



Facultad de Ciencias Económicas y Empresariales

Análisis del uso actual de tecnologías de Big Data en el entorno empresarial

Autor: José Luis López-Garzón Hernández

Director: Lucía Barcos Redín

Resumen

En el contexto económico actual, en el que la competitividad es extrema, especialmente entre las empresas más grandes. Las empresas buscan cualquier manera que sean capaces de encontrar de lograr una ventaja competitiva en el mercado. Las nuevas tecnologías de la comunicación son en muchos casos el camino que siguen las empresas en su búsqueda de desmarcarse ante su competencia. En los últimos años la tendencia ha sido y sigue siendo hacia la Analítica de Datos, o lo que en la mayoría de los casos es lo mismo el Big Data. Pese a que al definirlo es un término muy abstracto que resulta casi teórico, en la práctica cientos de empresas en todo el mundo han mejorado sus resultados en uno o muchos aspectos gracias al almacenamiento y análisis de los datos a su alcance. En este trabajo por lo tanto se pretende hacer un estudio que conceda una idea general de cómo funcionan estas tecnologías, en qué se basan, cuáles son las áreas en las que las empresas las están utilizando y qué clase de usos les están dando. Primero se explicará qué es el Big Data y sus cualidades y propiedades más definitorias. Después se procederá a analizar los usos del Big Data que se están realizando en una serie de áreas de la actividad empresarial en la que ya se utilizan estas tecnologías para estudiar cómo lo utilizan las empresas para lograr sus objetivos.

Palabras clave: Big Data, previsión de demanda, inventarios, cadena de producción y cadena de suministro

Abstract

In the current global economic context competition is outstanding, specially among the bigger multinational companies. Companies constantly strive to find whatever way they can to find a competitive advantage on the market. New technologies of communication and cloud are in many cases the road companies chose to drive to make themselves stand out among the competition. In the past few years the tendency has been, and still is, towards the Data Analytics, or what ends up being the same in most cases, Big Data. Despite how hard it may be to describe due to it's abstract nature, in practice hundreds of companies around the world have seen their numbers improve in one or many ways as a result of storing and analyzing the data on their reach. Hence, the aim of this paper is to present a study that provides a general idea of how this technologies work, what they are based on, in which areas are companies implementing them and what kind of uses are they giving them. First I'll properly explain what Big Data is and what are it's main qualities and characteristics. Then I'll proceed to analyze the use of Big Data in a few areas of the business activity in which these technologies are already being developed to study how companies move closer to their goals thanks to them.

Key words: Big Data, demand planning, inventories, supply chain and production chain

INDICE:

1. Introducción.....	3
2. Introducción al Big Data.....	7
2.1 Las 5 Vs.....	8
2.2 Analítica de datos.....	10
2.3 Análisis de datos.....	11
3. Big Data Business Analytics.....	13
4. Previsión de demanda.....	14
4.1 Previsión de demanda por series temporales.....	14
4.2 Previsiones de demanda individualizadas.....	19
4.3 Modelaje de la producción con previsiones individualizadas.....	22
4.4 Aprendizaje y planificación de preferencias.....	23
5. Analítica de la cadena de suministro y gestión de inventarios a.....	24
5.1 Modelo SCOR.....	24
5.2 Proceso Analítico Jerárquico (AHP).....	26
5.3 Modelo Integrado AHP-SCOR (ASIM).....	28
6. Cadena de Producción: Industria 4.0.....	32
7. Dificultades y problemáticas.....	36
7.1 Limitaciones legales.....	37
7.2 Limitaciones operacionales.....	38
8. Conclusiones.....	39
9. Índice de imágenes.....	40
10. Bibliografía.....	42

1. Introducción

En las últimas tres décadas la extensión del uso de tecnologías digitales ha sido totalmente exponencial e imparable. Este crecimiento está trayendo consigo de manera inevitable cambios muy grandes en nuestras formas de vida, desde cómo nos socializamos hasta cómo trabajamos pasando por nuestras maneras de producir, comprar y consumir bienes y servicios.

Más recientemente estos cambios han estado impulsados, más allá de por el mero desarrollo tecnológico, por el omnipresente “Big Data”. ¿Pero qué es el Big Data? De acuerdo con Min Shiwen y Yunho (2014), el Big Data normalmente comprende grandes masas desestructuradas de datos que necesitan más análisis en tiempo real. Manyika et al. (2011) definieron el Big Data como la próxima frontera para la innovación, la competencia y la productividad. Por su parte Richard et al. (2011) declararon en su documento técnico de IDC que las tecnologías de Big Data pueden ser descritas como una nueva generación de tecnologías y arquitecturas diseñadas para que las empresas y organizaciones puedan extraer el valor económico de volúmenes muy grandes de una amplia variedad de datos, permitiendo la captura, el descubrimiento, el almacenamiento y el análisis a alta velocidad.

Esta última es de las definiciones más ampliamente acordadas por muchos investigadores y directivos. Pero como es evidente, pese a ser uno de los temas más de moda y más analizado entre la comunidad científica, 598 artículos científicos incluían “Big Data” como uno de sus términos clave en el periodo de 2011 a 2017 (Nguyena et al., 2017), no sería cierto decir que haya un consenso total respecto a qué es y qué técnicas entran en su categoría. Por lo que no merece la pena hacer otro estudio tratando como otros tantos de darle una definición consistente al término.

Independientemente, sobre lo que si hay consenso, es sobre que estas técnicas, cuando usadas apropiadamente han revolucionado para bien la eficiencia y los resultados de muchas empresas de todos los tamaños a lo largo de todo tipo de industrias. Y que virtualmente que cualquier empresa del mundo tiene el potencial para que el Big Data lleve su actividad un paso más adelante. La prácticamente total extensión del uso de dispositivos conectados ha hecho que cada vez más y más empresas se actualicen y traten de utilizar el “Big Data Business Analytics” (en adelante BDBA) como lo que es, “una capacidad crítica para los negocios para obtener valor de cantidades cada vez más masivas de datos y lograr así poderosas ventajas competitivas” (Cheng et al. 2012).

Esto es cierto para cientos de empresas de todos los tamaños en decenas de sectores que a día de hoy ya utilizan metodologías de Análisis de Datos de maneras tremendamente diversas. Como en el sector financiero, donde el análisis de los precios históricos de los distintos valores hace cada día más fácil la predicción de precios futuros; o en el sector de la salud donde muchos hospitales ya analizan sus muy heterogéneas fuentes de datos para optimizar tanto su gestión clínica como el tratamiento y la atención al cliente.

El crecimiento de estas bases de datos y su disponibilidad para las empresas viene directamente ligado a la extensión global de los dispositivos conectados a internet y del aumento de los usos que la sociedad en general le da a la red.

Según el informe direndia: Mobile en España y en el mundo 2017 (1) el 88% de la población española son usuarios regulares de móviles. Esta cifra, que ha crecido desde un insignificante 2% en 1995 es ahora mismo la más alta a nivel global, 22 puntos por encima de la media mundial, y es muy significativa sobre el impacto que tienen estas tecnologías en todos los aspectos de nuestras vidas. Ese 88% de la población española que es usuaria regular de dispositivos móviles conectados a internet gasta de media 2 horas y 50 minutos al día usando su smartphone.




Ilustración 1. Fuente: Informe Ditrendia 2017

Usamos mucho estos dispositivos y para una gran variedad de funciones cuyo objetivo final se podría decir que es hacernos las vidas más fáciles. Los usamos para comunicarnos, consumir contenidos, leer noticias, hacer la compra, ... No es exagerado decir que hoy en día desarrollamos una buena parte de nuestras vidas online, y al hacerlo, como es evidente, dejamos una huella digital. Una huella digital en forma de todo tipo de datos sobre nosotros y nuestra actividad en la red que es recogida normalmente en forma de cookies, que son almacenadas en grandes bases de datos. Contienen todo tipo de información sobre nosotros, nuestro uso de internet, nuestros hábitos de compra, nuestros gustos musicales, ...en definitiva nuestra forma de vida. Esta información es recogida y analizada por las organizaciones con las que interactuamos en internet que la usan para promocionarnos sus productos.

Este sea seguramente el uso del Big Data que hacen las empresas con el que la gente está más familiarizada a un nivel de diario y que resulta más obvio y visual al ser el más directo para el cliente e impactar más. Un día compras unos vuelos a París y al día siguiente en Instagram te salta un anuncio de un hotel con vistas a la Torre Eiffel. No hace falta saber como funciona por detrás para saber que lo que haces online es analizado y usado a la hora de personalizar tu publicidad. Pero no es, ni mucho menos,

la única manera en que las empresas están utilizando las metodologías de análisis de grandes cantidades de datos para maximizar sus beneficios.

La Analítica de Datos puede abarcar prácticamente cualquier proceso o sección de la actividad empresarial, desde los Recursos Humanos hasta los controles de calidad. Pero, aunque el rango de tecnologías y metodologías que entran dentro de lo que uno puede llamar Big Data y los usos que se les pueden dar es totalmente inmenso para este trabajo nos vamos a centrar en el BDPA. Específicamente vamos a analizar, tanto a nivel teórico como a través de ejemplos prácticos, como las empresas están integrando el BDPA en sus procesos de producción, principalmente en torno a las siguientes operaciones generales:

- Previsión de demanda
- Gestión de la cadena de suministro y de Inventarios
- Cadena de producción

Limitaremos el estudio a estos procesos dentro de la actividad empresarial, aparte de porque el Big Data como concepto es prácticamente inabarcable, por tres principales razones:

- I. La primera porque estos tres ámbitos son absolutamente claves en la dirección de operaciones, y no se puede lograr buenos resultados como compañía si no se tienen buenos resultados en ellos.
- II. La segunda es porque son procesos en los que la creación de datos es inherente a su mera actividad. Incluso antes de que existiera la Analítica de Datos y se le empezara a sacar partido las empresas ya generaban mucha información en el desarrollo de estas actividades.
- III. La tercera es porque por esta misma naturaleza cuantificable, es en este ámbito industrial donde generalmente las empresas más se han esforzado en perfeccionarse y donde por tanto hay más estudios e información disponible.

Para el propósito de este trabajo se tiene por tanto el siguiente objetivo: “Realizar un análisis de las metodologías de Big Data existentes actualmente y los usos que se le dan en las empresas sobre todo en torno a la previsión de demanda, la cadena de producción y la gestión de inventarios y teorizar sobre cuál es el futuro de estas tecnologías”.

De cara a lograr este objetivo a lo largo de este trabajo se van a cubrir los siguientes apartados sobre los que pretendo fundamentarlos conceptos que pretendo transmitir con el trabajo:

- Ofrecer una breve pero clara definición de lo que son el Big Data, el Big Data Business Analytics y sus principales términos.
- Contextualizar la evolución histórica y la situación actual del uso de estas tecnologías.

