



Facultad de Ciencias Económicas y Empresariales

# **MANUAL DE INTEGRACIÓN DE ANALYTICS Y DIGITALIZACIÓN EN EL SECTOR DE LA MODA**

Autor: Javier Llerandi Fernández

Director: Tomás Curto

# Índice

- Abstract
- Introducción a la digitalización en retail
  - Retos de la adopción
- Técnicas en entornos digitales
  - Tendencias
  - Previsión de la demanda
  - Gestión de inventarios
  - Gestión de la calidad
  - Text mining
  - Reglas de asociación
  - Algoritmos predictivos y de clasificación aplicados al consumidor
  - Análisis de redes sociales
  - Segmentación
- Técnicas en entornos físicos
  - Tendencias
  - Optimización de vestidores
  - Asistentes digitales
  - Geolocalización y Heatmaps
  - Beacons
  - Realidad Virtual, aumentada y mezclada
  - Neuromarketing
  - Self-checkout
  - Nuevos modelos de compra
- Marco legal y ética
- Conclusión
- Bibliografía

## **Abstract**

El objetivo de este TFG es presentar algunas de las técnicas de analytics y digitalización en retail que se están aplicando, orientándolas hacia marcas de ropa, pues es un sector que se encuentra en plena evolución digital, y que puede encontrar mucho valor en este tipo de prácticas. Más allá de esto, se busca elaborar una especie de “manual” básico que se puede aplicar a empresas de distinto tamaño con el fin de dar comienzo a la transformación digital y empezar a enfocar las actividades del negocio hacia el dato. Además aportaremos algunas de las nociones básicas del marco ético y legal que se deben tener en cuenta al dar el paso hacia la digitalización puesto que ambas temáticas han estado en el foco público desde hace unos años.

Para la consecución de este objetivo, se dará una explicación teórica de cada técnica además de un ejemplo práctico haciendo uso de programas como R o Azure en el caso de técnicas de análisis de datos. En la sección de digitalización en el retail físico recopilaremos informes de grandes consultoras como Accenture o Deloitte, las cuales elaboran estudios de tendencias en este campo con frecuencia. Finalmente, el aspecto ético y legal consistirá en la síntesis de leyes como la GDPR y algunos de los dilemas éticos que se plantean hoy en día.

## Barreras

Pese a su inmensa utilidad, estas técnicas tienen varias barreras de adopción:

- **Coste:** La digitalización supone una inversión importante para las empresas ya que conlleva costes de formación, contratación, investigación, entre otros y frecuentemente les resulta más barato continuar con su modelo de negocio en vez de dar el paso digital. Pero no todas las empresas tienen las mismas necesidades ni requieren el mismo grado de digitalización.
- **Tiempo:** la digitalización lleva tiempo, ya que se tiene que reestructurar la empresa parcial o totalmente, y esto sumado a la inversión que requiere puede resultar inviable para la mayoría de negocios. Además, si se va a analizar datos, dependiendo de lo que queramos hacer, a veces tendremos que esperar unos meses o años hasta tener suficientes.
- **Disponibilidad de datos:** dependiendo del negocio, las muestras pueden ser muy pequeñas y difícil de extraer conclusiones ya que se tiene que acudir a fuentes distintas para construir un dataset.

Pero estas barreras de adopción puede complementarse con las siguientes soluciones:

- **Empezar por cosas simples:** No todas las empresas tienen las mismas necesidades. Algunas pueden necesitar un equipo de científicos de datos y otras un modelo de CRM simple . Se debe tener un plan de digitalización basado en la realidad de la empresa y que se ajuste a sus verdaderas necesidades.
- **Externalización de las actividades de análisis:** dependiendo de lo que queramos hacer, cabe la posibilidad de externalizar ciertas actividades. Muchas empresas dependen de agencias de marketing que llevan a cabo las labores de análisis de datos o gestión de medios.
- **Establecer sistemas de recogida de datos zero y first party data,** y buscar proveedores de second y third party data que aplique a sector y segmento de clientes.

# Técnicas en entornos digitales

## Tendencias

Las ventas a través del e-commerce han ido creciendo en los últimos años, y las empresas reconocen el potencial de este canal por lo que han incrementado su inversión en él. Además del paso hacia el e-commerce, se están explorando nuevas formas de optimizar la experiencia del cliente y la comprensión que tienen las empresas del mismo en términos de su comportamiento. Esto lleva a mejores recomendaciones, estrategias de precios más acertadas y previsiones de demanda más fieles, algo que se ha podido hacer en gran parte gracias a las cookies.

Además, desde la creación de las cookies podemos acceder a información de distinto tipo y de distintas fuentes obtenidas del comportamiento digital de los consumidores. Existen cookies first-party y third-party. Las first-party son aquellas propias de una empresa o una web, y las third-party se generan en una página y siguen al usuario a través de su sesión online, pudiendo recabar información de distintos tipos como si vieron un anuncio particular, o si llegaron a la web desde otra específica. También pueden extraer las compras que se hacen.

## **1. Previsión de la demanda**

La previsión de la demanda es la ciencia que intenta predecir cuantas unidades de un producto o servicio se van a vender. Es la base de todas las decisiones empresariales como la producción, inventario, personal, instalaciones requeridas... Esto es de especial interés para las marcas de ropa ya que suelen tener problemas de overstock o falta de stock, por lo que este tipo de técnica les permite ajustar la producción y así reducir su riesgo.

Las previsiones se pueden hacer a corto plazo (1 mes – 1 año), medio plazo (3 meses – 3 años) y largo plazo (> 3 años). Las previsiones a corto plazo pretenden organizar el trabajo mediante la asignación de tareas, y comprende la actividad de compras. Las previsiones a medio plazo engloban la planificación de ventas, producción y presupuesto, y las previsiones a largo plazo comprenden la planificación de nuevos productos, I+D y ubicación de las instalaciones.

Algo que debemos tener en cuenta es que las previsiones no son perfectas, y que se debe tener varios escenarios elaborados con distintas técnicas para minimizar el riesgo.

Para realizar una previsión, tenemos métodos cualitativos y métodos cuantitativos, dependiendo de lo que queramos estudiar.

### **Procedimiento**

Para realizar una predicción debemos seguir una serie de pasos. En primer lugar debemos determinar la utilización de la previsión, y seleccionar los artículos sobre los cuales vamos a realizarla. Tras esto, debemos determinar el horizonte temporal y el modelos o los modelos que usaremos. A continuación, debemos recabar los datos que vamos a analizar, y finalmente realizaremos la previsión, la validaremos, e implementaremos los resultados. Además de esto, conviene realizar un post-mortem al finalizar el periodo para determinar cómo se ha ajustado la previsión a la realidad, y que podemos mejorar del modelo en el futuro.

### Métodos cualitativos

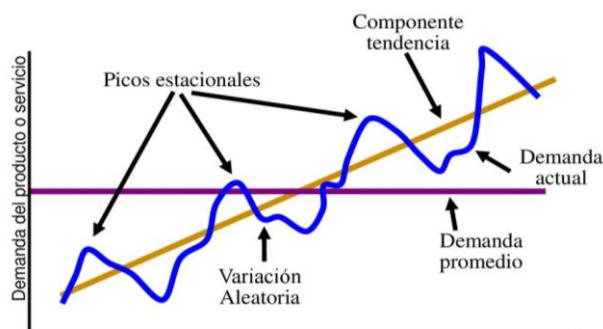
Usaremos métodos cualitativos si queremos predecir la demanda de nuevos productos o tecnologías, o si hay inestabilidad en el mercado, pues no tendremos datos históricos a nuestra disposición o estos no serán útiles para análisis cuantitativos. Estos métodos hacen uso de la experiencia y la intuición que aporta trabajar en el sector, por lo que se basan en opiniones subjetivas, pero estas no son menos válidas que los análisis cuantitativos puesto que la experiencia de una persona puede valorar aspectos de la realidad que no se pueden recoger fácilmente en un modelo. Aunque no nos enfocaremos en ellos, algunos de estos métodos son el jurado de opinión ejecutiva, propuesta del equipo comercial, método Delphi y el estudio de mercado.

### Métodos cuantitativos

Usaremos métodos cuantitativos cuando queremos predecir la demanda de productos y tecnologías existentes, o si hay estabilidad en el mercado, pues tendremos datos históricos para analizar. Estos métodos requieren técnicas matemáticas de análisis, y podemos separarlos en dos:

- Modelos de series temporales: las series temporales son una secuencia de datos uniformemente espaciados por períodos de tiempo. Se basa en datos pasados, y asume que los factores que influyeron en las ventas previamente, también lo harán en el futuro. Las series temporales tienen cuatro conceptos: la tendencia, los ciclos, la estacionalidad y las variaciones aleatorias.
  - Tendencia: movimiento gradual de los datos en el tiempo que persiste varios años. Por ejemplo, si cada período vendemos más, la tendencia será creciente.
  - Estacionalidad: ascenso o descenso regular de las ventas durante períodos específicos del año. Por ejemplo, los helados tienen picos de estacionalidad en los meses calurosos, y el chocolate durante el invierno.

- Ciclos: Movimientos de ascenso y descenso repetitivos que son difíciles de predecir y que duran varios años. Por ejemplo, los ciclos de superávit y recesión en la economía.
- Variaciones aleatorias: saltos en los datos causados por el azar y situaciones imprevistas. Duran poco y no se repiten, y no se pueden predecir.



- Dentro de los modelos de series temporales, tenemos varios métodos:
  - Enfoque simple: Asume que las ventas del próximo período serán las mismas que las del período anterior. Por ejemplo, si en enero vendimos 30 unidades, en febrero también venderemos 30. Este método tiene la mejor relación eficacia-coste.
  - Medias móviles: Las medias móviles son una serie de operaciones que se usan si no hay una tendencia clara. Se suele usar con el alisado exponencial.

$$media\ móvil = \frac{\sum\ demanda\ de\ n\ periodos\ previos}{n}$$



Mes	Ventas Reales	Media Móvil 3 Meses
Enero	10	
Febrero	12	
Marzo	13	
Abril	16	$(10 + 12 + 13)/3 = 11 \frac{2}{3}$
Mayo	19	$(12 + 13 + 16)/3 = 13 \frac{2}{3}$
Junio	23	$(13 + 16 + 19)/3 = 16$
Jul	26	$(16 + 19 + 23)/3 = 19 \frac{1}{3}$

comillas.edu

En el caso de que haya una tendencia, usaremos las media móviles ponderadas. Esta técnica atribuye un peso a cada período basándose en la experiencia e intuición.

$$\text{media móvil ponderada} = \frac{\sum(\text{peso de período } n) \times (\text{demanda en período } n)}{\sum \text{pesos}}$$

Mes	Ventas Reales	Media móvil ponderada 3 meses
January	10	
February	12	
March	13	
April	16	$[(3 \times 13) + (2 \times 12) + (10)]/6 = 12 \frac{1}{6}$
May	19	$[(3 \times 16) + (2 \times 13) + (12)]/6 = 14 \frac{1}{3}$
June	23	$[(3 \times 19) + (2 \times 16) + (13)]/6 = 17$
July	26	$[(3 \times 23) + (2 \times 19) + (16)]/6 = 20 \frac{1}{2}$

Pesos Aplicados	Periodo
3	Mes pasado
2	Hace 2 meses
1	Hace 3 meses
6	Suma de pesos

comillas.edu

- Alisado exponencial: El alisado exponencial hace uso de las medias móviles ponderadas, y es una técnica que predice la demanda futura teniendo en cuenta el promedio de ventas de los períodos anteriores y ajustándolo con las desviaciones del pasado. Los pesos disminuyen exponencialmente, dando mayor ponderación a los datos recientes. La constante de alisado toma valores entre 0 y 1, y se escoge de forma subjetiva.

$$F_t = F_{t-1} + \alpha(A_{t-1} - F_{t-1})$$

$F_t$  = nueva previsión

$F_{t-1}$  = previsión de período anterior

$A_{t-1}$  = Demanda real

$\alpha$  = constante ( $0 \leq \alpha \leq 1$ )

- Modelos ARIMA: Aunque muchas de las técnicas que se han comentado siguen utilizándose, estas son algo anticuadas, y ahora los modelos más utilizados son los llamados modelos ARIMA (Auto Regression Integrated Moving Average). Estos modelos hacen uso de las medias móviles y tienen en cuenta el pasado de la variable a mediar, en este caso las ventas. La principal limitación de este tipo de modelos, es que cuanto menor el plazo de predicción, más complejo será el modelo además de ser menos fiable. Además de estar muy limitados por el plazo, estos modelos necesitan una inmensa cantidad de datos históricos para funcionar correctamente.

