



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA



INFLUENCIA DE LA INTELIGENCIA ARTIFICIAL EN EL SECTOR FINANCIERO. DESARROLLO DE UN MODELO DE PREDICCIÓN DE TRANSACCIONES FUTURAS

Sheyla Nieves del Amo

Tutor: Alicia Mateos Ronco

Cotutor: Adrián Colomer Granero

Trabajo Fin de Grado presentado en la Facultad de Administración y Dirección de Empresas de la Universitat Politècnica de València, para la obtención del Título de Graduado en Administración y Dirección de Empresas

Curso 2018-19

Valencia, 5 de julio de 2019

Resumen

En los últimos años, la rápida evolución experimentada en el sector tecnológico y el constante incremento del número de datos disponibles en el mundo han dado lugar al nacimiento de la inteligencia artificial. Esta va encaminada al diseño e implementación de sistemas inteligentes, capaces de aprender autónomamente a gran velocidad con el fin de ayudar al ser humano en diversas actividades de la vida cotidiana. En concreto, en el sector financiero, un elevado número de aplicaciones han sido propuestas para dar apoyo, tanto a los clientes como a las propias entidades, contribuyendo así a propiciar el correcto funcionamiento del sistema financiero.

Por ello, el principal objetivo de este Trabajo Fin de Grado es identificar las principales aplicaciones hasta ahora existentes en el entorno financiero, tales como los *chatbots* y la autenticación biométrica, entre otras, así como los beneficios que estas reportan a la sociedad. Además, a modo de ejemplo práctico se va a proponer el diseño de un modelo inteligente de clasificación binaria. Concretamente, consistirá en predecir si un determinado cliente realizará o no transacciones futuras independientemente de la cantidad a transferir. Para ello, se utilizarán redes neuronales artificiales, como es el caso del perceptrón multicapa.

Palabras clave: *sector financiero; banca; chatbots; asistente virtual; inteligencia artificial; perceptrón multicapa.*

Resum

En els últims anys, la ràpida evolució experimentada al sector tecnològic i el constant increment del nombre de dades disponibles al món, han donat lloc al naixement de la intel·ligència artificial. Esta va encaminada al disseny i implementació de sistemes intel·ligents, capaços d'aprendre autònomament a gran velocitat amb el fi d'ajudar al ser humà en diverses activitats de la vida quotidiana. En concret, al sector financer, un elevat nombre d'aplicacions han sigut proposades per a donar suport tant als clients com a les pròpies entitats, contribuint així a propiciar el correcte funcionament del sistema financer.

Per això, el principal objectiu d'aquest Treball Fi de Grau és identificar les principals aplicacions que, fins ara, existeixen a l'entorn financer, com ara els *chatbots* i la autenticació biomètrica, entre altres, així com els beneficis que estes reporten a la societat. A més, com a exemple pràctic es va a proposar el disseny d'un model intel·ligent de classificació binària. Concretament, consistirà en predir si un determinat client realitzarà o no transaccions futures independentment de la quantitat a transferir. Per a això, s'utilitzaran xarxes neuronals artificials, com és el cas del perceptró multicapa.

Paraules clau: *sector financer; banca; chatbots; assistent virtual; intel·ligència artificial; perceptró multicapa.*

Abstract

In recent years, the rapid evolution experienced in the technology sector and the continuous growth of available data in the world have led to the birth of artificial intelligence. Its objective is the design and implementation of intelligent systems, capable of learning autonomously at high speed in order to help humans in various activities of daily life. Specifically, in the financial sector a large number of applications have been proposed to support both customers and the financial institutions, thus contributing to the proper working of the financial system.

Therefore, the main objective of this Final Degree Project is to identify the main applications existing so far in the financial environment, such as chatbots and biometric authentication, among others, as well as the benefits they bring to society. In addition, as a practical example, the design of an intelligent binary classification model will be proposed. Specifically, it will consist of predicting whether or not a given customer will carry out future transactions regardless of the transfer amount. Artificial neural networks will be used for this purpose, as is the case of the multilayer perceptron.

Keywords: *financial sector; banking; chatbots; virtual assistant; artificial intelligence; multilayer perceptron*

ÍNDICE

Capítulo 1. Introducción y Objetivos	6
1.1. Introducción	6
1.2. Objetivos	7
Capítulo 2. Estado del arte de la inteligencia artificial. Concepto y aportaciones a la economía. 8	
2.1. Orígenes de la inteligencia artificial.....	8
2.2. Impacto de la inteligencia artificial en la economía.....	9
2.3. Influencia de la inteligencia artificial entre sectores	13
2.3.1. Sector sanitario.....	14
2.3.2. Sector del automóvil.....	15
2.3.3. Sector minorista.....	16
Capítulo 3. El sector financiero español.....	17
3.1. Estado actual del sector financiero español.....	17
3.2. Influencia del sector financiero en la economía.....	20
3.3. Principales entidades bancarias españolas	22
3.3.1. Rentabilidad	23
3.3.2. Liquidez.....	24
3.3.3. Riesgo.....	25
3.3.4. Solvencia.....	26
3.3.5. Eficiencia.....	27
Capítulo 4. Inteligencia artificial en el sector financiero.	29
4.1. Aplicaciones de la inteligencia artificial en el sector financiero	31
4.1.1. <i>Chatbots</i>	32
4.1.2. Asistentes virtuales de voz	32
4.1.3. Autenticación biométrica	33
4.1.4. Antifraude y control del blanqueo de capitales	34
4.1.5. Evaluación crediticia	34
4.1.6. Datos alternativos en negociación y gestión de activos	34
4.2. Limitaciones de la inteligencia artificial	35
4.3. Inclusión de la inteligencia artificial en las principales entidades bancarias españolas. ...	36
4.3.1. Banco Santander.....	36
4.3.2. BBVA.....	38
4.3.3. CaixaBank.....	40
4.3.4. Análisis comparativo.....	41
Capítulo 5. Modelo de predicción de transacciones.....	44

5.1. Técnicas de <i>machine learning</i> disponibles para la resolución de problemas de clasificación.....	44
5.2. El perceptrón multicapa.....	46
5.2.1. Estructura del perceptrón multicapa.....	47
5.2.2. Modo de funcionamiento de un perceptrón multicapa.....	47
5.3. Material empleado.....	50
5.3.1. Base de datos.....	50
5.3.2. Entorno de programación.....	50
5.4. Análisis estadístico de los datos.....	51
5.5. Descripción de la arquitectura diseñada.....	55
5.5.1 Preprocesado de datos.....	55
5.5.2. Arquitectura del perceptrón multicapa.....	56
5.5.3. Elección de los hiperparámetros del modelo.....	58
5.6. Resultados.....	59
Capítulo 6. Conclusiones.....	62
Capítulo 7. Líneas de trabajo futuro.....	64
Referencias.....	65
Anexo I.....	70
Anexo II.....	71
1. Histogramas.....	71
2. Diagrama <i>box-whiskers</i>	73
3. Matriz de correlación.....	75
4. Matriz de multicolinealidad.....	76

