



Facultad de Ciencias Económicas y Empresariales

IMPACTO DEL MACHINE LEARNING EN EL SISTEMA FINANCIERO

Autor/a: Teresa Francés Monedero
Director/a: José Luis Arroyo Barrigüete

MADRID | ABRIL 2020

ÍNDICE

| | |
|--|-----------|
| Resumen | 4 |
| Abstract | 4 |
| Palabras clave | 5 |
| Keywords | 5 |
| Introducción | 6 |
| Justificación de interés en el trabajo / Objetivos | 6 |
| Metodología | 7 |
| Partes principales del TFG | 7 |
| Estado de la cuestión y revisión de la literatura | 8 |
| Definición y tipos de ML | 8 |
| Historia de la IA | 9 |
| Percepción socioeconómica | 11 |
| Situación actual | 12 |
| ¿Por qué el sector financiero? | 13 |
| Como implementar ML | 14 |
| Aplicación en diferentes ramas del sistema financiero | 16 |
| Detección de fraude | 16 |
| Predecir riesgo de crédito | 18 |
| ML en los mercados bursátiles | 20 |
| Chatbots | 22 |
| Roboadvisors | 24 |
| Análisis de documentos | 25 |
| Ventajas y desafíos de la aplicación del ML | 26 |
| Ventajas de implementar ML en el sistema financiero | 26 |
| Machine Learning como ventaja competitiva | 26 |
| Automatización de tareas manuales | 26 |
| Creación de empleo..... | 28 |
| Objetividad | 28 |
| Rapidez..... | 30 |
| Nuevos participantes | 31 |
| Desafíos que presenta el ML en el sector financiero | 32 |
| Contratación de talento..... | 32 |
| El acceso a los datos es crítico | 32 |
| Pequeño grupo de competencia..... | 34 |
| Pasar del “laboratorio a la acción” | 35 |
| Problemas éticos y legales..... | 35 |
| Barrera humana | 38 |
| Conclusión | 39 |
| Bibliografía | 42 |
| Anexos | 48 |

ÍNDICE DE FIGURAS

| | |
|--|----|
| Figura 1: Metodología CRISP-DM | 14 |
| Figura 2: Proceso de algo-trading..... | 22 |

Resumen

Este trabajo proporciona un estudio sobre el impacto del machine learning en el sistema financiero. Su interés radica en que el aprendizaje automático es la disciplina de la inteligencia artificial más utilizada en la actualidad en el sector financiero, porque tiene la capacidad de procesar la ingente cantidad de datos disponibles y transformarlos en información con valor de negocio. Se presenta un análisis cualitativo de fuentes secundarias sobre el concepto de inteligencia artificial y machine learning, las aplicaciones de sus algoritmos en el sector financiero y las ventajas y desafíos de esta tecnología. El estudio realizado concluye que la aplicación del machine learning va a transformar el sector de forma positiva, permitiendo a los asalariados optimizar su tiempo y colaborar con las máquinas para que estas realicen las tareas monótonas. Para explotar los beneficios del aprendizaje automático, las entidades financieras deben desarrollar una estrategia para implementar los algoritmos con eficacia y estar dispuestas a cambiar su cultura de trabajo. La forma de abordar la cuestión del aprendizaje automático en las entidades financieras definirá su cuota de mercado.

Abstract

This report studies machine learning's impact on the financial services industry. Its interest lies in the fact that machine learning is the current most widely used discipline of artificial intelligence in the financial sector because it has the capacity to process the vast amount of data available and transform it into business value information. A qualitative analysis of secondary sources has been carried out in order to analyse artificial intelligence and machine learning, the applications of machine learning algorithms in the financial sector and the advantages and challenges that this technology presents. The study concludes that the application of machine learning will transform the financial system positively, allowing employees to optimise their time, enabling machines to perform monotonous tasks. In order to exploit machine learning's benefits, financial institutions must develop a strategy to implement these algorithms effectively and be willing to change their working culture. The way in which financial institutions deal with machine learning will determine their future market share.

Palabras clave

Aprendizaje automático, inteligencia artificial, sector financiero, algoritmos, impacto, transformación.

Keywords

Machine learning, artificial intelligence, financial sector, algorithms, impact, transformation.

Introducción

Justificación de interés en el trabajo / Objetivos

“The banks that don't invest in AI will lose ground and will have a long, difficult catchup process” Daniel Pinto, JPMorgan co-president (United Consulting Group, 2018: 2).

Vivimos una era tecnológica fascinante de innovaciones constantes, donde sólo el paso del tiempo va descubriendo la potencialidad de cada una de ellas. En agosto de 1981, IBM creó el primer ordenador personal, con la intención de optimizar el lanzamiento balístico, dando comienzo a un proceso de desarrollo de otros muchos aprovechamientos que han cambiado nuestra sociedad. Con la tercera revolución industrial, internet, fue tomando relevancia el teléfono móvil, como el dispositivo personal de gestión de la información y de servicios, también financieros. Ya está llamando a la puerta la computación cuántica; recientemente, en octubre de 2019, Google informó haber logrado en tres minutos y veinte segundos una operación para calcular números aleatorios, que al ordenador convencional más potente de la actualidad le llevaría miles de años.

El aumento de la capacidad de proceso y el acceso a información individualizada, por el uso masivo de dispositivos móviles y de las redes sociales, ha permitido transformar esos datos dispersos en información, identificando necesidades, gustos y hábitos de consumo en tiempo real, que potencian el marketing directo. En resumen, John Naisbitt (autor de Megatrends) "Tenemos por primera vez una economía basada en un recurso clave (la información) que no solamente es renovable, sino que se auto-genera. El problema no es que se nos acabe, sino que nos ahogemos en ella" (Naisbitt, 1984: 23). En definitiva, el crecimiento rápido y exponencial de las nuevas tecnologías, hace necesario profundizar en su impacto.

La metodología utilizada en la analítica de negocio, o de sus clientes, se denomina Machine Learning, una de las aplicaciones de la Inteligencia Artificial. A partir de observaciones se modela la información con intención de describir (qué paso), diagnosticar (por qué paso), predecir (qué va a pasar) o prescribir (cómo puedo hacer que pase).

En concreto, este trabajo introduce esa metodología, el aprendizaje automático, y estudia su impacto en el sistema financiero, un sector rico en datos que por su capacidad innovadora ya ha implementado esta tecnología con éxito y es uno de sus principales inversores e impulsores. Nos centraremos, por tanto, en el aprendizaje automático, porque es la rama de la inteligencia artificial más aplicada en el sector.

El estudio se realizará mediante un análisis cualitativo de fuentes secundarias externas. Para alcanzar las conclusiones sobre su impacto, se explicará el concepto de inteligencia artificial y de aprendizaje automático, las diferentes aplicaciones de estos algoritmos en el sector financiero y se analizarán las ventajas y los desafíos que presentan.

Metodología

Para llegar a estos objetivos, se utilizará una metodología inductiva, donde la pregunta de investigación será cómo es el impacto del Machine Learning en el sistema financiero. La recogida de datos se hará mediante un análisis cualitativo de fuentes secundarias externas mediante el web research y la lectura individual de textos como libros, revistas, y artículos.

Partes principales del TFG

Este trabajo se estructura en tres partes. En primer lugar, se explica en qué consiste la inteligencia artificial y el machine learning, desarrollando los diferentes tipos de algoritmos que existen, para a continuación justificar su relevancia en el sector financiero y por qué es necesario estudiar su impacto. En segundo lugar, se exponen las diferentes aplicaciones del machine learning en el sector financiero y qué utilidad tienen sus algoritmos en las diferentes funciones del sector. Por último, se evalúa su impacto, enunciando las ventajas y desafíos que presentan en las entidades financieras; para concluir con una valoración global de su implementación.

Estado de la cuestión y revisión de la literatura

Definición y tipos de ML

El aprendizaje automático (Machine Learning, en adelante “ML”) es una rama de la inteligencia artificial (en adelante “IA”) que programa a las máquinas con algoritmos para optimizar su funcionamiento y permitir que aprendan utilizando datos de muestra o la experiencia. En otras palabras, que las máquinas aprenden sin ser programadas.

Cuando estas técnicas se aplican a grandes bases de datos, se denomina “Minería de Datos”. El nombre proviene de las minas, de las cuales se extraen una poca cantidad de materiales preciosos. De igual manera, cuando se analiza una gran cantidad de datos, se extrae una pequeña cantidad de datos que aportan información (valor) (Alpaydin, 2014).

Dentro del ML se diferencian el aprendizaje supervisado, el aprendizaje no supervisado, el aprendizaje por refuerzo, y el aprendizaje profundo.

En el aprendizaje supervisado, el algoritmo es capaz de replicar un proceso, donde tanto sus entradas como sus salidas correctas son dadas al programa. A partir de estas entradas y salidas, identifica el juicio llevado a cabo para poder replicarlo en el futuro. Así, su objetivo es predecir el comportamiento o tomar decisiones basándose en datos dados. Esto implica que la precisión del aprendizaje supervisado depende de la calidad y cantidad de los datos. Dependiendo de las salidas se diferencia entre problemas de regresión y de clasificación. Si es un valor numérico corresponde a regresión. Si es un patrón hablamos de clasificación.

Por el contrario, en el aprendizaje no supervisado, el programa solo conoce los datos de entrada. Busca relaciones sin establecer la variable a predecir. No necesita estudiar el proceso llevado a cabo con anterioridad, si no que conglomerar datos por semejanzas entre ellos. Por tanto, su objetivo es encontrar las similitudes entre los datos. Establece los patrones que aparecen con más frecuencia como normas para su clasificación. Así, su eficacia depende de la semejanza de los datos.

El aprendizaje por refuerzo, es un proceso de prueba y error en el que el programa toma decisiones y recibe recompensas, si el proceso es correcto, y castigos, si el proceso es

incorrecto. Tras varios intentos, el programa desarrolla un algoritmo con la política correcta a seguir.

Por último, el aprendizaje profundo es aquel compuesto por varios algoritmos funcionando en paralelo, cada uno proporciona un nuevo límite a los datos ya procesados. Como si fuera un embudo, el número de datos se va reduciendo a medida que supera las diferentes capas de algoritmos. Esta red de algoritmos recibe el nombre de redes neuronales artificiales, inspirado en las funciones de las redes neuronales del cerebro.

Historia de la IA

El concepto de inteligencia artificial es complejo de describir. Fue descrito por primera vez en una conferencia en el Dartmouth College en el verano de 1956 por John McCarthy como “la ciencia y la tecnología de crear máquinas inteligentes” (Shmelova, Sikirda & Sterenharz, 2019: 38). Una definición más actualizada es la de la Comisión Europea, la cual entiende que son “los sistemas que manifiestan un comportamiento inteligente, pues son capaces de analizar su entorno y pasar a la acción –con cierto grado de autonomía– con el fin de alcanzar objetivos específicos” (Comisión Europea, 2018). En conclusión, es la ciencia cuyo objetivo es alcanzar la inteligencia a nivel humano.

Para entender el concepto de inteligencia a nivel humano, es necesario diferenciar entre inteligencia artificial general y específica. Como su propio nombre indica, la inteligencia específica es aquella que tiene capacidad para desarrollar una función concreta, mientras la general es una inteligencia global, siendo esta última la inteligencia humana.

McCarthy defendió que el sentido común es fundamental para replicar la inteligencia humana. Estudió la forma en la que la gente usa lo que sabe y lo que se le ha dicho para averiguar qué hacer. Para él, el aprendizaje y el sentido común estaban ligados: "Nuestro objetivo final es hacer programas que aprendan de su experiencia de manera tan eficiente como los humanos" (McCarthy, 1960: 78); defendía que el rendimiento de las máquinas mejora con el asesoramiento y no con la reprogramación. Así su sistema se denomina “Advice Taker”, que consiste en la construcción de un programa que razona y deduce el comportamiento a seguir. De esta manera llegó a la conclusión de que “Un programa tiene sentido común si deduce automáticamente por sí mismo una clase suficientemente amplia de las consecuencias que provoca cualquier cosa que se le dice y lo que ya sabe”

(McCarthy, 1960: 78). El problema con esta propuesta es que hemos de ser capaces de explicar a la máquina ese algo que tiene que aprender. Por ello su estudio tiene como base la conjetura de que todos los aspectos del aprendizaje o de la inteligencia pueden ser descritos con tal precisión que una máquina puede simularla (McCarthy, Minsky, Rochester & Shannon, 2006). Como ya supuso McCarthy, actualmente, existe la inteligencia artificial específica, pero no se ha podido crear una verdadera inteligencia artificial de tipo general.