○ Modelos asociativos:

- Regresión lineal: Se usa para prever la línea de tendencia, y toma la forma

$$Y = \alpha + \beta X$$

Y: variable a predecir, en este caso la demanda

$\alpha$ : término independiente

X: variable explicativa

$\beta$ : coeficiente de la variable explicativa (su peso)

El método para calcularla es el de los mínimos cuadrados ordinarios (MCO), el cual minimiza la suma de los errores cuadrados.

A continuación tenemos un ejemplo en el que se intenta predecir el precio del alquiler de una casa de Airbnb en Nueva York. Los datos recogen distintas variables como el barrio en el que se encuentra, su estancia mínima, si es una casa entera, compartida o una habitación...

En primer lugar se determinan las variables relevantes para incluirlas en el modelo final, lo cual se hace mediante el análisis de MCO y estudiando su p-valor.

	Estimate		
(Intercept)	-26565.524956	(Intercept)	***
availability_365	0.173238	availability_365	***
Bronx	142.069957	Bronx	***
Brooklyn	125.141975	Brooklyn	***
calculated_host_listings_count	-0.092771	calculated_host_listings_count	*
Entire.home.apartment	135.972631	Entire.home.apartment	***
latitude	-151.411296	latitude	***
longitude	-441.184138	longitude	***
Manhattan	175.584493	Manhattan	***
minimum_nights	-0.211604	minimum_nights	***
number_of_reviews	-0.194772	number_of_reviews	***
Private.room	35.251221	Private.room	***
Queens	146.881704	Queens	***
reviews_per_month	0.109363	reviews_per_month	
Shared.room	NA	Shared.room	
Staten.Island	NA	Staten.Island	

Las variables relevantes son aquellas que tienen asteriscos los cuales representan el p-valor, tal que cuantos más asteriscos más relevantes son, siendo tres asteriscos equivalente a un p-valor igual o menor que 0,001.

Finalmente, podemos crear la fórmula de la regresión para calcular el precio teniendo en cuenta los valores estimados:

$$\begin{aligned} \text{Price} = & -26565.52 + (0.17 \times \text{Availability}) + (142.06 \times \text{Bronx}) + \\ & (125.14 \times \text{Brooklyn}) + (175.58 \times \text{Manhattan}) + (146.88 \times \text{Queens}) + \\ & (135.97 \times \text{Entire.Home}) + (35.25 \times \text{Private Room}) - (0.19 \times \end{aligned}$$

Number.of.Reviews) – (0.21 x Minimun.Nights) – (0.09 x  
Host.Listings) - (151.41 x Latitude) – (441.18 x Longitude)

Ahora se puede tomar cualquier observación y obtener el precio para la propiedad. Por ejemplo: Apartamento entero en Manhattan con 25 reseñas, estancia mínima de 6 noches, y 5 listings del anfitrión. Disponibilidad 180 días. Latitud 40.73 y Longitud –73.90.

• Price = -26565.52 + (0.17 x 180) + (142.06 x 0) + (125.14 x 0) + (175.58 x 1) + (146.88 x 0) + (135.97 x 1) + (35.25 x 0) – (0.19 x 25) – (0.21 x 6) – (0.09 x 5) - (151.41 x 40.73) – (441.18 x –73.90)

• Price = -26565.52 + 30.6 + 175.58 + 135.97 - 4.75 - 1.26 - 0.45 - 6166.93 + 32603.2

• Price = \$206.44 Una propiedad con las características citadas tendría un precio de \$206.44

De la misma manera, para nuestro caso podemos hacer un estudio que identifique las variables relevantes para la demanda de nuestros productos, camisetas por ejemplo. Si las variables relevantes son el número de publicaciones de moda en redes sociales, el mes (por el tiempo y época del año), y la temperatura media, si introducimos estos datos en la regresión podremos estimar la demanda de camisetas.

## **2. Gestión de inventarios**

La gestión de inventarios puede ser una fuente de ventaja competitiva no solo por ser capaz de alcanzar la demanda y completar los pedidos a tiempo, sino por la reducción de costes que implica. En Estados Unidos por ejemplo, el coste medio de mantener el inventario es del 30 al 35% de su valor por obsolescencia, seguros, ... por lo que si una empresa tiene un inventario valorado en \$50 millones, el coste de mantenerlo será de entorno \$15 millones. No obstante, es importante mantener un inventario ya que permite hacer frente a las demandas inciertas y oscilantes, la incertidumbre generada por los proveedores, amortiguar imprevistos como averías o fallos de calidad... Hay dos modelos de gestión de inventarios:

- Demanda dependiente: Estos modelos se usan cuando la demanda de un bien depende de otro, pero no nos enfocaremos en ellos.
- Demanda independiente: Los modelos de demanda independiente se utilizan cuando esta se ve afectada por las condiciones del mercado. Hay tres tipos de modelos:
  - Cantidad fija de pedido o revisión continua: Cada vez que se realiza una transacción se revisa el nivel de inventario, y cuando decrezca hasta cierto punto se hará un nuevo pedido, siempre de por la misma cantidad.
  - Modelos de periodo fijo o revisión periódica: Se revisa el inventario cada vez que pasa un período determinado de tiempo, y el pedido se hace para alcanzar un nivel de inventario preestablecido.
  - Modelos probabilísticos: Se utilizan cuando la demanda no es constante o es inestable, por lo que se requiere un stock de seguridad para hacer frente a posible roturas de stock. Para determinar el stock de seguridad necesario, nos basaremos en el

nivel de servicio (probabilidad de no tener una ruptura de stock) previsto. Para aplicar este modelo, asumimos que la demanda de un período sigue una distribución normal. Veamos este modelo junto con el de cantidad fijada de pedido, aunque también se puede aplicar al de período fijo:

- En el sistema de cantidad fija, se revisa el stock de forma continua hasta llegar a un mínimo, momento en el cual hacemos un nuevo pedido, por el cual debemos esperar un tiempo de suministro (TS) hasta recibirlo. Si la demanda aumenta en este período y el TS es mayor al esperado, habrá un ruptura de stock, por lo que necesitamos un stock de seguridad (SS) para hacer frente a él. El SS se calcula:

$$SS = Z \times S_{TS}$$

Z: número de desviaciones típicas correspondientes al nivel de servicio deseado

$S_{TS}$ : desviación típica de la demanda durante el TS. El punto de pedido (PP) se calcula  $PP = \text{Demanda esperada en TS} + Z S_{TS}$

Sumado a estos modelos de gestión de inventarios, se está dando un cambio de la cadena de suministros tradicional a una digital, los llamados digital supply networks (DSN). Los DSN son cadenas de suministros dinámicas que hacen frente a la incertidumbre y falta de capacidad de reacción que conllevan las tradicionales mediante el uso de datos en tiempo real. Esta nueva modalidad de cadena de suministro permite una mayor transparencia en todos los pasos mediante el uso de sensores, tal que se puede saber en todo momento el stock exacto en tienda y en almacén o la ubicación de un pedido de reposición. Esto implica que podemos actuar proactivamente, sobre todo si hacemos uso de herramientas como el machine learning, o predicciones para estimar la demanda tal como comentamos en el punto anterior, para anticiparnos a

posibles rupturas de stock. No solo esto, sino que también podremos gestionar el stock moviéndolo entre tiendas con poca antelación, optimizando así los inventarios, algo que comentaremos más adelante.

En cuanto al machine learning en este campo, esta técnica es capaz de optimizar la gestión de inventarios gracias a la gran disponibilidad de datos en tiempo real y su integración con otros software y el rastreo de productos.

Amazon por ejemplo está implementando el machine learning en prácticamente todos los pasos de su cadena de suministro con el uso de series temporales y aprendizaje por, y ahora la demanda, los pedidos a proveedores y el almacén está guiado por machine learning o incluso modelos más complejos de inteligencia artificial.

El machine learning tiene dos aplicaciones principales en la gestión de inventarios:

- **Predicción de la demanda:** Aunque ya la hemos tratado detalladamente en el punto anterior, también la mencionaremos en la gestión de inventarios dada su estrecha relación. Esta predicción permite estimar la demanda que habrá en el futuro.
- **Gestión del inventario a través de aprendizaje por refuerzo:** Este aplicación implica que una inteligencia artificial toma el control casi en su totalidad de las operaciones de inventario, con revisiones y ajustes manuales para corroborar y optimizar los resultados. El aprendizaje por refuerzo permite que una inteligencia artificial tome decisiones en base a sus predicciones, “castigando” al modelo cuando permite que un producto se quede sin stock o compra demasiado.

Con el machine learning siempre debemos tener en cuenta la gran cantidad de datos que necesitan, generalmente datos de varios años, y que no todos los productos seguirán el mismo modelo ni serán igual de fáciles de predecir.

Finalmente, algo que se está estudiando es el uso del procesado de lenguaje natural (NLP) para optimizar la cadena de suministros. El NLP es una técnica

que estudia cantidades masivas de texto que puede venir de blogs, redes sociales, noticias,... para resumirlo y extraer conclusiones. Las aplicaciones que se están dando son el estudio de ciertas palabras clave para determinar si un suministrador o productor está teniendo problemas, cambios meteorológicos que pueden afectar el tiempo de envío, estudiar si los suministradores obtienen los materiales de forma ética, hacer un benchmarking de precios de combustible y transporte... Por ejemplo, la demanda de algunos bienes como el papel higiénico aumentó en hasta 600% durante el comienzo de la pandemia, y aunque ninguna empresa estaba preparada para esto, mediante el uso de NLP se podría haber detectado un aumento en ciertas búsquedas, y junto los DSN se hubiese visto que el stock disponible estaba descendiendo rápidamente a nivel mundial, lo cual hubiese permitido a las empresas mitigar muchas de las consecuencias que tuvieron que afrontar posteriormente como la ruptura de stock, retraso de pedidos, quiebra de suministradores y distribuidores, entre otros muchos ejemplos.



### 3. Gestión de la calidad

La calidad es una parte esencial de cualquier tipo de negocio, pero aún más en un fabricante de ropa, ya que un defecto en una prenda por lo general hará que esta no se pueda vender. Es por esto que el trabajo debe centrarse en el control de calidad, ya que este supone un ahorro en dinero (menos defectos y por tanto menos desperdicio) y contribuye a la fidelidad de los clientes. Más detalladamente, el control de la calidad aumenta la rentabilidad mediante:

- Respuesta más rápida ante crisis.
- Precios más elevados (o más bajos pero con mayor cuota de mercado)
- Mejora la reputación de la marca
- Aumenta la productividad mediante la reducción de costes por desperdicio y retrabajo, y menores gastos de devolución o garantía.