Índice de figuras

Figura 1: Crecimiento del PIB de las principales economías mundiales potenciado por la inteligencia artificial.....	13
Figura 2: Instituciones financieras españolas. En naranja aparecen las reguladas por el banco de España, en verde las que regula la CNMV y en azul la DGSFP.	19
Figura 3: Incremento del número de datos y principales fuentes de generación de ellos.	29
Figura 4: Principales aplicaciones de inteligencia artificial en diferentes instituciones financieras y fases de la cadena de valor, atendiendo al grado de madurez.	31
Figura 5: Comparativa entre una neurona real y una artificial.....	47
Figura 6: Propagación hacia delante de una red neuronal artificial. Activación de las neuronas.	48
Figura 7: Arquitectura de un perceptrón multicapa con una única capa oculta.	49
Figura 8: Frecuencias relativas y absolutas de la variable categórica de la base de datos de entrenamiento.	51
Figura 9: Representación de la distribución de las variables de entrenamiento (izquierda) y testeo (derecha).	52
Figura 10: Diagrama "box-whiskers" de las cuatro primeras variables de la base de datos de entrenamiento (izquierda) y testeo (derecha).	53
Figura 11: Histograma de las 200 variables de entrenamiento.	71
Figura 12: Histograma de las 200 variables de test.....	72
Figura 13: Diagrama box-whiskers de las 200 variables de entrenamiento.	73
Figura 14: Diagrama box-whiskers de las 200 variables de test.....	74
Figura 15: Mapa de color 'jet'.....	75
Figura 16: Matriz de correlación en escala de color 'jet'.	75
Figura 17: Mapa de color 'gist-rainbow'.	76
Figura 18: Matriz de multicolinealidad en escala de color 'gist-rainbow'.	76

Índice de gráficas

Gráfica 1: Evolución del número de puestos de trabajo que requieren cualificación en inteligencia artificial.	10
Gráfica 2: Número de aplicaciones patentadas basadas en inteligencia artificial. A) Evolución global. B) Evolución experimentada por cada país.	12
Gráfica 3: Ingresos globales en el sector sanitario debidos a la inclusión de sistemas inteligentes.	15
Gráfica 4: Evolución del PIB en el sector financiero y aseguradoras en España.	20
Gráfica 5: Evolución del número de empleados y del salario en el sector financiero y de seguros.	21
Gráfica 6: Variación del número sucursales bancarias en España.	22
Gráfica 7: Financiación capital riesgo a start-ups especializadas en aplicaciones de inteligencia artificial.	30
Gráfica 8: Uso de tecnologías biométricas en los bancos.	33
Gráfica 9: Resultados de las pérdidas y precisión de las fases de enteramiento y validación del modelo.	59
Gráfica 10: Representación de la curva ROC.	60
Gráfica 11: Porcentaje de clientes pertenecientes a cada clase tras la predicción de las muestras de test.	61

Índice de tablas

Tabla 1: Principales partidas de las CCAA de las cinco entidades a analizar.	23
Tabla 2: Ratios de rentabilidad de las cinco principales entidades bancarias españolas.	23
Tabla 3: Ratios de liquidez de las cinco principales entidades bancarias españolas y el sector global.	24
Tabla 4: Ratios de riesgo de las cinco principales entidades bancarias españolas.	25
Tabla 5: Ratios de solvencia de las cinco principales entidades bancarias españolas y el sector global.	26
Tabla 6: Ratios de eficiencia de las cinco principales entidades bancarias españolas y el sector global.	27
Tabla 7: Resumen de los diferentes ratios calculados, bancos ordenados de mejor a menor posición (1-5)..	27
Tabla 8: Cuadro resumen de las aplicaciones de inteligencia artificial integradas en Banco Santander, BBVA y CaixaBank, atendiendo a la necesidad que satisfacen así como al ámbito de aplicación: G) aplicación global, E) en España.	42
Tabla 9: Comparativa de diversas técnicas de clasificación.	45
Tabla 10: Funciones de activación comunes..	48
Tabla 11: Parámetros estadísticos de las cuatro primera variables de la base de datos de entrenamiento (izquierda) y testeo (derecha).	53
Tabla 12: Matriz de correlación de las cuatro primeras variables de entrenamiento.	54
Tabla 13: Matriz de multicolinealidad de las cuatro primeras variables de entrenamiento..	54
Tabla 14: Dimensiones originales de los datos proporcionados..	55
Tabla 15: Dimensiones originales de los datos tras realizar las particiones requeridas..	56
Tabla 16: Resumen de los hiperparámetros del modelo.....	58
Tabla 17: Informe de clasificación del modelo.	59
Tabla 18: Matriz de confusión.	61
Tabla 19: Principales partidas de las 10 entidades bancarias españolas con mayor partida de activo.....	70

Capítulo 1. Introducción y Objetivos

1.1. Introducción

En el mundo actual, existe una creciente tendencia a la inclusión de las tecnologías en todas las áreas y sectores económicos, así como a la digitalización y automatización de procesos. En este último aspecto y gracias a la amplia labor de investigación desarrollada por psicólogos, ingenieros y matemáticos, la inteligencia artificial puede aportar grandes contribuciones. Así, la inteligencia artificial surge para dar lugar a sistemas cognitivos que puedan ayudar al hombre en la realización de tareas repetitivas y que requieran de mayor precisión y velocidad de actuación.

El impacto que la llegada de la inteligencia artificial puede producir en la economía comienza a dar los primeros frutos, si bien actualmente la mayoría de informes disponibles basan sus estudios en pronósticos de futuro pues se trata de una tecnología considerablemente reciente. Con ello, gran parte de las economías experimentarán los beneficios económicos que estos sistemas pueden generar, lo cual puede contribuir a abrir una brecha entre aquellos países que la utilizan y aquellos más rezagados.

En lo que respecta al sector financiero, la inteligencia artificial puede contribuir en varios niveles de su cadena de valor de forma que puede ayudar a mejorar el servicio ofrecido al público, diseñando aplicaciones disponibles en todo momento para dar respuesta a las dudas y preguntas sugeridas por los mismos. Del mismo modo, contribuye en gran medida a proteger la identidad de los usuarios y evitar la realización de transacciones fraudulentas recurriendo al empleo de técnicas de reconocimiento biométricas.

En otro eslabón de la cadena de valor de las entidades bancarias, el *credit scoring* y los modelos predictivos pueden contribuir, entre otras cosas, a la reducción del tiempo empleado en la evaluación de clientes en el momento de concederles determinadas prestaciones, así como a incrementar la fiabilidad de dichas predicciones. De esta forma, la inteligencia artificial y más concretamente el *machine learning* pueden resultar técnicas claves de resolución de problemas.

En definitiva, muchas son las ventajas que la inteligencia artificial puede aportar a la sociedad en general y a la banca en particular. No obstante, estos sistemas todavía se encuentran en desarrollo por lo que presentan una serie de limitaciones, tanto sociales como referentes al diseño de dichas aplicaciones, que han de ser abordadas.

