

Machine Learning, una pieza clave en la transformación de los modelos de negocio



Diseño y Maquetación
Dpto. Marketing y Comunicación
Management Solutions - España

Fotografías
Archivo fotográfico de Management Solutions
iStock

© **Management Solutions 2018**

Todos los derechos reservados. Queda prohibida la reproducción, distribución, comunicación pública, transformación, total o parcial, gratuita u onerosa, por cualquier medio o procedimiento, sin la autorización previa y por escrito de Management Solutions.

La información contenida en esta publicación es únicamente a título informativo. Management Solutions no se hace responsable del uso que de esta información puedan hacer terceras personas. Nadie puede hacer uso de este material salvo autorización expresa por parte de Management Solutions.

Índice



Introducción

4



Resumen ejecutivo

8



La revolución digital y la transformación
de los modelos de negocio

12



Concepto y tendencias
en aprendizaje automático

18



Ejercicio cuantitativo

30



Bibliografía

38



Glosario

40

Introducción

I believe that at the end of the century the use of words and general educated opinion will have altered so much that one will be able to speak of machines thinking without expecting to be contradicted

Alan Turing¹



La revolución digital está produciendo profundos cambios en los hábitos de consumo de los clientes; entre otros motivos, por un mayor acceso a datos y un creciente desarrollo de nuevas tecnologías. Todo ello nos invita a revisar en profundidad los actuales modelos de negocio.

Una palanca fundamental para la transformación de los modelos de negocio es la ciencia de datos (o *Data Science*), que se basa en el uso combinado de técnicas de aprendizaje automático, inteligencia artificial, matemáticas, estadística, bases de datos y optimización², concepto que ya fue ampliamente tratado en una publicación anterior de Management Solutions³.

Existen diversos factores, con origen fundamentalmente en la tecnología, que impulsan el uso de estas técnicas de *Data Science* en un conjunto amplio de sectores. Estos factores pueden agruparse en cuatro ejes: (i) el incremento sin precedentes del volumen y tipología de datos disponibles, (ii) la conectividad y el acceso al dato, (iii) la mejora de los algoritmos utilizados y (iv) el aumento de la capacidad computacional de los sistemas.

Con relación al volumen de datos, existen diversos estudios que recogen distintas métricas que permiten tomar conciencia de la magnitud de tal crecimiento. Por citar algunos de los más relevantes:

- ▶ Según recientes informes, el 90% de los datos creados en toda la historia de la humanidad se produjeron durante el último año y se estima todavía un 40% de crecimiento anual para la próxima década⁴. En la actualidad, debido al avance de las comunicaciones conocidas como *Machine to Machine* (M2M), y al desarrollo del denominado Internet de las Cosas (IoT), el volumen de datos disponibles es aún mayor.
- ▶ Estudios publicados por grandes empresas de telecomunicaciones⁵, señalan que el número de dispositivos conectados a internet será más de 3 veces la población mundial en 2021 y el número de conexiones IoT alcanzará los 13.700 millones ese mismo año, frente a los 5.800 millones registrados en 2016.
- ▶ Como consecuencia de ello, para 2020 el total de datos existentes llegará a los 44 billones de gigabytes⁶.

- ▶ De estos, un gran conjunto de datos se generan en el entorno digital directamente, como son las búsquedas en Google (40.000 búsquedas por segundo), los mensajes en Facebook (31 millones de mensajes por minuto) o el incremento de datos en vídeos y fotos (300 horas de vídeos subidos a YouTube cada hora).
- ▶ Se estima que en 2020 el 100% de los dispositivos móviles incluirán tecnología biométrica⁷. Asimismo, se estima que para ese año, al menos un tercio de los datos pasará a través de la nube⁸.

En segundo lugar, las mejoras en la conectividad suponen un salto cualitativo que permite el desarrollo de nuevos servicios y modelos de negocio ligados a la generación de datos en tiempo real, así como su análisis, para adaptar el servicio o el precio en función del uso: la generación y recolección de datos se realiza de forma automática a través de la sensorización y la digitalización de los terminales en el punto de venta, lo que crea un flujo de información continuo. Una gran parte de esta conectividad se realiza entre máquinas: una vez que una acción se realiza, los datos generados por los distintos elementos digitales involucrados se conectan con servidores con el objetivo de almacenar y analizar la información. Este tipo de conexiones M2M, se ha incrementado hasta alcanzar 1.100 millones de conexiones en 2017⁹.

En tercer lugar, la mejora de los algoritmos ha permitido tanto optimizar el tratamiento de grandes volúmenes de datos (a través de técnicas de escalado, *resampling*, etc.) como obtener métodos más eficientes y robustos y tratar *missings*, variables no numéricas y atípicos. A pesar de que la mayor parte de los algoritmos fueron desarrollados antes del año 2000, es ahora cuando las empresas están invirtiendo mayores esfuerzos en su implementación, obteniendo mejores resultados que los alcanzados por los humanos. Por ejemplo:

¹Turing, A.M. (1950). Matemático considerado padre de la ciencia de la computación. Descifró la máquina Enigma durante la 2ª Guerra Mundial. Fue precursor de la informática moderna y la inteligencia artificial.

²Dahr, V. (2013). Profesor de Stern School of Business y Director en Center for Digital Economy Research, New York.

³Management Solutions (2015).

⁴Ministerio de Industria, Energía y Turismo. Gobierno de España (2018).

⁵Cisco (2017).

⁶Forbes (2015).

⁷Acuity Market Intelligence (2016).

⁸Forbes (2015).

⁹Statista (2017).

- ▶ En la actualidad, los algoritmos de DeepMind AlphaZero y AlphaGo tienen un nivel de juego superior a cualquier humano en los juegos de ajedrez y *go*.
- ▶ Un algoritmo basado en inteligencia artificial es capaz de detectar cáncer de mama 30 veces más rápido que un médico y con una fiabilidad del 99%¹⁰.
- ▶ En Estados Unidos los *roboadvisors*¹¹ tienen 25,83 millones de usuarios, lo que supone un grado de penetración del 1,8% en 2018. Se espera que este ratio llegue al 8,3% en 2022¹².

Por último, de la capacidad de computación, que en las últimas décadas se ha incrementado enormemente apoyada en la mejora de los procesadores, cuenta ahora con otros factores como principales impulsores, entre otros: la gran evolución de los lenguajes de programación (tanto generalistas como dedicados a procesamiento de datos, visualización, algoritmia, etc.), el *cloud computing* y, especialmente, el diseño de nuevas arquitecturas de computación dirigidas específicamente a tareas de aprendizaje automático, análisis de datos y aplicaciones de ingeniería (conocidas como GPUs¹³).

En resumen, en las últimas dos décadas la disponibilidad de datos digitales se ha incrementado casi 1.000 veces, mientras que con relación a la algoritmia, se han registrado mejoras de 10 veces en su eficiencia, al tiempo que la velocidad de computación ha aumentado 100 veces su desempeño¹⁴. Todo ello ha desembocado en un renovado interés por estas técnicas como fórmula para obtener información de valor añadido en el nuevo entorno de los negocios.

Aprendizaje automático: más de medio siglo de historia

Las técnicas de aprendizaje automático (o *Machine Learning*) están experimentando un auge sin precedentes en diversos ámbitos, tanto en el mundo académico como en el empresarial, y constituyen una importante palanca de transformación. Si bien estas técnicas eran conocidas en los dos ámbitos, diversos factores están provocando que su uso sea más intensivo cuando antes era minoritario, y que se extienda a otros campos cuando antes prácticamente no eran utilizadas, tanto por los elevados costes de implantación como por los escasos beneficios inicialmente esperados de su aplicación.

Las técnicas de aprendizaje automático pueden definirse como un conjunto de métodos capaces de detectar automáticamente patrones en los datos¹⁵. Bajo esta definición, el concepto de aprendizaje automático lleva existiendo al menos desde los años 50, periodo en el que se descubrieron y redefinieron diversos métodos estadísticos y se aplicaron al aprendizaje automático a través de algoritmos simples, aunque circunscritos casi exclusivamente al ámbito académico.

¹⁰Forbes (2016).

¹¹Algoritmos automáticos que proporcionan asesoramiento y gestión online con una mínima intervención humana.

¹²Statista (2018).

¹³Graphics processing unit.

¹⁴Brynjolfsson, E. y McAfee, A. (2017). Brynjolfsson, profesor en la MIT Sloan School of Management. Director de MIT Initiative on the Digital Economy, Director de MIT Center of Digital Business. Es conocido por su contribución al mundo del IT *Productivity*. McAfee, co-director de MIT Initiative on the Digital Economy y Director asociado de Center for Digital Business.

¹⁵Murphy, K. (2012).





Este concepto de aprendizaje automático incluye desde entonces el uso de los patrones detectados para realizar predicciones, o para tomar otros tipos de decisiones en entornos de incertidumbre¹⁶.

Frente a las técnicas estadísticas clásicas, la introducción de técnicas de *Machine Learning* permiten mejorar el proceso de estimación de modelos, no solo con relación al aumento del poder predictivo a través de nuevas metodologías y técnicas de selección de variables, sino también en la mejora de la eficiencia de los procesos a través de la automatización.

En este contexto, el presente estudio pretende dar una visión sobre la revolución digital y su impacto en la transformación de los negocios, con un especial foco en las técnicas de aprendizaje automático. Para ello, el documento se estructura en tres secciones, que responden a tres objetivos:

- ▶ Ilustrar el desarrollo de la revolución digital y su impacto en distintos frentes.
- ▶ Introducir la disciplina de aprendizaje automático, describir distintos enfoques y exponer las tendencias actuales en este campo.
- ▶ Exponer un caso de estudio para ilustrar la aplicación de técnicas de *Machine Learning* en el caso específico del sector financiero.

¹⁶Ibid.

Resumen ejecutivo



La revolución digital y la transformación de los modelos de negocio

1. El cambio de paradigma que introduce la digitalización nos invita a revisar los actuales modelos de negocio.
2. El móvil e internet como puerta de acceso a servicios *on-line*, las redes sociales como fuente de datos, la inteligencia artificial y las arquitecturas *big data*, las infraestructuras para la computación distribuida y el uso de aplicaciones en la nube, el desarrollo de las tecnologías de computación por bloques (*blockchain*), la aplicación de criptografía y biometría, el denominado internet de las cosas, los robots y asistentes virtuales, la impresión 3D y la realidad virtual, etc.; son herramientas útiles al alcance de las empresas que, por un lado, cambian el propio entorno y, por otro, impulsan el rediseño de los modelos de negocio ante dicho nuevo entorno.
3. En la era digital, el dato se convierte en una clara fuente de valor. Su volumen aumenta de forma exponencial por la digitalización de los procesos y la creciente interacción con terceros (clientes, empleados, proveedores, etc.) a través de canales digitales.
4. También adquieren un mayor protagonismo la experiencia del cliente, la personalización de la oferta, o el concepto de acceso al servicio frente a la propiedad; y se produce al mismo tiempo una entrada de nuevos competidores cuya propuesta de valor está basada fundamentalmente en elementos tecnológicos.
5. Y es que la introducción de la dimensión digital lo cambia todo en la empresa impactando en su definición de la estrategia; en su gobierno, organización y cultura de trabajo; en sus procesos comerciales y operativos; en el acceso, almacenamiento, procesamiento y modelización de sus datos; en la gestión y control de sus riesgos (donde afloran nuevos riesgos, como los de ciberseguridad, los relativos a la protección de datos personales o la ética en la inteligencia artificial); así como en la propia normativa, que se vuelve más global.

Concepto y tendencias en aprendizaje automático

6. Uno de los elementos vertebradores de esta transformación digital es el aprendizaje automático o *Machine Learning*: la aplicación de técnicas y algoritmos capaces de aprender a partir de distintas y nuevas fuentes de información, construyendo algoritmos que mejoren de forma autónoma con la experiencia. Esto permite disponer de métodos capaces de detectar automáticamente patrones en los datos, y usarlos para predecir sobre datos futuros en un entorno de incertidumbre.
7. Los componentes principales del aprendizaje automático se pueden clasificar en cuatro grupos:
 - Las fuentes de información, que pueden aportar datos tanto estructurados como no estructurados, y que son la base del resto de componentes.
 - Las técnicas y algoritmos para el tratamiento de información no estructurada (texto, voz, video, etc.) y para la obtención de patrones a partir de los datos.
 - La capacidad de autoaprendizaje, que permite que el algoritmo se adapte a los cambios en los datos.
 - El uso de sistemas y software como vehículo para la visualización de la información y la programación.
8. El desarrollo de estos componentes supone una evolución con respecto al enfoque que tradicionalmente ha tenido la modelización. Ello implica, entre otros elementos, el uso de un mayor número y tipos de fuentes de información, la capacidad de detección de patrones ocultos en los datos a partir de métodos inductivos, el mantenimiento del poder predictivo durante más tiempo, así como la necesidad de una mayor capacidad de almacenamiento y procesamiento de los datos. De este modo, la selección de la técnica de aprendizaje automático más apropiada de entre las múltiples existentes dependerá en gran medida de los elementos citados.
9. Por un lado, algunas técnicas pueden utilizarse para la transformación de información no estructurada (textos, sonidos, imágenes, etc.) en datos que puedan ser analizados y procesados por un ordenador. Entre estas técnicas cabe destacar el uso de estadísticos o la clasificación de palabras en categorías de cara a la comprensión del texto escrito, el uso de redes neuronales para el reconocimiento de voz o de imágenes, la aplicación de cadenas de Markov para la

construcción de textos en lenguaje natural, o la aplicación de algoritmos no supervisados de clasificación para la organización de imágenes.