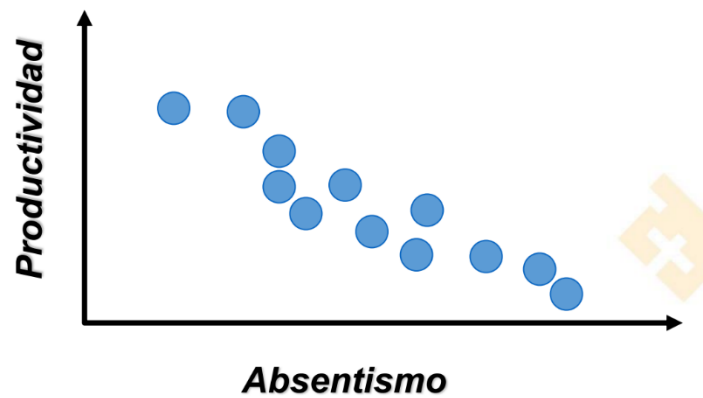
Hay varios métodos para gestionar de calidad, entre ellos el Six Sigma, mejora continua / Kaizen, potenciación de los empleados, benchmarking, Just In Time, ... pero nos centraremos en las hojas de control, diagramas de dispersión, gráficos de Pareto, histogramas, y control estadístico de procesos.

- Hojas de control: Las hojas de control son fichas de recogida de datos. Puede ser para registrar el número de veces que se producen distintos errores a lo largo del día, o para comprobar que se han completado todas los pasos de un proceso para distintas actividades.

	<b>Hora</b>							
<b>Defecto</b>	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>	<b>6</b>	<b>7</b>	<b>8</b>
<b>A</b>	///	/		/	/	/	///	/
<b>B</b>	//	/	/	/			//	///
<b>C</b>	/	//					//	////


Esto puede desvelar información relevante de manera muy eficiente en coste, por ejemplo pudiendo detectar que ciertos errores se producen en las últimas horas de la jornada, y permite tomar acción.

- Diagramas de dispersión: Los gráficos de dispersión muestran los valores de una variable en función a otra, pudiendo mostrar




relaciones entre ellas. Por ejemplo, podemos crear un gráfico que mida los errores que se producen en relación al número de prendas que se hacen.

- Gráficos de Pareto: Los gráficos de Pareto representan los defectos en orden descendente de frecuencia, tal que podremos identificar cuales se dan más a menudo y qué debemos resolver con prioridad.



Por ejemplo, al resolver los 3 primeros errores podemos estar solucionando más de la mitad de las causas de defectos.

- Histogramas: Muestran el rango de valores y frecuencia de una variable, por ejemplo tiempo que se tarda en preparar y enviar un pedido. Esto sirve para identificar y establecer los límites máximos y mínimos para el control de una tarea, por ejemplo.



- Control estadístico de procesos: Utiliza estadísticas y gráficos para determinar cuando hay que revisar un proceso. Supone la creación de estándares superiores y e inferiores, le medición de la muestra de producción, y la creación de reglas para corregir los errores. Un ejemplo es tener una variable que representa la resistencia de unos vaqueros al ser estirados por una máquina. Se tomará una muestra de cada lote, y si estos tienen una resistencia entre el máximo y mínimo establecido, el lote pasará a la venta. Sin embargo, si la resistencia sobrepasa los límites inferiores o superiores, se retirará el lote y se deberá inspeccionar el proceso para identificar el fallo.




Gráfico del porcentaje de tiros libres fallados por los Chicago Bulls en sus nueve primeros partidos de la primera temporada

Fuente: Heizer & Render, 2004. Operations Management



Para nuestro caso, tras lanzar una campaña con un influencer por ejemplo, veríamos si las búsquedas de este influencer están correlacionadas de forma positivas con nuestra marca, y si es así, sabremos que la campaña al menos ha sido exitosa para generar *awareness*, aunque también deberíamos evaluar el impacto en ventas y el ROI.

A parte del análisis de correlaciones, tenemos distintas métricas que podemos analizar, como los clicks en un anuncio, tiempo medio que se ve un spot publicitario... para determinar su efectividad. Las herramientas como Google Ads y Google Analytics son estándares en la empresa, y permiten llevar a cabo muchos tipos de análisis de publicidad de forma intuitiva. Estas herramientas además facilitan la evaluación del desempeño de los elementos de publicidad digital mediante el uso de métricas como el coste por click (CPC), coste por mil impresiones (CPM), visualizaciones, y conversiones, lo que facilita la evaluación de las acciones publicitarias en tiempo real y permite tomar acción rápidamente.

Algo muy frecuente en el campo de la publicidad es el *A-B testing* para evaluar si ciertas configuraciones o diseños de anuncios o webs dan mejores resultados. Esto es de especial importancia en marketing ya que se debe tener distintos modelos de anuncio o campaña para poder contrastar resultados, puesto que hay varios factores no evidentes que determinan su efectividad. Las métricas que se suelen estudiar en el *A-B testing* son los clicks en el anuncio, el tiempo que se queda un usuario en la página, o el ratio de conversión de usuarios en clientes.

Hay herramientas que permiten etiquetar menciones de una marca en redes sociales, lo cual permite analizar el comportamiento de los consumidores y sus opiniones sobre la marca. Frecuentemente estas herramientas se usan para llevar a cabo el sentiment analysis (sentimientos de los usuarios respecto a la marca), analizar el impacto de campañas publicitarias, y estudiar como se relacionan los usuarios con la marca (principalmente el customer journey).

En un ejemplo real, Mahou San Miguel necesitaba estudiar las menciones en Twitter de su marca y de su competencia para entender mejor a los

consumidores y lo que comentan, y cómo consumen sus productos. Con este objetivo, se analizaron las menciones en Twitter con la herramienta Digimind según si comentaban conocimiento de la marca, sentimientos, si son críticos de la marca, si estaban consumiendo, qué consumían, dónde y cómo... para tener una visión general de la conversación en redes sociales. Esto les permitió ver insights del consumidor y elaborar una estrategia basada en sus menciones de Twitter y las de su competencia.

 TWITTER RANK 4 FOLLOWERS 705 INTERACTIONS 2  VIEW ACTIVITY 15/03/2021

 **Juanan Nuevo** @JuananNuevo  
[@Lobo41015](#) [@CorazonRural](#) Mal ya cuando **Mahou** se comió el mercado de los litros de El Aguila y San Miguel en los parques, peor aún cuando las marcas blancas tomaron ventaja. Eso y el vino en cartón.

**NEGATIVE**  MAHOU  **CRÍTICA - CERVEZAS**  **GLOBAL - TODAS MARCAS**  **CJ GLOBAL - TODAS FASES**   
**EARNED MEDIA**  **CONOCE - ARQUITECTURA**  **NEGATIVO**  [less tags](#)

---

 TWITTER RANK 4 FOLLOWERS 679 INTERACTIONS 1  VIEW ACTIVITY 27/03/2021

 **MeDueleEspaña** @RamnSenra  
[@expuca](#) Mientras más cerveza bebo...más tuiteo... Ley de **Mahou**

**NO SENTIMENT**  MAHOU  **NONE**  **GLOBAL - TODAS MARCAS**  **TENDENCIAS - ESPAÑOL**   
**CJ GLOBAL - TODAS FASES**  **EARNED MEDIA**  **CONOCE - ARQUITECTURA**  [less tags](#)

---

 TWITTER RANK 4 FOLLOWERS 622  VIEW ACTIVITY 03/03/2021

 **Emilio** @MrBoticario  
[@Panchicista](#) El problema va a ser la **Mahou** que te bebiste en 1999

**NEGATIVE**  MAHOU  **GLOBAL - TODAS MARCAS**  **CONSUME - ARQUITECTURA**  **CJ GLOBAL - TODAS FASES**   
**EARNED MEDIA**  **CONOCE - ARQUITECTURA**  **NEGATIVO**  [less tags](#)

## 5. Text mining

El text mining es de extrema utilidad ya que permite analizar inmensas cantidades de texto para identificar patrones, palabras comunes, sentimientos,... Por ejemplo es posible analizar tanto un libro para extraer un “resumen” de conceptos principales, como una página de reseñas para ver qué opinan los consumidores. Evidentemente el segundo ejemplo aplica más a lo que queremos hacer, pero hay decenas de ejemplos como ese. El text mining permite a una empresa analizar distintos aspectos del consumidor, principalmente opiniones. Puede aplicarse en distintas plataformas como pueden ser redes sociales, blogs, páginas de servicios (TripAdvisor,...) para resumir lo que dicen las personas y tomar decisiones en base ello, todo con inmediatez y exactitud. Es de especial utilidad ya que antes había que esperar a veces meses, o más, hasta poder evaluar acciones como una campaña publicitaria, mientras que ahora se puede extraer información cada hora con herramientas como Google Trends, y es por ello que consideramos el text mining uno de los temas más importantes que vamos a tratar.

### Extracción de datos

Los datos se pueden extraer de casi cualquier fuente. Hay ciertas páginas o apps que limitan lo que podemos obtener de ellas, como Instagram. Dependiendo de la fuente se hará de una u otra manera, pero por lo general habrá un paquete de R o Python que permita hacer lo que queremos.

### Preparar datos

Una vez descargados los datos en formato csv, va a ser necesario limpiarlos para eliminar números, posibles símbolos y las palabras que no aportan significado. Estas palabras se llaman stop words, y son palabras muy comunes por ejemplo los artículos, pronombres, ciertos verbos muy comunes como “ser”,... Esto es importante ya que nada más queremos un resumen de conceptos clave, y las técnicas que vamos a utilizar tienen en cuenta el número

de veces que se repite un elemento o una palabra en el texto, y las stop words, números y símbolos ofuscarían los resultados. Además de las stop words establecidas es importante analizar los resultados e identificar palabras que no nos interesan por ser muy obvias (“museo” en un análisis de reseñas de un museo evidentemente va a salir), o elementos que no se filtraron correctamente ( a veces aparecen artículos, números,...), logrando así representar lo verdaderamente relevante.

### Wordcloud

Las wordcloud permiten identificar las palabras que más se repiten de forma gráfica. De esta forma podemos entender a primera vista las palabras claves de que usan las personas en relación a nosotros.

En este ejemplo, hemos descargado datos de veganismo, vegetarianismo y flexitarianos obtenidos de Google Trends para evaluar si hay diferencias en las búsquedas de cada grupo.

En primer lugar hemos tenido que eliminar las stopwords específicas de español y algunas más como “vegano”, “vegetariano” y “flexitariano” puesto que son muy evidentes en este tipo de búsqueda. Luego, a medida que vamos creando las word clouds, iremos eliminando más palabras que ofuscan los resultados como puede ser “recetas”, pero tomando nota de ellas para comentar en las conclusiones puesto que estas sí pueden ser relevantes. Finalmente, podemos obtener una wordcloud que muestra los términos más relevantes de nuestro análisis, y podemos ver diferencias a primera vista en el tipo de búsquedas para cada grupo. Esto permite tomar acciones específicas para cada grupo, como distintos productos o anuncios.