- Estudiar los distintos tipos de datos que las empresas recopilan, fuentes desde las que los obtienen y cómo lo hacen.
- Estudiar las formas en las que las empresas están utilizando estos datos para potenciar su eficiencia a distintos niveles y fases de su proceso de producción.
- Mostrar, a través de ejemplos reales de estos usos, como de tangibles pueden llegar a ser las mejoras de resultados usando Big Data.

Como metodología para la realización se han usado diversas fuentes de información. Principalmente una intensiva revisión bibliográfica de artículos científicos y libros de expertos relacionados con la materia. Revisión de entrevistas de terceros a profesionales y académicos que dediquen su actividad a materias relacionadas con el tema. Y lectura de múltiples blogs y páginas de noticias dedicados sobre todo al mundo de los negocios, la economía, marketing y analítica.

Por lo tanto, a partir de ahora se procede a utilizar esta metodología para realizar el mencionado análisis y tratar de extraer conclusiones sobre la historia y la situación actual del Big Data Business Analytics.

2. Introducción al Big Data

¿Qué es el Big Data? Como ya decíamos en la introducción Big Data no es un término nada fácil de definir, he aquí una representación gráfica:




Ilustración 2: Definición de Big Data basada en una encuesta realizada a 154 ejecutivos a nivel global (Malvicino et al., 2015)

Estas son de acuerdo a una encuesta realizada a 154 directivos a nivel global las definiciones más habituales para el término (Malvicino et al., 2015). Como se puede observar, la más repetida es “crecimiento masivo de datos transaccionales de los consumidores y la cadena de suministro” pero la diferencia con el resto de las opiniones no es muy grande. Aún así, esta definición nos sirve muy bien para entender cómo han sido el nacimiento y expansión de estas tecnologías. El Big Data surge como un nuevo paso en la evolución de la información y la comunicación, y ofrece una nueva oportunidad de reducir las brechas de productividad e intensificar la competencia.

El primer paso esencial del Big Data es la recopilación. No hay análisis de datos si no hay datos. Prácticamente desde que existe la industria las compañías han analizado los datos a su alcance con el objetivo de producir y vender de una manera más eficiente. Hasta hace no demasiados años estos datos con los que las empresas han tratado de maximizar su eficiencia eran simples y venían de lo que eran capaces de recopilar por sí mismas en su actividad de diario. Como volúmenes de ventas pasados, tiempos de producción o costes. Hoy en día estos datos que las empresas tienen a su alcance se han ampliado enormemente en alcance y en detalle. Además, han aparecido muchísimas fuentes de datos externas de las que las empresas han aprendido a sacar valor (Feng et al., 2018).

2.1 LAS CINCO Vs

Como decíamos el Big Data abarca una gran cantidad de tecnologías, lo datos se de diversas fuentes como redes sociales, registros o sensores. IBM en su *White paper "Making Sense of Big Data"* (2017) define que los sets de datos, para ser considerados Big Data tienen que abarcar tres grandes dimensiones, conocidas como "Modelo de las tres V". Estas son volumen, velocidad y variedad. Muchos otros estudios añaden a estas tres otras dos características más también importantes, veracidad y valor.

I. Volumen

La característica esencial del Big Data es el volumen. Como veíamos las empresas almacenan exponencialmente más y más cantidades de datos de las cada vez más diversas fuentes a su disposición.

Actualmente se crean en el mundo 2,5 quintillones de bytes al día, eso es en un día $1,25 \times 10^{15}$ veces más datos que a lo largo de todo el año 2000. Y también significa que el 90% de todos los datos jamás almacenados han sido creados tan solo en los últimos dos años, y explica el componente exponencial que tiene la expansión de su uso en el mundo empresarial. Pero al igual que cifras de hace 20 parecen totalmente insignificantes comparadas con las de hoy, a las de hoy lo perecerán también en mucho menos tiempo.

De acuerdo con el informe realizado por Reinsel et al (2018) para IDC se estima que para el año 2025 el tamaño de la "datosfera", es decir, el conjunto de todos los datos almacenados en todas partes, podría llegar a los 175 zetabytes, 5 veces más que a día de hoy (33 ZB) (Ilustración 2). Esa cantidad almacenada en un formato físico supondría una pila de CD lo suficientemente larca como para llegar de la Tierra a la Luna y volver. Además, se estima que más de la mitad de toda esta información residirá en bases de datos privadas, pertenecientes principalmente a corporaciones y gobiernos.




Ilustración 3: Data Age 2025, sponsored by Seagate with data from IDC Global DataSphere, Nov 2018

II. Velocidad

Se refiere al ritmo con el que los datos son recopilados, analizados y se toman acciones sobre ellos. Implica que para sacar verdadero valor de ellos el procesamiento y análisis posterior de los datos tienen que ocurrir en tiempo real. No se refiere a la velocidad a la que crecen en tamaño los almacenes y depósitos de datos, eso es el volumen. Se refiere a velocidad a la que estos datos fluyen, es decir a la capacidad de procesamiento que las empresas tienen sobre los datos que recopilan. La cadena Wal-Mart por ejemplo llega a procesar más de un millón de transacciones a la hora. Proviene de diferentes dispositivos móviles y en tienda y son utilizados y generan flujos de información sólida sobre los clientes como geolocalización, demografía y hábitos de consumo que son utilizados para generar ofertas personalizadas en tiempo real (Harrison S. Martin Aldana et al. 2018).

III. Variedad

Se refiere a lo estructuralmente heterogéneos que son los datos almacenados. Las fuentes de datos pueden recoger información de todas las clases. Pueden ser texto, registros de clics, video, audio, procedentes de sensores,... Estos datos pueden ser estructurados, es decir, datos tabulares almacenados en hojas de cálculo o bases de datos relacionales. Semiestructurados, que no cumplen estándares estrictos, por ejemplo las bases de datos HTML o en Extensible Markup Language (XML) que acumulan datos editados por el usuario en un lenguaje textual para hacerlos intercambiables en la Web y legibles por una máquina. O no estructurados, estos últimos suponen un 95% del total de la datosfera y requieren de técnicas que los relacionen para poder ser analizados como un conjunto.

IV. Veracidad

Según el ya mencionado estudio de IBM: “Uno de cada tres líderes de negocio (directivos) no se fía de las informaciones que utilizan para tomar decisiones” (IBM, 2017). Esto hace que sea importante asegurarse de la fiabilidad de las fuentes de datos que se utilizan. Las redes sociales por ejemplo están plagadas de abreviaciones, hashtags, errores gramaticales y demás irregularidades que hacen que sea más complicado asegurar la calidad de los análisis. Las señales GPS pierden calidad en grandes áreas urbanas al rebotar en los edificios y estructuras más altas. Estos y otros ejemplos hacen que para las empresas y proveedores de servicios de datos sea un reto asegurar la calidad de los datos. Una manera de conseguirlo, en el caso de las señales GPS por ejemplo consistiría en cruzar los datos de esas señales con los de tráfico en las carreteras para filtrarlos mejor.

V. Valor

El desafío final de todo análisis de datos es al fin y al cabo identificar la información valiosa y lograr obtener valor económico de la misma. No siempre se pueden obtener los insights que se buscan de analizar sets de datos y por eso es muy importante tener en cuenta el coste de recopilar, almacenar y analizar estos sets y ser conscientes de si las acciones que se están tomando a raíz de ellos están resultando beneficiosas globalmente.

2.2 Analítica de datos

La analítica de datos es la rama de la investigación científica a la que pertenecen el Big Data y sus técnicas. Engloba todos los procesos que forman parte del mundo del dato. Desde la recopilación hasta la toma de decisiones. Existen distintos métodos para la Analítica de datos en función de los objetivos a alcanzar y los tipos de datos a utilizar. Estos métodos suelen ser agrupados en tres grandes categorías:

I. Analítica Descriptiva

Las técnicas de modelaje para la analítica descriptiva son aquellas cuyo objetivo es describir o replicar el objeto de análisis ya sea un sistema o un proceso para tratar de responder a qué está pasando (Souza, 2014). Se recopilan patrones y resultados para poder inferir en qué ocurrirá en el futuro. Al usar un modelo totalmente descriptivo se deberían obtener resultados similares a aquellos del propio sistema en la realidad. Es la adición de elementos aleatorios (o estocásticos) lo que permite aumentar la cantidad y variedad de los resultados ofreciendo medidas sobre su incertidumbre y sus riesgos.

Estos elementos aleatorios que se incluyen en el modelo varían y pueden incluir factores como distintas distribuciones de probabilidad en los tiempos de llegada o de servicio de los clientes, distintos rangos de tiempos de entrega de recursos o patrones de demanda.

II. Analítica Prescriptiva

Las técnicas de modelaje para la analítica prescriptiva formulan para el responsable de la toma de decisiones algunos sets de decisiones “óptimas” en función de lo que calculan que ocurrirá en el futuro (Souza, 2014). Un buen ejemplo de este tipo de analítica se encuentra en cualquier sistema de navegación por GPS como Waze o Google Maps, que ofrecen distintas rutas para llegar a un mismo destino en función los datos que tienen sobre de las

condiciones presentes y futuras de la carretera, ofreciendo al usuario las vías más rápidas. A nivel industrial esto podría ayudar a elegir cosas como cuánto producir, por dónde planear una ruta de reparto o dónde colocar una nueva tienda o fábrica.

En resumen, proporcionan los mejores escenarios para guiar las decisiones subsiguientes o incluso alterar decisiones ya tomadas.

III. Analítica Predictiva

Las técnicas de modelaje para la analítica predictiva proporcionan alguna proyección del desempeño del sistema o proceso en el futuro (Souza, 2014). El principal ejemplo de esto es la previsión de demanda, que al ser uno de los puntos principales del Big Data desde el punto de vista de operaciones será analizando en profundidad más adelante. En pocas palabras la técnicas predictivas cogen una gran variedad de información como la ubicación del cliente, sus preferencias en el momento de comprar, el tipo de compras que hace, las épocas del año en las que aumenta y disminuye el volumen de compras,... Cruza esta información y ofrece estimaciones avanzadas del comportamiento en el futuro del sistema y de los clientes.