1.2. Objetivos

El objetivo principal perseguido en este Trabajo de Fin de Grado consiste en el análisis del efecto que la inteligencia artificial puede generar en el sector financiero, concretamente en la banca española. Para ello, otra serie de objetivos pueden plantearse, que serán la guía para el desarrollo de este documento:

- Analizar la influencia de la inteligencia artificial en la economía, valorando aspectos tales como el impacto que se espera que esta genere en los diferentes países, así como la inversión ya realizada por las diferentes economías del mundo. Del mismo modo, se pueden extraer conclusiones de forma individualizada analizando los sectores económicos que más influencia reciben de esta tecnología, en función de su grado de adopción.
- Estudiar el sector financiero español realizando un análisis de la estructura del mismo, así como el análisis de distintas variables económicas que evidencien las aportaciones que dicho sector ejerce sobre la economía nacional. De esta forma, también es posible establecer una comparativa entre entidades que conforman el sector bancario, a partir del análisis económico-financiero de las mismas.
- Descripción de las principales tecnologías de inteligencia artificial integradas en el sector financiero así como las necesidades para las cuales han sido diseñadas.
- Identificación de dichas tecnologías dentro de las tres principales entidades bancarias españolas, de modo que se permita analizar el nivel de maduración de la inteligencia artificial en el sector bancario español.
- Aplicación práctica de un modelo de predicción de aplicación en el sector financiero, mediante el empleo de técnicas de inteligencia artificial.

Capítulo 2. Estado del arte de la inteligencia artificial. Concepto y aportaciones a la economía.

En este capítulo se va a exponer una breve descripción del concepto de inteligencia artificial, así como de sus orígenes y evolución. A continuación, se analizará la influencia que esta tecnología puede ejercer directamente sobre la economía de los países que la integran en sus actividades laborales y los beneficios que ello supone.

2.1. Orígenes de la inteligencia artificial.

Desde los orígenes de la humanidad, el hombre siempre ha tratado de entender aquello que le hace pensar, para después poder recrearlo en máquinas inteligentes. Un primer ejemplo procede de la antigua Grecia de la mano de Aristóteles (384 a.C.), cuya obra se basó en explicar el funcionamiento racional de la mente (Luger, 2005). Por su parte, Ramón LLull (siglo XIII) planteó la idea de que el razonamiento se podría plasmar en una máquina de manera artificial (Fidora & Sierra, 2011); y, Hobbes (siglo XVI), promulgó la idea de que la razón no era más que cálculos (Dreyfus & Dreyfus, 1991). Así pues, el nacimiento de la inteligencia artificial (IA) parte de orígenes remotos, impulsado por el trabajo de psicólogos, ingenieros y matemáticos que, a pesar de no realizar una investigación y desarrollo en este campo sí que han contribuido aportado grandes ideas.

Ya en 1950, Alan Turing publica el artículo “*Computing Machinery and Intelligence*”, en el que ahonda en la idea de que una máquina puede imitar el funcionamiento de la mente humana (Turing, 2009). Además, propuso un mecanismo capaz de determinar si una máquina es o no inteligente, conocido como test de Turing. Justo un año después, Marvin Minsky se inspiró en el modelo propuesto por Nicolas Rashevsky en 1930 para dar lugar a la primera red neuronal digital. (Minsky, 2007).

No obstante, el término de inteligencia artificial no existía como tal hasta 1956 tras su asignación en el congreso de Dartmouth, organizado por diferentes investigadores interesados en desarrollar máquinas que imitasen el comportamiento de las personas. En él, John McCarthy de la universidad de Stanford, dio nombre a la inteligencia artificial, que definió como “la ciencia e ingenio de hacer máquinas inteligentes, especialmente programas de cómputo inteligentes”. Durante el encuentro, que duró dos meses, se definieron líneas de actuación futuras en este campo, partiendo de la hipótesis de que “todo aspecto de aprendizaje o cualquier otra característica de inteligencia puede ser definido de forma tan precisa que puede construirse una máquina para simularlo” (Moor, 2006).

Previamente a la creación de computadoras inteligentes, es necesario saber cómo dotar a estas de conocimiento. El principal problema es que a pesar de que algunos conocimientos son innatos, la mayoría se aprenden de la experiencia, por lo que no se les puede dotar manualmente de todo el

conocimiento, sino que hay que dejar que ellos mismos aprendan del entorno, ya sea con bases de datos o motores de búsqueda (Scientific American, 2016).

Por este motivo, surgieron los algoritmos de aprendizaje, capaces de hacer que las máquinas aprendan por ellas mismas. El hecho de captar información del entorno es de suma importancia para la inteligencia artificial, y dado que hay una inmensa cantidad de datos que crecen y varían continuamente, en el siglo XXI el Big data es esencial. Se estima que la cantidad de datos aumente de 33 Zettabytes en 2018 a 175 en 2025 (Reinsel et al., 2018). Un ejemplo de cómo se ha introducido el *Big Data* en sistemas inteligentes se ve claramente reflejado en el ordenador Watson de IBM. Este ordenador almacenaba en torno a 200 millones de páginas y datos en su memoria, que le permitió derrotar a los contrincantes más fuertes del programa de televisión estadounidense *Jeopardy's!*, en febrero de 2011 (Ferrucci et al., 2013).

Otro sistema revolucionario fue creado por *DeepMind*, conocido como “*AlphaGo*”. Esta máquina, gracias a la utilización de aprendizaje profundo (o *Deep Learning*) se enseñó a sí misma a jugar al Go, realizando cientos de partidas y aprendiendo en cada una de ellas. Así, fue capaz de evaluar posiciones y seleccionar movimientos, convirtiéndose en la primera máquina capaz de derrotar 4-1 a Lee Sodol en 2016, campeón mundial en Go (Hassabis & Silver, 2017).

Con el paso de los años, la demanda social de sistemas inteligentes ha crecido considerablemente en muchos ámbitos de la vida cotidiana, como son los sectores de la automoción, industria, la medicina, aeronáutica y finanzas entre otros. Esta demanda social ha forzado a la creación de lo que se conoce como inteligencia artificial 2.0 (Pan, 2016). En ella, principalmente se proponen dos grandes metas, que son conseguir sistemas inteligentes híbridos combinando máquinas y humanos, y crear sistemas inteligentes más complejos, lo que comúnmente se conoce como “*man-in-the-loop*”. En la literatura, también se conoce como sistemas cognitivos, que persigue principalmente hablar de la IA no simplemente como el desarrollo de sistemas artificiales sino como la capacidad de enseñar a los ordenadores a pensar como los seres humanos, de forma mucho más rápida, dotando a estos sistemas de tecnología que modela la biología del cerebro humano. Así pues, estas máquinas son capaces de aprender de su propia experiencia e interactuar con el ser humano ayudándole a tomar decisiones (Noor, 2015).

2.2. Impacto de la inteligencia artificial en la economía.

El gran desarrollo de sistemas inteligentes y su inclusión en diversas áreas de la economía, conlleva, en parte, a modificaciones de la actividad laboral de los empleados, así como a diferencias económicas entre comunidades.