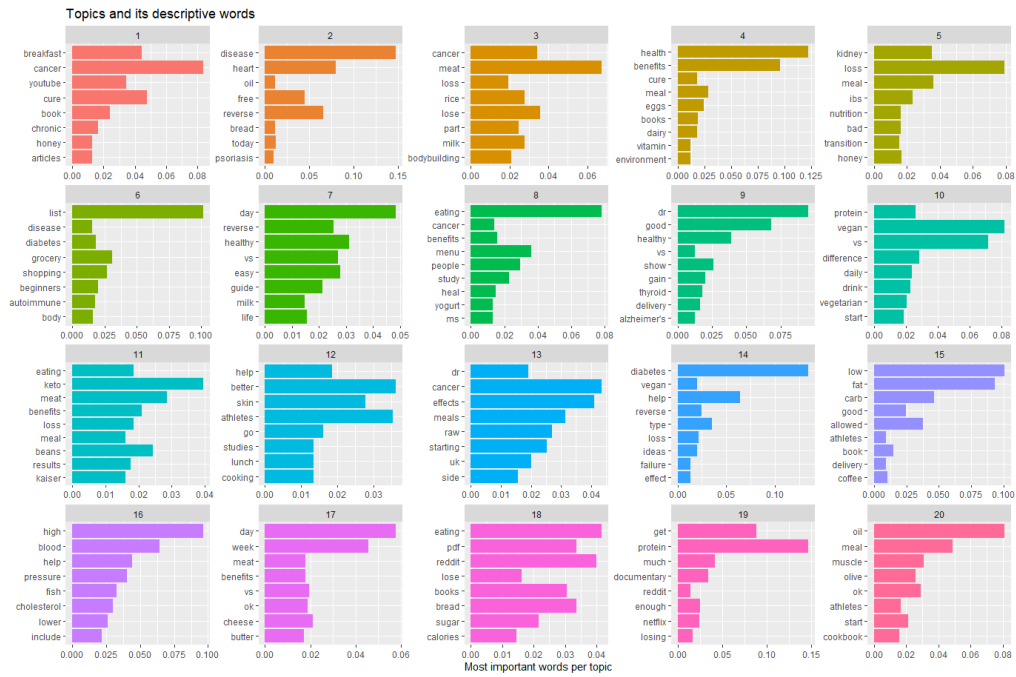
Como podemos ver, el grupo de flexitarianos tiende a hacer búsquedas relacionadas con temas de salud como puede ser el peso, revertir efectos del cancer o la diabetes... mientras que el grupo de veganos hace búsquedas



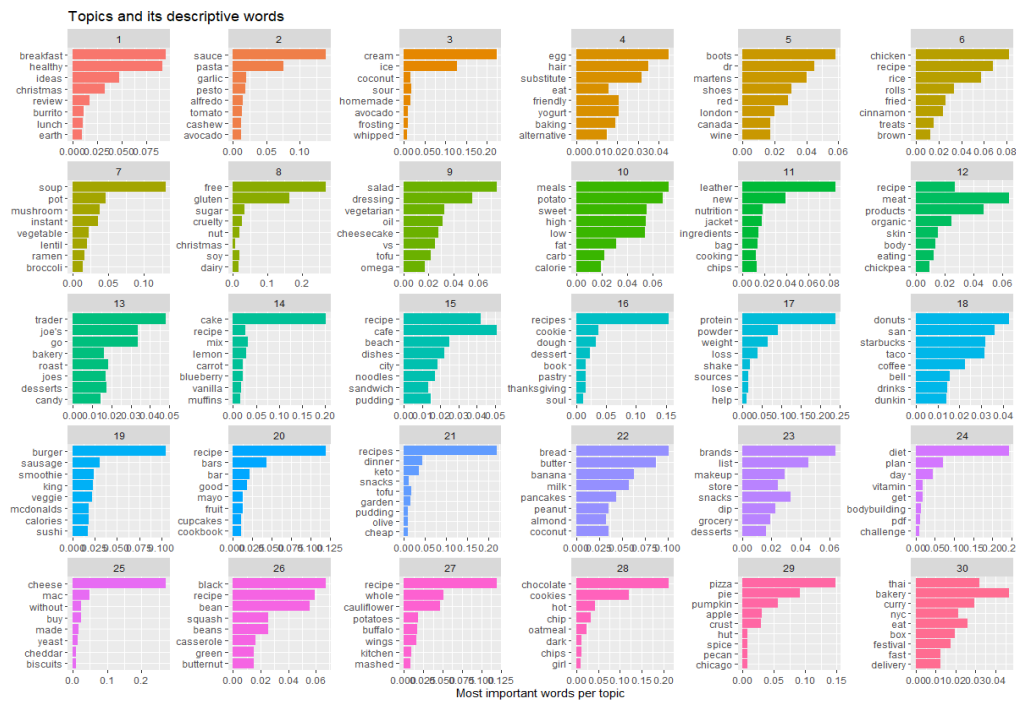


grupo podemos ver diferencias también; dentro del grupo de veganos se ve claramente una diferencia entre quienes buscan análogos veganos de los productos tradicionales y aquellos que buscan recetas.

## Flexitarianos



## Veganos





## 6. Reglas de asociación

Esta técnica estudia patrones, llamados transacciones, en bases de datos mediante un algoritmo (el algoritmo *a priori* principalmente), para poder identificar elementos, llamados items, que suelen suceder o aparecer juntos para formar un conjunto. Algunas de sus aplicaciones están en la domótica, como puede ser abrir las cortinas cuando sale el sol y después encender la cafetera, y en los sistemas de recomendación, como puede ser el sistema de recomendaciones de un e-commerce o de plataformas como Netflix.

En el caso de e-commerce, las reglas de asociación permiten hacer recomendaciones más acertadas e incrementar las ventas. No solo se aplica a asociaciones evidentes, como calcetines y zapatos, sino a cestas de productos cada vez más grandes sin aparente relación, siempre que estos aparezcan juntos frecuentemente. Esto permite desarrollar el cross-selling, lo cual puede aumentar la eficiencia al vender, permitiendo reducir el stock restante al final de temporada al haber conseguido vender más productos.

Algunos términos importantes son:

- $X \rightarrow Y$ : Y donde X es el antecedente e Y su consecuente, es decir, primero aparece X y luego Y.
- Itemset: conjunto de items

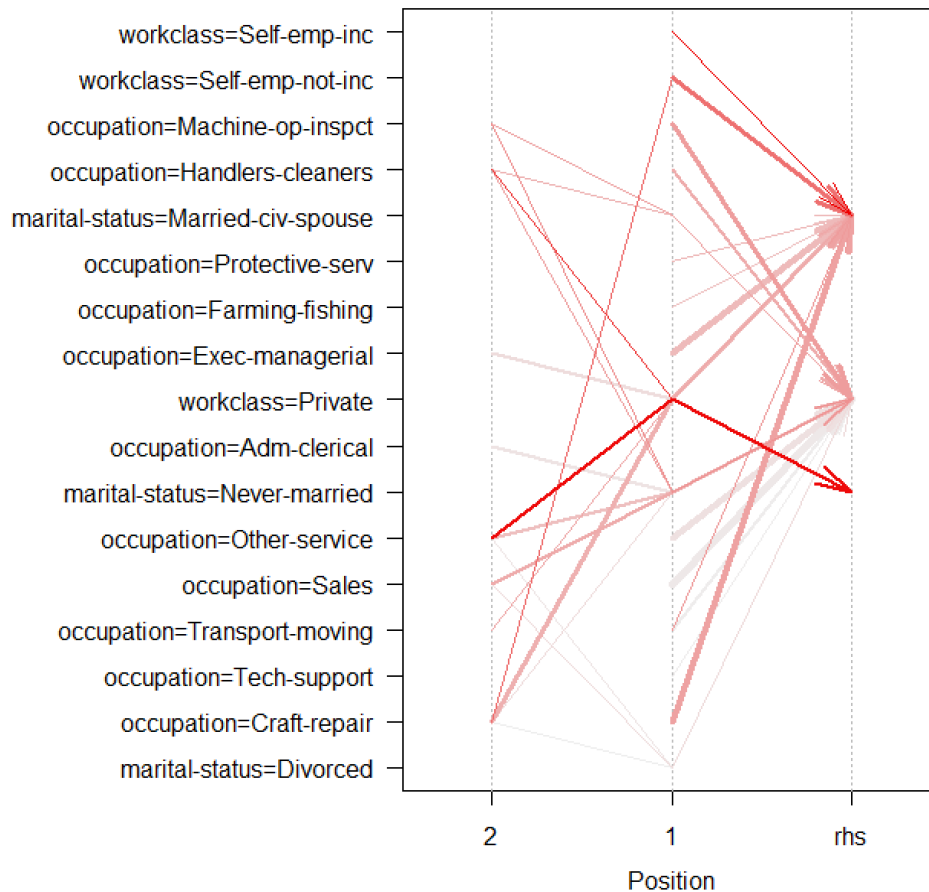
Las medidas que se utilizan para determinar la eficiencia del modelo son:

- Soporte: Porcentaje de las transacciones que contienen los itemsets.
- Confianza: Es el porcentaje de transacciones que contienen Y dividido por las transacciones que contienen X.

A continuación tenemos un ejemplo de reglas de asociación aplicadas a datos de un censo que contiene varias variables como modalidad de empleo, nivel de educación, estado civil, sexo, raza... para poder ver que elementos aparecen juntos frecuentemente, aunque no entraremos en los detalles técnicos del modelo.

Como podemos ver en el ejemplo, las personas con Occupation = Other Service también suelen tener Workclass = Private y Marital Status = Never-married.

**Parallel coordinates plot for 30 rules**



Aplicado a nuestro caso, sería el equivalente de ver, por ejemplo, que las personas europeas suelen comprar camisetas y pantalones en una misma cesta de compra, mientras que las personas asiáticas suelen comprar camisetas y sudaderas. La utilidad de esta técnica es muy evidente, ya que podemos hacer recomendaciones acertadas dependiendo de muchos factores como nacionalidad, sexo o edad entre otras muchas.

## **7. Algoritmos predictivos y de clasificación aplicados al consumidor**

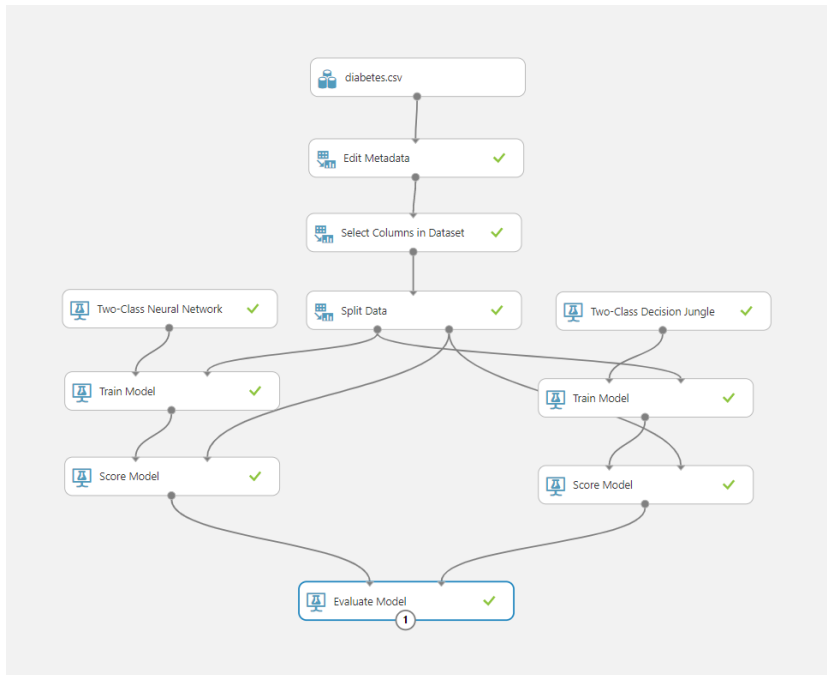
Con esto podemos evaluar muchos aspectos. Por una parte se puede predecir si alguien va a permanecer como cliente de la empresa, si va a comprar un cierto producto o si le va a impactar una determinada acción, por ejemplo, mediante modelos predictivos y de clasificación, usando aprendizaje supervisado y no supervisado.