2.3 Análisis de datos

Independientemente del tipo de analítica y de los objetivos que se buscan, el ciclo que sigue su proceso científico es más o menos el mismo siempre:



Ilustración 4 Elaboración propia

De estos, el paso más importante y en el que se crea ese valor extra que aporta el Big Data es evidentemente el análisis:

Una vez recopilados, los datos son analizados. “El análisis es el proceso de examinación de los datos con el objetivo de hallar hechos, relaciones, patrones, explicaciones y tendencias.” (Bernal, 2017). Se analiza con el objetivo de que esta información encontrada sirva para aumentar, respaldar o alterar decisiones sobre diferentes procesos dentro de la empresa. Partiendo de esto existen dos tipos de análisis, análisis cuantitativo y cualitativo:

I. Análisis cuantitativo:

El análisis es cuantitativo cuando el set de datos a analizar es numérico o bien cuando lo que se está haciendo es convertir en numéricos datos de otro tipo como por ejemplo videos y fotos. Se llama análisis cuantitativo porque implica el recuento o la medición de algún atributo, patrón o relación entre datos. Los resultados obtenidos de este tipo de análisis han de ser de naturaleza y absoluta y pueden ser expresados de manera numérica (p.e. 7 de cada 10 clientes...).

II. Análisis cualitativo

Por su parte, el objetivo del análisis cualitativo es “describir cualidades de la información analizada en lenguaje cotidiano” (Bernal, 2017). A diferencia del análisis cuantitativo que se aplica a un set entero de manera general, el cualitativo está pensado para analizar más en profundidad y de manera independiente una muestra específica del set. También contrariamente al cuantitativo los resultados de este análisis no son solo numéricos, sino que consisten, además de en números, en texto, imágenes, símbolos, o lo que sea necesario para aportar ese nivel de entendimiento y explicación sobre los datos. Por lo tanto, no se suele poder utilizar para llevar a cabo comparaciones estadísticas. Este análisis debería ocurrir simultáneamente con la recopilación de los datos para darles claridad, aunque el sentido y el significado que aportan se va desarrollando y mejorando con el tiempo y la acumulación de información.

3. Big Data Business Analytics

En este apartado vamos a entrar un poco más específicamente en cómo y para qué las empresas están usando estas tecnologías a lo largo de sus operaciones. Esto a lo que se refiere el termino Business Analytics. El siguiente gráfico muestra, según un estudio realizado por Deloitte y MHI en 2016 en el que se encuestaba a más de 900 miembros de la industria (más del 50% de ellos directivos) sobre la situación del uso de las tecnologías de BDBA en sus empresas. Estas fueron las respuestas ante la pregunta “¿Cuándo cree más probable que su empresa comience a utilizar las siguientes metodologías?”




Ilustración 5. Fuente Deloitte & HMI (2016)

Vamos a hacer este estudio entorno a tres ejes que representan tres de las actividades empresariales que globalmente más han visto potenciados sus resultados mediante el uso de la analítica de datos. Estas cuatro áreas son la previsión de demanda, la gestión de inventarios y cadena de suministro y la cadena de producción. Como podremos ver, están directamente relacionadas con las cuatro tecnologías más extendidas y con más previsión de crecimiento. Una buena gestión conjunta de las tres es importantísima para los resultados de cualquier empresa manufacturera.

4. Previsión de demanda

La incertidumbre de la demanda es uno de los retos más importantes a los que se enfrentan las empresas modernas. La existencia de la alta variabilidad en la demanda de productos de rápido movimiento e intermitente (objetos con una elevada proporción de observaciones nulas) plantean considerables dificultades en términos de planificación de producción y control de inventarios. Las desviaciones del grado de variabilidad que permite la distribución normal a menudo hacen que la previsión estándar y la teoría de inventarios sean inapropiadas (Rostami-Tabar, B., 2013).

Todas las áreas de la empresa dependen de la demanda final y los resultados que se obtienen de ella. Más allá, la actividad y la planificación de muchas de estas áreas depende de manera directa de prever con la mayor precisión posible dicha demanda. No es lo mismo la actividad en una fábrica de helados en el mes de julio que en el mes de enero, y eso parece simplista, pero es llevar ese concepto al máximo detalle posible lo que las empresas buscan haciendo estas previsiones. Algunas de las actividades de la empresa que más fuertemente se ven afectadas por las previsiones de demanda y más varían en torno a ellas son:

- La producción
- Las compras y adquisiciones
- El establecimiento de precios y ofertas
- La distribución de personal y recursos
- La gestión de riesgos

Hay muchos enfoques que se pueden utilizar para reducir la incertidumbre de la demanda y, por lo tanto, mejorar las previsiones. La capacidad para almacenar y analizar grandes cantidades de datos posibilita el perfeccionamiento de estos enfoques. Estos son algunos de ellos:

4.1 Previsión de demanda por series temporales

Una serie temporal o cronológica es un set de datos que incluye distintas mediciones de un mismo valor a través del tiempo ordenados cronológicamente. Los datos pueden estar espaciados en el tiempo de forma regular (como la temperatura en un reactor que se mida una vez cada hora) o irregular (como las analíticas de un paciente cada vez que va al médico).

Los cambios de los valores dentro de estas series se deben a todo tipo de variantes en según qué caso, económicas, políticas, naturales, propias de la industria,... Estas variantes se conocen como componentes de las series temporales, y hay cuatro tipos de ellos:

- Tendencias globales:

Son las condiciones generales y mayormente constantes que indican la dirección en la que la gráfica de un dato que afecta a la actividad empresarial

evoluciona en periodos de tiempo relativamente largos. Suelen estar relacionadas con la evolución tecnológica, la demografía o grandes cambios en movimientos sociales.

Estas tendencias son positivas si el valor del dato aumenta con el tiempo y negativas si decrece. Algunos ejemplos pueden ser:

La población mundial:




Ilustración 6 Fuente: Naciones Unidas

U otro directamente relacionado con el ascenso del Big Data, la capacidad de procesamiento de un gráfico logarítmico:

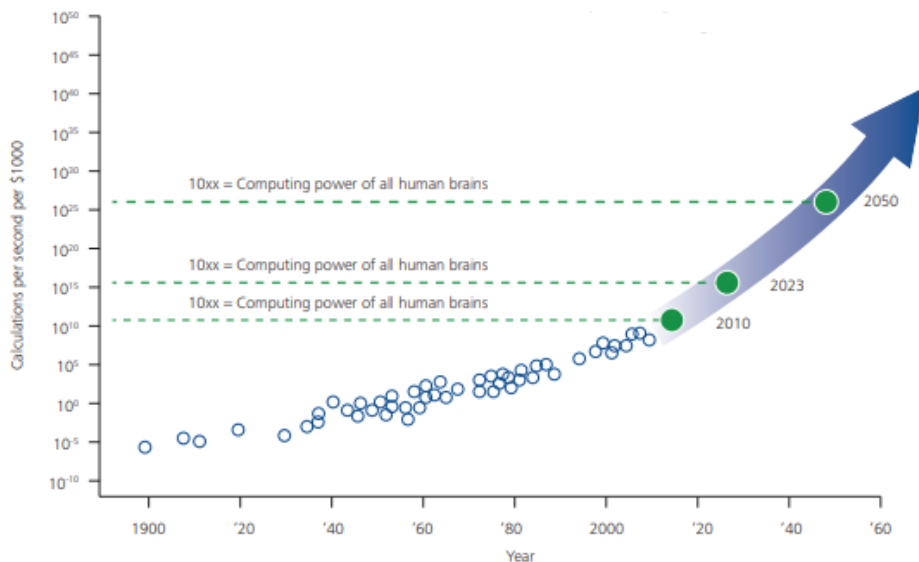


Ilustración 7. Fuente: Deloitte &HMI (2016)

➤ Variaciones estacionales

Son fluctuaciones en una serie temporal que ocurren periódicamente año tras año. Bien pueden estar causadas por los cambios en las demandas de la gente de una época del año a otra como por las temporadas de actividad como la temporada de festivales o de rebajas.

Visualmente un buen ejemplo es esta gráfica que representa la venta de la venta de refrescos en España de 2015 a 2017:




Ilustración 8 Fuente: Investigación y análisis de marketing. Pablo Tenorio

➤ Variaciones cíclicas:

Las variaciones cíclicas son tendencias recurrentes al alza y a la baja que afectan a una serie temporal en fases superiores a un año. Son menos regulares y pro tanto menos predecibles que las variaciones estacionales.

La propia economía, tanto a nivel global como a nivel nacional evoluciona en el muy largo plazo siguiendo una tendencia cíclica, alternando periodos de crecimiento y de recesión.

Como ejemplo, la siguiente gráfica muestra la tasa de crecimiento del PIB histórica para España y para la UE (1966-2014):

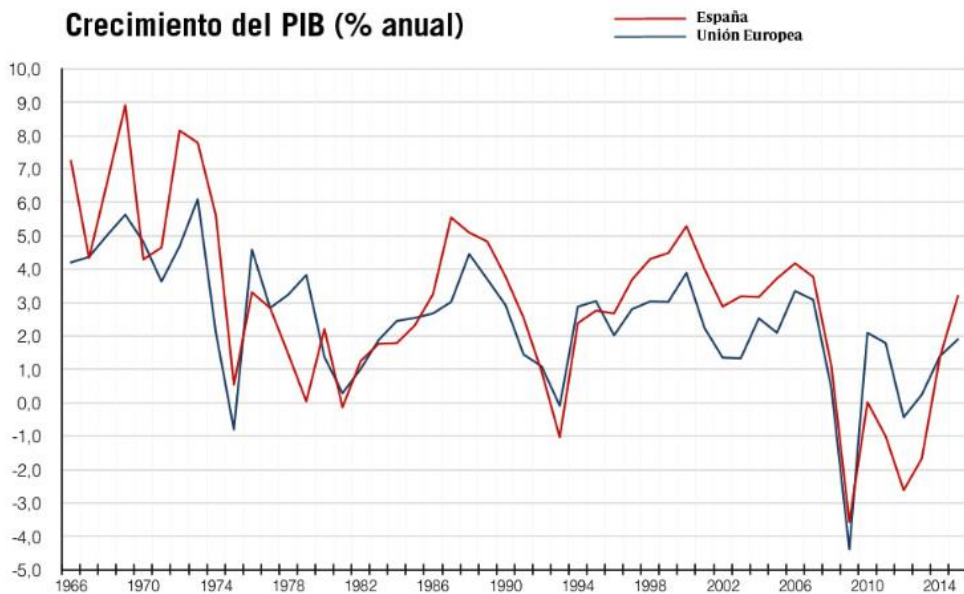


Ilustración 9 Fuente: IESE Business School

➤ **Variaciones Irregulares:**

Son fluctuaciones fuertes en una serie temporal causadas durante un periodo de tiempo corto por un evento errático en la naturaleza o la economía que ocurre sin seguir ninguna tendencia o patrón. También se conocen como variaciones residuales porque por definición representan los cambios que se salen de las tendencias o ciclos presentes.

Algunos eventos que pueden producir estas variaciones son terremotos, guerras o cortes de electricidad.

En definitiva, estos sets de datos temporales son el principal recurso que las empresas utilizan para elaborar sus previsiones de demanda. Eso se hace usando medias simples, semi- medias, medias móviles,... pero estas suelen resultar simples y poco precisas. El método más preciso y más extendido a nivel empresarial es el método de mínimos cuadrados.