10. Por otro lado, las técnicas de modelización que se utilizan con información estructurada pueden clasificarse como aprendizaje supervisado o no supervisado, en función de la información utilizada para el aprendizaje. En el aprendizaje supervisado se dispone de una variable objetivo observada en los datos, mientras que en el aprendizaje no supervisado el objetivo es encontrar patrones o relaciones en ellos.
11. En el proceso de modelización, se suele realizar una primera fase de organización y preparación del conjunto de datos inicial con el objetivo de facilitar y optimizar su posterior uso. Para ello se realizan tareas de análisis descriptivo y preparación de los datos (incluyendo técnicas específicas de regularización, como por ejemplo la aplicación de redes elásticas).
12. Entre las técnicas utilizadas en el aprendizaje supervisado pueden destacarse las redes neuronales (incluyendo su extensión al *deep learning*), las máquinas de vector soporte, los clasificadores bayesianos, o los árboles de regresión y clasificación.
13. Estas técnicas pueden combinarse con algoritmos que permiten mejorar la capacidad predictiva, denominados métodos ensemble, que consisten en la combinación de modelos para generar un modelo más predictivo o más estable.
14. Dentro del aprendizaje no supervisado cabe destacar las técnicas de *clustering* o las técnicas de *Data Analysis*, como la de reducción de la dimensionalidad.
15. La aplicación de estas técnicas implica que los métodos de validación de resultados deben ser más sofisticados, como el *bootstrapping* o el *cross-validation*, que permiten analizar el modelo en más de una muestra de validación. Asimismo, la naturaleza dinámica de estas técnicas dificulta la trazabilidad de los modelos.
16. Existe un gran número de casos de implementación de técnicas de aprendizaje automático en distintos sectores. Como ejemplos, destacan aplicaciones en las industrias de la educación (como tutores inteligentes), las finanzas (para el *trading* automático, *roboadvisors*, detección del fraude, medición del riesgo o elaboración de modelos *prospect* con fines comerciales), la salud (el diagnóstico por imagen, la gestión de consultas de tratamiento y sugerencias, recopilación de información médica o la cirugía robótica), o, de modo transversal, en la mejora de la eficiencia de las organizaciones (p. ej. a través de la mejora de la función de IT).
17. Entre las principales tendencias en la implantación de técnicas de *Machine Learning* se pueden destacar el uso de fuentes de información que recopilan datos en tiempo real, la mayor importancia que se le da a obtener un poder de predicción elevado en relación con la interpretabilidad de los modelos, la incorporación de la capacidad de que el algoritmo se modifique de forma autónoma en función de los cambios que se van produciendo en la población objetivo, o la inversión en arquitecturas e infraestructuras tecnológicas que garanticen la escalabilidad en la capacidad de almacenamiento de datos y una mayor velocidad de procesamiento, combinadas con soluciones basadas en *Cloud* y el uso de infraestructuras de *edge computing* donde se ofrecen funciones ya previamente instaladas preparadas para su uso directo (*Functions as a Service*).
18. Todo ello conlleva una serie de retos y dificultades. El uso de nuevas fuentes de información implica la necesidad de realizar una inversión económica para identificar nuevas fuentes de datos relevantes, incorporar técnicas de *data quality*, garantizar la protección de la información, o establecer controles y sistemas de ciberseguridad.
19. La aplicación de nuevas técnicas y algoritmos conlleva también la necesidad de reforzar la función de gestión del riesgo de modelo, realizar una elección previa del algoritmo más adecuado de entre una amplia gama de posibilidades, o vigilar que los resultados automáticos no impliquen la aparición de tratamientos discriminatorios. Incorporar la característica de autoaprendizaje en los modelos puede dificultar la validación de los mismos y exige considerar nuevos elementos como el control de grados de libertad en la automatización, una mayor frecuencia en la evaluación del poder discriminante u otras técnicas de contraste. Finalmente, todo ello conlleva la necesidad de realizar inversiones en recursos e infraestructuras IT.
20. Asimismo, la introducción del aprendizaje automático en las organizaciones conlleva la necesidad de contar con recursos humanos con un alto grado de preparación y especialización, capaces de comprender y trabajar con lenguajes de programación, algoritmos, matemáticas, estadística y arquitecturas tecnológicas complejas.

Ejercicio cuantitativo: uso de técnicas de Machine Learning en la construcción de un modelo de scoring

21. Los objetivos del ejercicio propuesto han sido: (i) analizar e ilustrar cómo impacta el uso de técnicas de *Machine Learning* en el desarrollo de modelos, y (ii) evaluar cómo varía el proceso de estimación y los resultados obtenidos mediante el uso de técnicas *Machine Learning*.
22. Para ello, se ha entrenado un score de comportamiento utilizando distintos algoritmos de *Machine Learning*, y se han comparado los resultados con los obtenidos con técnicas tradicionales.
23. El estudio se ha llevado a cabo utilizando un conjunto de más de 500.000 préstamos, que comprenden más de 10

años de historia, con una tasa de mora del 6%. La muestra incluye información relativa a la operación y el cliente, así como otro tipo de información que puede ser útil en la modelización, como comisiones, número de transacciones realizadas, etc.

24. En una primera fase de *knowledge discovery* se ha realizado un tratamiento de *missings* (mediante técnicas de imputación a través de, entre otros, el uso de algoritmos de *clustering* o modelos de regresión), un análisis y tratamiento de atípicos, y un proceso de simplificación y agrupación de variables (utilizando de nuevo algoritmos de *clustering*). Esto ha permitido reducir el número de variables con el objetivo de mejorar la eficiencia de los procesos posteriores y preparar la información existente para que se adecúe a los requisitos específicos de los distintos modelos y posibles limitaciones de los algoritmos.
25. En una segunda fase se han estimado distintos modelos: uno tradicional (logístico) que sirve de comparación, y cinco técnicas de *Machine Learning*: un modelo con técnicas de regularización (red elástica), dos métodos ensemble (un *random forest* y un *adaboost*), y dos máquinas de vector soporte (utilizando, respectivamente, una función lineal y una radial). Posteriormente se ha procedido a calcular dos medidas de la capacidad discriminante sobre una muestra de validación: la tasa de acierto de modelo (basada en una estimación del punto de corte) y el área bajo la curva ROC.
26. Tras la comparación con estos estadísticos se observa que tres de las técnicas analizadas permiten mejorar el poder predictivo del modelo, tanto en tasa de acierto¹⁷ como en poder discriminante: el *random forest*, la aplicación de la red elástica y el *adaboost*.
27. En particular, el *random forest* es el que presenta el mejor resultado frente al resto de métodos: en términos de tasa de acierto se eleva desde el 74,7% del modelo tradicional al 80,3%, lo que supone un incremento porcentual de 7,5% sobre el obtenido a través de técnicas tradicionales; en

términos de poder discriminante, se consigue mejorar el área bajo la curva ROC desde el 81,5% en el modelo tradicional hasta el 88,2%, lo que representa un incremento porcentual del 8,2%. El segundo mejor método es la aplicación de la red elástica, con la que se consiguen valores de tasa de acierto y área bajo la curva ROC de 79% y 86,4%, respectivamente. Esto representa un incremento porcentual del 6% en ambos indicadores.

28. Este incremento del poder predictivo implica que, a igualdad de volumen de negocio, la tasa de morosidad se reduciría un 48% en el caso del *random forest* (utilizando un punto de corte óptimo con el modelo clásico, se obtendría una tasa de morosidad de un 2,1%, que se reduce al 1,1% con el *random forest* si se mantiene el volumen de operaciones aprobadas), y un 30% en el caso de la red elástica (donde la tasa de mora se reduce al 1,4%). Asimismo, a igualdad de tasa de morosidad, el volumen de negocio se incrementaría un 16% en el caso del *random forest*, y un 13% en el caso de la red elástica.
29. Estas mejoras, no obstante, se han conseguido a través de un incremento de la complejidad con respecto al modelo tradicional, habiéndose utilizado un total de 80 variables entre los 50 árboles que componen el bosque en el caso del *random forest*, y un total de 45 variables tras la aplicación de la red elástica, frente a 11 variables en el modelo tradicional.
30. Por tanto, como se ha observado en el estudio realizado, las técnicas de *Machine Learning* permiten mejorar el poder discriminante de los modelos, lo que implica mejoras en el negocio, si bien a costa de una mayor complejidad tanto desde un punto de vista estadístico como por el volumen de información utilizada, lo que redundaría en mayor dificultad a la hora de analizar la interpretación de los resultados y la necesidad de reforzar los procedimientos de validación (entre otros, utilizando modelos replicables que hagan *challenge* a los modelos de *Machine Learning* y explicando las diferencias en las salidas de ambos modelos).

¹⁷Porcentaje de operaciones correctamente clasificadas por el modelo, definido un punto de corte.



La revolución digital y la transformación de los modelos de negocio

Technology doesn't provide value to a business. Instead, technology's value comes from doing business differently because technology makes it possible

George Westerman¹⁸



Desde hace unos años están apareciendo numerosas iniciativas para la transformación tanto de los procesos como de los sistemas utilizados por las empresas, lo que impacta en definitiva en la forma de trabajar. Estas iniciativas surgen tanto en el ámbito de la empresa privada como en el sector público, y se fundamentan en la combinación de infraestructuras físicas con elementos novedosos provenientes del desarrollo en la tecnología digital y la biotecnología.

Este conjunto de cambios no es únicamente una continuación y sofisticación de los actuales sistemas de producción, sino que supone un nuevo paradigma, la llamada cuarta revolución industrial. Este paradigma se basa en cambios radicales en la producción, ligados a la velocidad de implantación, que no tiene precedentes históricos, y en el alcance de la transformación, que afecta a un conjunto elevado de elementos de la cadena de valor¹⁹.

Dentro de esta revolución industrial, el concepto de transformación digital aglutina aquellas iniciativas relacionadas directamente con tecnologías digitales. Según algunos autores²⁰, la transformación digital puede ser definida como:

“The use of new digital technologies (social media, mobile, analytics or embedded devices) to enable major business improvements (such as enhancing customer experience, streamlining operations or creating new business models)”

Estas tecnologías digitales impactan directamente en los procesos, en cuestiones relativas a la velocidad, la seguridad o la transparencia, lo que permite el desarrollo de nuevos servicios que antes no existían, por falta de mercado o de rentabilidad, ya que las tecnologías digitales en general presentan escasas barreras de entrada y con costes marginales que tienden a cero.

Asimismo afecta también a los intermediarios de servicios, al corregir, al menos parcialmente, algunas imperfecciones del mercado como son la información asimétrica, los costes de

transacción o las asimetrías en la casación de oferta y demanda, través del uso de plataformas B2B o P2P²¹ con una mínima intervención de terceros.

Además, la gestión de datos ha pasado a ser un activo fundamental para la empresa, siendo al mismo tiempo materia prima y generador de negocio. La digitalización de los procesos, la interacción con los clientes, empleados y proveedores a través de canales digitales aporta una cantidad ingente de información que puede aprovecharse para nuevas oportunidades. A modo ilustrativo, según la Comisión Europea, el valor de la economía de los datos en la Unión podría ascender en 2020 hasta el 4% del PIB (más del doble respecto a la situación actual).

Por último, también supone un cambio de paradigma en el mercado de trabajo, puesto que se requiere la ejecución de tareas más cualificadas, lo que implica la necesidad de realizar una mayor inversión tanto en el sistema educativo como en los planes de formación continua en las empresas.

Sin embargo, como se comentará posteriormente, la transformación digital no se refiere a las nuevas aplicaciones y usos que tienen las nuevas tecnologías, sino a cómo estas tecnologías cambian el entorno en el que operan las empresas y cómo estas deben adaptarse a este nuevo entorno (Figura 1), utilizando precisamente estas tecnologías en los procesos y sistemas, pero también cambiando su organización y estrategia.

Figura 1. Elementos de la transformación digital.



¹⁸Westerman, G. (2017). Investigador en MIT Initiative on the Digital Economy y co-autor del best seller *Leading Digital: Turning Technology Into Business Transformation*.

¹⁹Schwab, K. (2016). Economista y empresario alemán, conocido principalmente por ser el fundador de Foro Económico Mundial.

²⁰Fitzgerald et al. (2013). Editor y contribuidor sobre transformación digital en MIT Sloan Management Review.

²¹B2B: Business to Business. P2P: Peer to Peer.

Tecnologías de la transformación digital


La transformación en el ámbito empresarial, que abarca diversos ámbitos y propuestas, se fundamenta en una serie de desarrollos tecnológicos que, si bien obedecen a distintos orígenes y naturaleza, tienen elementos comunes: su fuerte apalancamiento en la inversión, la generación y uso de grandes volúmenes de datos, y el objetivo de mejorar la experiencia del cliente y la eficiencia operacional. Entre las principales tecnologías que impulsan la transformación se encuentran las siguientes (Figura 2):

- ▶ **Acceso móvil e internet:** debido a la generalización de las telecomunicaciones y el acceso a un amplio rango de servicios *online*, se están desarrollando *interfaces* de programación de aplicaciones (APIs) por parte de las compañías, lo que permite a las empresas tener nuevos canales de interlocución con los clientes y contar con un conjunto de datos amplio. Esto conlleva que aparezcan nuevas formas relevantes de información, como la geolocalización. Asimismo, el acceso móvil ha permitido que se haya universalizado el acceso a la información y a la comunicación, independientemente de la ubicación física. Como ejemplo, las comunicaciones de banda ancha móvil se han multiplicado por cinco en las economías desarrolladas en los últimos 10 años²².
- ▶ **Social Media:** las redes sociales son una fuente de datos que proporciona una mejor comprensión del comportamiento de los clientes y una mayor productividad a través de la mejora de la comunicación interna. Las tendencias relacionadas con Social Media son un marketing mucho más segmentado y dirigido, y nuevas formas de comunicación en tiempo real.
- ▶ **Inteligencia artificial, Big Data y Analytics:** herramientas de detección de patrones y modelos de predicción de comportamiento basados en el uso de enormes bases de datos (que contienen información tanto estructurada como no estructurada²³—logs de conexión a internet, mensajes en redes sociales, etc.—) y en la aplicación de técnicas de

modelización y algoritmos avanzados. Todo ello permite obtener un mayor conocimiento del cliente, lo que mejora la segmentación, la personalización del producto y el precio, y permite un marketing más eficiente.

- ▶ **Computación distribuida²⁴:** los recursos tecnológicos (almacenamiento, procesamiento, fuentes de datos y supercomputadores) se pueden encontrar distribuidos geográficamente, pero su interconexión puede ser aprovechada por los usuarios en cualquier parte del mundo.
- ▶ **Cloud computing:** el uso de aplicaciones en la nube permite el acceso a información desde cualquier lugar, facilita operaciones comerciales y permite mayor rapidez, seguridad y menor coste. Esto lleva a un nuevo modelo de negocio donde estos recursos se ofrecen como *utilities* y se factura el uso del servicio.
- ▶ **Distributed Ledger Technology (Blockchain):** estructura de datos que implementa un sistema de registro distribuido (*ledger*), es decir, un registro criptográfico de todas las operaciones realizadas y previamente validadas por una red de nodos independientes a través de un algoritmo de consenso. Ello permite el registro de cualquier activo digitalizable, como criptomonedas, instrumentos financieros o contratos "*smart contracts*" (contratos programables que implementan reglas de negocio y cuyo código queda registrado y puede ser ejecutado de forma distribuida por los diferentes nodos de la red). Todo ello aporta inmediatez de las operaciones, seguridad y privacidad a través de reglas criptográficas que permiten el registro inviolable de las operaciones, transparencia (ya que todas las operaciones se encuentran almacenadas en el registro y pueden ser auditadas por cualquier miembro de la red), eliminación de un punto único de fallo y disminución de costes (se elimina la intermediación para validar y registrar las operaciones).
- ▶ **Criptografía, ciberseguridad y biometría:** nuevas herramientas criptográficas e iniciativas que persiguen la mejora de los procesos de seguridad y cifrado de la información, así como la creación de sistemas de seguridad más robustos basados en sensores y biométrica.
- ▶ **Internet of Things:** en contraposición a los sistemas de comunicación clásicos, el concepto de internet de las cosas se refiere a la interconexión a través de redes abiertas de dispositivos con capacidad computacional que envían y reciben datos sin intervención humana, lo que permite la recopilación masiva y directa de datos, así como la operación remota en tiempo real de los dispositivos conectados a internet. Esta tecnología mejora la experiencia del cliente a su vez permite el uso de estos

Figura 2. Tecnologías de la transformación digital.