Para ilustrar la utilidad y poder de estas herramientas, tenemos un ejemplo:

Target, una enorme cadena de supermercados, es capaz de determinar si alguien va a tener un hijo a través del data mining, mediante el estudio de sus compras pasadas y un modelo de clasificación. Para esto, anonimizan los datos con un ID para cada usuario el cual está ligado a su tarjeta de crédito para, como ya hemos dicho, estudiar sus compras. Algunos de los patrones que identificaron son que las mujeres embarazadas empieza a comprar crema no perfumada y suplementos de zinc, y esto les permitía estimar incluso cuando daría a luz lo cual les daba la oportunidad de enviar ofertas de productos que le podrían interesar a una nueva madre. Con todos los datos que obtenían, asignaban una “pregnancy score” a los usuarios para ir enviándoles distintas ofertas y folletos según el estado de su embarazo. Eventualmente Target se dio cuenta de que algunos clientes podrían sentirse espiados si les llegaba publicidad de productos para madre/bebés si nunca se lo habían dicho a la empresa, por lo que empezaron a mezclar los anuncios de dichos productos con los de otros que una madre no compraría, como un cortacésped.


Gracias a este tipo de técnicas el crecimiento anual de Target aumento de \$44 mil millones en 2002 a \$67 mil millones en 2010, y en particular por su dominio del sector de madres y productos de bebé.

A continuación tenemos un ejemplo de un modelo que determina si alguien es diabético o no. Este modelo se ha creado en Azure, un software en la nube de Microsoft que permite programar modelos de forma muy simple e intuitiva.



En resumen, este modelo toma un dataset con varias variables, entre ellas si alguien es diabético o no, y lo divide en dos grupos: un grupo sobre el cual entrenar las capacidades clasificadoras del modelo, y otro

sobre el cual se hace la clasificación y se evalúa su exactitud. Para entrenar al modelo se pueden elegir distintos métodos, pero en este caso hemos seleccionado el Two-Class Neural Network y Two-Class Decision Jungle. Para determinar cómo de bien predice el modelo, estudiaremos su AUC la cual determina la exactitud del modelo.



En este caso hemos obtenido una AUC de 0.829 y 0.827 para el Two-Class Neural Network y el Two-Class Decision Jungle respectivamente, por lo que el Two-Class Neural Network muestra mejores capacidades de clasificación.

Para nuestro caso, esto se puede aplicar a distintos campos, como podría ser un modelo que determine si alguien va a aprovechar una oferta o no, por lo que podremos optimizar nuestros recursos y dirigir la publicidad únicamente a aquellos clientes que sí se verán impactados por la oferta. No obstante debemos tener en cuenta que, como para la mayoría de técnicas que ya hemos comentado, se necesitan datos históricos y no se debería tomar este modelo como una predicción exacta, sino como una herramienta complementaria a otros tipos de análisis.



## 8. Análisis de redes sociales


El análisis de redes sociales (SNA) estudia las estructuras de conexiones de elementos mediante el uso de redes y la teoría de grafos. Este tipo de análisis expresa las estructuras sociales en términos de nodos (elementos como individuos) y aristas (las interacciones o conexiones entre los nodos). Algunas de sus utilidades son estudiar la transmisión de enfermedades o movimiento de capitales, así como identificar personas de influencia en un grupo.

Las métricas que deberemos tener en cuenta son principalmente el grado y pagerank:

- Grado:
  - Grado in: El **grado in** recoge el número de conexiones que entran en un elemento. Puede ser muchas cosas como recibir un mensaje, una transferencia bancaria, un pase en fútbol...
  - Grado out: El **grado out** indica el número de conexiones que salen de un elemento. Puede ser enviar un mensaje, una transferencia o hacer un pase en fútbol.
- Pagerank: el pagerank es un algoritmo desarrollado por Google que mide la relación entre grado in y grado out para determinar como de relevante es una página web, de tal forma que cuanto mayor grado in (hipervínculos que redirigen a la página en cuestión) tenga una web, más importante es. Puesto que este algoritmo es muy útil, hoy en día se aplica en otros campos, principalmente el análisis de redes sociales con el fin de identificar elementos de influencia.

A continuación tenemos un ejemplo de SNA con datos de los partidos de 2014 y 2015 del Fútbol Club Barcelona. El dataset tiene varias variables, entre ellas si se ha hecho un pase, quién lo ha hecho, y a quién. La utilidad de este análisis es identificar a qué jugador le pasan más el balón, un indicador de quién es el mejor jugador del equipo. En este ejemplo el grado se mide con los pases, siendo el **grado in** recibir un pase, y **grado out** hacer un pase.

El siguiente gráfico muestra los pases que se han hecho a lo largo de la temporada. Los puntos azules son los nodos, que en este caso representan a los jugadores, y las flechas son los pases. En función del número de pases hechos y recibidos, es decir, del grado, el punto será mayor, indicando un mejor posicionamiento dentro del equipo. Podemos ver que el jugador con mayor grado es Lionel Messi.



Otra forma de analizarlo es con una matriz en la que podemos ordenar los datos según su grado total para así ver a los mejores diez jugadores:

jugador	gradoTotal	gradoOut	gradIn	cercania	pagerank	intermediacion	label
5503	5428	2357	3071	0.04347826	0.109282073	1.340284e+01	Lionel Andrés Messi Cuccittini
4324	4121	2176	1945	0.03846154	0.071157072	1.813925e+00	Daniel Alves da Silva
5203	3898	2089	1809	0.04000000	0.063470043	1.774709e+00	Sergio Busquets i Burgos
5211	3866	2084	1782	0.04000000	0.065608222	3.875961e+00	Jordi Alba Ramos
4320	3654	1504	2150	0.04347826	0.077355804	6.242215e+00	Neymar da Silva Santos Junior
20131	3450	1768	1682	0.04166667	0.063933848	9.423212e+00	Xavier Hernández Creus
5470	3390	1722	1668	0.04000000	0.062330036	6.239639e+00	Ivan Rakitic
5506	3333	1771	1562	0.04166667	0.052913526	8.114474e+00	Javier Alejandro Mascherano
5213	3012	1617	1395	0.04000000	0.047356416	2.425302e+00	Gerard Piqué Bernabéu
5216	2831	1398	1433	0.04000000	0.053618169	8.742222e-01	Andrés Iniesta Luján

Una de las mayores utilidades de esta técnica en nuestro contexto es la identificación de influencers y microinfluencers en redes sociales.

## 9. Segmentación

Otra técnica muy útil en el ámbito empresarial es el clustering, el cual tiene muchas funciones aunque nos enfocaremos en el clustering para segmentación de clientes. Mediante esta técnica se pueden agrupar consumidores con características similares lo permite entenderles más detalladamente. Hay dos tipos principales de clustering:

- Jerárquico: es un modelo no supervisado que agrupa elementos similares de forma jerárquica. Puede ser aglomerativo o divisible, y representa los resultados en un dendrograma.
  - Modelo aglomerativo: El modelo aglomerativo funciona agrupando elementos “de abajo a arriba”, es decir, considera que cada elemento del dataset es su propio clúster, y va agrupándolos por su similitud hasta formar un único grupo.
  - Modelo divisible: El modelo divisible funciona agrupando elementos “de arriba abajo”, es decir, considera que todos los elementos pertenecen a un único grupo, y va separándolos según la heterogeneidad de cada clúster.
- K-means: es un modelo supervisado que mide la distancia entre las observaciones y unos puntos llamados centroides, y busca minimizarla hasta conseguir grupos que abarcan todas las observaciones y que son diferentes entre sí.

A continuación tenemos dos ejemplos de cada tipo de clustering, aplicado a un dataset que recoge datos sobre arrestos en los EEUU. Este dataset tiene una serie de observaciones que recogen variables como si el arresto fue por un asesinato, asalto, violación... además del estado en el que sucedió y la población urbana de ese estado.




cluster	Murder	Assault	UrbanPop	Rape	
1	12.165	255.2500	68.40000	29.16500	Como podemos ver, el
2	4.870	114.4333	63.63333	15.94333	clúster 1 tiene valores

medios mayores para cada categoría de crimen, mientras que la población urbana no varía mucho entre clústeres (UrbanPop). De esto podemos concluir que los estados en el clúster 1 son aquellos que tienen mayores índices de criminalidad, mientras que los del clúster 2 tienen niveles menos elevados.

Para una empresa del sector de la moda, esto puede permitir identificar grupos de consumidores y entender que variables hacen que pertenezcan a un grupo u otro, como pueden ser su nivel de ingresos, su gasto en ropa, su edad... lo que nos permite entenderlos mejor y crear acciones específicas para cada grupo.

### Jerárquico:

El clústering jerárquico puede hacerse computándolo según distintas distancias (euclídea, Pearson, manhattan,...) aunque no entraremos en detalle sobre ellas, o indicando el número de clústeres que debe extraer. A continuación tenemos un ejemplo con el mismo dataset de arrestos en EEUU, y lo computaremos con la distancia euclídea:



La interpretación puede ser algo compleja a primera vista, pero debemos atender al orden en que se han formado los clústeres de arriba abajo, es decir, de forma jerárquica. Podemos ver como se forman dos grupos distintos inicialmente, y a medida que vamos descendiendo, se van formando grupos de elementos similares. De esta

forma, podemos ver que se forman dos clústeres con este método. Podemos utilizar el clustering jerárquico para determinar el número de clusters óptimo para el método k-means, iterándolo varias veces y observando cuantos clusters se forman.

## Técnicas en entornos físicos

### Tendencias

El avance tecnológico del que venimos hablando no solo aplica a entornos digitales, es más, el ámbito con mayor margen de innovación es el entorno físico del retail. Actualmente podemos ver una tendencia que busca unir ambos entornos, el digital y el físico, para crear una experiencia fluida. Esta es la llamada omnicanalidad, que precisamente busca crear una relación uniforme a través de los distintos canales digitales y físicos para llegar a los consumidores. Algunas tendencias que reflejan esto son los asistentes digitales como los *smart mirror* y *chatbots* los cuales pueden ayudar a los consumidores a tomar decisiones más inteligentes y personalizadas, la geolocalización que permite, entre otras cosas, comunicarse con los consumidores dependiendo de su ubicación, las *in-store analytics* que proporcionan información en tiempo real del comportamiento de los consumidores, y los nuevos modelos de compra como el BoPiS, RoPo o Dynamic Pricing.

Según un informe de Deloitte, los retailers tradicionales deben digitalizarse por varios motivos:

En primer lugar, la omnicanalidad es esencial para los consumidores, quienes ahora quieren comprar en cualquier lugar y cualquier momento, y con inmediatez. Por ello, los retailers tradicionales deben reestructurar sus canales de distribución, estructuras organizativas y modelos de negocio. En segundo lugar, los retailers tradicionales ahora deben competir con retailers puramente digitales; los clientes hoy en día tienen un amplio abanico de opciones donde comprar, y productos que comprar, gracias al e-commerce, y los retailers tradicionales deben de buscar como alcanzar este mismo repertorio.

Finalmente, los hábitos de compra de los consumidores van a seguir cambiando a medida que aparezcan tecnologías, y los retailers físicos deben adaptarse cuanto antes a la tendencia digital.

Este mismo informe recalca la importancia de convertir las tiendas físicas en centrales de recopilación de datos las cuales ayudan a tomar decisiones que



aumenten las ventas y reduzcan los costes. Sumado a esto, explica que los consumidores ahora esperan más de las tiendas; quieren una experiencia.


## Técnicas

- Optimización de vestidores

Al analizar qué productos se llevan al probador, y relacionar estos datos con los productos que se compran vs los que se dejan en tienda, los retailers pueden tomar decisiones que mejoren la experiencia del cliente. Si se juntan los datos recién mencionados con datos demográficos y uso de redes sociales, se pueden obtener conclusiones sobre preferencias.