❖ **Método de mínimos cuadrados**

Este método fue desarrollado por Karl Gauss (1777-1855). El concepto consiste crear una función que permita describir como se comporta una variable dependiente Y en función de una o más variables independientes X. Para ello, hay que hallar unos

parámetros (β) que de acuerdo a esa ecuación hagan mínima la suma de los cuadrados de los valores observados y los estimados (Martín, 2011). Funciona tal que así:

Parte de buscar una línea de tendencia tal que el sumatorio de los cuadrados de las desviaciones entre los valores reales y los valores estimados sea la mínima posible:

$$\min \sum (Y - Y_c)^2$$

Existe una versión diseñada para líneas rectas y otra para parabólicas, como partimos de que una previsión de demanda nunca va a ser una línea recta analizaremos solo la parabólica. Esta ecuación tendría la siguiente forma:

$$Y_c = a + bx + cx^2$$

Podría subirse a tercer grado añadiendo una tercera constante 'd' y un término de la unidad de tiempo x al cubo. Así en segundo grado las tres constantes a calcular son: a, b y c.

Suponiendo una muestra de 5 años (1992-1996) elaboramos la siguiente tabla con las diferencias en el tiempo respecto al año central (x) y las siguientes operaciones entre x y la producción (Y):

Year	Production	Dev. From Middle Year (x)	xY	x ²	x ² Y	x ³	x ⁴	Trend Value $Y = a + bx + cx^2$
1992	5	-2	-10	4	20	-8	16	5.7
1993	7	-1	-7	1	7	-1	1	5.6
1994	4	0	0	0	0	0	0	6.3
1995	9	1	9	1	9	1	1	8.0
1996	10	2	20	4	40	8	16	10.5
	$\sum Y = 35$	$\sum X = 0$	$\sum xY = 12$	$\sum x^2 = 10$	$\sum x^2Y = 76$	$\sum x^3 = 0$	$\sum x^4 = 34$	

Con estos resultados usamos las siguientes tres ecuaciones para estimar los valores de:

a)
$$\sum Y = Na + b \sum X + c \sum X^2$$

b)
$$\sum XY = a \sum X + b \sum X^2 + c \sum X^3$$

c)
$$\sum X^2Y = a \sum X^2 + b \sum X^3 + c \sum X^4$$

Con lo que nos quedaría un desarrollo de la ecuación anterior tal que así:

$$Y = 6,14 + 1,2x + 0,43 x^2$$

Sustituyendo en esta ecuación las x por las diferencias temporales entre el año base y el año a predecir obtendríamos la predicción de la demanda a calcular.

Este ejemplo es una simplificación y solo sirve para entender la esencia matemática del método ya que con tan pocos años y tan poca información a tener en cuenta no se puede considerar Big Data, ni siquiera requiere la enorme capacidad de computación que normalmente resulta necesaria al extrapolar este método para las predicciones reales de una empresa real.

4.2 Previsiones de demanda individualizadas

En teoría el acceso a más información lleva a mejores predicciones y modelos como el del apartado anterior mejoran de la que se les añade información ya no solo interna sino también externa en relación a situación político-económica o de la competencia. Eso sí, esto plantea un desafío que viene al tener que manejar tantísimas variables y sus ambiguas relaciones. Estas relaciones pocas veces van a estar definidas por formulas funcionales simples como lineares y exponenciales simples. Identificar una buena relación estable requiere de algo más aparte de grandes cantidades de datos, que muchas veces son demasiado dispersos como para sacar conclusiones fáciles de ellos. Muchos estudios sugieren que las técnicas de Machine Learning (ML), una de las ramas más prolíferas del Big Data supera en precisión cualquier análisis de series temporales al analizar información que va mucho más allá.

Estas metodologías y la mayoría de la literatura referente a la previsión de demanda se centran en análisis en un nivel agregado, global para las compañías. Pero recientemente el Big Data gracias sobre todo a plataformas como Facebook

o Google, está habilitando a las empresas un nivel de detalle previamente inimaginable sobre los consumidores individualmente. El conjunto de estos aprendizajes individualizados o personalizados posibilita una definición de la demanda futura mucho más fina que hasta ahora.

Para ejemplificar el potencial de estas técnicas vamos a utilizar el modelo teórico desarrollado por Feng, Q. et al. (2017) para una compañía de retail:

❖ Modelo de aprendizaje de demanda individualizada para un Retailer Online:

Imaginemos el caso de una típica tienda online. En el momento de registrarse (t_s) el consumidor aporta una serie de datos sobre sí mismo (dirección, edad, genero, método de pago,..) que son recogidos en un vector (x_0). Con el paso del tiempo este cliente visita la tienda online una serie de veces dejando un historial de navegación y de compras. Cada una de estas visitas deja en las bases de datos de la tienda un registro con las páginas y productos visitados, los comprados si los hay y la secuencia en que lo hizo todo. Esta información de su trayecto se recoge para cada visita en otro vector (c_n , donde n es el número de visita a la página). En el caso de haber compras usamos S_n para denominar el juego de productos adquiridos y $q_{n:i}$ para determinar la cantidad adquirida del producto adquirido i donde $i \in S_n$. Si a esta información le añadimos el precio ($p_{n:j}$) y la cantidad disponible ($y_{n:j}$) de cada producto $j \in J_n$ en ese momento donde J_n es el conjunto completo de productos ofertados en ese momento. Por tanto la información recogida de cada visita que incluya una compra quedaría como un conjunto de vectores tal que así:

$$Z_n = (c_n, S_n, q_n, J_n, p_n, y_n)$$

De no realizarse ninguna compra la visita solo registra el Flow de clicks a través de la página (c_n).

Con el tiempo la historia completa del cliente ($\{z_1, z_2, z_3, \dots, z_n\}$) va conteniendo una cantidad masiva de información sobre cada cliente individualmente. Además, la tienda puede estar por monitorizando por otra parte a la competencia y las tendencias económicas y sociales, factores que pueden influir fuertemente en las decisiones del consumidor. Para este modelo no vamos a incluir esa información, pero su tratamiento sería similar a la que si estamos estudiando.

Con toda esa información para tratar de predecir el comportamiento futuro del consumidor es necesario extraer las cualidades críticas del consumidor. La selección y extracción de cualidades críticas facilita el procesamiento de datos haciéndolo más eficiente. Para ello se utilizan diversos métodos como filtros, algoritmos o regularización entre otros muchos. Los datos a extraer y las técnicas a usar dependen en gran medida del objetivo del análisis y las variables a predecir por lo que de un mismo set de datos se pueden llegar a sacar conclusiones o cualidades muy distintas (Guyon et al.,2006). Tras esta extracción pasaríamos de el mencionado conjunto z_n a un conjunto de tamaño manejable w_n .

Ahora supongamos que la tienda tiene registrados m clientes en el momento t y que la información para el cliente j de acuerdo con el set de cualidades extraídas $x_t^{(j)}$ es la siguiente:

$$\{(\mathbf{a}_n^{(j)}, \mathbf{w}_n^{(j)}), n = 1, 2, \dots, n^{(j)}(t)\}$$

Podemos estimar la llegada y las decisiones a tomar del siguiente consumidor basándonos en los datos de los anteriores clientes y de los productos y precios disponibles. Si por ejemplo decidiéramos usar un modelo de máxima similitud la probabilidad de registro de la siguiente llegada a la página sería algo así:

$$\sum_{j=1}^m \sum_{k=1}^{n^{(j)}(t)-1} \log (f_A^{(j)}(a_{k+1}^{(j)} - a_k^{(j)}, \mathbf{w}_k^{(j)}, \mathbf{x}_t^{(j)})) - \sum_{j=1}^m \log (\bar{F}_A^{(j)}(t - a_{n^{(j)}(t)}^{(j)}, \mathbf{w}_{n^{(j)}(t)}^{(j)}, \mathbf{x}_t^{(j)})).$$

Donde f_A es el la función de densidad de la siguiente llegada del consumidor j después de la llegada k , dada la información sobre el flujo de clics y la compra del consumidor $w^{(j)}k$ y las características extraídas $x^{(j)}t$ en el momento t , y $F^{(j)}_A$ es la función de supervivencia correspondiente.

Además, también podemos estimar la probabilidad de transición para las compras del consumidor:

$$p(\mathbf{w}, \mathbf{w}_k; \mathbf{x}_t) \equiv P\{\mathbf{W}_{k+1} = \mathbf{w} | \mathbf{W}_k = \mathbf{w}_k, \mathbf{x}_t\}$$

Por lo tanto para un cliente con un vector de cualidades \mathbf{x}_t , cuya última visita fue en τ y sus datos de clicks y compras \mathbf{w} , tendrá una función de densidad de destino para su próxima visita t tal que:

$$\frac{f_A(s + (t - \tau), \mathbf{w}, \mathbf{x}_t)}{F_A(t - \tau, \mathbf{w}, \mathbf{x}_t)}, \quad s \geq 0$$

Potencialmente mediante el análisis de todos estos vectores de información individualizada se podrían llegar a estimar parámetros como perdida de clientes o productos sustitutos en caso de falta de stock. Por ejemplo, si un cliente compra regularmente un producto que se encuentra sin existencias pasaría a comprar algún otro que mira o compra muy ocasionalmente. Con este modelo ese evento podría preverse antes de que ocurriera y así calcular las pérdidas que produce y las acciones a tomar para reducirlas. En otras palabras, la demanda personalizada derivada del análisis de datos nos puede llevar a una nueva manera de aprender y planificar.

4.3 Modelaje de la producción con previsiones individualizadas

Evidentemente, estas previsiones de demanda individualizadas pueden ser agregadas para hacer una previsión global. No es muy distinto a otros métodos de previsión más tradicionales.

Sin embargo, esto va algo en contra de la extendida creencia en la gestión de que las agregaciones en torno a factores individuales como tiempo producto o zona geográfica solo ayudan a mejorarlas previsiones si los elementos sumados no estaban previamente correlacionados. Esta creencia ha demostrado ser valida reduciendo las diferencias entre oferta y demanda en el largo plazo. Sin embargo, trabajando en el corto plazo, negocios minoristas pueden ajustes a sus pedidos, envíos, precios, merchandising y ofertas de un día para otro gracias a las previsiones individualizadas. Más allá incluso, este tipo de previsiones se han probado capaces de permitir a las firmas ofrecer de acuerdo a ellas precios y marketing personalizado a sus clientes incrementando las ventas y los beneficios (Shankar et al. 2016).

