación de las recomendaciones individuales, 3) agregación de recomendaciones individuales, y 4) recomendación grupal (ver figura 3).

Resulta válido acotar que esta propuesta está alineada con el paradigma de recomendación grupal basado en agregación de recomendaciones (ver sección 2.1). Se deja para trabajos futuros la posible integración de un modelo de consenso de mínimo costo con recomendación basada en agregación de preferencias.

Figura 3.

### Esquema general de la recomendación grupal basada en un modelo de consenso de mínimo costo enfocado en las preferencias de los usuarios



*Análisis del consenso de costo mínimo entre las preferencias de los usuarios:* esta primera etapa de la propuesta aplica el modelo de consenso de mínimo costo a las preferencias de los usuarios en el grupo, con vistas a ajustar estas para lograr el alcance del consenso. Como salida de esta etapa, se obtiene un conjunto de nuevos valores de preferencias, mínimamente modificados.

Específicamente, el modelo de consenso es aplicado independientemente para cada ítem  $i$ , considerando las siguientes asunciones para extrapolar la notación de dicho modelo (sección 2.3), hacia el escenario de recomendación grupal.

- $\forall_{u \in G} (o_u = r_{ui})$  (cada preferencia del usuario sobre el ítem  $i$ , se toma como la opinión del experto  $u$  sobre  $i$ ).
- $\forall_{u \in G} (c_u = 1)$  (el costo de modificar las preferencias de  $u$  es siempre 1).
- $\forall_{u \in G} (w_u = 1/n)$  (el peso del experto  $u$  es siempre  $1/n$ , donde  $n$  es el número de expertos).
- Varios valores de  $\epsilon$  serán estudiados en la sección de experimentos.

*Generación de las recomendaciones individuales:* esta etapa se centra en calcular las recomendaciones individuales generadas para cada uno de los miembros del grupo, basándose en las preferencias que se obtuvieron tras el alcance del consenso en la etapa anterior. Aquí puede ser utilizado un método tradicional de filtrado colaborativo para obtener las preferencias individuales de los usuarios, tales como la recomendación basada en vecindades usuario-usuario, basada en vecindades ítem-ítem, así como métodos basados en factorización matricial. El desempeño de varios de estos métodos en este contexto, será evaluado en la sección de experimentación.

*Agregación de recomendaciones individuales:* en esta etapa se realiza la agregación de las recomendaciones individuales, con vistas a obtener la recomendación grupal. En este trabajo se considerarán como estrategias de agregación a utilizar, a las estrategias “promedio” y “minimización de la miseria”, las que han sido identificadas entre las de mejor desempeño en recomendación grupal (Amer-Yahia *et al.*, 2009; Dwivedi y Bharadwaj, 2015).

La estrategia “promedio”, se centra en agregar los listados de recomendaciones individuales a través del cálculo del promedio de los valores de predicción de las preferencias del grupo para un ítem específico. Este valor promedio es el que se asume como la preferencia global del grupo sobre dicho ítem, y es el que se usa posteriormente para construir la lista de recomendaciones para el grupo. Esta estrategia agrega las recomendaciones de una manera intuitiva y deseable, y se corresponde con una de las maneras en la que un grupo de personas toma decisiones de un modo natural (Masthoff, 2004).

Por otro lado, en la estrategia de “minimización de la miseria”, se asume que el nivel de satisfacción del grupo por las recomendaciones, está asociado al nivel de satisfacción del miembro más insatisfecho del mismo. Por tanto, la meta es obtener al menos un nivel predefinido de satisfacción para todos los miembros del grupo (De Pessemier, Dooms y Martens, 2014). Para implementar esta estrategia, se toma el valor de predicción del grupo para un ítem en específico, como el valor mínimo entre todas las predicciones hechas para los miembros del grupo, con respecto al ítem en cuestión.

*Recomendación a grupo:* una vez que se obtienen los valores de preferencia del grupo por cada uno de los ítems correspondientes, el listado final de recomendaciones se obtiene mediante la ordenación descendente de estos ítems acorde a su valor de preferencia.

### 3.2. Recomendación grupal con consenso enfocado en las recomendaciones individuales

La utilización de un modelo de consenso de mínimo costo en el contexto de la recomendación grupal y enfocado en lograr un mayor consenso en las recomendaciones individuales generadas, viene dado por las siguientes etapas: 1) recomendación individual, 2) análisis del consenso de costo mínimo entre las recomendaciones individuales generadas, 3) agregación de recomendaciones individuales, y 4) recomendación a grupo (ver figura 4).

Figura 4.

#### Esquema general de la recomendación grupal basada en un modelo de consenso de mínimo costo enfocado en las recomendaciones individuales



*Recomendación individual:* tal y como se presentó en la sección 3.1, esta etapa se centra en calcular las recomendaciones individuales generadas para cada uno de los miembros

del grupo. Aunque aquí se puede en principio utilizar cualquier método tradicional de filtrado colaborativo, es importante la utilización en este escenario particular de un método que siempre garantice la generación de predicciones/recomendaciones tales como los basados en factorización matricial, en contraposición con los basados en vecindario que en ocasiones presentan problemas de cubrimiento (Koren, Bell y Volinsky, 2009). Esto resulta necesario dado el hecho de que posteriormente se aplica un modelo de consenso, y que se espera por lo tanto tener disponibles las preferencias individuales de todos los miembros del grupo. A raíz de lo anterior, como método de recomendación se utilizará el SVD tradicional referido por Koren, Bell y Volinsky (2009).

*Análisis del consenso de costo mínimo entre las recomendaciones generadas:* esta primera etapa de la propuesta aplica el modelo de consenso de mínimo costo a las recomendaciones generadas para los usuarios en el grupo, con vistas a ajustar estas para lograr un mayor consenso. Como salida de esta etapa, se obtiene un conjunto de nuevos valores de los *ratings* asociados a los ítems recomendados, mínimamente modificados hacia el logro de un mayor consenso.

Específicamente, el modelo de consenso es aplicado independientemente para cada ítem  $i$ , considerando las siguientes asunciones para extrapolar la notación de dicho modelo (sección 2.3), hacia el escenario de recomendación grupal, operando sobre las recomendaciones individuales.

- $\forall_{u \in G} (o_u = r_{ui})$  (cada *rating* del usuario sobre el ítem  $i$ , se toma como la opinión del experto  $u$  sobre  $i$ ).
- $\forall_{u \in G} (c_u = 1)$  (el costo de modificar los *ratings* de  $u$  es siempre 1).
- $\forall_{u \in G} (w_u = 1/n)$  (el peso del experto  $u$  es siempre  $1/n$ , donde  $n$  es el número de expertos).
- Varios valores de  $\epsilon$  serán estudiados en la sección de experimentos.

*Agregación de recomendaciones individuales:* en esta etapa se realiza la agregación de las recomendaciones individuales consensuadas, con vistas a obtener la recomendación grupal. En este escenario se considerará como estrategias de agregación a utilizar a la “minimización de la miseria”, ya presentada en la sección previa 3.1. Aquí es relevante acotar que un estudio más profundo de la estrategia “promedio” para este contexto se dejará para trabajos futuros, considerando que en principio se obtuvieron resultados modestos respecto a la aplicación de la etapa de alcance de consenso. Esto podría ser esperado, considerando la naturaleza de la operación promedio en la que siempre se esperaría que un promedio de valores y un promedio de valores consensuados, pudiera dar lugar a similares resultados. Aunque es necesario realizar un estudio mucho más profundo para dar validez a esta afirmación.

*Recomendación a grupo:* una vez que se obtienen los *ratings* del grupo por cada uno de los ítems correspondientes, el listado final de recomendaciones se obtiene mediante la

ordenación descendente de estos ítems acorde a su valor de preferencia, de igual forma que el método de la sección 3.1.

En la siguiente sección se realizará una evaluación experimental del marco de recomendación aquí presentado.

## 4. EVALUACIÓN EXPERIMENTAL

La presente sección se centra en evaluar los métodos de recomendación presentados en este trabajo. Con este fin, se detalla primeramente el protocolo de experimentación empleado, incluyendo las bases de datos y métricas de evaluación que se utilizan (sección 4.1). Posteriormente, se presentan y discuten los resultados asociados a la evaluación del método. Finalmente se apuntan posibles trabajos futuros.

### 4.1. Protocolo de experimentación

La presente investigación emplea un protocolo de evaluación ampliamente utilizado para sistemas recomendadores grupales (De Pessemier, Dooms y Martens, 2014), el cual está conformado por los siguientes pasos:

- Dividir la base de datos original de preferencias de usuarios, en los conjuntos de entrenamiento y de prueba.
- Construir los grupos correspondientes, en este caso de manera aleatoria.
- Generar las recomendaciones para cada grupo, utilizando el conjunto de entrenamiento.
- Evaluar individualmente la eficacia de las recomendaciones, de un modo semejante a la recomendación individual, comparando las preferencias obtenidas para el grupo, con las preferencias del usuario del conjunto de prueba.

La implementación del método de recomendación grupal presentado en la sección anterior, requiere inicialmente la identificación de varios componentes adicionales. En el caso de la recomendación grupal basada en consenso y sobre las preferencias individuales de los usuarios (sección 3.1), estos componentes serán:

- El enfoque de recomendación individual que será empleado internamente. En este caso, se evaluarán cuatro de los enfoques de recomendación más utilizados en la literatura, que son los siguientes:
  1. El método de recomendación basada en vecindades usuario-usuario inicialmente presentado por Resnick *et al.* (1994). Aquí se utilizará el coeficiente de correlación de Pearson como medida de similitud, con 40 vecinos.

2. El método de recomendación basada en vecindades ítem-ítem presentado por Sarwar *et al.* (2001). Se utilizará la misma medida de similitud y número de vecinos que el caso anterior.
  3. El método inspirado en la factorización matricial, popularizado por Koren, Bell y Volinsky (2009). Particularmente, en este caso se utilizará la variante inicialmente propuesta por Simon Funk en el Netflix Prize (Bennett y Lanning, 2007). Se utilizarán 100 factores para modelar los usuarios y los ítems.
  4. El método inspirado en la factorización matricial que en adición asume valores implícitos de *ratings*, presentado por Koren (2008). Aquí se consideran 20 factores.
- El esquema de agregación utilizado para combinar las preferencias individuales de los usuarios. Aquí se considerará el esquema “promedio”, expuesto en la sección anterior. Es válido resaltar que este esquema está asociado a la teoría de la elección social (*social choice theory*) (Sen, 1986).
  - El valor de  $\epsilon$ , que representa la máxima posible distancia entre la preferencia colectiva y la individual en el usuario, después de alcanzado el consenso (ver secciones 2.3 y 3). Un valor menor de  $\epsilon$  indica que se está requiriendo un mayor grado de consenso entre las preferencias de los usuarios del grupo, siéndose por tanto más invasivo en la transformación de las preferencias. Por otro lado, un mayor valor de  $\epsilon$  asume la existencia de consenso a pesar de ser mayor la diferencia entre las preferencias de los usuarios del grupo.

En el caso de la recomendación grupal soportada por consenso sobre las recomendaciones individuales generadas (sección 3.2), estos componentes serán:

- El enfoque de recomendación individual empleado internamente. Tal y como se comentó en la sección 3.2, en este caso se utilizará el SVD tradicional propuesto por Simon Funk (Bennett y Lanning, 2007), con 100 factores.
- El esquema de agregación utilizado para combinar las preferencias individuales de los usuarios. Aquí se considerará el esquema “miseria mínima”, expuesto en la sección anterior.
- De manera semejante al método de consenso enfocado en las preferencias, se considerarán varios valores de  $\epsilon$ .

El protocolo de experimentación que aquí se presenta, utilizará la base de datos *Movielens 100K*, compuesta por 943 usuarios, 1.682 películas, y un total de 100.000 valores de preferencia de los usuarios por las películas (Harper y Konstan, 2015). Estos valores de preferencia están en el rango [1; 5]. Aquí es importante indicar que este rango implica que sea necesario realizar un proceso de normalización previo a la aplicación del modelo de consenso de mínimo costo, para llevarlo al rango [0; 1]. Posterior al alcance del consenso, los valores obtenidos son proyectados nuevamente al rango [1; 5].

Como métricas de evaluación, serán utilizadas el error medio absoluto (MAE), y la raíz cuadrada del error cuadrático medio (RMSE), las cuales están entre las métricas más utilizadas en recomendación grupal (Gunawardana y Shani, 2015), fundamentalmente para métodos basados en filtrado colaborativo como el que se presenta en este trabajo.

$$MAE = \frac{1}{|R|} \sum_{r_{ui} \in R} |r_{ui} - r_{ui}^*| \quad [5]$$

$$RMSE = \sqrt{\frac{1}{|R|} \sum_{r_{ui} \in R} (r_{ui} - r_{ui}^*)^2} \quad [6]$$

Las ecuaciones [5] y [6] presentan estas dos métricas de evaluación. En estas, R representa el conjunto de valores de preferencias,  $r_{ui}$  el valor real de la preferencia del usuario, y  $r_{ui}^*$  el valor predicho por el método que se evalúa.

Finalmente, en la ejecución del protocolo previamente descrito, en el contexto de este trabajo serán generados aleatoriamente 20 grupos de cinco usuarios cada uno, para registrar la eficacia de la recomendación.

#### 4.2. Resultados de la evaluación del método de recomendación grupal basado en consenso y sobre las preferencias individuales de los usuarios

Las tablas 1-4 presentan los resultados de la evaluación del método basado en consenso y sobre las preferencias individuales de los usuarios, acorde a la métrica MAE, y utilizando los cuatro métodos de recomendación individual a utilizar en este caso. En cada tabla se presenta primeramente la eficacia de la recomendación obtenida por la propuesta, considerando varios valores de  $\epsilon$ , en el conjunto {0.01, 0.05, 0.1, 0.2, 0.3, 0.4, 0.5}. En una segunda fila, se presenta el valor de la misma propuesta, pero excluyendo la etapa de alcance de consenso, presentada en la sección 2.3.

Tabla 1.

##### Desempeño del SRG con consenso sobre preferencias, utilizando similitud usuario-usuario y diferentes niveles de consenso, en comparación con un enfoque que no considera consenso (MAE)

Método \ $\epsilon$	0.01	0.05	0.1	0.2	0.3	0.4	0.5
SRG con UsuarioKNNPearson y consenso	0.8506	0.844	0.8441	0.8486	0.8518	0.8525	0.8529
SRG con UsuarioKNNPearson	0.8526						

La tabla 1 muestra el resultado para la recomendación grupal apoyada por el método UsuarioKNNPearson. En esta se puede apreciar que el uso del método de consenso de costo mínimo mejora con notoriedad la eficacia de las recomendaciones generadas, obteniéndose

el mejor resultado para  $\epsilon=0.05$ . También para  $\epsilon=0.1$  y  $\epsilon=0.2$ , se puede apreciar una mejora importante con respecto a la variante que no considera consenso.

Tabla 2.

**Desempeño del SRG con consenso sobre preferencias, utilizando similitud ítem-ítem y diferentes niveles de consenso, en comparación con un enfoque que no considera consenso (MAE)**

Método\ $\epsilon$	0.01	0.05	0.1	0.2	0.3	0.4	0.5
SRG con ItemKNNPearson y consenso	0.8216	0.8131	0.8078	0.8075	0.8069	0.8081	0.8083
SRG con ItemKNNPearson				0.8081			

En el caso de la recomendación grupal apoyada por el método ItemKNNPearson (tabla 2), los mejores resultados fueron obtenidos para escenarios donde se requirió un nivel menor de consenso que con respecto a UserKNNPearson. En este caso, el mejor desempeño se obtuvo para  $\epsilon=0.3$ .

Tabla 3.

**Desempeño del SRG con consenso sobre preferencias, utilizando factorización matricial y diferentes niveles de consenso, en comparación con un enfoque que no considera consenso (MAE)**

Método\ $\epsilon$	0.01	0.05	0.1	0.2	0.3	0.4	0.5
SRG con SVD y consenso	0.8386	0.8302	0.8224	0.8175	0.8161	0.8158	0.8159
SRG con SVD				0.8161			

La tabla 3 por su parte presenta los resultados asociados al método basado en factorización matricial. En contraste con las tablas 1 y 2, aquí es menor el efecto del método de consenso en la recomendación grupal, considerando más discreta la mejora introducida. Aun así, es importante resaltar que para  $\epsilon=0.4$  y  $\epsilon=0.5$ , el método basado en el consenso da lugar a una mejora en el desempeño. Similar comportamiento viene asociado al método de factorización matricial que considera preferencias implícitas (tabla 4), en el que para  $\epsilon$  en el rango  $[0.3; 0.5]$  se mejora el resultado del método base.

Tabla 4.

**Desempeño del SRG con consenso sobre preferencias, utilizando factorización matricial que incluye valores implícitos, y diferentes niveles de consenso, en comparación con un enfoque que no considera consenso (MAE)**

Método\ $\epsilon$	0.01	0.05	0.1	0.2	0.3	0.4	0.5
SRG con SVD++ y consenso	0.8213	0.8131	0.8059	0.8017	0.8011	0.8012	0.8016
SRG con SVD++				0.8019			

Por su parte, las tablas 5-8 presentan el resultado de la métrica RMSE. A diferencia de la métrica MAE, en el cálculo de la eficacia de la recomendación RMSE otorga una mayor penalidad a aquellos escenarios en los que es mayor la diferencia entre la preferencia predicha y la real.

La tabla 5 presenta los resultados para la recomendación grupal apoyada por la similitud usuario-usuario y similitud Pearson (UsuarioKNNPearson). En este caso se puede observar que para los valores de  $\epsilon$  desde 0.01 hasta 0.3, se supera el desempeño del método base sin considerar consenso. Aquí el mejor resultado se obtuvo para  $\epsilon=0.1$ .

Tabla 5.

**Desempeño del SRG con consenso sobre preferencias utilizando similitud usuario-usuario y diferentes niveles de consenso, en comparación con un enfoque que no considera consenso (RMSE)**

Método\ $\epsilon$	0.01	0.05	0.1	0.2	0.3	0.4	0.5
SRG con UsuarioKNNPearson y consenso	1.0877	1.079	1.0772	1.089	1.097	1.0984	1.0991
SRG con UsuarioKNNPearson	1.0981						

La tabla 6 por su parte muestra este mismo análisis considerando la similitud ítem-ítem. En contraposición con la métrica MAE para este mismo escenario de experimentación (tabla 2), el mejor resultado aquí estuvo asociado al alcance de un alto consenso ( $\epsilon=0.1$ ). No obstante, para  $\epsilon$  en el rango [0.05; 0.4], la propuesta siempre supera el método base.

Tabla 6.

**Desempeño del SRG con consenso sobre preferencias utilizando similitud ítem-ítem y diferentes niveles de consenso, en comparación con un enfoque que no considera consenso (RMSE)**

Método\ $\epsilon$	0.01	0.05	0.1	0.2	0.3	0.4	0.5
SRG con ItemKNNPearson y consenso	1.0485	1.0396	1.0349	1.0381	1.0397	1.0416	1.0419
SRG con ItemKNNPearson	1.0417						

Finalmente, las tablas 7 y 8 presentan los resultados asociados a los dos métodos de factorización matricial considerados (ver sección 4.1). En el caso particular del método básico de factorización matricial (tabla 7), el margen de mejora de RMSE asociado al método basado en consenso con respecto al método base, es más representativo que utilizando la métrica MAE. Este se obtiene para un valor de  $\epsilon=0.2$ .

A su vez, en el método de factorización matricial que considera información implícita (Koren, 2008), la utilización del consenso en el rango  $\epsilon=[0.2; 0.5]$ , da lugar a una mejora en el método base. El mejor desempeño se obtiene para  $\epsilon=0.2$ , obteniéndose un RMSE de

1.0064, por 1.0101 que obtiene el método base. Este método de factorización matricial es el que obtiene los mejores resultados a nivel global, tanto para MAE como para RMSE.

Tabla 7.

**Desempeño del SRG con consenso sobre preferencias utilizando factorización matricial y diferentes niveles de consenso, en comparación con un enfoque que no considera consenso (RMSE)**

Método \ $\epsilon$	0.01	0.05	0.1	0.2	0.3	0.4	0.5
SRG con SVD y consenso	1.0366	1.0304	1.0254	1.0233	1.0237	1.0243	1.0247
SRG con SVD	1.0248						

Tabla 8.

**Desempeño del SRG con consenso sobre preferencias utilizando factorización matricial que incluye valores implícitos y diferentes niveles de consenso, en comparación con un enfoque que no considera consenso (RMSE)**

Método \ $\epsilon$	0.01	0.05	0.1	0.2	0.3	0.4	0.5
SRG con SVD++ y consenso	1.0209	1.0137	1.0083	1.0064	1.0076	1.009	1.0098
SRG con SVD++	1.0101						

En la primera parte de esta sección se realizó un análisis comparativo del efecto de la incorporación del consenso, en varios escenarios de recomendación grupal. Resulta necesario, no obstante, llevar a cabo una visualización más profunda del comportamiento del parámetro  $\epsilon$  en cada uno de los métodos, y cómo este afecta la eficacia de la recomendación.

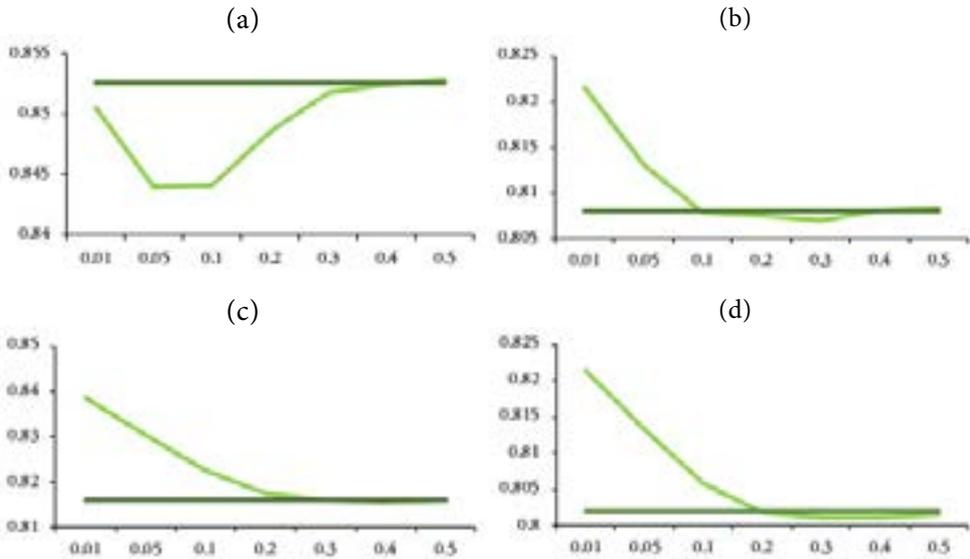
La figura 5 muestra este análisis según la métrica MAE. Se muestra que, más de allá de la introducción de una mayor o menor mejora en la eficacia de la recomendación asociada a la introducción del consenso, el mejor desempeño tiende a venir asociado a valores intermedios de  $\epsilon$ .

La utilización de valores pequeños de  $\epsilon$  se traduce en la demanda de un fuerte nivel de consenso del grupo, lo que a su vez implica la necesidad de transformar una mayor cantidad de valores de preferencias para lograr dicho consenso. Esta importante modificación de preferencias, a pesar de mejorar en algunos casos el método base, no da lugar a la obtención de los mejores resultados posibles.

Por otro lado, el uso de valores grandes de  $\epsilon$  se traduce en una mayor flexibilidad en cuanto a las posibles diferencias en las preferencias de los usuarios, para lograr el nivel de consenso que se asume. Así, en muchos casos no es necesaria la modificación de las preferencias de los usuarios, porque *a priori* ya existe el consenso en estos casos. Esta es la razón por la cual el desempeño del método basado en consenso tiende a igualar al método base, para valores grandes de  $\epsilon$ .

Figura 5.

### Estudio del parámetro $\epsilon$ para la métrica MAE y diferentes escenarios de recomendación grupal



*Nota:* La línea recta representa el desempeño del método sin considerar consenso. a) Soportado por UsuarioKNNPearson. b) Soportado por ÍtemKNNPearson. c) Soportado por factorización matricial. d) Soportado por factorización matricial e información implícita.

Por su parte la figura 6 muestra este mismo análisis para la métrica RMSE. Las conclusiones arrojadas de este análisis coinciden con las asociadas a la métrica MAE, viéndose además una mayor diferencia entre el desempeño de la propuesta y el del método base. En

Figura 6.

### Estudio del parámetro $\epsilon$ para la métrica RMSE y diferentes escenarios de recomendación grupal

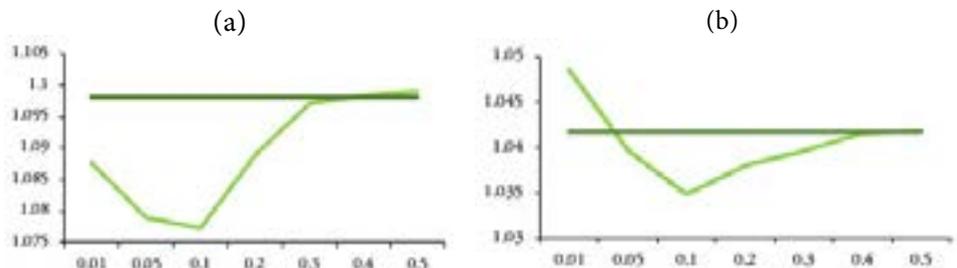
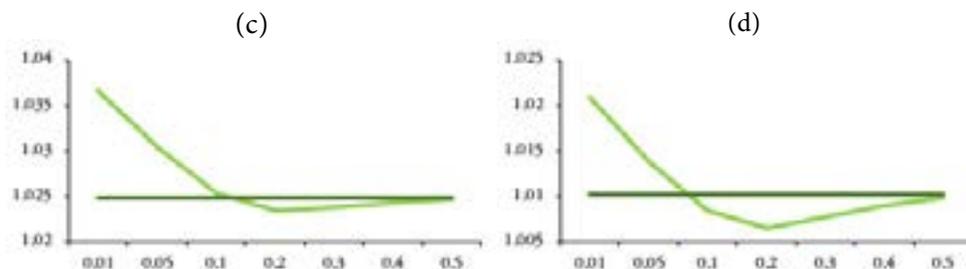


Figura 6. (continuación)

### Estudio del parámetro $\epsilon$ para la métrica RMSE y diferentes escenarios de recomendación grupal



*Nota:* La línea recta representa el desempeño del método sin considerar consenso. a) Soportado por UsuarioKNNPearson. b) Soportado por ÍtemKNNPearson. c) Soportado por factorización matricial. d) Soportado por factorización matricial e información implícita.

adición se observa con una mayor claridad que los mejores resultados son obtenidos con valores intermedios de  $\epsilon$ .

#### 4.3. Resultados de la evaluación del método de recomendación grupal basado en consenso y sobre las recomendaciones individuales de los usuarios

Las tablas 9 y 10 presentan los resultados de la evaluación del método basado en consenso y sobre las recomendaciones individuales proporcionadas a los usuarios, utilizando las métricas MAE y RMSE. En cada tabla se presenta primeramente la eficacia de la recomendación obtenida por la propuesta y considerando consenso, considerando  $\epsilon$  en el conjunto  $\{0.03, 0.05, 0.1, 0.3\}$ . En una segunda fila, se presenta el desempeño de la propuesta, pero sin considerar consenso.

Tabla 9.

#### Desempeño del SRG con consenso sobre recomendaciones utilizando factorización matricial y diferentes niveles de consenso, en comparación con un enfoque que no considera consenso (MAE)

Método/ $\epsilon$	0.03	0.05	0.1	0.3
SRG con SVD y consenso	0.8701	0.8794	0.9037	0.9301
SRG con SVD	0.9301			

Particularmente, la tabla 9 muestra los valores asociados a la métrica MAE, donde se evidencia que para un valor menor de  $\epsilon$  se introduce una disminución más representativa del error de la recomendación. Así, tanto para  $\epsilon=0.03$ ,  $\epsilon=0.05$ , y  $\epsilon=0.1$ , se introducen mejoras

con respecto al método base; aunque resulta necesario utilizar con cautela la configuración de  $\epsilon$  puesto que menor valor implica una mayor deformación de las predicciones inicialmente generadas por el algoritmo de recomendación. Esto podría traer implícito la disminución del grado de personalización del sistema. Por otra parte, para  $\epsilon=0.3$  no se produce ninguna mejora con respecto al método base.

Tabla 10.

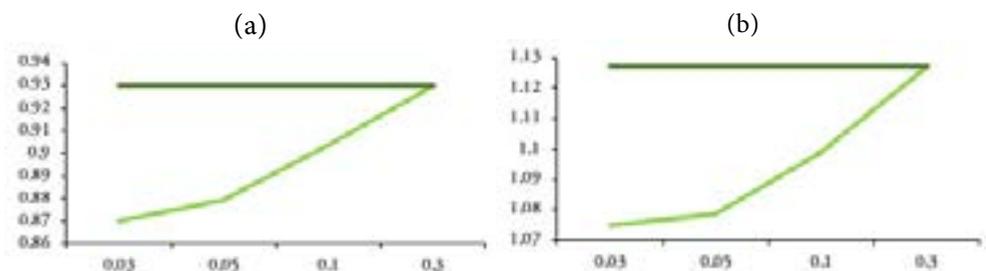
**Desempeño del SRG con consenso sobre recomendaciones utilizando factorización matricial y diferentes niveles de consenso, en comparación con un enfoque que no considera consenso (RMSE)**

Método\ $\epsilon$	0.03	0.05	0.1	0.3
SRG con SVD y consenso	1.0747	1.0786	1.0988	1.1270
SRG con SVD	1.1270			

La tabla 10 presenta los valores asociados al RMSE, y da lugar a un razonamiento análogo al obtenido con los valores del MAE. Aquí resulta interesante el hecho que entre  $\epsilon=0.03$  y  $\epsilon=0.05$  no existe una diferencia muy representativa en cuanto al desempeño. Esto podría indicar que no resulta necesario un valor muy pequeño de  $\epsilon$  para obtener resultados cercanos al óptimo, evitándose de este modo una mayor intrusividad del método de consenso de mínimo costo.

Figura 7.

**Estudio del parámetro  $\epsilon$  para la recomendación grupal basada en consenso sobre recomendaciones individuales**



Nota: La línea recta representa el desempeño del método sin considerar consenso. a) MAE. b) RMSE.

La figura 7 ilustra gráficamente este resultado, donde se puede corroborar que para valores grandes de  $\epsilon$ , la etapa de alcance de consenso no tiene ningún efecto sobre la recomendación grupal. En adición, para valores pequeños de  $\epsilon$  se logra mejorar de manera considerable la eficacia de la recomendación, aunque en algunos casos al costo de modificar los *ratings* predichos de manera más sustancial.

#### 4.4. Discusión y trabajos futuros

El desarrollo de la evaluación experimental de los métodos presentados en la sección 3, ha indicado que resulta efectiva la introducción de un método de consenso de mínimo costo dentro de un método de recomendación grupal. Se ha probado que en varios escenarios de experimentación diferentes, soportados por diversos métodos de recomendación individual (ver sección 4.1), el uso del consenso de mínimo costo logra mejorar la eficacia de la recomendación.

Esta mejora de desempeño no fue igual en todos los escenarios. En el enfoque basado en consenso sobre las preferencias (sección 3.1), en los métodos basados en vecindades usuario-usuario e ítem-ítem se vio una tendencia a acentuarse más esta mejora, mientras que en los dos métodos basados en factorización matricial esta fue más moderada. Aun así, en todos los casos se logró mejorar el método base.

Por otro lado, en el enfoque basado en consenso sobre recomendaciones individuales (sección 3.2), para las dos métricas de evaluación consideradas se logró mejorar el desempeño del método base.

Aquí es importante resaltar la importancia del parámetro  $\epsilon$ , que permite lograr un balance entre la eficacia lograda, y la intrusividad del método de consenso, asociada a la transformación requerida para lograrse el nivel de consenso deseado.

A raíz de estos resultados, se abre un grupo de trabajos futuros a desarrollar. En el futuro inmediato, resulta necesario cuantificar ese nivel de intrusividad llevado a cabo por el método de consenso. Esto permitirá caracterizar mejor el funcionamiento de la propuesta y del parámetro  $\epsilon$ , determinando cuántas preferencias de usuario fueron necesarias modificar para alcanzar el requerido consenso. Otra dirección de trabajo es el empleo de métodos de consenso de mínimo costo más avanzados, tales como el propuesto por Labella *et al.* (2020), considerando que en el presente trabajo se ha empleado uno de los métodos más básicos de esta familia.

## 5. CONCLUSIONES

El desarrollo del presente trabajo permitió llegar a las siguientes conclusiones:

- Existe una insuficiente incorporación de modelos de consenso, acoplados a un escenario de recomendación grupal.
- La incorporación de un modelo de consenso de mínimo costo dentro de varios métodos de recomendación grupal, dio lugar a una mejora en la eficacia en todos los escenarios de recomendación.

- En el caso del método basado en consenso sobre las preferencias individuales de los usuarios, los mejores resultados de eficacia fueron obtenidos para un nivel intermedio de consenso entre las preferencias de los usuarios. Por otro lado, un alto nivel de consenso no garantiza necesariamente un mejor desempeño en la recomendación.
- En el caso del método basado en consenso sobre las recomendaciones individuales generadas, para valores grandes de  $\epsilon$  se asume que ya existe consenso entre los usuarios y, por tanto, se obtiene el mismo resultado que el método base. En cambio, para valores pequeños de  $\epsilon$  el método de consenso sí introduce cambios en las recomendaciones individuales, y este cambio da lugar a una mayor eficacia en la recomendación grupal.

## Referencias

- ADOMAVICIUS, G. y TUZHILIN, A. (2005). Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions. *IEEE transactions on knowledge and data engineering*, 17(6), pp. 734-749.
- AGGARWAL, C. C. (2016). Neighborhood-based collaborative filtering. *Recommender systems*, pp. 29-70. Springer.
- AL-SHAMRI, M. Y. H. (2016). User profiling approaches for demographic recommender systems. *Knowledge-Based Systems*, 100, pp. 175-187.
- AMER-YAHIA, S., ROY, S. B., CHAWLAT, A., DAS, G. y YU, C. (2009). Group recommendation: Semantics and efficiency. *Proceedings of the VLDB Endowment*, 2(1), pp. 754-765.
- BEN-ARIEH, D. y EASTON, T. (2007). Multi-criteria group consensus under linear cost opinion elasticity. *Decision support systems*, 43(3), pp. 713-721.
- BENNETT, J. y LANNING, S. (2007). *The netflix prize*. Paper presented at the Proceedings of KDD cup and workshop.
- BURKE, R. (2002). Hybrid recommender systems: Survey and experiments. *User modeling and user-adapted interaction*, 12(4), pp. 331-370.
- CASTRO, J., YERA, R. y MARTÍNEZ, L. (2017). An empirical study of natural noise management in group recommendation systems. *Decision support systems*, 94, pp. 1-11.
- DARA, S. (2020). A survey on group recommender systems. *Journal of Intelligent Information Systems*, 54, pp. 271-295.
- DE PESSEMIER, T., DOOMS, S. y MARTENS, L. (2014). Comparison of group recommendation algorithms. *Multimedia tools and applications*, 72(3), pp. 2497-2541.
- DWIVEDI, P. y BHARADWAJ, K. K. (2015). e-Learning recommender system for a group of learners based on the unified learner profile approach. *Expert Systems*, 32(2), pp. 264-276.
- EKSTRAND, M. D., RIEDL, J. T. y KONSTAN, J. A. (2010). Collaborative filtering recommender systems. *Foundations and Trends in Human-Computer Interaction*, 4(2), pp. 81-173.
- GUNAWARDANA, A. y SHANI, G. (2015). Evaluating recommender systems. *Recommender systems handbook*, pp. 265-308. Springer.
- GUO, Y., WANG, M. y LI, X. (2017). Application of an improved Apriori algorithm in a mobile e-commerce recommendation system. *Industrial Management y Data Systems*.
- HARPER, F. M. y KONSTAN, J. A. (2015). The movielens datasets: History and context. *ACM Transactions on Interactive Intelligent Systems (TIIS)*, 5(4), pp. 1-19.