En 1950 A. M. Turing, intento responder a la cuestión sobre si las máquinas podían pensar, inventando un modelo que determinase si una máquina era capaz o no. Llegó a la conclusión de que las definiciones pensar y máquina, tal y como están formuladas no permiten responder a la pregunta. Así, inventó la prueba “Imitation Game” (“Juego de Imitación”) para no basarse en palabras con tanta ambigüedad. La pregunta que se planteó se parecía más a ¿Puede una máquina comportarse como una persona pensante? (Levesque, 2017). Turing desvió la atención de cómo era la máquina físicamente, como se creó; a su comportamiento externo, defendía que una máquina que pudiese pensar no necesitaba parecer humana físicamente. Por este motivo, su juego es a ciegas. Debe contar con tres participantes: una persona, una máquina y un interrogador, el cual está en una sala aparte, no se le permite ver a los otros participantes. Al final del juego, el interrogador debe averiguar quién es la máquina y quién es la persona a base de preguntas sin ningún límite de temas ni cantidad. Lo único que no puede pedir a los interrogados son demostraciones prácticas. Si no consigue distinguirlos, entonces podremos decir que la máquina piensa.

En la década de 1980, el filósofo John Searle se opuso a esta teoría, basando su desacuerdo en un posible caso del “Imitation Game”. Donde la conversación era en chino y la persona que participaba no hablaba chino. No obstante, la persona entraba en la sala con un libro. Este, contenía la programación informática que utiliza la máquina para responder en chino. Manifestó que, con la ayuda de este libro, el humano, pese a no entender chino, podría simular el mismo programa que utiliza la máquina y ser capaz de mantener una conversación con el interlocutor, sin entender lo que dice. Con este ejemplo, defiende que no es suficiente con pasar la prueba de Turing. El comportamiento externo de la persona, sería perfecto, pasaría la prueba Turing, pues no se le diferenciaría de un

nativo. No obstante, no entiende chino, por lo que la prueba no es suficiente (Levesque, 2017). Este argumento recibe el nombre de “Sala China”.

Una discrepancia de este último argumento, es que no es la persona quien responde, sino el libro. En respuesta Searle, añadió una condición más a su hipotético caso expuesto: la persona memoriza el libro y no lo utiliza durante la prueba, por lo que la respuesta ya sí que la origina la persona. Pero este argumento deja cuestiones sin resolver: ¿Cómo sabemos que al memorizar el libro, la persona no acaba entendiendo chino? y ¿Cómo debe de ser ese libro para que la persona pueda responder a cualquier pregunta del interrogador?. Levesque, en su libro “*Common sense, the turing test, and the quest for real AI*” manifiesta nula la teoría de Searle. Explica que si el libro en lugar de chino contuviera la suma de veinte números de diez dígitos; un libro que enumerase todas las posibles combinaciones, como sugirió Searle, no podría existir, ya que “necesitaría contener 10^{200} entradas distintas, sin embargo, todo nuestro universo físico sólo tiene alrededor de 10^{100} átomos” (Levesque, 2017: 12). Defiende la posibilidad de crear un libro que explique cómo sumar, así si la persona memorizase el libro, como dijo Searle, la persona aprendería a sumar. Haciendo válido el “Imitation Game”. Por tanto, podremos decir que hemos alcanzado la inteligencia artificial cuando el “Imitation Game” se supere.

En junio de 2014, un programa informático llamado Eugene, se hizo pasar en el Juego de Imitación por un niño ucraniano de 13 años llamado Eugene Goostman y consiguió convencer a un tercio de los humanos con los que conversó. Así, Eugene fue declarado el primer IA que superó la prueba de Turing (Ackerman, 2014).

Percepción socioeconómica

A lo largo de la historia, las nuevas tecnologías (ej. Internet) han provocado una transformación socioeconómica, lo que genera inquietud. Asimismo, la visión sobre el futuro de la IA no es unánime, existen diferentes puntos de vista.

Existe un movimiento que se opone a los avances tecnológicos: el neoludismo, que presenta ideas similares al ludismo del siglo XIX. El ludismo fue un movimiento que surgió en Gran Bretaña en plena revolución industrial, que rechazaba la aparición de maquinaria, por miedo a la reducción de mano de obra. Fue un movimiento violento. El neoludismo se diferencia en que es un movimiento pasivo. Niega el valor positivo del

desarrollo tecnológico, considerándolo perjudicial para los seres humanos, la naturaleza y la sociedad en su conjunto. Ray Kurzweil, inventor de los programas de OCR: reconocimiento óptico de caracteres, sostiene que este movimiento se irá extendiendo conforme la IA se implemente en la vida cotidiana de las personas. Además, defiende que la evolución del hombre va ligada a la tecnología (Kurzweil, 1999).

Asimismo, un estudio realizado por Timo Gnambs y Markus Appel comprobó que el 72% de la población cree que los robots les sustituirán en su lugar de trabajo, por ello, solo el 57% aceptaría trabajar con un asistente robótico (Gnambs, Appel & Batinic, 2010).

Por otro lado, la Comisión Europea defiende que la IA es la tecnología más estratégica de nuestro siglo. “Es mucho lo que está en juego. Nuestra forma de abordar la cuestión de la IA definirá el mundo en el que vamos a vivir” (Comisión Europea, 2018: 2). Como defiende Andrew Ng, cofundador de Coursera: "AI es la 'nueva electricidad', así como la electricidad transformó muchas industrias hace unos cien años; AI cambiará ahora las grandes industrias" (Lynch, 2017).

Ambos puntos de vista tienen un argumento en común: la IA va a dar un giro al mundo en el que vivimos, ya sea negativo o positivo.

Situación actual

En el entorno global podemos percibir un incremento tecnológico: cada vez hay más compañías tecnológicas en Asia y EEUU, ya que disponen de infraestructuras y volumen de datos necesarios (Fernández, 2019). Además, si analizamos el grado de cambio ocupacional en US durante los últimos años (ver Anexo 1), observamos un gran crecimiento en STEM (Science, technology, engineering, and mathematics) (Elvery, 2019). Cabe subrayar el conjunto de las nuevas tecnologías: el nacimiento del término cloud computing que se refiere a la posibilidad de ofrecer servicios a través de Internet, el tratamiento masivo de datos (Big Data) y la robotización, entre otras. Todas ellas “están sirviendo de palanca para la transformación digital de las organizaciones” (Banco de España, 2020).

La inteligencia artificial puede ser el cambio tecnológico más rápido en la historia. El líder mundial en la adopción de IA es Asia y el Pacífico, donde una empresa de cada cinco ha implementado la IA; seguido por América del Norte con una de cada diez (MMC

Ventures, 2019). En Europa, el emprendimiento de empresas relacionadas con la IA crece de manera exponencial. Así, en 2019, una de cada 12 nuevas empresas centro de su propuesta de valor en la IA; mientras que, en 2013, solo una de cada 50. Actualmente, Europa cuenta con alrededor de 1600 empresas de IA. Siendo Reino Unido líder con un tercio del total en Europa, seguido por Francia y Alemania. España ocupa la cuarta posición y su contribución supera su tamaño (MMC Ventures, 2019). “La adopción generalizada de la IA entre los empresarios actuales es un indicador destacado de un futuro a corto plazo en el que la IA es omnipresente” (MMC Ventures, 2019: 100).

Siendo la inteligencia artificial, una de las principales tendencias en la actualidad y teniendo un crecimiento exponencial, el estudio de su impacto es de gran interés. A continuación, nos centraremos en el sector financiero.

¿Por qué el sector financiero?

La riqueza de datos del sector financiero facilita la implementación del machine learning. “Los bancos no son conscientes del potencial de más del 80% de los datos acumulados” (United Consulting Group, 2018). Con la digitalización y los servicios multicanal, los datos se están masificando, creando una nueva oportunidad de negocio para las instituciones financieras de especializarse y dar un valor añadido, anticipándose a las necesidades de sus clientes a través de herramientas analíticas.

Además, el sector financiero ocupa un alto ranking en el Índice de Digitalización de la Industria de MGI (Manyika & Bughin, 2018), se encuentra entre los principales usuarios e inversores de IA.

No es casualidad, por tanto, que el concepto Fintech (constituido por los prefijos de finanzas y tecnología) este revolucionando el sector de las finanzas. Ese maridaje se define como las “innovaciones digitales e innovaciones de los modelos de negocio facilitadas por la tecnología en el sector financiero” (Philippon, 2016: 2). Los principales catalizadores de esa revolución tecnológica en ese sector son la inteligencia artificial, el aprendizaje automático y el Smart Data (Cuya, 2016).

El aprendizaje automático es la disciplina de la inteligencia artificial más utilizada en el sector financiero (Fernández, 2019), razón por la que este estudio se centra en sus aplicaciones. Antes de profundizar en ellas, se introducirá su proceso de implementación.

Como implementar ML

La aplicación del ML en los procesos de negocio requiere de una metodología de trabajo junto con la definición de un proyecto que obtenga un modelo que permita alcanzar los objetivos establecidos.

Para exponer las diferentes fases de un proceso de tratamiento de los datos aplicado a un negocio se presentará la metodología CRISP-DM (Cross Industry Standard Process for Data Mining) ya que es el modelo analítico más utilizado. Surgió a finales de los años 90 y adopta dos aspectos claves: estrategia de calidad total (o mejora continua) y proyecto como proceso o secuencia de fases (Hernández Orallo, Ramírez Quintana & Ferri Ramírez, 2004) y (Gironés Roig, Casas Roma, Minguillón Alfonso & Caihuelas Quiles, 2017); que se muestran en la siguiente figura:

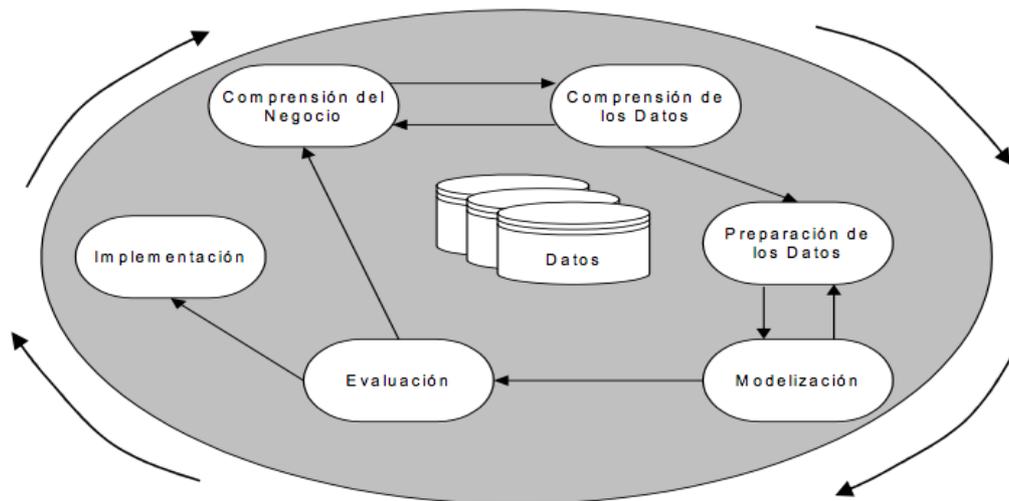


Figura 1: Metodología CRISP-DM

Fuente: Fernández, Merlino, Ochoa, Diez, Britos, & García Martínez (2005: 2).