Por ejemplo, en una tienda física se pueden usar los patrones individualizados de compra y de días de visita vistos en el apartado anterior para atraer clientes a los días más flojo mandando cupones para los productos que quieren que solo sean validos en fechas específicas. Así se consiguen múltiples objetivos suavizar el tránsito en la tienda, regularizar la demanda de ciertos productos a lo largo de la semana y aumentar la eficiencia del espacio y de los empleados. Y eso es solo un ejemplo de las muchas acciones que se pueden tomar para maximizar los beneficios gracias a esta metodología.

4.4 Aprendizaje y planificación de preferencias

Aprender sobre los gustos y las preferencias de los consumidores en cuanto a las características y funcionalidades de un producto o servicio es una parte integral del estudio de la demanda. El estudio de las reacciones de los consumidores siempre ha sido un paso esencial para el diseño de buenos productos y servicios.

Con la expansión de medios como los motores de búsqueda, los blogs, las reviews y demás fuentes de feedback los investigadores han desarrollado múltiples técnicas para analizar la opinión y los sentimientos de los consumidores ante un producto (ver Pang y Lee, 2008). Además, la creciente expansión del Internet of Things (IoT) y con ella la enorme cantidad de sensores y medidores que se colocan tanto en los propios productos como en el ambiente en general aumentan aún más la información disponible y arrojan luz para entender cómo los clientes interactúan con los productos sobre el terreno. Qué prestaciones nunca se usan, bajo que tipos de uso se estropean antes, cómo interactúan unos consumidores con otros... Con toda esta información y la analítica de datos se puede obtener información útil y realizar predicciones certeras que ayuden a orientar los procesos de diseño y producción.

La necesidad de los consumidores de obtener productos únicos y personalizados ha sido documentada por muchos estudios como Tian et al. (2001). Consecuentemente los diseños personalizables se han convertido en una tendencia en múltiples áreas como los complementos, la medicina, el turismo o los coches. Especialmente los compradores online son propicios a demandar servicios personalizados (Amato-McCoy, 2017). El Big Data ayuda a las compañías a entender mejor las percepciones de sí mismos que tienen sus clientes y el rol que eso juega en sus decisiones de compra.

En definitiva, el IoT y el Big Data ayudan las empresas a conocer lo que los clientes quieren de ellas casi mejor que los propios clientes y así sacar un partido a sus operaciones inimaginable hace poco tiempo. Cabe matizar que aunque se haya analizado desde un punto de vista más bien de reetail, de cara al cliente final, todos estos procedimientos y metodologías funcionan igualmente bien (si no mejor por la mayor información disponible) en relaciones comerciales business-to-business.

5. Analítica de la cadena de suministro y gestión de inventarios

La cadena de suministro es el conjunto de pasos involucrados en mayor o menor medida en la adquisición, preparación y distribución de un elemento para su venta. Se encarga de la planificación y coordinación de las actividades a realizar de cara a encontrar, obtener y transformar los distintos elementos utilizados por el proceso productivo de la empresa. El objetivo principal en la gestión de la cadena de suministro es, como cualquier otra área de la empresa, maximizar su eficiencia y rentabilidad. La rentabilidad de la cadena de suministro es la diferencia entre el ingreso generado de los clientes y el coste total de todas las fases de la cadena. Las decisiones tomadas en torno a este proceso influyen muy directamente en los resultados de la empresa y por tanto tienen mucho impacto en el éxito o fracaso de las operaciones (Adin et al., 2013).

De acuerdo con Boltorff et al. (2012) 'moverse como uno solo' es el comportamiento natural de los peces y debería serlo también de las cadenas de suministro. Igual que un pez se puede morir si se separa del grupo, para una cadena de suministro global, un desajuste, no ir bien coordinados, puede causar problemas como un servicio pobre al cliente, inventario demasiado alto, costes inesperados, limitaciones sobre el crecimiento y las ganancias y pérdidas de cuota de mercado. La problemática está en lograr esa sincronización de las diferentes áreas sin alterar aquellas que de por sí solas ya funcionan eficientemente.

La gran competitividad existente en los mercados a día de hoy hace que hasta seleccionar el proveedor adecuado pueda ser algo determinante en los resultados de una compañía. De acuerdo con Rajesh & Malliga (2013), la globalización del comercio, el desarrollo de las tecnologías de la información y la comunicación y el sistema mundial que utiliza Internet ha ampliado el abanico de opciones del comprador. Por otra parte, el flujo en constante evolución de las preferencias de los clientes requiere de una cuidadosa y atenta selección de proveedores. La tendencia en la gestión en los últimos años va encaminada a la máxima reducción posible del número de proveedores seleccionándolos evaluando su rendimiento considerando el mayor número de variables posibles incluyendo precio, calidad, rendimiento, historia, puntualidad de envíos, compatibilidad, reciprocidad de acuerdos, ... entre otras cosas.

5.1 Modelo SCOR

El modelo de referencia de operaciones de la cadena de suministro, en adelante SCOR (Supply Chain Operations Reference), es un modelo diseñado estándar para cualquier tipo de industria como una herramienta de diagnóstico y mantenimiento en la cadena de suministro. Ayuda a las empresas a evaluar y

comparar más rápidamente la eficiencia de la cadena de suministro y de cada uno de sus miembros y operaciones relacionadas, tanto internamente como comparativamente con otras compañías de la competencia.

Consiste en un modelo jerárquico con al menos cuatro niveles (eso ya depende de cómo cada organización lo adapte a su caso específico):

- 1) Nivel 1: identifica los procesos importantes dentro de la cadena de suministro, estos suelen ser planificación, fuente, fabricación, entrega y devolución. En este nivel se ayuda a las empresas a establecer los objetivos de gestión de la cadena de suministro.
- 2) Nivel 2: explica las principales categorías de procedimientos que existen en cada parte de la cadena de suministro real y planificada por la empresa. Por ejemplo, la parte de la fuente tiene 'productos almacenados', 'fabricación bajo pedido' y 'productos a fabricar'
- 3) Nivel 3: incluye información para que la gerencia de la cadena de suministro planifique la fuente y establezca metas para estrategia de gestión de la cadena de suministro. Esto también consiste en definiciones, puntos de referencia y capacidades del sistema de software.
- 4) Nivel 4: se centra en la implementación de las medidas adecuadas para lograr ventajas competitivas gracias a la eficiencia de la gestión de suministros. (Wang et al. 2005)

El modelo SCOR sigue además una serie de procesos que se repiten cíclicamente entorno a los que se debe planificar la cadena de suministro, son los siguientes:

- 1) Planificación: Consiste en analizar la información y pronosticar las tendencias del mercado de bienes y servicios. Los departamentos de marketing y finanzas aplican el proceso de planificación mediante informes mensuales y anuales.
- 2) Adquisición: Se trata de un sistema de aprovisionamiento con un modelo completo de aprovisionamiento. Incluye agentes de búsqueda, negociación y evaluación para modificar la selección, negociación con y evaluación de proveedores.
- 3) Fabricación: Es la fabricación de mercancías no sólo en términos de tiempo sino también de cinta de producción y lote.
- 4) Entregas: Son los procesos por los que proporcionan los productos y servicios terminados a donde sea necesario para alcanzar la demanda planificada o real.
- 5) Retornos: Se trata de los procesos de devolución de la mercancía o recepción del producto. Trkman et al (2010)

En un entorno en el que se usa este modelo el aspecto de la cadena quedaría de la siguiente manera:



Ilustración 10 Fuente: Supply Chain Council : SCOR 9.0 Overview Booklet, 2008

5.2 Proceso Analítico Jerárquico (AHP)

La importancia de la toma de decisiones en la empresa es total. El Proceso Analítico Jerárquico, en adelante AHP (Analytical Hierarchy Process) es una potente y flexible herramienta de toma de decisiones para ayudar a directivos y gerentes a elegir la mejor opción cuando aspectos tanto cualitativos como cuantitativos han de ser tomados en consideración. Consiste en 8 pasos principales:

- 1) Definir el problema que se pretende solucionar.
- 2) Identificar los factores y criterios que tienen algún tipo de influencia sobre la existencia y el comportamiento del problema
- 3) Crear una estructura con estos criterios, sus respectivos subcriterios y de las alternativas con su respectivo orden de prioridad.
- 4) Ordenar según su prioridad los criterios primarios en función de su impacto global sobre el objetivo.
- 5) Ordenar dentro de cada criterio sus subcriterios de acuerdo a su importancia para solucionarlos.
- 6) Hacer un test de consistencia de la estructura
- 7) Seleccionar las mejores alternativas. Se debería seleccionar la alternativa que al final del estudio tuviera una mayor prioridad.
- 8) Hacer un test de sensibilidad para probar la alternativa elegida.

Uno de los métodos más habituales y extendidos a la hora de evaluar la prioridad de estos criterios es la escala del 1 al 9 de Saaty creada en 1980 por el distinguido profesor de la Universidad de Pittsburg Thomas L. Saaty y que establece una serie de consideraciones para evaluar la importancia de una actividad frente a otra dentro de un proyecto u objetivo:

Intensity of Importance	Definition	Explanation
1	Equal Importance	Two activities contribute equally to the objective
2	Weak	Experience and judgement slightly favor one activity over another
3	Moderate Importance	
4	Modarate Plus	Experience and judgement strongly favor one activity over another
5	Strong Importance	
6	Strong Plus	An activity is favored very strongly over another, its dominance demonstrated in practice
7	Very Strong Importance	
8	Very very strong	An evidence favoring one activity over another is of the highest possible order of affirmation
9	Extreme Importance	
Reciprocal of above	If activity I has one of the above nonzero numbers assigned to it when compared with activity j, then j has the reciprocal value when compared with I.	A reasonable assumption
Rationals	Ratios arising from the scale	If consistency were to be forced by obtaining n numerical values to spun the matrix

Ilustración 11. Fuente: Adyn et al. (2013)

La estructura de decisión por tanto tendría un aspecto general como el siguiente, teniendo en cuenta que los criterios y subcriterios variarán siempre en función de la compañía y de los objetivos para los que se realiza el estudio.