- Asistentes digitales

Los probadores pueden guardar la información de clientes tal que cuando entren a la tienda y se pongan ante el espejo, son reconocidos a través del móvil si disponen de la app de la tienda. Esto permite que el asistente le muestre información personalizada al cliente, como cuales de sus productos guardados online están en la tienda, o recomendaciones basadas en su historial de búsqueda en la web o aplicación. También pueden crear un modelo virtual de la prenda para probársela en el espejo y tramitar la compra desde él para recibirla en casa posteriormente. Esto crea una experiencia, que es de las principales prioridades para los consumidores como ya hemos mencionado, y puede incentivar la compra. Además de esto, cabe la posibilidad de tener un stock reducido en tienda, y esta puede pasar a servir como fulfillment center urbano y showroom, lo cual aumentaría la rentabilidad de mantener un espacio físico al reducir los costes de inventario y el personal en tienda.



- Geolocalización y Heatmaps

Mediante la red wifi de una tienda y las aplicaciones móviles se puede detectar y estudiar el flujo de personas tanto en la calle como en la tienda. Esto permite que si van andando o conduciendo por la calle y pasan cerca de la tienda un sistema automatizado les envía una oferta, o si estudiamos el carrito de la compra de la app de un cliente, al pasar cerca de una tienda podemos notificarle de que el producto está en stock. Esto será más posible con 5G y el IOT, mediante el cual se podrá conectar oferta y demanda mucho mejor. Dentro de la tienda se puede estudiar el flujo de personas también para identificar la trayectoria que siguen los clientes, en que lineal se paran, cuánto se quedan parados... y con tecnologías como los RFID en las perchas se puede saber qué productos se compran, cuales se cogen y devuelven al ver el precio,... para identificar productos poco comprados y moverlos a una zona más transitada, o reducirles el precio.

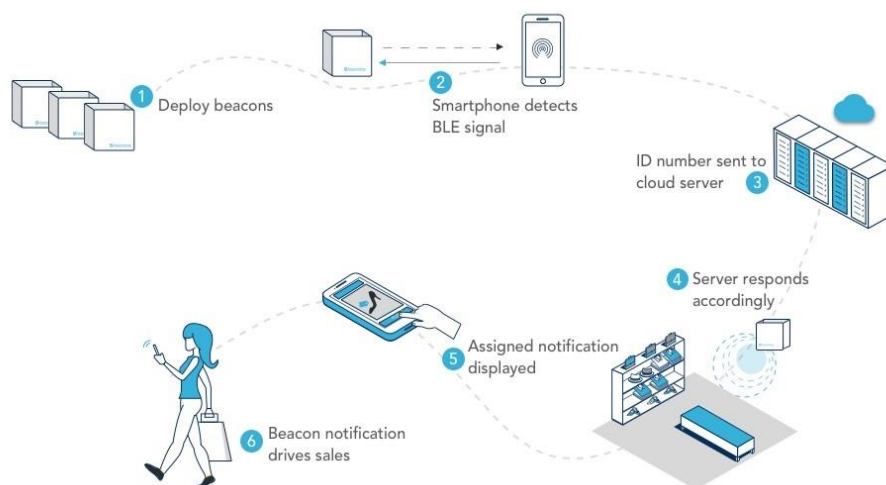


Pero los heatmaps no sólo son aplicables de cara al cliente. Pueden ser usados para analizar cuántos productos se están vendiendo en relación al stock que hay, en tiempo real, lo cual permite optimizar el inventario de una tienda rápidamente. Por ejemplo, el heatmap puede estar mostrando que X tienda tiene un tráfico muy elevado y que el inventario no va a aguantar hasta el próximo pedido, mientras que otra tiene bajo tráfico y exceso de stock, por lo

que en un par de horas o días se puede trasladar parte del inventario de una tienda a otra para evitar una ruptura de stock. También pueden ser usados en un almacén para identificar el flujo de los trabajadores y detectar posibles ineficiencias o puntos calientes donde concentrar el trabajo. Por ejemplo, el heatmap de un almacén puede desvelar que los trabajadores deben desplazarse de una punta a otra con frecuencia para tramitar los pedidos, a la vez que muestra un punto muy transitado por todos los empleados, por lo que el capataz de almacén puede reorganizar el espacio para optimizar el flujo de personas , ahorrando tiempo y aumentando la eficiencia.

- Beacons

Los beacons son una tecnología que va de la mano con la geolocalización y heatmaps. Son una serie de dispositivos que hacen uso de la red wifi de las tiendas para conectarse a los dispositivos de los clientes y así analizar su ubicación en la tienda, demografía, y otros datos (siempre que tengan la app) para así dinamizar las ofertas personalizadas. Si el cliente dispone de la app, los beacons son capaces de acceder a ella y estudiar sus compras pasadas, por ejemplo, para enviarles un descuento personalizado cuando se sitúen en la parte de la tienda que tiene el tipo de productos que han comprado históricamente, lo cual aumenta la probabilidad de compra.



- Realidad Virtual, aumentada y mezclada

Las tecnologías de realidad virtual (VR) y realidad aumentada (AR), y en menor medida la realidad mezclada (MR), son una tendencia desde hace unos años con productos como cascos de realidad virtual o aplicaciones como el Pokemon Go, pero a medida que estas tecnologías han ido mejorando se han ido descubriendo nuevos usos orientados hacia el negocio, especialmente el retail.

- Realidad virtual: La realidad virtual recrea un entorno físico de forma digital de tal forma que el usuario puede interactuar con él, pero sólo es posible con el uso de equipamiento especializado.
- Realidad aumentada: La realidad aumentada es una dimensión adicional sobre un entorno real, la cual puede incluir objetos, sonidos, videos... superpuestos, pero con poca posibilidad de interacción. Se puede visualizar con productos ya existentes como el teléfono móvil.
- Realidad mezclada: La realidad mezclada combina la VR y AR junto con sensores para generar espacios virtuales que reaccionan a los usuarios de forma más precisa y real que los espacios generados por VR.

Estas tecnologías pueden tener impacto en la adquisición, conversión y retención de clientes:

- Adquisición: La AR/VR/MR puede generar experiencias para el consumidor, uno de los principales retos del mundo del retail en la actualidad, y uno de los mayores drivers de la adquisición de clientes. Además, puede servir para hacer demos de productos; por ejemplo, Gucci publicó una función en su app que permite visualizar distintos modelos de sus zapatos a través de la cámara del móvil, tal que los usuarios pueden ver cómo les quedan.

- Conversión: Estas tecnologías pueden incitar a la compra mediante experiencias de compra virtual personalizadas, ofertas a medida, y asesoramiento con personal shoppers en remoto.
- Retención: La retención de clientes es más fácil con estas tecnologías ya que se pueden usar para crear experiencias individuales para cada usuario, y que diferencian la marca de las demás. No obstante, es importante considerar el valor añadido al cliente ya que puede resultar una inversión innecesaria si no hay otros drivers que la apoyen.

Algunas aplicaciones que se están dando hoy en día son:

- Planificación de compras: La VR permite visitar la tienda de forma remota, tal que los usuarios pueden ver el catálogo de productos desde casa. Un caso real de este uso viene del retailer de lujo The Apartment que, mediante el uso de Samsung Gear, permite a los usuarios ver su tienda desde cualquier lugar del mundo.
- Gestión de información: La AR puede dar información adicional de los productos en tiempo real, como la composición de una prenda o el valor nutricional de un alimento. Kraft junto con Walmart facilita recetas para sus productos mediante la app Blippar.
- Personalización de productos: Los clientes son capaces de personalizar sus productos con el uso de AR y VR para ajustarlos a sus preferencias.
- Campañas experienciales: La AR/VR permite añadir componentes emocionales a cualquier campaña mediante la gamificación o storytelling.

- Tiendas virtuales y probadores en casa: Con estas tecnologías los clientes pueden tener experiencias de compra desde su propia casa, probándose las prendas de forma digital. El proyecto Tango de Google tiene el objetivo de hacer esto una realidad accesible a todos, y se ha juntado con Gap y BMW para testar sus productos. En el caso de Gap, los usuarios se escanean para generar un avatar virtual sobre el cual visualizar las prendas del catálogo.



- Neuromarketing

El neuromarketing es la ciencia que estudia los señales neuronales y fisiológicas para entender mejor al consumidor, sus motivaciones y sus decisiones, con el fin de mejorar las campañas de comunicación, el diseño de productos, precios y otras áreas de marketing. Esto generalmente se hace a través de escaneos de la actividad cerebral y siguiendo el registro visual de las personas, pero a medida que ha avanzado la tecnología han surgido técnicas como las biométricas (ritmo cardiaco, respiración...) y la codificación facial (registra expresiones y micro-expresiones en las caras de las personas)

- Branding: Las aplicaciones del neuromarketing al branding son de las más importantes, ya que las marcas en esencia son conceptos y atributos a los que el consumidor les da un significado. Aplicando el neuromarketing al branding somos capaces de entender la respuesta

emocional del consumidor a nuestra marca comparada con la respuesta a nuestros competidores, así como determinar que activos de la marca contribuyen más a su valor. Por ejemplo, se puede determinar que aspectos del diseño de la marca suscitan una mayor respuesta en el consumidor, por ejemplo el nombre, el diseño de la web, los colores...

- Productos: El neuromarketing permite entender como los consumidores reaccionan ante un producto, dándonos la posibilidad de modificarlo basándonos en evidencias hasta lanzarlo al mercado. Algunas aplicaciones en este campo son estudiar las reacciones ante distintos tipos de packaging, la exposición del producto en el punto de venta, y sobre todo ante el uso o consumo del producto.
- Anuncios: Puesto que estamos expuestos a inmensas cantidades de estímulos y anuncios a diario, es imprescindible conseguir que los usuarios se fijen en los nuestros y para ello es importante entender qué capta la atención de los consumidores. Con el neuromarketing podemos comparar distintas versiones de anuncios y determinar cuáles son sus elementos clave mediante la respuesta emocional de los consumidores y a través de su registro visual.
- Punto de venta: Aunque este campo está menos explorado a día de hoy, el neuromarketing tiene muchas aplicaciones en el punto de venta. Si nos basamos en un estudio previo, podemos determinar elementos clave para la experiencia del consumidor como la distribución de la tienda, el olor en ella, sus colores o su diseño. Modificando estos atributos podemos conseguir mayor flujo de personas en la tienda y un aumento de compras ya que estaremos contribuyendo a la experiencia de compra, uno de los aspectos esenciales del retail hoy en día como hemos comentado varias veces.





- Self-checkout

El self-checkout o caja de autopago permite a los clientes ejecutar la compra sin la ayuda de un empleado. Esto pareado con tecnologías como el RFID, de la cual hablaremos más adelante, e IA de reconocimiento de imagen puede aportar mucho valor tanto a la tienda retail como a los clientes. Las principales ventajas del self-checkout son la reducción de costes laborales, mayor velocidad en el checkout, y una experiencia más dinámica para el cliente.

Con el uso de la tecnología RFID, un tipo de sensor de radiofrecuencias, nada más basta con colocar todos los productos sobre el mostrador y el checkout se hace instantáneamente sin necesidad de pasarlos uno a uno, lo cual reduce el tiempo de checkout a 30 segundos, comparado con una media de 4 minutos con sistemas tradicionales.