La primera etapa consiste en la **comprensión del negocio**, es la base de todo proceso de machine learning aplicado a los datos de un negocio, ya que permite establecer y evaluar la situación actual, fijar los objetivos a nivel de minería de datos y obtener un plan de proyecto que nos permita identificar claramente lo que esperamos obtener de todo el proceso. En la segunda fase, **procesos de captura de los datos**, se define de donde se van a extraer los datos, es decir, buscar las fuentes prestando atención a la calidad de las

mismas y la fiabilidad. Una vez identificadas, se decide el método de extracción que asegure la mínima corrupción y cumpla los requisitos de seguridad. Luego tiene lugar la **comprensión de los datos** donde se realizan tareas de exploración y gestión la calidad de los mismos; identificando problemas y proporcionando soluciones. Una vez completada, se **preparan de los datos**, estableciendo el universo de datos con los que trabajar, y se realizan las tareas de limpieza necesarias. Es en esta fase donde se aplican las técnicas de preparación de datos que se orientan a la adecuación del juego de datos para ser usado por los diferentes algoritmos. En la fase del **modelado**, se seleccionan las técnicas de ML más adecuadas, y que por tanto produce los mejores resultados para nuestro juego de datos en función del tipo de los mismos y nuestros objetivos y se fija una estrategia de **verificación de la calidad del modelo**. Es importante tener en cuenta que ningún método o algoritmo domina sobre los demás, depende del conjunto de datos que se analiza. Por ello, es importante evaluar el modelo. Por último, se diseña un plan de **despliegue** en producción de los modelos y se comunica el conocimiento sobre nuestra organización obtenido de estos, revisando el proyecto en su globalidad con el objetivo de identificar lecciones aprendidas (Hernández Orallo et al, 2004) y (Gironés Roig et al, 2017).

Este modelo evalúa sus resultados según el éxito de la compañía y no según criterios estadísticos.

Aplicación en diferentes ramas del sistema financiero

En concreto, en el sistema financiero, se utiliza tanto en el front-office, como en middle-office y back-office. Ver anexo 2.

Detección de fraude

Los métodos no supervisados son utilizados para analizar abundantes cantidades de datos. En el sector financiero se utiliza para detectar la posibilidad de fraude. A medida que la tarjeta de crédito se convierte en el modo de pago más utilizado, la tasa de fraude tiende a acelerarse. Las instituciones financieras han recurrido a técnicas inteligentes, ya que, los métodos tradicionales de detección de fraude de forma manual eran lentos (Awoyemi, Adetunmbi & Oluwadare, 2017).

Los bancos cuentan con un servicio de seguridad que salta cuando los gastos de un cliente no concuerdan con los gastos “corrientes” del cliente. Los métodos no supervisados comparan cada operación con las operaciones anteriores para identificar las que podrían considerarse sospechosas (outliers) (Digiampietri et al, 2008). Estas se definen a través del análisis de la localización, preferencia, hábitos de compra y comportamiento habitual del cliente.

También se utilizan los métodos supervisados donde el modelo se elabora con las muestras de transacciones fraudulentas y legítimas para clasificar las nuevas transacciones como fraudulentas o legítimas. Según Bhattacharyya, Jha, Tharakunnel, & Westland (2011), los bosques aleatorios (tipo de algoritmo supervisado) tienen un mejor desempeño en todas las medidas de desempeño. Para reconocer patrones y detectar transacciones irregulares, se hace uso de los datos históricos y del comportamiento del cliente.

Algunos obstáculos como los grandes volúmenes de datos, las distribuciones cambiantes y sesgadas (el fraude ocurre con mucha menos frecuencia), la diferencia y variabilidad en el tiempo de los costes de error (falso positivo (el algoritmo indica que existe fraude cuando en realidad no lo hay) vs falso negativo (el algoritmo predice que no hay fraude y sí que lo hay), el constante cambio y la necesaria adaptación a nuevos comportamientos y cuestiones sociales; hacen que la implantación del machine learning sea complicada (Fawcett, Haimowitz, Provost & Stolfo, 1998).

Por otro lado, también se puede detectar el fraude mediante el uso de la herramienta SNA. El análisis de redes sociales, en inglés, Social Network Analysis (SNA) tiene como objetivo localizar e interpretar las conexiones entre los participantes de grupos sociales y estudiar el impacto de la estructura de las interconexiones de los protagonistas de la red, para entender fenómenos sociales (Van der Hulst, 2009). Una red social es un conjunto de actores vinculados, donde los actores pueden ser individuos o entidades y pueden estar conectados por un vínculo familiar, parentesco, familiar o la pertenencia a un mismo grupo/ organización (Knoke & Yang, 2008). Esta técnica se basa en la teoría de los grafos: medidas matemáticas que describen la estructura de la red y el significado del orden de los nodos. Los actores de la red social reciben el nombre de “nodos” y las relaciones entre los participantes de la red se traducen en enlaces entre nodos. Los nodos son tratados como individuos o entidades que están interconectadas, no como actores aislados. Es decir, el SNA se centra en el entendimiento del comportamiento humano basándose en la importancia de las relaciones sociales y sus implicaciones (MCGloin & Kirk 2010). La importancia del estudio de las redes sociales tiene su origen en la antropología y la sociología, en particular en los modelos psicométricos (Moreno, Jennings & Whitin, 1932). El estudio de las conexiones de la red, el SNA, permite a los modelos ser menos sensibles a la subjetividad y limitar el riesgo de perder información importante, ya que puede calcular parámetros de red cuantitativos, así como, interpretar gráficos (Van der Hulst, 2009).

El fraude está aumentando con el tipo de fraude de tarjeta no presente (CNP), es decir, el pago con tarjeta sin la necesidad de que esté físicamente presente en la transacción. Este tipo de fraude lo realizan un grupo de estafadores interconectados y el SNA es una vía para detectar sus conexiones (Ravi & Kamaruddin, 2017), puesto que se desarrollan mediante redes organizadas. De esta manera, el SNA es una herramienta muy atractiva para la detección del fraude financiero porque permite analizar la posibilidad de fraude mediante las relaciones entre los actores de las redes sociales y no solo por valores intrínsecos. Los métodos tradicionales de detección de fraude implicaban un análisis de puntuación de riesgo basándose en un modelo. Con la incorporación del SNA a este modelo, se pretende estudiar que fundamenta el comportamiento fraudulento, realizando un análisis de la conexión entre estafadores a través de diversos canales. En este escenario, los datos analizados provienen de formatos no estructurados (sin formato

específico), como pueden ser las redes sociales, registros telefónicos y pasarelas de pago, entre otras (Ravi & Kamaruddin, 2017).

Predecir riesgo de crédito

Los métodos supervisados (de regresión/ clasificación) son de gran utilidad para predecir variables de riesgo de crédito (credit scoring). Los métodos no supervisados analizan y procesan los datos, mientras que los métodos supervisados detectan los posibles futuros riesgos que podrían provocar el incumplimiento. Cuanto mejor sean los algoritmos de aprendizaje automático, mejor será la predicción del sistema de cuál podría ser el momento, datos, contenido y canal adecuados; con la oferta de pago adecuada para conseguir que paguen su deuda (Faggella, 2019).

Para analizar el riesgo crediticio de los clientes se utilizan los scorecards, especialmente, después de que el Basilea II (segundo acuerdo del Comité de Basilea) se implementara en 2007 (Dong, Lai & Yen, 2010). Este acuerdo obliga a las instituciones financieras a disponer de herramientas que midan el riesgo crediticio del cliente, así como modificar los sistemas de reporting y la metodología de análisis de la información (Rayo Cantón, Lara Rubio & Camino Blasco, 2010).

Un scorecard es un modelo basado en datos para predecir las probabilidades de incumplimiento (Bequé, Coussement, Gayler & Lessmann, 2017). Facilitan a los bancos evaluar la solvencia crediticia de los clientes con un formato estructurado y fácil de interpretar. Un scorecard está formado por características, atributos y puntos. Las características son los datos que analizamos del cliente (ej: edad; empleo), los atributos son las diferentes respuestas de estas características (ej: 18-25, 25-35, entre otros; desempleado, directivo, entre otros) y los puntos son las puntuaciones que damos a los atributos, cuantos más puntos obtenga un cliente, menor será su probabilidad de incumplimiento. La cantidad de puntos que se asigna a cada atributo dependerá de la información histórica que tenga el banco sobre la capacidad predictiva de la característica y la correlación entre características (Siddiqi, 2006).

Existen dos tipos de credit scoring: application scoring and behavior scoring. Application scoring solo utiliza y analiza la información proporcionada por el cliente que pide el

crédito, mientras que behavior scoring utiliza tanto la información proporcionada, como información histórica (Dong, Lai & Yen, 2010).

El desarrollo del scorecard conlleva tres fases: recopilación y construcción del dataset, aplicación del modelo y documentación.

La primera fase consiste en recopilar los datos y separar los datos en dos grupos. Utilizar los datos de entrenamiento (un 70% del juego de datos) para crear el scorecard y los datos de test (30%) para medir la precisión alcanzada por el scorecard realizado. A continuación, para aplicar el modelo, debemos evaluar las características y eliminar las que menos predicción aportan, llegando a tener una cantidad manejable de datos. Además, se pueden segmentar los datos, realizando diferentes scorecards para clientes con diferentes atributos, para mejorar la predicción de estos. Una vez hemos realizado el modelo, se prueba con los datos test. Si el banco está satisfecho con la exactitud de la predicción del modelo, procederá a utilizarlo.

Las entidades financieras pueden enfrentarse a un problema cuando utilizan los datos históricos, ya que, los datos suelen estar desbalanceados. Este desequilibrio se puede ocasionar debido a que la probabilidad de una clase sea baja o difícil de registrar (He & Garcia, 2009). En el caso del análisis del riesgo crediticio, ha de considerarse que el banco solo tiene los outputs de los clientes a los que ha concedido el préstamo, no de los que no les ha sido concedido, teniendo solo el input de estos últimos. Por este motivo, los datos históricos son respecto al número total de clientes a los que se ha concedido el préstamo, no del total que ha pedido el préstamo. Las empresas no registran los datos de aquellas personas a las que no se les ha concedido el préstamo, solo disponen de una base de datos de los clientes a los que se les ha sido concedidos y si estos han pagado su deuda o no. Este problema recibe el nombre de reject bias (Thomas, Edelman & Crook, 2017). De esta manera, el banco tiene más casos de gente que ha pagado su crédito frente a los que no. Balancear los datos supondría un enorme coste a la empresa, se vería obligada a conceder préstamos a gente cuyo análisis indicase que no iba a poder devolver su crédito. Para evitar esto, existen diferentes técnicas de minería de datos que se pueden aplicar para mitigar este problema. La más utilizada es el muestreo. Existen tres técnicas de muestreo. El submuestreo consiste en eliminar del dataset observaciones aleatorias de los datos que más se repiten (clientes que han podido devolver el crédito). El sobremuestreo, que trata el dataset de manera contraria, añade observaciones de la clase

que menos se repite, repitiendo los datos ya existentes de esta clase. Y, por último, la tercera técnica consiste en un híbrido de las anteriores técnicas mencionadas para equilibrar el dataset (Longadge & Dongre, 2013).

ML en los mercados bursátiles

Un área dominada por los algoritmos es el comercio de alta frecuencia, donde las decisiones deben tomarse de manera instantánea. La negociación de alta frecuencia, “High Frequency Trading (HFT)” son programas de software que permiten configurar una estrategia de inversión y aplicarla al número de valores deseado y durante las 24h del día. La ingeniería matemática (robots financieros) permite ejecutar órdenes bursátiles en cuestión de segundos, lo que está provocando tensión en el mercado. “Los sistemas automáticos copan más del 60% del negocio bursátil mundial en medio de una creciente controversia sobre su capacidad para desestabilizar al mercado” (Martínez, 2010).

Surgió con la idea de reducir los costes de negociación, maximizando así sus beneficios. El machine learning es un candidato ideal para la ejecución de operaciones y la generación de alpha (Kearns & Nevmyvaka, 2013).

Para optimizar la ejecución de operaciones se utiliza el aprendizaje por refuerzo, ya que este tipo de algoritmos nos permiten aprender a cómo actuar en el entorno representado, no simplemente predecir los valores del objetivo (Kearns & Nevmyvaka, 2013). El aprendizaje por refuerzo aplica modelos con la finalidad de indicar que acción es la más adecuada en las condiciones actuales. Así, puede indicar a los inversores el momento y el lugar oportuno en el que realizar la compra de los valores financieros, minimizando el gasto, maximizando la rentabilidad.

El concepto de alpha, en el mundo financiero, se refiere al exceso de rentabilidad en comparación al mercado, la capacidad del activo financiero de vencer al mercado. Para la generación de alpha se utilizan modelos de predicción del movimiento de los precios para encontrar señales predictivas rentables que sean mayores que los costes de negociación. Esto se realiza con el uso de datos históricos.