²²International Telecommunication Union (2017).

²³Se puede entender como información estructurada aquella que está procesada y preparada para ser utilizada directamente a través de lenguajes estadísticos y de programación. La información no estructurada se puede entender como información que no cumple estas características, como la información en lenguaje natural (texto, audio), imágenes, vídeo, etc.

²⁴International Telecommunication Union (2009).

datos en algunos procesos comerciales, como es el caso del ámbito del *pricing* o la búsqueda de la eficiencia.

- ▶ **Robotics and automated machinery:** las herramientas RPA²⁵ y los asistentes virtuales basados en la interpretación del lenguaje natural permiten automatizar tareas repetitivas de reducido valor añadido, tradicionalmente realizadas de forma manual, de modo que esta capacidad disponible se pueda orientar hacia tareas de mayor valor añadido. Las industrias dirigidas al usuario final están adaptando rápidamente esta nueva tecnología con el objetivo de mejorar la calidad de los productos y reducir los costes de manufactura.
- ▶ **La impresión 3D:** dirigida a la fabricación deslocalizada y descentralizada de objetos a partir de la recepción remota y digitalizada del diseño industrial, con aplicación en diversos sectores y a su uso directo por parte de los consumidores (en el sector aeronáutico, automoción, electrónica, medicina, etc.).
- ▶ **La realidad aumentada y realidad virtual:** presentan múltiples aplicaciones, como en la industria de los videojuegos o de contenidos multimedia, la formación a empleados de industrias muy especializadas, el soporte en reparaciones y mantenimiento en la industria energética, el apoyo en ventas de viviendas sobre plano, buscadores de viviendas, oficinas bancarias, cajeros, etc.

El nuevo entorno de la transformación digital

Este nuevo entorno digital está modificando significativamente las condiciones en las que los mercados alcanzan su equilibrio, a través del cambio tanto en las empresas oferentes, como de las expectativas y el comportamiento de los consumidores, así como de las distintas condiciones en las que se realizan las operaciones (compra-venta de productos, servicios, etc.).

Como se comentará en este apartado, la transformación digital se está produciendo en un entorno donde existen distintos impulsores. Desde luego, las nuevas capacidades tecnológicas son el origen, pero el elemento fundamental que propicia la transformación son los cambios en los clientes o mercados provocados por las tecnologías lo que posibilita, fomenta y requiere su implementación en las compañías para adaptarse a este nuevo paradigma.

Estos cambios se ven amplificados como consecuencia de la desaparición de las barreras de entrada existentes en los sectores (Figura 3).

Y es que esta disrupción de la oferta de bienes y servicios viene motivada por diversos factores. Uno de los principales es la entrada de nuevos competidores cuya propuesta de valor está

basada fundamentalmente en un elemento tecnológico, lo que tiene una influencia determinante en el modelo de negocio y los elementos asociados (elevada capacidad de crecimiento, bajos costes y coste marginal decreciente, fuertemente apalancado en la tecnología móvil, el análisis de datos, las tecnologías cloud y ciberseguridad).

Además de la entrada de nuevos competidores, estos en ocasiones sustituyen el producto o servicio ofrecido por un servicio totalmente digital o híbrido, lo que redundaría en menores costes y precio, y en una fácil y rápida sustitución del servicio tradicional. Este es el caso de nuevos modelos de servicio basados en el uso de algoritmos que interpretan datos de redes sociales y otras fuentes poco convencionales para proveer de información relevante para sus clientes en tiempo real, sustituyendo así a las fuentes tradicionales de información.

Por último, los proveedores pueden influir también en la adaptación de procesos específicos al generar plataformas de comunicación y enfoques de negocio digitales que facilitan la migración de los procesos de aprovisionamiento de productos o servicios a sus clientes.


Todo ello conlleva que los agentes clásicos en los mercados, como respuesta, estén también adaptando sus modelos de negocio, a pesar de la presencia de diversos inhibidores de la transformación digital, como son la resistencia al cambio, la cultura o la falta de formación de las personas.

Los factores tecnológicos anteriormente comentados también actúan indirectamente como un motor de cambio en la forma de entender la prestación de servicios por parte de los clientes.

Los cambios en la forma de consumir son sintetizados por el World Economic Forum (WEF) en tres elementos²⁶:

1. Mayor protagonismo de la experiencia del cliente: adquiere más valor la experiencia de compra, de forma que cualquier persona, empresa o institución opta por un producto o servicio no solo con base en su calidad y precio sino por la experiencia que este le reporta (p. ej., en plazos de entrega o la calidad del servicio postventa).

Figura 3. Porcentaje de encuestados que consideran muy probable que una industria se vea afectada por tendencias digitales.



Fuente: Harvard Business Review (2017).

²⁵Robotic Process Automation.

²⁶Digital Consumption (2016).

2. Hiperpersonalización de la oferta: los clientes tienen mayores expectativas sobre la adaptación del producto a sus gustos. La tecnología digital permite cumplir con estas expectativas sin incrementar los costes dramáticamente.

3. Acceso frente a propiedad: el concepto de acceso en lugar de propiedad se está generalizando. Los clientes prefieren el acceso bajo demanda, optimizando así el consumo.

Ejemplos de lo anterior explican el éxito de iniciativas como la de Amazon, donde la experiencia del cliente en el proceso de compra se enriquece con una selección personalizada de productos relacionados, y la oferta de valor al cliente incluye el producto y cierta personalización en los plazos y mecanismos de entrega; o el de las plataformas de contenidos Netflix o Spotify, donde el cliente accede a los contenidos sin tener la propiedad, por un coste menor.

En paralelo, la propia normativa internacional se está adaptando al nuevo entorno, volviéndose más global e incisiva, especialmente en los aspectos relativos a la protección de datos personales.

Por último, el propio mercado de trabajo se ve también impactado, con una creciente demanda de perfiles tecnológicos y cuantitativos y también la gestión de recursos humanos, impulsándose una mayor flexibilidad y fragmentación del trabajo, así como cambios en la medición del desempeño, las estrategias de contratación o las necesidades de formación.

Implicaciones en las organizaciones y ámbitos de actuación

Muchas organizaciones están incorporando nuevas tecnologías en sus procesos (con mayor o menor grado de integración), pero no siempre con el mismo objetivo. Algunas empresas pretenden beneficiarse de las nuevas tecnologías con objeto de ser más eficientes y reducir sus costes; otras como medio para llegar a nuevos mercados; pero solo algunas las aprovechan para generar nuevos modelos de negocio.

Según una encuesta de la Comisión Europea²⁷, las empresas tienden a usar estas tecnologías, tales como servicios móviles, tecnología *cloud*, *social media*, etc. (Figura 4), para mejorar funciones de negocio específicas más que como herramienta disruptiva para transformar los modelos de negocio.

La transformación digital en las empresas, entendida como cambio disruptivo, tiene implicaciones no solo en los procesos y sistemas, adaptándolos a las nuevas herramientas y enfoques de trabajo, sino en su gobierno, organización y en la propia definición estratégica.

Resulta pues importante posicionarse en cada uno de los principales ámbitos de actuación afectados por la transformación digital (Figura 5).

Estrategia y movilización. Una aproximación estratégica al reto digital implica un cuestionamiento de los actuales modelos de negocio y de soporte. No hay una receta universal que sirva para cualquier compañía, pero la transformación digital no es una opción sino una necesidad cuyos tiempos y alcance dependerán del contexto de cada una.

Existen diversas fórmulas para acometer esta transformación, tanto con relación a la posición de una entidad frente a las nuevas tecnologías (*early adopter*, seguidor, retardador, etc.) como con relación a la involucración de terceros (joint ventures, colaboración con *start-ups*, universidades, centros de investigación, fondos de capital riesgo u otras empresas, o incluso a través de plataformas basadas en ecosistemas abiertos).

Un primer paso muy importante es documentar bien la situación de partida de cada empresa y su sector, para acto seguido tratar de deducir las oportunidades y amenazas que se presentan con la digitalización.

Otra cuestión fundamental es el liderazgo de la transformación, que debe ser ejercicio por el primer ejecutivo de la compañía. Tampoco hay que olvidar el impacto de la citada transformación en las personas y en la propia cultura de trabajo de la empresa.

Dado que los costes y riesgos son elevados, y los plazos inciertos, es importante sintetizar y priorizar los objetivos de la transformación, así como contar con indicadores específicos (como son el impacto económico, la mejora de la experiencia del cliente o la vinculación de los empleados) que ayuden a medir el grado de cumplimiento de dichos objetivos.

Organización, cultura y gobierno. La forma de trabajar y organizar el trabajo también está cambiando. Las estructuras organizativas se vuelven más horizontales, con equipos multidisciplinares organizados en proyectos, adoptando principios y desarrollando organizaciones Agile. Además las tecnologías modifican la interacción, comunicación y toma de decisiones.

También surgen nuevas funciones, como las relativas a la visión estratégica de la tecnología, el gobierno de los datos y de los modelos, la protección de datos personales o la seguridad informática (ciberseguridad).

Figura 4. Porcentaje de adopción de las principales tecnologías.



Fuente: EC (2017)

²⁷EC (2017).

Procesos comerciales. Las compañías están revisando sus modelos de producción y distribución, rediseñando el uso de sus canales digitales y tradicionales. En este contexto, destaca la palanca de movilidad. El canal móvil se convierte en un elemento centralizador de la relación con el cliente.

Por otro lado, se busca una mayor personalización de la propuesta de valor (interpretando la información disponible a través de su modelización), procurando así mejorar la experiencia del cliente.

Procesos operativos. El objetivo fundamental de la transformación de los procesos operativos (end-to-end) es la mejora de la eficiencia y la calidad del servicio a los clientes, así como el robustecimiento del control de la operativa.

Para alcanzar estos objetivos proliferan iniciativas como el diseño de *back offices* sin papeles, la digitalización de los *contact centers*, la sensorización de los procesos productivos, la robotización de los centros de procesamiento, etc.

Datos y modelización. La mayor capacidad de almacenamiento y de tratamiento de datos, facilita una explotación más eficaz de la información disponible; pero también surgen nuevos retos, como el uso de información no estructurada, la gestión de grandes volúmenes de datos o el análisis de información en tiempo real.

Asimismo, se incorporan técnicas de modelización y de aprendizaje automático (como redes neuronales, redes profundas, máquinas de vector soporte, clasificadores bayesianos, árboles de clasificación y regresión, etc.), que contribuyen a mejorar los procesos de decisión.

Protección de datos. En el contexto actual, los datos se han convertido en un activo estratégico. Por ello su confidencialidad y seguridad se convierte en un elemento fundamental para el negocio, especialmente en lo relativo a datos de carácter personal.

Como consecuencia, se requiere una gestión proactiva de los permisos de usuarios, que permita a su vez cumplir con la regulación y explotar adecuadamente el potencial de los datos disponibles. Esto implica contar con políticas de gestión de consentimiento y finalidad, así como de tratamiento transfronterizo, identificar y mantener repositorios de datos de carácter personal, vincular actuaciones comerciales a los usos permitidos, etc., lo que supone una oportunidad para replantear la estructura y gobierno de los datos de una entidad.

Ciberseguridad. En los últimos años, el ciberriesgo ha aumentado debido a diversos factores, como la existencia de un mayor y más complejo ecosistema tecnológico en las empresas, la integración de empresas de distintos sectores o la propia profesionalización de los ataques. Los daños por ciberataques ya han alcanzado los 3 billones de dólares al año, y se estima que en 2021 alcanzarán los 6 billones anuales²⁹. Esto cobra gran importancia en un contexto de transformación digital, donde un posible incidente puede tener impacto en la continuidad de negocio de la empresa.

La ciberseguridad dentro de la estrategia de digitalización pasa por llevar a cabo iniciativas que eviten riesgos durante y tras los procesos de transformación. Entre las principales iniciativas, destacan la implantación de marcos de ciberseguridad, la revisión de la estructura organizativa asociada a la ciberseguridad, la identificación y revisión de los sistemas y servicios críticos, la medición del riesgo, o la generación de respuesta eficaz ante incidentes.


Nuevas tecnologías. La inversión en nuevas tecnologías es un elemento decisivo en todo proceso de transformación digital. Requiere disponer de conocimientos suficientes en tecnologías de la información y de las comunicaciones.

Y es que la evolución de las plataformas tecnológicas hacia entornos *cloud*, la definición de arquitecturas de software que incorporen soluciones abiertas y la utilización de tecnologías disruptivas (*big data*, *AI*, *blockchain*, *IoT*, *biometría*, *robotics*, etc.) se han convertido en cuestiones centrales de la estrategia empresarial.

²⁸Círculo de Empresarios (2018).

²⁹Cybersecurity Ventures (2017).

Figura 5. Ámbitos de actuación de la transformación digital²⁸.



Concepto y tendencias en aprendizaje automático

All models are wrong, but some models are useful
George Box³⁰



Como se ha expuesto, la cantidad de datos disponibles y la variedad de fuentes presentan un crecimiento exponencial, que sobrepasa la capacidad de análisis del ser humano. El uso de nuevas fuentes de información, así como la aplicación de técnicas y algoritmos capaces de aprender a partir de la nueva información³¹, permite obtener una serie de beneficios entre los que cabe destacar:

- ▶ El incremento de los tipos de datos (tanto estructurados como desestructurados) y fuentes de información que pueden incorporarse a los procesos de modelización.
- ▶ El uso eficiente de grandes cantidades de datos en los procesos de toma de decisiones.
- ▶ La detección de patrones sofisticados o no evidentes, no basados en hipótesis realizadas a priori.
- ▶ La mayor automatización de los procesos de modelización y autoaprendizaje, que facilita un incremento del poder predictivo de los modelos. Una vez diseñados e implementados, sus requerimientos de calibrado y mantenimiento son inferiores a los tradicionales, reduciendo así los tiempos de modelización y costes.

Concepto y componentes del aprendizaje

La definición clásica de aprendizaje automático se basa en los primeros estudios para el desarrollo de técnicas de aprendizaje:

“Campo de estudio que dota a los ordenadores de la capacidad de aprender sin ser explícitamente programados”.³²

Así, el campo de estudio del aprendizaje automático trata de cómo construir algoritmos que mejoren de forma autónoma con la experiencia³³. Desde el punto de vista de la ciencia de la computación, la experiencia se materializa en la información que se produce a través de procesos de almacenamiento de datos. Por tanto, los modelos y algoritmos que constituyen el cuerpo de esta disciplina se fundamentan en la extracción de información a partir de diferentes fuentes de datos. Todo ello lleva a la definición formal de aprendizaje automático³⁴:

“A computer program is said to learn from experience E with respect to some task T and some performance measure P, if its performance on T, as measured by P, improves with E”.