Las tecnologías de reconocimiento de imagen incluso pueden eliminar la necesidad de las cajas de autopago, algo que vemos en tiendas como Amazon Go. Esta tecnología detecta el movimiento de los clientes a lo largo de la tienda, en que lineal se detienen, y qué productos cogen. Esto, junto con una app conectada a la red de la tienda, permite a los usuarios coger los productos que desean y salir de la tienda sin pasar por la caja, y la facturación se hace automáticamente en la salida de la tienda.

Mientras que los principales usos de esta tecnología hoy en día se dan en supermercados, se espera que se expanda a todo tipo de tiendas retail dada su

inmensa eficiencia y utilidad. No obstante, su elevado coste junto con otras desventajas hace que aún no sean el estándar. Sus principales desventajas son la facilidad de robo en tiendas, la falta de interacción humana, y la dificultad de implementación para todo el catálogo de productos (ciertos productos como el alcohol requieren confirmar la edad del comprador, o el código de barras en otros productos puede ser difícil de escanear aunque esto se soluciona con la tecnología RFID).



- Nuevos modelos de compra

Hoy en día la gente tiene nuevos modelos de compra como el BoPiS (Buy Online, Pickup in Store), RoPo (Research Online, Purchase Offline). El BoPiS en particular ha cobrado importancia en los últimos años, sumándose casi todos los retailers a esta tendencia de una forma u otra como el Click & Car del Corte Inglés; se espera que para 2025 el 90% de los retailers tengan un modelo BoPiS. Algunas ventajas del modelo BoPiS son que aumenta las ventas, ya que el 49% de consumidores compran algo más al ir a recoger su producto, reduce los costes de envío y aumenta las ventas online (en torno al 60% de clientes que no finalizan una compra online no la tramitan por los costes de envío), y reduce el número de devoluciones (el 77% de los retailers afirman que sus devoluciones han disminuido desde la implantación del BoPiS, lo cual les ahorra en gastos de tramitación y restocking).

También se está aplicando el pricing dinámico o Price-match, una estrategia que actualiza los precios en tiendas retail teniendo en cuenta los precios de los competidores, para que los productos siempre tengan la mejor oferta o estén a la par con competidores fuertes como pueden ser Amazon u otros e-commerce, lo cual incentiva la compra.

Finalmente, otra tendencia es la compra virtual a través de un representante en la tienda, quien muestra a los clientes los productos a través de una cámara móvil. Esto ha sido una tendencia en países como China durante la pandemia, y ha alentado las compras en el entorno retail ya que ofrece una nueva experiencia de compra.



## **Marco legal y ética**

El aspecto ético y legal de la digitalización y el análisis de datos es un tema que ha cobrado inmensa relevancia en los últimos años dado el rápido cambio del entorno, el cual evoluciona más rápido de lo que se pueden crear leyes y debatir sobre las responsabilidades profesionales que se deben tener. Por ello, es necesario recalcar los puntos esenciales que se han de tener en cuenta a la hora de dar el paso digital.

Hoy en día no faltan ejemplos de empresas que sufren escándalos por la mala gestión de datos, como es el caso de Facebook y Cambridge Analytica, por supuesta discriminación, como es el caso de Google y su algoritmo que identificaba a las personas de tonalidad oscura como simios, o mala gestión de la seguridad, como es el caso de Sony y sus numerosos data-breaches. Es por esto que todas las empresas que quieran hacer uso de los datos y la digitalización deben estar en línea con las leyes y mantenerse actualizadas de los debates y dilemas éticos que se plantean para así estar un paso por delante en todo momento.

## **1. Marco legal**

En términos legales, la llamada General Data Protection Regulation (GDPR) regula lo que las empresas pueden hacer con los datos de clientes, y cada país tiene sus propias leyes complementarias. La GDPR cubre diversos aspectos de la recogida, procesamiento y uso de datos; en términos generales, es necesario anonimizar o pseudonimizar los datos, y no se pueden explotar datos personales como raza, origen étnico o sexualidad. Por otra parte requiere que se siga una serie de controles para intentar minimizar el sesgo en todos los pasos del proceso.

A continuación están recogidos algunos de los puntos más relevantes de la GDPR, aunque es imprescindible entenderla en su totalidad:

### Principios para el procesamiento de datos

Los datos personales deberán ser:

1. Procesados de forma legal, justa y transparente.
2. Obtenidos para un fin específico y legítimo y no procesados para otros fines excepto los iniciales. No obstante, una vez cumplido su propósito original, si pueden ser procesados para fines estadísticos, científicos o de investigación.
3. Limitados a lo necesario en relación al propósito por el cual están siendo procesados.
4. Precisos y actualizados. Es prioritario eliminar o rectificar datos erróneos.
5. Anonimizados una vez ya no sea necesario ser capaz de identificar al sujeto a quien pertenecen los datos.
6. Procesados de tal forma que la seguridad de los datos esté garantizada.

### Gestión de datos especiales

1. Se prohíbe el procesamiento de datos que desvelen raza u origen étnico, opiniones políticas, creencias religiosas o afiliación sindical.

Además se prohíbe el procesamiento de datos genéticos, biométricos, de salud, de vida sexual y orientación sexual.

2. Las únicas excepciones a estas restricciones son si el usuario ha dado su consentimiento, si dichos datos se hacen públicos por el usuario.

## **2. Marco ético**

El aspecto ético ha generado mucho debate, y abarca ámbitos desde la RSC a la inteligencia artificial. Esto no sorprende ya que todos los años surgen escándalos de empresas que recogen datos sin consentimiento de los usuarios, que utilizan información personal para afinar su marketing, o que comercializan la información de personas.

Aunque no todas las técnicas comentadas en este documento se vean sujetas a cuestiones éticas, aquellas que utilizan datos de personas reales deben someterse a escrutinio por parte del empresario para asegurar que los resultados que se obtienen de ellas y la respuesta que se da en base a ellos sea justa para todas las partes implicadas.

Un ejemplo idóneo para entender las cuestiones éticas que surgen en este campo es el caso de Facebook y Cambridge Analytica:

El caso comienza en 2016 con las elecciones de Estados Unidos, en las que Donald Trump contrató a Cambridge Analytica para gestionar ciertos aspectos publicitarios basándose en datos, ya que saber a quién se están dirigiendo las campañas y cómo llegar a esas personas indecisas en cuanto a quien votar es esencial en la política desde hace varios años. El objetivo de esta campaña era llegar a los votantes cuyos pensamientos, comportamientos e ideales pudiesen cambiar fácilmente a través de anuncios en Facebook. Ambas empresas estaban jugando con la psicología de las personas sin su consentimiento para controlar un proceso democrático.

Christopher Wylie, un científico de datos de Cambridge Analytica tenía el objetivo de conseguir la mayor cantidad de datos posibles para las campañas de la empresa. Para ello, contactó con Aleksander Kogan, un profesor de psicología en Cambridge. Este le hizo llegar información sobre unas apps en Facebook que tenían permiso especial para conseguir datos de usuarios que se unían a la app. Estas apps realizaban encuestas sobre datos psicológicos. Pero no solo recogían datos sobre los usuarios de las apps, sino de todos los amigos de estos usuarios a través de Facebook. Si eras amigo de alguien que usó la aplicación, no tendrías ni idea de que habían cogido tus datos sobre el

status, likes e incluso mensajes privados. Con estos datos, Cambridge Analytica pudo crear perfiles psicológicos para diseñar a la perfección mensajes electorales enfocados según las distintas audiencias.

La defensa de Facebook es que en el año 2015 le pidieron a Cambridge Analytica que borrara los datos y estos les dijeron que ya los habían borrado cuando más adelante se demostró que realmente siguió usando datos de Facebook para sus modelos de predicción. Además, Mark Zuckerberg defendió que Facebook simplemente fue lento en actuar.

Este caso real tiene contacto con varios puntos importantes del debate que se genera actualmente, y podemos resumirlos en los siguientes principios:

- Los usuarios deberían tener transparencia sobre cómo se están usando sus datos y como se comercializan, y la capacidad de gestionar el flujo a través de sistemas de terceros. En el caso de Facebook y Cambridge Analytica, los usuarios no sabían que se estaba recopilando su información y la de sus amigos a través de la app, y una vez lo supieron, no eran capaces de controlar la migración o comercialización de estos.
- El procesamiento de datos y las acciones que se toman en base a él no debería interferir con la voluntad humana. Por ello es importante tener en cuenta qué tipo de predicciones o análisis vamos a hacer, para así asegurar que es el consumidor quien realmente está decidiendo y no nosotros. Los usuarios de Facebook se estaban viendo influenciados de forma subliminal a través de los perfiles que se habían creado sin su consentimiento, y se puede considerar que la decisión de voto que tomaron al final estaba sesgada por los anuncios personalizados que habían visto.
- Alinear la seguridad de los datos con las expectativas de los usuarios. Ya que los usuarios tienen ciertas expectativas de cómo se gestionan y procesan sus datos, es importante saber cuáles son estas y procurar adherirse a ellas siempre para evitar posibles crisis. Mientras que la gran mayoría de usuarios de Facebook son conscientes de que sus datos son usados con ciertos fines, también esperan cierta responsabilidad por parte



de la plataforma a la hora de explotarlos y comercializarlos; uno de los fallos de Facebook fue no tener en cuenta este aspecto, lo cual hubiese evitado el escándalo por completo.

- Las prácticas de la empresa orientadas al dato deberían estar sujetas a supervisión interna y externa. Las empresas deben establecer sistemas que evalúen los aspectos éticos de su manipulación de datos, y la supervisión organizaciones externas garantiza tanto la imparcialidad como la confianza del público. Otra de las principales causas del escándalo fue que no hubiese un organismo interno o externo que pudiese vetar las decisiones que se tomaron, tanto en Facebook como en Cambridge Analytica como en el equipo de Trump. Por ello es importante tener un experto o departamento interno que pueda asesorar la toma de estas decisiones, no sólo desde un punto de vista empresarial sino moral y ético, y es importante que se cree un organismo que audite el uso de datos de las empresas y organizaciones.

Pese a que ya se haya recalcado la importancia del debate ético en este campo y ya haya ciertas leyes que lo regulan, hay empresas como Google que han tomado la iniciativa y han establecido una serie de normas internas por las que se tienen que regir todos los procesos que impliquen el uso de datos e inteligencia artificial (IA). En particular, las iniciativas propuestas por Google se pueden tomar como un estándar a seguir, como mínimo, para todas las empresas que gestionen información de usuarios y decidan en base a ella. Google define las siguientes normas para la IA:

- Debe tener un impacto positiva en la sociedad.
- Evitará crear o reforzar sesgos injustos.
- Será segura por diseño y se revisará constantemente.
- Los errores o sesgos que pueda tener serán responsabilidad de las personas encargadas de ella.

- Deberá mantener excelencia técnica y científica, revisándose y modificándose cuando sea necesario.
- Sólo se hará disponible para usos que se ajusten a estas normas.

Adicionalmente, hay otros argumentos que persuaden un uso más ético de los datos, algunos de ellos ya cubiertos por la ley:

- El procesamiento de datos no debe facilitar sesgos como el racismo o sexismo. Puesto que los algoritmos de machine learning pueden heredar sesgos de la población o sus programadores, los modelos estarían discriminando y limitando las capacidades de ciertas personas. Este es un punto que la GDPR cubre, ya que no permite que se exploten los llamados “datos especiales” de las personas.
- Cumplir la ley, pero entender que a veces esto es hacer lo mínimo. Puesto que la ley siempre va un paso por detrás de la digitalización, subestima los riesgos del panorama del momento. Por ello es importante tener un sistema de códigos internos que seguir para destacar en la ética del dato. Esto es especialmente importante hoy en día, ya que la sociedad cada vez exige mayor transparencia de las empresas, y puede haber un escándalo aunque la empresa esté cumpliendo la ley, como fue el caso de Target y la adolescente embarazada que se cubrió anteriormente. Por el contrario Google ha tomado la iniciativa y busca cumplir algunos puntos adicionales como la excelencia técnica.
- Procurar asegurar la auditabilidad de los datos para evaluar su calidad y precisión. Puesto que frecuentemente los datos se reciclan, es importante que estos vengán acompañados del contexto de su recolecta así como los métodos que fueron utilizados para poder determinar como de precisos son.
- Los modelos que utilicen datos para facilitar la tomas de decisiones deberán poder ser explicados perfectamente, de lo contrario no se podrán utilizar. Frecuentemente los modelos de machine learning evolucionan más allá de

sus capacidades de diseño, lo cual puede hacer que resulte difícil entenderlos y explicarlos; esto falta de transparencia no está permitida ya que los modelos pueden estar desarrollando un sesgo injusto.