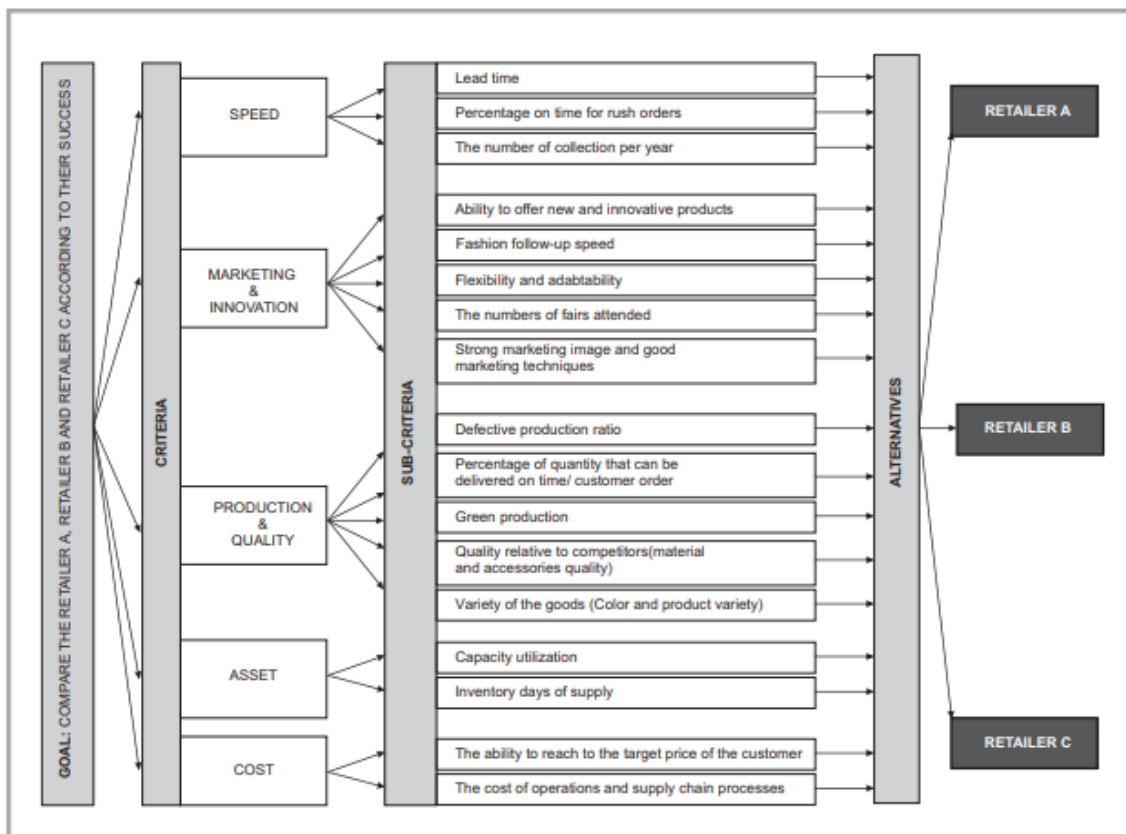


Ilustración 12Fuente: Adyn et al. (2013)

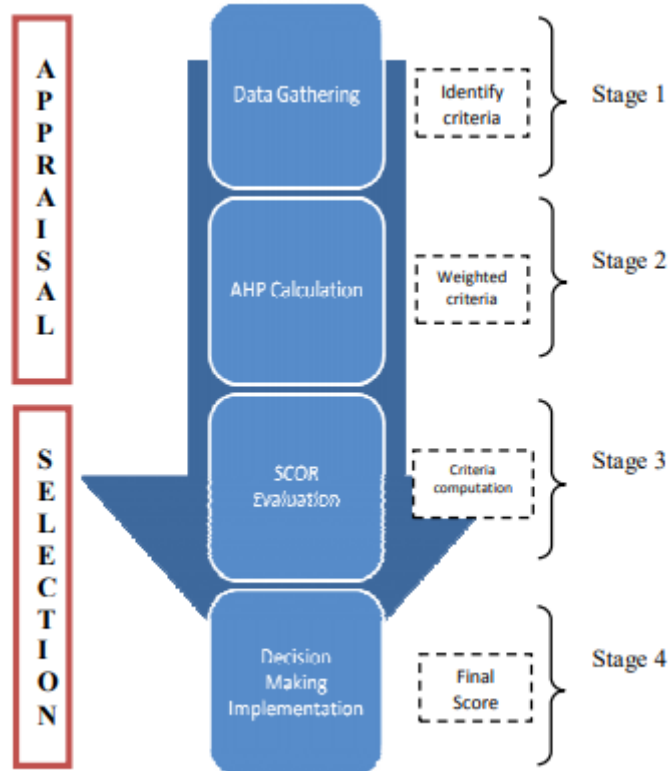
5.3 Modelo Integrado AHP-SCOR (ASIM)

En el año 2015, R. Nazim, S. Yahya y M.R. Malim realizaron un estudio dando un nuevo enfoque a la selección de proveedores integrando el modelo SCOR y la toma de decisiones AHP, y desarrollaron lo que bautizaron como ASIM (AHP-SCOR Integrated Model) y que junta lo mejor de cada uno para tratar de ofrecer una manera rápida, sencilla y eficaz de planear la selección de proveedores.

En este estudio se planteaba que el modelo SCOR carecía de capacidad ir mejorando con el uso de herramientas de modelización de negocio, para apoyar mas eficientemente a la toma de decisiones. Para mejorar este aspecto se fusiona el modelo con conceptos parciales de el proceso AHP para crear el modelo ASIM. En el desarrollo de este método el SCOR se utilizó para ordenar los criterios y alternativas mientras que el AHP se so para determinar la coherencia y la importancia de los umbrales adjudicados a cada criterio.

Como podemos ver en la siguiente figura el modelo consistiría de 4 fases; identificación, valoración y computación de los criterios y decisión final:

Como podemos ver, estas cuatro fases están divididas en dos partes, una dedicada a la obtención y la evaluación de los criterios y otra dedicada a su



utilización para llegar a la toma de una decisión.

Ilustración 13 Fuente: Nazim et al. 2015

A continuación, vamos a exponer de una manera muy simplificada con un pequeño caso imaginario el funcionamiento de este proceso. Como pasaba con el ejemplo de la predicción por mínimos cuadrados, hay que tener en cuenta que este ejemplo no puede ser considerado un uso de Big Data ya que no cumple las condiciones de las 5 V's y prácticamente se podría llegar a hacer sin necesidad de computar ningún dato. Pero es bueno para entender el funcionamiento del modelo, funcionamiento que sería extrapolable a casos infinitamente más amplios, con más criterios, más subcriterios, más opciones de proveedores, etc.

Ejemplo:

Supongamos que una empresa tiene 3 posibles proveedores de entre los que elegir y que el siguiente es el ranking de los 10 criterios de entre los que considera la empresa, en los que cada uno puntúa mejor de acuerdo con los analistas de la empresa, los que se consideran más relevantes son: calidad, precio, historial de rendimiento, garantías y flexibilidad.

Ranking	SUPPLIER 1	SUPPLIER 2	SUPPLIER 3
1	Quality	Quality	Price
2	Price	Warranties	Performance history
3	Quality Standards	Price	Quality standards
4	Technical capability	Research	Warranties
5	Warranties	Professionalism	Experience
6	Process improvement	Experience	Quality
7	Expertise	Quality standards	Impression
8	Attitude	Knowledge	Flexibility
9	Experience	Performance history	Desire
10	Performance history	Desire	Knowledge

Se utiliza la escala de Saaty (Ilustración 10) se adjudica a cada uno de los proveedores una puntuación para cada uno de los procesos relevantes del modelo SCOR (Ilustración 9). Esta puntuación es el índice de consistencia (IC). Más adelante este índice se divide por un índice de evaluación aleatorio (IA) para obtener el ratio de Coherencia (RC) que es la cifra que se compara:

	PLAN	SOURCE	MAKE	DELIVER	RETURN	TOTAL SCORE
SUPPLIER 1	0.274	0.044	0.07	0.035	0.06	0.483
SUPPLIER 2	0.055	0.131	0.07	0.012	0.02	0.288
SUPPLIER 3	0.165	0.044	0.07	0.035	0.02	0.334

Realizando una media la puntuación final de cada uno en el modelo ASIM será:

	SUPPLIER 1	SUPPLIER 2	SUPPLIER 3
Final Score	0.483	0.288	0.334

Y por lo tanto el proveedor más óptimo será el proveedor 1.

5.4 Gestión de inventarios

Una gestión eficiente de inventarios es una capacidad clave para una empresa para conseguir los mejores resultados posibles. Los inventarios son fuente de muchos gastos de diversa naturaleza. Almacenar demasiado stock cuesta dinero, tanto en espacio como en deterioro de unidades. No almacenar el suficiente cuesta dinero en forma de retrasos y mal servicio. Llevar las mercancías de un punto a otro también cuesta dinero y llama a elegir con mucho cuidado donde situar un almacén o una tienda.

Volviendo al estudio de Deloitte y MHI (2016) el 48% de los encuestados consideraba que su empresa tenía el potencial para generarse ventajas competitivas a si mismas mejorando la gestión de mercancías y del transporte de las mismas. Es un área con mucho por mejorar y se calcula que en los próximos 10 años el 90% empresas habrán optado por alguna técnica de Big Data para hacerlo. La siguiente figura muestra las herramientas de optimización de inventarios basadas en Big Data que las empresas de los encuestados estaban usando en el momento del estudio o planeaban implantar en los siguientes dos años:




Ilustración 14. Fuente: Deloitte & HMI, 2016

Estas herramientas suponen un soporte a la toma de decisiones haciendo más fácil que cada unidad este en el sitio correcto en el momento justo y por el mínimo coste.

Actualmente las tendencias de lo que las empresas buscan a la hora de usar la analítica para mejorar su gestión de inventarios son:

- Integración: se busca conseguir soluciones que permitan gestionar todo el proceso de gestión y transporte de inventarios desde una sola plataforma.
- Redes escalonadas: las empresas buscan establecer redes de varios niveles a través de múltiples tipos de inventarios (productos terminados, trabajo en curso, ...). Es lo que se conoce como clustering de inventarios y existen empresas como SmartOps (subsidiaria de SAP) y Logility (subsidiaria de Opiant) que ofrecen servicios dedicados a ayudar a las empresas a hacerlo eficientemente.
- Visibilidad: las empresas buscan maneras de acceder a la información de stock y almacenes desde cualquier punto, incluidas las tiendas físicas, para poder tomar decisiones eficientes basadas en información en tiempo real.
- Métricas: se busca que las plataformas a utilizar ofrezcan visuales de la situación de KPIs (key performances indicators) y que ofrezcan rápidamente información sobre como cambiaría de tomar una decisión u otra.

6. Cadena de Producción: Industria 4.0

La cadena de producción es el conjunto de pasos a los que unos inputs o materias primas son sometidos desde que son adquiridos y entran en la empresa hasta que salen de la misma convertidos en productos terminados. Es esencial para la rentabilidad de la compañía mantener un proceso de producción eficiente y flexible en el que no se produzcan paros inesperados y donde la compañía pueda ajustar su ritmo a las necesidades de producción determinadas en cada momento por la previsión de demanda. Como es evidente, durante este proceso se genera muchísima información útil que si es recogida y procesada adecuadamente puede ser utilizada por la empresa para maximizar su eficiencia.