Es necesario definir el concepto de mercado eficiente en el sector financiero. El mercado eficiente es aquel en el que los precios de los activos financieros reflejan totalmente la información disponible (Shleifer, 2000), es decir, el precio representa el valor intrínseco

real, los precios se actualizan a la información instantáneamente. Esta teoría elimina toda hipótesis de que se puede obtener beneficio estudiando el comportamiento futuro de los precios, considerando que los productos financieros no están ni infravalorados ni sobrevalorados. La teoría del mercado eficiente defiende que se puede obtener un alto rendimiento, pero siempre proporcionales al riesgo (Rechenthin & Street, 2013). No obstante, “la evidencia de la década anterior desacreditó las tesis básicas de la teoría de las finanzas” (Woolley, 2010: 56). El mercado financiero no es eficiente, por lo que predecir las futuras variaciones de los precios puede beneficiar a la rentabilidad del inversor. Y aquí entra en juego el aprendizaje automático.

Predecir los precios no es una tarea fácil: “Dos cambios en sentido contrario, ocurren aproximadamente tres veces tan a menudo como los cambios en la misma dirección” (Niederhoffer & Osborne, 1966: 901). Para predecir los precios se utilizan los métodos supervisados, dado que el precio futuro se conoce cada instante, el dataset se actualiza constantemente con datos etiquetados a medida que pasa el tiempo. El objetivo es encontrar patrones a través del análisis cuantitativo de los precios históricos. Wang & Wang (2017) logró un alto grado de precisión al utilizar algoritmos de aprendizaje automático para crear un modelo de predicción de los precios del mercado de valores.

Otra aplicación del ML en los mercados financieros recibe el nombre de algo-trading o algorithmic trading. Consiste en aplicar unas instrucciones al programa para ejecutar una orden de compra o venta. La aplicación de algoritmos en esta actividad permite aumentar el beneficio mediante la reducción de los costes de negociación, y aporta rapidez y frecuencia frente a la operativa manual. El comercio se vuelve menos sensible a la subjetividad humana, se vuelve más sistemático (Seth, 2020).

Las instrucciones que se le dan al algoritmo deben contener ciertos parámetros, como el precio al que se desea comprar o vender, el volumen de instrumentos con los que se desea operar y el vencimiento de esta orden, entre otros. En el caso de que la orden sea de compra, el parámetro de precio indicado, refleja el precio máximo al que está dispuesto el inversor a comprar ese instrumento financiero; la máquina comprará todos los productos financieros que estén por debajo del precio máximo condicionado (empezando por los de menor precio) hasta llegar al volumen deseado. Por el contrario, si la orden es de venta, el precio indicado es el mínimo permitido y la máquina procederá a vender a precios mayores o iguales al señalado (empezando por el mayor) hasta alcanzar el

volumen solicitado. Todos los títulos que no se contraten porque estén por debajo del precio indicado, en el escenario de venta y por encima del precio, en el caso de compra; quedarán en el registro de órdenes en espera hasta que se cumpla el vencimiento de la orden, donde la instrucción será eliminada del sistema. De esta manera la instrucción que se le da a la máquina está condicionada: solo cuando se cumpla la regla, se ejecutará la orden y se enviará al mercado financiero, configurándose en la plataforma del intermediario financiero. Esto garantiza rentabilidad y limita pérdidas. Bajo estas líneas, se encuentra un gráfico para explicar cómo funciona el algo-trading de manera más visual.

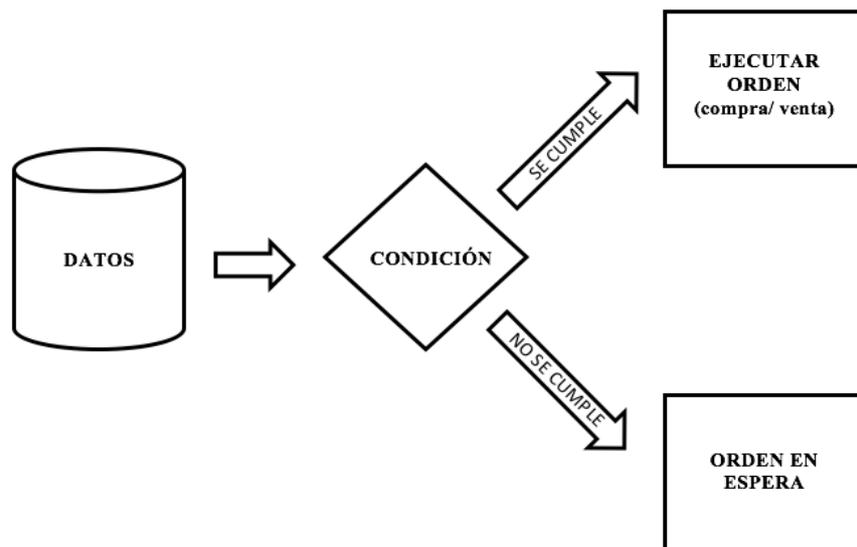


Figura 2: Proceso de algo-trading.

Fuente: Elaboración propia.

Chatbots

El mayor uso de la inteligencia artificial, a día de hoy, son los denominados Chatbots. El término chatbot hace referencia al programa que simula una conversación con un individuo en las plataformas de mensajería. Se puede descomponer en “chat”, una conversación y “bot”: robot, máquina que sustituye a un humano en las conversaciones con los usuarios (Okuda & Shoda, 2018). Esta conversación se realiza vía online a través de audio o de texto, con un lenguaje natural. Los chatbots permiten ofrecer una atención al cliente personalizada, fomentando la interacción entre clientes y entidades; permitiendo a los usuarios obtener beneficios sociales, informativos y económicos (Coulter, Gummerus, Liljander, Weman & Pihlström, 2012). Además, esta herramienta opera 24/7, ofreciendo servicio al cliente constante (Okuda & Shoda, 2018), reduciendo el tiempo de

desplazamiento a establecimientos físicos. También se implementa en las entidades para ayudar al trabajador, resolviendo dudas que puedan surgir. En las entidades del sector financiero, los chatbots tienen mucho potencial, “se pueden emplear los chatbots como asistente de recursos humanos, asistente de inteligencia de mercado, asistente de flujo de trabajo, asistente de redes sociales, asistente de analista financiero, asistente de programación y en general puede ser empleado como el embajador de la empresa” (Ravi & Kamaruddin, 2017: 19). Solo el 20% del trabajo de back office supone el 85% del coste total a los bancos. Se calcula que los chatbots serán responsables de más de 8.000 millones de dólares de ahorro de costes anuales en 2022 (United Consulting Group, 2018).

Del total de la oferta de productos relacionados con IA, los chatbots representan aproximadamente el 9,6% (Faggella, 2019). Sin embargo, representan casi el 33,9% de los casos de uso de AI en los bancos (Faggella & Bharadwaj, 2019). Este sobre uso de los chatbots puede deberse a que los bancos quieren dar la imagen de innovadores y para ello quieren estar lo más actualizados posible tecnológicamente. Sin embargo, los bancos tienden a no tener en mente ninguna estrategia de IA (Faggella & Bharadwaj, 2019). Según Ian Wilson, ex jefe de IA en HSBC, la pregunta más planteada en los bancos es "¿Qué viene después? ¿Cuál es el ROI?". Y no hay respuesta, lo cual es un problema. A esto se suma que estos programas sólo son capaces de manejar solicitudes rudimentarias de los clientes (Faggella, 2020).

Debido a la complejidad del lenguaje humano, es complicado conseguir que un chatbot logre mantener una conversación fluida. Sin embargo, como se introdujo al principio, el programa informático Eugene superó en 2014 el test de Turing, haciendo posible que una máquina converse con un humano utilizando el machine learning.

Los primeros proyectos de chatbots se basaban en normas establecidas por expertos, luego se introdujeron proyectos híbridos, incorporando el machine learning y actualmente se están llevando a cabo chatbots que solo utilizan el machine learning (Serban et al, 2017). El sistema es entrenado con los diferentes datos históricos y continuará mejorando a perpetuidad con datos adicionales. El algoritmo identifica la intención del usuario y extrae bits estructurados de información del mensaje, evaluando así el problema del cliente. Para generar la respuesta, analiza cuál es la solución más común en su dataset. En caso de encontrarla, se devolverá al sistema; haciendo uso del aprendizaje supervisado. En caso

de haber diversas respuestas las evaluará y devolverá la más conveniente basándose en la entrada actual y el contexto de la conversación, utilizando el aprendizaje profundo (Rahman, Al Mamun & Islam, 2017).

El funcionamiento de los chatbots emplea diferentes técnicas. Para el frontend (parte del software que interactúa con los usuarios) se utiliza el Procesamiento de Lenguaje Natural (PNL). El PNL es una rama de la inteligencia artificial que consiste en la habilidad de entendimiento de las máquinas del lenguaje natural (humano) (Gelbukh, 2010). Se fundamenta en la manipulación de la información recibida para que una máquina lo comprenda. En el backend (procesador de entradas del frontend) se emplea el aprendizaje supervisado y aprendizaje profundo (Ravi & Kamaruddin, 2017).

Roboadvisors

España ha sido el país más "bancarizado" del mundo, con el mayor número de oficinas por habitante - 95,87 sucursales por cada 100.000 personas (Camino & de Garcillán López-Rua, 2014: 16). Si bien, esto está cambiando, gracias a las nuevas tecnologías. "Necesitamos el sistema financiero, pero no los bancos" (Bill Gates, 1994. Citado en Larsen, 2017: 3). Están saliendo al mercado aplicaciones de móvil y servicios automatizados en la red que ofrecen un servicio financiero personalizado al cliente. Son los denominados "roboadvisors".

Esta herramienta utiliza los algoritmos de aprendizaje automático para asesorar al cliente en sus inversiones. La máquina interactúa con el cliente y analiza los ingresos y gastos históricos de este para recomendar planes de ahorro y de inversión. El cliente se crea un perfil, donde responde a una serie de preguntas, lo que permite al programa informático conocer el perfil del inversor (perfil de riesgo, preferencias en tipo de activos, etc); y, con esta información, el roboadvisor aplica los algoritmos y proporciona una recomendación personalizada al usuario. "Los roboadvisors permiten añadir ese CRM al ciclo financiero bancario de los clientes y así poder incidir y mejorar su planificación financiera ajustada a los distintos ciclos vitales, a su perfil de riesgo, y así alinear mejor sus objetivos financieros con las estrategias necesarias para alcanzarlos" (Llopart, 2016).

De esta manera, su utilización, podría reducir el número de oficinas necesarias operativas para los clientes. Asimismo, los roboadvisors permiten a que una parte considerable de la

población que carece de los conocimientos financieros básicos (Lusardi & Mitchell, 2014) pueda invertir, ahorrar o incluso planificar su jubilación.

Análisis de documentos

El análisis y reconocimiento de documentos (DAR) tiene como objetivo la extracción automática de información, determinando que cuestiones deben ser tratadas para evaluación, destacando así la información más importante. Según Marinai & Fujisawa (2007), la incorporación del ML para este análisis es idónea.

El análisis de documentos tiene tres fases: recopilación y almacenamiento de la información, pre-procesamiento de los datos y aplicación de técnicas de análisis. La fase de tratamiento de la información es necesaria porque los documentos son datos no estructurados; la información no tiene una organización definida. Se emplean técnicas de simplificación, como la reducción de las palabras a su raíz o la eliminación de palabras sin significado porque no aportan valor a las frases. La fase de análisis aplica diferentes técnicas para analizar el texto (Guo, Shi & Tu, 2016). Se puede realizar un análisis cuantitativo, basado en la repetición de las palabras en un mismo documento, donde la frecuencia de las mismas puede señalar la importancia del tema en el texto presentado o un análisis del sentimiento, entre otros.

Esta herramienta posibilita escanear y obtener la información más relevante de documentos extensos, convirtiéndose en uno de los principales beneficios del ML para el sector financiero, resolviendo sus necesidades con rapidez. En el caso de JP Morgan, la empresa utiliza la plataforma COiN para extraer la información fundamental de acuerdos anuales de crédito comercial en cuestión de segundos, ahorrando 360.000 horas al año bajo revisión manual (United Consulting Group, 2018).