- KOREN, Y. (2008). Factorization meets the neighborhood: a multifaceted collaborative filtering model. Paper presented at the *Proceedings of the 14<sup>th</sup> ACM SIGKDD international conference on Knowledge discovery and data mining*.
- KOREN, Y., BELL, R. y VOLINSKY, C. (2009). Matrix factorization techniques for recommender systems. *Computer*, 42(8), pp. 30-37.
- LABELLA, Á., LIU, H., RODRÍGUEZ, R. M. y MARTINEZ, L. (2020). A cost consensus metric for consensus reaching processes based on a comprehensive minimum cost model. *European Journal of Operational Research*, 281(2), pp. 316-331.
- LOPS, P., DE GEMMIS, M. y SEMERARO, G. (2011). Content-based recommender systems: State of the art and trends. *Recommender systems handbook*, pp. 73-105.
- MASTHOFF, J. (2004). Group modeling: Selecting a sequence of television items to suit a group of viewers. *Personalized digital television*, pp. 93-141. Springer.
- PALOMARES, I., ESTRELLA, F., MARTÍNEZ, L. y HERRERA, F. (2014). Consensus under a fuzzy context: Taxonomy, analysis framework AFRYCA and experimental case of study. *Information Fusion*, 20(15), pp. 252-271.
- RESNICK, P., IACOVOU, N., SUCHAK, M., BERGSTROM, P. y RIEDL, J. (1994). GroupLens: An open architecture for collaborative filtering of netnews. Paper presented at the *Proceedings of the 1994 ACM conference on Computer supported cooperative work*.
- SARWAR, B., KARYPIS, G., KONSTAN, J. y RIEDL, J. (2001). Item-based collaborative filtering recommendation algorithms. Paper presented at the *Proceedings of the 10<sup>th</sup> international conference on World Wide Web*.
- SEN, A. (1986). Social choice theory. *Handbook of mathematical economics*, 3, pp. 1073-1181.
- TRAN, T. N. T., ATAS, M., FELFERNIG, A. y STETTINGER, M. (2018). An overview of recommender systems in the healthy food domain. *Journal of Intelligent Information Systems*, 50(3), pp. 501-526.
- YERA, R., ALZHRANI, A. A. y MARTÍNEZ, L. (2019). A food recommender system considering nutritional information and user preferences. *IEEE Access*, 7, 96695-96711.
- YERA, R. y MARTÍNEZ, L. (2017a). Fuzzy tools in recommender systems: A survey. *International Journal of Computational Intelligence Systems*, 10(1), pp. 776-803.
- YERA, R. y MARTÍNEZ, L. (2017b). A recommendation approach for programming online judges supported by data preprocessing techniques. *Applied Intelligence*, 47(2), pp. 277-290.



## CAPÍTULO IV

## Retos de la adopción de los nuevos sistemas de recomendación basados en inteligencia artificial

Daniel Belanche

Carlos Flavián

Este trabajo centra la atención en la incorporación progresiva de distintos tipos de aplicaciones basadas en inteligencia artificial para la prestación de servicios en el contexto financiero. Por un lado, los asistentes virtuales que responden a preguntas de los usuarios están suponiendo una verdadera revolución en la prestación de servicios, facilitando su automatización y estandarización. La creciente digitalización de los servicios financieros constituye un caldo de cultivo especialmente adecuado para la introducción de estos nuevos sistemas de interacción con el cliente a través de la voz. No obstante, para garantizar mayores tasas de éxito en la adopción de este tipo de servicios, resulta necesario prestar atención a tres grandes bloques de factores que deberían condicionar el desarrollo de estos asistentes virtuales: 1. Las particularidades del diseño del asistente virtual; 2. Las particularidades del usuario al que va dirigido y 3. Las particularidades del servicio prestado.

Por otro lado, este trabajo centra la atención en la progresiva introducción de *robo-advisors*, sistemas basados en la inteligencia artificial que van más allá del asesoramiento de inversiones en carteras de inversión, al encargarse de la gestión automatizada de las operaciones de compra y venta. Aunque los *robo-advisors* presentan diferentes ventajas para los clientes, es necesario un mayor conocimiento de las motivaciones de los usuarios y de las barreras que están impidiendo la adopción multitudinaria de estos servicios. Al analizar la adopción de los *robo-advisors* resulta especialmente importante destacar el papel que desempeñan las propias actitudes de los clientes y de su entorno social, así como su grado de preparación tecnológica y las distintas dimensiones que lo integran. Un análisis detallado puede ser la base para el desarrollo de interesantes implicaciones para la gestión.

El trabajo ofrece un decálogo de conclusiones que reflejan el creciente uso de las nuevas tecnologías para la automatización de los servicios financieros, describe las cuestiones que deben tenerse presente en su desarrollo y sugiere diversas recomendaciones para lograr una implantación más rápida y eficaz de los nuevos sistemas de servicios basados en inteligencia artificial.

*Palabras clave:* *robo-advisors*, servicios financieros, asistentes virtuales inteligentes, inteligencia artificial.

## 1. INTRODUCCIÓN

Durante las últimas décadas, la forma en la cual se prestan los servicios a los consumidores ha evolucionado de forma extraordinaria en todos los sectores de actividad. De hecho, no hace muchos años todos los clientes que se dirigían a cualquier establecimiento eran directamente atendidos por un empleado que trataba de satisfacer sus necesidades de forma personal. La búsqueda de ahorros en costes, condujeron a una progresiva generalización de los sistemas de autoservicio. Hoy en día la tecnología ya permite ofrecer un servicio más personalizado a través de los diferentes sistemas basados en la inteligencia artificial. Estos cambios se están produciendo en todo tipo de contextos, como la distribución comercial, el sector turístico, la hostelería e incluso en el sector financiero. Al igual que la atención personal de la ventanilla bancaria, fue sustituida progresivamente por los servicios prestados a través de cajeros automáticos, algunos de estos servicios están siendo prestados ya por diversas aplicaciones móviles u otros sistemas de recomendación basados en inteligencia artificial.

Ante la progresiva automatización del servicio a través de la inteligencia artificial, este capítulo trata de profundizar en dos tecnologías de creciente implantación en el sector servicios en general y en el sector financiero en particular. Concretamente, se analizan los asistentes virtuales inteligentes que actúan como agentes e interactúan directamente con clientes a través de la voz y los *robo-advisors* o asesores financieros automatizados que gestionan carteras de inversión a lo largo del tiempo sin apenas intervención humana. Las entidades bancarias están adoptando estas innovaciones tecnológicas con el objetivo de aumentar su productividad y eficiencia (Belanche, Casaló y Flavián, 2019). Sin embargo, la implementación de estas tecnologías disruptivas supone un verdadero reto puesto que son utilizadas en tareas habitualmente realizadas por empleados. Las características propias de la tecnología suponen mayores capacidades en algunas tareas (por ejemplo, capacidad analítica, uso de varios idiomas, accesibilidad cualquier día y a cualquier hora), pero también presentan barreras en otros aspectos (por ejemplo, falta de afecto y trato personal, rechazo por parte de algunos clientes).

Este capítulo permite conocer y comprender estas particularidades con el propósito de lograr una implementación exitosa basada en la adopción de estas tecnologías por parte de un gran espectro de clientes. En un contexto de gran competencia como el sector bancario, los avances tecnológicos suponen una fuente de ventaja competitiva para lograr una mayor rentabilidad. En esta carrera por conseguir ser pioneros en el lanzamiento y consolidación en el mercado de este tipo de servicios basados en la tecnología, este trabajo analiza el papel que los asistentes virtuales y los *robo-advisors* están llamados a desempeñar en el medio plazo para así avanzar en los retos y oportunidades del sector.

## 2. LOS ASISTENTES VIRTUALES INTELIGENTES

### 2.1. Popularidad y particularidades de los asistentes virtuales

En la actualidad existe un amplio abanico de asistentes virtuales y son conocidos con muy distintas denominaciones como asistentes virtuales inteligentes, asistentes persona-

les inteligentes, agentes conversacionales o los asistentes de voz que tanto se han popularizado durante los últimos años (por ejemplo, Alexa de Amazon; Google Assistant de Google; Cortana de Microsoft; Siri de Apple; Bixby de Samsung; Celia de Huawei; etc.). En general, al margen de los matices que permite diferenciarlos, todos ellos se caracterizan por ser sistemas que permiten interactuar con el usuario respondiendo a comandos, imágenes, preguntas escritas o dictadas por voz por parte del usuario. Estos sistemas pueden responder de forma escrita, por voz o ejecutando distintas acciones (por ejemplo, programando una alarma, realizando una llamada, buscando una canción o un vídeo, ofreciendo información, apagando la luz o la televisión, etc.). Los asistentes virtuales presentan un desarrollo más avanzado y ofrecen mayores posibilidades de interacción que los originales *chatbots* que son capaces de responder únicamente por escrito a una batería de preguntas frecuentes de los usuarios (el término “bot” se deriva de robot).

Sin embargo, gracias a los espectaculares avances realizados recientemente por los sistemas de procesamiento de lenguaje natural se están popularizando los asistentes virtuales por voz. Este tipo de asistentes no siempre precisan de una pantalla y permiten una interacción con las personas mucho más natural a través de la voz. Las personas pueden interactuar con ellos a través de comandos o entradas de voz que permiten realizar distintas tareas como la búsqueda de información, productos o servicios, realizar compras, gestionar consultas e interactuar con otros objetos también conectados a Internet, para realizar distintas funciones. Por ejemplo, en el hogar, los asistentes de voz como Alexa son capaces de controlar el funcionamiento de las luces, alarmas o una amplia variedad de electrodomésticos (Home Connnect, 2021). Además, la gran capacidad de procesamiento de información de estos sistemas combinada con los sistemas de *machine learning* permite a estos dispositivos aprender las preferencias del usuario con el paso del tiempo y personalizar la forma en la que interactúan con cada usuario.

Todos estos avances también se están incorporando progresivamente a múltiples industrias como la del automóvil. De hecho, algunas marcas de automóviles ya incorporan en sus vehículos sistemas de inteligencia artificial que no solo permiten interactuar de múltiples formas con el teléfono móvil inteligente del usuario, sino que también permiten realizar distintas funciones como subir o bajar las ventanillas, asegurar las puertas, regular la velocidad del vehículo, mantener la dirección (Capgemini, 2019) en una progresiva automatización de diferentes tareas que permiten incluso la conducción autónoma del vehículo en determinados entornos.

## 2.2. Los asistentes virtuales en el sector servicios

La posibilidad de interactuar con el usuario de forma más natural a través de la voz, la mayor capacidad de procesamiento de los sistemas que permite a los asistentes responder a un mayor número y tipo de preguntas y la posibilidad de desarrollar diferentes acciones, ha abierto unas posibilidades de interacción con los usuarios extraordinaria. Todo ello, está motivando una creciente proliferación de asistentes virtuales en la prestación de servicios

en general y en el ámbito comercial en particular. No obstante, parece claro que todavía nos encontramos en una fase embrionaria de la introducción de asistentes virtuales. De hecho, parece razonable que con la generalización de las conexiones de cualquier dispositivo a Internet a través de la red 5G, muy probablemente los manuales de usuario de cualquier dispositivo serán reemplazados por asistentes virtuales que expliquen de forma más interactiva e intuitiva sus posibles funciones, la forma de utilizarlos, como programarlos, etcétera.

Según Statista (2021a) en 2020 había en el mundo alrededor de 4.200 millones de asistentes virtuales y se estima que su número se multiplicará por dos en 2024 superando los 8.400 millones. Paralelamente al número de asistentes, el tamaño del mercado también ha crecido de forma espectacular durante los últimos años. De hecho, se estima que el mercado está creciendo de los 1.939 millones de dólares norteamericanos en 2016 hasta los 15.792 millones en 2021 (Statista, 2020).

Cada vez es mayor el número de usuarios familiarizados con este tipo de asistentes virtuales. De hecho, de una muestra global de más de 12.000 usuarios (Capgemini, 2019), el 74 % había utilizado los asistentes de voz o chat para buscar información, comprar productos y servicios, crear listas de compra o chequear la situación de un pedido; el 58 % lo había utilizado para escuchar música, chequear direcciones, reservar apartamentos o coches y el 53 % lo había utilizado para obtener información sobre productos bancarios o seguros, chequear el balance de la cuenta, pagar facturas o realizar transferencias.

Son muchos los beneficios percibidos por los usuarios respecto a estos asistentes virtuales. De hecho, en un estudio realizado en Estados Unidos (Nae, 2018), el 59 % de los entrevistados destacó la mayor conveniencia de los asistentes virtuales para la vida diaria, el 40 % resaltó el menor tiempo que pasamos frente a una pantalla, las sugerencias que ofrecen para comprar productos y servicios (39 %) y el menor tiempo que debemos esperar cuando contactamos con un servicio de atención telefónica (28 %). Por el contrario, también es cierto que el creciente uso de los asistentes virtuales tiene asociados aspectos negativos como la mayor dificultad para contactar con otras personas (indicado por el 50 % de los participantes en el mismo estudio), la falta de personalización en el trato de la vida diaria (50 %), los malentendidos en las relaciones (39 %) o el mayor volumen de publicidad recibida (30 %).

### 2.3. Asistentes virtuales en el contexto financiero

No cabe duda de que la crisis sanitaria generada por COVID-19 ha influido de forma determinante en la digitalización de la sociedad y el sector financiero no ha permanecido ajeno a este fenómeno. De hecho, los cambios experimentados entre febrero y agosto de 2020 han sido muy notables: los usuarios que utilizaban la banca *online* crecieron del 49 % al 57 %; los usuarios de la banca móvil pasaron de representar un 47 % a un 55 % y los usuarios que habían interactuando con *chatbots* crecieron del 15 % al 21 % (Capgemini, 2020a). En esta misma línea podríamos ver cómo nuevos fenómenos como la plataforma para transacciones entre iguales bizum han alcanzado una gran penetración en el mercado. De hecho, desde que

apareció la aplicación, en España la han utilizado más de 15 millones de personas (la tasa de penetración entre los usuarios de banca digital supera el 70 %), que han realizado más de 370 millones de operaciones por un volumen superior a los 18.000 millones de euros (Europa Press, 2021).

Si centramos la atención de forma más específica en las expectativas sobre la preferencia, los usuarios por la interacción con asistentes de voz frente a la visita a las oficinas bancarias o de seguros es clara. De hecho, el 66 % de los entrevistados creía que dentro de tres años preferiría interactuar con asistentes de voz antes que ir a la oficina para obtener información de productos (Capgemini, 2019), un porcentaje algo superior indicaba que lo preferiría para chequear el estado de la cuenta, para actualizar sus productos o servicios o para contratar nuevos productos.

Si bien los puntos de contacto automatizados están teniendo cada vez una mayor importancia en la experiencia del cliente en el contexto financiero, también es cierto que el contacto directo con los bróker o el personal de ventas sigue siendo muy importante. Esto es especialmente relevante para algunos productos como los seguros. De hecho, los seguros están diseñados de forma relativamente compleja y resultan difíciles de comprender para muchos potenciales compradores, lo cual favorece al contacto directo con el personal de ventas (Capgemini, 2020b).

En el sector de la banca y de los seguros numerosas empresas están empezando a reemplazar o complementar las habituales secciones de preguntas frecuentes (FAQs) por asistentes virtuales. Se espera que estos sistemas desempeñen un papel muy importante en la prestación de servicios financieros (Smith, 2017). De hecho, estos sistemas permiten prestar un servicio cada vez más consistente al cliente en muchas tareas repetitivas, liberar a las personas de las tareas rutinarias para que puedan concentrarse en las cuestiones más complejas o responder las preguntas del cliente en cualquier momento. Además, el almacenamiento de un mayor volumen de información en un solo sistema podría ser utilizado en sus sistemas de procesamiento de información para la relación con clientes y combinarla con el *big data*, para mejorar la interacción y, en definitiva, la eficiencia y el servicio prestado al cliente.

Un número creciente de entidades financieras españolas están incorporando sistemas de inteligencia artificial o asistentes virtuales (Melgarejo, 2021). De esta forma, CaixaBank incorpora en su App el asistente NEO que permite responder preguntas de los clientes sobre los servicios ofrecidos por la entidad. También ha creado un nuevo asistente virtual a partir de la tecnología de IBM Watson que permite resolver las dudas de los trabajadores de su red de ventas. El Banco Santander también cuenta con un asistente que asesorará a sus empleados en materia de seguros y dispone de un asistente virtual que atiende las preguntas de los clientes de forma ininterrumpida. Todos estos sistemas han sido desarrollados gracias a la apuesta decidida de algunas corporaciones públicas (por ejemplo, departamento de defensa de EE. UU.) y, sobre todo, por parte de las grandes compañías tecnológicas (por ejemplo, IBM, Google, Apple, Samsung, Amazon, Facebook, etc.) que de forma gradual se están introduciendo en el sector financiero.

## 2.4. Claves del diseño de los asistentes virtuales para la prestación de servicios

El diseño de asistentes virtuales para la prestación de servicios requiere tener en cuenta múltiples aspectos que podrían garantizar unas mayores posibilidades de éxito y aceptación por parte de los clientes que deben utilizarlos. La aceptación del servicio prestado por estos asistentes sería un paso previo para lograr la satisfacción de los clientes que permita la fidelización con el servicio prestado y, en definitiva, el éxito de esta nueva forma de prestar servicios.

Un estudio reciente clasifica en tres grandes bloques los factores que deberían tenerse en cuenta a la hora de desarrollar asistentes virtuales en el sector servicios (Belanche, Casaló y Flavián, 2020): 1) aspectos relativos al diseño del asistente virtual; 2) características del cliente al que va dirigido el servicio, y 3) particularidades del servicio prestado y del tipo de interacción. Este esquema se desarrolló tanto para los asistentes virtuales como para los robots de servicio por lo que podría ser generalizado y sensiblemente adaptado cualquier otro contexto de servicios prestados a través de inteligencia artificial. Esto podría permitirnos identificar los aspectos que podrían resultar clave para lograr el éxito en el diseño de asistentes virtuales dirigidos a la prestación de servicios en el ámbito financiero.

La tabla 1 muestra las cuestiones clave en cada uno de estos bloques y la forma en la que podrían abordarse según los estudios previos en este campo. Sin duda alguna, todas estas cuestiones merecen una importante reflexión, ya que lograr identificar las respuestas adecuadas a estas preguntas podrá ser la clave del éxito de la implementación de los asistentes virtuales en el sector servicios y en el sector bancario en particular.

Tabla 1.

### Modelo para la implementación de los asistentes virtuales en servicios

	<i>Diseño del asistente virtual</i>
1.1. ¿El asistente virtual debe tener asociada una representación gráfica (por ej. una persona, otro ser animado)? ¿Qué tipo de aspecto y voz debería tener este asistente?	Existen muchas opciones desde la ausencia de imagen hasta una imagen humana hiperrealista. El uso de diseños específicos (por ej. animal) podría estar particularmente indicado en algunos sectores (por ej. ocio). Los asistentes virtuales suelen tener voces femeninas por resultar más agradables. Pero esto puede llevar a fomentar estereotipos. El acento o la entonación utilizada también podrían ser aspectos relevantes.
1.2. ¿Los asistentes virtuales deberían informarnos de que no estamos hablando con una persona?	En algunas ocasiones los usuarios son incapaces de distinguir si están interactuando con la inteligencia artificial o con una persona (estos sistemas superan el conocido test de Turing). Se ha demostrado que en la venta de tarjetas de crédito por asistentes virtuales es más efectivo no decir que se está interactuando con la tecnología o decirlo al final del proceso.
1.3. ¿Cuál es el número óptimo de opciones de manipulación en un asistente?	Muchas opciones podrían desconcertar al usuario, pero si hay pocas podría percibirse negativamente. En algunos casos es necesario que los asistentes virtuales sean muy intuitivos, sin embargo, esto puede disminuir el grado de control que usuarios más avanzados pueden tener sobre la tecnología.

Tabla 1. (continuación)

**Modelo para la implementación de los asistentes virtuales en servicios**

<i>Diseño del asistente virtual</i>	
1.4. ¿Cuál es el grado óptimo de proactividad de los asistentes?	Una excesiva proactividad podría resultar molesta, pero a veces puede resultar oportuna. Al igual que ocurre con los empleados, es importante que la inteligencia artificial identifique en qué momentos mostrar una actitud más proactiva o reactiva.
1.5. La empatía es esencial en los encuentros de servicio, ¿los asistentes virtuales deberían transmitir emociones?	Aunque a día de hoy la tecnología es incapaz de tener emociones, sí que puede identificar emociones en el usuario a través de su tono de voz o escritura y actuar consecuentemente transmitiendo otras emociones. El grado de afectividad necesaria podría depender del sector y tipo de tarea.
1.6. ¿Los asistentes deben ser siempre formales o puede aceptarse cierto grado de informalidad?	Aunque la formalidad parece crucial en sectores de productos y servicios de alta implicación, cierto grado de informalidad puede reducir las barreras entre los humanos y la tecnología, particularmente en sectores donde la experiencia del usuario es más hedónica.
<i>Características de los usuarios</i>	
2.1. ¿Influye la preparación tecnológica de los potenciales usuarios en su aceptación?	Los usuarios difieren en gran medida en la forma en la que abordan una tecnología disruptiva. La sección de este capítulo dedicada a la preparación tecnológica aclara algunas de estas cuestiones.
2.2. ¿Influye la edad de las personas?	En general, las personas mayores son más reacias al uso de las nuevas tecnologías. Sin embargo, la ayuda prestada por los asistentes virtuales también podría ser particularmente útil para las personas mayores o con menores capacidades.
2.3. ¿Influye el género del usuario?	Aunque la literatura previa sugiere que los hombres son más propensos a adoptar las nuevas tecnologías, las mujeres también pueden presentar elevadas tasas de adopción dado el carácter social y utilitario de los asistentes virtuales.
2.4. ¿Influye la cultura o nacionalidad?	Las diferencias culturales entre países podrían determinar el grado de aceptación. Aunque países como Japón parecen más propensos al uso de este tipo de tecnología, lo cierto es que podría depender de los rasgos particulares de cada cultura (por ejemplo, el grado de aversión a la incertidumbre).
2.5. ¿Influyen los rasgos de la personalidad, los valores y los estilos de vida?	Aspectos como el mayor o menor grado de extroversión, innovación, orientación a los logros, etc. pueden ser relevantes. Por ejemplo, las personas más introvertidas suelen preferir inteligencia artificial más mecánica y menos humana.
2.6. ¿Influye el vínculo del cliente con la organización y sus expectativas?	Diversos aspectos del perfil del cliente como la experiencia, la fidelidad, etc. también pueden afectar a la aceptación de este tipo de asistentes virtuales. Por ejemplo, clientes con una mayor vinculación con la empresa pueden exigir un trato personal, mientras que nuevos clientes pueden sentirse atraídos por este nuevo canal.

Tabla 1. (continuación)

**Modelo para la implementación de los asistentes virtuales en servicios**

<i>Características del tipo de interacción en el servicio</i>	
3.1. ¿Qué volumen de información debe ofrecerse al usuario?	Los asistentes virtuales suelen emplearse como una fuente de información y resolución de dudas. Sin embargo, más allá de su labor asistencial, cada vez es más habitual que realicen tareas diversas, tales como la automatización de procesos más complejos o la venta directa.
3.2. ¿En qué medida debe participar el usuario en la toma de decisiones?	De forma análoga al grado de proactividad de los asistentes virtuales, el cliente puede tener una mayor vinculación y participación en el proceso. En productos y servicios con mayor implicación o incertidumbre los clientes podrían desear la interacción con un empleado humano.
3.3. ¿Cómo deben abordarse los fallos o las quejas con los asistentes virtuales?	Los asistentes virtuales también son utilizados en tareas de atención al cliente. Sin embargo, cuando esta tecnología falla es necesaria la participación de un empleado. No es conveniente forzar al cliente a depender de un único canal de interacción, particularmente cuando este medio le resulta problemático.
3.4. ¿En qué medida debe influir en las particularidades del producto o del servicio a la hora de diseñar el asistente virtual?	La venta de productos más concretos y tangibles representa una oportunidad para el empleo de asistentes virtuales. No obstante, el verdadero valor añadido de estos asistentes está en su capacidad de llevar a cabo interacciones en contextos más complejos y adaptados al cliente, como es el caso de los servicios.
3.5. ¿Cómo deben adaptarse los asistentes virtuales según el carácter transaccional o relacional de la interacción de servicio?	Normalmente los clientes más motivados por el valor utilitario o transaccional no tendrán objeción en utilizar asistentes virtuales. Sin embargo, los clientes centrados en el valor relacional de la interacción, es decir en crear un vínculo con el empleado o la entidad, tratarán de evitar el uso de agentes tecnológicos.
3.6. ¿Cuál es el punto óptimo en la colaboración-sustitución de las personas por los asistentes virtuales?	Los asistentes virtuales no han de suponer el reemplazo de los empleados. De hecho, pueden especializarse en tareas más mecánicas o repetitivas y liberar a los empleados para tareas más complejas. En definitiva, agentes virtuales y humanos se complementan, especializándose cada uno de ellos en aquellas tareas en las que son más eficientes.

Fuente: Elaboración propia en base a Belanche *et al.* (2020).

### 3. LOS ROBO-ADVISORS O ASESORES FINANCIEROS AUTOMATIZADOS

#### 3.1. Principales características de los *robo-advisors*

Un caso especialmente interesante para comprender el impacto que la aplicación de la inteligencia artificial puede llegar a tener en los servicios financieros es la introducción de los *robo-advisors*. Estos *robo-advisors* son verdaderos asistentes virtuales de última generación.

Etimológicamente la palabra *robo-advisor* procede de la combinación del término robot y asesor (*advisor*), si bien la apariencia física para el usuario no es la de un humanoide sino la

de una web o aplicación móvil. El uso de esta palabra *robo-advisor* se ha generalizado rápidamente, ya que permite reflejar de forma intuitiva el servicio prestado. Se trata de un servicio de asesoramiento de carteras de inversión, pero que también incluye la gestión automatizada de las operaciones de compra y venta de distintos tipos de activos financieros. Estas aplicaciones se basan en una inteligencia artificial avanzada que, a través de distintos algoritmos permite automatizar los procesos de compra y venta de la cartera según las preferencias del usuario. Además, los complejos algoritmos de *machine learning* utilizados por estos sistemas, les permiten aprender a invertir y ser capaces de automatizar los procesos para equilibrar los activos de la cartera según el perfil inversor de cada cliente considerando diferentes parámetros (por ejemplo, tipos de inversiones, nivel de riesgo asumible, liquidez deseada, etc.).

Al contrario de lo que suele ser habitual en robots u otros sistemas automatizados, que fundamentalmente se basan en una inteligencia artificial mecánica, estos nuevos servicios financieros están basados en una inteligencia artificial analítica. La inteligencia artificial analítica incluye la habilidad de procesar información y la capacidad de aprender para resolver futuros problemas (Huang y Rust, 2018).

Los primeros *robo-advisors* surgieron en Estados Unidos durante la crisis del 2008 y llegaron a España unos años más tarde (por ejemplo, Feelcapital en 2014; Indexa en 2015; Finizens en 2016; Finabest, Micappital y Finletic en 2017; Openbank en 2018).

El uso de *robo-advisors* se ha popularizado gracias a las importantes ventajas que tienen asociadas:

- Facilidad de uso de las interfaces y en la gestión de las operaciones financieras.
- Menores comisiones asociadas a estos sistemas de asesoramiento, ya que la automatización del servicio reduce los costes de personal.
- La posibilidad de acceso por parte de pequeños capitales a estos nuevos sistemas de inversión, lo cual podría suponer la democratización de las inversiones financieras.
- Asesoramiento inicial de los expertos a la hora de configurar la cartera inicial, lo cual facilita la entrada a nuevos inversores con escasa experiencia previa.
- Las grandes posibilidades de diversificación incluso en el caso de pequeñas carteras. Al estar automatizados los procesos, una misma cartera podría tener cientos de posiciones distintas.
- La accesibilidad *online* a través de diferentes tipos de dispositivos conectados a Internet.
- El seguimiento de las inversiones 24/7 a través de una vinculación *online* dinámica. Esto permite una gran capacidad de reacción ante los cambios inesperados en el mercado.
- Al automatizar los procesos, se evitan los sesgos emocionales asociados a las personas.

### 3.2. Retos para la adopción de los *robo-advisors* por parte de los usuarios

A pesar de que la tasa actual de usuarios de *robo-advisors* es relativamente reducida (Jung *et al.*, 2018b; Belanche *et al.*, 2019), se estima que en 2025 casi medio millón de usuarios confíen en los *robot-advisors* para gestionar sus inversiones en el mercado financiero (Statista, 2021b).

A finales de 2021 los *robo-advisors* gestionan activos por un valor de 1.171.702 millones de euros (Statista, 2021b). Esta misma fuente prevé que la tasa anual de crecimiento esperada entre 2021-2025 se sitúe en torno al 18,29 % y el volumen de activos gestionado en 2025 alcance los 2.293.783 millones de euros.

Frecuentemente, se presentan los *robo-advisors* como una nueva tecnología que va a permitir la democratización de los mercados financieros (Dayan, 2019), ya que están permitiendo la entrada de pequeños inversores, con escasa experiencia previa y limitados conocimientos financieros. De hecho, desde la perspectiva del consumidor, la entrada en este mercado a través de un *robo-advisor* es algo relativamente simple y práctico. Solamente es necesario dedicar unos minutos a rellenar un breve cuestionario sobre las preferencias de inversión. Estos datos son utilizados por el sistema para evaluar el grado de propensión o aversión al riesgo del usuario, sus expectativas de beneficio, el horizonte temporal de la inversión, etc. (Belanche, Casaló y Flavián, 2019). Con esta breve información y el empleo de la inteligencia artificial analítica, el sistema es capaz de realizar una propuesta inicial de inversión ajustada a las preferencias del usuario y gestionarla a lo largo del tiempo.

Este nuevo sistema de inversión, al ser relativamente simple y particularmente conveniente para el usuario, había generado un notable entusiasmo en el sistema financiero respecto al crecimiento previsible de esta nueva alternativa de inversión. No obstante, algunos autores han puesto de manifiesto que los inversores no están mostrando tanto entusiasmo respecto a los *robo-advisors* como las entidades financieras que los estaban promocionando (Jung *et al.*, 2018b). Probablemente, las entidades financieras no eran conscientes de que buena parte de los usuarios potenciales no estaban preparados para adoptar estos sistemas basados en inteligencia artificial analítica (Flavián *et al.*, 2021) o de algunas limitaciones que la literatura científica en el área ya había asociado a los *robo-advisors*. De hecho, Jung *et al.* (2019) criticaron el escaso contacto personal y la menor reglamentación exigida para operar en el mercado financiero. Tertilt y Scholz (2018) destacaron que la falta del contacto personal entre el inversor y el asesor debería requerir que los usuarios potenciales completaran cuestionarios mucho más exhaustivos antes de empezar a operar y Ji (2017) destacó la necesidad de que las empresas ofreciesen una información más transparente respecto a cómo toman las decisiones estos sistemas automatizados o cómo gestionan los posibles conflictos de intereses que pudieran surgir.

En el mercado financiero español, el optimismo inicial asociado a la proliferación de los *robo-advisors*, se está viendo limitado por una cierta ralentización del ritmo de crecimiento del volumen de negocio real. De hecho, las entidades financieras que más decididamente han

apostado por invertir a través de estos nuevos sistemas, acumulaban en 2020 unas pérdidas por valor de 10 millones de euros como consecuencia de las inversiones realizadas desde el inicio de sus operaciones (Vector, 2020). A pesar de que el coste medio con la gestión de los *robo-advisors* es claramente inferior (0,8 % frente al 1,94 % del coste con gestión activa por empleados), la gran mayoría de los clientes potenciales siguen sin utilizar este nuevo sistema de inversión y las tasas de penetración actuales siguen siendo reducidas. En Estados Unidos el crecimiento de usuarios en algunos segmentos de población sigue sin despegar. Entre 2019 y 2020 los *baby boomers* que utilizaron estas formas de inversión pasaron del 7,2 % al 7,8 %, aunque los *millennials*, sí mostraron un crecimiento algo mayor en la tasa de aceptación pasando del 13,6 % al 16,4 % (Vector, 2020).

En definitiva, las limitadas tasas de crecimiento real que está experimentando este sector de actividad frente a las espectaculares previsiones iniciales, pone de manifiesto la necesidad de analizar con más detalle los principales precursores y frenos que podrían motivar o desmotivar a los inversores a adoptar esta nueva tecnología. En este sentido, podríamos centrar la atención en un reciente estudio realizado por Belanche, Casaló y Flavián (2019).

### 3.3. Factores determinantes de la adopción de *robo-advisors*

El estudio de Belanche, Casaló y Flavián (2019) analiza la decisión de adoptar *robo-advisors* por parte de los potenciales usuarios de Reino Unido, Estados Unidos y Portugal. En el estudio se consideran un espectro amplio de clientes en cada país y se incluyen variables clave identificadas como precursores de la adopción de nuevas tecnologías en modelos teóricos de comportamiento del consumidor como el modelo de aceptación tecnológica. Estos modelos clásicos analizan el papel que desempeñan aspectos como la actitud del usuario hacia la nueva tecnología, la utilidad percibida o su facilidad de uso, así como las posibles influencias sociales generadas por las normas subjetivas. El trabajo también evalúa el papel moderador que podría desempeñar en este proceso la familiaridad del usuario con el uso de este u otros sistemas automatizados, o factores demográficos básicos de segmentación como el género, la edad o incluso la cultura.

Los resultados de este estudio confirman que la intención de uso de los *robo-advisors* está fuertemente condicionada por la propia actitud de los usuarios hacia esa tecnología y por la norma subjetiva (es decir, la percepción acerca de la opinión que los demás tienen hacia estos sistemas). Estos resultados son coherentes con los hallazgos realizados en los modelos tradicionales que han sido desarrollados previamente para explicar el comportamiento de adopción de otras tecnologías como la banca *online*. En definitiva, la intención de adoptar los *robo-advisors* no solo depende de la actitud del propio inversor hacia ese tipo de herramientas, sino que también se encuentra fuertemente condicionada por las expectativas del resto de personas que le rodean hacia el uso de dichos *robo-advisors*. Sin embargo, la utilidad percibida de los *robo-advisors* no es suficiente para generar su adopción y no ejerce un efecto significativo sobre la intención. El efecto positivo de la utilidad percibida en sobreintención

de uso solamente se logra cuando también existe una actitud favorable hacia su uso. Es decir, el usuario no solo utilizaría los *robo-advisors* por el valor añadido que genera, sino que tiene que estar convencido y predispuesto hacia el uso de esta tecnología.

Otro interesante resultado pone de manifiesto que la mayor familiaridad de los usuarios con la tecnología, reduce la influencia de la norma subjetiva sobre la intención de uso de estas tecnologías. Este aspecto resulta razonable y pone de manifiesto que los usuarios con mayores conocimientos y por tanto más familiarizados con la tecnología, confían más en sus propias percepciones. Sin embargo, aquellos que la perciben como algo más lejano, valoran mucho más la opinión de terceros antes de adoptar el uso de esta nueva tecnología. Estos resultados son coherentes con los hallazgos realizados por otros autores en tecnologías previas como Venkatesh y Davis (2000).

Los resultados de este estudio no permiten constatar la existencia de diferencias significativas por edad o por género en la intención de adoptar *robo-advisors*. Por tanto, no podemos concluir la existencia de una brecha tecnológica relacionada con la edad, ni la existencia de distintas intenciones comportamentales como consecuencia del género de los inversores. No obstante, sí se encuentran diferencias culturales significativas que puedan estar afectando a este comportamiento en los tres países de los cuales procede la muestra. De esta forma, en el caso de los usuarios portugueses, la influencia de la actitud sobre la intención es claramente superior que en el caso de los usuarios de Reino Unido y Estados Unidos. La explicación de este interesante matiz podría venir dada por las diferencias existentes en las dimensiones culturales entre países detalladamente investigadas por Hofstede (2018). En concreto, en Portugal existe una mayor tendencia a evitar la incertidumbre y unos menores índices de individualismo y masculinidad. Los estudios de Hofstede (2018) mostraron que en las culturas donde más se busca evitar la incertidumbre, los individuos necesitan estar más seguros para tomar una decisión. Por tanto, la actitud ejerce una mayor influencia sobre la intención. De igual forma, tanto en Estados Unidos como en el Reino Unido, los valores asociados a la masculinidad son claramente superiores y, por tanto, las personas se encuentran más motivadas por alcanzar el éxito y su comportamiento se encuentra más condicionado por la utilidad percibida (Hofstede, 2018).