De un modo menos formal, se puede entonces definir³⁵ el campo del aprendizaje automático como un conjunto de métodos capaces de detectar automáticamente patrones en los datos, y usarlos para predecir sobre datos futuros o bien para llevar a cabo otros tipos de decisiones en un entorno de incertidumbre. Por tanto, las técnicas de aprendizaje automático partirán de un conjunto de datos observados³⁶, sobre los que se obtendrán reglas de clasificación o patrones de

³⁰Box, G. y Draper, N. (1987). Box, estadístico británico que trabajó en las áreas de control de calidad, análisis de series temporales, diseño de experimentos, y la inferencia bayesiana, es considerado como una de las mentes más brillantes de la estadística del siglo XX. Draper, profesor emérito en el departamento de estadística de la universidad de Wisconsin, Madison.

³¹Shalev-Shwartz, S. y Ben-David, S. (2014). Shalev-Shwartz, profesor en la Facultad de Ciencias de la Computación e Ingeniería en la Universidad de Jerusalem, Israel. Ben-David, profesor en la Escuela de Ciencias de la Computación en la Universidad de Waterloo, Canada.

³²Parafraseado de Samuel, A. (1959). La cita textual es: *“Programming computers to learn from experience should eventually eliminate the need for much of this detailed programming effort”*. Samuel, A., máster en Ingeniería Eléctrica por MIT, ensambló los laboratorios Bell, trabajó en la primera computadora comercial de IBM y fue profesor en la Universidad de Stanford.

³³Mitchell, T. (1997). Doctorado en Stanford, profesor de la cátedra E. Fredkin en el departamento de *Machine Learning* de la escuela de Ciencias de la Computación en Carnegie Mellon University.

³⁴Mitchell, T. (1997).

³⁵Murphy, K. (2012). Postdoctorado en MIT, profesor en Ciencias de la computación en la Univ. British Columbia (Canadá), este libro recibió el premio *DeGroot* en 2013. Actualmente es investigador en Google (California) sobre Inteligencia Artificial, *Machine Learning*, computer vision, y entendimiento del lenguaje natural.

³⁶Este conjunto de datos suele denominarse “muestra de entrenamiento”.



comportamiento, que serán aplicados sobre datos diferentes a aquellos utilizados para el análisis³⁷.

Bajo esta definición pueden englobarse los distintos componentes del aprendizaje automático:

- ▶ Las **fuentes de información**, que reflejan la experiencia E de la que se aprende:
 - Datos estructurados: bases de datos relacionales, sistemas de ficheros, etc.
 - Datos no estructurados: transaccionales, *mailing*, CRM, voz, imágenes, etc.
- ▶ Las **técnicas y algoritmos**, que se relacionan con las tareas a ejecutar T:
 - Técnicas para el tratamiento de la información no estructurada: *tf-idf*, *parsing*, mapas auto-organizativos, etc.
 - Modelos supervisados y no supervisados: modelos de clasificación, modelos estocásticos, simulación, optimización, *boosting*, etc.
- ▶ La **capacidad de autoaprendizaje**, que mejora las medidas de desempeño P:
 - Reentrenamiento automático a partir de nueva información.
 - Combinación de modelos y reponderación/calibración.
- ▶ El uso de **sistemas y software** para la visualización de la información y la programación³⁸:
 - Visualización: QlikView, Tableau, SAS Visual Analytics, Pentaho, TIBCO Spotfire, Power BI.
 - Programación: R, Python, Scala, Ruby, SAS, Java, SQL, Matlab, C, Google, AWS, Azure.

El desarrollo de estos componentes supone una evolución respecto al enfoque que tradicionalmente ha tenido la modelización. Dicha evolución presenta una serie de diferencias respecto al enfoque tradicional³⁹ (Figura 6).

Técnicas de aprendizaje automático

Machine Learning en función de la información y el paradigma de aprendizaje

Existen múltiples técnicas de aprendizaje automático, dependiendo del tipo de información (información estructurada o desestructurada) y del paradigma de aprendizaje que se utilicen (Figura 7). La selección de la técnica que hay que aplicar dependerá, entre otros, del objetivo del modelo que se quiere construir, así como del tipo de información disponible.

Existen algunas técnicas específicas que pueden utilizarse para la transformación de información no estructurada (textos, sonidos, imágenes, etc.) en datos que puedan ser analizados y procesados por un ordenador. Como ejemplos se pueden destacar el procesamiento del lenguaje natural o la identificación de imágenes (Figura 8). Algunos ejemplos son el uso de estadísticos para la valoración de la relevancia de palabras en textos escritos, la clasificación de palabras en categorías de cara a la comprensión del texto escrito, el uso de redes neuronales para el reconocimiento de voz o de imágenes, la aplicación de cadenas de Markov para la construcción de textos en lenguaje natural o la aplicación de algoritmos no supervisados de clasificación para la organización de imágenes.

³⁷No obstante, en el propio proceso de construcción y validación del modelo se emplean datos que, aunque observados, no se incluyen en la muestra de entrenamiento, y simulan los que serán los datos de aplicación. Estos datos suelen conformar las que se denominan "muestra de test" y "muestra de validación".


³⁸El uso masivo de datos conlleva también la implantación de herramientas de *big data* y la aplicación de técnicas de eficiencia computacional, si bien estos elementos no se han incluido en el concepto de *Machine Learning* en esta publicación.

³⁹Domingos, P. (2012). Profesor en la Universidad de Washington. Investigador en *Machine Learning* y conocido por su trabajo en las lógicas de Markov en la red.

Figura 6. Diferencias del aprendizaje automático respecto al enfoque tradicional.

	Modelización tradicional	Machine Learning
1 Fuentes de información	<ul style="list-style-type: none"> ▶ Datos estructurados ▶ Número reducido de fuentes de datos ▶ Limitadas por el diseño inicial, estructura y procesos internos de obtención de la información ▶ Actualizaciones no continuas y planificadas de los datos 	<ul style="list-style-type: none"> ▶ Datos estructurados y desestructurados + granulares ▶ Múltiples fuentes de datos ▶ Extensas, de fácil acceso y en continuo crecimiento: redes sociales, bases de datos públicas o pools de datos privados, Int. of Things, etc. ▶ Actualización continua y en tiempo real de los datos
2 Técnicas y algoritmos	<ul style="list-style-type: none"> ▶ Fundamento estadístico y matemático ▶ Limitación en los patrones y relaciones identificadas debido a la asunción de hipótesis previas ▶ Uso de métodos deductivos 	<ul style="list-style-type: none"> ▶ Fundamento estadístico y matemático + ciencia de la computación (en particular, inteligencia artificial) ▶ Identificación de patrones ocultos en los datos sin asumir hipótesis previas ▶ Uso de métodos inductivos
3 Aprendizaje	<ul style="list-style-type: none"> ▶ Reentrenamiento manual y planificado. ▶ Hipótesis predefinidas o conocimiento previo de las relaciones entre variables ▶ Reducción del poder predictivo a lo largo del tiempo por el anclaje a una ventana temporal ▶ Trazabilidad disponible 	<ul style="list-style-type: none"> ▶ Reentrenamiento automático y auto-aprendizaje ▶ Búsqueda de patrones y relaciones sin restricciones ▶ Mantenimiento del poder predictivo a lo largo del tiempo por la adaptación de la ventana temporal ▶ Trazabilidad: no asegurada
4 Sistemas y software	<ul style="list-style-type: none"> ▶ Menor requerimiento computacional ▶ Herramientas tradicionales, a veces usadas stand-alone ▶ Uso único de repositorios de información estructurada ▶ Datos desestructurados vistos como archivo sin valor 	<ul style="list-style-type: none"> ▶ Mayor requerimiento computacional y velocidad de procesamiento y capacidad de gestión de datos ▶ Combinación de herramientas ▶ Almacenamiento y uso de Data Lakes que combinan datos estructurados y desestructurados

Figura 7. Tipologías y técnicas de aprendizaje automático.



Por otro lado, las técnicas de modelización que se utilizan con información estructurada pueden clasificarse en función de la información utilizada para el aprendizaje^{40,41}:

Aprendizaje supervisado: la información para construir el algoritmo contiene información sobre la característica en estudio, que no está presente en los datos futuros. Por tanto, la información que se quiere predecir o por la que se quiere clasificar una población está disponible en los datos utilizados para construir el modelo. Más formalmente, el objetivo del aprendizaje supervisado es entrenar una aplicación de un conjunto de variables (denominadas explicativas, características o factores) "x" en una variable output "y", a partir de un conjunto de datos (denominado muestra de entrenamiento) de pares $\Delta = \{(x_i, y_i), i \in 1, \dots, N\}$, donde "N" es el tamaño de la muestra.

Cuando la variable output "y" es continua se habla de un problema de regresión, mientras que cuando es nominal o discreta, se habla de un problema de clasificación⁴².

Aprendizaje no supervisado: como concepto opuesto al caso anterior, no se dispone en la muestra de construcción de la información de una variable que se quiera predecir. Por tanto, en este caso no se dispone de la variable output, por lo que el conjunto de datos es de la forma $\Delta = \{x_i, i \in 1, \dots, N\}$, donde N es el tamaño de la muestra⁴³. El objetivo de este tipo de problemas es encontrar patrones o relaciones en los datos. Por ello, también se conoce como *knowledge discovery* (proceso de identificar patrones en los datos que sean válidos, nuevos, potencialmente útiles y entendibles⁴⁴).

⁴⁰Shalev-Shwartz, S. y Ben-David, S. (2014).


⁴¹Murphy, K. (2012).

⁴²Por ejemplo, en el caso de los modelos de clasificación en función de la calidad crediticia, la variable objetivo es dicotómica (*default / no default*), o discreta (nivel de *rating*), en cuyo caso se habla de problema de clasificación.

⁴³Se pretende encontrar diferentes grupos en los datos sin tener una muestra donde se hayan observado previamente estos grupos.

⁴⁴Cios, K.J. y otros (2007). Doctor en Ciencias de la computación por la Universidad de Ciencia y Tecnología de Kracovia, trabajó en la agencia internacional de la energía atómica. Es profesor y jefe del departamento de ciencias de la computación de la Virginia Commonwealth University. Sus trabajos de investigación se centran en machine learning, data mining e informática biomédica.

Figura 8. Métodos para Natural Language Processing y Computer Vision.



Técnicas de Machine Learning

En el proceso de modelización se suele realizar una primera fase de knowledge discovery. Dentro de este proceso se realizan, entre otras, las siguientes tareas (Figura 9):

- ▶ **Entendimiento de los datos:** preparación inicial y análisis descriptivo de los datos, análisis de la calidad de la información, etc.
- ▶ **Preparación de los datos:** limpieza o tratamiento de los datos (incluyendo el tratamiento de missings, outliers, registros erróneos o inconsistentes), análisis multivariante, combinación o creación de nuevas variables a partir de las existentes, reducción del número de variables (vía eliminación de variables redundantes, proyección sobre subespacios de dimensión inferior), etc.
- ▶ **Selección de la técnica apropiada y aplicación de procesos de regularización,** donde se transforman los datos y se preparan para la modelización. Por ejemplo, entre estos métodos se pueden considerar los siguientes:
 - Homogeneización del rango de las variables, por ejemplo restando la media y dividiendo por la desviación típica (normalizar), dividiendo por el rango de la variable (escalar), etc.
 - Identificación de aquellas variables que son más relevantes para el modelo que se quiere construir. Frente a los métodos previos de selección de variables, como el stepwise⁴⁵, se pueden aplicar técnicas como el uso de redes elásticas (*elastic nets*): la función que se utiliza para la estimación de los parámetros del modelo (denominada función objetivo o función de coste, cuyo valor se pretende minimizar) se modifica añadiendo un término adicional para detectar qué variables no aportan información cuando se compara el modelo en muestras de construcción y de test, lo que permite por tanto la selección automática de variables: si L es la

función de coste que se utiliza para obtener los estimadores del modelo, $\beta^t = (\beta_1, \dots, \beta_n)$ los estimadores, y $\lambda_1 \in \mathbb{R}$, $\lambda_2 \in \mathbb{R}^+$, entonces la función se puede transformar con la siguiente expresión⁴⁶:

$$L' = L + \lambda_2 \|\beta\|_2^2 + \lambda_1 \|\beta\|_1$$

En el caso particular en que $\lambda_2=0$, se obtiene el método denominado LASSO, y cuando $\lambda_1=0$ se obtiene el método denominado ridge regression⁴⁷.

Dentro de las técnicas de *Machine Learning* de aprendizaje supervisado cabe mencionar los llamados métodos individuales (Figura 8), denominados así porque pueden utilizarse de forma aislada. Entre ellos destacan las redes neuronales, las máquinas de vector soporte, los clasificadores bayesianos, o los árboles de clasificación y regresión:

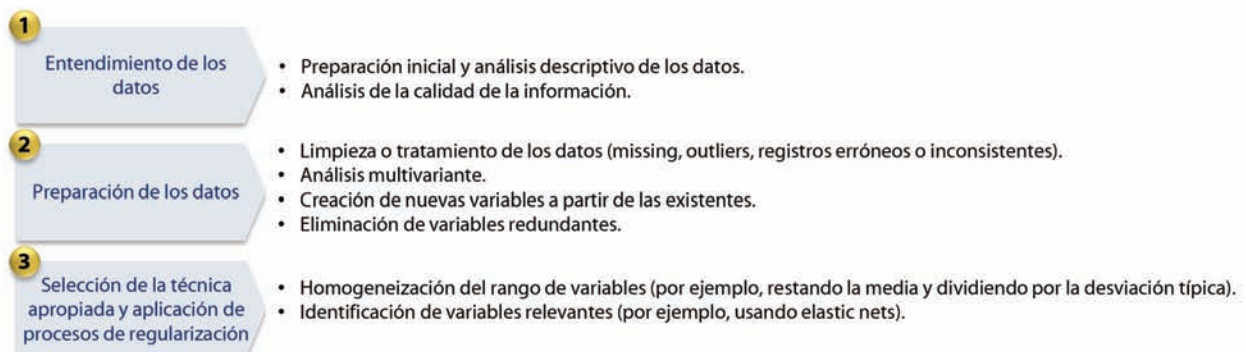
- ▶ Las **redes neuronales** son modelos matemáticos multivariantes no lineales que utilizan procedimientos iterativos, con el objetivo de minimizar una determinada función de error y clasificar así las observaciones. Las redes neuronales se componen de neuronas conectadas entre sí a través de nodos y capas. Dichas conexiones emulan las dendritas y los axones en los sistemas nerviosos biológicos, por los que se traspa información. Se emplean tanto en problemas supervisados como no supervisados, con la ventaja de que pueden separar regiones de forma no lineal. Su mayor desventaja es el carácter de "caja negra", es decir, la dificultad en la interpretación de los resultados y la limitación a la hora de incorporar el sentido de negocio sobre la compleja estructura de pesos.