Ventajas y desafíos de la aplicación del ML

La aplicación de los algoritmos en las diferentes funciones del sector financiero mencionadas, presentan ventajas y desafíos para las entidades. En esta sección se exponen estos beneficios y retos para conocer cuál es el impacto, positivo o negativo.

Ventajas de implementar ML en el sistema financiero

Machine Learning como ventaja competitiva

Históricamente, las instituciones financieras confiaban en el precio, la velocidad y el acceso como formas de atraer clientes. Pero la globalización ha cambiado esto. Para obtener una ventaja competitiva, la cantidad de datos junto con los algoritmos que encuentren los productos que mejor se adapten a las necesidades de los clientes serán clave. Las expectativas de los clientes están cambiando hacia ofertas más diversas y personalizadas (Alt & Puschmann, 2012). La estandarización no será el origen de los ingresos, sino los productos altamente personalizados, donde entra en juego la IA. Así, los grandes operadores tradicionales se conviertan en proveedores de servicios de IA (Contri, Galaski, Baumann, Stier & Celner, 2018). Ver anexo 3.

De esta manera, el aprendizaje automático permite segmentar a los clientes a fin de desarrollar estrategias diferenciadas según sus características. Es necesario que las personas que forman parte del mismo segmento sean homogéneas entre sí y heterogéneas con respecto a otros grupos. Desarrollando diferentes estrategias para los distintos segmentos, siendo estas más personalizadas y adaptadas al cliente.

En consecuencia, el aprendizaje automático supondrá una ventaja competitiva a las entidades del sector financiero que lo posean, permitiendo ofrecer un servicio al cliente más personalizado.

Automatización de tareas manuales

“Mediante técnicas como el procesamiento del lenguaje natural o el reconocimiento de imágenes, las entidades pueden automatizar aquellas tareas manuales que son más repetitivas o aportan menos valor añadido (p. ej., respuestas a preguntas frecuentes)” (Fernández, 2019: 2). En el caso de Amazon, la empresa ha introducido más de cien mil

robots en todo el mundo y, como explica el director de operaciones, Dave Clark: “La empresa quería que las máquinas realizaran la mayoría de las tareas monótonas y que las personas tuvieran trabajos que los mantuvieran ocupados mentalmente” (Wingfield, 2017). “Olvídate de 'humanos contra máquinas' - La IA se trata de 'humanos mejorados por máquinas” (Jubraj, Graham & Ryan, 2018: 12).

La IA aumentará las habilidades humanas, optimizando el tiempo de los empleados de una empresa, liberándolos de tareas repetitivas para realizar tareas de mayor valor.

“Los economistas siempre han dado por supuesto que en cualquier lugar una máquina podía sustituir a varios trabajadores, pero a la postre han sostenido que la productividad aumentaría enormemente y, como consecuencia de ello, los ingresos y el producto interior” (Rifkin, 1996: 6).

Por consiguiente, se producirá un cambio en la obtención de beneficios en la cadena de valor. De manera progresiva, el valor se desplazará a las tareas que exigen habilidades de los expertos y la sociedad estará menos dispuesta a pagar por servicios que no requieran el trabajo de profesionales experimentados. Esto se debe a que el ML permite realizar estas tareas a un precio mucho menor.

En el sector financiero, la automatización de las tareas más repetitivas liberaría más del 20% del tiempo de los equipos directivos financieros (Chui, Manyika & Miremadi, 2015), dejando realizar a las máquinas el trabajo de recopilación, verificación y consolidación de datos para centrarse en el análisis y la toma de decisiones. La automatización de las tareas será mayor cuantas más actividades rutinarias requiera el puesto de trabajo del empleado.

En el caso de los trabajadores encargados de conceder préstamos hipotecarios, el aprendizaje automático realizará la tarea rutinaria de recolectar los datos y procesarlos, permitiendo al empleado procesar más solicitudes de préstamos y así, asesorar a más clientes. En consecuencia, el asalariado optimizará su tiempo en tomar decisiones con el análisis de los datos realizado por las máquinas.

Por otro lado, los asesores financieros se centrarán en comprender las necesidades de sus clientes y desarrollar diferentes estrategias para lograr sus objetivos, dedicando menos tiempo a analizar la situación financiera de los clientes. Las máquinas facilitarán el

procesamiento y la evaluación de los datos de cada cliente que previamente realizaban los empleados del sector.

Creación de empleo

Pese a la sustitución de las tareas manuales, un estudio elaborado por la firma McKinsey en 2018, sugiere que se crearán más puestos de trabajo que los que se sustituirán. El estudio indica que la sustitución de algunos empleos por máquinas, representará menos de la mitad del total de los beneficios que aportará la inteligencia artificial (Manyika & Bughin, 2018).

Debido al cambio de la cultura empresarial, donde se adopta la IA, se demandarán diferentes habilidades en los puestos de trabajo. La demanda de aptitudes físicas disminuirá, por lo que habrá un exceso de oferta y la demanda de habilidades cognitivas aumentará. Como consecuencia, habrá una subida salarial (Manyika & Bughin, 2018).

Según un informe de Bloomberg, el auge de las máquinas en los bancos va a cambiar la definición de las funciones de los empleados de los mismos. Así, según portales de empleo, como Glassdoor y LinkedIn, los candidatos más demandados en el sector financiero son aquellos que tienen experiencia en inteligencia artificial, aprendizaje automático y data science (Wagner & Hagan, 2019).

Asimismo, si se automatizan algunas de las tareas de los empleados del sector financiero, los clientes demandarán un servicio más personal; incrementando la necesidad de puestos que atiendan directamente al cliente, que se dediquen a la gestión de relaciones con el cliente (en inglés CRM).

Algunas partes de los servicios financieros no pueden funcionar sin la cooperación humana. Las máquinas generan recomendaciones, mientras los empleados financieros mejoran la experiencia del cliente, atendiéndoles de una forma más personal. La inteligencia humana emocional y la rapidez de las máquinas deben cooperar.

Objetividad

En las actividades donde se necesitan tomar decisiones es necesario que haya objetividad. El aprendizaje automático ofrece una mayor precisión, ya que puede analizar datos de

diversas fuentes, en diferentes formatos y comprobar su conformación (Chui, Harryson, Manyika, Roberts, Chung, van Heteren & Nel, 2018), siendo las decisiones menos sensibles a la subjetividad de un individuo. Un ejemplo de la necesidad de objetividad en las actividades de una empresa es la auditoría. Cuando las empresas tienen un cierto volumen de capital están obligadas por ley (en el caso de España) a ser auditadas por un auditor externo. Este último, no debe estar asociado a ninguna actividad de la empresa. Esta actividad garantiza la confiabilidad de los estados financieros y elimina el conflicto de intereses.

Esta característica es idónea para sectores como el sector financiero, donde la toma de decisiones supone elegir entre varias opciones y afectan directamente a la economía del cliente. Para esto es necesario tener información significativa y elegir una estrategia con la máxima objetividad. Los asesores humanos son subjetivos, propensos a errores y requieren mucho tiempo. Sin embargo, los algoritmos son objetivos, más precisos, rápidos, efectivos y trabajan las 24 horas del día (Sabharwal, 2018). El aprendizaje automático procesa los datos con precisión.

En el caso del análisis cualitativo de la probabilidad de incumplimiento, el input de información que se utiliza para calificar el riesgo crediticio del cliente es subjetivo y difuso (Rao, 2003). Es necesario subsanar este problema para garantizar una mayor objetividad y cumplir las directrices del BPI. El Banco de Pagos Internacionales (BPI) es la organización encargada de garantizar estabilidad en sistema financiero y monetario internacional. El BPI publicó, en 2015, once principios de orientación supervisora sobre riesgo de crédito y contabilidad de pérdidas crediticias esperadas. El principio número dos señala que “Un banco debe adoptar, documentar y cumplir metodologías sólidas para el desarrollo de políticas, procedimientos y controles de evaluación y cálculo del riesgo de crédito en todas las exposiciones crediticias” (Banco de Pagos Internacionales, 2015: 1).

Tradicionalmente, los bancos recogían la información del solicitante del préstamo a través del formulario de solicitud y otras fuentes para estudiar si se le concedía el préstamo y las condiciones del mismo (Trelewicz, 2017). Los empleados analizaban esta información y tomaban una decisión. Podría ocurrir que un asesor, tras su estudio, no concediera el préstamo, y el análisis de otro empleado concluyera que sí se debía conceder. Mediante el uso del aprendizaje automático, se crea un modelo de decisión

central de calificación crediticia. Así, la decisión es universal y no depende del análisis de un individuo.

Rapidez

Los datos analizados en el machine learning se caracterizan por las 3Vs: volumen, variedad y velocidad. El incremento del volumen de datos se debe al aumento de la cobertura y conexiones a internet (European Political Strategy Center, 2018), lo que crea un problema con el almacenamiento físico. La variedad de los distintos medios de los que viene la información, la variedad en la que se representa y su variedad de disponibilidad, dificulta su análisis. Por último, debido al avance en la difusión de datos de los dispositivos, la velocidad con la que se generan los datos crece de forma exponencial (Lee, 2017). La información debe ser analizada y almacenada de manera rápida y eficiente para evitar que se genere un coste de oportunidad, considerando que, a veces es imposible analizar toda la información.

El término Internet of Things (Internet de las cosas) se refiere a la interconexión de los objetos mediante una red (privada o Internet) (Xia, Yang, Wang & Vinel, 2012). Todos los dispositivos conectados a la red interactúan, intercambiando datos constantemente. Por tanto, la magnitud de datos, tanto cuantitativos como cualitativos, que se maneja es enorme.

En el sector financiero, los dispositivos móviles han incrementado el número de operaciones y, por tanto, de datos disponibles. Para hacer un uso eficiente de estos datos son necesarios los algoritmos de aprendizaje automático porque permiten procesar los datos en línea y obtener información de valor inmediata. Precisamente, la primera incorporación de inteligencia artificial en el sector financiero se beneficiaba de esta característica, permitía acelerar los procesos: el uso del reconocimiento automático de dígitos (Hanmandlu, Mohan, Chakraborty, Goyal, & Choudhury, 2003).

Los mercados financieros operan 24h al día y como declaró Jennifer Q. Trelewicz (2017): “cuanto más rápido puedan los sistemas procesar los datos comerciales, más rápido podrán gestionar el comercio”. Por tanto, el aprendizaje automático permite tomar decisiones en tiempo real y posicionarse y anticiparse en los mercados financieros.

Asimismo, “los cambios anteriores –rápidos y de gran alcance– afectan también al Banco de España, tanto en su funcionamiento interno como en sus funciones analíticas y supervisoras” (Banco de España, 2020: 5). El sector financiero está expuesto constantemente a nuevos reglamentos y normas de presentación de informes. Lo que hace necesaria una rápida adaptación.

El aprendizaje automático no solo agiliza el análisis de los datos e información de un cliente, también acelera la formación de los empleados de un banco; consiguiendo que sean productivos en un menor tiempo, siendo más rentables para las empresas. La automatización de tareas conlleva a una reducción del tiempo necesario para implementarlas, agilizando el proceso de aprendizaje de las nuevas incorporaciones. Asimismo, el uso del aprendizaje automático transmite solidez al trabajo de las nuevas incorporaciones porque están apoyadas en la fiabilidad de sus algoritmos (Sabharwal, 2018).

Nuevos participantes

Actualmente, la atención sanitaria y los servicios financieros son accesibles para determinadas clases sociales (MMC Ventures, 2019). Al optimizar el tiempo de los trabajadores, el aprendizaje automático, permitirá la escalabilidad de los servicios financieros, siendo accesibles para un mayor número de personas.

En el caso de los pequeños préstamos (ej. empresas pequeñas), la poca cantidad demandada y el posible alto riesgo del prestamista, no justifican el coste de examinar el riesgo crediticio del cliente. Para estos casos, la implementación del aprendizaje automático resulta idónea (Aggarwal & Stein, 2016), permitiendo a un mayor número de la población acceder a servicios financieros.

Por otro lado, si se automatiza parte del trabajo, las comisiones de los asesores financieros serán menores. Esto atraerá a un mayor número de clientes.