### 3.4. La preparación tecnológica de los usuarios ante los *robo-advisors*

Un estudio más reciente elaborado por Flavián *et al.* (2021) investiga hasta qué punto los clientes de entidades bancarias están preparados para adoptar una tecnología disruptiva como es el caso de los *robo-advisors*. Este estudio aplica el modelo de preparación tecnológica elaborado por Parasuraman y Colby (2015) que asume que las características de la personalidad y la forma en la que los usuarios afrontan la tecnología determinan su comportamiento hacia las mismas. Concretamente, este modelo teórico plantea que en la preparación mental de los usuarios para utilizar nuevas tecnologías existen dos principales motivadores (el optimismo y el grado de innovación) y dos inhibidores (la falta de confort y la inseguridad). La literatura previa ha comprobado la independencia de estos cuatro factores y cómo estos

varían entre diferentes usuarios. De forma complementaria, se consideró el grado de conocimiento de los *robo-advisors*, como factor adicional motivador de su adopción entre los clientes. A continuación, la tabla 2 muestra la definición de cada una de estas dimensiones según Parasuraman y Colby (2015), las hipótesis de partida o posible influencia sobre la adopción y el resultado de la investigación de Flavián *et al.* (2021).

Tabla 2.

### Estudio de las dimensiones de preparación tecnológica de los usuarios potenciales de *robo-advisors* y su influencia sobre la adopción

<i>Dimensión de la preparación tecnológica</i>	<i>Definición</i>	<i>Hipótesis de partida</i>	<i>Resultado obtenido en el estudio empírico</i>
Optimismo	Opinión positiva de la tecnología y creencia de que ofrece un mayor control, flexibilidad o eficiencia en la vida del cliente	Influencia positiva sobre la aceptación, mejora la voluntad de uso de la tecnología por ser percibida como funcional y confiable, ignorando posibles aspectos negativos	El optimismo tecnológico incrementa la intención de uso de los <i>robo-advisors</i>
Innovación	Tendencia del usuario de ser el pionero en el uso de la tecnología y convertirse en un líder de opinión respecto a su manejo	Los clientes más innovadores tienden a tener una mayor amplitud de miras y muestran un mayor atrevimiento ante retos en el uso de la tecnología	La innovación incrementa levemente la intención de uso de <i>robo-advisor</i> , si bien este efecto no es estadísticamente significativo
Falta de confort	Falta de control sobre la tecnología y sentimiento de agobio por la complejidad de su uso	Los clientes que no se sienten cómodos usando la tecnología la perciben como complicada, se sienten superados y prefieren no usarla porque creen que no satisfará sus necesidades	Sorprendentemente y, en contra de la predicción, la falta de confort tecnológico incrementa en lugar de reducir la intención de uso de los <i>robo-advisors</i>
Inseguridad	Falta de confianza en la tecnología y escepticismo sobre las capacidades de la tecnología	La inseguridad tecnológica provoca que los clientes no utilicen la tecnología para así evitar las posibles consecuencias negativas de su uso	La inseguridad tecnológica reduce la intención de uso de los <i>robo-advisors</i>
Grado de conocimiento	Ser consciente, tener el conocimiento o haber sido informado acerca de la existencia y características de una nueva tecnología	El grado de conocimiento se asocia al uso derivado de la notoriedad de la tecnología y su capacidad de ser identificada de forma espontánea o sugerida	Un mayor grado de conocimiento incrementa la intención de uso de los <i>robo-advisors</i>

Fuente: Elaboración propia en base a Flavián *et al.* (2021).

Los resultados del estudio empírico en el que participaron más de 400 clientes potenciales norteamericanos de *robo-advisors* muestra unos hallazgos interesantes. Conforme a las hipótesis teóricas y en línea con estudios realizados sobre el uso de tecnologías previas en servicios financieros, el optimismo incrementa, mientras que la inseguridad reduce la intención de uso de los *robo-advisors*. Sin embargo, la innovación de los usuarios no llega a tener un efecto positivo estadísticamente significativo. Estos resultados sugieren que las estrategias de lanzamiento y captación de clientes de *robo-advisors* deberían aprovechar, por un lado, el optimismo que algunos usuarios tienen hacia la tecnología y, por otro, la reducción de la inseguridad percibida como factor inhibidor de la adopción.

Particularmente interesante resulta el hallazgo del efecto ejercido por la falta de confort. A diferencia de tecnologías previas en las que la falta de confort tecnológico representaba una barrera para la adopción de la tecnología, en el caso de los *robo-advisors* este efecto se invierte, es decir, los usuarios que se sienten menos cómodos usando la tecnología estarían más dispuestos a utilizar los *robo-advisors*. Ese resultado singular se explica por las características particulares de la inteligencia artificial como base tecnológica de los *robo-advisors*. A diferencia de tecnologías previas que requieren que el usuario dedique un gran esfuerzo de aprendizaje para poder comprenderlas y utilizarlas, los *robo-advisors* gestionan la cartera de inversión de forma automática, sin apenas interacción por parte del usuario. De esta forma, el usuario deja de desempeñar un papel tan activo en el manejo de la tecnología, siendo este papel asumido por la inteligencia artificial. Así pues, los *robo-advisors* serían particularmente adecuados para usuarios menos hábiles en el manejo de la tecnología que evitarían así la necesidad de gestionar la cartera por sí mismos, delegando esta tarea en la inteligencia artificial.

Por último, conforme a las predicciones, el grado de conocimiento de los *robo-advisors* tiene un efecto positivo sobre la adopción de los mismos. Un análisis en profundidad de este resultado muestra que los usuarios que se han informado acerca de los *robo-advisors* buscando información por ellos mismos, a través de una entidad bancaria o a través de otros clientes tienden a mostrar un mayor grado de adopción de esta tecnología. Por el contrario, aquellos que conocen los *robo-advisors* a través de la publicidad, las noticias u otros medios, presentan una menor intención de uso. De estos resultados se derivan interesantes implicaciones para la gestión y podrían orientar la información proporcionada por las entidades financieras de forma directa o las campañas de atracción de nuevos clientes a través de otros ya existentes. Todo ello podría permitir una mayor aceptación e incrementar las tasas de penetración en el mercado.

#### 4. CONCLUSIONES

Este trabajo ha centrado la atención en el análisis de las recientes aplicaciones basadas en inteligencia artificial para la prestación de servicios y más específicamente en su creciente influencia en el mercado de servicios financieros. En general, el uso de asistentes virtuales está creciendo de forma notable y particularmente los *robo-advisors* pueden introducir cambios

notables en el mercado de servicios financieros. Las principales conclusiones que pueden derivarse de este trabajo podrían sintetizarse en los diez puntos siguientes:

- La automatización de servicios continúa en verdadero auge motivado por las nuevas tecnologías con base en la inteligencia artificial.
- Las entidades bancarias están adoptando estas innovaciones para aumentar su productividad y eficiencia, con el objetivo de lograr una ventaja competitiva en un mercado en crecimiento dentro del sector.
- Las tecnologías basadas en la inteligencia artificial que reemplazan a los empleados en diferentes tareas, tales como los asistentes virtuales por voz o los *robo-advisors* (asesores financieros automatizados) presentan características diferenciales que suponen un reto en su implementación y adopción por parte de los usuarios.
- Los asistentes virtuales por voz se están popularizando en diversos contextos y suponen un canal de comunicación más conveniente gracias a su continua mejora y progresiva adaptación a las necesidades de los clientes.
- El diseño de estos asistentes virtuales ha de tener en cuenta una gran variedad de aspectos, tales como la apariencia física, la notificación de estar interactuando con un agente virtual o el grado de proactividad y de formalidad en la interacción.
- El éxito de estos asistentes virtuales depende de la adaptación del diseño a las características de los usuarios (por ejemplo, edad, género, personalidad) y a las particularidades de la interacción en cada contexto (por ejemplo, volumen de información, carácter transaccional o relacional, fallos del servicio, etc.).
- Los *robo-advisor* son capaces de ofrecer un servicio de asesoramiento competente en unas condiciones económicas y de accesibilidad que resultan más favorables para los clientes.
- La adopción de los *robo-advisors* depende en gran medida de la actitud de los usuarios hacia la tecnología, y de las opiniones de las personas del entorno del usuario, así como de la utilidad percibida. El efecto de estas variables es ligeramente diferente en cada país.
- La preparación tecnológica de los usuarios es fundamental para la adopción de los *robo-advisors*. Los usuarios más optimistas y seguros hacia la tecnología son los clientes que más frecuentemente los adoptan. Sorprendentemente, los usuarios que se sienten menos confortables con el uso de las tecnologías, prefieren a los *robo-advisors* porque les permite simplificar estas tareas y operar con carteras de inversión sin necesidad de dominar la tecnología.
- Un mayor conocimiento acerca de los *robo-advisors* fomenta su adopción entre los clientes, siendo los canales de comunicación más eficaces la propia entidad bancaria,

la búsqueda de información por parte del cliente y la información proporcionada al cliente por otros usuarios.

## Referencias

- BELANCHE, D., CASALÓ, L. V. y FLAVIÁN, C. (2019). Artificial Intelligence in FinTech: understanding robo-advisors adoption among customers. *Industrial Management & Data Systems*, 119(7), pp. 1411-1430.
- BELANCHE, D., CASALÓ, L. V., FLAVIÁN, C. y SCHEPERS, J. (2020). Service robot implementation: a theoretical framework and research agenda. *The Service Industries Journal*, 40(3-4), pp. 203-225.
- BOCK, D. E., WOLTER, J. S. y FERRELL, O. C. (2020). Artificial intelligence: disrupting what we know about services. *Journal of Services Marketing*, 34(3), pp. 317-344.
- CAPGEMINI (2019). Smart talk. How organizations and consumers are embracing voice and chat assistants. Capgemini Research Institute. [https://www.capgemini.com/wp-content/uploads/2019/09/Report\\_Conversational-Interfaces-1.pdf](https://www.capgemini.com/wp-content/uploads/2019/09/Report_Conversational-Interfaces-1.pdf)
- CAPGEMINI (2020a). Pioneering intelligent banking. Capgemini Research Institute. <https://pioneering-intelligent-banking-ebook.s3.amazonaws.com/index.html>
- CAPGEMINI (2020b). COVID-19 and the financial services consumer: Supporting customers and driving engagement through the pandemic and beyond. Capgemini Research Institute. [https://www.capgemini.com/wp-content/uploads/2020/05/COVID-19-and-the-financial-services-consumer\\_V5.pdf](https://www.capgemini.com/wp-content/uploads/2020/05/COVID-19-and-the-financial-services-consumer_V5.pdf)
- DAYAN, Y. (2019). How robo-advisors are single-handedly democratizing the investing world. <https://www.moneyunder30.com/how-robo-advisors-are-single-handedlydemocratizing-the-investing-world>
- EUROPA PRESS (2021). Bizum alcanza los 15 millones de usuarios y el 70 % de penetración de clientes bancarios digitales. <https://www.europapress.es/economia/finanzas-00340/noticia-bizum-alcanza-15-millones-usuarios-70-penetracion-clientes-bancarios-digitales-20210324105858.html>
- FLAVIÁN, C., PÉREZ-RUEDA, A., BELANCHE, D. y CASALÓ, L. V. (2021). Intention to use analytical artificial intelligence (AI) in services—the effect of technology readiness and awareness. *Journal of Service Management*, en prensa.
- HOFSTEDE, G. (2018). Hofstede insights. Compare countries. <https://www.hofstede-insights.com/product/compare-countries/>
- HOME CONNECT (2021). Home Connect: electrodomésticos conectados. <https://www.home-connect.com/es/es/electrodomesticos-conectados>
- HUANG, M. H. y RUST, R. T. (2018). Artificial intelligence in service. *Journal of Service Research*, 21(2), pp. 155-172.
- Ji, M. (2017). Are robots good fiduciaries? Regulating robo-advisors under the investment advisers act of 1940. *Columbia Law Review*, 117(6), pp. 1543-1583.
- JUNG, D., DORNER, V., GLASER, F. y MORANA, S. (2018). Robo-advisory. *Business & Information Systems Engineering*, 60(1), pp. 81-86.
- JUNG, D., DORNER, V., WEINHARDT, C. y PUSMAZ, H. (2018). Designing a robo-advisor for risk-averse, low-budget consumers. *Electronic Markets*, 28(3), pp. 367-380.
- MELGAREJO, K. (2021). Inteligencia Artificial en los bancos: Chatbots en la banca. <https://kevinmeltgarejo.com/inteligencia-artificial-en-los-bancos-chatbots-en-la-banca/>
- NAE (2018). Tendencias globales para el mercado de los asistentes virtuales. Nae. <https://nae.global/es/tendencias-globales-para-el-mercado-de-los-asistentes-virtuales/>

- PARASURAMAN, A. y COLBY, C. L. (2015). An updated and streamlined technology readiness index: TRI 2.0. *Journal of Service Research*, 18(1), pp. 59-74.
- PUNTONI, S., RECZEK, R. W., GIESLER, M. y BOTTI, S. (2021). Consumers and artificial intelligence: an experiential perspective. *Journal of Marketing*, 85(1), pp. 131-151.
- SMITH, P. (2017). Westpac looks to bots after customer service upgrade. *Financial Review*, June.
- STATISTA (2020). Virtual Assistant Technology in the U.S. – Statistics y Facts. Statista. <https://www.statista.com/topics/7022/virtual-assistants-in-the-us/>
- STATISTA (2021a). Number of voice assistants in use worldwide 2019-2024. <https://www.statista.com/statistics/973815/worldwide-digital-voice-assistant-in-use/>
- STATISTA (2021b). Robo-Advisors. <https://es.statista.com/outlook/dmo/fintech/digital-investment/robo-advisors/worldwide?currency=eur>
- TERTILT, M. y SCHOLZ, P. (2018). To advise, or not to advise—how robo-advisors evaluate the risk preferences of private investors. *The Journal of Wealth Management*, 21(2), pp. 70-84.
- VECTOR (2020). El mercado de los Robo-advisors sigue sin despegar. Vector a softtek company. <https://www.vectoritcgroup.com/tech-magazine/artificial-intelligence/el-mercado-de-los-robo-advisors-sigue-sin-despegar/>
- VENKATESH, V. y DAVIS, F. (2000). A theoretical extension of the technology acceptance model: four longitudinal field studies. *Management Science*, 46(2), pp. 186-204.



## CAPÍTULO V

# Cómo conseguir tu objetivo *offline* utilizando la navegación del usuario

Jesús Romero Leguina

En este capítulo profundizamos en la creación de audiencias y su óptima activación dentro de nuestras estrategias omnicanales. Combinando la información de Google Analytics junto con el uso de técnicas de *machine learning* somos capaces de generar audiencias y cualificar aquellos usuarios de mayor valor para el negocio. Veremos cómo podemos hacer crecer los negocios integrando las ventas *offline* en nuestras estrategias digitales, gracias al uso de la tecnología y a los modelos matemáticos.

*Palabras clave: marketing omnicanal, machine learning, ventas offline.*

## 1. INTRODUCCIÓN

El concepto de *marketing* omnicanal resulta hoy en día un concepto lejano para muchas compañías. A pesar de que se lleva años hablando sobre ello y en el sector se entiende la importancia de que los canales *online* y *offline* estén conectados entre sí, las empresas y expertos de *marketing* se siguen encontrando con ciertas barreras que les impiden construir un diálogo de cooperación entre ambos.

Una de las grandes limitaciones que nos encontramos es la que trata los objetivos de conversión. Tradicionalmente, las campañas de *marketing* digital tienen como objetivo conseguir acciones en la web por parte de los usuarios, pero como veremos más adelante en este capítulo, estos no son los únicos objetivos de las compañías. Para que los negocios crezcan es importante que sus estrategias de *marketing online* persigan de una forma u otra los objetivos de conversión de la compañía independientemente de cuál sea el canal de venta.

En este capítulo, veremos cómo optimizar la estrategia de *marketing* digital para conseguir un aumento de nuestros objetivos de venta *offline*. Profundizaremos sobre todo en la parte más técnica y la metodología. Desarrollaremos el proceso de trabajo desde la recogida de datos de navegación de los usuarios, pasando por la creación de los modelos matemáticos que cualifican las probabilidades hasta la activación.

A lo largo del capítulo se usará a modo ilustrativo un caso de uso en el que realizaremos el proyecto de optimización sobre una campaña de *marketing* digital para una compañía inmobiliaria. En este contexto, se asumirá que esta compañía trabaja con el conjunto completo de las herramientas de *marketing* de Google. Se usará Google Analytics como fuente de datos, GMP (Google Ads, Search Ads 360, Display and Video 360 y Campaign Manager) para la activación y Google Cloud Platform como la infraestructura para todo el análisis de datos, así como la construcción y el despliegue del modelo matemático.

## 2. PLANTEAMIENTO DEL PROBLEMA

A pesar de que el objetivo principal de toda compañía es generar negocio, tenemos que entender que esto no significa lo mismo para todas ellas. Identificar el objetivo de conversión de las empresas es el primer paso para lograr el éxito de nuestras estrategias. El siguiente paso es entender el embudo de conversión y los diferentes canales de venta, la relación que mantienen entre ellos y la prioridad que tiene cada uno de ellos dentro del negocio.

Cuando entramos a analizar los diferentes puntos de venta que una compañía puede tener es muy habitual encontrar compañías que tienen modelos híbridos. Es decir, la venta de sus productos y sus servicios se hace tanto a través de la web como de establecimientos físicos. Algunos casos característicos de este tipo de compañías son las de gran consumo (Carrefour, Walmart, Inditex, etc) u hoteleras (Hilton Worldwide, Marriott International, Radisson Hotel Group...). Todas estas compañías tienen como objetivo empresarial vender tanto en su web

como en los puntos físicos o *call centers*. Por tanto, la optimización de toda estrategia de *marketing* (incluyendo *marketing* digital) tiene que estar dirigida a maximizar las ventas en ambos entornos.

Sin embargo, encontramos otro tipo de compañías, que es en el que nos vamos a focalizar en este capítulo, y que engloba aquellas empresas que utilizan la web como medio para iniciar los procesos de compra. Ejemplo de este tipo de compañías son las empresas inmobiliarias (Vía Célere, Hábitat, Neinor Homes) o de venta de automóviles (BMW Group, Ford, Honda) donde, por la casuística del negocio, el proceso de contratación ocurre fuera de la web. En estos casos la estrategia de las campañas de *marketing* digital suele ser la captación de tráfico y *leads* en la web. Los objetivos tradicionalmente se centran en dar visibilidad a los productos y conseguir registros para después cerrar la venta con otros canales de venta como el *call center*. Pero este sistema no es siempre óptimo. Los registros que se obtienen no siempre distinguen el nivel de interés de los usuarios y no están cualificados. Aquí es donde encontramos nuestro principal punto de mejora estratégica y es por lo tanto lo que se va a trabajar a lo largo del capítulo. Planteamos un objetivo de campañas mejorado en el que la estrategia *online* persiga que esos registros sean de calidad y se traduzcan en ventas finales *offline*.

A continuación, ilustramos con un ejemplo la realidad de una empresa inmobiliaria (la llamaremos HouseSale) y la agencia de medios que le gestiona la activación y optimización de las campañas de medios digitales.

Figura 1.

### Embudo de conversión por el que pasan los usuarios para el proceso de compra en la compañía



Fuente: Elaboración propia.

Empezamos analizando el embudo de conversión de HouseSale. En la figura 1 podemos ver el proceso por el que pasan los clientes antes de realizar la compra o alquiler de un inmueble. La agencia de medios debe encargarse de que los usuarios vayan pasando a través de los distintos estadios para conseguir que se realicen las máximas operaciones de compraventa.

De los distintos hitos del embudo, los tres primeros (visibilidad, visita web y *lead* de contacto) son eventos que ocurren en el entorno digital y por tanto la agencia tendrá visibilidad de ellos (y la traza completa de los usuarios) a través de las herramientas de medición. Por tanto, al tener visibilidad y conocer el camino que ha seguido el usuario hasta cada uno de estos objetivos, la actividad de campañas se puede optimizar sin necesidad de integrar otras herramientas. El reto lo encontramos en los dos pasos finales (5 y 6).

Se suele dar el caso en el que, a pesar de estar generando de forma correcta un gran volumen de *leads*, que estos no se estén traduciendo en ventas de inmuebles. En este escenario y desde nuestro punto de vista (el de la agencia de medios) las campañas de *marketing* están funcionando de forma correcta y están optimizadas. Se está consiguiendo dar visibilidad de los distintos inmuebles y, además, estamos también consiguiendo que los usuarios que navegan por la web rellenen formularios contacto. En este punto, la agencia de medios está trabajando de forma correcta, ya que está alcanzando todos los objetivos de los que tiene visibilidad. Además, puede incluso que las distintas ratios como son CPA, CR, CTR, etc. estén incluso optimizadas.

La agencia hablaría con el cliente para decirle que el problema lo tiene con sus oficinas o *call centers*, ya que a pesar de que nosotros llevamos volumen, no están consiguiendo cerrar la conversión. Pero el problema real viene de esta falta de visibilidad sobre el proceso completo. Al no tener la visión de lo que ocurre con el usuario más allá de la web, puede que la agencia esté derivando usuarios de poca calidad y que ya de por sí tenían desde un inicio pocas probabilidades de comprar o alquilar el inmueble. Los usuarios que rellenan los formularios no llegan a completar los siguientes pasos, como concentrar o realizar la visita a un inmueble, enviar una oferta, que la misma sea aceptada, firmar el contrato de arras y finalmente firmar la escritura de la casa.

Nuestro reto como agencia colaboradora de HouseSale es ayudarles a generar negocio, es decir que los inmuebles se vendan. Como hemos visto en el ejemplo anterior, no es suficiente con que los usuarios se registren en la web ya que esto no garantiza el cierre final de la transacción y, por lo tanto, no aporta valor de negocio para HouseSale.

### 3. NUEVOS OBJETIVOS Y RETOS

Con el reto identificado, lo siguiente que debemos definir es el nuevo objetivo que queremos alcanzar e identificar los obstáculos que podemos encontrar en el proceso.

El objetivo dependerá tanto de la industria en la que trabajemos como del cliente. Por ejemplo, en una empresa de gran consumo podemos estar interesados en llevar usuarios a los

supermercados y que estos compren. Estos son dos objetivos claros, pero en otras industrias pueden ser muy diferentes. Es el caso de las inmobiliarias donde, como hemos visto antes con HouseSale tenemos múltiples objetivos, queremos que los usuarios acuerden la visita de un inmueble, realicen la visita, envíen una oferta, firmen el contrato de arras y compren el inmueble. Podemos ver que en este caso elegir un único objetivo es un poco más complejo puesto que tenemos muchos más objetivos que en el caso de la venta minorista.

Además, dentro de una misma industria el objetivo a conseguir puede variar de un cliente a otro en base a sus intereses. Por ejemplo, en el caso del gran consumo podemos tener un cliente que esté interesado en los objetivos que hemos mencionado (usuarios a los supermercados y que estos compren), pero podríamos tener otro cliente de gran consumo que en lo que esté interesado es que los usuarios vayan múltiples veces al supermercado y en vez del número de ventas esté interesado en que gasten lo máximo posible. En estos dos casos los objetivos son muy dispares, ya que en unos queremos llevar el mayor número de usuarios y que estos compren, en cambio en el otro queremos usuarios que vayan a hacer compras más grandes y con mayor frecuencia.

Volviendo a nuestro ejemplo en el que estamos ayudando a HouseSale, identificar el objetivo final es sencillo: aumentar la venta de inmuebles. Pero existen objetivos intermedios que también queremos optimizar, como ya se ha mencionado estos serán: la reserva de una visita al inmueble, la visita del inmueble, el envío de una oferta y la firma del contrato de arras.

Una vez tengamos claros cuáles son nuestros nuevos objetivos tenemos que analizar qué nuevos retos nos surgen para poder optimizar la estrategia. Empezamos viendo dos retos que van a estar siempre presentes en cualquier escenario.

- El primero de estos retos es la visibilidad de los objetivos. Necesitaremos tener visibilidad de cómo evolucionan los objetivos para ser capaces de entender si nuestra estrategia está funcionando o no.
- El segundo hace referencia a la trazabilidad de los usuarios. En *marketing* digital la optimización de usuarios se basa en tener el conocimiento completo de todos los puntos por los que ha pasado el usuario. Esto nos permite entender cuáles son las acciones y puntos de contacto que funcionan de nuestra estrategia y cuáles no. El problema cuando no integramos el mundo *online* con el *offline* es que no conocemos qué ha hecho un usuario después de salir de la web y ahí es donde se complica la optimización.

Pero, además, de manera específica para nuestro caso identificamos otros dos retos que debemos considerar:

- Por la naturaleza del negocio, el tiempo que transcurre desde la última interacción digital (rellenar el formulario de interés) hasta que tiene lugar cada una de las acciones *offline* es de semanas o incluso meses. Esto dificulta el trabajo sobre las campañas que se tendrán que optimizar contra objetivos que ocurrirán a meses en el futuro, si es que estos llegan a ocurrir.

- El último reto que nos encontramos está asociado a la trazabilidad en digital. Los usuarios de HouseSale dedican mucho tiempo a investigar antes de realizar la compra, realizando muchas acciones en la web. Pero nos encontramos con que estas interacciones ocurren desde múltiples dispositivos (móvil, ordenador, *tablet*, aplicación). Es por esto por lo que ser capaces de captar toda la navegación en los distintos dispositivos es muy relevante ya que nos dará mucha información relevante si conseguimos solventar el problema de trazabilidad entre dispositivos.

#### 4. SOLUCIONES PROPUESTAS

Ahora que ya tenemos claro qué es lo que queremos optimizar y cuáles son los distintos retos que tenemos que superar, es el momento de diseñar una solución que nos permita conseguir ambas cosas. A continuación, vamos a ver cómo podemos, de forma general, superar los dos primeros obstáculos que hemos identificado y que son comunes a todas las industrias y clientes.

- Empezaremos por el reto de la visibilidad. De forma general existen dos vías para solventar este problema:
  - La primera solución sería tener un informe compartido por parte del cliente y que esté siempre actualizado. Es decir, un informe en tiempo real o diario en el que nos informe de cuánto hemos conseguido de cada uno de los objetivos. Esto nos permitirá optimizar la estrategia de medios a alto nivel como optimizar, por ejemplo, la distribución de presupuestos entre canales y días de la semana. También permite trabajar con modelos avanzados de tipo econométrico.
  - Por otro lado, lo que podemos hacer es subir las consecuciones de cada uno de los objetivos a las plataformas de medios, esto exige que haya trazabilidad del usuario, pero nos permitirá que las herramientas optimicen la inversión de medios a un nivel más táctico de forma similar a como lo haríamos con cualquier otro objetivo digital.
- Para el segundo obstáculo, que era el problema de la trazabilidad, lo más sencillo es utilizar un evento de registro en la web que conecte los dos mundos. De esta forma, si luego asociamos las acciones que haga el usuario fuera de la web al ID de la base de datos, tendremos toda la trazabilidad del usuario. Lo único que nos queda es subir todas las acciones que nos sean relevantes de vuelta a la plataforma de *marketing* en que queramos utilizarlos.

##### 4.1. Trazabilidad *offline*

Veamos cómo solventamos los problemas para nuestro cliente HouseSale. Empezaremos solucionando la trazabilidad de los usuarios fuera de la web. Con HouseSale esto es sencillo

ya que un usuario que muestre interés por un inmueble tendrá que rellenar un formulario con su *email* o teléfono para poder contactarte. Y usaremos esa información para identificar al usuario fuera de la web y así ser capaces de identificar su actividad *offline*. Cuando rellene el formulario se asocia al *email*/teléfono un User ID que registramos en Google Analytics y que quedará asociado con la *cookie*. Después se crea un proceso automático que de forma diaria subirá todos los eventos *offline* generados por los usuarios y los asocia al User ID correspondiente.

#### 4.2. Medición de objetivos *offline*

Este paso, al tener solventada la trazabilidad, consiste en elegir cuáles van a ser los eventos *offline* que queremos subir para cada usuario. En nuestro caso la información de los eventos se subirá solo a Google Analytics, ya que es suficiente para la activación que llevaremos a cabo. Lo eventos que se han detectado que son relevantes en inmobiliarias y, por tanto, para HouseSale son:

1. Visita física: cuando un usuario concreta una visita a un inmueble.
2. Oferta enviada: cuando un usuario envía una oferta para la compra de un inmueble.
3. Oferta aceptada: cuando la oferta enviada por el usuario es aceptada por el propietario del inmueble.
4. Contrato de arras: cuando el usuario firma un contrato de arras.
5. Escritura: cuando un usuario firma la escritura de un inmueble.

De esta forma con la ayuda del User ID y de la *cookie* tenemos la visibilidad para cada usuario de lo que ha hecho desde que ha entrado en la web hasta que adquiere el inmueble. Toda esta información está disponible en Google Analytics para ser consultada, utilizada y explotada por las personas de la agencia.

#### 4.3. Trazabilidad *cross-device*

Para la trazabilidad completa queremos ser capaces de entender el comportamiento de los usuarios en todos sus dispositivos. De forma adicional, intentaremos tener la trazabilidad fuera de la web sabiendo con qué anuncios ha sido impactado el usuario y cómo ha interactuado con ellos.

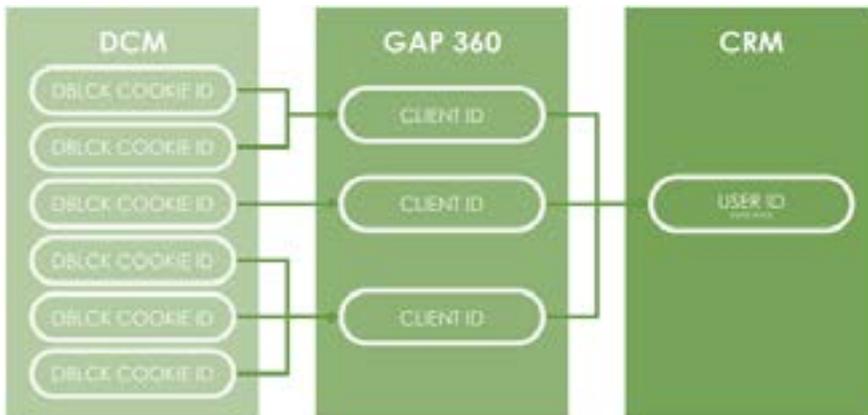
Primero veremos cómo hacemos la trazabilidad entre dispositivos, para esto usaremos el User ID que hemos mencionado previamente. Siempre que un usuario se identifique en un dispositivo sabremos cuál es su User ID y esto nos permitirá saber que es el mismo usuario (*cookie*) en otro dispositivo ya que su User ID es el mismo. Este cruce de datos no se puede

realizar de forma automática en Google Analytics, pero nosotros trabajaremos los datos en Bigquery donde hacer el cruce es sencillo.

Para tener la trazabilidad del usuario en las campañas de *marketing* usaremos un sistema parecido. Lo que haremos será disparar un *floodlight* de Campaign Manager cuando el usuario entre en la web, este evento registrará el Client ID de Google Analytics. De esta forma tenemos conectada la actividad de Google Analytics y la de Campaign Manager. Teniendo todos los datos en Bigquery y usando un esquema de relación entre los ID como el descrito en la figura 2, somos capaces de tener la traza del usuario desde las campañas que le han impactado hasta sus acciones fuera de la web.

Figura 2.

### Relación entre los ID identificativos de cada uno de los usuarios en las distintas plataformas para tener una visión única del usuario



Fuente: Elaboración propia.

#### 4.4. Conversiones lejanas en el tiempo

El problema de que el proceso de compra se alargue en el tiempo es que los algoritmos de optimización pueden interpretar que no se están consiguiendo los objetivos. Además, puede confundir al algoritmo sobre cuál de las acciones de *marketing* es la que está trayendo las conversiones. Por ejemplo, las que ocurran entre el contrato de arras y la escritura es probable que no tengan relevancia. Todo esto sumado al problema de que el número de conversiones que tendremos es muy bajo hace que la forma normal de optimización de las campañas con los algoritmos automáticos no sea la más adecuada para este negocio en concreto.

La solución que usaremos es crear un modelo matemático que, usando toda la información que tenemos gracias a la trazabilidad completa, prediga si un usuario va a realizar cada una de las acciones en las que estamos interesados. Una vez tengamos este modelo entrenado

y funcionando seremos capaces de asignar a cada usuario una probabilidad de conversión en base a su comportamiento. Teniendo esta clasificación de todos los usuarios, lo que haremos será trabajar la estrategia de *marketing* en base a audiencias, donde cada audiencia será el grupo de usuarios que tengan más o menos probabilidad de realizar una compra.

## 5. IMPLEMENTACIÓN

A lo largo de esta sección veremos cuáles son las distintas fases que se deben seguir para llevar a cabo la solución que se ha planteado en las secciones anteriores. Aunque las secciones son comunes para cualquier problema de este tipo, nosotros de nuevo ilustraremos cada uno de los pasos con la ayuda del ejemplo que tenemos con HouseSale. Las distintas fases y su orden es el siguiente:

1. Trazabilidad de la información
2. Importación de los datos
3. Agregación de los datos de usuario
4. Crear variables predictivas y construir tabla final
5. Dividir datos
6. Identificar objetivos
7. Construir modelo
8. Desplegar modelo
9. Disponibilizar resultados
10. Activación en medios
11. Visualización
12. Revisiones

### 5.1. Trazabilidad de la información

El primer paso es conseguir todos los datos que utilizaremos durante la construcción del modelo. Por lo tanto, lo primero que tenemos que hacer es solventar los problemas de trazabilidad que tenemos (trazabilidad *offline* y trazabilidad *cross-device*).

Para nuestro caso de estudio, decidimos usar Google Analytics como plataforma centralizadora que nos dará la total trazabilidad de los usuarios. Para esto, lo primero que haremos es que cuando un usuario rellene cualquier formulario en la web o se registre se enviará desde

los sistemas de HouseSale a Google Analytics un identificador único para ese usuario basado en el *email* y el teléfono. Este número nos permitirá conectar las actividades entre los distintos dispositivos en los que el usuario realice alguna de estas acciones. Además, este usuario estará presente en todos los registros que ocurran por parte de HouseSale referente a la actividad *offline* del usuario.

Como todos los eventos *offline* están asociados al ID de usuario que también tenemos en Google Analytics, podemos utilizar este ID para utilizar *measurement protocol*. De esta forma, subiremos a Google Analytics los eventos relevantes para el modelado de formas que estén disponibles en la plataforma y asociados al usuario correcto. Haremos la subida de cinco eventos distintos que son relevantes para nosotros:

- Visita física al inmueble
- Envío de oferta
- Aceptación de la oferta
- Contrato de arras
- Escritura

Para el proceso de informar los distintos eventos lo que haremos será la subida automática de forma diaria de todos los nuevos eventos que se hayan registrado de forma manual en los sistemas de la compañía.

## 5.2. Importación de los datos

Un paso sencillo de elaborar, pero crucial para la ejecución de los siguientes. Lo que haremos durante este paso será la importación en la base de datos en la que vayamos a trabajar de todos los datos de navegación y *offline* que tenemos disponibles gracias al paso previo.

Para nuestro caso de uso, donde usaremos como base de datos Bigquery y teniendo todos los datos disponibles en Google Analytics, la única tarea necesaria es la activación de Export de Google Analytics que nos enviará de forma diaria todos los eventos que hayan ocurrido en la web.

## 5.3. Agregación de los datos de usuario

Una vez tenemos todos los datos disponibles en la base de datos tenemos que tratarlos para que tengan un formato para que sirvan a nuestros propósitos.