- Los principios y valores éticos deben ser robustos, conocidos organizacionalmente y revisados periódicamente. Este es de los puntos más importantes de todos los mencionados, ya que recalca la importancia de tener una serie de principios y valores conocidos y apoyados por toda la organización, lo cual puede evitar que se planteen y ejecuten ideas que van en contra de la integridad ética del uso de datos, y además deja en evidencia la necesidad de tener un sistema de mejora constante a través de la revisión de los principios por los que se rigen las organizaciones, ya que estos pueden cambiar según la realidad de la empresa y entorno en cualquier momento.

## **Conclusiones**

La digitalización y el análisis de datos ya no es solo una tendencia sino una realidad comparable a la revolución industrial. Ya no es cuestión de obtener una ventaja mediante la digitalización o el uso de big data, sino una cuestión de adoptar el cambio o dejar de ser competitivos. El sector de la moda ha permanecido relativamente hermético a este cambio, pero desde que empresas como Inditex han realizado inmensas inversiones en nuevas tecnologías la industria de la moda también ha comenzado a modernizarse aunque a un menor ritmo que el resto de sectores. Por esto es el momento de dar el paso hacia la digitalización, antes de que se convierta en una necesidad.

Las técnicas de análisis comentadas se aplican en todo tipo de sector, pero son de especial importancia en la moda ya que es un sector tradicionalmente ineficiente y sujeto a mucha incertidumbre en la demanda, desde su previsión a la creación de productos. Por ello, técnicas como los modelos ARIMA, regresión lineal y text mining pueden dar una ventaja competitiva importante frente a otras marcas, especialmente ahora puesto que gran parte del sector sigue apoyándose en técnicas y medios tradicionales.

Además del paso hacia la digitalización en las actividades de la empresa, se debe dar el paso hacia la digitalización de cara al consumidor. Los entornos de retail físicos apenas han evolucionado en las últimas décadas puesto que no se ha visto la necesidad. Pero ahora con la saturación de este entorno, en el que hay una tienda a cada vuelta de la esquina, es imprescindible conseguir diferenciarse en la experiencia de compra además de obtener mayor rentabilidad e información del punto de venta. Por ello las tendencias como asistentes digitales, beacons, neuromarketing y self-checkout son tan importantes; son el próximo paso en la cadena evolutiva del retail.

Pero nada de esto sirve si nos regimos bajo las nuevas normativas y leyes a las que están sujetas las empresas que deciden digitalizar, algo que pasa frecuentemente hoy en día como se ejemplifica en el caso de Facebook. El mundo del dato abre la puerta a numerosas posibilidades de obtener una ventaja competitiva, por lo que puede ser fácil olvidar que hay una serie de

leyes muy claras que debemos de seguir, y que en ocasión es fácil no cumplir si no estamos bien informados y no estudiamos la viabilidad legal de nuestras ideas. Por ello, cualquier empresa que quiera embarcar hacia la digitalización debe dedicar parte de sus recursos al aspecto legal. Pero la legalidad no lo es todo, puesto que la tecnología cambia más rápido de lo que lo hacen las leyes. Es por esto que las empresas deben valorar los aspectos éticos de sus actividades digitales, teniendo en cuenta al usuario en todo momento.

Empresas como Google ya han tomado la iniciativa y llegan un paso más allá de lo que exige la ley, ya que entienden que hoy en día la sociedad está muy concienciada y preocupada por el uso de sus datos, y darle la seguridad de que se usan de forma ética y que aporta valor es imprescindible para la supervivencia de la empresa.

Adicionalmente, como ya se explicó al principio, no todas las empresas deben aplicar estas técnicas; cuando uno oye hablar de algoritmos y big data es fácil lanzarse a la aventura sin considerar como de rentable es realmente. Por ejemplo, las necesidades de una pequeña tienda multimarca no son las mismas que las de LVMH; a la tienda multimarca puede bastarle con analizar el impacto de sus anuncios en redes sociales, mientras que LVMH necesita un modelo predictivo de la demanda altamente sofisticado. Es importante que entendamos en todo momento la realidad de nuestro negocio y qué necesitamos realmente.

Finalmente, en este documento se han recogido las técnicas más relevantes que se están aplicando, aportando ejemplos claros, holísticos y sencillos que se pueden extrapolar a cualquier empresa pero en particular una marca en el sector de la moda. Por esto, creemos que cualquier empresario o emprendedor que consulte esta disertación será capaz de integrar las técnicas, haciendo un estudio previo y apoyándose en cierta formación, sin dificultad.

## Bibliografía

-Dharmani, S. (2020, 1 septiembre). *How natural language processing can build supply chain resiliency*. EY. [https://www.ey.com/en\\_es/advanced-manufacturing/how-natural-language-processing-can-build-supply-chain-resiliency](https://www.ey.com/en_es/advanced-manufacturing/how-natural-language-processing-can-build-supply-chain-resiliency)

-Deloitte. (2017a). *The future of retail. 11 predictions on the disruptive forces in retail*. <https://www2.deloitte.com/content/dam/Deloitte/de/Documents/Innovation/Deloitte-Digital-Future-of-Retail-11-Predictions-English-2017.pdf>

-Deloitte. (2020, febrero). *Digital disruption in retail*. [https://www2.deloitte.com/content/dam/Deloitte/in/Documents/consumer-business/in-consumer-Digital%20Disruption%20in%20Retail\\_Retail%20Leadership%20Summit%2020%20Report.pdf](https://www2.deloitte.com/content/dam/Deloitte/in/Documents/consumer-business/in-consumer-Digital%20Disruption%20in%20Retail_Retail%20Leadership%20Summit%2020%20Report.pdf)

-Deloitte. (2017c, noviembre). *Disruptions in Retail through Digital Transformation. Reimagining the Store of the Future*. <https://www2.deloitte.com/content/dam/Deloitte/in/Documents/CIP/in-cip-disruptions-in-retail-noexp.pdf>

-Shaw, N. (2020, 17 septiembre). *Why Your Retail Business Needs to Deploy BOPIS*. Business 2 Community. <https://www.business2community.com/consumer-marketing/why-your-retail-business-needs-to-deploy-bopis-02347326#:~:text=It%20bridges%20the%20gap%20between,with%20a%20convenient%20shopping%20experience.>

Accenture. (2020). *Data Ethics*. <https://www.accenture.com/sk-en/insight-data-ethics>

Accenture Labs. (2016a). *Ethical algorithms for “sense and respond” systems*. [https://www.accenture.com/\\_acnmedia/PDF-27/Accenture-Ethical-Algorithms-Digital.pdf#zoom=50](https://www.accenture.com/_acnmedia/PDF-27/Accenture-Ethical-Algorithms-Digital.pdf#zoom=50)

-Accenture Labs. (2016b). *The Ethics of Data Sharing: A guide to best practices and governance*. [https://www.accenture.com/\\_acnmedia/PDF-35/Accenture-The-Ethics-of-Data-Sharing.pdf#zoom=50](https://www.accenture.com/_acnmedia/PDF-35/Accenture-The-Ethics-of-Data-Sharing.pdf#zoom=50)

-Harrell, E. (2019, 30 enero). *Neuromarketing: What You Need to Know*. Harvard Business Review. <https://hbr.org/2019/01/neuromarketing-what-you-need-to-know>

-Deloitte. (2017b, mayo). *Retail trends vr ar*. <https://deloitte-au-cip-retail-trends-vr-ar-retail-020517.pdf>

-25+ examples of neuromarketing applications. (2021, 12 febrero). Bitbrain. <https://www.bitbrain.com/blog/neuromarketing-examples-applications>

-Gail, T., & Scott, L. (1995, 1 diciembre). *Waiting time delays and customer satisfaction in supermarkets | Emerald Insight*. Emerald. <https://www.emerald.com/insight/content/doi/10.1108/08876049510100281/full/html?skipTracking=true#:~:text=Although%20the%20average%20checkout%20time,has%20remained%20a%20long%2Dstanding>

-Variawa, R. (2019, 29 septiembre). *Ethics in AI: Decisions by Algorithms - Towards Data Science*. Medium. <https://towardsdatascience.com/ethics-in-ai-decisions-by-algorithms-eed510efc9>

Parlamento Europeo. (2019, 2 septiembre). *General Data Protection Regulation (GDPR) – Official Legal Text*. General Data Protection Regulation (GDPR). <https://gdpr-info.eu/>

-Llerandi, J., & Mejías, J., Wentz, C. (2021, enero). *TRABAJO FINAL ANALYTICS. MODELO PREDICTIVO DE PRECIO DE UN PISO EN AIRBNB EN NUEVA YORK*.

-Martinez, L., Soto, M., Wentz, C., & Llerandi, J. (2020, marzo). *CONFLICTO ÉTICO: FACEBOOK Y EL GRAN HACKEO*.

-Google AI. (2018). *Our Principles*. <https://ai.google/principles/>

- Barcos, L. (2020a). *Gestión de Inventarios* [Diapositivas]. comillas.edu.  
[https://sifo.comillas.edu/pluginfile.php/2696887/mod\\_resource/content/1/Tema%209\\_Gesti%C3%B3n%20de%20inventarios\\_2020.pdf](https://sifo.comillas.edu/pluginfile.php/2696887/mod_resource/content/1/Tema%209_Gesti%C3%B3n%20de%20inventarios_2020.pdf)
- Barcos, L. (2020b). *Gestión de la Calidad* [Diapositivas]. comillas.edu.  
[https://sifo.comillas.edu/pluginfile.php/2677583/mod\\_resource/content/1/Tema%205%202020.pdf](https://sifo.comillas.edu/pluginfile.php/2677583/mod_resource/content/1/Tema%205%202020.pdf)
- Barcos, L. (2020c). *Previsión de la demanda* [Diapositivas]. comillas.edu.  
[https://sifo.comillas.edu/pluginfile.php/2677581/mod\\_resource/content/1/Tema%2003%20Prevision%20de%20demanda\\_2020.pdf](https://sifo.comillas.edu/pluginfile.php/2677581/mod_resource/content/1/Tema%2003%20Prevision%20de%20demanda_2020.pdf)
- Cruz, A. (2020a, octubre). *Reglas de Asociación*. <https://comillas.edu>.
- Cruz, A. (2020b, octubre). *Técnicas de clasificación o clústering*.  
<https://comillas.edu>
- Rayón, A. (2020c). *Análisis FCB* [Código de R].
- Rayón, A. (2020d). *Text Mining* [Código de R].
- Cruz, A. (2020e). *USarrests K-means* [Código de R].
- Cruz, A. (2020f). *USarrests H-Clustering* [Código de R].
- Cruz, A. (2020g). *Reglas Asociación 1* [Código de R].
- Cruz, A. (2020h). *Reglas Asociación 2* [Código de R].
- Cruz, A. (2020i). *Reglas Asociación 3* [Código de R].