⁴⁵Es un método iterativo de construcción de modelos basado en la selección automática de variables.

⁴⁶Donde \mathbb{R} representa el conjunto de números reales, \mathbb{R}^+ el conjunto de números reales positivos, $\|\beta\|_2^2 = \sum_j \beta_j^2$ y $\|\beta\|_1 = \sum_j |\beta_j|$

⁴⁷Para una discusión detallada de cada método, ventajas e inconvenientes, véase Murphy, K. (2012).

Figura 9. Tareas en el proceso de modelización.



Como una extensión de las redes neuronales, pueden destacarse las redes profundas, que consisten en el uso de redes neuronales con múltiples capas. Estos modelos, englobados en lo que se denomina aprendizaje profundo o *deep learning*⁴⁸, pueden tener millones de parámetros, en función de la complejidad del problema que se quiera abordar. No obstante, dada la dificultad de estimación, caben múltiples aproximaciones en el uso de este tipo de métodos⁴⁹ (por ejemplo, el uso de algoritmos de optimización para ajustar los parámetros en las redes profundas en función de los errores de sus *outputs*; algoritmos *greedy* para el entrenamiento de redes específicas, como las redes dirigidas; *auto-encoders* para reducción de la dimensionalidad, etc.). Gracias al desarrollo tecnológico, esos métodos se han podido incorporar, por ejemplo, en procesos de reconocimiento y generación automática de textos, o en *computer vision*.

- ▶ Las **máquinas de vector soporte** (*support vector machine* o SVM) son modelos de clasificación que tratan de resolver las dificultades que pueden suponer muestras de datos complejas, donde las relaciones no tienen por qué ser lineales. Es decir, se pretende clasificar a las observaciones en varios grupos o clases, pero estas no son separables vía un hiperplano en el espacio dimensional definido por los datos. Para ello, el conjunto de datos se embebe en un espacio de dimensión superior a través de una función⁵⁰ que permita poder separar los datos en el nuevo espacio a través de un hiperplano en dicho espacio. Entonces, se busca un hiperplano equidistante a los puntos más cercanos de cada clase (es decir, el objetivo es encontrar el hiperplano que separa las clases y que más dista de las observaciones de las mismas de forma simultánea).

⁴⁸Los algoritmos utilizados en *deep learning* pueden ser del tipo de aprendizaje supervisado o no supervisado.

⁴⁹Murphy, K. (2012).

⁵⁰A esta función se le denomina kernel.

Diferencias entre inteligencia artificial, Machine Learning y deep learning

Inteligencia Artificial (IA), *Machine Learning* y *Deep Learning* son conceptos que están relacionados, pero que habitualmente es tedioso vislumbrar la diferencia entre ellos. Con el objetivo de ilustrar dichas diferencias se proporcionan a continuación las siguientes definiciones:

- La inteligencia artificial es el concepto más amplio, cuyo objetivo es que las máquinas sean capaces de realizar tareas de la misma forma en que las haría un ser humano. En la mayoría de los casos, esto se desarrolla a través de la ejecución de reglas previamente programadas. Se definió en la Conferencia de Inteligencia Artificial de Dartmouth (1956) como “todos los aspectos del aprendizaje o cualquier otra característica de la inteligencia que puede, en principio, ser precisamente descrita de tal forma que una máquina pueda realizarla”. Ya desde principios de siglo XX tenemos algunos ejemplos de ello en pioneros como Alan Turing quien descifró la máquina Enigma en lo que fue la primera aparición de lo que hoy llamaríamos las redes neuronales.
- Por otra parte, el aprendizaje automático (ML) puede considerarse como una rama de la IA, y se define⁵¹ como “el conjunto de métodos que puede detectar patrones automáticamente en un conjunto de datos y usarlos para predecir datos futuros, o para llevar a cabo otro tipo de decisiones en entornos de incertidumbre”.
- Por último, el *Deep Learning* o aprendizaje profundo es una rama del *Machine Learning* que, definido en su aspecto más básico, se puede explicar como un sistema de probabilidad que permite a modelos computacionales que están compuestos de múltiples capas de procesamiento aprender sobre datos con múltiples niveles de abstracción⁵².



⁵¹Murphy, K. (2012).

⁵²Bengio, Y. y otros (2015). Yoshua Bengio es científico computacional en Canadá. Principalmente conocido por su trabajo en las redes neuronales y el *Deep Learning*.

- ▶ Los **clasificadores bayesianos** son modelos basados en el teorema de probabilidad condicionada de Bayes, que utilizan la información conocida de las variables explicativas, es decir, los denominados *priors*, para clasificar las observaciones. Dicho de otro modo, un clasificador bayesiano asume que la presencia o ausencia de ciertas características permite asignar cierta probabilidad a la ausencia o presencia de otra característica, o a definir una variable objetivo en función de la relación existente en una muestra entre estas características y la variable objetivo definida. Es una técnica simple pero robusta para clasificar observaciones en un conjunto de clases. El clasificador bayesiano toma formas específicas según la distribución que se asuma que siguen las variables explicativas (normal, multinomial, etc.).
- ▶ Finalmente, **los árboles de clasificación** (cuando la variable objetivo es categórica) **y de regresión** (cuando la variable objetivo es continua) son técnicas de análisis que permite predecir la asignación de muestras a grupos predefinidos en función de una serie de variables predictivas. Los árboles de decisión son modelos sencillos y fácilmente interpretables, lo que hace que sean muy valorados por los analistas. Sin embargo, su poder predictivo puede ser más limitado que el de otros modelos, porque realizan una partición ortogonal⁵³ del espacio, lo que convierte en silos la muestra y limita la capacidad predictiva debido a que este tipo de algoritmo tiende al sobreentrenamiento.

Todos estos métodos individuales pueden combinarse con técnicas y algoritmos que permiten mejorar la capacidad predictiva, a través de métodos ensemble (Figura 10). Estos métodos consisten en la agregación de modelos individuales para generar un modelo más predictivo o más estable que aprovecha el conocimiento del colectivo. Por ejemplo, los modelos se pueden combinar a través del uso de los resultados de modelos independientes (como el caso de la técnica de *bagging*) o tratando de corregir en cada iteración el error cometido (como en el caso del *boosting*).

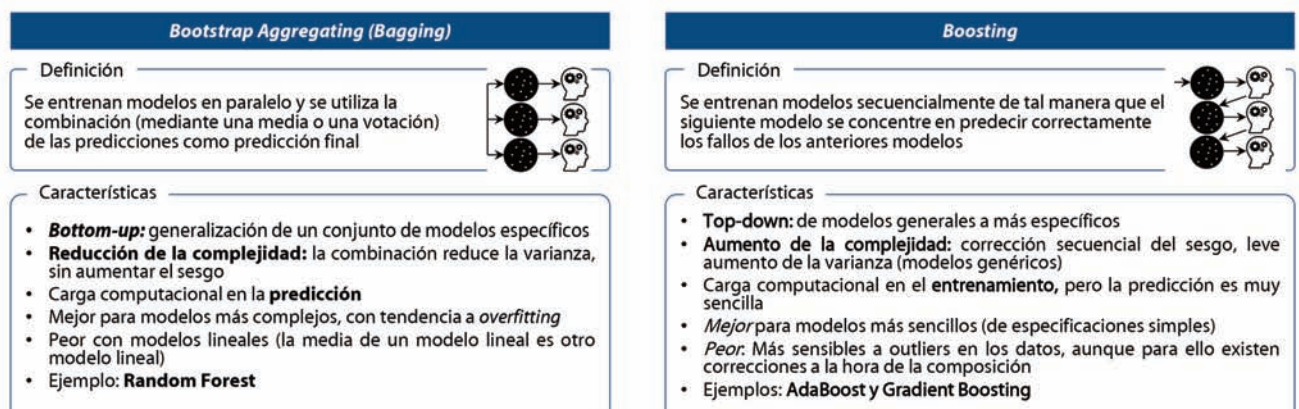
Finalmente, entre los modelos no supervisados cabe destacar las técnicas de *clustering* o las técnicas de *Data Analysis*, como la de reducción de la dimensionalidad:

- El *clustering* es un modelo no supervisado que se utiliza para identificar grupos (*clusters*) o patrones de observaciones similares en un conjunto de datos. Una de las técnicas más utilizadas es el método de k-means, que consiste en definir un punto central de referencia de cada *cluster* (denominado centroide) y asignar a cada individuo al *cluster* del centroide más próximo en función de las distancias existentes entre los atributos de entrada. El algoritmo parte de la fijación de k centroides aleatoriamente y, mediante un proceso iterativo, se asigna cada punto al *cluster* con el centroide más próximo, procediendo a actualizar el valor de los centroides. Este proceso termina cuando se alcanza un determinado criterio de convergencia.
- Los métodos de reducción de dimensionalidad pretenden reducir el número de dimensiones del espacio de análisis, determinado por el conjunto de variables explicativas. Una de las técnicas es el análisis de componentes principales (principal component analysis o PCA), que convierte un conjunto de variables correlacionadas en otro (con menor cantidad de variables) sin correlación, llamadas componentes principales. La principal desventaja de aplicar PCA sobre el conjunto de datos es que estos pierden su interpretabilidad.

En todo caso, la aplicación de estas técnicas implica que los métodos de validación de resultados deben ser más

⁵³Es decir, una partición de un espacio n-dimensional en regiones a través de hiperplanos perpendiculares a cada uno de los ejes que definen las variables explicativas.

Figura 10. Ejemplos de métodos ensemble.





sofisticados. Debido a que en muchos casos el aprendizaje es continuo y utiliza más de una submuestra en la construcción, se han de implementar técnicas que sean adecuadas para estos nuevos procesos, tales como el *bootstrapping*⁵⁴ o el *k-fold cross-validation*⁵⁵, que permiten evaluar el modelo en más de una muestra de validación. Asimismo, debe también ponerse la atención en otros aspectos de la validación, tales como la existencia de posibles sesgos en la frecuencia de actualización de los datos, relaciones espurias o sin una relación causal. Por último, la naturaleza dinámica de estas técnicas dificulta la trazabilidad. Esto cobra especial relevancia en entornos regulados o con supervisión, que exigen un marco de validación y de trazabilidad específico.

Usos y tendencias en aprendizaje automático


El uso del aprendizaje automático en las industrias

La incorporación del aprendizaje automático en el desarrollo de los negocios en las distintas industrias es desigual (Figura 11) tanto en función del sector como de diversos factores relacionados con el tamaño, el estilo de dirección y en general el entorno en el que la empresa opera.

Las técnicas de aprendizaje automático se están implementando con diferente grado de velocidad y profundidad en distintos sectores. Como ejemplos, se destacan algunas aplicaciones en las industrias de la

⁵⁴Generación de muchas muestras de validación a partir de la selección aleatoria con reemplazamiento.
⁵⁵Se parte la muestra en k grupos. En la primera iteración, k-1 se utilizan para la construcción, y el restante para la validación. Este proceso se repite eligiendo como grupo de validación cada uno de los k grupos construidos.

Figura 11. Presencia del desarrollo de Machine Learning en las distintas industrias a 2016.





educación, las finanzas, la salud, o de modo transversal, en la mejora de la eficiencia de las organizaciones^{56,57}:

- ▶ En el ámbito educativo⁵⁸ la inteligencia artificial podrá proveer de sistemas que funcionen como “compañeros de aprendizaje” durante toda la vida del alumno y accesibles a través de múltiples canales.
- ▶ En finanzas, los algoritmos de *Machine Learning* van dirigidos a funciones como el *trading* automático, la creación de *roboadvisors* para la gestión automática de carteras, la detección del fraude o la medición del riesgo. Uno de los ámbitos con mayor crecimiento es el conocido como *RegTech*⁵⁹, en el que se usan técnicas de *Machine Learning* para cumplir con la regulación y la supervisión. Se prevé que el mercado de *RegTech* alcance 6.500 millones de dólares en 2020⁶⁰. Asimismo, estas técnicas pueden utilizarse para el análisis de carteras donde no existe tanta información estructurada almacenada en las bases de datos de las entidades

financieras, como es el ejemplo de los modelos de prospect de no clientes. En este caso, los modelos de prospect pretenden clasificar a potenciales clientes en función de su probabilidad de incumplimiento, lo cual tiene aplicaciones en procesos comerciales como el lanzamiento de campañas o la emisión de nuevos productos. Estos modelos suelen ser también de interés en aquellos segmentos de clientes donde no existe mucha información, como el caso de autónomos y microempresas, o en segmentos de particulares o autónomos no bancarizados. Para ello, se puede utilizar

⁵⁶Kaggle (2017).


⁵⁷Forbes (2017).

⁵⁸Pearson (2016).

⁵⁹RegTech surge de la combinación de los términos “regulatory technology” y consiste en un grupo de compañías que utilizan la tecnología para ayudar a las empresas a cumplir con la normativa de manera eficiente y con bajo coste.

⁶⁰Frost & Sullivan (2017).





información sobre cuentas anuales (incluyendo información sobre actividad, como rotación de inventarios o de proveedores, ratios de apalancamiento, de liquidez, solvencia o rentabilidad), que se complementa con información de productos y servicios, o bien con información externa no estructurada.

- ▶ En el caso del sector de la salud, los esfuerzos se dirigen a mejorar el diagnóstico por imagen, la gestión de consultas de tratamiento y sugerencias, así como la recopilación de información médica para su estudio o la cirugía robótica. Se estima que el mercado de la inteligencia artificial en el campo de la salud puede alcanzar los 6.600 millones de dólares en 2021 y ahorrar potencialmente 150.000 millones de dólares en 2026 en el sector de la salud en EEUU⁶¹.
- ▶ En sectores como la industria o la logística, se plantean soluciones para la mejora del mantenimiento de la maquinaria (a través del uso de modelos y sensorización

para el mantenimiento predictivo) o la eficiencia en la distribución (por ejemplo, mediante la optimización de la correlación entre necesidades de transporte con múltiples empresas)⁶².


- ▶ En relación con la mejora de la eficiencia de las organizaciones, la función de tecnología y operaciones puede ser más proactiva en compañías donde los sistemas tecnológicos generan datos masivos (logs, reportes de estado, archivos de errores, etc.). A partir de esta información, los algoritmos de *Machine Learning* pueden detectar la causa raíz de algunos problemas, o los fallos en sistemas pueden ser mitigados significativamente utilizando analítica predictiva. Asimismo, se pueden incorporar experiencias tecnológicas personalizadas: la disponibilidad de un asistente virtual por empleado ayudará a las compañías a

⁶¹Techemergence (2017).