Lo primero que tenemos que hacer es construir el *path* de usuario (*cross-dispositivo*). De esta forma tenemos disponible la visibilidad completa para cada usuario de los eventos que ha hecho, tanto *online* en los distintos dispositivos como *offline*.

En nuestro caso la construcción del *path* de usuario consiste en crear una tabla de correspondencia entre el ID de usuario con los ID de *cookie* de cada uno de los dispositivos en los que hayamos sido capaces de trazar al usuario. Utilizando esto, somos capaces de sustituir la *cookie* por el ID de usuario. Habiendo hecho esto estamos en condiciones de unificando toda la actividad de cada ID de usuario tener la visión de todas las interacciones de cada uno de ellos.

Una vez tenemos para cada ID de usuario toda su actividad, lo que queremos hacer es agregar la actividad para cada día, esto nos facilitará su análisis.

En el caso de HouseSale donde ya tenemos toda la actividad de cada usuario unificada lo que hacemos es utilizar el *timestamp* del evento para extraer la fecha. De esta forma, haciendo la agregación para cada ID de usuario y cada fecha y sumando el número de eventos de cada tipo tendremos para cada día y usuario todos los eventos que ha realizado el usuario en ese día.

#### 5.4. Crear variables predictivas y construir tabla final

Una vez tenemos todos los datos de cada usuario es el momento de construir las variables que vamos a utilizar para predecir nuestros objetivos, así como las variables que queremos predecir. Como ya hemos mencionado, nuestro problema tiene un importante componente temporal y, por lo tanto, lo que haremos será construir variables basadas en el tiempo. Para cada día y usuario vamos a construir variables que nos digan si cada uno de los posibles even-

Figura 3.

**Ejemplo de la tabla previa al entrenamiento del modelo en la cual están disponibles todas las variables descriptivas, así como las que queremos predecir con sus respectivas distribuciones temporales**

<i>User ID</i>	<i>Fecha</i>	<i>Sesiones últimos 30 días</i>	<i>Inmuebles visitados últimos 30 días</i>	<i>Clicks últimos 30 días</i>	<i>Sesiones últimos 15 días</i>	<i>Inmuebles visitados últimos 15 días</i>	<i>Clicks últimos 15 días</i>
a5dc48245dg5	06/09/2021	7	10	1	7	6	1
a5dc48245dg5	07/09/2021	16	11	5	14	10	1
a5dc48245dg5	08/09/2021	23	18	6	5	13	3
f514t84h56sc	06/09/2021	10	7	2	4	7	1
f514t84h56sc	07/09/2021	7	0	1	1	0	1
f514t84h56sc	08/09/2021	1	0	0	1	0	0
f514t84h56sc	09/09/2021	0	0	0	0	0	0

Figura 3. (continuación)

**Ejemplo de la tabla previa al entrenamiento del modelo en la cual están disponibles todas las variables descriptivas, así como las que queremos predecir con sus respectivas distribuciones temporales**

<i>User ID</i>	<i>Fecha</i>	<i>Sesiones últimos 7 días</i>	<i>Inmuebles visitados últimos 7 días</i>	<i>Clicks últimos 7 días</i>	<i>Compra siguientes 30 días</i>	<i>Compra siguientes 15 días</i>	<i>Compra siguientes 7 días</i>
a5dc48245dg5	06/09/2021	3	5	1	1	0	0
a5dc48245dg5	07/09/2021	9	6	1	1	0	0
a5dc48245dg5	08/09/2021	5	6	2	1	1	0
f514t84h56sc	06/09/2021	4	1	1	0	0	0
f514t84h56sc	07/09/2021	1	0	1	0	0	0
f514t84h56sc	08/09/2021	1	0	0	0	0	0
f514t84h56sc	09/09/2021	0	0	0	1	0	0

*Fuente:* Elaboración propia.

tos ha ocurrido en un determinado periodo de tiempo. De la misma forma, construiremos para cada uno de los objetivos si este evento ha ocurrido o no en los siguientes días desde el día que se está calculando.

Cuando preparamos los datos para HouseSale sabemos que los usuarios navegan mucho antes de decidirse por una casa y, además, sabemos también que el tiempo que toma la consecución de los objetivos *offline* puede ser muy grande. Es por eso por lo que construiremos variables que nos informarán de la actividad del usuario en los últimos 7, 15 y 30 días. Y lo mismo a futuro para los objetivos *offline* que son los que estamos interesados en ser capaces de predecir. De esta forma construiremos una tabla que será la que se utilizará para predecir. Como se puede ver en el ejemplo de la figura 3 tendremos una fila para cada usuario y día. También tendremos tres columnas por cada evento (sesiones, *clicks*, inmuebles vistos, etc.) que estemos trazando para el usuario. Si el evento es un objetivo, entonces tendremos si se ha conseguido en los próximos 7, 15 o 30 días. Mientras que, para el resto de las variables, que serán las explicativas, tendremos cuántas veces ha ocurrido en los últimos correspondientes días.

### 5.5. Dividir datos

Como en cualquier proyecto de modelado, uno de los pasos más importantes es la división de todo el conjunto en tres distintos *dataset* que son: entrenamiento, validación y test. Donde el mayor porcentaje de los datos se dedicarán al conjunto de entrenamiento, después a validación y el resto a test.

Figura 4.

### Porcentajes de división de la tabla completa de datos en cada uno de los *datasets* para el entrenamiento del modelo

70 % Entrenamiento	20 % Validación	10 % Test
-----------------------	--------------------	--------------

Fuente: Elaboración propia.

Estos *datasets* se utilizarán para entrenar los modelos y elegir el mejor. El *dataset* de entrenamiento es el que se utiliza para construir cada uno de los modelos, que después se contrastará con los datos del *dataset* de validación. En base a los resultados del modelo, en los datos de validación se harán correcciones y se volverá a entrenar el modelo. Este proceso se repetirá hasta tener un modelo con el que estemos contentos. El modelo final se utilizará sobre los datos de test, este *dataset* no ha sido utilizado en ningún momento durante la preparación del modelo y, por tanto, son datos reales que el modelo no ha visto y simulará el desplegarlo en un entorno real.

En este paso, las particularidades del caso de uso de HouseSale no son muy grandes, los porcentajes que se utilizarán son 70 % para entrenamiento, 20 % para validación y 10 % para test tal y como se muestra en la figura 4.

## 5.6. Identificar objetivos

Llega el momento de analizar los datos para confirmar que son útiles y que con ellos se pueden predecir los objetivos en los que estamos interesados. Este paso va a depender de la industria y los datos que tengamos.

Para los datos de la compañía HouseSale empezaremos analizando los objetivos para tratar de ver si tienen la calidad necesaria. Lo primero con lo que nos encontramos es que la correlación entre las ofertas enviadas y las ofertas aceptadas no es muy grande, así que no será muy diferente trabajar con uno o con otro. Lo siguiente que vemos durante el análisis es el número de ocurrencias para los eventos de oferta enviada, oferta aceptada, contrato de arras y escritura. De forma que el único evento que tenemos con un gran número de ocurrencias es la visita física. Además, nos hemos encontrado con otro problema relacionado con el tiempo. El problema con el que nos encontramos es que hemos visto que los eventos posteriores a la visita física no solo tardan mucho tiempo en ocurrir, si no, que el tiempo que le lleva a cada usuario el llegar a ese objetivo difiere mucho de un usuario a otro. Esta discrepancia hace que sea muy difícil fijar cuál es la ventana de tiempo con la que debemos trabajar para predecir si alguien realizará la acción en el futuro.

Basándonos en este análisis lo que hacemos es que vamos a construir el modelo que prediga si el usuario realizará una visita. Esto nos permite fijar el número de días a futuro que

tenemos que seleccionar que en este caso serán 30 y teniendo muchos más ejemplos positivos en el caso de los otros objetivos.

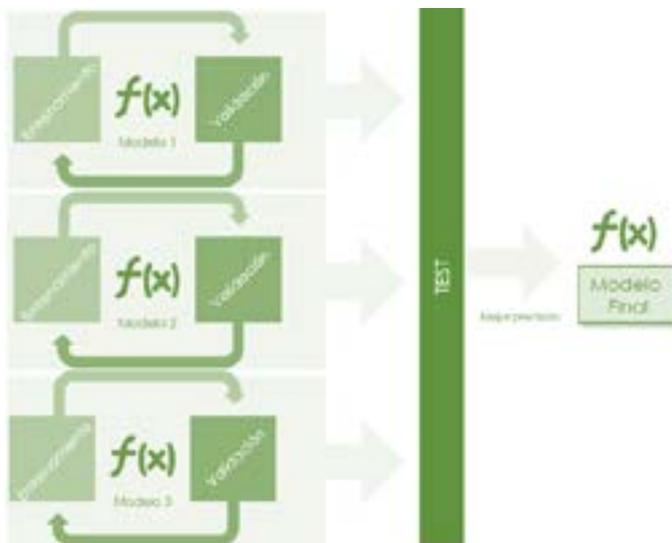
### 5.7. Construir modelo

Una vez definido el objetivo que queremos predecir y teniendo ya preparados los distintos *datasets*, ha llegado el momento de entrenar el modelo. Para el proceso de construcción (resumido en la figura 5) de los modelos, primero seleccionamos cuáles son las técnicas que utilizaremos para intentar predecir el objetivo. Sobre cada una de las técnicas entrenaremos un modelo que después validaremos. En base a los resultados que obtengamos en la validación cambiaremos los parámetros del modelo y lo volveremos a entrenar. Este proceso lo repetiremos hasta que tengamos un modelo con el que estemos contentos y el cual no queramos iterar más sobre él. Una vez tengamos modelos, en la fase de validación utilizaremos los datos de test para evaluar todos los modelos y de esta forma validarlos con “datos reales”. En base a los resultados obtenidos de esta evaluación compararemos los distintos modelos que tenemos y el que mejor funcione en la fase de test es el que seleccionaremos como modelo a utilizar.

Para la comparación de los distintos modelos, que en este caso son modelos de clasificación, se utilizarán las técnicas tradicionales. Se utilizan métricas derivadas de la matriz de

Figura 5.

**Metodología a seguir para el entrenamiento del modelo con el uso de los distintos *datasets* y cada uno de los modelos**



Fuente: Elaboración propia.

confusión como son precisión, exhaustividad o ratio de acierto. Pero también utilizamos otras métricas como pueden ser el *AUC* o *Log loss* para evaluar el funcionamiento de los modelos.

En el caso específico de HouseSale tenemos todos los datos disponibles en Bigquery así que vamos a poder utilizar toda la potencia que nos ofrece Google Cloud para construir los modelos. Trabajar directamente con los datos en Bigquery quiere decir que el lugar donde hemos hecho todas las transformaciones es también el lugar donde almacenamos los datos para ser explotados por el modelo.

Las técnicas que utilizaremos en este caso para construir el modelo de predicción son:

- Regresión logística
- *Support Vector Machine (SVM)*
- *Naive Bayes*
- Redes neuronales
- *Random forest*
- Árbol de clasificación

Para la construcción de estos modelos usaremos distintas herramientas dentro de Google Cloud para ser lo más eficientes y rápidos en el entrenamiento de los modelos. Usaremos como primera herramienta Google Dataproc que nos permite poner en marcha un *cluster* con el número de núcleos y el tamaño de estos a gran velocidad. Y de la misma forma nos permite eliminar el *cluster* en unos segundos. Además, estos *clústeres* vienen de forma predefinida con todas las herramientas instaladas para poder entrenar el modelo como con Spark o Python. Todo esto nos permite de forma muy ágil levantar un modelo, entrenarlo y después destruir el *cluster*, de esa forma no tendremos ningún coste innecesario y podremos utilizar las técnicas de paralización para que los modelos se entrenen de manera rápida y así llevar a cabo el proceso de forma muy rápida.

Tras realizar todo el entrenamiento y validación se llega a la conclusión de que el modelo que mejor funciona es la regresión logística. Esto es una suerte, ya que es un modelo fácilmente interpretable, lo que es muy útil para explicar a las distintas personas involucradas en el proyecto cómo funciona el modelo y cuáles son los factores más relevantes a la hora de detectar si un usuario realizará la visita o no. Otra gran ventaja que tiene que el modelo sea una regresión logística es que podemos utilizar directamente Bigquery para construirlo. Esto hace que solamente necesitemos un único proyecto para almacenar los datos, transformarlos, entrenar los modelos y hacer las predicciones. Además, la construcción del modelo se hace directamente con sentencias SQL lo que también simplificará su mantenimiento. Tras construir el modelo en Bigquery y confirmar que funciona de la misma forma que lo hacía en Dataproc, se decide que por simplicidad se utilizará Bigquery para construir el modelo.

## 5.8. Desplegar modelo

Tras haber decidido el modelo que vamos a utilizar, llega el momento de asegurarnos que el modelo se ejecuta de forma que pueda ser explotado. Para esto hay varios procesos que se tienen que automatizar. El primero de todos es el que realiza todas las transformaciones hasta la creación de la tabla final. Este proceso se automatizará de forma que utilizando los datos más actuales nos dé las métricas de entrada para cada usuario en el día actual. Con esto tendremos los datos necesarios para que el modelo trabaje.

El siguiente proceso es la ejecución del modelo. Este proceso tomará la tabla de datos para todos los usuarios y le aplicará el modelo. Esto nos dará para cada uno de los usuarios de la tabla (cada una de las personas que haya navegado por la web en los últimos 30 días) un número de 0 a 1. Este número es la probabilidad que nos dice el modelo de que ese usuario vaya a realizar la acción específica en el tiempo determinado. A este número es a lo que se llamará *score* de usuario. En el caso concreto de nuestro caso de uso el *score* nos dirá la probabilidad de que un usuario realice una visita a un inmueble en los siguientes 30 días.

El último proceso es poner a disponibilidad los *scores* de los usuarios para que puedan ser consumidos por un servicio externo. Una vez estos procesos están automatizados lo que se hace es que se despliegan de forma que se ejecuten de forma periódica o en base a peticiones según se requiera.

Para HouseSale se construye el proceso de creación de la tabla de entrada para el modelo, así como la ejecución del modelo. Para disponibilizar los datos lo que se hace es que se crea una tabla en la que estarán los *scores* actualizados para cada uno de los usuarios que estén dentro del periodo de análisis. Para la casuística de HouseSale la ejecución de todos estos procesos se hará de forma diaria, así que cada día regeneraremos la tabla en la que tendremos los *scores* para cada usuario actualizados.

## 5.9. Disponibilizar resultados

Esta fase es la que hace que los resultados lleguen a las distintas herramientas que vayan a explotarlos. Estas herramientas pueden ser de *marketing*, para la activación de campañas, de personalización web o cualquier otra herramienta que se beneficie del uso del *score*.

En HouseSale, como se ha establecido desde el principio, el principal objetivo es la activación en medios. Para esto, lo primero en lo que estamos interesados es en enviar los *scores* para que estén en Google Analytics. Para realizar este envío utilizaremos el *data import* para subir los *scores* y asociarlos a cada ID de usuario que ya creamos previamente. Esta información estará en Google Analytics como una variable personalizada que por razones de facilitar el trabajar con ella se subirá un número de 0 a 10 (en vez del valor de 0 a 1 que arroja el modelo).

Además, los datos se dispondrán de otras formas para que puedan ser utilizados para otras explotaciones. Se utilizará Google cloud functions para que el *score* de cada uno de los usuarios esté disponible en tiempo real a través de una petición web. De esa forma el *score* podrá ser utilizado por herramientas de personalización.

La última forma a través de la que se dispondrán los datos es con el envío de un documento a un FTP que contiene la información actualizada del *score* de todos los usuarios. A través del FTP este documento llegará a los sistemas internos de HouseSale donde se convertirá en un atributo más del CRM. De esa forma esta información estará disponible para departamentos como el de *call center* que podrá priorizar sus llamadas basándose en el *score* que tiene cada uno de los usuarios.

### 5.10. Activación en medios

Para esta fase trataremos directamente el caso de HouseSale. En este caso usaremos Google Analytics como el centralizador de toda la activación en medios. Teniendo la variable personalizada creada se puede utilizar para crear diferentes audiencias con cada uno de los posibles valores que puede tomar el *score*. En la figura podemos ver el número de usuarios que tenemos en cada una de las audiencias.

Figura 6.

#### Número de usuarios, así como usuarios nuevos en cada una de las audiencias para cada valor del *score*

<i>User score</i>	<i>Users</i>	<i>New users</i>
0	10.032	669
1	15.867	1.327
2	23.297	466
3	22.652	227
4	13.293	798
5	9.265	371
6	7.266	291
7	6.941	69
8	4.766	95
9	3.795	0
10	1.679	0

Fuente: Elaboración propia.

Es importante conocer el número de usuarios en las audiencias creadas con vistas a la activación. Podemos ver en la figura 6 que el mayor volumen de usuarios se concentra en torno a 2-3 y que tenemos pocos usuarios en los valores altos. Basándonos en estos números tomamos las siguientes decisiones:

Para la activación en SEM, display y social se necesita un número mínimo de usuarios para poder hacer el *retargeting*, por tanto, lo que hacemos es que agrupamos a los usuarios de siete o más para poder dedicar mayor presupuesto y mejores pujas sobre los usuarios que son de alto valor. Todos los usuarios que tengan una probabilidad menor a cuatro serán excluidos de las estrategias de *retargeting* consiguiendo así un ahorro en impresiones sobre usuarios no interesados. El resto de los usuarios seguirán con la estrategia de *retargeting* que se estaba llevando a cabo hasta entonces.

### 5.11. Visualización

El último paso de trabajo con los resultados es presentarlos para que puedan ser consultados de forma sencilla por las distintas personas. Para esto lo que se hace es crear una visualización de datos donde se muestra toda la información asociada a los *scores*. Es importante mostrar el número de usuarios que hay en cada *score* en el momento actual. También es importante entender cómo los usuarios se mueven desde un *score* a otro a lo largo del tiempo. Y finalmente, si se tiene un modelo que sea fácilmente explicable es conveniente usar gráficos como el de la figura 7 en donde se muestre la importancia de cada una de las variables para predecir el objetivo.

Figura 7.

#### Importancia de cada una de las variables para la predicción de la visita física a un inmueble



Fuente: Elaboración propia.

En el caso de estudio que estamos siguiendo usaremos como herramienta para construir la visualización a Data Studio. Teniendo los datos en Bigquery es sencillo conectar los datos directamente con la plataforma. En Data Studio mostramos los datos referentes a los *scores* de usuario que se han mencionado previamente. De forma adicional, utilizando los conectores nativos de Data Studio extraemos la información de la plataforma de activación (Search Ads 360 y Campaign Manager) para conseguir también un informe actualizado de cómo es el desempeño de cada uno de los distintos *scores*.

### 5.12. Revisiones

Es importante notar que el trabajo de modelización es un trabajo que no se puede hacer una única vez. Los cambios en el comportamiento de los usuarios a lo largo del tiempo, en las estrategias de activación o modificaciones de la web pueden hacer que el modelo se quede obsoleto. Es por eso por lo que es importante la creación de una metodología en la que, de forma automática o manual, se revise de forma periódica el desempeño de los modelos para que sean ajustados cuando su comportamiento no sea el esperado.

En HouseSale se crea un sistema que reentrena el modelo de forma mensual para asegurar que esté actualizado. Al utilizar Bigquery para la construcción del modelo este reentrenamiento es rápido y sencillo. A pesar de tener este sistema, también se establecen sistemas de alarma que avisarán si el desempeño del modelo disminuye por debajo de los niveles deseados. Y finalmente, de forma trimestral se establece una revisión más profunda del modelo en la que se evaluará si hay cambios en el entorno que requieran de la modificación del modelo, de los objetivos o añadir / quitar variables predictivas.



## CAPÍTULO VI

## ¿Utiliza Facebook datos sensibles con fines publicitarios? Análisis mundial e impacto del Reglamento General de Protección de Datos europeo (RGPD)\*

José González Cabañas  
Ángel Cuevas  
Rubén Cuevas

El reciente Reglamento General de Protección de Datos (RGPD) y otras normativas de protección de datos restringen el tratamiento de algunas categorías de datos personales (salud, orientación política, preferencias sexuales, creencias religiosas, origen étnico, etc.) debido a los riesgos de privacidad asociados a dicha información. El RGPD se refiere a estas categorías como categorías especiales de datos personales. Este trabajo cuantifica el número de usuarios de Facebook (Facebook), en 197 países, que son etiquetados con intereses publicitarios vinculados a esta categoría de datos personales que pueden clasificarse como potencialmente sensibles para el usuario. Nuestro estudio revela que Facebook etiqueta al 67 % de los usuarios con intereses potencialmente sensibles. Esto corresponde al 22 % de la población en los 197 países referidos. Además, nuestro trabajo muestra que la aplicación del RGPD tuvo un impacto insignificante en esta asignación de intereses potencialmente sensibles ya que el porcentaje de usuarios de Facebook etiquetados con éstos en la Unión Europea sigue siendo casi el mismo cinco meses antes y nueve meses después de la entrada en vigor del RGPD. El documento también ilustra los riesgos potenciales asociados al uso de intereses sensibles. Por ejemplo, en este trabajo cuantificamos la proporción de usuarios de Facebook etiquetados con el interés “Homosexualidad” en países donde la homosexualidad puede ser castigada con la pena de muerte. La última contribución es la implementación de una extensión de navegador que permite a los usuarios de Facebook eliminar de forma sencilla los intereses potencialmente sensibles que Facebook les ha asignado.

*Palabras clave:* Facebook, RGPD, datos personales sensibles.

\* Este trabajo ha sido parcialmente financiado por: (i) el Ministerio de Economía, Industria y Competitividad, España y el Fondo Social Europeo (UE), bajo el programa Ramón y Cajal (subvención RyC-2015-17732) y el Proyecto TEXEO (Subvención TEC2016- 80339-R), (ii) el Proyecto Europeo H2020 SMOOTH (Grant 786741), (iii) el Ministerio de Educación, Cultura y Deporte, España, a través del programa FPU (Grant FPU16/05852) y (iv) el proyecto sinérgico de la Comunidad de Madrid EMPATIA-CM (Grant Y2018/TCS-5046).

## 1. INTRODUCCIÓN

Los ciudadanos de todo el mundo han demostrado una gran preocupación por la gestión de la información personal por parte de los servicios en línea. Por ejemplo, el *Eurobarómetro* de 2015 sobre protección de datos (Opinion and Social, 2015) revela que el 63 % de los ciudadanos de la Unión Europea (UE) no confía en las empresas en línea, a más de la mitad no le gusta proporcionar información personal a cambio de servicios gratuitos y al 53 % no le gusta que las empresas de Internet utilicen su información personal en la publicidad dirigida. Del mismo modo, una encuesta reciente realizada entre usuarios estadounidenses (Janrain.com, 2018) revela que el 53 % de los encuestados es contraria a recibir anuncios personalizados a partir de la información que los sitios web y las aplicaciones aprenden sobre ellos, el 42 % no cree que los sitios web se preocupen en absoluto por utilizar los datos de los usuarios de forma segura y responsable y el 73 % considera que los sitios web saben demasiado sobre los usuarios. Una encuesta realizada por Internet Society (ISOC) en la región de Asia-Pacífico en 2016 (InternetSociety.org, 2016) reveló que el 59 % de los encuestados no sentía que su privacidad estuviera suficientemente protegida cuando utilizaba Internet y el 45 % consideraba urgente llamar la atención de los responsables políticos de su país en materia de protección de datos.

Los responsables políticos han reaccionado ante esta situación aprobando o proponiendo nuevas normativas en materia de privacidad y/o protección de datos. Por ejemplo, en mayo de 2018, la UE puso en vigor el Reglamento General de Protección de Datos (RGPD) (EU, 2016) en los 28 Estados miembros. Del mismo modo, en junio de 2018, California aprobó la Ley de Privacidad del Consumidor de California (Legislature, 2018), que se reivindica como la ley de privacidad de datos más dura del país. En países como Argentina o Chile los gobiernos propusieron en 2017 nuevos proyectos de ley que actualizan su regulación de protección de datos existente (PWC.in, 2018). A efectos de este trabajo tomaremos como referencia el RGPD por ser el que afecta a más países, ciudadanos y empresas.

El RGPD (pero también la mayoría de las normativas de protección de datos) define algunas categorías de datos personales como sensibles y prohíbe su tratamiento con limitadas excepciones (por ejemplo, el usuario da su consentimiento explícito para el tratamiento de esos datos sensibles para un fin específico). En particular, el RGPD define como datos personales sensibles *datos personales que revelen el origen étnico o racial, las opiniones políticas, las convicciones religiosas o filosóficas, o la afiliación sindical, y el tratamiento de datos genéticos, datos biométricos dirigidos a identificar de manera unívoca a una persona física, datos relativos a la salud o datos relativos a la vida sexual o las orientaciones sexuales de una persona física.*

Debido a las implicaciones legales, éticas y de privacidad del tratamiento de datos personales sensibles, es importante verificar si los servicios en línea están explotando actualmente dicha información sensible con propósitos comerciales. Si ese es el caso, también es esencial medir la proporción de usuarios/ciudadanos que pueden verse afectados por la explotación de sus datos personales sensibles. En este artículo, abordamos estas cuestiones cruciales cen-

trándonos en la publicidad en línea, que representa la fuente de ingresos más importante para la mayoría de los servicios en línea. En particular, consideramos el caso de Facebook, cuya plataforma de publicidad en línea es la segunda después de Google en términos de ingresos (Emarketer.com, 2017).

Facebook etiqueta a los usuarios con las llamadas *preferencias publicitarias*, que representan los intereses potenciales de los usuarios. Facebook asigna a los usuarios diferentes preferencias publicitarias en función de su actividad en línea dentro de esta red social. Los anunciantes que realizan campañas publicitarias pueden dirigir su anuncio a grupos de usuarios a los que se les ha asignado una preferencia publicitaria concreta (por ejemplo, dirigirse a usuarios de Facebook interesados en “Starbucks”). Algunas de estas preferencias publicitarias sugieren opiniones políticas, orientación sexual, datos relativos a la salud y otros atributos potencialmente sensibles. De hecho, un autor de este artículo recibió el anuncio que se muestra en la figura 1 (lado izquierdo). El texto del anuncio refleja claramente que el anuncio se dirigía a personas interesadas en homosexualidad. El autor no había definido explícitamente su orientación sexual, pero descubrió que Facebook le había asignado la preferencia de anuncio “Homosexualidad” (véase la figura 1, lado derecho). El conjunto de datos recogidos para esta investigación sugiere que la asignación de preferencias publicitarias potencialmente sensibles es mucho más amplia. Por ejemplo, algunas páginas de destino asociadas a los anuncios almacenados en nuestro conjunto de datos son *iboesterreich.at* (política), *gaydominante.com* (sexualidad), *elpartoestuyo.com* (salud).

Este episodio ilustra que Facebook puede estar procesando información personal sensible, que ahora está prohibida por el RGPD de la UE sin consentimiento explícito. Sin embargo, esto tampoco estaba permitido por algunas regulaciones nacionales de protección de datos de la UE antes del RGPD. En mayo de 2017, la Agencia Francesa de Protección de Datos (AFPD) multó a Facebook con 150 mil euros argumentando (entre otras cosas) que Facebook “recopila datos sensibles de los usuarios sin obtener su consentimiento explícito”<sup>1</sup>. Del mismo modo, en septiembre de 2017, la Agencia Española de Protección de Datos (AEPD) multó a Facebook con 1,2 millones de euros argumentando (entre otras cosas) que Facebook *recoge, almacena y utiliza datos, incluidos datos especialmente protegidos, con fines publicitarios sin obtener el consentimiento del usuario*<sup>2</sup>.

Motivado por todos estos acontecimientos, este trabajo examina el uso que Facebook hace de los datos potencialmente sensibles en 197 países diferentes en febrero de 2019. El objetivo principal de este trabajo es *cuantificar la proporción de usuarios de Facebook a los que se les puede haber asignado preferencias publicitarias vinculadas a datos personales potencialmente sensibles*. Además, para el caso particular de los 28 países que formaban la UE en febrero de 2019, analizamos si se produjo alguna reducción relevante en la proporción de usuarios etiquetados con preferencias publicitarias potencialmente sensibles comparando tres conjuntos de datos recogidos en enero de 2018, octubre de 2018 y febrero de 2019 (cinco meses antes,

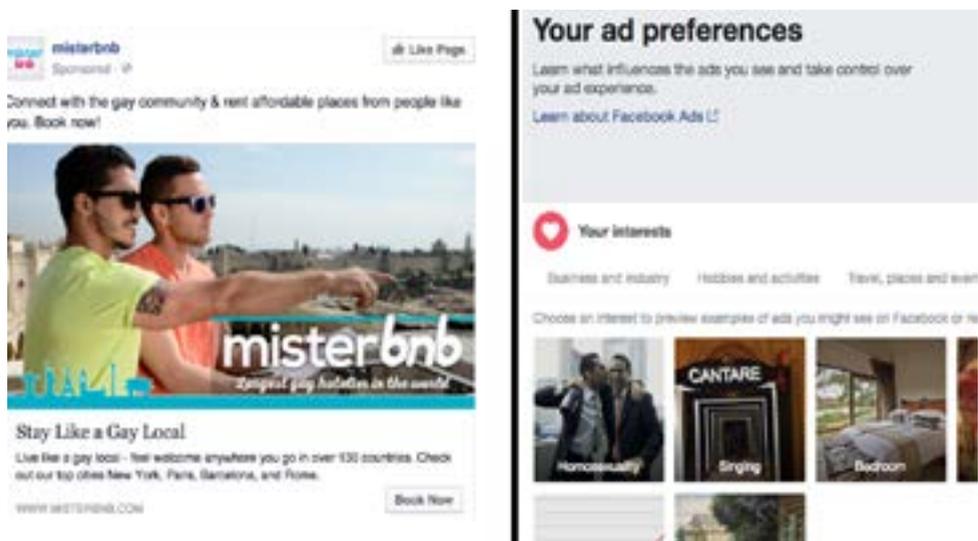
<sup>1</sup> <https://www.cnil.fr/en/facebook-sanctioned-several-breaches-french-data-protection-act>

<sup>2</sup> <https://techcrunch.com/2017/09/11/facebook-fined-e1-2m-for-privacy-violations-in-spain/>

cinco meses después y nueve meses después de la promulgación del RGPD, respectivamente). También ilustramos los riesgos éticos y de privacidad que pueden derivarse de la explotación de las preferencias publicitarias sensibles de Facebook. Por último, presentamos una solución técnica que permite a los usuarios eliminar de forma sencilla los intereses potencialmente sensibles que Facebook les ha asignado.

Figura 1.

**Ilustración de un anuncio recibido por uno de los autores de este trabajo y la lista de preferencias de anuncios que muestra que Facebook dedujo que esta persona estaba interesada en *homosexualidad***



Fuente: facebook.com

## 2. CONTEXTO

En Facebook, los anunciantes configuran sus campañas publicitarias a través del Creador de Anuncios de Facebook (*Facebook Ads Manager*)<sup>3</sup>. Este, permite a los anunciantes definir la audiencia (es decir, el perfil de usuario) a la que quieren dirigirse con sus campañas publicitarias. Se puede acceder a él a través de un panel de control o de una API. El Facebook Ads Manager ofrece a los anunciantes una amplia gama de parámetros de configuración tales como (pero no limitados a) *localización* (país, región, etc.), *parámetros demográficos* (sexo, edad, etc.), *comportamientos* (dispositivo móvil, sistema operativo y/o navegador web utilizado, etc.) e *intereses* (deportes, comida, etc.). El parámetro *interés* es el más relevante para nuestro trabajo. Incluye cientos de miles de posibilidades que captan los intereses y gustos de los usuarios de cualquier tipo. Además, el Facebook Ads Manager proporciona información

<sup>3</sup> <https://www.facebook.com/ads/manager>

detallada sobre la audiencia configurada. El elemento más relevante para nuestro trabajo es el *alcance potencial* que informa del número de usuarios activos mensuales en Facebook que coinciden con la audiencia definida.

De manera paralela, Facebook asigna a cada usuario un conjunto de preferencias publicitarias, o en otras palabras, un conjunto de intereses, derivados de los datos y la actividad del usuario en Facebook. Estas preferencias publicitarias son, de hecho, los intereses que se ofrecen a los anunciantes en el Facebook Ads Manager<sup>4</sup>. Por lo tanto, si a un usuario se le asigna el interés “relojes” dentro de su lista de preferencias publicitarias, será un objetivo potencial de cualquier campaña publicitaria en Facebook configurada para llegar a usuarios interesados en relojes.

El conjunto de datos utilizado en este trabajo se obtiene a partir de los datos recogidos con una extensión de navegador web: FDVT (Cabañas, Cuevas y Cuevas, 2017). La funcionalidad principal del FDVT es informar a los usuarios de Facebook de los ingresos que generan los anuncios que reciben en Facebook. El FDVT recoge (entre otros datos) las preferencias publicitarias que Facebook asigna a los usuarios. Es importante señalar que los usuarios del FDVT nos han concedido permiso explícito para utilizar la información recogida (de forma anónima) con fines de investigación.

Por último, para cualquier preferencia publicitaria, podemos consultar la API de Facebook Ads Manager para obtener el *alcance potencial* (es decir, usuarios activos de Facebook) asociado a cualquier audiencia de Facebook. Por lo tanto, podemos obtener el número de usuarios de Facebook en cualquier país (o grupo de países) a los que se les ha asignado un interés particular (o grupo de intereses).

### 3. DATOS Y METODOLOGÍA

En este trabajo buscamos cuantificar el número de usuarios de Facebook a los que se les han asignado preferencias publicitarias potencialmente sensibles en 197 países en febrero de 2019. Para ello, seguimos un proceso de dos pasos.

En primer lugar, identificamos los intereses que tienen más probabilidad de ser sensibles dentro de cinco de las categorías relevantes enumeradas como *datos personales sensibles* por el RGPD: origen racial o étnico, opiniones políticas, creencias religiosas o filosóficas, salud y orientación sexual. Este trabajo reutiliza la lista de 2.092 preferencias publicitarias potencialmente sensibles de un trabajo previo (Cabañas, Cuevas y Cuevas, 2018) que fueron extraídas a partir del análisis de más de 126 mil preferencias publicitarias únicas asignadas 5,5 millones de veces a más de 4.500 usuarios del FDVT.

<sup>4</sup> Dado que los intereses y las preferencias publicitarias se refieren a lo mismo, utilizamos estos dos términos indistintamente en el resto del capítulo.

Para extraer esa lista, primero implementamos un proceso automático para reducir la lista de 126 mil preferencias publicitarias a 4.452 preferencias publicitarias probablemente sensibles. A continuación, un grupo de 12 voluntarios clasificó manualmente las 4.452 preferencias publicitarias entre sensibles, en caso de que pudieran asignarse a alguna de las cinco categorías sensibles mencionadas anteriormente, o no sensibles. Cada preferencia publicitaria recibió cinco votos y la mayoría de votos determinó cada preferencia publicitaria como sensible o no sensible. En total, 2.092 de las 4.452 preferencias publicitarias se clasificaron como sensibles. La lista completa de preferencias publicitarias clasificadas como sensibles puede consultarse en el sitio web del FDVT<sup>5</sup>. Nos referimos a este subconjunto de 2.092 preferencias de anuncios como *subconjunto sensible*. Este conjunto fue recogido en enero de 2018 y todavía 2.067 de estas 2.092 preferencias de anuncios potencialmente sensibles seguían estando disponibles dentro del Facebook Ads Manager en febrero de 2019.

En segundo lugar, aprovechamos la API de Facebook Ads Manager para recuperar el porcentaje de usuarios de Facebook en cada país a los que se les había asignado al menos una de las  $N$  (con  $N$  entre 1 y 2.067) preferencias de anuncios potencialmente sensibles del subconjunto presuntamente sensible. En concreto, recuperamos cuántos usuarios de un país determinado están interesados en *interés 1* O *interés 2* O *interés 3...* O *interés  $N$* . Un ejemplo de esto para  $N = 3$  podría ser “cuántas personas en Francia están interesadas en el embarazo O la homosexualidad O el veganismo”. Para el resto del documento hemos definido la siguiente métrica:

- **FFB( $C,N$ )**: porcentaje de usuarios de Facebook en un país  $C$  a los que se les ha asignado al menos una de las  $N$  principales preferencias publicitarias potencialmente sensibles del subconjunto sospechoso. Observamos que  $C$  también puede referirse a todos los países que forman una región concreta (por ejemplo, la UE, Asia-Pacífico, América, etc.). FFB( $C,N$ ) se calcula como la relación entre el número de usuarios de Facebook a los que se ha asignado al menos una de las  $N$  preferencias publicitarias potencialmente sensibles y el número total de usuarios de Facebook en dicho país  $C$ . Por último, es importante señalar que la API de Facebook Ads Manager solamente permite crear audiencias con un máximo de  $N = 1.000$  intereses. Por lo tanto, en la práctica, el valor máximo de  $N$  que podemos utilizar para calcular el FFB es 1.000.