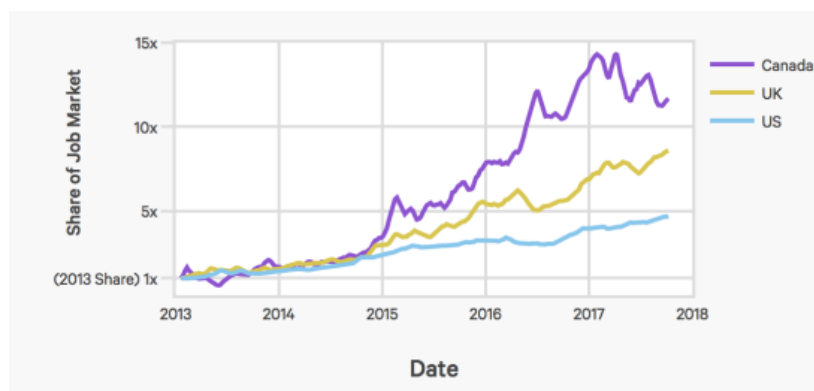
Con la llegada de la revolución industrial a finales del siglo XVIII se experimentó un gran cambio en el empleo. Por una parte, aumentan los puestos de trabajo en el sector industrial, y en menor medida en el sector servicios, en detrimento del sector agrario, debido a la incorporación de maquinaria en las fábricas y labores agrícolas. Con la incorporación de dicha maquinaria se permite complementar y ampliar el trabajo manual desarrollado por las personas, sustituyendo

algunos puestos de trabajo y, al mismo tiempo, mejorando la productividad ya que ajusta los productos de las empresas a las necesidades del consumidor (Makridakis, 2017).

Más adelante, con la revolución digital a mediados del siglo XX esta tendencia se intensificó con la llegada del internet y de los ordenadores, aumentando mucho más el empleo en el sector servicios y disminuyendo la industria manufacturera y el sector agrícola. En este caso, fueron los ordenadores los que complementaron las actividades cotidianas de las personas. Automatizando procesos se permite reemplazar tareas mentales repetitivas llevadas a cabo por los trabajadores, produciéndose un cambio en el perfil del empleado (Moran, 2018).

Es posible establecer una analogía entre estas dos revoluciones y la que se espera que genere la inteligencia artificial. Por una parte, dado el alto potencial de esta tecnología, se espera que los sistemas inteligentes sean capaces de imitar la mente humana, por lo que será posible reemplazar diversas tareas rutinarias y repetitivas del empleado por estas máquinas. Además, la velocidad de trabajo de esta tecnología es superior a la velocidad de pensamiento humano, lo que fomentará a realizar las tareas de forma más eficiente, consiguiendo así un aumento de la productividad (Makridakis, 2017). En principio, esto podría parecer la sustitución del ser humano por las máquinas en lo que respecta al trabajo, sin embargo, lo que realmente se espera es un cambio en el perfil del trabajador. Se requerirá de mayor cualificación del trabajador en aspectos más técnicos y mayores competencias para utilizar herramientas de inteligencia artificial, que requieren mayores conocimientos digitales y técnicos, y para llevar a cabo las tareas no repetitivas restantes (Moran, 2018).

Este cambio ya se puede apreciar en algunas economías, como en Estados Unidos, Reino Unido y Canadá, ya que, analizando la evolución experimentada en el perfil del empleado durante los últimos cinco años, se observa cómo se ha incrementado la demanda de personal cualificado en el dominio de inteligencia artificial (véase Gráfica 1).



Gráfica 1: Evolución del número de puestos de trabajo que requieren cualificación en inteligencia artificial. Fuente: Indeed.

El hecho de incorporar inteligencia artificial dentro de la actividad de las empresas va a generar grandes diferencias entre ellas. Así pues, va a ser posible comparar entre aquellas conocidas como *early-adopters*¹ y las más rezagadas. El primer caso, se trata de empresas proactivas, dispuestas a incorporar o desarrollar las tecnologías y herramientas más innovadoras a sus negocios, en diferentes niveles, mientras que por el contrario, los *late-adopters* tenderían a quedarse atrás entre sus competidores más cercanos, pues el impacto que generarán en el consumidor será menor ya que las oportunidades de la IA habrán sido previamente capturadas por los *front-runners*, y se quedan atrás en cuanto a desarrollar capacidades y captar talento se refiere. Además, las empresas que no se adapten a las novedades, verían reducida su cuota de mercado en detrimento de los costes asociados y un aumento de los plazos de entrega en comparación con la competencia (Bughin et al., 2018). Cabe añadir, que las ganancias procederán no solo del avance tecnológico y aumento de su consumo por parte de los clientes, sino que además permitirá de conocer mejor al público al que dirigen su actividad, recogiendo mayor cantidad de datos y analizando más en detalle el perfil del consumidor, sus preferencias y sus necesidades (Rao et al. 2017).

La inteligencia artificial, por otra parte, va a generar un gran impacto en la economía mundial, produciéndose a su vez grandes desigualdades entre los países que incorporan esta tecnología a su actividad y los que no lo hagan. Además, se espera que este hecho transcurra de forma progresiva. En las primeras etapas, las diferencias entre países no serán muy notorias ya que previamente al lanzamiento de sistemas cognitivos, es necesario invertir tiempo y recursos en investigación y desarrollo, por lo que los beneficios tardarán en percibirse. Pero, llegado el momento el incremento de los beneficios se producirá de forma acelerada en aquellos países que adopten estos sistemas en épocas tempranas, lo que conllevará a abrir una brecha entre países.

Según un informe presentado por PwC, los avances de la inteligencia artificial van a producir un incremento del PIB global de un 14% en el período de tiempo entre 2018 y 2030, lo que supondrá un total de 15.7 trillones de dólares. Sin embargo, hay grandes diferencias entre las aportaciones generadas por los diferentes países. Además, especifican que del total del crecimiento esperado, 6.6 trillones de dólares procederán de ganancias derivadas de la productividad, como puede ser la automatización de tareas, mientras que los 9.1 trillones restantes serán debidos a un incremento de la demanda por parte de los consumidores (Rao et al., 2017).

En cuanto al impacto que la Inteligencia artificial generará en los diferentes países, tanto PwC (Rao et al., 2017) como McKinsey (Bughin et al., 2018), coinciden en la misma clasificación:

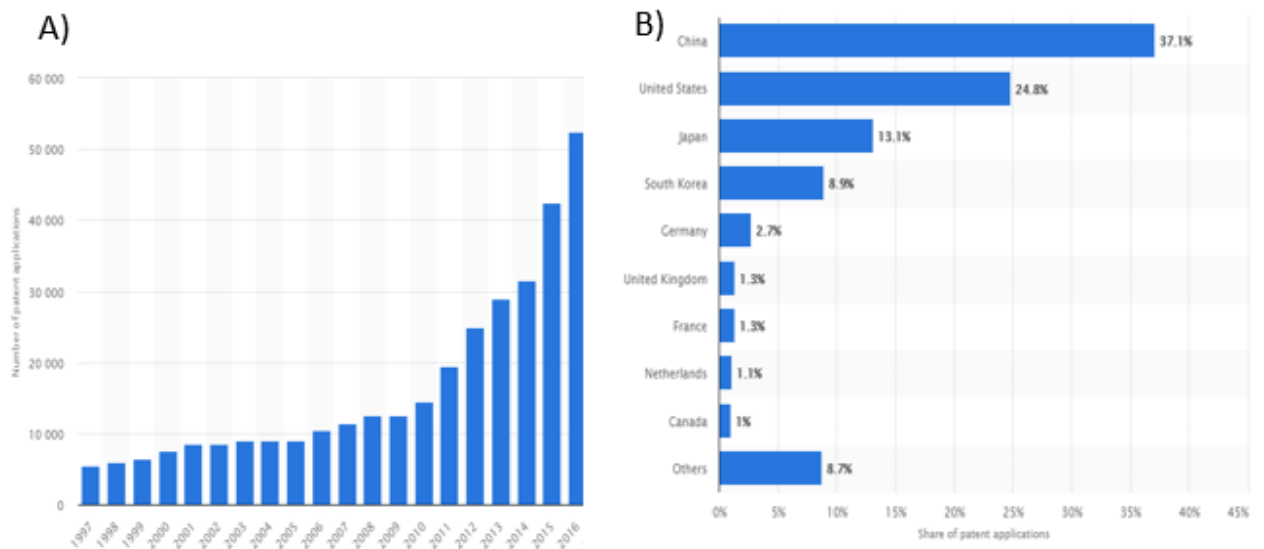
- Por un lado, Estados Unidos y China, líderes globales, son los países donde se espera que más impacto se genere, y donde actualmente existen más patentes y publicaciones de investigación registradas. No obstante, existen diferencias entre ambos. EEUU será el país que mayor beneficio genere en el corto plazo ya que es el más avanzado en cuanto a recursos financieros y de investigación se refiere. Por otra parte, se espera que China sea la que experimente un mayor crecimiento, sin embargo tardará más en conseguirlo ya que actualmente dispone de menor cantidad de recursos económicos. Además, gran parte de la economía de China es debida a la industria manufactura, que es donde más influencia

¹ *Early-adopters*: se trata de consumidores que sienten la necesidad de probar un nuevo producto en el momento en que sale al mercado.

va a ejercer la IA. De los 15.7 trillones de incremento, 7 procederán de China, en detrimento de los 3.7 trillones que se espere que EEUU produzca.

Analizando la evolución experimentada en cuanto al número de aplicaciones patentadas en el mundo global se refiere, en el período de tiempo transcurrido entre 1997 y 2016 se ha producido un incremento exponencial de las mismas (véase Gráfica 2A) . De esta forma, en 2016 el número de aplicaciones inteligentes registradas superaba las 50.000, mientras que en 1997 apenas superaba las 5.000.

De igual modo, en la Gráfica 2B, se puede apreciar que China es la economía que mayor incremento de aplicaciones patentadas ha experimentado en dicho período, ya que de las aproximadamente 50.000 patentes incorporadas, el 37.1% pertenecen a este país, seguidas por el 24.8% patentadas en Estados Unidos y un 13.1% de Japón; lo que supone un 75% sobre el total. De esta forma, el resto de países tan solo ha registrado un 25% de patentes relacionadas con aplicaciones inteligentes.



Gráfica 2: Número de aplicaciones patentadas basadas en inteligencia artificial. A) Evolución global. B) Evolución experimentada por cada país. Fuente: Statista.

A estos países le siguen las economías con grandes fortalezas tales como Canadá, Corea del Sur, Japón y Europa del Norte. Tienen alto potencial para el desarrollo de nuevas tecnologías e incluso ya están en crecimiento, sin embargo, incurren en costes de producción elevados. El crecimiento que se espera en Europa del norte es de 1.8 trillones de dólares desde 2018 a 2030.

- El tercer grupo estaría conformado por economías moderadas, como son India, Malasia y el sur de Europa. Tienen capacidad moderada de captar beneficios procedentes de la inteligencia artificial. Disponen de infraestructuras digitales y medios de producción más débiles en la actualidad.
- Economías que necesitan fortalecerse: son aquellos países que carecen de recursos necesarios, tratándose por tanto de comunidades en vías de desarrollo. Previamente a la integración de la inteligencia artificial a su actividad, han de lidiar por la lucha de salarios más justos y mejoras de la productividad, tanto en el sector agrario como en la industria y servicios.

En la Figura 1, se puede apreciar el crecimiento estimado que se experimentará en diferentes regiones en el periodo 2018-2030 debido al efecto producido por la inclusión de la inteligencia artificial en tareas productivas y comerciales.

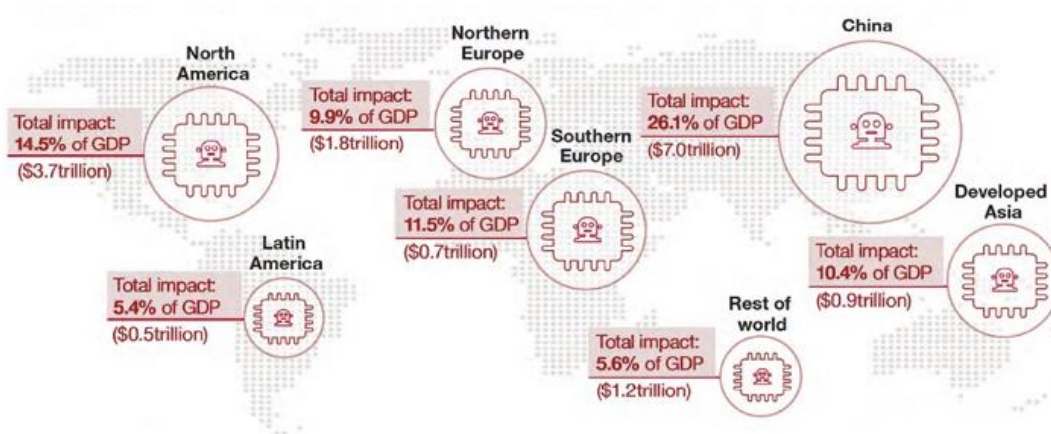


Figura 1: Crecimiento del PIB de las principales economías mundiales potenciado por la inteligencia artificial.

Fuente: PwC (Rao et al., 2017)

2.3. Influencia de la inteligencia artificial entre sectores

A continuación, se va a proceder a realizar una revisión de las principales aplicaciones que la inteligencia artificial presenta en diferentes sectores económicos. Según el informe de PwC publicado en 2017, (Rao et al., 2017) aquellos sectores con mayor impacto procedente de la aplicación de tecnologías inteligentes atendiendo al nivel de influencia generado por las mismas son el sector sanitario, seguido del sector automovilístico y de transporte, el sector financiero y el sector minorista. Atendiendo a todos ellos, en esta sección se va a proceder a analizar el sector sanitario, el automovilístico y, finalmente el sector minorista y, en los siguientes capítulos, se profundizará en el efecto que la inteligencia artificial genera sobre el sector financiero en particular, objeto de este TFG.