⁶²Círculo de empresarios (2018).



Figura 12. Tendencias y retos sobre los componentes del aprendizaje automático.



maximizar la productividad en el puesto de trabajo. Este asistente será capaz de conectar información de uso de aplicaciones del usuario con otras bases de datos almacenadas y detectará patrones que anticipen las siguientes acciones y accesos a bases de datos de documentos por parte del empleado.

Como ejemplo ilustrativo de cómo se está realizando la incorporación de estas técnicas en una industria clásica se puede destacar el caso de Rolls-Royce, que ha llegado a un acuerdo con Google para utilizar los motores de *Machine Learning* de Google en *Cloud* con el objetivo de mejorar la eficiencia y la seguridad en la navegación en el corto plazo y con el objetivo de culminar en el control remoto sin tripulación. Este caso recoge todos los elementos típicos del aprendizaje automático: recogida de información no estructurada basada en sensores, tratamiento de información mediante nuevas técnicas, objetivo de automatización completa, etc.

Tendencias sobre los componentes del aprendizaje automático

El uso de distintas técnicas y la proliferación de enfoques y herramientas diversas modifican el proceso de modelización en todas sus aristas: los datos utilizados, nuevas técnicas y metodologías de estimación, y las arquitecturas y sistemas soporte (Figura 12). Sin embargo, este nuevo enfoque conlleva un conjunto de retos desde el punto de vista técnico, metodológico y de negocio⁶³:

1. Según las fuentes de información: se busca obtener una visión 360° de los clientes a través del cruce de canales internos y externos, utilizando datos que se recopilan en tiempo real. Ello conlleva una serie de retos como la inversión económica para acceder a fuentes de información restringidas, la identificación de nuevas fuentes de datos relevantes y su continua actualización, así como la incorporación de técnicas de Data Quality capaces de tratar grandes volúmenes de datos de

distinto tipo en tiempo real. Asimismo, uno de los grandes retos es la aplicación de la regulación en materia de protección de datos, como la GDPR en Europa, que implica un análisis en profundidad de las fuentes de información que pueden ser utilizadas en los modelos de aprendizaje automático, su tratamiento y almacenamiento, así como el establecimiento de controles y sistemas de ciberseguridad.

2. Según las técnicas y algoritmos: aunque incrementa la dificultad en la interpretación de los algoritmos y en la justificación de los resultados obtenidos, en ciertos ámbitos prevalece el poder de predicción sobre dicha interpretación. Todo ello lleva a que sea más relevante implementar una correcta gestión del riesgo de modelo durante el ciclo de vida completo (desarrollo, validación, implementación, uso, mantenimiento y retirada). La naturaleza y las posibles fuentes del riesgo de modelo, como carencias en los datos, la incertidumbre en la estimación o errores en los modelos, y el uso inadecuado del modelo⁶⁴, están igualmente presentes en el uso de técnicas de aprendizaje automático. Asimismo, entre los retos en la resolución de problemas mediante el uso de técnicas de Machine Learning se encuentran la propia elección del algoritmo más adecuado de entre una amplia gama de posibilidades (ya que éste puede depender tanto del objetivo del modelo que se quiere construir como de la información disponible), la aparición de posibles problemas de *overfitting*⁶⁵ y de *data dredging*⁶⁶, o la necesidad de establecer mecanismos para que la aplicación de los resultados

⁶³Jordan, M. I., Mitchell, T. M. (2015) y Kaggle (2017). Jordan, Doctor en Ciencia cognitiva por la Universidad de California, fue profesor del MIT, y actualmente es profesor en el departamento de Ingeniería Eléctrica y Ciencias de la computación y del departamento de Estadística en la universidad de California.

⁶⁴Management Solutions (2014).

⁶⁵*Overfitting*: el modelo está demasiado ajustado a la muestra de entrenamiento, de forma que no consigue resultados satisfactorios sobre muestras diferentes a esta (p. ej. la muestra de validación).

⁶⁶El *data dredging* se produce cuando se encuentran relaciones que no están respaldadas por hipótesis o causas que realmente expliquen dichas relaciones.

automáticos no implique la aparición de tratamientos discriminatorios (este riesgo se trata a través de lo que se conoce como ética algorítmica).

3. Según el autoaprendizaje: incorporar la característica de autoaprendizaje en los modelos implica la capacidad de que el algoritmo se modifique de forma autónoma en función de los cambios que se van produciendo en la población objetivo. Esto puede originar modificaciones en los parámetros o las variables relevantes para construir el algoritmo, así como la necesidad de tomar decisiones de modelización en tiempo real. Sin embargo, estos ajustes a los modelos en tiempo real dificultan su validación que debe evolucionar desde el enfoque tradicional e incorporar nuevos elementos como el control de grados de libertad en la automatización, una mayor frecuencia en la evaluación del poder discriminante u otras técnicas de contraste (por ejemplo, a través de modelos alternativos más sencillos que, aunque pierdan capacidad de ajuste, permitan cuestionar los resultados). En el caso particular de modelos que requieran aprobación supervisora como, por ejemplo, los modelos regulatorios en el sector financiero, un reto añadido a esta validación es la dificultad de obtener la aprobación por parte del supervisor.

4. Según los sistemas y el software utilizado: se invierte en arquitecturas e infraestructuras tecnológicas que garanticen la escalabilidad en la capacidad de almacenamiento de datos y una mayor velocidad de procesamiento. Asimismo, se desarrollan soluciones basadas en *Cloud*, como plataformas alternativas a las implantaciones *in-house* utilizadas tradicionalmente por las empresas, y se incorporan infraestructuras de *edge computing*, donde se ofrecen funciones ya previamente instaladas (FaaS⁶⁷) preparadas para su uso directo, lo que simplifica la experiencia del desarrollador, ya que reduce el esfuerzo de programación y gestión del código. Todo ello conlleva la necesidad de realizar inversiones en recursos y estructuras IT.

Asimismo, todo ello supone la necesidad de contar con recursos humanos con un alto grado de preparación y especialización, capaces de comprender y trabajar con lenguajes de programación, algoritmos, matemáticas, estadística, y arquitecturas tecnológicas complejas.

⁶⁷ *Functions as a Service*, un modelo sin servidores.

Fuentes de información y restricciones regulatorias

La rápida evolución tecnológica y la globalización han planteado nuevos retos en el ámbito de la protección de los datos personales. En este sentido, se ha incrementado de manera significativa la magnitud de la recogida e intercambio de datos personales, y en la actualidad la tecnología permite el tratamiento de los datos personales en una escala sin precedentes.

Estos avances y el uso de fuentes de información que incorporan datos de carácter personal, requieren un marco sólido y coherente para la protección de datos, dada la importancia de generar la confianza que permita el desarrollo de la economía digital. Así, surge la necesidad de que las personas físicas tengan el control de sus propios datos personales, y de reforzar la seguridad jurídica y práctica para las personas físicas, los operadores económicos y las autoridades públicas⁶⁸. Como consecuencia, los reguladores han desarrollado normativas para garantizar la protección de dichos datos. Como ejemplo paradigmático se puede analizar el caso de la Unión Europea, donde la General Data Protection Regulation (GDPR), aplicable desde mayo de 2018, ha establecido una serie de requisitos generales de tratamiento y protección de la información, homogeneizando dicho tratamiento en todos los países miembros (Figura 13).

⁶⁸Parlamento Europeo (2016).

Figura 13. Principales requisitos de la GDPR.



Ejercicio cuantitativo

Your job in a world of intelligent machines is to keep making sure they do what you want, both at the input (setting the goals) and at the output (checking that you got what you asked for)

Pedro Domingos⁶⁹



Las técnicas de *Machine Learning* introducen diversas novedades frente a las técnicas estadísticas y econométricas clásicas, apalancadas en el uso de mayor cantidad de información y mayor complejidad de los algoritmos.

Ello introduce un conjunto de nuevos elementos en el marco de la modelización, que si bien por un lado permite realizar análisis más robustos, por otro requiere resolver cuestiones como el aumento de las variables disponibles (lo que incrementa la complejidad en el tratamiento de los datos así como en la selección de información relevante), la correcta identificación de relaciones espurias o el incumplimiento de las hipótesis de los modelos tradicionales (p. ej. falta de cointegración en series temporales, o presencia de multicolinealidad y autocorrelación).

Como resultado de lo anterior, se puede modificar el enfoque de modelización, introduciendo herramientas diferentes para aprovechar los algoritmos de *Machine Learning*, pero evitando cometer errores ligados a estas nuevas herramientas.

En este apartado se ha desarrollado un modelo de *scoring* comportamental para clasificar préstamos bancarios. Para ello se han utilizado algunas de estas nuevas técnicas con el fin de poder comparar los resultados, así como evaluar los retos que supone su uso en el proceso de modelización, las oportunidades que surgen y los riesgos existentes.

Objetivo

El objetivo del ejercicio es analizar e ilustrar cómo impacta el uso de técnicas de *Machine Learning* en el desarrollo de modelos. Específicamente se persigue evaluar cómo varía el proceso de estimación y los resultados obtenidos, partiendo de distintos enfoques de modelización mediante el uso de técnicas de *Machine Learning*.

Para ello, se ha entrenado un score de comportamiento utilizando distintos enfoques de *Machine Learning*, y se han comparado con las técnicas tradicionales. Se ha partido de una muestra de préstamos y se han desarrollado dos fases de modelización (tratamientos de datos en tareas de preparación, limpieza y selección de variables, y aplicación de diversos enfoques para estimar el modelo). A continuación se describe la muestra utilizada y se detallan las distintas fases del estudio, así como los resultados y principales conclusiones obtenidas.

Datos utilizados

El estudio se ha llevado a cabo utilizando un conjunto de más de 500.000 préstamos, que comprenden más de 10 años de historia, con una tasa de mora del 6%. La muestra incluye variables relativas a la operación (importe, plazo de la operación, tipo de interés, finalidad de la financiación, etc.), al cliente (información económica como los ingresos anuales, mensuales, patrimonio, variables de endeudamiento, puntuación de *scoring* externos, etc., información sobre impagos como quiebras en registros públicos, cuentas con retrasos, etc., o variables de antigüedad como cliente y antigüedad en otros productos), así como relativa a otro tipo de información que puede ser útil en la modelización, como comisiones, número de transacciones realizadas, etc. En este ejercicio, todas estas variables se han mantenido en la muestra inicial con el propósito de realizar *knowledge discovery*.

Desarrollo del estudio

El estudio se ha desarrollado en dos fases, que se detallan a continuación:

Fase 1: Knowledge Discovery. Inicialmente se ha desarrollado una fase de *knowledge discovery*, donde se han realizado distintos tratamientos de *missings*, *outliers* y agrupación de variables.

Fase 2: Aplicación de técnicas de Machine Learning. En una segunda fase se ha procedido a desarrollar distintos modelos, utilizando técnicas de modelización sobre las muestras de construcción generadas.

Fase 1: Knowledge Discovery

La primera fase del desarrollo del ejercicio consiste en aplicar algunas técnicas de *knowledge discovery*. Algunos de los tratamientos aplicados, que se describen a continuación, pueden ser más adecuados que otros, en función del tipo de algoritmo final que se utilice para la modelización. Así, esta primera fase permite obtener un conjunto de muestras de construcción susceptibles de utilización como datos para entrenar distintos algoritmos.

En esta primera fase se ha observado que el 40% de las variables presenta más de un 10% de observaciones *missing*. De cara a utilizar la información disponible, se han realizado distintos tratamientos sobre estas variables⁷⁰:

- Se ha imputado el valor medio (o la moda, en el caso de variables cualitativas) a las observaciones *missing*.
- Se ha lanzado un *clustering analysis*, y se ha asignado a cada valor *missing* la media (o la moda, en el caso de variables cualitativas) del *cluster*. La determinación del número óptimo de *clusters* que genera la mejor clasificación se ha realizado a través de métodos cuantitativos⁷¹.
- Se ha realizado una regresión sobre otras variables para estimar un valor para las observaciones *missing* de una variable en función del resto de información.
- Para el caso específico del *Random Forest* se ha imputado un valor máximo (p. ej. 9999) de cara a identificar el *missing* como un valor adicional para que el árbol cree de forma automática una rama específica para esta información.

Por otro lado, se ha realizado un tratamiento de *outliers*, que por simplicidad ha consistido en aplicar un *floor* en el percentil 1, y un *cap* en el percentil 99 en aquellas variables con presencia de valores atípicos.

Finalmente, se ha realizado un proceso de simplificación de variables. Para ello, se ha vuelto a aplicar un algoritmo de *clustering*, de cara a sustituir aquellas variables que permiten

identificar una buena clasificación en grupos por el *cluster* asignado (Figura 14). Asimismo, también se han eliminado aquellas variables que, tras un primer análisis exploratorio, no contienen información relevante (por mala calidad de la información, variables informadas a un valor constante, etc).

Tras todos estos tratamientos, se han obtenido diferentes muestras de construcción, que se utilizarán para la estimación de los algoritmos⁷².

En conjunto, estas técnicas permiten reducir el número de variables con el objetivo de mejorar la eficiencia de los procesos posteriores, preparar la información existente para que se adecúe a los requisitos específicos de los distintos modelos y posibles limitaciones de los algoritmos, así como anticipar y validar hipótesis para evaluar los resultados de las distintas técnicas de modelización utilizadas.

Fase 2: Aplicación de técnicas de Machine Learning

En la segunda fase, partiendo de las distintas muestras ya tratadas, se han aplicado diferentes técnicas, y se ha procedido a calcular distintas medidas de la capacidad discriminante del modelo sobre una muestra de validación. Las técnicas que se han desarrollado son las siguientes:


- En primer lugar, para poder realizar una comparación con un método tradicional de modelización, se ha construido un modelo logístico.
- Se ha aplicado una red elástica como técnica de regularización, para observar el impacto de esta técnica sobre la modelización tradicional.

⁷⁰Tratamientos adicionales al clásico que consiste en cambiar un *missing* por un cero, y crear una variable *dummy* para reconocer dónde se han imputado los *missing*.

⁷¹Existen diversos métodos cuantitativos para realizar esta selección, como el *elbow method*, o el algoritmo *partition around medoids* (PAM). En términos generales, se pretende analizar el número de *clusters* a partir del cual se hace residual la ganancia marginal de información en la clasificación al ampliar el número de *clusters*. En este caso, se ha aplicado el algoritmo PAM.

⁷²Aunque se pueden tener distintas muestras de construcción para un único algoritmo, y por tanto distintos resultados, en este estudio se muestran solamente los resultados óptimos.