Además de tener beneficios, el ML también plantea desafíos.

Desafíos que presenta el ML en el sector financiero

Contratación de talento

La implementación de la IA en la empresa hace necesario el reclutamiento de expertos, denominados científicos de datos. Debido a la enorme competencia, la contratación de personal con las aptitudes adecuadas es difícil (MMC Ventures, 2019); actualmente, la demanda de estas cualidades supera la oferta (Manyika & Bughin, 2018). En consecuencia, las empresas que deseen implementar el aprendizaje automático en sus servicios, deben hacer lo posible no solo por atraer, sino por retener a estos especialistas.

El 90% de las 1,600 startups de IA en Europa, tienen como actividad principal ofrecer servicios de IA a otras empresas (MMC Ventures, 2019). Esto implica que ciertas compañías subcontratan el servicio aprendizaje automático a otras empresas. Para las empresas en este escenario, los factores de éxito son integrar de manera eficiente estos servicios y desarrollar una relación a largo plazo con sus proveedores.

En vista de que el número de profesionales de este ámbito es reducido, en el caso de que las empresas del sector financiero dependieran significativamente del aprendizaje automático para su correcto funcionamiento, ocasionaría un incremento del riesgo operacional de la empresa y a su vez, un riesgo sistemático (Fernández, 2019).

El acceso a los datos es crítico

Un factor de éxito para la implementación de la IA es la posesión de grandes datasets para desarrollar algoritmos, asegurarse el acceso a los datos es clave. Además, el esfuerzo humano necesario para la captación de datos es enorme (Manyika & Bughin, 2018). Tradicionalmente, se dedicaba mucho tiempo a la extracción de datos, mientras que actualmente el tiempo se destina a la preparación de los datos (Hoffmann, 1990). Debido a las características de los datos procesados en el aprendizaje automático (3Vs), las empresas requieren un proceso de captura de datos eficaz.

Sin embargo, esto no es un desafío para el sector financiero. El sector financiero cuenta con una enorme base de datos que se ha almacenado durante mucho tiempo debido al sistema de contabilidad (Srivastava & Gopalkrishnan, 2015) y a las exigencias bancarias fiscales o jurídicas de un horizonte temporal amplio. Los registros históricos mantenidos

por exigencias regulatorias, hoy tienen un valor mucho mayor al previamente esperado, su potencial no estaba planificado. Además, el sector financiero se ha transformado en una industria multicanal (Ravi & Kamaruddin, 2017), de esta manera, las transacciones monetarias en el sector financiero, generan un mayor volumen de datos en menos tiempo a partir de diversos dispositivos. Así el volumen de datos del que dispone el sector financiero es tan grande que se ha vuelto necesarios aplicar técnicas para analizarlos (Pérez-Martín, Pérez-Torregrosa & Vaca, 2018).

Por otro lado, como el aprendizaje automático genera el algoritmo con los datos de entrenamiento, los sesgos históricos se pueden reflejar en el ML, como el género y la raza. Así, pueden no ser óptimos cuando se prestan servicios financieros a minorías. Existe una importante diferencia entre la precisión de clasificar a hombres con un tono de piel más claro y hombres más oscuros, igual que en el caso de las mujeres. Esto se debe a que los datasets están principalmente compuestos por personas de piel clara (Buolamwini & Gebru, 2018). Es decir, los algoritmos de aprendizaje automático son justos pero los datos con los que se entrenan estos algoritmos pueden estar sesgados. Para evitar este riesgo discriminatorio y que las entidades financieras tengan algoritmos justos y transparentes, deben hacer uso de datos heterogéneos y utilizar los mecanismos de entrenamiento y las metodologías de elaboración de algoritmos más óptimas (Fernández, 2019).

Amazon intentó elaborar un modelo de aprendizaje automático para agilizar su proceso de selección de personal. El objetivo era que analizara los CVs de la gente y eliminara del proceso a aquellas personas que, según los datos históricos de la compañía, no tenían probabilidad de ser contratadas. Para ello, utilizó todos los CVs de los anteriores 10 años. El género no se utilizó como parte de la decisión. No obstante, el modelo rara vez preseleccionaba a mujeres porque los datos utilizados para formar el modelo tenían ciertas tendencias de contratar a hombres. Se descubrió que el algoritmo eliminaba del proceso de selección aquellos CVs que contenían las palabras "mujer" o "femenino" (Miller, 2019). Otro ejemplo es el algoritmo que Google implementó para el reconocimiento facial. El algoritmo etiquetó erróneamente a las personas negras como gorilas, a consecuencia de que los datos utilizados para entrenar el modelo no tenían suficientes observaciones de caras de personas de color (Barr, 2015).

En el sector financiero, “el uso generalizado de este tipo de algoritmos en actividades como la provisión de crédito o la negociación de activos financieros podría llevar a situaciones de comportamiento gregario y, eventualmente, procíclico” (Fernández, 2019: 6).

Pequeño grupo de competencia

La economía de la IA dará ventaja a las instituciones con gran cuota de mercado y a los innovadores ágiles. De esta manera, es posible que exista un monopolio de las grandes instituciones financieras tradicionales, ya que las PYMEs no podrán hacer frente a la inversión necesaria para innovar tecnológicamente. Esto se refleja en un estudio realizado por Edelman y WEF, en 2019, que señala que el 54% del público general y el 43% de los líderes tecnológicos opinan que la IA perjudicará a los más desfavorecidos, mientras el 67% y 75% respectivamente estiman que beneficiará a los más ricos. Provocando así desequilibrios (Edelman AI center of expertise, 2019).

La brecha entre las empresas que adopten el aprendizaje automático y las que no, se ampliará a medida que las primeras aumenten su inversión en el aprendizaje automático y adquieran más datos. La clave estará en anticiparse a este cambio e implantar el ML. La enorme competencia desplazará a las compañías que no han adoptado esta tecnología en su negocio fuera del mercado (Manyika & Bughin, 2018). Así, se producirá un cambio del posicionamiento competitivo de las empresas, exigiendo nuevos factores de éxito.

El aprendizaje automático acelerará el ritmo de los negocios, impulsando y acortando así los ciclos de innovación, adopción y consumo (MMC Ventures, 2019). Esta aceleración, históricamente, acortaba el periodo en el que las grandes empresas eran líderes en el mercado.

El ML probablemente será una ventaja competitiva y supondrá un monopolio a las grandes empresas, existiendo un pequeño grupo de competencia.

Pasar del “laboratorio a la acción”

Aplicar algoritmos ya desarrollados en unas circunstancias concretas en otro caso similar pero distinto supone un desafío para las compañías. Por tanto, el uso de algoritmos en datos diferentes a aquellos con los que ha sido entrenado, puede suponer un problema (Manyika & Bughin, 2018). Se necesitan desarrollar algoritmos generalizables. Esto se puede alcanzar con el uso de datos heterogéneos, donde las observaciones provienen de diferentes escenarios.

La compañía Knight Capital creó un programa para negociar valores de acciones en la bolsa de Nueva York en 2012. Un fallo informático provocó que la empresa perdiera 440 millones de dólares en tan solo 45 minutos, momento en el cual la compañía se dio cuenta y consiguió parar el algoritmo. El algoritmo compraba y vendía millones de acciones constantemente. Al comprar una gran cantidad de acciones a la vez, subía la demanda, por lo que subía el precio. Provocando que la acción estuviese sobrevalorada y cuando se procedía a vender, la compañía obtenía pérdidas (Harford, 2012). El algoritmo estaba diseñado para comprar acciones infravaloradas, pero no había considerado que, si se compra un gran número de acciones, sube su demanda y por consiguiente su precio; haciendo que las acciones ya no estén infravaloradas.

Problemas éticos y legales

El aprendizaje automático tiene la capacidad de potenciar el sector financiero, pero también plantea obstáculos a nuestros principios y normas. Cada vez las máquinas tienen un papel más decisivo en la banca y a medida que esto ocurre, surgen más problemas éticos y legales. Estos aspectos deben ser atendidos a nivel directivo (Wagner & Hagan, 2019).

De esta manera, es necesario reevaluar el equilibrio entre la seguridad y la privacidad de datos que se desea, para evitar un uso indebido y malicioso de la información disponible. La necesidad de un gran volumen de datos de los clientes para potenciar la exactitud del algoritmo, pone en riesgo la privacidad de los clientes y que “algunas entidades puedan utilizar determinados datos sin que sus clientes sean plenamente conscientes de ello” (Fernández, 2019: 6). Para evitar esto, se han desarrollado leyes de protección de datos, imponiendo requisitos más estrictos para la recopilación de datos. Así, en Europa, la

Comisión Europea, publicó el 25 de enero de 2012 el Reglamento General de Protección de Datos (RGPD).

La ciberseguridad es el cimiento de la economía digital. Su objetivo es proteger del uso no autorizado en el ciberentorno, tanto usuarios, como activos o recursos digitales (redes, equipos y contenidos).

En toda comunicación hay un emisor, un receptor y un mensaje que se transmite. Las propiedades que garantizan la confianza (o seguridad) digital son cuatro: autenticidad (el mensaje recibido fue enviado por el emisor), integridad (el mensaje recibido no fue modificado), confidencialidad (el mensaje recibido sólo fue leído por el receptor) y no repudio (el emisor no puede negar su autoría del mensaje) (Drovandi, 2000).

La criptografía (palabra griega que significa escritura oculta, secreta) es una rama de las matemáticas que ha tenido una amplia aplicación en entornos militares. Cifrar es transformar los datos originales en unos nuevos datos ininteligibles, mediante un algoritmo de cifrado y una clave. Descifrar es transformar los datos ininteligibles, mediante un algoritmo de descifrado y una clave, en los datos originales.

En el escenario histórico, mediante la criptografía, sólo era posible ofrecer la propiedad de la confidencialidad (permutación del orden de caracteres de los espartanos, sustitución monoalfabética de Julio César o sustitución polialfabética de Vigenere). No teníamos forma de saber si el mensaje original venía del origen legítimo (autenticidad), ni tampoco si el mensaje había sido modificado en el transporte (integridad). La autenticidad e integridad se basaban en la llegada del mensaje a destino; se confiaba en el mensajero.

Los protocolos criptográficos actuales depositan su fortaleza en las matemáticas, con sus herramientas o algoritmos criptográficos, para garantizar conjuntamente las cuatro propiedades criptográficas: autenticidad, integridad, confidencialidad y el no repudio.

Tres son los algoritmos o herramientas criptográficas:

- Criptografía simétrica o algoritmo de clave secreta, de una única clave secreta y compartida entre todas las entidades autorizadas para cifrar/descifrar los datos. Es una criptografía con consumo de proceso de cálculo moderado-intenso. Tiene por propiedad nativa la confidencialidad.

- Criptografía asimétrica o algoritmo de clave pública: de dos claves, diferentes pero relacionadas entre sí, una privada (generada por la autoridad certificadora para el ciudadano) y otra pública (generada por la autoridad certificadora a partir de la clave privada del ciudadano). Los datos cifrados con la clave privada solo pueden descifrarse con su clave pareja pública. Los datos cifrados con la clave pública solo pueden descifrarse con su clave pareja privada. Consume más recursos de cálculo que la criptografía simétrica. Sus propiedades nativas son la autenticidad y la confidencialidad.
- Criptografía de funciones hash o algoritmos criptográficos hash es un algoritmo sin clave que consiste en un resumen digital de los datos originales. Es una criptografía con proceso de cálculo moderado. La propiedad nativa de las funciones hash es la integridad (factor de conocimiento del algoritmo, clave y sello).

De esta manera, la aplicación de los diferentes algoritmos criptográficos en las actividades del sector financiero, garantizan seguridad.

Por otro lado, cuando se aplica el aprendizaje automático en las entidades y surge algún problema, a quién se debe asignar esa responsabilidad es un aspecto que se debe considerar. Por ejemplo, en el caso que el algoritmo esté discriminando a cierta parte de la población, si se demanda a la entidad por ser discriminatoria, en quién cae la responsabilidad. Este aspecto debe de tratarse con anterioridad a la implantación del ML. La ética aristotélica defiende que el conocimiento y el control son necesarios para que exista responsabilidad (Aristóteles. Nicomachean, 1984). Con respecto a la tecnología, en concreto los algoritmos, es complicado cumplir estas condiciones. Por tanto, la ética en la tecnología supone un problema. Las tecnologías financieras permanecen invisibles y no tenemos en consideración la forma en la que los humanos y las máquinas interactúan. Según World Economic Forum (2018) el responsable es la compañía que aplica el modelo.