2.3.1. Sector sanitario


En el ámbito clínico, la inteligencia artificial puede ser utilizada como un método de apoyo a profesionales y poder minimizar los errores de diagnóstico que son inevitables en la práctica humana (Ferrucci et al., 2013). En este contexto, la inclusión de la inteligencia artificial es muy relevante ya que el incremento de la calidad en el cuidado del paciente depende directamente de la velocidad de detección y precisión del diagnóstico (Modha et al., 2011).

Para poder desarrollar sistemas inteligentes en este ámbito, es necesario dotar a estos de diversas fuentes de información, tales como el historial clínico del paciente, edad y casos similares a los del sujeto en cuestión, para completar el ECE (Expediente Clínico Electrónico) en cada situación (Jiang et al., 2017). Con todos estos datos, el sistema inteligente analiza posibles diagnósticos dando la probabilidad de ocurrencia de cada uno de ellos y aceptando, finalmente, la mejor de las hipótesis.

Un ejemplo práctico de aplicación en esta área es la detección de la existencia de cáncer de piel a través de aplicaciones para *Smartphone*, empleando para ello técnicas de reconocimiento de imágenes (Esteva et al., 2017). De esta forma, el usuario fotografía el tejido a analizar y la aplicación realiza un reconocimiento de la misma, comparándola con una amplia base de datos, dando finalmente el diagnóstico. Este tipo de aplicaciones presentan dos funcionalidades principales. La primera de ellas es que permite realizar un diagnóstico inicial que indique si se presentan o no signos a priori de presentar una determinada patología. La segunda es que las aplicaciones pueden tener gran alcance social ya que las personas con difícil acceso a la atención médica, pueden obtener rápidamente un diagnóstico².

En cuanto al nivel de inclusión de estas tecnologías dentro del sector sanitario, la Gráfica 3 muestra los ingresos globales procedentes de los sistemas inteligentes aplicados en medicina. De esta forma, se puede apreciar la evolución experimentada desde 2013 a 2018, así como el pronóstico de crecimiento que se va a experimentar hasta 2021. Así, los ingresos se han visto incrementados un total de 1495.7 millones de dólares entre 2018 y 2013, lo que supone un crecimiento del 295% referidos al valor presentado en 2013. Además, se espera que estos ingresos experimenten un crecimiento exponencial desde el momento actual hasta 2021 (Brayne et al., 2018).

² En España, según estadísticas de INE, el 98% de las viviendas españolas cuentan con al menos un teléfono móvil. Además, el 12.22% de los residentes en España en 2018 habitaban en poblaciones sin hospital con censos de población inferior a 5000 habitante.



Gràfica 3: Ingresos globales en el sector sanitario debidos a la inclusión de sistemas inteligentes. Fuente: (Brayne et al., 2018)

2.3.2. Sector del automóvil

La industria de la automoción es una de las más rápidas en experimentar la evolución tecnológica (Hengstler et al., 2016). La aplicación de la inteligencia artificial en esta área aporta grandes beneficios a la sociedad, especialmente en relación a un aspecto importante como es la seguridad y protección vial (Wei et al., 2013).

La inteligencia artificial también está presente en este sector ofreciendo ayuda a los conductores. En este sentido, se persigue el diseño y creación de automóviles que actúen de forma proactiva e incluso algunos de estos diseños permiten a los vehículos de conducir de forma autónoma.

Los coches autónomos necesitan trabajar con una gran cantidad de datos en un periodo muy reducido de tiempo para barajar todas las posibles situaciones (cruce de peatones, visualización de señales, presencia de ciclistas, etc.) que puedan darse y responder de forma rápida y segura. Por esta razón, llevan integrados GPS, cámaras y sensores que les permiten capturar toda la información del entorno (Häne et al., 2017). Dado que las posibles situaciones que se plantean en el entorno varían rápidamente, es necesario que los automóviles tengan capacidades cognitivas, es decir, que sean capaces de aprender y tomar decisiones por sí mismos.

Algunas de estas tareas inteligentes son la detección de peligros en la calzada, introducida por General Motor en 2012 (Krebs et al., 1999), o el aparcamiento automático desarrollado por varias empresas automovilísticas.

La IA en este sector presentaba una inversión global de 6.200 millones de dólares para el periodo comprendido entre los años 2010 y 2013. Esta partida se incrementa considerablemente en el período transcurrido entre 2014 y 2017, siendo de 27.300 millones dólares, es decir, más del cuádruple (Cornet et al. 2017).

2.3.3. Sector minorista

Las necesidades del consumidor son las que impulsan el cambio en el sector del minorista o *retail*, y de las que dependen sus decisiones. En este sentido, el principal objetivo es poder estimar la evolución de estas necesidades para poder anticipar la situación futura (Grewal et al., 2017)

En la actualidad, la inteligencia artificial se utiliza para realizar el control de *stocks* e investigaciones de mercado de forma que puedan anticiparse a la demanda de los clientes. De este modo, se puede conseguir una ventaja competitiva frente al resto de compañías del mismo sector (Rao et al., 2017)

La IA también permite incrementar la velocidad de compra del consumidor gracias al conocimiento de sus preferencias, a partir de las cuales se le ofrecen productos asociados. Este es el caso de la compra *online* (Desouza, 2001).

Un ejemplo revolucionario en este campo es el supermercado Amazon GO, donde se puede comprar sin pasar por la caja registradora. El proceso de pago se realiza automáticamente al salir del establecimiento gracias a cámaras y sensores situados en diferentes posiciones estratégicas en el local (Polacco & Backes, 2018).

Según un estudio de *Juniper Research*, para finales de año se espera que la inversión total en este sector alcance los 3.600 millones de dólares y se estima que, para 2023 esta cifra ascienda hasta un importe de 12.000 millones, lo que supondrá un incremento del 233.3% (Juniper Research, 2019).

Capítulo 3. El sector financiero español

3.1. Estado actual del sector financiero español

El sector financiero se define como el marco institucional que recoge tanto a oferentes como demandantes de fondos. Lo integran diferentes instituciones, agentes económicos e instrumentos financieros, cuya misión consiste en canalizar los recursos monetarios existentes desde los ahorradores de fondos hasta los demandantes de los mismos. El sector financiero, por tanto, ha de llevar a cabo tareas como la vinculación entre ahorradores e inversionistas, recogiendo, administrando y dirigiendo el ahorro y la inversión, valorar los activos financieros existentes, facilitar el flujo de recursos financieros y transmitir y regular la política monetaria española (Calvo et al., 2014).

Los agentes económicos quedan representados por las economías domésticas, así como el sector público y el sector empresarial. En el transcurso del tiempo, todos ellos pasarán por las fases de ahorro, inversión, consumo y producción, así como de déficit y de superávit.