#### 4. RESULTADOS

En este apartado presentamos las principales contribuciones y resultados de esta investigación. Primero, mostramos el porcentaje de usuarios de Facebook y ciudadanos afectados por la asignación de preferencias publicitarias potencialmente sensibles en sus perfiles. Luego, seleccionamos un listado de quince intereses sensibles verificados y mostramos los resultados encontrados. Finalmente, incluimos un análisis comparativo sobre el impacto del RGPD en la asignación de intereses sensibles.

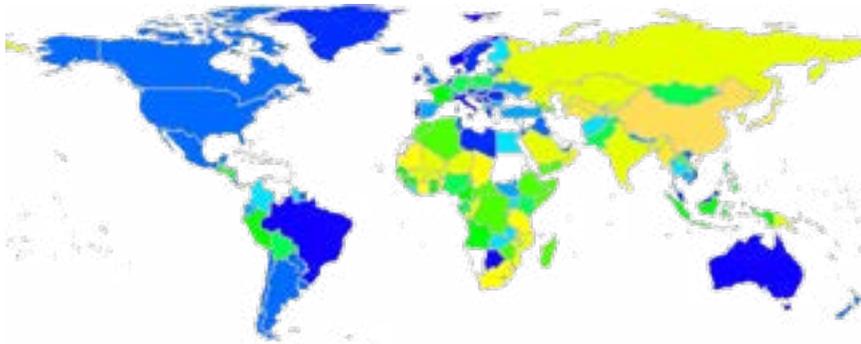
<sup>5</sup> <https://fdvt.org/usenix2018/panelists.html>

#### 4.1. Exposición de los usuarios de Facebook a preferencias publicitarias potencialmente sensibles

En esta investigación hemos calculado el porcentaje de usuarios de Facebook a los que se les ha asignado alguna de las 2.067 preferencias publicitarias potencialmente sensibles para alrededor de 197 países diferentes. La figura 2 muestra el mapa de colores de la métrica FFB(C,1000) para los 197 países analizados en febrero de 2019.

Figura 2.

**Mapa de colores del número de usuarios de Facebook a los que se les han asignado preferencias publicitarias potencialmente sensibles (FFB(C,1000)) para los 197 países analizados en esta investigación**



Fuente: Elaboración propia.

Si tenemos en cuenta los 197 en conjunto, el 67 % de los usuarios de Facebook están etiquetados con alguna preferencia publicitaria potencialmente sensible. Este porcentaje de usuarios se corresponde en realidad con el 22 % de los ciudadanos de los 197 países analiza-

Tabla 1.

**Correlación de Pearson y p\_value entre la métrica FFB y seis indicadores de desarrollo socioeconómico de un país**

Indicador	Correlación con FFB	p_value
Penetración de Facebook	0.544	2.2e-16
Años previstos de escolarización	0.444	7.249e-09
Acceso a un teléfono móvil o Internet en el hogar (% mayores de 15 años)	0.395	1.478e-06
PIB por habitante (USD)	0.381	5.733e-08
Voz y responsabilidad	0.372	1.142e-07
Tasa de natalidad, bruta (por cada 1.000 personas)	-0.455	4.922e-11

Fuente: Elaboración propia.

dos según los datos de población reportados por el Banco Mundial<sup>6</sup>. Sin embargo, podemos ver que la métrica FFB muestra una importante variación entre los distintos países.

En estos resultados descubrimos que el país más afectado es Malta, donde el 82 % de los usuarios de Facebook tienen alguna preferencia publicitaria potencialmente sensible. Por el contrario, el país menos afectado es Guinea Ecuatorial, donde el 37 % de los usuarios de Facebook tienen preferencias publicitarias potencialmente sensibles.

Lo más interesante es que una visión general del mapa parece sugerir que los países occidentales están más expuestos a preferencias publicitarias potencialmente sensibles en comparación con los países asiáticos y africanos. Para cuantificar estos efectos, hemos calculado la correlación de Pearson de la métrica FFB con los siguientes indicadores socioeconómicos: (i) penetración de Facebook; (ii) años previstos de escolarización; (iii) acceso a un teléfono móvil o a Internet en el hogar; (iv) PIB per cápita; (v) voz y responsabilidad, una métrica que mide la libertad de los ciudadanos en el país; y (vi) tasa de natalidad. Obsérvese que los países desarrollados tienden a tener valores más altos en todos los indicadores, excepto en el caso de la tasa de natalidad. Por lo tanto, nuestra hipótesis es que encontraremos una correlación positiva entre la métrica FFB y todos los indicadores con la excepción de la tasa de natalidad. La tabla 1 muestra los resultados de las correlaciones referidas. Obsérvese que en todos los casos los resultados son estadísticamente significativos ya que el *p\_value* más alto es de 1,478e-06.

Los resultados de la tabla 1 corroboran nuestra hipótesis ya que todos los indicadores, excepto la tasa de natalidad, están correlados positivamente con la métrica FFB. En resumen, los resultados validan nuestra observación inicial de que los usuarios de Facebook de los países occidentales desarrollados están más expuestos a ser etiquetados con preferencias publicitarias sensibles que los usuarios de África y Asia. Es interesante observar que en el caso de Sudamérica se observa un patrón similar en el que las economías más poderosas y los países desarrollados como Brasil, Chile y Argentina muestran una mayor exposición a las preferencias publicitarias sensibles que otros países de Sudamérica.

#### 4.2. Exposición de los usuarios de Facebook a preferencias publicitarias muy sensibles

Aunque la legislación trata de definir qué son los datos sensibles, algunas personas podrían pensar que no todos los datos sensibles son igualmente sensibles. Por poner un ejemplo, los datos que revelan la orientación sexual de alguien podrían considerarse más sensibles que los que muestran que un usuario puede estar afectado por una gripe. Por lo tanto, el nivel de sensibilidad de nuestra lista de intereses podría variar en función de la importancia que le dé alguien en particular.

En esta sección, queremos ampliar nuestro análisis creando una lista reducida de intereses que coinciden sin duda con la definición del RGPD para el caso de los datos personales sensibles. Examinamos un subconjunto de quince preferencias publicitarias que han sido verificadas por un experto de la AEPD como intereses que se ajustan perfectamente a la definición de datos personales sensibles del RGPD.

<sup>6</sup> <https://data.worldbank.org>

En el siguiente resultado presentaremos el porcentaje de usuarios en Facebook para cada una de las quince preferencias publicitarias verificadas por el experto y la agregación de las mismas. Dado que es inviable mostrar los resultados para cada uno de los países dentro del documento, los hemos agrupado en cinco continentes: África, América, Asia, Europa y Oceanía. Para obtener los resultados desagregados para cada uno de los 197 países remitimos al lector al siguiente enlace externo<sup>7</sup>.

La tabla 2 muestra la métrica FFB para cada una de las preferencias de anuncios sensibles verificadas por expertos dentro de los cinco continentes. Además, la última fila denominada *Unión* muestra los resultados agregados considerando los quince intereses dentro de un grupo, mientras que la última columna *Mundo* muestra los resultados globales considerando los 197 países. Los resultados describen que, al considerar los 197 países, el 33 % de los usuarios de Facebook, que corresponde a casi el 11 % de los ciudadanos de esos países, han sido etiquetados con alguno de los quince intereses sensibles de la tabla. Como era de esperar a partir de los resultados de la correlación descrita en la sección anterior, Asia y África muestran los valores más bajos de Facebook (27,62 % y 30,43 %, respectivamente). La exposición

Tabla 2.

**Porcentaje de usuarios de Facebook (FFB) dentro de África, América, Asia, Europa y Oceanía que tienen asignada alguna de las preferencias de anuncios sensibles de una lista de quince intereses sensibles verificados por expertos como intereses que incumplen con la RGPD**

<i>Interés</i>	<i>África</i>	<i>América</i>	<i>Asia</i>	<i>Europa</i>	<i>Oceanía</i>	<i>Mundo</i>
Medicina alternativa	3,40	11,35	3,27	7,17	10,82	6,26
Biblia	13,28	14,65	6,31	8,13	14,61	9,68
Budismo	2,87	5,38	10,36	4,13	7,19	7,23
Feminismo	3,22	9,27	2,08	6,52	10,84	5,01
Identidad de género	0,08	0,46	0,07	0,20	0,60	0,21
Homosexualidad	2,66	7,93	2,27	6,07	8,48	4,57
Inmigración ilegal	0,26	0,15	0,02	0,03	0,07	0,08
Judaísmo	11,06	3,72	1,91	2,24	2,44	3,33
Comunidad LGBT	3,93	13,89	5,39	11,94	14,82	8,79
Nacionalismo	1,82	1,11	1,28	1,32	0,95	1,28
Oncología	1,30	1,33	0,38	0,84	0,97	0,81
Embarazo	11,75	19,17	11,58	17,09	21,41	14,71
Salud reproductiva	0,36	0,24	0,17	0,07	0,09	0,19
Prevención del suicidio	0,05	0,30	0,03	0,08	1,02	0,13
Veganismo	5,97	14,18	6,83	16,98	22,78	10,61
Unión	30,43	40,66	27,62	38,25	46,92	33,45

*Notas:* La última columna “Mundo” muestra la métrica FFB para la agregación de los 197 países considerados. La última fila muestra el resultado de las quince preferencias publicitarias agregadas.

*Fuente:* Elaboración propia.

<sup>7</sup> [https://fdvt.org/world\\_sensitivities\\_2019/display\\_sensitivities.html](https://fdvt.org/world_sensitivities_2019/display_sensitivities.html)

de los usuarios de Facebook crece hasta el 38,25 %, 40,66 % y 46,92 % para Europa, América y Oceanía, respectivamente.

Si miramos en detalle algunas de las preferencias publicitarias en la tabla, observamos que la porción de usuarios en los 197 países etiquetados con la preferencia publicitaria “Homosexualidad” es de casi el 5 %. Esta cifra se duplica en el caso de la preferencia publicitaria “Biblia” (relacionada íntimamente con una creencia religiosa concreta) y crece hasta casi el 15 % en el caso de “Embarazo”.

### 4.3. Comparación de la exposición de los usuarios de Facebook de la UE a las preferencias publicitarias potencialmente sensibles antes y después de la aplicación del RGPD

Esta sección tiene como objetivo analizar si la aplicación del RGPD tuvo algún efecto en la utilización de preferencias publicitarias potencialmente sensibles para etiquetar a los usuarios de Facebook en la UE. Para ello, comparamos la exposición de los usuarios de la UE a las preferencias publicitarias potencialmente sensibles en enero de 2018 (Cabañas, Cuevas y Cuevas, 2018) (cinco meses antes de la entrada en vigor del RGPD) con la exposición medida en octubre de 2018 y febrero de 2019 (cinco y nueve meses después de la entrada en vigor del RGPD, respectivamente).

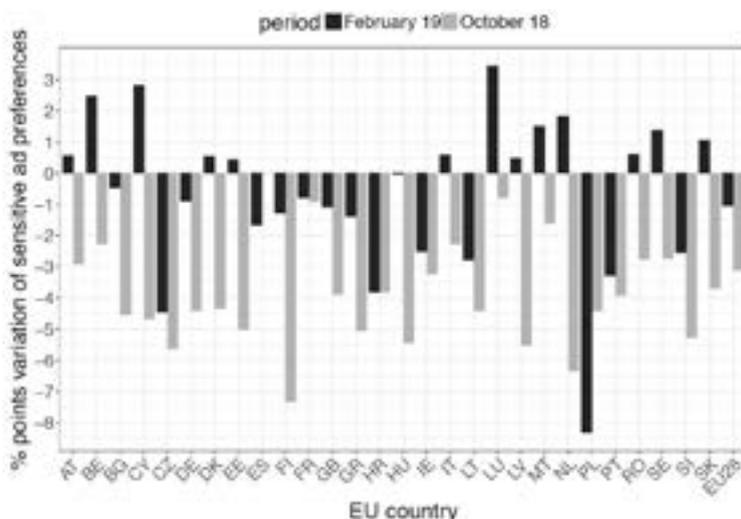
El primer cambio relevante es que Facebook había eliminado 19 preferencias publicitarias en octubre de 2018 y un total de 25 en febrero de 2019 del conjunto de 2.092 preferencias publicitarias potencialmente sensibles que obtuvimos en enero de 2018. Aunque se trata de una cantidad insignificante, cabe destacar que cinco de las preferencias de anuncios eliminadas son: Comunismo, Islam, Corán, Socialismo y Cristianismo. Estas cinco preferencias publicitarias estaban incluidas en un conjunto inicial de 20 preferencias publicitarias verificadas por el experto de la AEPD como muy sensibles. Por lo tanto, parece que Facebook considera algunos intereses muy sensibles como demasiado invasivos y ha decidido eliminarlos de su plataforma publicitaria.

La figura 3 muestra la diferencia de la métrica FFB en puntos porcentuales entre los resultados obtenidos en enero de 2018 y octubre de 2018 (barra gris); y entre enero de 2018 y febrero de 2019 (barra negra) en los 28 países de la UE y toda la UE agregada, etiquetada como EU-28.

Si tenemos en cuenta los resultados de octubre de 2018, observamos que el porcentaje de usuarios etiquetados con preferencias publicitarias potencialmente sensibles fue menor en todos los países de la UE, excepto en España, tras la aplicación del RGPD (en comparación con los datos obtenidos en enero de 2018). Sin embargo, la reducción agregada de la UE es bastante pequeña, solo 3 puntos porcentuales. La mayor reducción es de 7,33 puntos porcentuales en el caso de Finlandia.

Figura 3.

Variación de la métrica FFB en puntos porcentuales para cada país de la UE entre: (i) los datos obtenidos en enero de 2018 y octubre de 2018 (cinco meses antes y cinco meses después de la entrada en vigor del RGPD) representados por la barra gris; (ii) los datos obtenidos en enero de 2018 y febrero de 2019 (cinco meses antes y nueve meses después de la entrada en vigor del RGPD) representados por la barra negra. La última etiqueta (EU-28) representa los resultados de todos los países de la UE juntos



Fuente: Elaboración propia.

El ligero efecto del RGPD observado en los resultados obtenidos en octubre de 2018 parece desaparecer cuando observamos los resultados de febrero de 2019. Hay trece países en los que la porción de usuarios etiquetados con datos potencialmente sensibles es mayor en febrero de 2019 en comparación con enero de 2018. En general, los resultados agregados muestran que el porcentaje de usuarios etiquetados con preferencias publicitarias potencialmente sensibles en febrero de 2019 es solo un 1 % menos que en enero de 2018. En resumen, Facebook parece haber adoptado algunas medidas para eliminar algunas preferencias publicitarias muy invasivas, pero el impacto general del RGPD para evitar que Facebook utilice preferencias publicitarias potencialmente sensibles con fines publicitarios es insignificante.

## 5. RIESGOS ÉTICOS Y DE PRIVACIDAD ASOCIADOS A LA EXPLOTACIÓN DE DATOS PERSONALES SENSIBLES

La posibilidad de llegar a usuarios etiquetados con datos personales potencialmente sensibles puede suponer el uso de campañas de anuncios de Facebook para atacar (por ejem-

plo de odio) a grupos específicos de personas en función de datos personales sensibles (etnia, orientación sexual, creencias religiosas, etc.). Peor aún, en un trabajo previo (Cabañas, Cuevas y Cuevas, 2018), realizamos una estimación aproximada que muestra que, en promedio, un atacante podría recuperar la información personal que identifica a un usuario (*PII*, por sus siglas en inglés) de los usuarios etiquetados con alguna preferencia publicitaria sensible a través de un ataque tipo phishing (Hong, 2012) a un coste barato que oscila entre 0,015 euros y 1,5 euros por usuario, dependiendo del porcentaje de éxito del ataque. A continuación, describimos otros riesgos potenciales asociados a las preferencias publicitarias sensibles. Recientemente, una periodista del *Washington Post* escribió un artículo para denunciar su propia experiencia después de quedarse embarazada<sup>8</sup>. Parece que los algoritmos de Facebook dedujeron esa situación a partir de algunas acciones que la periodista realizó mientras navegaba en Facebook. Probablemente Facebook la etiquetó con la preferencia publicitaria “embarazo” o alguna otra similar y empezó a recibir anuncios relacionados con el embarazo. Desgraciadamente, la periodista tuvo un parto prematuro, pero siguió recibiendo anuncios relacionados con el embarazo, lo que la expuso a una experiencia muy incómoda.

Otro grave riesgo, muy preocupante a nuestro juicio, está relacionado con el hecho de que muchos usuarios de Facebook son etiquetados con el interés “Homosexualidad” en países donde ser homosexual es ilegal y puede ser castigado incluso con la pena de muerte. Todavía hay 78 países en el mundo en los que la homosexualidad está penalizada<sup>9</sup> y en algunos de ellos donde la pena de muerte es el máximo castigo. La tabla 3 muestra los resultados de la métrica FFB solo considerando el interés “Homosexualidad” en los países que penalizan la homosexualidad con la muerte. Por ejemplo, en el caso de Arabia Saudí encontramos que Facebook asigna la preferencia de anuncio “Homosexualidad” a 540 mil personas (2,08 % de

Tabla 3.

**Porcentaje de usuarios de Facebook (FFB) etiquetados con el interés “Homosexualidad” en países donde ser homosexual puede llevar a la pena de muerte**

<i>Code</i>	<i>Country</i>	<i>Homosexuality</i>	<i>Code</i>	<i>Country</i>	<i>Homosexuality</i>
AF	Afghanistan	12,31	BN	Brunei	5,24
MR	Mauritania	0,99	NG	Nigeria	2,35
QA	Qatar	2,35	SA	Arabia Saudi	2,08
SO	Somalia	1,44	YE	Yemen	1,08
PK	Pakistan	1,54	IQ	Iraq	3,20
AE	United Arab Emirates	3,00			

*Nota:* No incluimos a Irán ni a Sudán porque Facebook no proporciona información sobre estos países.

*Fuente:* Elaboración propia.

<sup>8</sup> <https://www.washingtonpost.com/lifestyle/2018/12/12/dear-tech-companies-i-dont-want-see-pregnancy-ads-after-my-child-was-stillborn/>

<sup>9</sup> [https://ilga.org/downloads/2017/ILGA\\_WorldMap\\_ENGLISH\\_Criminalisation\\_2017.pdf](https://ilga.org/downloads/2017/ILGA_WorldMap_ENGLISH_Criminalisation_2017.pdf)

los usuarios de Facebook en ese país). En el caso de Nigeria, 620 mil personas (el 2,35 % de los usuarios de Facebook en ese país).

Reconocemos que el debate sobre lo que es sensible y lo que no es complejo. Sin embargo, creemos que Facebook debería tomar medidas inmediatas para evitar situaciones preocupantes como las expuestas en esta sección, en la que Facebook puede exponer involuntariamente a los usuarios a graves riesgos. Por ejemplo, una acción directa consistiría en dejar de utilizar la preferencia publicitaria “Homosexualidad” (o similares), al menos en países donde la homosexualidad está penada.

## 6. FUNCIONALIDAD DE LA EXTENSIÓN FDVT QUE PERMITE A LOS USUARIOS ELIMINAR LAS PREFERENCIAS PUBLICITARIAS POTENCIALMENTE SENSIBLES

Los resultados expuestos en los apartados anteriores motivan la necesidad de encontrar soluciones que conciencien a los usuarios del uso de datos personales sensibles con fines

Figura 4.

**Captura de pantalla de la nueva funcionalidad del FDVT que permite a los usuarios borrar sus preferencias publicitarias**

**Checking & Deleting Sensitive Ad Preferences**

**Total #Ad Preferences: Active: 4 - Removed: 2 - Inactive: 2**

Preference Name	Topic	Sensitive	Remove	More Info	Status
Homosexuality	Lifestyle and culture	Sensitive	Delete Ad Preference	More Info	ACTIVE
Democracy	Lifestyle and culture	Sensitive	Delete Ad Preference	Less Info	ACTIVE
<b>HISTORICAL INFORMATION</b>					
<i>This ad preference appeared in your profile in the following periods:</i>					
From 2016-09-16 to 2016-09-20. Reason: You have this preference because you clicked on an ad related to Democracy.					
From 2019-01-14 to NOWADAYS. Reason: You have this preference because you liked a Page related to Democracy.					
Coupons	Shopping and fashion	Non-Sensitive	Delete Ad Preference	More Info	ACTIVE
Shopping	Shopping and fashion	Non-Sensitive	Delete Ad Preference	More Info	ACTIVE
Universidad de Chile	Removed interests	Non-Sensitive		More Info	REMOVED
Televisions	Removed interests	Non-Sensitive		More Info	REMOVED
Real Madrid C.F.	Sports and outdoors	Non-Sensitive		More Info	INACTIVE
TripAdvisor	Business and industry	Non-Sensitive		Less Info	INACTIVE
<b>HISTORICAL INFORMATION</b>					
<i>This ad preference appeared in your profile in the following periods:</i>					
From 2016-09-16 to 2016-09-20. Reason: You have this preference because we think it may be relevant to you based on what you do on Facebook, such as pages you've liked or ads you've clicked.					

Fuente: fdvt.org

publicitarios. Además, también es importante capacitarlos para que puedan eliminar de forma muy sencilla aquellas preferencias publicitarias sensibles con las que no se sientan cómodos. Desgraciadamente, el proceso actual que Facebook ofrece es desconocido y complejo para la mayoría de los usuarios. Con este fin, hemos ampliado la extensión del navegador FDVT para (i) informar a los usuarios sobre las preferencias publicitarias potencialmente sensibles que Facebook les ha asignado; tanto las activas como las que se les asignaron en el pasado y que ya no están activas en la actualidad, y (ii) permitir a los usuarios eliminar con un solo clic todas las preferencias publicitarias sensibles activas o aquellas con las que los usuarios no se sientan cómodos.

Hemos introducido un nuevo botón en la interfaz del FDVT con el texto "Sensitivity of my FB interests". Cuando un usuario hace clic en ese botón, se le muestra una página que enumera en la parte superior los intereses potencialmente sensibles incluidos en el conjunto de intereses del usuario (tanto los activos como los inactivos). La figura 4 muestra un ejemplo de esta página. En ella, la siguiente información para cada interés es proporcionada: (i) Nombre de la preferencia publicitaria, (ii) Tema y (iii) Sensibilidad, si la preferencia publicitaria es potencialmente sensible (resaltada en amarillo) o no. Además, junto a cada preferencia publicitaria hay un botón *Borrar preferencia publicitaria* para eliminar individualmente esas preferencias publicitarias. Además, se dispone también de otro botón *Más información* para mostrar individualmente la información histórica del interés, que incluye el periodo o periodos en los que la preferencia de anuncios ha estado activa y la razón por la que Facebook ha asignado ese interés al usuario. Por último, en la parte superior de la página incluimos una barra de búsqueda para buscar preferencias específicas y dos botones: *Eliminar todos los intereses sensibles* y *Eliminar todos los intereses* para eliminar todas las preferencias de anuncios potencialmente sensibles activas y todas las activas, respectivamente.

## 7. TRABAJOS RELACIONADOS

En esta sección vamos a inspeccionar los trabajos que tienen relación con esta investigación. Primero, es importante mencionar que con anterioridad a esta investigación publicamos un artículo (Cabañas, Cuevas y Cuevas, 2018) en el que ya analizábamos el uso de la información sensible en Facebook. Ese trabajo solamente se centraba en la Unión Europea unos meses antes de la entrada en vigor del RGPD. La comunidad investigadora nos pidió en varios foros que sería interesante ampliar nuestro análisis para (i) cubrir el uso de información sensible en Facebook en todo el mundo y no solo en la UE, y (ii) entender el impacto potencial que el RGPD podría tener en la reducción de la exposición de los usuarios a las preferencias de anuncios sensibles. Este documento cubre ambas peticiones y, además, añade dos aportaciones más: (i) presentamos dos escenarios claros en los que el uso de preferencias publicitarias sensibles podría tener graves consecuencias para los usuarios, y (ii) introducimos una mejora del FDVT que permite a los usuarios eliminar de forma sencilla las preferencias publicitarias potencialmente sensibles que no les gusten. Por lo tanto, este artículo contribuye con una visión notablemente más amplia que nuestro trabajo anterior.

Continuando con la inspección de trabajos relacionados, hay pocos trabajos anteriores en la literatura que aborden cuestiones relacionadas con los datos personales sensibles en la publicidad *online*. Existen, sin embargo, algunos trabajos recientes que analizan cuestiones de privacidad y discriminación relacionadas con la publicidad en Facebook y las preferencias publicitarias.

Carrascosa *et al.* (2015) proponen una nueva metodología para cuantificar la proporción de anuncios dirigidos que reciben los usuarios de Internet mientras navegan por la web. Crean *bots*, denominados *personas*, con perfiles de intereses muy específicos (por ejemplo, persona interesada en los coches) y miden cuántos de los anuncios recibidos coinciden realmente con el interés específico de la persona analizada. Crean personas basadas en datos personales sensibles (por ejemplo salud) y demuestran que también se les dirigen anuncios relacionados con información sensible utilizada para crear el perfil de la persona.

Castellucia, Kaafar y Tran (2012) demuestran que un atacante que obtiene acceso (a través de una red WiFi pública, por ejemplo) a los anuncios de Google recibidos por un usuario podría crear un perfil de intereses que podría revelar hasta un 58 % de los intereses reales del usuario. Los autores afirman que si algunos de los intereses desvelados son sensibles, esto podría implicar graves riesgos para la privacidad de los usuarios.

Venkatadri *et al.* (2018) y Speicher *et al.* (2018) expusieron vulnerabilidades de privacidad y discriminación relacionadas con la publicidad de Facebook. En Venkatadri *et al.* (2018), los autores demuestran cómo un atacante puede utilizar JavaScript de seguimiento de terceros de Facebook para recuperar datos personales (por ejemplo, números de teléfono móvil) asociados a los usuarios que visitan el sitio web del atacante. Además, en Speicher *et al.* (2018) demuestran que las preferencias publicitarias sensibles de Facebook pueden utilizarse para aplicar una discriminación negativa en las campañas publicitarias (como puede ser excluyendo a personas por su raza). Los autores también demuestran que algunas preferencias de anuncios que inicialmente pueden no parecer sensibles se podrían utilizar realmente para discriminar en campañas publicitarias (por ejemplo excluyendo personas interesadas en el sitio web *Blacknews.com* pues asumen que serían potencialmente de raza negra).

## 8. CONCLUSIONES

Facebook ofrece a los anunciantes la opción de explotar comercialmente información potencialmente sensible para realizar campañas publicitarias a medida. Esta práctica se encuentra, en el mejor de los casos, dentro de un área legal gris según el RGPD. Nuestros resultados revelan que el 67 % de los usuarios de Facebook (el 22 % de los ciudadanos) de todo el mundo están etiquetados con alguna preferencia publicitaria potencialmente sensible. Curiosamente, los usuarios de los países más desarrollados presentan una exposición significativamente mayor a que se les asignen preferencias publicitarias sensibles. Nuestro trabajo también revela que la aplicación del RGPD tuvo un impacto insignificante en Facebook con respecto al uso de preferencias publicitarias sensibles dentro de la UE. Creemos que es

urgente que las partes interesadas en el ecosistema de la publicidad en línea (es decir, anunciantes, redes publicitarias, editores, responsables políticos, etc.) definan una lista inequívoca de datos personales que no deben seguir utilizándose para proteger a los usuarios de posibles riesgos para su privacidad como los descritos en este trabajo.

## Referencias

- CABAÑAS, J. G., CUEVAS, A. y CUEVAS, R. (2017). FDVT: Data Valuation Tool for Facebook users. En: *Proceedings of the 2017 CHI Conference on Human Factors in Computing Systems*, CHI '17 (pp. 3799–3809). New York: ACM.
- CABAÑAS, J. G., CUEVAS, Á. y CUEVAS, R. (2018). Unveiling and quantifying Facebook exploitation of sensitive personal data for advertising purposes. En: *27<sup>th</sup> USENIX Security Symposium (USENIX Security 18)* (pp. 479–495). Baltimore, MD.: USENIX Association.
- CARRASCOSA, J. M., MIKIANS, J., CUEVAS, R., ERRAMILI, V. y LAOUTARIS, N. (2015). I always feel like somebody's watching me: Measuring online behavioural advertising. En: *Proceedings of the 11<sup>th</sup> ACM Conference on Emerging Networking Experiments and Technologies*, CoNEXT '15 (pp. 13:1–13:13). New York: ACM.
- CASTELLUCCIA, C., KAAFAR, M.-A. y TRAN, M.-D. (2012). Betrayed by your ads! En: *International Symposium on Privacy Enhancing Technologies Symposium* (pp. 1–17). Berlin, Heidelberg. Springer: Springer Berlin Heidelberg.
- EMARKETER.COM (2017). Google and Facebook tighten grip on us digital ad market. <https://www.emarketer.com/Article/Google-Facebook-Tighten-Grip-on-US-Digital-Ad-Market/1016494>
- EU (27 April 2016). Regulation (EU) 2016/679 of the European Parliament and of the Council of 27 april 2016 on the protection of natural persons with regard to the processing of personal data and on the free movement of such data, and repealing directive 95/46/ec (General Data Protection Regulation). <http://eur-lex.europa.eu/eli/reg/2016/679/oj>
- HONG, J. (2012). The state of phishing attacks. *Commun. ACM*, 55(1), pp. 74–81.
- INTERNETSOCIETY.ORG (2016). The Internet Society Survey on Policy Issues in Asia-Pacific 2016. [https://www.internetsociety.org/wp-content/uploads/2017/08/APAC\\_Regional\\_Policy\\_Survey\\_Report\\_2016\\_final\\_copy\\_compressed.pdf](https://www.internetsociety.org/wp-content/uploads/2017/08/APAC_Regional_Policy_Survey_Report_2016_final_copy_compressed.pdf)
- JANRAIN.COM (2018). Consumer Attitudes Toward Data Privacy Survey 2018. <https://www.janrain.com/resources/industry-research/consumer-attitudes-toward-data-privacy-survey-2018>
- LEGISLATURE, C. S. (2018). California Consumer Privacy Act. <https://www.caprivacy.org/>
- OPINION, T. AND SOCIAL (2015). Special eurobarometer 431 data protection. [http://ec.europa.eu/commfrontoffice/publicopinion/archives/ebs/ebs\\_431\\_en.pdf](http://ec.europa.eu/commfrontoffice/publicopinion/archives/ebs/ebs_431_en.pdf)
- PWC.IN (2018). Privacy in the Data Economy. <https://www.pwc.in/assets/pdfs/publications/2018/privacy-in-the-data-economy.pdf>
- SPEICHER, T., ALI, M., VENKATADRI, G., RIBEIRO, F. N., ARVANITAKIS, G., BENEVENUTO, F., GUMMADI, K. P., LOISEAU, P. y MISLOVE, A. (2018). Potential for discrimination in online targeted advertising. En: S. A. FRIEDLER y C. WILSON (editors), *Proceedings of the 1st Conference on Fairness, Accountability and Transparency*, volume 81 of *Proceedings of Machine Learning Research* (pp. 5–19). New York, NY, USA.: PMLR.
- VENKATADRI, G., LIU, Y., ANDREOU, A., GOGA, O., LOISEAU, P., MISLOVE, A. y GUMMADI, K. P. (2018). Privacy risks with Facebook's PII-based targeting: Auditing a data broker's advertising interface. En: *S&P 2018, IEEE Symposium on Security and Privacy* (pp. 89–107). San Francisco, CA, USA: IEEE.

## CAPÍTULO VII

## RSC 2.0: La comunicación entre empresas y *stakeholders* en redes sociales

Pablo Gómez Carrasco  
Encarna Guillamón Saorín

Desde de la crisis financiera de 2008, el sector bancario español se ha enfrentado a un escenario inédito en el que los consumidores están más sensibilizados con la ética en las finanzas, y donde la Responsabilidad Social Corporativa (RSC) se convierte en una herramienta fundamental para adaptarse a las nuevas condiciones del mercado y protegerse del elevado riesgo reputacional. Por otro lado, en los últimos años las redes sociales han cobrado una gran relevancia en todos los ámbitos de las relaciones sociales y, en particular, en la relación de las empresas con sus grupos de interés o *stakeholders*.

En este trabajo planteamos un análisis de la comunicación sobre RSC a través de las redes sociales, concretamente de la red de *microblogging* Twitter. Con la ayuda de una herramienta de *software*, realizamos un análisis de contenido de todos los mensajes asociados con cada una de las entidades, que representan la práctica totalidad de los activos del sector bancario español. Nuestra clasificación parte de la distinción entre RSC Central (*Core CSR*) y Complementaria (*Supplementary CSR*) y, posteriormente, se divide en aquellas cuestiones que las entidades de crédito consideran clave en sus memorias de sostenibilidad.

Encontramos que las redes sociales son un entorno propicio para el estudio de cuestiones relacionadas con la RSC por la gran cantidad de contenidos que se generan sobre aspectos relativos a la relación entre empresas y *stakeholders*. Podemos concluir que la estrategia de comunicación de las entidades bancarias no está alineada con los intereses de sus *stakeholders* externos. Este hallazgo pone de manifiesto que las redes sociales son un medio de difícil control por parte de las empresas y constituye, asimismo, la principal implicación del trabajo para la práctica empresarial, evidenciando que las empresas no están aprovechando el potencial de este canal de comunicación, que permite una interacción permanente con los *stakeholders*, y siguen empleando estrategias tradicionales de comunicación unidireccional.

*Palabras clave:* Responsabilidad Social Corporativa (RSC), *stakeholders*, redes sociales, Twitter, RSC Central, RSC Complementaria.

## 1. INTRODUCCIÓN

En los últimos años las redes sociales han cobrado una gran relevancia en todos los ámbitos de las relaciones sociales y, en particular, en la relación de las empresas con sus grupos de interés. Internet y muy especialmente las redes sociales han democratizado los procesos de diálogo entre empresas y *stakeholders* (grupos de interés), convirtiéndose en medios de comunicación para informaciones, críticas, quejas, recomendaciones y todo tipo de comentarios que buscan informar sobre un determinado producto, marca o empresa, e incluso influir en el comportamiento y actitudes de los usuarios y consumidores hacia ellos (Coombs, 1998; Jansen *et al.*, 2009). Es importante entender el rol de cada grupo de interés para la empresa y cómo puede actuar a favor o en contra de la misma. Las estrategias de *marketing* digital de la empresa ayudan a fortalecer las relaciones con los distintos *stakeholders* que contribuyen a mejorar la situación de la empresa en situaciones difíciles o tiempos de crisis.

Este fenómeno coincide con una cada vez mayor sensibilización y movilización por parte de los ciudadanos en lo relativo al impacto social de la actividad empresarial. Una mayor preocupación que empieza a reflejarse en la actividad legislativa, por ejemplo, la Unión Europea aprobó en 2014 una directiva sobre información no financiera que en España ha dado lugar a la Ley 11/2018 obligando a grandes empresas y entidades de interés público a publicar información social y medioambiental relevante en sus informes de gestión.

En este trabajo estudiaremos la confluencia de ambos fenómenos en la actividad empresarial sobre la base del marco teórico desarrollado en el artículo de Gómez-Carrasco, Guillamón-Saorín y García Osma (2016). De esta forma determinaremos si en las redes sociales hay una mayor presencia de información sobre Responsabilidad Social Corporativa (RSC) Central (*Core CSR*), esto es, la directamente relacionada con la actividad principal de una compañía o, por el contrario, predomina la información sobre actividades de acción social, cultural y/o medioambiental, desligadas de la actividad principal y que en nuestro marco teórico hemos denominado RSC Complementaria (*Supplementary CSR*). Asimismo, analizaremos si la información sobre RSC difundida por las empresas coincide con los asuntos que preocupan a sus grupos de interés. De esta forma, las empresas dispondrán de una herramienta para orientar sus políticas de RSC hacia aquellos aspectos de mayor interés para sus *stakeholders* y podrán optimizar el impacto de éstas en términos de reputación corporativa.