Barrera humana

Como se ha mencionado anteriormente, existen diferentes puntos de vista sobre el impacto socioeconómico de las nuevas tecnologías y ciertas personas se oponen a trabajar con máquinas. Así, los banqueros y vendedores consideran que la carencia de una cultura de innovación es la barrera crítica para la adopción de la IA en la banca (Faggella & Bharadwaj, 2019).

Para evitar esto, las empresas deben asegurarse de que los conocimientos adquiridos por el uso de la IA se incorporen en el día a día de la empresa, es decir, en los procesos de la empresa y comportamientos de los empleados (Manyika & Bughin, 2018). Así, la IA debe ser inculcada en la cultura de la empresa, transformando parte de los procedimientos de la misma.

Conclusión

Hay evidencias para afirmar que el impacto del aprendizaje automático es positivo en el sector financiero, pero para potenciar este impacto las entidades deben cuidar el proceso de implementación en sus servicios. Para llegar a esta observación se han realizado varios análisis.

En primer lugar, se ha definido el concepto y la historia de la inteligencia artificial. McCarthy ya introducía que no se ha podido crear una verdadera inteligencia artificial de tipo general, actualmente, solo existe la inteligencia artificial específica (McCarthy, 1960). Por otro lado, Ray Kurzweil afirma que la evolución del hombre va ligada a la tecnología (Kurzweil, 1999). Existen diferentes puntos de vista sobre su impacto, pero todos sostienen que va a dar un giro a la sociedad, va a cambiar nuestra forma de actuar; solo quedaría por aclarar si ese giro va a ser negativo o positivo.

A continuación, el estudio se centró en el sector financiero debido a su gran dataset disponible, motivado por su sistema de contabilidad y la regulación bancaria existente que exige posibles auditorías con un horizonte temporal amplio, que precisan de herramientas de análisis rápidas y eficientes, que permitan a las instituciones financieras especializarse y dar un valor añadido, anticipándose a las necesidades de sus clientes. Asimismo, la generación de datos crece de manera exponencial debido al avance en la difusión de datos de los servicios multicanal. La rama de la inteligencia artificial en la que se ha enfocado el trabajo es el aprendizaje automático, siendo la más aplicada del sector financiero

Luego, se han estudiado las diferentes aplicaciones de estos algoritmos en el sector financiero. Se utilizan tanto en el front-office, como en middle-office y back-office. Permiten facilitar la detección de fraude, predecir el riesgo crediticio con mayor precisión, reducir los costes de las operaciones bursátiles en los mercados financieros y aumentar la rentabilidad obtenida de estas, asesorando sobre que operaciones son más rentables, así como ofrecer un servicio al cliente constante y personalizado con el uso de chatbots y roboadvisors y analizar documentos con rapidez.

Históricamente, las instituciones financieras confiaban en el precio, la velocidad y el acceso como formas de aumentar su cuota de mercado. Con la globalización, la

personalización en tiempo real de los productos financieros que precisen los clientes determinará la ventaja competitiva en el sector. La implementación de los algoritmos de machine learning, su interiorización en la cultura de trabajo y la innovación y mejora continua será clave en el éxito empresarial porque permitirán el incremento de su cuota de mercado.

La aplicación de los algoritmos de aprendizaje automático, aumentará la productividad de los empleados, optimizando el tiempo de trabajo, liberándolos de tareas repetitivas para realizar tareas de mayor valor, e incrementará la importancia de las habilidades humanas. Las máquinas realizarán el trabajo de recopilación, verificación y consolidación de datos; permitiendo a los empleados centrarse en el análisis y la toma de decisiones, mejorando la experiencia del cliente y atendiendo de una forma más personal. Es decir, habrá una cooperación entre la rapidez de las máquinas y la inteligencia humana emocional. Esto ocasionará un cambio en la obtención de beneficios en la cadena de valor. De esta manera, la demanda de aptitudes físicas en el sector financiero disminuirá, por lo que habrá un exceso de oferta y la demanda de habilidades cognitivas aumentará. Los candidatos más demandados en el sector financiero son aquellos con experiencia en inteligencia artificial, aprendizaje automático y data science, y esta tendencia seguramente se mantendrá en el futuro.

Además, la automatización de las tareas y la rapidez que aportan estos algoritmos agilizará la formación de las nuevas incorporaciones de un banco y permitirá la escalabilidad de los servicios financieros, siendo accesibles para un mayor número de personas.

No obstante, para beneficiarse de la incorporación de estos algoritmos es necesario considerar una serie de aspectos y elaborar una estrategia para aplicarlos correctamente. El número de científicos de datos es reducido, por lo que las empresas deben dedicar atención a atraer a este talento a su empresa y en caso de subcontratarlo, establecer relaciones a largo plazo. También se requiere atención por parte de las compañías para tener algoritmos justos y transparentes, evitando sesgos históricos, haciendo uso de datos heterogéneos y mecanismos de entrenamiento y metodologías de elaboración de algoritmos óptimas. Asimismo, se necesitan desarrollar algoritmos generalizables para evitar que la aplicación de un algoritmo en un escenario distinto a aquel en el que ha sido entrenado, suponga un mal funcionamiento y, en consecuencia, pérdidas para la entidad.

Además, para evitar un uso indebido y malicioso de los datos de los clientes, es necesario reevaluar el equilibrio entre la seguridad y la privacidad de datos que se desea, porque la responsabilidad es de la compañía que aplica el modelo. Para lidiar con este desafío se han desarrollado leyes de protección de datos y se hace uso de la ciberseguridad. Igualmente, el ML debe de esta inculcado en la cultura de la empresa para superar la barrera humana de carencia de una cultura de innovación.

En conclusión, es necesario tener en cuenta diversos aspectos antes de incorporar algoritmos a las entidades financieras para explotar sus beneficios. El estudio realizado indica que la forma de abordar la cuestión del ML en las entidades financieras definirá su cuota de mercado y, por tanto, su viabilidad en el futuro.

Bibliografía

- Ackerman, E. (2014). A better test than turing [News]. *IEEE Spectrum*, 51(10), 20-21.
- Aggarwal, R., & Stein, P. (2016). The complex regulatory landscape for fintech: an uncertain future for small and medium-sized enterprise lending. En *World Economic Forum White Paper*, 1-35.
- Alpaydin, E. (2014). *Introduction to machine learning*. MIT press.
- Alt, R., & Puschmann, T. (2012). The rise of customer-oriented banking-electronic markets are paving the way for change in the financial industry. *Electronic Markets*, 22(4), 203-215.
- Aristóteles. (1984). *Nicomachean En: The complete works of Aristotle*. Vol II (ed. J. Barnes).
- Awoyemi, J. O., Adetunmbi, A. O., & Oluwadare, S. A. (2017). Credit card fraud detection using machine learning techniques: A comparative analysis. En *2017 International Conference on Computing Networking and Informatics (ICCNI)*. IEEE, 2017, 1-9.
- Banco de España. (2020). Plan Estratégico 2024. *Eurosistema*
- Banco de Pagos Internacionales. (2015). Orientaciones sobre riesgo de crédito y contabilidad de pérdidas crediticias esperadas. *Comité de Supervisión Bancaria de Basilea*
- Barr, A. (2015). Google mistakenly tags black people as ‘gorillas,’ showing limits of algorithms. *The Wall Street Journal*, 1, 2015.
- Bequé, A., Coussement, K., Gayler, R., & Lessmann, S. (2017). Approaches for credit scorecard calibration: An empirical analysis. *Knowledge-Based Systems*, 134, 213-227.
- Bhattacharyya, S., Jha, S., Tharakunnel, K., & Westland, J. C. (2011). Data mining for credit card fraud: A comparative study. *Decision Support Systems*, 50(3), 602-613.
- Buolamwini, J., & Gebru, T. (2018). Gender shades: Intersectional accuracy disparities in commercial gender classification. En *Conference on fairness, accountability and transparency*, 77-91.
- Camino, J. R., & de Garcillán López-Rúa, M. (2014). *Marketing sectorial. Principios y aplicaciones*. Esic Editorial.
- Chui, M., Harryson, M., Manyika, J., Roberts, R., Chung, R., van Heteren, A., & Nel, P. (2018). Notes from the AI frontier: Applying AI for social good. *McKinsey Global Institute*.
- Chui, M., Manyika, J., & Miremadi, M. (2015). Four fundamentals of workplace automation. *McKinsey Quarterly*, 29(3), 1-9.
- Comisión Europea. (2018). Comunicación de la Comisión al Parlamento Europeo, al Consejo Europeo, al Consejo, al Comité Económico y Social Europeo y al Comité de las Regiones: Inteligencia artificial para Europa. Bruselas. Recuperado de <https://ec.europa.eu/transparency/regdoc/rep/1/2018/ES/COM-2018-237-F1-ES-MAIN-PART-1.PDF>
- Contri, B., Galaski, R., Baumann, N., Stier, C., & Celner, A. (2018). The New Physics of Financial Services: Understanding how artificial intelligence is transforming the financial

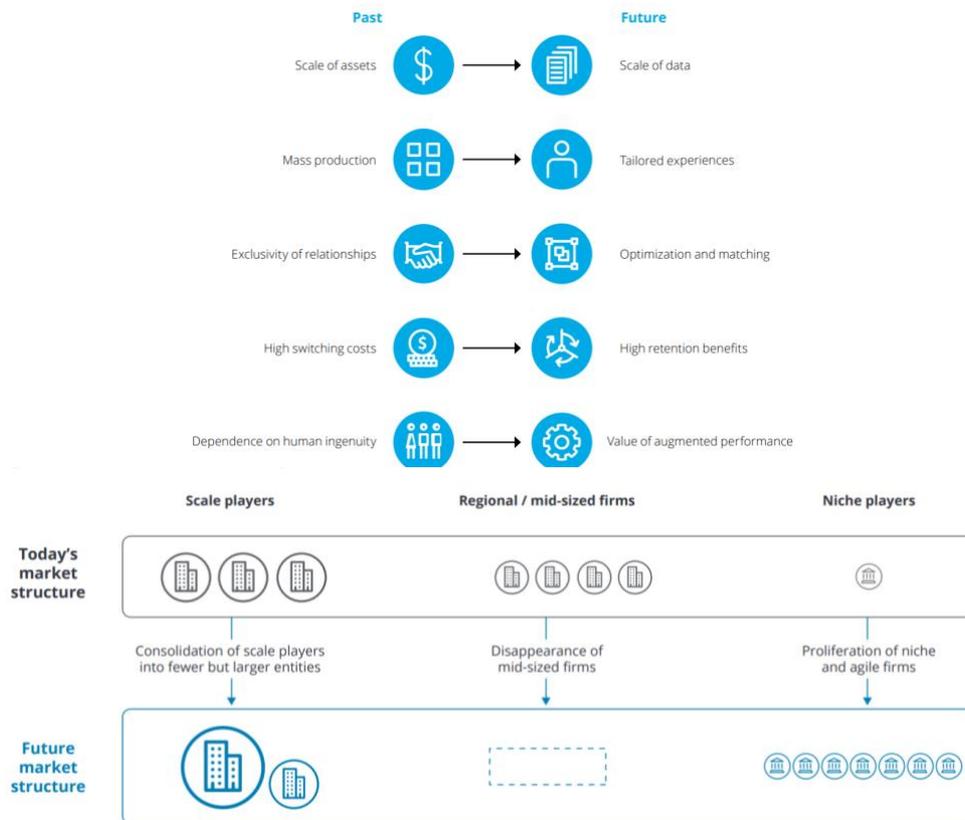
- ecosystem. *En Deloitte, World Economic Forum*. Recuperado el 22 de enero de 2020, de <https://www2.deloitte.com/content/dam/Deloitte/uk/Documents/financial-services/deloitte-uk-world-economic-forum-artificial-intelligence-summary-report.pdf>
- Coulter, K. S., Gummerus, J., Liljander, V., Weman, E., & Pihlström, M. (2012). Customer engagement in a Facebook brand community. *Management Research Review*.
- Cuya, M. L. (2016). La disrupción de las startups FinTech en el mundo financiero.
- Digiampietri, L. A., Roman, N. T., Meira, L. A., Ferreira, C. D., Kondo, A. A., Constantino, E. R., ... & Lanna, A. (2008). Uses of artificial intelligence in the Brazilian customs fraud detection system. *En Proceedings of the 2008 international conference on digital government research. Digital Government Society of North America*, 181-187.
- Dong, G., Lai, K. K., & Yen, J. (2010). Credit scorecard based on logistic regression with random coefficients. *Procedia Computer Science*, 1(1), 2463-2468.
- Drovandi, M. C. (2000). Criptografía-Seguridad en esquemas de File Transfer-Seguridad en Internet. *Revista de la Universidad de Mendoza*.
- Edelman AI Center of Expertise (2019). 2019 Artificial Intelligence Survey. Recuperado el 15 de febrero 2020, de <https://www.edelman.com/research/2019-artificial-intelligence-survey>
- Elvery, J. (2019). Changes in the Occupational Structure of the United States: 1860 to 2015. *Economic Commentary*, (2019-09).
- Faggella, D. (2019). AI and Financial Risk Management – Critical Insights for Banking Leaders, *Emerj*. Recuperado el 22 de enero de 2020, de <https://emerj.com/ai-podcast-interviews/artificial-intelligence-and-financial-risk-management/>
- Faggella, D. (2020). AI in Banking – An Analysis of America’s 7 Top Banks, *Emerj*. Recuperado el 12 de abril de 2020, de <https://emerj.com/ai-sector-overviews/ai-in-banking-analysis/>
- Faggella, D., & Bharadwaj, R. (2019). Emerj Vendor Scorecard and Capability Map: AI in Banking 2019, *Emerj*. Recuperado el 22 de enero de 2020, de <https://emerj.com/emerj-team-updates/emerj-launched-ai-in-banking-report/>
- Fawcett, T., Haimowitz, I., Provost, F., & Stolfo, S. (1998). AI approaches to fraud detection and risk management. *AI Magazine*, 19(2), 107-107.
- Fernández, A. (2019). Inteligencia artificial en los servicios financieros. *Boletín Económico*, (JUN)
- Fernández, E., Merlino, H., Ochoa, M. A., Diez, E., Britos, P. V., & García Martínez, R. (2005). Gestión asistida de documentos en una metodología de explotación de información. *En XI Congreso Argentino de Ciencias de la Computación*.
- Gelbukh, A. (2010). Procesamiento de lenguaje natural y sus aplicaciones. *Komputer Sapiens*, 1, 6-11.
- Gironés, J., Casas, J., Minguillón, J., & Caihuelas, R. (2017). *Minería de datos, modelos y algoritmos*. Editorial UOC.
- Gnambs, T., Appel, M., & Batinic, B. (2010). Color red in web-based knowledge testing. *Computers in Human Behavior*, 26(6), 1625-1631.