El sistema financiero necesita de una serie de elementos clave para el correcto funcionamiento:

- **Instrumentos financieros:** son los contratos mediante los cuales se da lugar a derechos o activos para uno de los agentes económicos, y a una obligación o pasivo en la otra parte del contrato. Todos ellos, se encuentran caracterizados por un nivel de rentabilidad, riesgo y liquidez que hará que sean activos financieros más o menos deseables entre los agentes.
- **Intermediarios financieros:** son los encargados de poner en contacto a demandantes y oferentes de fondos para que cedan sus recursos y así, favorecer a la canalización de los recursos financieros. Adquieren títulos primarios del mercado y los transforman en títulos secundarios de forma que se adapten a las necesidades de ambas partes.
- **Mercados financieros:** es el lugar donde se lleva a cabo el intercambio de fondos. Así, si el título es emitido por primera vez, se lanzaría en el mercado primario, mientras que si ha sufrido alguna modificación y no es la primera vez que se emite, la transmisión se realizaría en el mercado secundario. Además, los mercados financieros es el lugar donde se determinan los precios. Por tanto, son un medio para dotar de liquidez a los activos así como para proteger la transparencia de las transacciones llevadas a cabo en ellos.

Para velar por el correcto funcionamiento de las finanzas en España, el sistema financiero se subdivide en diferentes instituciones financieras, cada una de las cuales se hará responsable de una serie de tareas concretas, recogidas bajo un marco normativo particular. Estas instituciones se encuentran a la vez supervisadas por diferentes órganos, que en España son el Banco de España (BE), la Comisión Nacional del Mercado de Valores (CNMV) y la Dirección General de Seguros y Fondos de Pensiones (DGSFP). No obstante, dado que España es un país miembro de la Unión Europea, el órgano soberano superior será el Banco Central Europeo (BCE) y otro tipo de instituciones de la misma índole, cuyo objetivo es mantener la salud financiera en el conjunto de países de la Unión Europea (Manzano & Valer, 2013).

El Banco de España ha de colaborar con las instituciones europeas, de forma que garantice que las funciones del Banco Central Europeo y del Eurosistema en general se aplican dentro del territorio español. De esta forma, supervisa a todos los intermediarios financieros que pertenecen al sistema bancario en el marco español, como son las entidades de crédito y de depósito, tales como bancos, cajas de ahorro, Instituto de Crédito Oficial y cooperativas de crédito. Cabe añadir que, desde finales de 2014 tras la crisis acaecida en España, el Banco Central Europeo es el encargado de supervisar a las principales entidades bancarias españolas, por lo que realmente, el banco de España supervisará a entidades más pequeñas.

Además, bajo la supervisión del Banco de España se encuentran algunas entidades que no pertenecen al sistema bancario como tal, pero que son establecimientos de crédito como puede ser el *leasing*, *factoring* y sociedades de crédito hipotecario, entre otras, así como a las sociedades de garantía recíproca cuya actividad no es la de proporcionar crédito sino la mediación.

La Comisión Nacional del Mercado de Valores, es la institución encargada de supervisar a los intermediarios financieros cuya actividad consiste en poner en contacto a agentes económicos para la emisión de valores mobiliarios, como pueden ser las acciones y las obligaciones, excepto que se encuentren bajo la vigilancia del Banco de España, como es el caso de del mercado de la deuda pública. Así, la CNMV supervisa a diferentes intermediarios tales como agentes especialistas, *Brokers* y *Dealers*; a las instituciones de inversión colectiva que captan dinero del público para invertirlo en valores, a las empresas de servicios de inversión que actúan como mediadores; y a los fondos de capital riesgo, cuya labor es invertir en empresas nuevas o en expansión; además de velar por la transparencia del precio de los valores mobiliarios.

En cuanto a la Dirección General de Seguros y Fondos de Pensiones se refiere, las entidades aseguradoras y gestoras de fondos de pensiones se encuentran reguladas bajo la misma.

En la Figura 2 se muestran las principales instituciones financieras españolas. En naranja aparecen las reguladas bajo el Banco de España, en verde, las supervisadas por la CNMV, y en azul las controladas por la DGSFP.

INSTITUCIONES FINANCIERAS

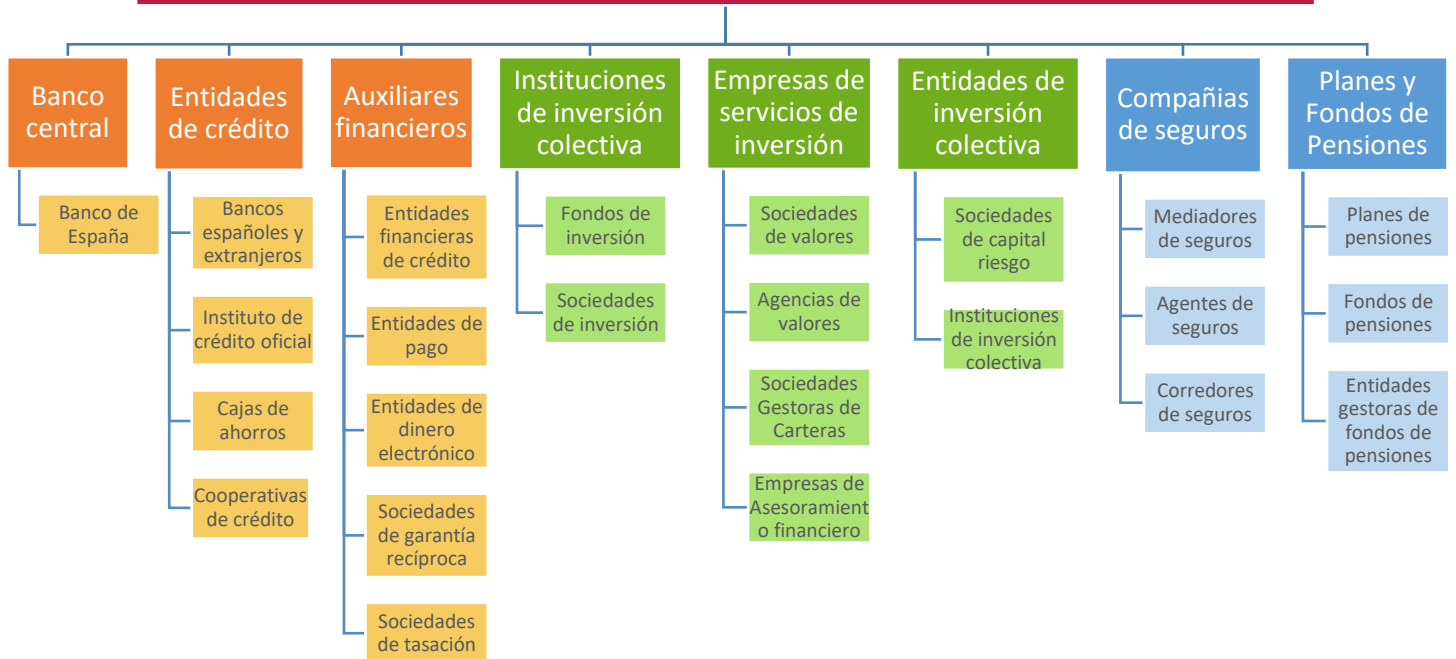


Figura 2: Instituciones financieras españolas. En naranja aparecen las reguladas por el banco de España, en verde las que regula la CNMV y en azul la DGSFP. Fuente: Elaboración propia.