Hemos elegido el sector bancario español para la realización de este estudio, por tratarse de una actividad empresarial con un elevado impacto social, en especial tras la crisis financiera iniciada en España en 2008, como demuestra el hecho de que por vez primera las entidades de crédito apareciesen entre las principales preocupaciones de los españoles desde el barómetro del Centro de Investigaciones Sociológicas de junio de 2012. Este hecho se ha unido a la aparición de crecientes indicios de la existencia de un cambio de mentalidad en torno a la ética en las finanzas, que se ha traducido también en modificaciones en el comportamiento de los consumidores de productos y servicios financieros. La denominada “banca ética” que, si bien sigue teniendo un peso poco significativo en el sistema bancario español, ha visto cómo sus depósitos crecían exponencialmente en los últimos años. Según el Obser-

vatorio de la Asociación Finanzas Éticas y Solidarias (FETS), en el periodo 2008-2012, los activos depositados en estas entidades se multiplicaron por 4,5 hasta rozar los mil millones de euros. Además, la desaparición de numerosas cajas de ahorros y su obra social ha dejado un importante vacío en el mercado que ahora otras entidades buscan ocupar.

El sector bancario español se enfrenta a un escenario inédito en el que los consumidores están más sensibilizados con la ética en las finanzas y donde la RSC se convierte en una herramienta fundamental para que las entidades de crédito se adapten a las nuevas condiciones del mercado. Nos encontramos, por tanto, ante un entorno de máximo riesgo reputacional para el sector, que ha de buscar necesariamente estrategias para mitigarlo.

## 2. REVISIÓN DE LA LITERATURA Y PREGUNTAS DE INVESTIGACIÓN

En un entorno de movilización social potenciado por las nuevas tecnologías de la información y la comunicación, el diálogo con los *stakeholders* se presenta como una estrategia esencial para la estabilidad financiera de las empresas (Vasi y King, 2012; Morsing y Schultz, 2006; Ruf *et al.*, 2001). El activismo social gana fuerza y presencia en internet (Yang, 2013; Kahn y Kellner, 2004), como demuestra el hecho de que la plataforma de activismo *online* Change.org cuenta con más de 200 millones de usuarios en 196 países<sup>1</sup>. Un claro ejemplo de su poder de presión es el caso de la petición realizada en Change.org por parte de una cliente de Bank of America (el segundo mayor grupo bancario de los Estados Unidos), que solicitaba la supresión de una comisión de 5 dólares mensuales que la entidad había comenzado a aplicar por el uso de sus tarjetas de débito. Esta petición consiguió más de 300.000 adhesiones en un mes, y finalmente la entidad se vio obligada a ceder a las presiones eliminando la comisión bancaria por ese servicio<sup>2</sup>.

King y Soule (2007) demostraron empíricamente que las protestas de grupos de activistas tienen una influencia negativa sobre la cotización de los valores de una empresa cuando se involucra a los principales grupos de interés de la empresa y se genera un alto impacto en los medios de comunicación. Estas dos premisas se cumplen en el entorno de las redes sociales, ya que se trata de plataformas con una gran presencia de grupos de activistas que consiguen una rápida difusión de sus protestas. Por otro lado, King (2008) afirma que las empresas que han sufrido recientemente un descenso en sus ventas o afrontan problemas de reputación son más sensibles a los efectos de un potencial boicot por parte de grupos de activistas y, por tanto, presentan una mayor predisposición a ceder ante las presiones. Este elevado riesgo reputacional, como ya hemos comentado anteriormente, se da en la actualidad en el sector bancario español, por lo que consideramos relevante analizar la manera en que estas entidades y sus grupos de interés utilizan la información en las redes sociales para, en fases posteriores de nuestra investigación, determinar el impacto que esta información puede tener sobre el

<sup>1</sup> Página web de la plataforma de activismo *online* Change.org (<http://www.change.org/about>).

<sup>2</sup> Change.org: Petición: "Tell Bank of America: No \$5 Debit Card Fees" (<http://www.change.org/petitions/tell-bank-of-america-no-5-debit-card-fees>).

desempeño financiero de las entidades de crédito, y si condiciona de alguna manera la toma de decisiones en las empresas afectadas.

Aunque por el momento hay pocos estudios acerca del efecto que la información en redes sociales puede tener en la práctica empresarial, los primeros datos al respecto apuntan a que estos medios de comunicación ya influyen en determinados aspectos del desempeño empresarial, así Blankespoor, Miller y White (2014) demuestran que la utilización de Twitter por parte de determinadas empresas para difundir su información incrementa la liquidez de sus títulos. Bollen, Mao y Zheng (2011) y Zhang, Fuebres y Gloor (2011) encuentran una correlación entre el sentimiento en Twitter y diversos indicadores en los mercados de valores que los llevan a plantear que esta red de *microblogging* podría servir para predecir movimientos futuros en los mercados de valores. Por otro lado, Jansen *et al.* (2009) concluyen que esta popular red de *microblogging* se ha convertido en un importante canal para el “boca a boca” de los clientes y recomiendan a las empresas tenerlo en cuenta en el diseño de sus estrategias de *marketing*. Kane *et al.* (2009) analizan el cambio que está teniendo lugar en las relaciones de las empresas con su entorno debido a la aparición de las redes sociales y cómo están cambiando las reglas del juego, ya que este nuevo escenario potencia la interacción de las empresas con sus *stakeholders* y demanda de una comunicación inmediata y coherente por parte de las empresas para prevenir daños en su reputación. Culnan, McHugh y Zubillaga (2010) profundizan en la idea de la necesidad de una gestión eficiente de la relación de las compañías con sus *stakeholders* en el entorno virtual y realizan una serie de recomendaciones a tener en cuenta en la estrategia de comunicación 2.0 para que esta repercuta positivamente en el valor de la empresa.

### 2.1. Gestión de los *stakeholders* y tipos de RSC

Desde el punto de vista de la gestión de los *stakeholders*, las empresas pueden responder a las preocupaciones sobre temas de RSC a través de las redes sociales. Es posible que la comunicación de RSC en las redes sociales se utilice de manera oportunista como un instrumento para lograr legitimidad y reparación del daño a la reputación, en lugar de como un medio para comprender los intereses de los *stakeholders* y hacer una gestión eficiente de los mismos. Ciertos tipos de RSC se prestan a estas últimas prácticas, donde el potencial para la gestión de las partes interesadas probablemente dependa de la relación subyacente entre la RSC y las actividades comerciales centrales (por ejemplo, Jenkins, 2009; Pelozo, 2006; Porter y Kramer, 2002; Porter y Kramer, 2006). Burke y Logsdon (1996, p. 496) sostienen que la RSC “es estratégica cuando produce beneficios sustanciales relacionados con la actividad principal de la empresa, en particular al respaldar actividades comerciales centrales y, por lo tanto, contribuir a la eficacia de la empresa para lograr sus objetivos”. Estas actividades de “responsabilidad social básica” tienen consecuencias positivas y, por tanto, la información sobre la RSE básica es probable que sea más creíble.

Sin embargo, a menudo, las acciones de RSC están desconectadas del negocio principal, como las actividades filantrópicas (Brammer y Millington, 2008; Seifert, Morris y Bartkus,

2004; Wang, Choi y Li, 2008). Estas actividades de “RSC complementarias” se relacionan con la acción social, cultural y/o proyectos ambientales a menudo canalizados estratégicamente a través de fundaciones benéficas (Petrovits, 2006). Estos programas generalmente carecen de enfoque y coherencia, lo que reduce su impacto social y efecto positivo en la competitividad a largo plazo (Porter y Kramer, 2002; 2006). Sin embargo, las actividades filantrópicas gozan de una gran visibilidad en los medios a través de patrocinios y/o *marketing* relacionado con una causa (McAlister y Ferrell, 2002). Por lo tanto, la información complementaria de RSC se ajusta a las teorías identificadas por Downling y Pfeffer (1975) y Deegan (2002) sobre las acciones que las empresas toman para mantener la legitimidad, y en particular, con intentos de: 1) cambiar las percepciones de las partes interesadas, sin cambiar el comportamiento real de la empresa, y 2) manejar las percepciones desviando la atención de los temas de interés a otros temas afines, en este caso, a la acción filantrópica. Al divulgar la RSE complementaria, las empresas pueden llamar la atención sobre la acción filantrópica, mientras que descuidan o minimizan la información relativa a implicaciones negativas de sus actividades (Gómez-Carrasco, Guillamón-Saorín y García Osma, 2016).

## 2.2. Comunicación RSC y tipos de *stakeholders*

Teniendo en cuenta la evidencia en la literatura anterior, esperamos que los miembros de las empresas comuniquen RSC tanto básica como complementaria en las redes sociales. Sin embargo, como es probable que usen las redes sociales por motivos de legitimidad, esperamos que se centren en cuestiones complementarias de RSC. Esto incluye promover su faceta filantrópica para reparar y mantener su legitimidad, particularmente cuando se discuten noticias negativas sobre la empresa. Esta expectativa está en línea con las conclusiones de Yang y Liu (2017), quienes encuentran que, al revelar información financiera en Twitter, las empresas tienden a minimizar la información negativa y a enfatizar la información positiva. Por el contrario, los *stakeholders* externos (medios de comunicación, administraciones públicas, organizaciones no gubernamentales, asociaciones cívicas, sindicatos y usuarios individuales de Twitter) se espera que utilicen las redes sociales para recopilar información sobre cuestiones fundamentales de RSC que les preocupen y que quieren que las empresas mejoren (Kietzmann *et al.*, 2011, p. 250). Por lo tanto, esperamos que las partes interesadas externas prefieran comunicación relacionada con las cuestiones fundamentales de RSC casi exclusivamente. Esto será particularmente cierto cuando haya noticias que llegan al mercado sobre las implicaciones negativas de las actividades de la empresa.

Sobre la base de estos planteamientos, planteamos las siguientes preguntas de investigación:

- ¿Cuál es la importancia de la RSC de las empresas en las comunicaciones que tienen lugar en Twitter?
- ¿Cuáles son los aspectos de la RSC que provocan un mayor interés para los *stakeholders*? ¿Y para las compañías? ¿En qué se diferencia la comunicación entre los distintos tipos de usuarios?

### 3. METODOLOGÍA

Para dar respuesta a las preguntas de investigación calcularemos la proporción de *tweets* asociados a alguna de las categorías de nuestro esquema de RSC sobre el total de *tweets* relacionados con las entidades analizadas en el periodo de estudio. Posteriormente, estudiaremos la comunicación de las cuentas de usuarios dividiéndolas en internas y externas en función de su relación con las entidades analizadas. Analizaremos el contenido de sus mensajes sobre la base de nuestro marco teórico de RSC, que diferencia las acciones de RSC en función de su conexión con el negocio principal. De esta forma, podremos determinar si la comunicación de las cuentas internas de las compañías está alineada con los intereses de los *stakeholders* o, por el contrario, presenta intereses divergentes.

Analizaremos la estrategia de comunicación de las entidades bancarias españolas en redes sociales. Para ello utilizaremos la información vinculada al nombre de las distintas entidades en la red social de *microblogging* Twitter. Twitter inició su actividad en julio de 2006 y cuenta actualmente con más de 300 millones de usuarios activos en todo el mundo. Además de su expansión, Twitter ofrece otra ventaja fundamental para nuestro análisis, la concreción de sus mensajes, que se encuentran limitados a un máximo de 280 caracteres (140 en el momento del estudio) facilitando así el análisis del contenido esencial de cada uno de los *tweets* asociados a las entidades.

A continuación, detallamos el proceso completo mediante el cual recogemos y analizamos la información asociada al impacto social de las entidades que componen el sistema bancario español, en el que distinguimos cinco fases:

- *Almacenamiento de información* (*tweets*). El *software* que utilizamos realiza capturas constantes de *tweets* desde la Twitter “application program interface” (API) en función de los términos de búsqueda que hemos introducido, hasta 400 por dirección IP. Cada *tweet* queda almacenado en una base de datos en *Structured Query Language* (SQL), incorporando la siguiente información: a) término de búsqueda; b) código identificador del *twittero*; c) fecha y hora exacta del *tweet*; d) vínculo del *tweet* con otro anterior (*retweet* o respuesta), y e) mensaje o *tweet* propiamente dicho.
- *Extracción de tweets*. Nuestros términos de búsqueda son los nombres de las entidades bancarias que hemos seleccionado para analizar y que representan la práctica totalidad del sector bancario español. Los datos financieros se han obtenido de Bankscope tomando en cuenta las cifras de cierre del ejercicio 2012, ya que eran las últimas disponibles para todas las entidades en el momento en que delimitamos el sector. Las 41 entidades analizadas representan el 95,9 % de los activos bancarios en España y abarcan todas las categorías de entidades de crédito que reconoce el Banco de España: bancos, cajas de ahorros, cooperativas de crédito y entidades bancarias extranjeras. Debido a la importante reestructuración que ha sufrido el sector bancario español en los últimos años, la categoría de cajas de ahorros representa realmente a las antiguas cajas de ahorro reconvertidas en bancos. Todos los *tweets* capturados

en el periodo analizado, que en este caso abarca desde el 14 de noviembre de 2013 al 17 de febrero de 2014, se vuelcan en un fichero con el formato CSV (del inglés, *comma-separated values*). Posteriormente, subimos el fichero a la aplicación que nos permite procesar la información dando lugar a un corpus de *tweets* ya codificados en base a nuestra metodología.

- *Filtrado de contenidos.* Con anterioridad a la creación del corpus se eliminan las palabras sin significado (preposiciones, conjunciones, determinantes, etc.) o “stopwords” y se filtran todas aquellas palabras, *twitteros* y *hashtags* que introducen información no directamente relacionada con la actividad de la entidad, normalmente derivadas de una acción publicitaria o de patrocinio llevada a cabo por la entidad financiera. Por ejemplo, en el caso de BBVA, que patrocinaba en ese momento la Liga de Fútbol Profesional (LFP) española, hay multitud de mensajes asociados con la liga de fútbol y que incluyen la palabra “BBVA” sin que en ningún caso el mensaje haga referencia a la entidad, ya que hablan de partidos concretos, fichajes, arbitrajes, etcétera.
- *Creación del corpus.* El *software* convierte el fichero de *tweets* en una lista de palabras ordenadas de mayor a menor frecuencia de aparición. Estas palabras, que agrupan a todo el conjunto de *tweets* en los que aparecen, constituyen la unidad fundamental para realizar nuestro análisis de contenido. El proceso es el mismo para *hashtags* (palabras precedidas del símbolo #, que son etiquetadas de esta forma para conseguir una mayor visibilidad). En cuanto al análisis de *twitteros*, estos aparecen ordenados en el listado de mayor a menor grado de participación (ya sea porque los escriben o porque son mencionados en ellos) en *tweets* que contengan el nombre de la entidad o cualquiera de los términos de búsqueda asociados. El programa informático en este caso presenta una limitación, ya que el fichero con el que se elabora el corpus de palabras puede contener un máximo de 5.000 *tweets*. En el caso de que el fichero asociado a una determinada entidad supere esta cifra, lo que suele ocurrir con la banca mediana y la gran banca dependiendo de la amplitud del periodo de análisis, el programa realiza un muestreo aleatorio de 5.000 *tweets* para elaborar el corpus y posteriormente aplica el trabajo de codificación a todo el fichero. No obstante, el tamaño de esta muestra garantiza que será representativa para una población infinita de *tweets* con un nivel de confianza del 95 % y un error muestral asociado de 1,386 %.
- *Proceso de codificación manual.* Consiste en ir asociando esas palabras, *hashtags* y *twitteros* a cada uno de los criterios que hemos creado en función de nuestro marco teórico, que parte de la distinción entre RSC Central y Complementaria. Tanto para la identificación de los *stakeholders* clave como de los criterios asociados en el marco de la RSC, hemos tenido en cuenta la información proporcionada por todas las entidades en sus informes de RSC y definido un marco común para todas. Los criterios son los mismos para palabras y *hashtags* y están basados en impactos de las entidades bancarias sobre sus principales grupos de interés o *stakeholders*. La tipología de *twitteros* se ha realizado en función del colectivo al que pertenecen y de su relación con la entidad analizada. El trabajo de codificación se extiende a las 300 palabras más usadas (se revisan y únicamente se clasifican cuando proceda), los 90 *hashtags* (se revisan y sola-

mente se clasifican cuando proceda) y los 30 *twitteros* más relevantes (se clasifican en todos los casos). Estos límites se han fijado tras observar que la frecuencia asociada a palabras, *hashtags* y *twitteros* caía significativamente para una entidad promedio.

#### 4. RESULTADOS

*Pregunta de investigación #1: ¿Cuál es la importancia de la RSC de las empresas en las comunicaciones que tienen lugar en Twitter?*

En primer lugar, nos interesa conocer la importancia que los temas relacionados con la RSC tienen sobre todo el contenido de Twitter acerca del sector bancario español. Como podemos ver en la tabla 1, en los tres meses analizados se han recogido cerca de un millón de *tweets* que contienen el nombre de las 41 entidades objeto de estudio. El proceso de filtrado ha eliminado 81,6 miles de *tweets* por no guardar relación alguna con la propia actividad de estas empresas. De los 888,3 miles de *tweets* analizados, un 47,2 % han sido incluidos en, al menos, uno de los criterios definidos, es decir, casi la mitad de los mensajes que se han emitido en Twitter en este periodo acerca de las entidades bancarias españolas están relacionados con el impacto de su actividad sobre alguno de sus grupos de interés.

Tabla 1.

#### Número de *tweets* recogidos, filtrados, analizados y clasificados en al menos un criterio de RSC por entidad bancaria

#	Entidad	Tweets			Clasificados en al menos un criterio RSC	
		Recogidos	Filtrados	Analizados	Total	%
1	Banca March	482	0	482	162	33,6
2	Banco Popular	20.538	4.605	15.933	6.782	42,6
3	Banco Sabadell	12.059	3.604	8.455	5.353	63,3
4	Banco Santander	34.566	485	34.081	21.002	61,6
5	Banco Valencia	3.009	0	3.009	2.793	92,8
6	Banesto	5.664	1.343	4.321	1.283	29,7
7	Bankia	307.527	735	306.792	201.955	65,8
8	Bankinter	9.423	0	9.423	5.014	53,2
9	Bantierra	417	0	417	278	66,6
10	Barclays	19.867	3.138	16.729	5.953	35,6
11	BBVA	310.235	21.173	289.062	59.199	20,5
12	BFA*	2.856	0	2.856	2.796	97,9
13	BMN	9.563	1.413	8.150	4.180	51,3
14	Banco Caixa Geral	201	2	199	170	85,4
15	Caixa Ontinyent	116	0	116	65	56,0
16	Caixabank	74.590	13.650	60.940	30.012	49,2
17	Caja Laboral	2.100	1.244	856	323	37,7
18	Caja Rural CLM	274	0	274	251	91,6
19	Caja Rural Extremadura	211	4	207	146	70,6
20	Caja Rural Granada	78	0	78	65	83,3

Tabla 1. (continuación)

**Número de *tweets* recogidos, filtrados, analizados y clasificados en al menos un criterio de RSC por entidad bancaria**

#	Entidad	Tweets			Clasificados en al menos un criterio RSC	
		Recogidos	Filtrados	Analizados	Total	%
21	Caja Rural Navarra	43	0	43	26	60,5
22	Caja Rural Soria	33	0	33	27	80,6
23	Caja Rural Teruel	147	0	147	22	15,0
24	Caja3	1.923	65	1.858	1.331	71,7
25	Cajamar	4.815	910	3.905	2.329	59,6
26	CatalunyaBanc	2.833	0	2.833	2.476	87,4
27	CEISS	2.067	0	2.067	1.501	72,6
28	Citibank	4.228	1.589	2.639	554	21,0
29	Coop57	212	0	212	104	49,3
30	Deutsche Bank	9.781	79	9.702	5.813	59,9
31	Ibercaja	10.735	66	10.669	8.899	83,4
32	ING Direct	4.318	1.946	2.372	1.279	53,9
33	Kutxabank	11.091	758	10.333	6.108	59,1
34	Liberbank	34.162	0	34.162	28.176	82,5
35	Lloyds	1.993	15	1.978	1.584	80,1
36	NCG Banco	3.773	340	3.433	2.173	63,3
37	Oikocredit	42	0	42	13	31,7
38	Openbank	2.505	0	2.505	2.307	92,1
39	Triodos Bank	1.492	0	1.492	699	46,9
40	Unicaja	59.850	24.450	35.400	6.076	17,2
41	Unnim	126	6	120	96	80,0
TOTAL		969.945	81.620	888.325	419.376	47,2

Nota: \*Matriz del grupo BFA-Bankia.

Fuente: Elaboración propia.

Por lo tanto, la primera conclusión que podemos extraer es la enorme relevancia de la RSC en el contenido de las redes sociales. Asimismo, llama la atención que cerca de un 50 % de los *tweets* clasificados guardan relación con la entidad BFA-Bankia. Este protagonismo se explica por tratarse de la cuarta entidad bancaria del país por volumen de activos, protagonizar el mayor rescate de una entidad financiera española durante la crisis, el elevado número de ahorradores afectados por el caso de las “participaciones preferentes” y por diversos casos de corrupción, uno de los cuales tuvo importantes novedades judiciales durante el periodo estudiado. No obstante, aunque Bankia es la entidad que más mensajes genera por su relación con los *stakeholders* en términos absolutos, en valores relativos son varias las entidades que la superan en las que los *tweets* sobre RSC representan por encima del 80 del total, como se puede observar en la tabla 1. El caso de Bankia nos sirve para plantear la hipótesis de que, en un sector controvertido, la información difundida por las redes sociales tiene un marcado sesgo negativo y, por tanto, potencia la mala reputación de las empresas. En cualquier caso, será una cuestión que analizaremos en estudios posteriores, ya que en el trabajo que nos ocupa nos centramos en el análisis de contenidos sin entrar a analizar sentimiento.

Otra de las cuestiones que nos llama la atención en la tabla 1 es que las dos entidades con un mayor número de *tweets* filtrados, BBVA y Unicaja, se encuentran entre las que proporcionalmente tienen un menor número de *tweets* relacionados con la RSC con un 20,5 % y un 17,2 %, respectivamente. Esto se debe a que para las entidades cuyo nombre aparece vinculado a cuestiones alejadas de su actividad principal y, muy especialmente, a grandes eventos deportivos (BBVA era el patrocinador principal de la Liga de Fútbol Profesional y Unicaja esponsoriza a un equipo de baloncesto de la Liga ACB), la mayor parte de los *tweets* aparecen referidos a cuestiones de la actividad patrocinada y nuestro proceso de filtrado es capaz de mitigar solamente en parte el ruido que generan para el análisis de contenido en relación a la actividad bancaria.

*Pregunta de investigación #2: ¿Cuáles son los aspectos de la RSC que provocan un mayor interés para los stakeholders? ¿Y para las compañías? ¿En qué se diferencia la comunicación de estos dos tipos de usuarios?*

A continuación, analizaremos el contenido de los mensajes para identificar los temas que más influyen en que una entidad genere un mayor o menor número de comentarios. Asimismo, estudiaremos la estrategia de comunicación en redes sociales de las empresas para determinar cuáles son sus principales puntos de interés y si éstos coinciden con los de sus *stakeholders*. De ahora en adelante abandonamos el análisis de corte exclusivamente transversal y trabajaremos con un modelo de datos de panel siendo cada observación el número de *tweets* por entidad y día, lo que da lugar a un total de 2.816 observaciones. Hay días para los que no se ha registrado actividad en Twitter en relación a algunas empresas y por ello esas observaciones no forman parte de la muestra, que podría haber contado con un máximo de 3.772 observaciones (41 empresas \* 92 días).

En la tabla 2 podemos observar el contraste de medias del cruce de criterios de usuarios y tipo de RSC que demuestra que los usuarios de Twitter que pertenecen a las empresas presentan un comportamiento distinto al de los usuarios externos. Como usuarios internos encontramos cuentas corporativas, de directivos y de empleados. Los usuarios externos son administraciones públicas, empresas, medios de comunicación, ONG, plataformas y asociaciones, sindicatos y *twitteros* particulares. Para ello, hemos realizado un test de contraste de medias primero en valores absolutos y, posteriormente, en relación al total de *tweets* emitidos por cada uno de los grupos de usuarios, ya que los usuarios externos son más y presentan un mayor nivel de actividad y, por tanto, podrían no ser comparables de esta manera. Ambos tipos de test arrojan el mismo resultado, indicando que los usuarios externos de las empresas hablan más que los internos sobre RSC Central, y que estos últimos presentan un mayor nivel de participación que los primeros en cuestiones de RSC Complementaria. Por lo tanto, se puede concluir que, a pesar del predominio global de contenidos sobre RSC Central, las empresas analizadas realizan un notable esfuerzo de comunicación sobre acciones de RSC Complementaria que, sin embargo, no se traduce en un mayor interés de los grupos de interés por este tipo de acciones. De esta forma proporcionamos evidencia empírica de que las redes sociales son canales que escapan al control de las empresas, a diferencia de los medios

de comunicación tradicionales, donde este control sí está presente en mayor o menor medida (Mangold y Faulds, 2009).

Tabla 2.

**Valores medios de *tweets* relacionados con RSC Central y Complementaria para usuarios internos y externos y prueba T pareada**

	Obs**	Valores medios	
		Número de <i>tweets</i> por entidad y día	
		Usuarios externos	Usuarios internos
<i>Tweets</i> relacionados con RSC Central	2.816	44,81	8,82*
<i>Tweets</i> relacionados con RSC Complementaria	2.816	1,41	2,49*
<i>Tweets</i> relacionados con RSC Central/ Número total de <i>tweets</i> por tipo de usuario	834	0,79	0,68
<i>Tweets</i> relacionados con RSC Complementaria/ Número total de <i>tweets</i> por tipo de usuario	834	0,21	0,36*

*Notas:* \*Diferencia estadísticamente significativa – Prueba T pareada,  $p < 0.001$ . \*\* El número de observaciones se reduce a 834 cuando hablamos en términos relativos porque se trata de un cociente en el que el denominador es “número de *tweets* emitidos por usuarios internos (externos)”, por lo tanto, cuando no existen *tweets* el cociente es indeterminado y esas observaciones se excluyen de la muestra. Dado que las cuentas internas presentan una actividad inferior al de las externas y el test exige que haya observaciones comparables para ambos tipos de usuarios, esta circunstancia hace que el número de observaciones se vea disminuido.

*Fuente:* Elaboración propia.

Para concluir nuestro análisis de resultados, en las tablas 3 y 4 profundizamos en los temas que componen cada una de las dos grandes áreas que diferenciamos en relación a la RSC. Así, en la tabla 3 observamos que los temas de RSC Central que más relacionados se encuentran con la generación de *tweets* son, por este orden: 1) la creación de valor para los accionistas (*tw\_a\_creavalor*), lo cual se explica por tratarse de un periodo que contiene la fecha de cierre del ejercicio y la publicación de resultados, lo que en el caso de las sociedades cotizadas tiene un notable impacto en materia informativa; 2) las prácticas comerciales (*tw\_c\_p\_practcom*), y dentro de ellas, las relacionadas con la gestión del ahorro (*tw\_c\_p\_ahorro*) por los casos de afectados por las “participaciones preferentes”; y 3) los incumplimientos normativos (*tw\_s\_incumplimiento*), relacionados con escándalos contables y casos de corrupción, como los apuntados anteriormente en el caso de BFA-Bankia. En cuanto a los temas que generan un menor interés y, por tanto, menor cantidad de información son, también por este orden: 1) la igualdad en materia laboral y la inclusión social de colectivos desfavorecidos en la plantilla de trabajadores (*tw\_e\_igualdad&div*), un aspecto que, a pesar de aparecer en la mayor parte de las memorias de sostenibilidad, no ha generado ni un solo mensaje en el periodo analizado; 2) la inclusión financiera (*tw\_s\_inclusionfinanc*), que era originariamente la razón de ser de las cajas de ahorros pero en la actualidad tiene un carácter marginal en la actividad de este tipo de entidades de crédito; y 3) la inversión socialmente responsable (*tw\_s\_isr*), un tipo de productos financieros elaborados en base a criterios ASG (ambientales, sociales y de buen gobierno corporativo) que, tal y como indica el informe “European SRI

Study 2012” elaborado por Eurosif (European Sustainable Investment Forum), suscitan en España un interés inferior a la media europea y además se vio seriamente reducido durante la crisis financiera.

Tabla 3.

**Estadísticos descriptivos y correlaciones con el número total de *tweets* para las variables que se agrupan en RSC Central**

Variable	Desviación				tw_total
	Media	Típica	Mín	Máx	
(1) tw_total	315.4	1.053.1	1	18.084	1
(2) tw_ac_creacvalor	50.42	269.1	0	5.345	0.72**
(3) tw_c_e_credito	4.29	35.1	0	1.393	0.23**
(4) tw_c_p_ahorro	16.99	117.2	0	4.017	0.54**
(5) tw_c_p_credito	11.17	70.3	0	1.505	0.29**
(6) tw_c_p_practcom	34.34	155.9	0	4.342	0.65**
(7) tw_e_empleo	3.33	30.3	0	1.189	0.12**
(8) tw_e_condlaborales	7.37	53.8	0	1.863	0.52**
(9) tw_e_igualdad&div	0	0	0	0	-
(10) tw_gc_retribdirectivos	8.89	120.2	0	4.051	0.24**
(11) tw_gc_transparencia	4.37	72.3	0	3.253	0.22**
(12) tw_s_inclusionfinanc	0.09	1.1	0	29	(0.01)
(13) tw_s_incumplimiento	51.59	383.7	0	10.135	0.65**
(14) tw_s_isr	0.13	3.6	0	180	(0.01)

Notas: \*p <0.05; \*\*p <0.01.

Fuente: Elaboración propia.

Respecto a la RSC Complementaria, que recordamos se trata de información procedente casi en su totalidad de las propias entidades bancarias, la tabla 4 muestra que la acción cultural es la que guarda una mayor correlación con la cantidad total de *tweets*, seguida de la acción social y, a una mayor distancia, se encuentra la acción medioambiental. Este hallazgo refuerza la tesis defendida por diversos autores (*i.e.* Gómez-Carrasco, Guillamón-Saorín y García Osma, 2016; Valverde y Fernández, 1998; Núñez, 1998) de la mayor visibilidad de este tipo de acciones y de su uso como acciones de *marketing*.

Tabla 4.

**Estadísticos descriptivos y correlaciones con el número total de *tweets* para las variables que se agrupan en RSC Complementaria**

Variable	Desviación				tw_total
	Media	Típica	Mín	Máx	
(1) tw_total	315.456	1.053.129	1	18.084	1
(2) tw_cultural	9.641	40.709	0	855	0.351**
(3) tw_medioambiental	1.301	10.688	0	281	0.338**
(4) tw_social	4.726	18.457	0	286	0.249**

Notas: \*p <0.05; \*\*p <0.01.

Fuente: Elaboración propia.

## 5. DISCUSIÓN Y CONCLUSIONES

Esta investigación ha sido un primer acercamiento al fenómeno de la RSC a través de las redes sociales, concretamente de la red de *microblogging* Twitter. Para ello, hemos realizado, con la ayuda de una herramienta informática, un análisis de contenido de todos los mensajes asociados con cada una de las entidades analizadas, que representan la práctica totalidad de los activos del sector bancario español. Hemos establecido una clasificación que parte de la diferencia entre RSC Central y Complementaria y que, posteriormente, se divide en aquellas cuestiones que las entidades de crédito consideran clave en sus memorias de sostenibilidad. Tras nuestro trabajo de clasificación y el posterior análisis hemos alcanzado las siguientes conclusiones:

- Cerca de la mitad de los mensajes (47,2 %) que se han emitido en Twitter en el periodo analizado están relacionados con la RSC de las entidades bancarias, lo que pone de manifiesto la relevancia de esta cuestión en las redes sociales.
- La RSC Central es el contenido predominante en redes sociales. Mientras las cuentas internas de las empresas (corporativas y de directivos y empleados) realizan un esfuerzo para potenciar la RSC Complementaria, esto no se traduce en un mayor interés de los grupos de interés por este tipo de acciones.
- Los temas que más cantidad de *tweets* generan en relación con la RSC Central son la creación de valor para los accionistas, las prácticas comerciales relacionadas con la gestión del ahorro y los incumplimientos normativos relacionados con escándalos contables y casos de corrupción. Los temas que generan un menor interés y, por tanto, menor cantidad de información son la igualdad en materia laboral y la inclusión social de colectivos desfavorecidos en la plantilla de trabajadores, la inclusión financiera y la inversión socialmente responsable (ISR).
- Respecto a la RSC Complementaria, la acción cultural es la que guarda una mayor correlación con la cantidad total de *tweets*, seguida de la acción social y, a una mayor distancia, se encuentra la acción medioambiental.

Este estudio presenta varias limitaciones entre las que destacamos el hecho de haberlo basado en una única red social y se podría argumentar que el comportamiento e intereses de los usuarios difieren de unas redes a otras. No obstante, Twitter es, como ya hemos comentado, la red de *microblogging* más grande del mundo y se encuentra entre las de mayor número de participantes en el global de las redes sociales. Además, cada día estas redes están más interconectadas permitiendo compartir contenidos entre ellas, una asociación que Muralidharan *et al.* (2011) califican de “estadísticamente significativa” para el caso de Twitter y Facebook. De esta forma, las conclusiones extraídas de este estudio podrían ser aplicables a todo el entorno de redes sociales. Por otro lado, Twitter refleja de manera sistemática las noticias publicadas en otros medios de comunicación (Sprenger *et al.*, 2014) y podría ser también el reflejo de realidades sociales más allá de Internet, tal y como demuestran Tumasjan *et al.* (2010) en el caso de procesos electorales.

En cuanto a las fortalezas del estudio, destacamos que se trata de una cuestión de actualidad con amplias implicaciones para la práctica empresarial, ya que las empresas se encuentran actualmente en un nuevo escenario al que tienen que adaptar sus estrategias de comunicación. También es importante subrayar que abarca la práctica totalidad de un sector empresarial y la totalidad de los *tweets* referidos a la actividad de estas empresas durante un periodo de 93 días, llegando a recoger cerca de un millón de *tweets*, por lo tanto, los resultados obtenidos reflejan fielmente la realidad de este sector. Por último, la clasificación manual de los *tweets* ha sido replicada para dos de las entidades analizadas por personas ajenas al proyecto alcanzando una coincidencia superior al 80 %, lo que dota de fiabilidad a nuestro trabajo.

Nuestro trabajo proporciona nuevas evidencias que no habían sido hasta ahora contempladas en la literatura y refuerza algunos hallazgos que ya habían sido puestos de manifiesto por otros autores previamente. En el ámbito de la investigación, este trabajo presenta las redes sociales como un entorno apropiado para el estudio de cuestiones relacionadas con la RSC por la gran cantidad de contenidos que se generan sobre aspectos relativos a la relación entre empresas y *stakeholders*. Por otro lado, encontramos que la estrategia de comunicación de las empresas no está adecuadamente alineada con la de los *stakeholders*, ya que estos se interesan básicamente por cuestiones relacionadas con el negocio principal de las compañías mientras que las cuentas internas se ocupan de cuestiones complementarias en una proporción significativamente superior a la de los *stakeholders* externos, este resultado demuestra que las redes sociales son un medio de difícil control por parte de las empresas en línea con lo expuesto por Mangold y Faulds (2009). Este punto constituye asimismo la principal implicación del trabajo para la práctica empresarial, ya que pone de manifiesto que no se está aprovechando el potencial de este canal de comunicación que permite una interacción permanente con los *stakeholders* y se siguen empleando estrategias tradicionales de comunicación unidireccional.