Figura 14. Ejemplos de clustering para K=2, K=4 y K=8 en función de dos variables. Las variables X e Y se sustituirían por la variable que define el cluster.



- c. Se ha desarrollado un *random forest* como uno de los métodos ensemble.
- d. Asimismo, se ha estimado un *adaboost*, para disponer de un segundo método ensemble.
- e. Se ha estimado un modelo a través de una SVM utilizando una función lineal.
- f. Por último, se ha estimado un segundo modelo de SVM con una función radial.

Tras aplicar estas técnicas, se han obtenido los siguientes modelos:

a. Modelo logístico (modelo tradicional base para la comparación). Se ha realizado una preselección de variables mediante técnicas bivariantes y multivariantes, teniendo en cuenta la significatividad individual de cada variable, el poder discriminante del modelo global, y distintos métodos de criterios de información. Como resultado se ha obtenido un modelo que cuenta con 11 variables donde las que presentan mayor importancia son de tipo comportamental (por ejemplo, número de cuentas que nunca han entrado en *default*, si existen adeudos pendientes, o el número de cuentas que alguna vez ha estado más de 120 días en situación irregular). Se ha medido la importancia de cada variable como la contribución marginal de dicha variable a la bondad de ajuste del modelo. Por tanto, se puede analizar cuál es el patrón de incorporación de cada variable en función de su importancia (Figura 15).

b. Modelo con técnicas de regularización. Tras aplicar la red elástica, se ha desarrollado un modelo con un total de 45 variables, entre las que destacan las variables comportamentales (por ejemplo, cuentas en situación irregular, adeudos pendientes en los últimos 12 meses, la información positiva en registros públicos, etc.). Se han incluido variables relativas a la operación y al cliente, si bien la importancia de las primeras es mucho más significativa (Figura 16).

c. Random Forest. Se ha obtenido un algoritmo con 50 árboles, en el que la máxima profundidad de las ramas es 3 y el número de variables incluidas aleatoriamente como candidatas en cada nodo es igual a 7. En total se están utilizando 80 variables para conformar el conjunto de árboles. Las variables con mayor relevancia en el algoritmo son de tipo comportamental (por ejemplo, existencia de adeudos pendientes, otras cuentas con vencimientos incumplidos, número de cuentas activas, etc.), y algunas otras variables que caracterizan al cliente o la operación (por ejemplo el nivel de endeudamiento). Se observa que en términos de importancia, las primeras variables obtienen un elevado peso, mientras que el resto de variables mantienen una importancia relativa reducida (Figura 17).

Figura 15. Importancia de las variables en el algoritmo tradicional.




Figura 16. Importancia de las variables tras aplicar redes elásticas.





Figura 17. Importancia de las variables en el algoritmo de Random Forest.



d. Adaboost. Se ha seleccionado un algoritmo con 20 iteraciones, y cuyo parámetro de reducción se ha fijado por defecto en 1. Como resultado se han obtenido 68 variables significativas entre las que destacan de nuevo las de tipo comportamental (por ejemplo, el promedio del saldo *revolving* en el conjunto de cuentas, el número de cuentas de tarjetas de crédito sin impagos, el principal devuelto por el cliente hasta la fecha, etc.), así como otras variables relativas al cliente (como el FICO). En este caso, se observa un decaimiento reducido pero paulatino en la importancia de las variables (Figura 18).

e. SVM con función lineal. Se han obtenido distintos modelos en función de las variables utilizadas, y se ha seleccionado el mejor modelo utilizando técnicas de validación cruzada. En el modelo elegido se han obtenido 68 variables relevantes, de las cuales las que presentan mayor importancia son las comportamentales; (por ejemplo, los adeudos pendientes en los últimos 12 meses o el porcentaje de cuentas que nunca han estado en situación irregular, Figura 19).

f. SVM con función radial. Al igual que en el caso lineal, se ha hecho una selección de entre diversos modelos. Este modelo también tiene 68 variables, donde las que presentan mayor importancia son asimismo las comportamentales. Aunque ambos modelos de SVM son muy similares, la importancia de las variables en cada uno de ellos difiere notablemente. (Figura 20)

Figura 18. Importancia de las variables en el algoritmo Adaboost.

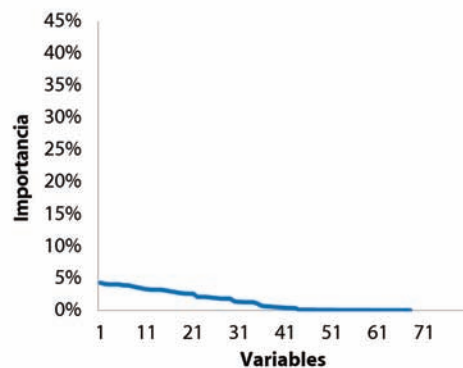


Figura 19. Importancia de las variables en el algoritmo SVM con función lineal.





Figura 20. Importancia de las variables en el algoritmo SVM con función radial.



Detalle de las técnicas utilizadas en el estudio⁷³


Red Elástica. Como se ha descrito en el apartado anterior, la aplicación de la red elástica se realiza mediante la incorporación del término $\lambda_2 \|\beta\|_2^2 + \lambda_1 \|\beta\|_1$ a la función objetivo que se pretende optimizar cuando se estiman los parámetros $\beta^t = (\beta_1, \dots, \beta_n)$.

Para ello, se ha realizado la transformación $\alpha = \frac{\lambda_2}{\lambda_1 + \lambda_2}$ y por tanto se ha estimado el término

$$(1 - \alpha) \cdot \|\beta\|_2^2 + \alpha \cdot \|\beta\|_1$$

Entonces, se procede a construir la devianza de la función de verosimilitud parcial (*partial likelihood deviance*, o PLD⁷⁴) como función de dicho parámetro α , y se busca el mínimo de dicha función. En este caso, el valor mínimo se encuentra en $\alpha=0,8$ (Figura 21). Con dicho valor de α se entrena la función objetivo, de donde se obtienen variables cuyo estimador asociado es cercano a cero, y por tanto no se consideran en la construcción del modelo.

Figura 21. Función de optimización para el método de redes elásticas. Se muestra el valor de α que minimiza la devianza de la función de verosimilitud parcial (PLD)



Random Forest. Esta técnica se basa en las técnicas de combinación de modelos independientes (*bagging*), de forma que se genera un número elevado de árboles y se calcula el promedio de sus resultados. Para realizar cada árbol se asignan aleatoriamente una selección aleatoria de la muestra con reemplazamiento y particiones de las variables con el objetivo de reducir el sobreentrenamiento y controlar la multicolinealidad (Figura 22). Para predecir una nueva observación, se

recorre el árbol en función del valor de sus predictores hasta llegar a uno de los nodos terminales. En el caso de árboles de clasificación, suele emplearse la moda de la variable respuesta como valor de predicción, es decir, la clase más frecuente del nodo. Además, la proporción de árboles que toman una misma respuesta se interpreta como la probabilidad de la misma, lo que aporta información sobre la confianza de la predicción.

Adaboost. En la aplicación de esta técnica se estiman distintos estimadores débiles sobre la muestra que posteriormente se agregan mediante técnicas de *boosting* utilizando distintas ponderaciones, lo que en un contexto iterativo permite al algoritmo aprender de los errores cometidos en las anteriores iteraciones. El proceso es el siguiente:


- Con la muestra de entrenamiento se construye un submodelo asignando pesos equivalentes a todas las observaciones.
- A aquellas observaciones incorrectamente clasificadas se les aumenta el peso relativo, y a aquellas observaciones correctamente clasificadas se les disminuye, y se construye un nuevo submodelo teniendo en cuenta los nuevos pesos. Esto se realiza hasta converger a un nivel de error bajo.
- Se combinan de forma secuencial todos los submodelos obteniendo un modelo final complejo con base en submodelos intermedios simples.

Aplicación de máquinas de vector soporte (SVM). La aplicación de las SVM se ha realizado utilizando dos modelos, uno lineal y otro radial. La diferencia radica en cómo se define la función kernel que permite separar los grupos. La SVM lineal utiliza como función $K(x_i, x_j) = x_i^t x_j$ (el producto escalar). La SVM radial utiliza como función $K(x_i, x_j) = \exp(-\gamma \cdot \|x_i - x_j\|_2^2)$, donde $\gamma > 0$. En los modelos desarrollados, se han utilizado valores de $\gamma=0,014$ para el modelo lineal, y $\gamma=1$ para el modelo radial.

⁷³La descripción de cada una de estas técnicas se puede encontrar en el capítulo anterior, por lo que se procede a incorporar algunos detalles técnicos asociados al uso específico de las mismas.

⁷⁴La devianza de la función de verosimilitud parcial (PLD) es un indicador que permite comparar el poder predictivo de un modelo bajo análisis con el de un modelo de referencia (que puede ser un modelo constante). Se calcula a través de la diferencia de las log-funciones de verosimilitud parcial entre el modelo bajo análisis y el modelo de referencia.

Figura 22. Ejemplo de segmentos de un árbol para el modelo Random Forest.



Resultados y conclusiones

Para comparar los resultados obtenidos en este estudio tras la aplicación de las distintas técnicas, se ha utilizado como medida de poder discriminante una matriz de confusión, así como el área bajo la curva ROC (AUC):


- ▶ La matriz de confusión permite medir las tasas de acierto del modelo. Para ello, se ha fijado el punto de corte en el valor que minimiza el error de la predicción.
- ▶ Respecto al indicador AUC, cuanto mayor es el valor del indicador, mayor es el poder de discriminación. La experiencia práctica⁷⁵ muestra que este indicador suele tomar valores en el rango entre 75% y 90%. Estos indicadores están estimados sobre una muestra de validación⁷⁶.

Asimismo, se ha comparado el impacto que tiene el cambio del poder predictivo en el negocio. Para ello se ha elegido el modelo tradicional como base de comparación (con el punto de corte fijado a partir de la optimización de los errores tipo I y tipo II). Sobre dicho modelo, se ha estimado cuál es la tasa de morosidad resultante con cada uno de los modelos analizados, manteniendo el mismo nivel de tasa de aceptación que el modelo tradicional (es decir, a igualdad del volumen de negocio), así como cuál es la tasa de aceptación de cada uno de los modelos, si se mantiene la misma tasa de morosidad que en el modelo tradicional.

Los resultados obtenidos son los siguientes⁷⁷ (figuras 23, 24 y 25):

- ▶ Tras la comparación con estos estadísticos (Figura 24), se observa un mejor desempeño en los modelos *ensemble* frente al resto de metodologías. En particular, el *random forest* es el método que arroja mejores resultados: en términos de tasa de acierto se eleva desde el 74,7% del modelo tradicional al 80,3%, lo que supone un incremento porcentual de 7,5% sobre el obtenido a través de técnicas tradicionales; en términos de poder discriminante, se consigue mejorar el área bajo la curva ROC desde el 81,5% en el modelo tradicional hasta el 88,2%, lo que representa un incremento porcentual de 8,2%. No obstante, esta mejora se ha conseguido aumentando la complejidad en la estimación, ya que se han utilizado muchas variables entre los 50 árboles estimados.

Figura 24. Tasa de acierto en la matriz de confusión (suma de la diagonal) para los distintos enfoques.



- ▶ El segundo mejor método es la aplicación de la red elástica, con la que se consiguen valores de tasa de acierto y área bajo la curva ROC de 79% y 86,4%, respectivamente. Esto representa un incremento porcentual del 6% en ambos indicadores. Como se observa, en muestras con muchas variables, la aplicación de técnicas de regularización suponen un incremento significativo respecto a métodos tradicionales de selección de variables (*stepwise*).
- ▶ Asimismo, en este caso particular se ha observado que la dificultad añadida por el uso de SVM (tanto lineal como radial) no conlleva un incremento en el poder predictivo del modelo. Esto se debe a que el modelo logístico tradicional ya presenta un poder discriminante elevado (82%), lo que suele ocurrir cuando las variables permiten separar de forma lineal las dos clases, y por tanto la aplicación de SVM no incorpora información sobre la separabilidad de las clases (de hecho, en este caso se pierde poder predictivo y tasa de acierto).

⁷⁵BCBS (2005).

⁷⁶De acuerdo con las prácticas en modelización, se ha separado la población total en muestras diferentes de construcción y de validación, de forma que cada modelo entrenado con la muestra de construcción se ha utilizado para repuntar la muestra de validación, y los resultados sobre la validación se han estimado sobre dicha muestra.

⁷⁷Estos resultados se han obtenido sobre unas muestras de validación específicas, si bien en un entorno de Machine Learning es adecuado evaluar en distintas submuestras la adecuación de los resultados (vía técnicas de bootstrapping o cross-validation).

Figura 23. Resultados para los distintos enfoques.


	Modelo tradicional		Red elástica		Random Forest		Adaboost		SVM Lineal		SVM Radial	
Matriz de confusión	70,3%	1,5%	74,4%	1,2%	75,6%	1,2%	72,4%	1,4%	65,2%	1,8%	67,6%	1,6%
	23,9%	4,4%	19,8%	4,6%	18,5%	4,7%	21,8%	4,5%	29,0%	4,0%	26,5%	4,2%
AUC	81,5%		86,4%		88,2%		83,7%		74,6%		81,1%	
Tasa de mora (igualdad de negocio)	2,1%		1,4%		1,1%		1,7%		2,7%		2,4%	
Tasa de aceptación (igualdad de mora)	71,8%		81,4%		83,2%		76,8%		41,8%		61,4%	

- ▶ Finalmente, desde el punto de vista del posible impacto en el negocio del incremento del poder predictivo de los modelos, se obtiene que, a igualdad de volumen de negocio, la tasa de morosidad se reduciría un 48% en el caso del *random forest* (utilizando un punto de corte óptimo con el modelo clásico, se obtendría una tasa de morosidad de un 2,1%, que se reduce al 1,1% con el *random forest* si se mantiene el volumen de operaciones aprobadas), y un 30% en el caso de la red elástica (donde la tasa de mora se reduce al 1,4%). Asimismo, a igualdad de tasa de morosidad (2,1%), el volumen de negocio se incrementaría un 16% en el caso del *random forest*, y un 13% en el caso de la red elástica.

Para poder beneficiarse de las ventajas asociadas a estas técnicas resulta clave, por tanto, disponer de un marco y una función de gestión del riesgo de modelo acordes con los máximos estándares de calidad (ya tratados en una publicación anterior⁷⁸ de Management Solutions “*Model Risk Management: Aspectos cuantitativos y cualitativos de la gestión del riesgo de modelo*”), que incluya, entre otros aspectos, la ejecución por parte de la función de Validación Interna de un *challenge* efectivo a las hipótesis utilizadas y resultados arrojados por dichos modelos, a través, entre otras técnicas, de la réplica de los mismos y, en aquellas entidades más avanzadas, del desarrollo de modelos “*challenger*” con técnicas tradicionales.