Las nuevas tecnologías, en especial el IoT están llevando a la industria manufacturera hacia un nuevo entorno de fábricas inteligentes. Este progreso, que algunos están llamando la nueva revolución industrial ha sido bautizado como Industria 4.0. La idea esencial es la integración de sistemas de IoT en la maquinaria y el entorno de la fabricación que están conectados a Internet. Este entorno inteligente de objetos inteligentes que está directamente integrado con los sistemas de información de la empresa dentro de los que se convierten en elementos activos del proceso de negocio. Comunican a las bases de datos en tiempo real toda la información que recogen acerca de infinidad de factores como consumo de energía (especialmente importante dada la tendencia hacia la necesidad de sostenibilidad hoy en día), temperatura, estado de la maquinaria, tiempos de producción y muchos otros más.

Las principales características que definen como se desmarcan tanto en rentabilidad como en sostenibilidad las fábricas inteligentes son:

➤ Personalización masiva

La superior eficiencia y versatilidad de estas nuevas maquinarias de producción hace posible incluir cambios específicos en los diseños de un producto individualmente. ¿Cómo es posible esto? Mediante la reducción de los lotes de producción potencialmente hasta 1 solo para hacer productos personalizados más específicos sin que eso afecte al ritmo de producción normal que se necesite mantener.

➤ Flexibilidad

Los procesos de producción inteligentes y autorregulados permiten tener ciertas horquillas en las que mover sus criterios como tiempo, calidad

o coste para adaptarse lo mejor posible a las necesidades de producción del momento.

➤ Visibilidad y optimización de la toma de decisiones

Tomar las decisiones correctas en el momento adecuado es la clave de mantenerse competitivo en el mercado. Como se viene tratando a lo largo de este trabajo cuanto más información se tiene tanto sobre uno mismo como sobre el mercado y la competencia mejor puede llegar a ser la calidad de las decisiones al tener más factores en cuenta. Con tecnologías IoT el decisor tiene una transparencia básicamente total sobre su proceso de producción en tiempo real mejorando las decisiones y reduciendo el tiempo desde que ocurre un problema hasta que se sabe como solucionarlo. O hasta evitando el problema antes de que ocurra. Por ejemplo, tener información en directo sobre el consumo de energía y la producción de residuos permite que se puedan tener en cuenta los costes que eso supone al elegir alternativas.

➤ Nuevos métodos de planificación

La planificación de producción dependiente de la información de IoT permite establecer planes flexibles que pueden ser editados en tiempo real a diferentes niveles y caso a caso. Además, permite planificar, dentro de los objetivos de producción marcados por la demanda en función de diferentes factores como minimización del gasto energético o del coste unitario.

➤ Creación de valor desde el Big Data recogido

Los datos recogidos por los elementos IoT de una fábrica inteligente cumplen perfectamente las 5 V's para ser considerados Big Data. Nuevas mejoras del proceso pueden ser encontradas a posteriori de analizar esas grandes series temporales de datos. Estas mejoras pueden ser a nivel mantenimiento, eficiencia, servicio,...

➤ Monitorización remota

La conexión directa de estos dispositivos con el sistema de datos de la empresa permite minimizar la necesidad de acciones de gestión del proceso sobre el terreno. Pudiéndose controlar toda la información de una fábrica en esencia desde cualquier sitio.

➤ Automatización y cambio del papel de los trabajadores

Como decíamos antes la intervención humana en el proceso de manufactura se minimiza en estas fábricas automatizadas. Esto no solo reduce errores y malgastos de tiempo y energía sino que permite emplear el capital humano de la empresa en otras actividades en las que será más valioso.

➤ Cadena de suministro conectada

La IoT ayudará a los fabricantes a obtener una mejor comprensión de la información de la cadena de suministro que puede ser entregados en tiempo real. Conectando las máquinas y a los proveedores, "todas las partes pueden entender interdependencias, el flujo de materiales, y tiempos de ciclo de fabricación"

➤ Gestión eficiente de la energía

La mejora de la eficiencia energética requiere conocer comportamiento del consumo de energía en la línea de producción y nivel de máquina. Los medidores inteligentes pueden proporcionar en tiempo real de datos, y tomar decisiones basadas en sus capacidades y en su capacidad de colaboración con servicios externos. De hecho, hay varias prácticas sostenibles que pueden ser adoptadas en base a la adopción de la tecnología de la IO para mejorar la eficiencia energética a nivel de producción (por ejemplo, evitar las horas punta, integrar la energía datos en el programa de producción, etc.). Además, permite una automatización de los controles ambientales en la fábrica, tales como HVAC.

Y merece una especial mención el mantenimiento predictivo. Tanto por la revolución que supone dentro del Big Data como por ser una de las técnicas que más extendidas y gracias a las cuáles más empresas han mejorado su eficiencia de fabricación.

❖ Mantenimiento Predictivo

Hasta la aparición del IoT se podría decir que había dos mentalidades a la hora de gestionar el mantenimiento de una maquinaria, fuera dl tipo que fuera.

La primera sería la conocida en inglés como la gestión run-to-failure, es decir "si no está roto, no lo arregles". Consiste básicamente en eso, en no realizar tareas de arreglos y mantenimiento en los equipos a no ser que sea necesario porque haya algún fallo o problema que impida la producción. Este

tipo de gestión resulta en mayores gastos, más retrasos y menos eficiencia y obliga a las empresas que lo utilicen a mantenerse siempre muy alerta para reaccionar en caso de rotura o fallo con medidas poco eficientes como teniendo almacén empleado en repuestos para las máquinas o confiando demasiado en la rapidez de quién tenga que repararlo. En la práctica a día de hoy casi se podría decir que ninguna empresa utiliza este tipo de gestión, en una mayor o menor medida todos los fabricantes realizan tareas como lubricar, limpiar o hacer ajustes en la maquinaria que al fin y al cabo no son otra cosa que medidas preventivas para evitar esos fallos y roturas.

La segunda sería el mantenimiento preventivo. Esta gestión se basa mucho en el tiempo pasado, es decir, en la propia experiencia de la compañía con su maquinaria y sus conocimientos de la misma. La siguiente imagen muestra la distribución típica de los fallos de una máquina de producción a lo largo de su vida útil




Ilustración 15. Fuente: Mobley (2016)

Las empresas que ejecutan mantenimientos preventivos tienen en cuenta estos factores para realizar sus tareas de mantenimiento de acuerdo. Se planean revisiones y reparaciones en el más bien largo plazo de acuerdo a cómo estiman que va a ir evolucionando el rendimiento de la máquina. Esto resulta en que no se tiene demasiado en cuenta la actividad real del día a día de la máquina y por tanto muchas veces resulta en que se realizan comprobaciones que solo resultan en que todo está bien, se ejecutan reparaciones antes de lo necesario, o no se ejecutan a tiempo y se tienen roturas que resultan en la necesidad de parar el proceso productivo.

El mantenimiento predictivo sin embargo es todo otro mundo y bien ejecutado es sin duda la mejor manera para las empresas de gestionar sus tareas de mantenimiento. Según la maquinaria y la industria puede adquirir muchas formas y variaciones. Pero si fuéramos a dar una definición global sería la “monitorización continua del equipamiento para detectar y diagnosticar defectos [...] y cuando un defecto es detectado planear y ejecutar labores de mantenimiento en consecuencia según van siendo necesarias” (Gidhar, 2004). Es decir, se utilizan dispositivos de IoT y maquinaria inteligente para medir de manera constante factores como la vibración, los residuos producidos, el ritmo, el consumo eléctrico, temperatura, etc. Y de esas mediciones se crean sets de datos que son analizados en tiempo real para saber cuando va a ocurrir una avería y actuar en consecuencia para evitarla a tiempo y no perder dinero con parones de producción no planeados. Y no suena a tanto definido al lado de otras mentalidades de gestión del mantenimiento, pero es que a parte de ser la única de las tres que al implicar análisis de grandes cantidades de datos se puede considerar una técnica de BDPA, bien ejecutada sus resultados van mucho más allá de simplemente gastar menos dinero en mantenimiento. Una gestión efectiva de mantenimiento productivo resulta en mejoras en calidad del producto, tiempos de entrega, costes, eficiencia y productividad de toda la planta de producción. Los programas de mantenimiento de predictivo proveen a los tomadores de decisiones con información visualizable en tiempo real, cuando detecta variaciones indicativas de posibles fallos futuros las evalúa en función de su severidad y recomienda acciones preventivas a tomar, eliminando el juicio humano, a veces subjetivo, en la toma de esta decisión y siguiéndolo por una evaluación totalmente exacta.

Todos estos pasos adelante están posibilitados por la recogida de datos de elementos IoT principalmente en las fábricas, pero también en otros muchos puntos del proceso comercial.

7. Dificultades y problemáticas

Está claro que siempre existe potencial de mejora, y que las tecnologías de Big Data ayudan a muchas empresas a encontrar y llegar a superar ese gap de eficiencia. Pero no es una cuestión tan simple como recopilar datos, analizarlos, mejorar y ya está. Hay ciertas limitaciones tanto legislativas como de forma respecto a los datos a los que se puede acceder y lo que se puede llegar a hacer con ellos. Además, muchas veces, casi siempre debido a falta de claridad en los objetivos, se llegan a dar casos de empresas que invierten en Big Data para luego nunca llegar a ver esa inversión convertida en la mejora de resultados que buscaban de ella pudiendo llegar a perder dinero en el proceso.

7.1 Limitaciones legales

Legislativamente, hasta hace muy poco las leyes que concernían la privacidad online de los ciudadanos eran poco definidas y orientadas más que otra cosa a proteger frente a errores humanos y ataques directamente orientados a la búsqueda de robar información privilegiada. La expansión de el uso empresarial del Análisis de Datos, que llega a abarcar técnicas tan “invasivas” como cámaras de reconocimiento facial ocultas en las tiendas, ha cambiado por completo el paradigma de la protección de datos. Requiriendo por parte de los gobiernos actualizar las leyes que conciernen estos temas para estar al día con la nueva realidad.

El 25 de mayo de 2016 entro en vigor para todos los países de la Unión Europea el nuevo Reglamento General de Protección de Datos (RGPD) que “garantiza al ciudadano la capacidad de decidir sobre los tratamientos de sus datos a través de una serie de opciones vinculadas a cada uno de los usos que las empresas hacen de ellos o mediante el ejercicio de los derechos reconocidos en la propia normativa” (Next International Business School, 2016). En España es de aplicación directa desde el 25 de mayo de mayo. Esto como es lógico, limita las capacidades de uso del Big Data por parte de las empresas, que en muchos casos tuvieron que cambiar de políticas de Big Data para evitar pagar multas de hasta 20 millones de euros según la gravedad de las infracciones. Desde entonces muchas empresas han designado a una figura encargada de asegurarse de que el uso que se haga de los datos de los clientes sea lícito y beneficiosos para la empresa al mismo tiempo.