## Referencias

- BLANKESPOOR, E., MILLER, G. S. y WHITE, H. D. (2014). The Role of Dissemination in Market Liquidity: Evidence from Firms' Use of Twitter™. *The Accounting Review*, 89(1), pp. 79-112.
- BOLLEN, J., MAO, H. y ZENG, X. (2011). Twitter mood predicts the stock market. *Journal of Computational Science*, 2(1), pp. 1-8.
- BRAMMER, S. y MILLINGTON, A. (2008). Does it pay to be different? An analysis of the relationship between corporate social and financial performance. *Strategic Management Journal*, 29(12), pp. 1325-1343.
- BURKE, L. y LOGSDON, J. M. (1996). How corporate social responsibility pays off. *Long Range Planning*, 29(4), pp. 495-502.
- CHO, C. H., GUIDRY, R. P., HAGEMAN, A. M. y PATTEN, D. M. (2012). Do actions speak louder than words? An empirical investigation of corporate environmental reputation. *Accounting, Organizations and Society*, 37(1), pp. 14-25.
- CHOW, C. W. y WONG-BOREN, A. (1987). Voluntary financial disclosure by Mexican corporations. *Accounting Review*, 62(3), pp. 533-541.
- COOMBS, W. T. (1998). The Internet as potential equalizer: New leverage for confronting social irresponsibility. *Public Relations Review*, 24(3), pp. 289-303.

- CULNAN, M. J., MCHUGH, P. J. y ZUBILLAGA, J. I. (2010). How large US companies can use Twitter and other social media to gain business value. *MIS Quarterly Executive*, 9(4), pp. 243-259.
- DEEGAN, C. (2002). Introduction: The legitimising effect of social and environmental disclosures – A theoretical foundation. *Accounting, Auditing and Accountability Journal*, 15(3), pp. 282–311.
- DOWLING, J. y PFEFFER, J. (1975). Organisational legitimacy: Social values and organisational behaviour. *Pacific Sociological Review*, 18(1), pp. 122–136.
- EUROSIF (2012). European SRI Study.
- GÓMEZ-CARRASCO, P., GUILLAMÓN-SAORÍN, E. y OSMA, B. G. (2016). The illusion of CSR: Drawing the line between core and supplementary CSR. *Sustainability Accounting, Management and Policy Journal*, 7(1), pp. 125-151.
- JANSEN, B. J., ZHANG, M., SOBEL, K. y CHOWDURY, A. (2009). Twitter power: Tweets as electronic word of mouth. *Journal of the American Society for Information Science and Technology*, 60(11), pp. 2169-2188.
- JENKINS, H. (2009). A ‘business opportunity’ model of corporate social responsibility for small-and medium-sized enterprises. *Business Ethics: A European Review*, 18(1), pp. 21–36.
- KAHN, R. y KELLNER, D. (2004). New media and internet activism: From the ‘Battle of Seattle’ to blogging. *New Media and Society*, 6(1), pp. 87-95.
- KANE, G. C., FICHMAN, R. G., GALLAUGHER, J. y GLASER, J. (2009). Community relations 2.0. *Harvard Business Review*, 87(11), pp. 45-50.
- KIETZMANN, J. H., HERMKENS, K., MCCARTHY, I. P. y SILVESTRE, B. S. (2011). Social media? Get serious! understanding the functional building blocks of social media. *Business Horizons*, 54(3), pp. 241–251.
- KING, B. G. (2008). A political mediation model of corporate response to social movement activism. *Administrative Science Quarterly*, 53(3), pp. 395-421.
- KING, B. G. y SOULE, S. A. (2007). Social movements as extra-institutional entrepreneurs: The effect of protests on stock price returns. *Administrative Science Quarterly*, 52(3), pp. 413-442.
- MANGOLD, W. G. y FAULDS, D. J. (2009). Social media: The new hybrid element of the promotion mix. *Business Horizons*, 52(4), pp. 357-365.
- MCALISTER, D. T. y FERRELL, L. (2002). The role of strategic philanthropy in marketing strategy. *European Journal of Marketing*, 36(5/6), pp. 689–705.
- MORSING, M. y SCHULTZ, M. (2006). Corporate social responsibility communication: stakeholder information, response and involvement strategies. *Business Ethics: A European Review*, 15(4), pp. 323-338.
- MURALIDHARAN, S., RASMUSSEN, L., PATTERSON, D. y SHIN, J. H. (2011). Hope for Haiti: An analysis of Facebook and Twitter usage during the earthquake relief efforts. *Public Relations Review*, 37(2), pp. 175-177.
- NÚÑEZ, C. E. (1998). El gasto en educación de las cajas de ahorros. *Papeles de Economía Española*, 74, pp. 234-258.
- PATTEN, D. M. (1992). Exposure, legitimacy, and social disclosure. *Journal of Accounting and Public Policy*, 10(4), pp. 297-308.
- PELOZA, J. (2006). Using corporate social responsibility as insurance for financial performance. *California Management Review*, 48(2), pp. 52–72.
- PETROVITS, C. M. (2006). Corporate-sponsored foundations and earnings management. *Journal of Accounting and Economics*, 41(3), pp. 335–362.
- PORTER, M. E. y KRAMER, M. R. (2002). The competitive advantage of corporate philanthropy. *Harvard Business Review*, 80(12), pp. 56–68.
- PORTER, M. E. y KRAMER, M. R. (2006). The link between competitive advantage and corporate social responsibility. *Harvard Business Review*, 84(12), pp. 78–92.

- RUF, B. M., MURALIDHAR, K., BROWN, R. M., JANNEY, J. J. y PAUL, K. (2001). An empirical investigation of the relationship between change in corporate social performance and financial performance: a stakeholder theory perspective. *Journal of Business Ethics*, 32(2), pp. 143-156.
- SEIFERT, B., MORRIS, S. A. y BARTKUS, B. R. (2004). Having, giving, and getting: Slack resources, corporate philanthropy, and firm financial performance. *Business and Society*, 43(2), pp. 135-161.
- SIMPSON, W. G. y KOHERS, T. (2002). The link between corporate social and financial performance: evidence from the banking industry. *Journal of Business Ethics*, 35(2), pp. 97-109.
- SPRENGER, T. O., SANDNER, P. G., TUMASJAN, A. y WELPE, I. M. (2014). News or Noise? Using Twitter to Identify and Understand Company-specific News Flow. *Journal of Business Finance and Accounting*, 41, pp. 791-830.
- TUMASJAN, A., SPRENGER, T. O., SANDNER, P. G. y WELPE, I. M. (2010). Predicting Elections with Twitter: What 140 Characters Reveal about Political Sentiment. *ICWSM*, 10, pp. 178-185.
- VALVERDE, S. C. y FERNÁNDEZ, F. R. (1998). Tendencias recientes en la obra social de las cajas de ahorros españolas. *Papeles de Economía Española*, 74, pp. 226-233.
- VASI, I. B. y KING, B. G. (2012). Social Movements, Risk Perceptions, and Economic Outcomes The Effect of Primary and Secondary Stakeholder Activism on Firms' Perceived Environmental Risk and Financial Performance. *American Sociological Review*, 77(4), pp. 573-596.
- WANG, H., CHOI, J. y LI, J. (2008). Too little or too much? Untangling the relationship between corporate philanthropy and firm financial performance. *Organization Science*, 19(1), pp. 143-159.
- YANG, G. (2013). *The power of the Internet in China: Citizen activism online*. Columbia University Press.
- YANG, J. H. y LIU, S. (2017). Accounting narratives and impression management on social media. *Accounting and Business Research*, 47(6), pp. 673-694.
- ZHANG, X., FUEHRES, H. y GLOOR, P. A. (2011). Predicting stock market indicators through twitter "I hope it is not as bad as I fear". *Procedia-Social and Behavioral Sciences*, 26, pp. 55-62.

## CAPÍTULO VIII

## Nuevas trazas del valor de marca de entidades financieras proporcionadas por su gestión *online*

Nora Lado  
Manuel Ceballos  
Camilo de la Cruz

Este capítulo presenta ejemplos aplicados al sector financiero español basados en las teorías de *marketing* sobre la respuesta del mercado y sobre el valor de las marcas. Estas aplicaciones ofrecen oportunidades de apalancar el valor de la marca. El primer ejemplo ofrece ciertos indicadores de notoriedad e implicación, obtenido del monitoreo de redes sociales, como trazas del valor de marca *online*. En el segundo, se aplican instrumentos de *neuromarketing* para optimizar la comunicación *online*, previa al lanzamiento de una campaña, verificando si atrae la atención hacia los estímulos deseados, como es la marca y analizando si las emociones que provoca son lo suficientemente fuertes para motivar a la audiencia y al potencial cliente. Se busca así realzar la implicación de la audiencia, que es otro de los indicadores del valor de marca. Todos los ejemplos son reales y pertenecen al sector financiero y de cajas de ahorros.

Palabras clave: *marketing*, valor de marca, respuesta del mercado, *neuromarketing*, indicadores *online*, monitoreo redes sociales.

## 1. INTRODUCCIÓN

Sobre la base de las diferentes teorías sobre cómo crear valor de marca, este capítulo abre el espectro de medidas tradicionales del valor de la marca a su aplicación en el entorno *online*. A su vez, se proporcionan ejemplos de su procesamiento mediante técnicas de *big data*, que ofrecen trazas para la detección del valor de marca desde la perspectiva del consumidor o usuario. La contribución se apoya en proponer medidas que provienen del análisis de los medios o redes sociales y del *marketing* digital.

La Web Semántica (Berners-Lee *et al.*, 2001) fue concebida con el propósito de solventar el problema de hallar la información precisa entre toda la referencia acerca de un contexto. Su propósito es añadir la semántica a los datos publicados en la web (es decir, determinar el sentido de los datos) de tal forma que las máquinas sean capaces de procesar los datos de forma similar a como lo hacen los humanos. Esto deriva de la visión que Berners-Lee tiene de la web como un medio universal de datos, información e intercambio de conocimiento. Sin embargo, el procesamiento de los datos de los medios o redes sociales, así como la extracción de toda la información proveniente de las conversaciones que allí se dan, requiere de la utilización de técnicas de procesamiento de lenguaje natural siendo necesario, una vez procesado el contenido de las redes sociales y el eWOM (comunicación interpersonal *online*), estructurar y almacenar la información de forma que sea procesable. Es aquí donde juegan un papel fundamental las técnicas de Web Semántica, concretamente ontologías y *linked data*. Así mismo, dado el gran volumen de información que se genera en las redes sociales, es necesario aplicar técnicas de *big data* para poder procesarla.

La relevancia para los directivos de las empresas, especialmente de *marketing*, del monitoreo de las redes sociales y de los desafíos que plantea, lleva a que figure entre las máximas prioridades de investigación por el Marketing Science Institute (MSI, 2016). El valor de marca representa el intangible que refleja todo el impacto de la gestión de *marketing* y de la gestión del producto e innovaciones. Su relevancia está fuera de dudas.

## 2. MARCO TEÓRICO

### 2.1. Valor de marca en la literatura tradicional

A continuación, se estudiará el estado actual del concepto de valor de marca y *a posteriori*, su reflejo en las redes sociales. El paradigma “La lógica dominante de servicio (DS) como marco teórico obliga a revisar cómo se genera el valor de marca”. La cocreación de valor, tal como proponen (Vargo y Lusch, 2004) tanto en el uso como en la generación de información es fundamental para el éxito de los productos, servicios y marcas. Es por esta razón que “el consumidor siempre es cocreador de valor” es una de las premisas que proponen y se basa en la interacción entre las partes y la contribución que cada uno da a ese valor total producido.

Esto idealmente se traslada a una situación más eficiente y menos costosa para las partes, y necesita de una alta implicación de los usuarios. Dentro de esta teoría se propone un avance en el triángulo marca-relación-valor introducido por Brodie *et al.* (2006) y Fyrberg y Jürriado, (2009). Estos autores concluyen que la lógica dominante del servicio, y la intersección con la teoría de redes, reconocen los diversos actores que crean valor mediante interacciones. La experiencia de marca, es considerada un facilitador y mediador entre las relaciones/interacciones de los diversos actores o partes. Si tomamos en cuenta la visión de los responsables de *marketing* y Ceos, vemos que su visión es clara y no dudan sobre el papel fundamental de las redes sociales en la creación de valor de marca. El argumento más directo que exponen es el efecto positivo de las recomendaciones en las ventas. Además, existe un segundo mecanismo más indirecto que puede resumirse mediante las palabras de Nigel Hollis (2014), vicepresidente de la empresa Millward Brown “[...] ser parte de la conversación social, hace que la marca viva y sea parte de la escena contemporánea. La exposición frecuente al nombre de la marca ayuda a mantener la notoriedad de la marca... desencadenando asociaciones de marca pre-existentes que ayudan a posicionarla en la mente del consumidor (y no sólo el comentario positivo es importante). Ser una marca muy conocida y actual incidirá como un halo de percepciones de marca existentes, y ayuda a asegurar a las personas que la marca es una buena opción, simplemente porque han oído hablar de ella”.

En la literatura clásica de *marketing*, la marca es concebida como el conjunto de activos intangibles (Aaker, 1996) que representan el valor añadido que la marca confiere al producto y juega un papel fundamental en las estrategias y decisiones empresariales. Los esfuerzos de *marketing* dirigidos hacia la creación de un valor de marca, deben estar fundamentados en una teoría que explique los mecanismos por los cuales una marca crea valor, al tiempo que, como en toda inversión empresarial, se debe analizar su eficiencia y dotar a los directivos de instrumentos útiles para la toma de decisiones (Esteban-Bravo y Lado, 2011; Srinivasan y Hanssens, 2005; Yoo, Donthu y Lee, 2000; Keller y Lehmann, 2003).

La revisión de la literatura de *marketing* sobre el valor de marca permite identificar dos enfoques diferentes, a la vez que complementarios, sobre las raíces del valor de marca:

- Un enfoque se apoya en el marco teórico que proporciona la economía de la información, el otro, tiene sus fundamentos en los desarrollos de la psicología cognitiva (Erdem y Swait, 1998). Desde la perspectiva de la economía de la información, las marcas contribuyen a las percepciones de calidad de los clientes al reducir el riesgo percibido y los costes asociados a la búsqueda de información. La calidad de un producto o servicio puede considerarse como un atributo sobre el que los compradores potenciales poseen información imperfecta. Así, tal como señalan (Erdem y Swait, 1998), bajo un supuesto de información imperfecta y asimétrica, la reputación de una marca supone para el mercado, una señal creíble sobre la calidad del producto y permite a las empresas incorporar a los precios de sus productos una prima de marca. Esta prima de precios de marca es el valor agregado por la marca, comparado con el precio de un mismo producto o servicio sin marca. La evidencia empírica así lo

muestra, y también se puede calcular el valor de marca en términos de una prima de ingresos por ventas al introducir la diferencia en la cantidad vendida, no solo en el precio. (Esteban-Bravo y Lado, 2011).

- Y en el contexto de la psicología cognitiva, el valor de marca proviene de dos elementos: notoriedad de la marca y asociaciones respecto a sus atributos. Tal como Keller (1993) sugiere, el valor de marca es el resultado de una asociación fuerte, favorable y única en la mente de los consumidores entre la marca y la calidad del producto. La notoriedad de una marca es abordada tanto en su profundidad como en su amplitud (Keller, 2016). Así, la profundidad se refiere a cuán fácilmente los consumidores recuerdan o reconocen la marca. Mientras que la amplitud incorpora el rango de situaciones de compra en las cuales la marca es evocada en la mente del consumidor. Investigaciones previas aportan evidencia empírica sobre la importancia de la unicidad de la asociación en la valoración de las primas de marca (Erdem *et al.*, 1999). La originalidad de las asociaciones es una propiedad de la marca que permite que productos con idénticos atributos observables sean diferentes en la mente del público. La unicidad, la calidad y el valor percibido de la marca son variables predictivas de la disposición a pagar una prima por ella. Según Erdem *et al.* (1999), la formación del valor de marca para el consumidor debe ser abordado desde una perspectiva dinámica donde las percepciones de los atributos son guiadas por el proceso de aprendizaje del consumidor. En este proceso las marcas juegan un papel de “organizador de la información” sobre el producto.

## 2.2. Valor de marca *online*

Antes de la era digital, el valor de marca percibido era influenciado por los instrumentos de comunicación de *marketing* tradicionales, los llamados del contexto *offline* (Bruhn, Schoenmueller y Schäfer, 2012). Actualmente, las acciones de las empresas *online* y los medios sociales afectan el proceso de decisión de compra y las intenciones de compra (Bruhn, Schoenmueller y Schäfer, 2012; Luo, Donthu y Lui, 2013). Por ello, hay que revisar los modelos de medición del valor de marca tradicionales que no han sido concebidos para capturar el impacto de los medios sociales (Keller, 2016).

Si consideramos el enfoque de la economía de la información, vemos como en los medios sociales el contenido generado por las empresas (Firm-Generated Content – FGC) y por los usuarios (User-Generated Content – UGC) son formas de transmitir información sobre las marcas y sus atributos, reducen los costes de búsqueda de información e influyen en el valor de la marca.

Desde el punto de vista de la psicología cognitiva, los medios sociales impactan también. La notoriedad de la marca que está en la base de su valor, ya no es controlada o determinada solamente por inversiones en publicidad. Los medios sociales son hoy utilizados como

medio prioritario de generación de notoriedad. Kumar *et al.* (2013), demostraron que el uso estratégico de los medios sociales mejora el rendimiento del negocio (ventas, ROI, el boca a boca y el conocimiento de la marca). Además, las redes sociales, en general, reflejan, refuerzan y construyen asociaciones con atributos. Surge además el grado de “implicación con la marca” (*brand engagement*) (Keller, 2016) como otro constructo reciente de especial relevancia. Si estudiamos el grado de implicación con la marca a través de las redes sociales, concluimos que está relacionado con la cocreación del valor de marca, ya que conduce a un uso más intensivo de la marca e incrementa el valor social de la misma. La conclusión es que el grado de implicación con la marca es un buen predictor de la atención diferencial, la memoria y la preferencia y lealtad hacia la marca. Por ello, la implicación con la marca debe incorporarse a los modelos de valor de marca.

Luo, Donthu y Lui (2013) analizan la capacidad de predicción de las métricas construidas con datos obtenidos de las redes sociales en relación con el valor de la firma y la ventaja de esta fuente de información es que facilita lo necesario en comparación con las métricas de comportamiento convencionales. Por ello, es importantísimo para las marcas el monitoreo constante de estas conversaciones que impactan en las ventas y en el valor de la empresa (Tirunillai y Tellis, 2012; Joshi y Hanssens, 2013).

La inteligencia generada en las redes sociales tiene múltiples ventajas frente a las tradicionales encuestas. La información es menos costosa, está disponible, tiene un formato no estructurado y es muy rica y variada. Los problemas de sesgos e interpretación que poseen, requieren de metodologías de análisis adecuadas.

Para mejorar el conocimiento sobre cómo las redes sociales pueden contribuir a una mejor comprensión del valor de marca es necesario utilizar un marco conceptual adecuado. En el presente trabajo el marco conceptual propuesto surge a partir de la literatura tradicional sobre el valor de marca desde la perspectiva del consumidor (*Customer Based Brand Equity, CBBE*) que fue principalmente desarrollado por Keller (1993). Por otra parte, hemos incorporado nuevos desarrollos propuestos por académicos que tienen una visión más orientada a la práctica (Kumar *et al.*, 2013). Además, con el fin de integrar adecuadamente el papel de las redes sociales hemos utilizado como referencia el esquema SOR. Este marco se basa en la teoría del aprendizaje social (Estímulo → Organismo → Respuesta – llamado paradigma SOR), dado que nos brinda un marco flexible que permite comprender cómo es la interacción entre las acciones de *marketing* en las redes sociales (*inputs*) y los objetivos de *marketing* (*outputs*).

La comunicación publicitaria *offline* y *online* son estímulos de *marketing* que, junto a los atributos que determinan la calidad objetiva o tangible del producto, determinan la percepción de calidad e influyen en el valor de marca. Existe un efecto halo entre los atributos tangibles y aspiracionales de una marca. Por ello, a continuación, presentamos el análisis de las distintas medidas del impacto de la comunicación. El objetivo es incorporar medidas del valor de marca *online*.

### 3. LAS MEDIDAS DE LA RESPUESTA DE LOS USUARIOS Y CONSUMIDORES A LOS ESTÍMULOS DE *MARKETING*

Como exponen Vakratsas y Ambler (1999), hay tres niveles identificables en la respuesta del mercado a los estímulos de *marketing*: 1) cognitivo o de pensamiento, que incluye el conocimiento y las percepciones; 2) afectivo, que se refiere a sentimientos, emociones, preferencias e intenciones; y 3) experiencia o comportamiento, que abarca acciones o reacciones que son más observables. Estos niveles también se citan como dimensiones de aprender-sentir-hacer (*Learn-feel-do*) de la respuesta del mercado en el modelo de jerarquía persuasiva. Existe una controversia sobre el mejor modelado para la respuesta de la audiencia. En particular, entre los modelos que incluyen las relaciones jerárquicas entre las dimensiones, y los otros que adoptan la posición contraria.

La clásica matriz FCB que fue propuesta por Richard Vaughn (Ratchford y Vaughn, 1989) –exvicepresidente sénior de la agencia de publicidad Foote, Cone y Belding– es un instrumento que es una extensión del modelo de jerarquía para diferentes tipos de decisiones de compra. La cuadrícula sugiere que la jerarquía de *learn-feel-do* varía dependiendo de si la decisión de compra es: 1) alta o baja en implicación; 2) si el procesamiento de la información es más afectivo o intelectual. Pensar/sentir representa dos polos del estilo de enfoque del procesamiento de la información, oponiéndose a la comprensión intelectual, lógica y lineal de la información versus el procesamiento holístico y simbólico de la información.

<i>Dimensión</i>	<i>Conceptos</i>	<i>KPI's online</i>
<i>Learn</i> (cognitiva)	<ul style="list-style-type: none"> <li>● Notoriedad</li> <li>● Percepciones</li> <li>● Asociaciones</li> </ul>	<ul style="list-style-type: none"> <li>● Popularidad</li> <li>● Búsquedas <i>online</i></li> <li>● Visitas a la página web</li> <li>● Análisis de contenido de eWOM (boca a boca <i>online</i>)</li> </ul>
<i>Feel</i> (afectiva)	<ul style="list-style-type: none"> <li>● Preferencias</li> <li>● Evaluación</li> <li>● Implicación</li> </ul>	<ul style="list-style-type: none"> <li>● “Sentiment análisis”</li> <li>● “Likes”</li> <li>● “Retweets, shares”</li> <li>● Recomendaciones</li> </ul>
<i>Do</i> (conductual)	<ul style="list-style-type: none"> <li>● Prueba o test</li> <li>● Adopción o compra</li> </ul>	<ul style="list-style-type: none"> <li>● Ventas</li> </ul>

Independientemente de si existe o no una estructura jerárquica para la respuesta cognitiva, afectiva y conductual de la audiencia objetivo del estímulo, el enfoque de tres niveles proporciona un buen panorama de la naturaleza multidimensional de las medidas que pueden corresponder a cada nivel.

Para cada uno de estos niveles es posible elegir un conjunto diferente de medidas para una comprensión profunda y monitoreo de los factores clave de éxito en la creación del valor de marca. Por ejemplo, para monitorear el nivel de *Learn* o *Think*, son relevantes algunas medidas como: notoriedad, menciones, percepciones y asociaciones. Para el nivel *Feel*, proponemos medidas sobre preferencias: me gusta, intención de compra y sentimientos positivos.

El nivel de *Do* se puede medir por cuota de mercado, contenido compartido, recomendaciones, etcétera.

El *marketing* digital abre el espectro de medidas que se pueden aplicar y su procesamiento mediante técnicas de *big data*, ofrecen trazas para la detección del valor de marca desde la perspectiva del consumidor o usuario.

El capítulo se centra en dos ejemplos de aplicaciones de *marketing* digital que son de relevancia para este tema.

## 4. APLICACIONES EMPÍRICAS

Presentamos a continuación dos aplicaciones empíricas aplicadas al sector financiero español. La primera, define y calcula indicadores del valor de marca que en investigaciones previas han sido señalados como los más relevantes por los directores de *marketing* en España. La segunda, muestra un ejemplo de instrumentos para optimizar la comunicación *online* y servir de apalancamiento para el valor de marca.

### 4.1. Implicación de los usuarios en las redes sociales

Los datos para este ejemplo fueron extraídos de la red social Twitter, utilizando su API (*Application Programming de Interfaces*) y posteriormente fueron analizados utilizando técnicas de *big data* (para más detalle véase Crespo *et al.*, 2016). Finalmente, presenta un estudio de casos de una muestra de instituciones del sector bancario español. Utilizando una técnica cualitativa y otra cuantitativa se presenta evidencia empírica a favor del potencial que tiene la utilización del *big data* para incrementar el conocimiento sobre valor de marca. En particular, se muestra cómo utilizando métricas que reflejan la interacción existente entre los usuarios corporativos y los no corporativos, a lo largo de diferentes dimensiones en el sector bancario español, se pueden detectar indicadores claves del valor de marca (KPI's).

#### 4.1.1. Aplicación empírica

La recolección de los datos se obtiene de la muestra de entidades financieras españolas detalladas en la tabla 1. Para ello, utilizamos un conjunto de palabras clave para cada una de las instituciones<sup>1</sup> incluidas en el estudio. Dicha selección fue realizada tomando en cuenta diferentes indicadores y posteriormente ha sido validada por un grupo de expertos. Para una descripción detallada del proceso de preparación y procesamiento de datos, revisar

<sup>1</sup> Bankia y Caixabank se han integrado durante el periodo de estudio, por ello figuran separadamente.

Tabla 1.

**Listado de empresas, palabras clave, usuarios corporativos y número de *tweets***

<i>Listado de empresas</i>			
<i>Nombre</i>	<i>Keywords</i>	<i>Usuario</i>	<i>Tweets</i>
Activobank	acivobank	--	39
Banca March	bancamarch; bancomarch	@bancamarch	3.173
Banco Caixa Geral	bancocaixageral	--	36
Banco de Sabadell	bancodesabadell	@bancosabadell	21.001
Banco de Valencia	bancodevalencia	@bancodevalencia	990
Banco Grupo Cajatres	bancogrupocajatres; caja3	@bancogrupocaja3	4.336
Banco Popular Español	bancopopularespañol	@popularresponde	43.651
Banco Santander	bancosantander	@bancosantander	194.847
Banco Gallego	bancogallego	--	219
Banesto	banesto	--	5.354
Bankia*	bankia	@bankia	224.087
Bankinter	bankinter	@bankinter	41.459
Barclays Bank	barclaysbank; barclays	--	13.398
Bantierra	bantierra	--	336
BBK Bank Cajasur	bankcajasur; cajasur	@cajasur	79.662
BBVA	bbva	@bbva	1.318.317
BNP Paribas	bnpparibas	--	3.000
Caixabank*	caixabank	@caixabank	470.513
Caja Rural de Granada	cajaruraldegranada	@cajaruralgr	511
Citibank España	citiespaña	@citi_es	19.961
Fund. Inv. y Ahorro Responsable	fundacióninversiónyahorro responsable, fiare	@fiarebe	5.130
Ibercaja	ibercaja	@ibercaja	28.980
ING	ing	@ing_es	2.784
Kutxabank	kutxabank	@kutxabank	14.831
Liberbank	liberbak	@liberbank	164.754
Lloyds Bank International	lloydsbankinternational	--	1.720
Open Bank	openbank	@openbank_es	5.939
Triodos Bank	triodosbank	@triodoses	3.465
Unicaja	unicaja	@unicajacb	95.757

*Nota:* \*Bankia y Caixabank se han integrado durante el periodo de estudio, por ello figuran separadamente.

*Fuente:* Elaboración propia.

la sección metodológica del artículo García-Crespo *et al.* (2017). En particular, para este estudio se incluyeron las instituciones y *keywords* especificadas en la tabla 1.

Por tanto, al analizar este contenido es posible identificar las características de los usuarios corporativos en función de las palabras empleadas. De esta forma, hemos podido diferenciar el contenido generado por la empresa del generado por los usuarios. Utilizando las métricas de re-tweets es posible estimar la respuesta de los usuarios no corporativos al contenido generado por los usuarios corporativos (FCC). En la tercera

columna de la tabla 1 se presentan los nombres de los usuarios correspondiente a las instituciones consideradas. El objetivo del análisis desarrollado es proporcionar un conjunto de indicadores para el estudio y análisis del conocimiento sobre las principales empresas del sector bancario español.

Nos centramos en el sector bancario español durante el periodo que comienza el 30 de octubre de 2020 hasta el 30 de octubre de 2021. En la muestra tenemos datos de las treinta principales empresas que ofrecen servicios bancarios en España, y que en conjunto, representan el 91,2 % de la actividad bancaria total en dicho periodo. Para ello se recopilamos los *tweets* que contienen al menos una de las palabras especificadas para cada entidad incluida en el presente estudio.

Otro aspecto muy relevante de esta investigación es que solo utilizamos datos en castellano. Siguiendo el procedimiento establecido por Crespo *et al.* (2017), recopilamos todos los *tweets* que contenían el nombre de la marca de cada empresa incluida en el estudio. Como indican Crespo *et al.* (2017), de esta manera aseguramos incluir todos los datos que se refieren a la marca, es decir los *tweets* emitidos por la empresa, conocidos en la literatura como “corporativos”, así como los que publican los demás usuarios, es decir los “no corporativos”. Todos nuestros datos son “*tweet* de marca”, es decir, son *tweets* que contiene el nombre de la marca. La mayoría de las investigaciones anteriores se limitan a recopilar menciones, sin considerar los demás “*tweets* de marca”. En este sentido, este conjunto de datos es más completo y representativo de las conversaciones sobre las marcas en Twitter.

Por lo general, cuando los usuarios no corporativos comparten experiencias, opiniones, percepciones o incluso bromas sobre una marca no siempre emplean menciones. Solamente el 53 % de las conversaciones en las redes sociales sobre productos, marcas y firmas son menciones. Para tener una visión completa y total de las conversaciones en las redes sociales, se deben incluir también todos los *tweets*, que aún no mencionando a ninguna cuenta corporativa, se están refiriendo a dicha marca. Con esta estrategia de recolección de datos surge un nuevo reto que es poder filtrar los *tweets* que incluyen el nombre de la marca, pero no son relativos a la marca. Por ejemplo, en el caso del Banco Santander, necesitamos excluir todos los *tweets* que hablan sobre la ciudad llamada de esta misma forma.

En conjunto, la muestra incluye 2.768.300 observaciones (*i.e.*, *tweets*). En el caso de estudio, los usuarios de Twitter nombran las treinta marcas de servicios bancarios seleccionadas, aunque, como podemos observar, la distribución entre ellas resulta muy poco uniforme, lo cual era de esperar teniendo en cuenta la diferencia de tamaño y mercado.

Por otro lado, también es posible realizar un análisis preliminar de tipo cuantitativo con los datos extraídos de la red social Twitter.

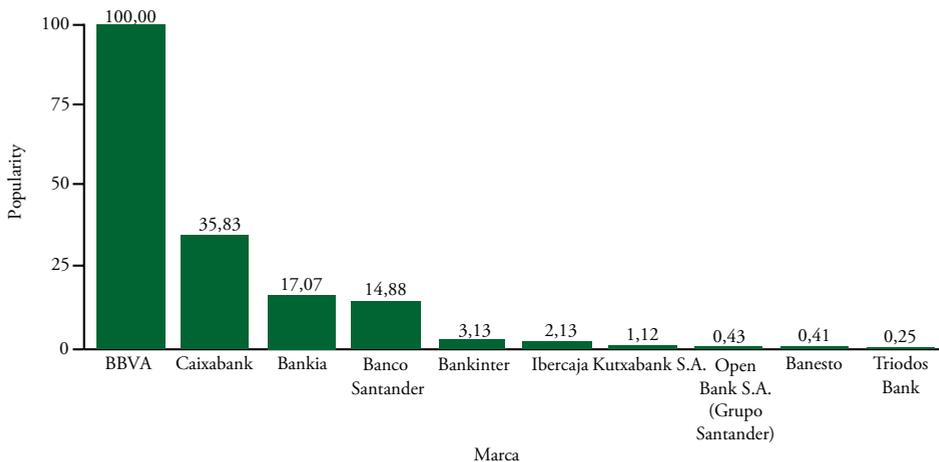
Las diferentes métricas que hemos calculado capturan diferentes dimensiones del desempeño de cada marca en esta red social. Las métricas son las siguientes:

- **Popularidad:** se calcula contabilizando la totalidad de *tweets* de marca en el periodo de análisis para cada una de las empresas incluidas en el estudio. Si esta métrica la calculásemos respecto a todo el sector y en porcentaje, podríamos decir que se trata de la cuota de voz (*share of voice*). Cuánto más se hable de una marca, en principio, es positivo, ya que indica que la marca forma parte de la conversación, está viva y presente en la vida de los usuarios. Evidentemente, en caso de crisis de reputación sería lo contrario. Esta métrica debe complementarse con el análisis de sentimiento o valencia de los *tweets*. Este aspecto no lo abordamos en este trabajo, si bien hemos realizado aproximaciones mediante un análisis de temas o *topic análisis* (Ceballos, 2017).
- **Esfuerzo:** representa la cantidad de *tweets* que se han emitido desde la cuenta corporativa de la empresa. La actividad de la marca en redes sociales es parte de la estrategia de marca. Cuando se trata de un sector de gran consumo o mercado de consumidores, cuánto más esfuerzo se dedique a la comunicación dirigida a los diferentes usuarios mayor será la orientación al mercado de la empresa. Ciertos bienes o sectores escapan a esta afirmación.
- **Alcance:** referencia al número total de seguidores de la cuenta corporativa multiplicado por el número de mensajes emitidos.
- **Engagement o implicación:** se refiere al número total de interacciones que han recibido los *tweets* corporativos para cada una de las empresas.

Por último, se han combinado dichas métricas para tener un indicador cuantitativo agregado que sirva para resumir y comparar el desempeño de las diferentes empresas. Con fines comparativos se han reescalado las diferentes métricas.

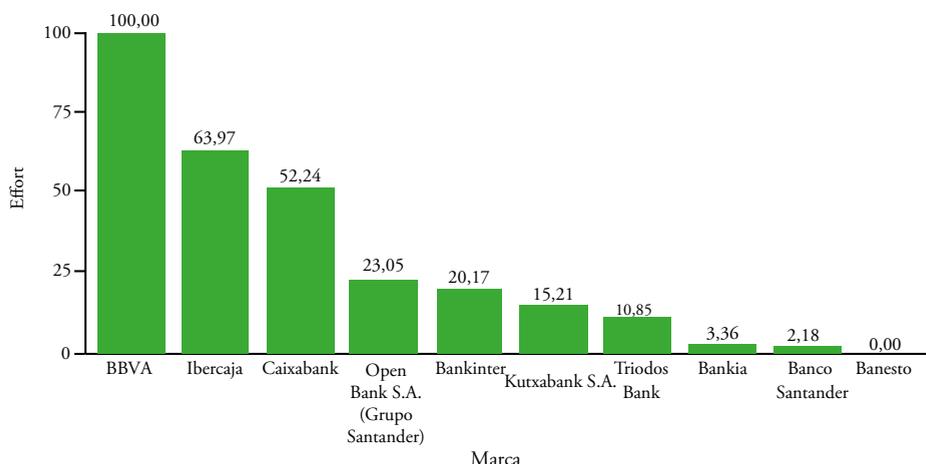
Figura 1.

### Métrica popularidad o menciones para las principales empresas



Fuente: Elaboración propia.