- Guo, L., Shi, F., & Tu, J. (2016). Textual analysis and machine learning: Crack unstructured data in finance and accounting. *The Journal of Finance and Data Science*, 2(3), 153-170.
- Hanmandlu, M., Mohan, K. M., Chakraborty, S., Goyal, S., & Choudhury, D. R. (2003). Unconstrained handwritten character recognition based on fuzzy logic. *Pattern Recognition*, 36(3), 603-623.
- Harford, T. (2012). High-frequency trading and the \$440 m mistake. *BBC Radio 4, More or Less*.
- He, H., & Garcia, E. A. (2009). Learning from imbalanced data. *IEEE Transactions on knowledge and data engineering*, 21(9), 1263-1284.
- Hernández Orallo, J., Ramírez Quintana, M. J., & Ferri Ramírez, C. (2004). *Introducción a la Minería de Datos*. Editorial Pearson Prentice Hall.
- Hoffmann, A. G. (1990). General Limitations on Machine Learning. En *ECAI*, 345-347.
- Jubraj, R., Graham, T., & Ryan, E. (2018). Redefine banking with artificial intelligence. *Intelligent Bank, Accenture*, 1-20.
- Kearns, M., & Nevmyvaka, Y. (2013). Machine learning for market microstructure and high frequency trading. *High Frequency Trading: New Realities for Traders, Markets, and Regulators*.
- Knoke, D., & Yang, S. (2008). *Social Network Analysis* (2nd ed.). Sage Publications, Incorporated.
- Kurzweil, R. (1999). *The Age of Spiritual Machines*, Viking.
- Larsen, M. (2017). Innovation in banking—Are we communicating the value created. *Published on behalf of Banking Network*.
- Lee, I. (2017). Big data: Dimensions, evolution, impacts, and challenges. *Business Horizons*, 60(3), 293-303.
- Levesque, H. J. (2017). *Common sense, the Turing test, and the quest for real AI*. MIT Press.
- Llopart, C. (2016). La opinión del experto: Los robots y el Big Data reemplazan el factor humano en los servicios financieros ¿A favor o en contra? | *NoviCap*. Recuperado el 15 de diciembre de 2019, de <https://novicap.com/blog/robots-big-data-reemplazan-humanos-servicios-finanzas/>
- Longadge, R., & Dongre, S. (2013). Class imbalance problem in data mining: Review. *arXiv preprint arXiv:1305.1707*
- Lusardi, A., & Mitchell, O. S. (2014). The economic importance of financial literacy: Theory and evidence. *Journal of economic literature*, 52(1), 5-44.
- Lynch, S. (2017). Andrew Ng: Why AI is the new electricity. *Insights by Stanford Business*, 11.
- Manyika, J., & Bughin, J. (2018). The promise and challenge of the age of artificial intelligence. *McKinsey Global Institute Executive Briefing*.
- Marinai, S., & Fujisawa, H. (Eds.). (2007). *Machine learning in document analysis and recognition*. Springer, 90, 1-20.

- Martínez, F. (2010). Robots financieros, los nuevos señores del corto plazo. Recuperado el 22 de enero de 2020, de https://cincodias.elpais.com/cincodias/2010/11/20/mercados/1290218503_850215.html
- McCarthy, J. (1960). *Programs with common sense*. RLE and MIT computation center, 300-307.
- McCarthy, J., Minsky, M. L., Rochester, N., & Shannon, C. E. (2006). A proposal for the dartmouth summer research project on artificial intelligence, august 31, 1955. *AI magazine*, 27(4), 12-12.
- McGloin, J., & Kirk, D. (2010). An overview of social network analysis. *Journal of Criminal Justice Education*, 21(2).
- Miller, T. (2019). Explanation in artificial intelligence: Insights from the social sciences. *Artificial Intelligence*, 267, 1-38.
- MMC Ventures (2019). *The State of AI 2019: Divergence*. Recuperado el 25 de marzo de 2020 de <https://www.stateofai2019.com/>
- Moreno, J. L., Jennings, H. H., & Whitin, E. S. (1932). *Group method and group psychotherapy* (No. 5). Beacon House.
- Naisbitt, J. (1984). *Megatrends: Ten new directions transforming our lives*. NY Warner Communications Company, 23-24
- Niederhoffer, V., & Osborne, M. F. M. (1966). Market making and reversal on the stock exchange. *Journal of the American Statistical Association*, 61(316), 897-916
- Okuda, T., & Shoda, S. (2018). AI-based chatbot service for financial industry. *Fujitsu Scientific and Technical Journal*, 54(2), 4-8.
- Pérez-Martín, A., Pérez-Torregrosa, A., & Vaca, M. (2018). Big Data techniques to measure credit banking risk in home equity loans. *Journal of Business Research*, 89, 448-454.
- Philippon, T. (2016). *The fintech opportunity* (No. w22476). National Bureau of Economic Research.
- Rahman, A. M., Al Mamun, A., & Islam, A. (2017). Programming challenges of chatbot: Current and future prospective. En *2017 IEEE Region 10 Humanitarian Technology Conference (R10-HTC)*. IEEE, 75-78.
- Rao, P. K. (2003). *Development finance*. Springer Science & Business Media.
- Ravi, V., & Kamaruddin, S. (2017). Big Data Analytics Enabled Smart Financial Services: Opportunities and Challenges. En *International Conference on Big Data Analytics*. Springer, Cham, 15-39.
- Rayo Cantón, S., Lara Rubio, J., & Camino Blasco, D. (2010). Un Modelo de Credit Scoring para instituciones de microfinanzas en el marco de Basilea II. *Journal of Economics, Finance and Administrative Science*, 15(28), 89-124.
- Rechenthin, M., & Street, W. N. (2013). Using conditional probability to identify trends in intra-day high-frequency equity pricing. *Physica A: Statistical Mechanics and its Applications*, 392(24), 6169-6188.
- Rifkin, J. (1996). *El fin de trabajo. Nuevas tecnologías contra puestos de trabajo: el nacimiento de una nueva era*. Paidós.

- Sabharwal, C. L. (2018). The rise of machine learning and robo-advisors in banking. *IDRBT Journal of Banking Technology*, 28-43.
- Serban, I. V., Sankar, C., Germain, M., Zhang, S., Lin, Z., Subramanian, S., ... & Rajeshwar, S. (2017). A deep reinforcement learning chatbot. *arXiv preprint arXiv:1709.02349*.
- Seth, S. (2020). Basics of algorithmic trading: Concepts and examples. *Investopedia*. Recuperado el 10 de abril de 2020 de <https://www.investopedia.com/articles/active-trading/101014/basics-algorithmic-trading-concepts-and-examples.asp>
- Shleifer, A. (2000). *Inefficient markets: An introduction to behavioural finance*. OUP Oxford.
- Shmelova, T., Sikirda, Y., & Sterenharz, A. (Eds.). (2019). *Artificial Intelligence Applications in the Aviation and Aerospace Industries*. IGI Global.
- Siddiqi, N. (2006). *Credit risk scorecards: Developing and implementing intelligent credit scoring*. John Wiley & Sons, 3.
- Srivastava, U., & Gopalkrishnan, S. (2015). Impact of big data analytics on banking sector: Learning for Indian banks. *Procedia Computer Science*, 50, 643-652.
- Thomas, L., Edelman, D., & Crook, J. (2017). *Credit scoring and its applications (Mathematics in industry)*. Society for Industrial and Applied Mathematics (SIAM).
- Trelewicz, J. Q. (2017). Big data and big money: The role of data in the financial sector. *IT Professional*, 19(3), 8-10.
- Turing, A. M. (1950) Computing Machinery and Intelligence. *Mind*, 59(236).
- United Consulting Group. (2018). Artificial Intelligence Effects on the Financial Services Sector. Recuperado de <http://www.ucg-sa.com/wp-content/uploads/2018/12/Artificial-Intelligence-Effects-on-the-Financial-Sector.pdf>
- Van der Hulst, R. C. (2009). Introduction to Social Network Analysis (SNA) as an investigative tool. *Trends in Organized Crime*, 12(2), 101-121.
- Van Liebergen, B. (2017). Machine learning: A revolution in risk management and compliance?. *Journal of Financial Transformation*, 45, 60-67.
- Wagner, S., & Hagan, S. (2019). *Finance Needs People Who Work Well With Robots*. Bloomberg. Recuperado el 3 de abril de 2020 de <https://www.bloomberg.com/news/articles/2019-08-20/finance-needs-people-who-work-well-with-robots>
- Wang, J., Wang, J. (2017). Forecasting stochastic neural network based on financial empirical mode decomposition. *Neural Networks*, 90, 8-20
- Wingfield, N. (2017). As Amazon Pushes Forward With Robots, Workers Find New Roles. *The New York Times*.
- Woolley, P. (2010). Por qué los mercados financieros son tan ineficientes y explotadores, y una propuesta de solución. *Revista de economía institucional*, 12(23), 55-83.
- World Economic Forum. (2018). How to Prevent Discriminatory Outcomes in Machine Learning. *White Paper. Global Future Council on Human Rights 2016–2018*.

Xia, F., Yang, L. T., Wang, L., & Vinel, A. (2012). Internet of things. *International journal of communication systems*, 25(9), 1101-1102.



Anexo 3: Cambios que provocará la implementación de la IA en empresas del sector financiero.
 Fuente: Contri, Galaski, Baumann, Stier & Celner, (2018: 6 y 16).