Las principales novedades a tener en cuenta de este reglamento respecto al anterior (que estaba vigente desde el año 99) son (CICE 2017):

- Reducción de la edad de consentimiento de los 14 a los 13 años, de acuerdo con lo que indica el Reglamento Europeo
- Exclusión del consentimiento tácito por el uso de datos personales. Ahora tiene que ser expreso y afirmativo (este consentimiento es el que damos cada vez que aceptamos la cookies al entrar en una página web)
- Inclusión del tratamiento de los datos personales de fallecidos por parte de sus herederos.
- Regulación de los sistemas de información crediticia, videovigilancia, exclusión publicitaria, y denuncias internas.
- Se concede a los usuarios los derechos de rectificación, supresión, limitación del uso, portabilidad y oposición al uso de todos sus datos personales.

7.2 Limitaciones operacionales

Incluso una vez superadas las limitaciones legales sigue siendo tremendamente valioso hacer un uso adecuado y orientado a objetivos de los datos de los clientes y el entorno. Eso sí, hay ciertos factores a tener en cuenta a la hora de aplicar estas metodologías si no se quiere acabar solamente perdiendo el dinero.

Según un estudio de la consultora Accenture (2014) 8 de cada 10 directivos considera esencial utilizar la Analítica de datos en su compañía, pero solo 3 de cada 10 sabía decir en qué aspectos o con qué objetivos opinaba necesario hacerlo. Hay un claro gap entre intenciones y conocimientos sobre estas tecnologías y constantemente se dan casos de empresas que pierden dinero por culpa de las malas ejecuciones resultantes de ese gap.

Por eso, el de Accenture y otros muchos estudios hacen recomendaciones para lograr el éxito en estos proyectos. Las claves más importantes son dos las siguientes:

- I. Tener claro el objetivo del proyecto. El mayor error es empezar a gastar recursos económicos y de personal en proyectos de Big Data con metas abstractas como mejorar en eficiencia o reducir costes. Se necesita tener claro que se busca y hacerlo a un nivel más específico como “reducir el tiempo de espera de los clientes en las tiendas” o “aumentar el porcentaje de clicks en los anuncios online”.
- II. Hacer uso de personal especializado. El 54% de las empresas en el estudio de Accenture habían recurrido a alguna consultora a la hora de implantar sus proyectos, el 45% había subcontratado a alguna empresa para llevarlos a cabo y el 34% había utilizado recursos de algún proveedor de IT. Además, en el largo plazo, si se pretende orientar la actividad de la empresa a una mentalidad del dato lo mejor es contratar a un científico de datos, la “profesión más sexy del s. XXI según el New York Times.

8. Conclusiones

De todo este estudio se extraen las siguientes conclusiones:

En primer lugar, se quiere destacar como el Big Data como su propia práctica empresarial y rama de estudio ha pasado de prácticamente la inexistencia hace poco menos de dos décadas a prácticamente la omnipresencia tanto a nivel empresarial como a nivel académico a día de hoy. Casi todas las empresas grandes lo utilizan ya en alguna de sus muchas formas y se escriben cientos de estudios al respecto que no hacen más que mover adelante y seguir agrandando y perfeccionando su alcance y posibilidades a nivel global. Se podría decir que actualmente es la tendencia más fuerte en el mundo empresarial en lo que a mentalidades y prácticas se refiere. Visto además como su crecimiento tanto en capacidades como en popularidad es totalmente exponencial y directamente ligado a unas posibilidades de computación, que no hacen más que superar sus propios límites constantemente, es seguro decir que de cara al futuro va a ser imposible para ninguna empresa elaborar una estrategia de éxito sin tener una mentalidad orientada al dato.

En segundo lugar, hay que puntualizar que las áreas de estudio de este trabajo de fin de grado, previsión de demanda, gestión de cadena de suministros e inventarios y cadena de producción son algunas de las que más han avanzado en esta dirección por ser algunas de las que más posibilidades tenían para hacerlo por su inherente generación continua de datos cuantificables. Pero aunque este trabajo se centre en estas áreas de la actividad empresarial la amplitud del Big Data es mucho mayor y virtualmente cualquier área, desde el marketing a los recursos humanos, tiene posibilidades de crecimiento y mejora haciendo el uso adecuado de estas prácticas.

Por último, también hay que sacar lo negativo y llamar la atención sobre que aunque lo parezca, en el Big Data no es todo de color de rosa. La mera existencia de bases de datos conteniendo información sensible de millones de personas al fin y al cabo implica un riesgo ante la posibilidad de que esos datos no sean protegidos como es debido o se realicen malas prácticas con ellos. Es esencial por lo tanto que los gobiernos tengan puesto en este tema la atención que se merece vista su relevancia para asegurarse de que las empresas hacen con todo este poder que los datos les dan lo que están pensadas para hacer, ayudar a nuestras sociedades a avanzar a un futuro mejor.

Indice de imágenes:

- 1) Porcentajes de penetración de los smartphones en el mundo
Fuente: Informe Ditrandia: Mobile en España y en el mundo, 2017
- 2) Definición de Big Data basada en una encuesta realizada a 154 ejecutivos a nivel global
Fuente: Malvicino et al., 2015
- 3) Tamaño global de la “datosfera”
Fuente: Seagate with data from IDC Global DataSphere, Nov 2018
- 4) Ciclo de pasos de la Analítica de datos
Fuente: elaboración propia
- 5) Respuestas a : “¿Cuándo cree más probable que su empresa comience a utilizar las siguientes metodologías?”
Fuente: Deloitte & HMI, 2016
- 6) Evolución de la población mundial.
Fuente: Naciones Unidas
- 7) Evolución de la capacidad global de procesamiento logarítmico
Fuente: Deloitte & HMI, 2016
- 8) Evolución anual de la venta de refrescos en España
Fuente: Investigación y análisis de marketing. Pablo Tenorio, 2015
- 9) Crecimiento anual del PIB en España y en la Unión Europea
Fuente: IESE Business School, 2014
- 10) Entorno del modelo SCOR
Fuente: Supply Chain Council : SCOR 9.0 Overview Booklet, 2008
- 11) Escala de decisión de Saaty
Fuente: Adyn et al. (2013)
- 12) Arbol de decisión en un proceso AHP
Fuente: Adyn et al. (2013)
- 13) Pasos del modelo integrado SCOR-AHP
Fuente: Nazim et al. 2015
- 14) Herramientas de optimización de inventarios utilizadas actualmente

Fuente: Deloitte &HMI, 2016

15) Distribución de fallos en el ciclo de vida de la maquinaria industrial.

Fuente: Mobley, 2016

Bibliografía:

Aydin, S.D., Eryuruk, S.H., Kalaoglu, F. (2013). "Evaluation of the Performance Attributes of Retailers Using the Scor Model and AHP: A Case Study in the Turkish Clothing Industry"

Bernal Niñi, O.D. (2017). "Introducción a Big Data". Universidad Libre de Colombia.

Bolstorff, P., & Rosenbaum, R. G. (2012). "Supply chain excellence: a handbook for dramatic improvement using the SCOR model. Amacom Div American Mgmt Assn"

Chen, H., Chiang, R.H., Storey, V.C. (2012). "Business Intelligence and Analytics: From Big Data to Big Impact." MIS Q.

Feng, Qi; Shanthikumar, J. George. Production and Operations Management, September 2018, Vol. 27 Issue: Number 9

Feng, Q, Shanthikumar, G. (2017). "How Research in Production and Operations Management May Evolve in the Era of Big Data"

Gidhar, P., 2004. "Practical Machinery Vibration Analysis and Predictive Maintenance"

Guyon, I., S. Gunn, M. Nikraves, L. A. Zadeh. (2006). "Feature Extraction: Foundations and Applications. Springer-Verlag, Berlin Heidelberg"

Harrison S.Martin Aldana, Julian D.Calderon Rivas & Jose M.Vargas Hidalgo (2018). "Big data, el futuro de las predicciones certeras"

IMB (2017). "Making Sense of Big Data: A Day in the Life of an Enterprise Architect"

Informe Ditrendia: Mobile en España y en el mundo 2017, Ditrendia

Malvicino, F., Yoguel, G. (2015). "Big Data. Avances recientes a nivel internacional y perspectivas para el desarrollo local"

Manyika, J., Chui, M., Brown, B., Bughin, J., Dobbs, R., Roxburgh, C. and Byers, A. H. (2011). "Big data: the next frontier for innovation, competition, and productivity." McKinsey Global Institute.

Min, C., Shiwen, M. and Yunhao, L. (2014). "Big data: A survey." Mobile Network Applications. Vol., 19

Mobley, R.K., 1990. "An Introduction to Predictive Maintenance"

Nazim, R., Alam, S., Yahya, S., & Malim, M. R. (2015). "A New Approach to Supplier Selection Problem: An Introduction of AHP-SCOR Integrated Model. International Journal on Recent and Innovation Trends In Computing and Communication"

Pang, B., L. Lee. (2008). "Opinion mining and sentiment analysis. Foundations and Trends in Information Retrieval 2"

Pérez, M. (2015). "Big Data – Técnicas, herramientas y aplicaciones", Alfaomega grupo editor

Richard, L., V., Matthew, E. and Carl, W., O. (2011). "Big data: What it is and why you should care." IDC

Rostami-Tabar, B., Babai, M. Z., Syntetos, A., & Ducq, Y. (2013). Demand forecasting by temporal aggregation. *Naval Research Logistics (NRL)*, 60(6), 479–498. doi:10.1002/nav.21546

Shankar, V., M. Kleijnen, S. Ramanathan, R. Rizley, S. Hollande, S. Morrissey. (2016). "Mobile shopper marketing: Key issues, current insights, and future research avenues. *Journal of Interactive Marketing*"

Souza, G. C. (2014). Supply chain analytics. *Business Horizons*, 57(5), 595-605

Truong Nguyena, Li ZHOU, Virginia Spiegler, Petros Ieromonachoua, Yong Lina (2017). "Big data analytics in supply chain management: A state-of-the-art literature review"

Wang, W., Micheal, S., & Patrick, Y. (2005). "A process oriented methodology for the supply chain analysis of implementing global logistics information systems." Proceedings of the 2nd International conference on Innovations in Informational Technology

"¿Cómo afecta el nuevo Reglamento General de Protección de Datos al Big Data?", Next International Business School, 2016, <https://www.nextibs.com/afecta-nuevo-reglamento-general-de-proteccion-de-datos-al-big-data/>

"Big dará y la nueva Ley de Protección de Datos", CICE, 2017, <https://www.cice.es/noticia/big-data-y-la-nueva-ley-de-proteccion-de-datos/>

"La transformación digital de la industria española: Informe Preliminar", Ministerio de Industria, Energía y Turismo, 2017, <http://www6.mityc.es/IndustriaConectada40/informe-industria-conectada40.pdf>