⁷⁸Management Solutions (2014)

Figura 25. Curvas ROC obtenidas para cada una de las técnicas.



La matriz de confusión a partir del punto de corte que minimiza los errores


Una de las técnicas para medir el poder discriminante del modelo es la matriz de confusión. Esta matriz compara la predicción del modelo con el resultado real. En el caso del modelo de *scoring*, permite comparar los *defaults* predichos por el modelo con los que han ocurrido realmente (Figura 26). Para ello, se calculan las tasas de acierto (*defaults* correctamente predichos por el modelo y operaciones clasificadas como *no defaults* que finalmente no han entrado en incumplimiento), y los errores del modelo (los conocidos como error tipo I y error tipo II⁷⁹).

Figura 26. Matriz de confusión.

		Realidad	
		No Default	Default
Predicción	No Default	Acierto	Error tipo I
	Default	Error tipo II	Acierto

Dado que los modelos otorgan una puntuación (que es una ordenación de las operaciones en función de la calidad crediticia), para poder determinar si el modelo predice un *default* es necesario establecer un punto de corte. Una de las metodologías aceptadas en la industria es fijar el punto de corte que minimiza simultáneamente ambos errores (Figura 27).

Figura 27. Punto de corte que minimiza simultáneamente el error tipo I y el error tipo II.



⁷⁹Porcentaje de *defaults* erróneamente clasificados por el modelo, y porcentaje de falsos *defaults* erróneamente predichos por el modelo, respectivamente.

Bibliografía



Acuity Market Intelligence (2016). "The Global Biometrics and Mobility Report: The Convergence of Commerce and Privacy". Market Analysis and Forecasts 2016 to 2022.

BCBS (2005). "Studies on the Validation of Internal Rating Systems". Bank for International Settlements.

Bengio, Y. y otros (2015). Bengio, Y. LeCun, Y. Hinton, G.: "Deep Learning"(2015) Nature.

Box, G. y Draper, N. (1987). "Empirical Model-Building and Response Surfaces". Wiley.

Breiman, L. (2001). "Statistical Modeling: The two cultures", Vol 16 (3), Statistical Science, 2001. pp. 199-231.

Brynjolfsson, E. y McAfee, A. (2017). "The business of artificial intelligence". Harvard Business Review.

Cios, K.J. y otros (2007). Cios, K.J., Pedrycz, W., Swiniarski, R.W., Kurgan, L.: "Data Mining: A Knowledge Discovery Approach". Springer 2007.

Círculo de Empresarios (2018). "Alcance e implicaciones de la transformación digital: principales ámbitos de actuación".

Cisco (2017). "The Zettabyte Era: Trends and Analysis". White paper. Junio 2017.

Cybersecurity Ventures (2017). Cyber economy research.

- Dahr, V. (2013). "Data Science and prediction". Association for Computer Machinery.
- Digital Consumption (2016). World Economic Forum White Paper Digital Transformation of Industries.
- Domingos, P. (2012). "A few useful things to know about Machine Learning", Vol 55 (10), Communications of the ACM, 2012. pp. 78-87.
- Domingos, P. (2015). "The Master Algorithm: How the Quest for the Ultimate Learning Machine Will Remake Our World". 2015.
- EC (2017). Digital Transformation Scoreboard 2017. European Commission.
- Fitzgerald et al. (2013). "Embracing Digital Technology: A New Strategic Imperative, Sloan Management Review
- Forbes (2015). "Big Data: 20 Mind-Boggling Facts Everyone Must Read".
- Forbes (2016). "Artificial Intelligence Is Helping Doctors Find Breast Cancer Risk 30 Times Faster".
- Forbes (2017). Janakiram MSV: "3 Key Machine Learning Trends To Watch Out For In 2018". Forbes, diciembre 2017.
- Friedman, J. H. (1997). "Data mining and statistics: what's the connection?" Presented at the 29th Symposium on the Interface: Computing Science and Statistics, May 14–17, 1997, Houston, TX, pp. 3–9.
- Frost & Sullivan (2017). "Global Forecast of RegTech in Financial Services to 2020".
- International Telecommunication Union (2009). "Distributed Computing: Utilities, Grids & Clouds". ITU-T Technology Watch Report 9.
- International Telecommunication Union (2017). ITU World Telecommunication/ICT indicators database 2015.
- Jordan, M. I., Mitchell, T. M. (2015). "Machine learning: Trends, perspectives, and prospects", Vol 349 (6245), Science, 2015. pp. 255-260.
- LEGOs (2018). Still "The Apple of Toys"? Harvard Business School
- Management Solutions (2014). "Model Risk Management: Aspectos cuantitativos y cualitativos de la gestión del riesgo de modelo".
- Management Solutions (2015). "Data Science y la transformación del sector financiero".
- McKinney (2018). "Python for Data Analysis". O'Reilly Media.
- Ministerio de Industria, Energía y Turismo. Gobierno de España (2018). "Nuevas tendencias y desafíos en el mundo de los datos". Marzo 2018.
- Mitchell, T. (1997). Machine Learning. McGraw Hill.
- Murphy, K. (2012). "Machine Learning: A probabilistic perspective". The MIT Press.
- Parlamento Europeo (2016). Reglamento (UE) 2016/679 del Parlamento Europeo y del Consejo de 27 de abril de 2016.
- Pearson (2016). Lukin, R. et al: "Intelligence Unleashed: An argument for AI in Education". Pearson.
- Samuel, A. (1959). "Some studies in machine learning using the game of checkers". IBM Journal. July 1959.
- Schwab, K. (2016). "The Fourth Industrial Revolution". World Economic Forum.
- Shalev-Shwartz, S. y Ben-David, S. (2014). "Understanding Machine Learning: From Theory to Algorithms". Cambridge University Press.
- Statista (2017). "Number of Machine-to-Machine (M2M) connections worldwide from 2014 to 2021". 2018.
- Statista (2018). "Digital Market Outlook". 2018.
- Techemergence (2017). "How America's 5 Top Hospitals are Using Machine Learning Today".
- The Economist (2017). Axel Springer's digital transformation.
- Turing, A.M. (1950). "Computer Machinery and Intelligence". Mind 49: p433-460.
- Westerman, G. (2017). "Your Company Doesn't Need a Digital Strategy". MITSloan Management Review.

Glosario



Análisis de componentes principales (PCA): es una técnica utilizada para describir un set de datos en términos de nuevas variables (componentes) no correlacionadas. Los componentes se ordenan por la cantidad de varianza original que describen, por lo que la técnica es útil para reducir la dimensionalidad de un conjunto de datos. El PCA busca la proyección según la cual los datos queden mejor representados en términos de mínimos cuadrados.

Auto-encoder: es una red neuronal utilizada para aprender codificaciones (por ejemplo, reducción de dimensionalidad, compresión, cifrado) eficientes.

Big Data: Cualquier cantidad voluminosa de datos estructurados, semiestructurados o no estructurados que tienen el potencial de ser extraídos para obtener información. Por extensión, se refiere también al conjunto de infraestructuras y arquitecturas tecnológicas que almacenan dichos datos.

Blockchain: estructura de datos que implementa un registro criptográfico de todas las operaciones realizadas y previamente validadas por una red de nodos independientes a través de un algoritmo de consenso.

Bootstrapping: Método de remuestreo que se utiliza para aproximar la distribución en el muestreo de un estadístico. Utilizado frecuentemente para aproximar el sesgo o la varianza de un análisis estadístico, así como para construir intervalos de confianza o realizar contrastes de hipótesis sobre parámetros de interés.

Business to Business (B2B): transacciones comerciales entre empresas, es decir, aquellas que se establecen entre un fabricante y el distribuidor de un producto, o entre el distribuidor y un minorista.

Cadena de Markov: proceso estocástico discreto en el que la probabilidad de que ocurra un evento depende únicamente del suceso anterior.

Ciberseguridad: conjunto de herramientas, políticas, métodos, acciones, seguros y tecnologías que pueden utilizarse para proteger los distintos activos tecnológicos y los datos de una organización almacenados en algún tipo de soporte físico o lógico en el ciberentorno, así como las comunicaciones entre dichos activos.

Computer Vision: subcampo de la inteligencia artificial, cuyo propósito es programar un computador para que entienda una escena o las características de una imagen.

Curva ROC (Receiver Operating Characteristic): curva empleada para analizar el poder predictivo de un modelo de salida binaria. Representa la relación entre el error de tipo 1 (clasificar incorrectamente sucesos adversos) y el error tipo 2 (clasificar incorrectamente sucesos favorables).

Data dredging: en *Data Mining* se analizan grandes volúmenes de datos buscando posibles relaciones entre los mismos. El *data dredging* se produce cuando se encuentran relaciones que no están respaldadas por hipótesis o causas que realmente expliquen dichas relaciones.

Función de coste: función que, a partir de un valor de los estimadores de un modelo, da una medida del error que se comete al utilizar el modelo. El proceso de entrenamiento de un modelo suele consistir en obtener los estimadores que minimizan la función de coste.

Function as a Service (FaaS): categoría de servicios de programación en la nube que provee una plataforma que permite a los usuarios desarrollar, usar y administrar funcionalidades de una aplicación sin la complejidad de construir y mantener la infraestructura típicamente asociada a dicha aplicación.

Graphics Process Unit (GPU): coprocesador dedicado al procesamiento de gráficos u operaciones de coma flotante para aligerar la carga de trabajo del procesador central (CPU).

Greedy: algoritmo en el que cada elemento a considerar se evalúa una única vez, siendo descartado o seleccionado, de tal forma que si es seleccionado forma parte de la solución, y si es descartado, no forma parte de la solución ni volverá a ser considerado para la misma.

Internet de las cosas (IoT): interconexión digital de objetos cotidianos (conexión avanzada de dispositivos, sistemas y servicios) con internet, lo que permite enviar y recibir datos de dichos objetos sin necesidad de intervención humana.

k-fold cross validation: proceso de validación de muestras cruzadas que consiste en dividir la muestra en "k" grupos, y de forma iterativa utilizar cada uno de los grupos para la validación y el resto para la construcción, cambiando el grupo de validación en cada iteración.

Knowledge discovery: proceso de identificar patrones en los datos que sean válidos, nuevos, potencialmente útiles, y entendibles.

Machine to Machine (M2M): conectividad entre máquinas donde, una vez que una acción es realizada, los datos generados por los distintos elementos digitales involucrados se conectan con servidores con el objetivo de almacenar y analizar la información.

Overfitting (sobrentrenamiento): característica de un modelo que se da cuando este se ha ajustado demasiado a la muestra de entrenamiento, de forma que no consigue resultados satisfactorios sobre muestras diferentes a esta (por ejemplo sobre la muestra de validación).

Partial likelihood deviance (PLD): indicador que permite comparar el poder predictivo de un modelo bajo análisis con el de un modelo de referencia (que puede ser un modelo constante). Se calcula a través de la diferencia de las log-funciones de verosimilitud parcial entre el modelo bajo análisis y el modelo de referencia.

Partición ortogonal: partición de un espacio n-dimensional en regiones a través de hiperplanos perpendiculares a cada uno de los ejes que definen las variables explicativas.

Peer to Peer (P2P): red de ordenadores que permiten el intercambio directo de información en cualquier formato, entre los ordenadores interconectados.

Regtech: combinación de los términos *regulatory technology*, que alude a una compañía que utiliza la tecnología para ayudar a las empresas a cumplir con la normativa de manera eficiente y con un coste reducido.

Regularización: técnica matemática que consiste en añadir un componente a la función de coste para detectar aquellas variables que no están aportando al modelo información significativamente diferente. Se utiliza para evitar problemas de *overfitting* (como, por ejemplo, el caso de las redes elásticas).

Resampling: conjunto de métodos que permite obtener nuevas muestras de datos a partir de un conjunto de datos determinado, diferentes a éste, pero representativas de la misma población (por ejemplo, el *bootstrapping*). Se utiliza principalmente para crear subconjuntos de entrenamiento y validación sobre la muestra original.

Roboadvisor: algoritmo automático que proporciona asesoramiento y gestión online con una mínima intervención humana. Este servicio se suele prestar típicamente para la gestión de inversiones financieras a través de web facilitando la creación de una cartera de inversión personalizada y adaptada al contexto de cada persona.

Robotics Process Automation (RPA): desarrollo de software que replica las acciones de un ser humano, interactuando con la interfaz de usuario de un sistema informático.

Smart contract: contrato programable que implementa reglas de negocio, cuyo código queda registrado y puede ser ejecutado de forma distribuida por los diferentes nodos de la red.

Stepwise: método iterativo de construcción de modelos basado en la selección automática de variables.

Nuestro objetivo es superar las expectativas de nuestros clientes convirtiéndonos en socios de confianza

Management Solutions es una firma internacional de servicios de consultoría centrada en el asesoramiento de negocio, finanzas, riesgos, organización y procesos, tanto en sus componentes funcionales como en la implantación de sus tecnologías relacionadas.

Con un equipo multidisciplinar (funcionales, matemáticos, técnicos, etc.) de 2.000 profesionales, Management Solutions desarrolla su actividad a través de 24 oficinas (11 en Europa, 12 en América y 1 en Asia).

Para dar cobertura a las necesidades de sus clientes, Management Solutions tiene estructuradas sus prácticas por industrias (Entidades Financieras, Energía y Telecomunicaciones) y por líneas de actividad (FCRC, RBC, NT) que agrupan una amplia gama de competencias: Estrategia, Gestión Comercial y Marketing, Gestión y Control de Riesgos, Información de Gestión y Financiera, Transformación: Organización y Procesos, y Nuevas Tecnologías.

El área de I+D da servicio a los profesionales de Management Solutions y a sus clientes en aspectos cuantitativos necesarios para acometer los proyectos con rigor y excelencia, a través de la aplicación de las mejores prácticas y de la prospección continua de las últimas tendencias en *data science*, *machine learning*, modelización y *big data*.

Javier Calvo

Socio de Management Solutions
javier.calvo.martin@msgermany.com.de

Manuel A. Guzmán

Gerente de I+D de Management Solutions
manuel.guzman@msspain.com

Daniel Ramos

Metodólogo de I+D de Management Solutions
daniel.ramos.garcia@msspain.com



Management Solutions, servicios profesionales de consultoría

Management Solutions es una firma internacional de servicios de consultoría, centrada en el asesoramiento de negocio, riesgos, finanzas, organización y procesos.

Para más información visita www.managementsolutions.com

Síguenos en: 

© **Management Solutions. 2018**
Todos los derechos reservados

www.managementsolutions.com

Madrid Barcelona Bilbao London Frankfurt Paris Warszawa Zürich Milano Roma Lisboa Beijing New York Boston Atlanta
Birmingham San Juan de Puerto Rico Ciudad de México Medellín Bogotá São Paulo Lima Santiago de Chile Buenos Aires