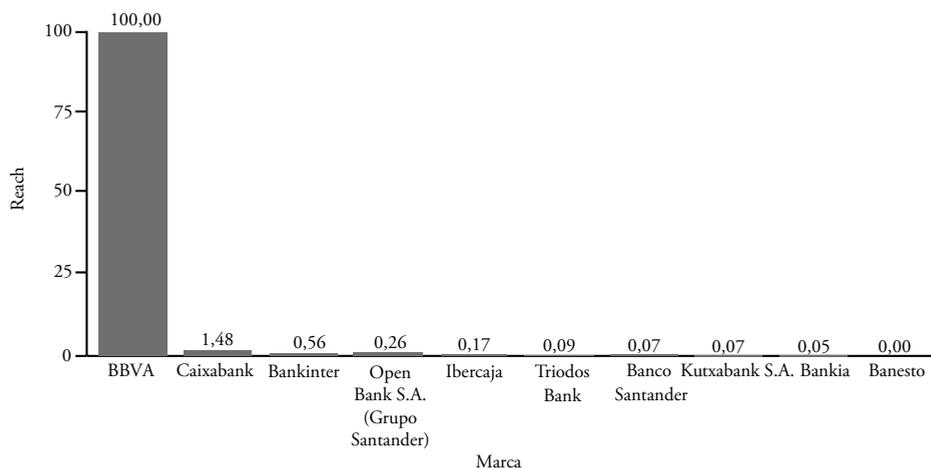
Figura 2.

**Métrica esfuerzo para las principales empresas**

Fuente: Elaboración propia.

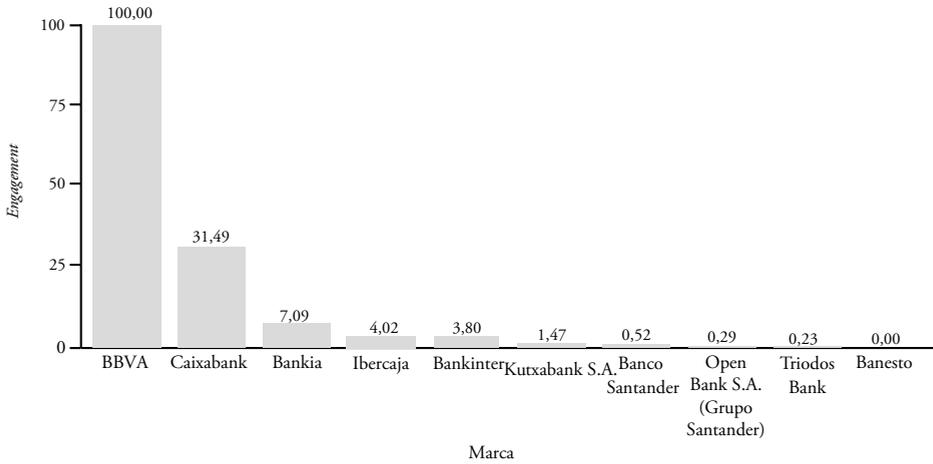
La figura 1 presenta la métrica *popularity* donde se puede apreciar que el desempeño relativo de la empresa BBVA en esta red social ha sido claramente elevado. También es interesante indagar la comparación del esfuerzo en la figura 2 donde se muestra un ordenamiento similar, aunque en este caso no son tan marcadas las distancias como en el indicador anterior. Si observamos las figuras 3 y 4, encontramos los resultados para alcance y *engagement*.

Figura 3.

**Métrica alcance para las principales empresas**

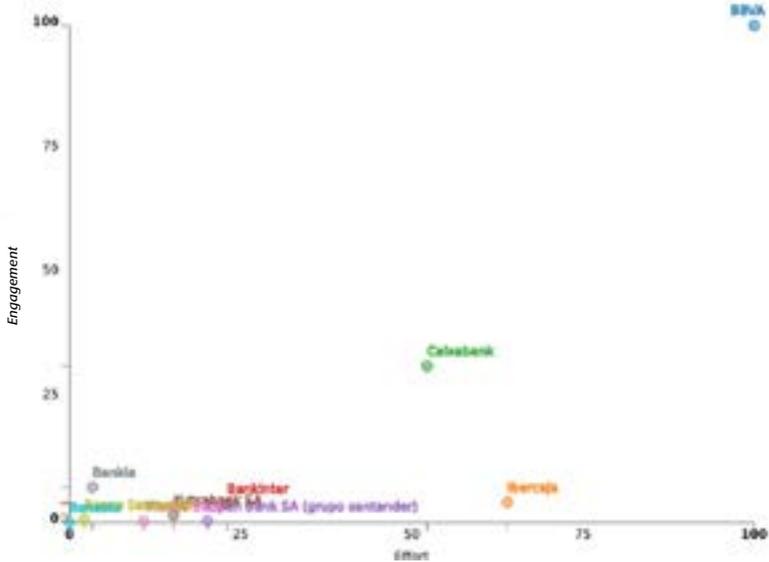
Fuente: Elaboración propia.

Figura 4.

Métrica *engagement* para las principales empresas

Fuente: Elaboración propia.

Figura 5.

Diagrama de dispersión entre las métricas *engagement* y esfuerzo

Fuente: Elaboración propia.

Utilizando las mismas métricas y presentándolas en una matriz, nos permite analizar la posible asociación (o la falta de ella) entre las métricas. La figura 5 presenta un patrón de asociación directa bastante definido entre las métricas esfuerzo y *engagement*. No podemos perder de vista que los datos expuestos son de corte transversal y se corresponden con el cálculo agregado para todo el periodo, sin realizar un análisis temporal.

#### 4.1.2. Conclusiones

Hemos analizado ciertas medidas que pueden encontrarse en las redes sociales y se consideran trazas del valor de marca. En concreto, la popularidad o presencia de la marca *online* es un indicador de la notoriedad de la marca. Debe ser completado con el análisis de la valencia o del sentimiento. Diferentes estudios han concluido que las diferentes aplicaciones como instrumentos de monitorización de los medios sociales que estiman el sentimiento, no son capaces de clasificar adecuadamente el contenido de las redes sociales dada su ambigüedad, el lenguaje corriente y la ironía que contienen. Por ello, proponemos en su lugar, realizar un análisis de contenido o *topic análisis* descomponiendo los mensajes y construyendo un corpus *ad hoc*. Cada sector o rama de actividad necesita su propio corpus y diccionario. Un mismo adjetivo (pequeño o grande, grueso o fino, por ejemplo) tienen muy distintas connotaciones dependiendo de la rama de actividad, producto o servicio.

Por otro lado, el contenido de los mensajes o comentarios de los usuarios que responden o se refieren a un mensaje corporativo debe ser también analizado. Lograr la implicación del consumidor o usuario de la marca es una de las metas de la comunicación de *marketing*. La calidad y optimización de esta comunicación es el objeto de la siguiente aplicación.

#### 4.2. Aplicación a la optimización de la comunicación

La comunicación *online*, además de los *tweets* anteriormente mencionados, incluye todo tipo de imágenes y vídeos. Su optimización requiere de un *pretest* o de un análisis aún más avanzado, como el que se nutre de técnicas usadas en *neuromarketing*.

Mediante la aplicación de metodologías de *neuromarketing* se puede investigar y analizar el comportamiento humano. Se utilizan diversos tipos de sensores para la recolección de datos (*eye-tracker*, GSR, ECG, etc.). Gracias a estos, se pueden obtener nuevas perspectivas sobre los procesos subconscientes que componen las experiencias humanas en respuesta a varios tipos de estímulos y los resultados deseados en respuesta a estos estímulos (iMotions, MIT).

El rastreo del movimiento del ojo, ha existido ya hace varias décadas. Ahora la diferencia radica en los sensores utilizados, en otras palabras, la recolección de datos. Ya no son procesos tan invasivos como antes, además de su adquisividad, coste reducido y facilidad en realizar su montaje. El uso del *eye-tracker* permite ver nuevas perspectivas de la publicidad no

solo en sus diseños, sino particularmente en identificar los elementos que llaman la atención y superan el umbral de indiferencia de la audiencia, además de cuáles son ignorados.

El rostro humano es una de las primeras puertas para explorar nuestra psique, ya que este está al descubierto para ser leído e interpretado por todos los que lo puedan ver. Una manera del *neuromarketing* de optimizar la publicidad, para obtener una mayor notoriedad de marca, es a través de las emociones, porque éstas tienen un impacto sobre nuestra atención, percepción y memoria. Con herramientas como iMotions se permite ver la interacción entre un estímulo y las conductas cognitivas de respuesta que provoca. Por esta razón el complemento de la cámara, que usa cambios sutiles en los indicadores como los ojos, cejas, labios, fosas nasales y otras, así como en conjunto, permite trabajar simultáneamente con el *eye-tracker* para obtener emociones asociadas a los estímulos (Winer, 2009).

Tabla 2.

### Tabla de estímulos

<i>Etiqueta del estímulo</i>	<i>Tipo de estímulo</i>
Cartel-seguro-unicaja	Imagen
FundacionIberCaja1080	Vídeo
Ibercaja-cartel-banca-movil-quelinka	Imagen
Kutxabank2	Imagen
KutxabankGanador	Imagen
KutxaBankKorner1080	Vídeo

Fuente: Elaboración propia.

Figura 6.

### Fotos de la sesión de laboratorio 3M MADCOM Universidad Carlos III de Madrid

Proceso de calibración



Sesión video Kutxabank



Fuente: Elaboración propia.

Hemos realizado una serie de experimentos utilizando el 3MLab MADCOM de la Universidad Carlos III de Madrid. Para comenzar hemos seleccionado una serie de estímulos, imágenes y vídeos (ver apéndice 1) y aplicando técnicas de *neuromarketing* para detectar la secuencia o recorrido de la vista del sujeto. En varias sesiones de laboratorio se expusieron

a siete personas a cinco estímulos, imágenes y vídeos, presentados de forma aleatoria en un bloque con una duración de 10 minutos.

En la figura 7 (los estímulos estáticos, *i.e.* imágenes) podemos apreciar que la cara humana en uno de los anuncios es la que atrae más la atención y comprobamos que en la mayoría de los casos se presta atención a la marca o anunciante. Este es el primer requerimiento (Vakratsas y Ambler, 1999) para obtener una comunicación eficaz.

Los resultados de los mapas de calor agregados son los siguientes:

Figura 7.

### Mapas de calor agregados



Fuente: Elaboración propia.

Tabla 3.

**Porcentajes de emociones por estímulo**

<i>Etiqueta del estímulo</i>	<i>Anger</i>	<i>Sadness</i>	<i>Joy</i>	<i>Surprise</i>	<i>Fear</i>	<i>Contempt</i>
Cartel-seguro-unicaja	0	0	16.66666667	0	0.56	0
FundacionIberCaja1080	0.788571429	0.108571429	1.785714286	0.301428571	0	2.052857143
Ibercaja-cartel-banca-movil-quelinka	0	0	0.095714286	0.671428571	0	0
Kutxabank2	3.152857143	4.778571429	6.714285714	0	0	1.342857143
KutxabankGanador	0	0	2.054285714	0	0	0.047142857
KutxaBankKorner1080	0.261428571	2.847142857	5.404285714	0.04	0	14.28571429

*Fuente:* Elaboración propia.

El análisis de las emociones mediante iMotions nos sugiere que el sexto estímulo, un vídeo, logra estimular emociones, las cuales a su vez operan como anclaje del mensaje y la marca anunciada. Esta comunicación es un ejemplo de comunicación eficaz. Faltaría ver, cómo atraer a la audiencia al canal o medio donde se coloca el estímulo publicitario.

Por último, mediante el análisis de la respuesta a nivel de la piel (*GSR, Galvanic skin response*) corroboramos la intensidad y relevancia de las emociones que se han detectado a través de los micromovimientos del rostro.

El análisis de las emociones mediante iMotions nos sugiere diferentes reacciones a cada estímulo, donde cada uno logra sacar a la superficie emociones por pequeños instantes, las cuales a su vez operan (deseada o no deseada) como anclaje del mensaje y la marca anunciada. En la tabla 3 se puede notar que, en estos breves instantes, las emociones básicas *anger, sadness* y *joy* son evocadas en los participantes. En promedio, la emoción alegría es la que prevalece en el mayor porcentaje de tiempo de exposición (*joy*) en cada estímulo, como se puede ver en la cuarta columna de la tabla 3. También mirando la dinámica de las emociones (variación de emociones sentidas en el transcurso de la imagen/vídeo), el cuarto estímulo logra obtener la mayor variación, presentando tres de las cinco emociones básicas. Estos resultados pueden ser un claro ejemplo de comunicación eficaz, dependiendo de la intención afectiva (*anger, joy, fear, etc.*) deseada en la audiencia objetivo (a quien el mensaje va direccionado).

## 5. CONCLUSIONES

En la comunicación *online* se pueden encontrar medidas que reflejan los indicadores del valor de marca basado en el consumidor (CBBE). Hemos mostrado un ejemplo aplicado a Twitter donde se han analizado todos los *tweets* que contenían el nombre de las marcas estudiadas. Esto nos permite medir la popularidad *online* de una marca, que es una aproximación al concepto de notoriedad. Más allá de eso, se ha estimado que parece existir una asociación entre el esfuerzo generado por la marca (FCC) y el *engagement* o implicación del consumidor. Cuando estas medidas se realizan en forma relativa y ponderadas por índices de sentimiento,

se puede obtener una mejor versión del valor de marca *online*. Las asociaciones que provoca la marca pueden ser abordadas mediante un análisis de contenido, para el que es necesario desarrollar un corpus y diccionario *ad hoc*.

Para que esta comunicación sea eficaz, se deben analizar los diferentes niveles de la respuesta del mercado.

Las campañas de comunicación, por otra parte, pueden optimizarse mediante técnicas de *neuromarketing*. Lo primero que hemos observado es que es posible verificar si la marca anunciada ha sido percibida por la audiencia. Pasando luego al nivel afectivo de la respuesta del mercado, hemos medido las emociones provocadas por los anuncios. Los resultados son especialmente interesantes para el caso de uno de los vídeos analizados. Gracias a los resultados se pudo observar si la respuesta afectiva tiene una dinámica grande (evocando varias emociones), como se pudo constatar con los estímulos 2, 4 y 6, o una dinámica pequeña (evocando mayoritariamente una emoción) como ocurre con el estímulo 1.

En resumen, se han presentado ejemplos aplicados al sector financiero español que ofrecen oportunidades para apalancar el valor de la marca. El primero, persigue presentar ciertos indicadores de notoriedad e implicación. En el segundo, vemos cómo optimizar la comunicación *online*, previa al lanzamiento de una campaña, verificando si atrae la atención hacia los estímulos deseados, como son la marca y si las emociones que provoca son lo suficientemente fuertes para motivar a la audiencia y al potencial cliente.

## Referencias

- BRUHN, M., SCHOENMUELLER, V. y SCHÄFER, D. B. (2012). Are social media replacing traditional media in terms of brand equity creation? *Management Research Review*, 35(9), pp. 770-790.
- CEBALLOS, M., GARCÍA-CRESPO, A. y LADO, N. (2016). Impact of firm-created content on user-generated content: using a new social media monitoring tool to explore twitter. En: *Rediscovering the Essentiality of Marketing* (pp. 303-306). Springer.
- DE VRIES, N. y CARLSON, J. (2014). Examining the drivers and brand performance implications of customer engagement with brands in the social media environment. *Journal of Brand Management*, 21, pp. 495-515 (August 2014).| Doi:10.1057/bm.2014.18
- ERDEM, T. y SWAIT, J. (1998). Brand Equity as a Signaling Phenomenon. *Journal of Consumer Psychology*, 7(2), pp. 131-157.
- ESTEBAN-BRAVO, M. y LADO, N. (2011). Brand value in horizontal alliances: the case of twin-cars. *Journal of the Operational Research Society*, 62(8), pp. 1533-1542.
- GARCÍA-CRESPO, A., CEBALLOS, M., GONZÁLEZ-CARRASCO, I. y LADO, N. (2017). Innovation in the Spanish twittersphere: An ontology and stakeholders'salience analysis. En: *Revolution of Innovation Management* (pp. 97-128). Springer.

- JOSHI, A. y HANSENS, D. M. (2013). The direct and indirect effects of advertising spending on firm value. *Journal of Marketing*, 74(1), pp. 20-33.
- KELLER, K. L. (1993). Conceptualizing, measuring, and managing customer-based brand equity. *The Journal of Marketing*, 10(1), pp. 1-22.
- KELLER, K. L. (2016). Reflections on customer-based brand equity: perspectives, progress, and priorities. *AMS Rev*, 6, pp.1-16. <https://doi.org/10.1007/s13162-016-0078-z>
- KUMAR, V., BHASKARAN, V., MIRCHANDANI, R. y SHAH, M. (2013). Creating a measurable social media marketing strategy for hokey pokey: Increasing the value and ROI of intangibles and tangibles. *Marketing Science. Articles in Advance*, 32(2), pp. 194-212.
- LUO, X. y DONTU, N. (2013). Marketing's credibility: a longitudinal investigation of marketing communication productivity and shareholder value. *Journal of Marketing*, 70(4), pp. 70-91.
- MSI (2016). <http://www.msi.org/research/2014-2016-research-priorities/>
- SRINIVASAN, S. y HANSENS, D. M. (2005). Marketing and Firm Value: Metrics, Methods, Findings, and Future Directions. *Journal of Marketing Research*, 46(3), pp. 293-312.
- VAKRATSAS, D. y AMBLER, T. (1999). How Advertising Works: What Do We Really Know? *Journal of Marketing*, 63(1), pp. 26-43. Doi:10.1177/002224299906300103
- VARGO, I. y LUSH, J. (2004). Evolving to a New Dominant Logic. *Journal of Marketing*, 68(1), pp. 1-17.
- WINER, R. S. (2009). New communications approaches in marketing: Issues and research directions. *Journal of Interactive Marketing*, 23(2), pp. 108-117.
- YOO, B., DONTU, N. y LEE, S. (2000). An examination of selected marketing mix elements and brand equity. *Journal of the Academy of Marketing Science*, 28(2), pp. 195-211.

## APÉNDICE 1

Los estímulos tipo imagen que se han utilizado con su etiqueta respectiva se pueden ver en la siguiente tabla.

Tabla A1.

**Estímulos imagen**

Cartel-seguros-Unicaja



Ibercaja-cartel-banca-movil-quelinka



Kutxabank2



KutxabankGanador



Vídeos:

Kutxabank Korner

<https://youtu.be/qaxBVQcJeJU>

SPOT Fundación IberCaja. Desarrollo integral de las personas:

<https://youtu.be/mjXwx80m5UM>



## Sobre los autores



### Daniel Belanche

Es profesor titular de Marketing en la Universidad de Zaragoza (España) e investigador del grupo METODO. Cuenta con más de cincuenta artículos publicados en revistas científicas. En sus líneas de investigación se aborda la interacción entre los usuarios o consumidores y la tecnología en ámbitos como la Administración Pública, el sector bancario o el turismo; con especial interés en el estudio de variables clave como las emociones, la influencia social, o la experiencia del usuario en contextos como la publicidad, las redes sociales o las decisiones de compra. En los últimos años su investigación se centra en el impacto de la inteligencia artificial y la robótica en los servicios desde la perspectiva del usuario.

Participa activamente en congresos científicos internacionales sobre los temas de investigación mencionados y forma parte del consejo editorial de revistas como: *The Service Industries Journal*, *International Journal of Consumer Studies*, o *Journal of Marketing Communications*.



### Manuel Ceballos

Es doctor en Ciencias Empresariales y Finanzas por la Universidad Carlos III de Madrid. Además, posee una maestría en Economía de la Empresa y Métodos Cuantitativos de la Universidad Carlos III de Madrid y una licenciatura en Economía por la Universidad Nacional de Córdoba (Argentina). Manuel posee una amplia formación en matemática y estadística. Su investigación se centra en la intersección entre el *marketing* y la comunicación, con particular foco en las redes sociales. Su trabajo ha sido presentado en conferencias internacionales como: *European Marketing Academy*, *The Frontiers in Service Conferencia* y *Academia de Ciencias del Marketing*. Profesor de grado y posgrado en múltiples universidades entre las que se destacan la Universidad Carlos III, IE University, Universidad Europea, ICADE, CUNEF y la Universidad Camilo José Cela.



### Camilo de la Cruz

Es ingeniero de sonido y posee un máster en Advertising Communications por la Universidad Carlos III de Madrid. Además, ha cursado un máster en *big data* por la UNE y un curso sobre neuromarketing aplicando iMotions, desarrollado por el MIT.



### Ángel Cuevas

El doctor Ángel Cuevas se licenció en Ingeniería de Telecomunicación, en Ingeniería Telemática y se doctoró en Ingeniería Telemática por la Universidad Carlos III de Madrid en 2006, 2007 y 2011, respectivamente. Actualmente es becario Ramón y Cajal (profesor ayudante titular) en el Departamento de Ingeniería Telemática de la Universidad Carlos III de Madrid y profesor adjunto en el Institut Mines-Telecom SudParis. Sus intereses de investigación se centran en las mediciones de Internet, la transparencia de la web, la privacidad y las redes P2P. Es coautor de más de 50 artículos en prestigiosas revistas y conferencias internacionales como *PNAS*, *IEEE/ACM Transactions on Networking*, *ACM Transactions on Sensor Networks*, *IEEE Network*, *IEEE Communications Magazine*, *WWW*, *ACM CONEXT*, *ACM CHI* y *USENIX Security*. Ha recibido el Premio al Mejor Trabajo en ACM MSWiM 2010 y el Premio de Investigación Emilio Aced 2018 concedido por la Agencia Española de Protección de Datos. La investigación del doctor Cuevas ha sido destacada en más de 200 medios de comunicación como *Financial Times*, *The Sunday Times*, *Le Figaro*, *Newscientists*, TVE, La Sexta, Antena 3, Cadena Ser, Cadena Cope, RNE, *El País*, *El Mundo*, *El Diario*, etcétera.



### Rubén Cuevas

El doctor Rubén Cuevas es profesor titular del Departamento de Ingeniería Telemática de la Universidad Carlos III de Madrid (UC3M). También es subdirector del Instituto Big Data UC3M-Santander (IBiDAT). Entre enero y diciembre de 2012 fue profesor adjunto de cortesía en el Departamento de Informática y Ciencias de la Información de la Universidad de Oregón.

Obtuvo el doctorado y el máster en Ingeniería Telemática y el máster en Ingeniería de Telecomunicaciones en la Universidad Carlos III de Madrid en 2010, 2007 y 2005, respectivamente. Además, obtuvo un máster en Planificación y Gestión de Redes en la Universidad de Aalborg (Dinamarca) en 2006.

Rubén es coautor de más de 70 artículos en prestigiosas revistas y conferencias internacionales como: *ACM CoNEXT*, *WWW*, *Usenix Security*, *ACM HotNets*, *IEEE Infocom*, *ACM CHI*, *IEEE/ACM TON*, *IEEE TPDS*, *CACM*, *PNAS*, *Nature Scientific Reports*, *PlosONE* o *Communications of the ACM*. Ha sido el IP de trece proyectos de investigación financiados por los programas H2020 y FP7 de la UE, el Gobierno Nacional de España y empresas privadas, y en total ha participado en 27 proyectos de investigación. Los principales intereses de investigación de Rubén incluyen la publicidad en línea, la transparencia de la web, la personalización y la privacidad, las mediciones de Internet y su aplicación para resolver problemas de larga data en otras disciplinas como la economía o la sociología.

Sus investigaciones sobre la piratería en el intercambio de archivos, las redes sociales *online*, el fraude en la publicidad *online* y la transparencia en la web han aparecido en los principales medios de comunicación internacionales y nacionales como: *The Financial Times*, *BBC*, *The Guardian*, *The Times*, *New Scientist*, *Wired*, *Corriere della Sera*, *O'Globo*, *Le Figaro*, *El Universal*, *El País*, *El Mundo*, *ABC*, Cadena Ser, Cadena Cope, TVE, Antena3, La Sexta, etcétera.

Rubén ha recibido varios premios de prestigio entre los que destacan el Premio Fundación Telefónica a la mejor Tesis Doctoral Española en Redes y Servicios de Comunicación otorgado por la Asociación Española de Telecomunicaciones así como el Premio de Investigación Emilio Aced 2018 al mejor trabajo de investigación en protección de datos otorgado por la Autoridad Española de Protección de Datos.

Rubén ha impartido docencia desde 2006 en diferentes grados y másteres de la UC3M en los ámbitos de la Ingeniería de Telecomunicaciones, la Ingeniería Telemática y la Informática. Además fue el instructor principal de un curso de Master/PhD en el departamento de CIS de la Universidad de Oregón en el semestre de otoño de 2012.



### **Carlos Flavián**

Es catedrático de Marketing en la Universidad de Zaragoza (España) y director del grupo METODO. Su investigación se centra en el análisis de la interacción de las personas con las nuevas tecnologías, estudiando las percepciones, las intenciones de comportamiento y los comportamientos reales de los consumidores (por ejemplo, adopción, recomendación, eWOM, satisfacción, fidelización, etc.). Su investigación se desarrolla en diversos contextos, como la adopción de servicios a través de Internet y, más recientemente, en el contexto de la inteligencia artificial, los robots de servicio, la realidad virtual, la realidad aumentada y otras tecnologías de la Industria 4.0.

Es editor de *Spanish Journal of Marketing-ESIC*, editor asociado de *The Service Industries Journal* y miembro del consejo editorial de varias revistas.

Ha coordinado números especiales como editor invitado de varias revistas científicas internacionales como *International Journal of Contemporary Hospitality Management*, *Service Business* y *The Service Industries Journal*. Ha dirigido diversos eventos organizados en Zaragoza, Hong Kong, Tokio, Seúl y fundador de AIRSI (Artificial Intelligence & Robotics in Service Interactions) celebrados en 2019, 2020 y 2021.



### **Pablo Gómez Carrasco**

Es actualmente profesor contratado doctor interino del Departamento de Contabilidad de la Universidad Autónoma de Madrid. Realizó el Máster Oficial en Contabilidad, Auditoría y Mercados de Capitales (MACAM) con Mención de Excelencia en el año 2012 y obtuvo el doctorado en Economía de la Empresa en el año 2016 con Premio Extraordinario en la Sección de Empresariales. Su investigación, que gira en torno a la Responsabilidad Social Corporativa (RSC), la teoría de los *stakeholders* y las redes sociales, se ha publicado en diversas revistas nacionales e internacionales y fue reconocida con el VI Premio de la Cátedra UAM-Accenture en Economía y Gestión de la Innovación, “Agenda Digital e Innovación”. Ha presentado su trabajo en numerosos seminarios y congresos internacionales y completado su formación predoctoral con una estancia de investigación en la University of Exeter Business School (Reino Unido).



### **José González Cabañas**

El doctor José González Cabañas nació en Madrid, en 1994. Actualmente es investigador posdoctoral en el Instituto Big Data UC3M-Santander. Obtuvo su doctorado “Cum Laude” en Ingeniería Telemática en 2021, su máster en Ingeniería Telemática en 2017 y su licenciatura en Ingeniería de Sistemas de Comunicaciones en 2016 con el mejor expediente académico de su promoción; todos ellos por la Universidad Carlos III de Madrid (UC3M).

José realizó su doctorado con una beca FPU del Ministerio de Educación.

Ha publicado trabajos en prestigiosas conferencias internacionales como *ACM CHI*, *Usenix Security* y *ACM IMC* y en revistas como *JCR Q1*, *IEEE Access* y la *COVER de Communications of the ACM*. También ha trabajado en proyectos europeos H2020. Los intereses de investigación de José incluyen la publicidad en línea, la privacidad, la transparencia de la web, las mediciones de Internet y las redes sociales. Finalmente, su investigación ha sido destacada por diferentes medios de comunicación internacionales (periódicos, *online*, radio y TV) como *Financial Times*, *Newscientist*, *LeFigaro*, *TheTimes*, *El País*, Antena 3 Noticias, ABC, LaSexta, Cadena Cope, etcétera.



### **Encarna Guillamón**

Es profesora de la Universidad Carlos III desde 2006 del Área de Contabilidad y subdirectora de Gestión Docente del Departamento de Economía de la Empresa. Su investigación se centra en el estudio de la calidad de la información revelada por las empresas, la calidad de la información financiera y el rol de los directivos en la comunicación de esta información. También realiza investigación en responsabilidad social corporativa y calidad del control interno. Cuenta con más de 20 publicaciones en revistas de reconocido prestigio internacional y ha realizado seminarios invitados en universidades internacionales tan relevantes como la University of Miami (dentro del Programa Fulbright), Manchester Business School, Rotman School of Management (University of Toronto), University of Queensland, Durham University y University of Lancaster, entre otras. Encarna ha realizado estancias de investigación financiadas por programas altamente reputados y competitivos como el Programa José Castillejo, el proyecto Europeo Harmonia financiado por la Comisión Europea. Ha liderado y participado en más de 20 proyectos de investigación nacionales e internacionales, entre ellos el Proyecto Europeo Harmonia financiado por la Comisión Europea y ha evaluado proyectos para organismos internacionales como el Social Sciences and Humanities Research Council de Canadá.



### **Álvaro Labella**

Se licenció en la Universidad de Jaén en 2014 y se doctoró en Informática por la misma universidad en 2021. Actualmente es investigador posdoctoral en el grupo de investigación SINBAD de la Universidad de Jaén y sus áreas de investigación son la toma de decisiones, la computación con palabras y el desarrollo de aplicaciones de *software*. Durante el desarrollo de su tesis doctoral, ha publicado 20 artículos en revistas internacionales, así como 17 contribuciones en congresos internacionales y 4 en congresos nacionales. Durante sus estudios de doctorado realizó una estancia en la Universidad Técnica Nacional de Atenas (NTUA) en Atenas, Grecia, y en la Portsmouth Business School en Portsmouth, Reino Unido. Fue galardonado por la Universidad de Jaén con el Premio Ada Lovelace en la modalidad de Mejor Aplicación, en 2019 recibió el Premio al Mejor Trabajo de Estudiante en la Conferencia Internacional de Sistemas Inteligentes y Difusos en Estambul, Turquía, y el Premio al Mejor Trabajo en la Conferencia Internacional de Sistemas Inteligentes e Ingeniería del Conocimiento en Dalian, China.



### **Nora Lado**

Es catedrática de marketing en la Universidad Carlos III de Madrid. Ha realizado cursos de posgrado en marketing y finanzas en la Universidad Católica de Lovaina, Bélgica, y se ha doctorado en marketing por la Universidad Autónoma de Madrid.

Ha publicado, entre otros, en *Journal of Service Research*, *Journal of Business Research*, *Journal of Market Research*, *European Journal of Marketing*, *International Marketing Review* e *International Journal of Service*

*Industry Management*.

Ha sido vicedecana de la Licenciatura en Administración de Empresas, y subdirectora del máster en Administración de Empresas de la Universidad Carlos III, codirectora del máster *online* en Dirección Comercial y Marketing y directora del Instituto para el Desarrollo Empresarial (INDEM). Actualmente, es directora del máster universitario en Advertising Communications.



### **Luis Martínez**

Es actualmente catedrático del Departamento de Informática de la Universidad de Jaén. También es profesor visitante en la Universidad Tecnológica de Sydney, la Universidad de Portsmouth (Isambard Kingdom Brunel Fellowship Scheme), y en la Universidad Tecnológica de Wuhan (Chutian Scholar). Ha sido investigador principal en 16 proyectos de I+D, y ha publicado más de 195 artículos en revistas indexadas por el SCI y más de 200 contribuciones en conferencias internacionales relacionadas con sus áreas. Sus intereses de investigación actuales

incluyen la toma de decisiones multicriterio, los sistemas basados en la lógica difusa, la computación con palabras y los sistemas de recomendación. Ha recibido el premio IEEE Transactions on fuzzy systems Outstanding Paper Award 2008 y 2012 (otorgado en 2011 y 2015, respectivamente). Es coeditor jefe del *International Journal of Computational Intelligence Systems* y editor asociado de las revistas: *Information Sciences*, *Knowledge Based Systems* e *Information Fusion*. Es IFSA Fellow 2021, miembro sénior del IEEE. Finalmente, ha sido nombrado Highly Cited Researcher 2017-2021 en Ciencias de la Computación.



### **Daniel Peña**

Es profesor emérito de la Universidad Carlos III de Madrid (UC3M) donde ha sido catedrático desde 1990. Antes fue profesor en las Universidades Wisconsin-Madison, Chicago y Politécnica de Madrid. Autor de 16 libros y más de 250 artículos de investigación sobre Estadística, Econometría y sus aplicaciones. Su investigación ha recibido varios premios, como el Youden Prize al mejor artículo publicado en *Technometrics* en 2006, el Premio a la carrera profesional de la

Asociación de Antiguos Alumnos de la ETSII, UPM en 2010, el Premio Jaime I de Investigación en Economía en 2011, el Premio Ingeniero del año en 2011, por el Colegio Oficial de Ingenieros Industriales de Madrid, la medalla de honor de la Sociedad Estadística e Investigación Operativa en 2014, la medalla de honor de la UC3M en 2015 y el Premio Nacional de Estadística de España en 2020. Es Fellow de The American Statistical Association, The Institute of Mathematical Statistics, The Royal Statistical Society y miembro electo del International Statistical Institute.



### Jesús Romero

Realizó en la Universidad Complutense de Madrid sus estudios de grado en Ingeniería Matemática y un máster en Tratamiento Estadístico Computacional de la Información. En 2018 ganó el I-COM Data Science Hackathon. Laboralmente se introdujo en el mundo del *marketing* digital en la compañía Neo Media World donde lideró el departamento de datos y tecnología. Actualmente, compagina la preparación de su doctorado en Ingeniería Telemática por la Universidad Carlos III de Madrid con su trabajo en Accenture, donde lidera la disciplina de

análisis avanzado de los datos.



### Ricardo Urías

Aunque soy ingeniero industrial y MBA, comencé trabajando en *marketing* en Procter & Gamble, cautivado por su visión del Brand Management. De allí pasé a United Biscuits, como director de Marketing, y después a RadioTelevisión Española como director de Marketing Estratégico. Posteriormente, cambio al mundo de la agencia, primero en Leo Burnett, y luego con mi propia empresa, Azul, en una andadura de más de cinco años. De allí paso a Publicis, y cinco años más tarde me incorporo a Havas, grupo en el que he pasado

los últimos 18 años. En Havas Media Group comencé como director general de Estrategia e Innovación, y mi último cargo ha sido Global Managing Director de Forward, una de las tres Redes de Agencias de Medios del Grupo.

Aparte de mi vida corporativa, durante los últimos doce años he participado activamente en diversas *start ups* y emprendimientos, ya sea como socio minoritario o como asesor. Es el caso de Ticketea (vendido a Eventbrite en 2018) o de Reclamador. También fui socio fundador de Weon Glasses, empresa pionera de gafas conectadas, y soy el socio mayoritario de Azul y Rojo Ópticas.

Mi pasión por la docencia me ha llevado a ser profesor asociado de la Universidad Carlos III durante varios años, y a ser un colaborador habitual en diversos programas del Instituto de Empresa y de ESCP. Al final de julio de 2021, he dejado Havas para fundar PANDORA, Club y Academia de Curiosos, con el objetivo de difundir la cultura y de preparar a las personas al ritmo del cambio que llegará en los próximos años.



### **Raciél Yera Toledo**

Es ingeniero en Ciencias Informáticas (2010), y doctor en Ciencias Técnicas especialidad Informática (2016) por la Universidad Central de Las Villas, Cuba. Actualmente profesor auxiliar del Departamento de Ciencias Informáticas en la Universidad de Ciego de Ávila, Cuba. Sus intereses de investigación incluyen modelos de personalización y sistemas de recomendación, soportados por técnicas de inteligencia computacional. Su trabajo ha sido publicado en revistas reconocidas como: *Knowledge-Based Systems*, *Decision Support Systems*, *Applied Soft Computing*, *Expert Systems with Applications*, *Applied Intelligence*, entre otras. Es miembro del comité editorial de *International Journal of Computational Intelligence Systems*. Entre sus principales reconocimientos resaltan el IFSA Best Journal Paper 2019 otorgado por la International Fuzzy Systems Association, y el Premio Nacional de la Academia de Ciencias de Cuba 2020, con el título "Métodos de preprocesamiento de datos para sistemas recomendadores de filtrado colaborativo". Miembro del Consejo Técnico Asesor del Ministerio de Educación Superior de Cuba, joven asociado de la Academia de Ciencias de Cuba, y miembro del Tribunal Nacional Permanente para la obtención del grado de doctor en Ciencias, en la especialidad de Informática.





Funcas  
Caballero de Gracia, 28  
28013 Madrid  
Teléfono: 91 596 54 81  
Fax: 91 596 57 96  
publica@funcas.es  
www.funcas.es

ISBN 978-84-17609-62-7