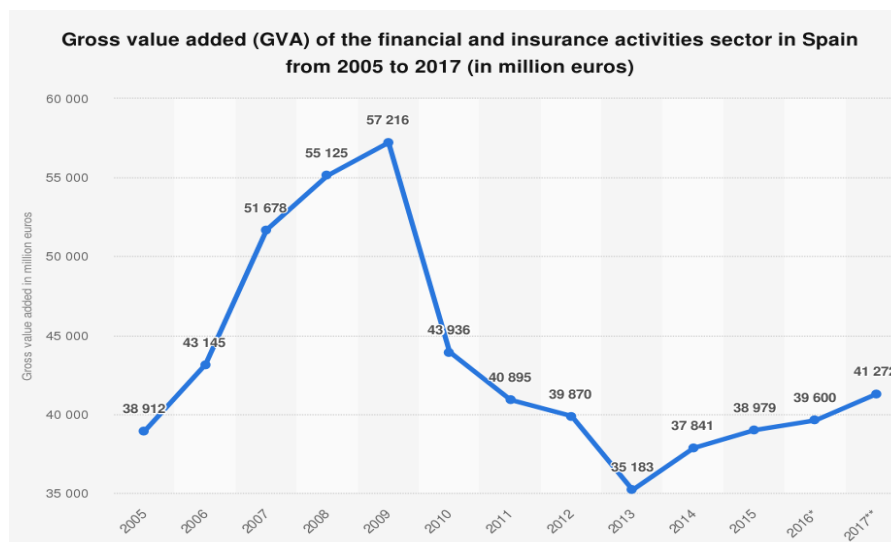
3.2. Influencia del sector financiero en la economía.

El sector financiero español ha sufrido un gran cambio en los últimos años debidos a la crisis económica acaecida en el país desde agosto de 2007. En el período de tiempo transcurrido desde 1984 hasta 2007, la economía española experimentó un amplio crecimiento debido por una parte a la incorporación de la nación a la Unión Europea, (1986) y, por otra parte, al incremento de la inversión. En este último aspecto, la entrada a la zona euro jugó un papel clave ya que los tipos de interés cayeron y se da lugar a un abundante incremento de liquidez. Con ello, se produce un aumento considerado del empleo, por lo que disminuye la percepción del riesgo de impago en la economía. De este modo, la banca y sobretodo las cajas de ahorro concedieron muchas facilidades a las empresas constructoras, quienes estaban experimentando un rápido crecimiento, un *boom* que conllevó a la especulación y al aumento del riesgo, tanto en el sector de la construcción como en el inmobiliario con la concesión de créditos hipotecarios (Pérez, 2011).

Cuando la crisis de las *subprime* llega a EEUU, la venta de inmuebles en el resto del mundo se paraliza, y, dados los esfuerzos económicos realizados por las entidades bancarias españolas, se agrava drásticamente la situación económica del sector financiero y del país, que se adentra en un largo período de crisis.

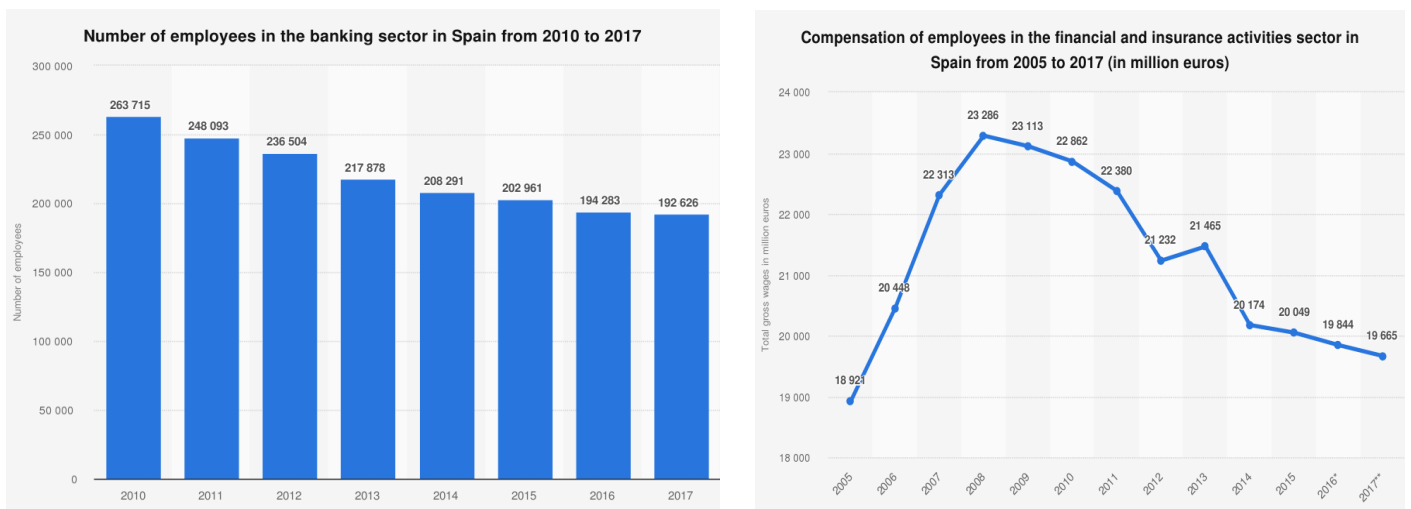
Desde entonces, comienza un proceso de recesión en la economía española, con la consiguiente disminución del PIB del sector financiero en los períodos anuales siguientes, hasta 2014. En este momento, el Banco Central Europeo y el Mecanismo Único de Supervisión de la Unión Europea asumen la supervisión de los principales bancos de Europa, por lo que España comienza a recuperarse (Consejo Europeo).

Este hecho se puede ver reflejado la Gráfica 4. En período 2005-2009, el PIB del sector financiero y de seguros se incrementa rápidamente. Seguidamente, entre 2009 y 2014 se aprecia el período de recesión mencionado, hasta que en 2014 da comienzo el control del BCE, que perdura hasta el momento actual.



Gráfica 4: Evolución del PIB en el sector financiero y aseguradoras en España. Fuente: Statista

La crisis produjo también por una parte, una disminución del número sucursales bancarias y, por otra, el cierre de prácticamente todas las cajas de ahorro (de 45 que había antes de la crisis, en la actualidad únicamente sigue presente la caja de ahorros Caixa Ontinyent, y Colonya, Caixa Pollença de Mallorca). Con ello, disminuye también el número de empleados en dicho sector. Analizando las gráficas que se muestran a continuación (Gráfica 5), se puede observar que en el periodo transcurrido entre 2010 y 2017 el empleo disminuye un 26.96%, mientras que el salario a pesar de parecer una disminución se incrementa un 17.76%, ya que el gráfico de la derecha muestra el salario total destinado a los empleados en su conjunto sin tener en cuenta el número de asalariados.




Gráfica 5: Evolución del número de empleados y del salario en el sector financiero y de seguros. Fuente: Statista

Por otra parte, el número de sucursales en el país se ha visto disminuido. En parte, en las primeras etapas debido al efecto de la crisis sobre las entidades, pero en una segunda etapa esta disminución se debe también a la reestructuración de la banca. Debido al incremento del uso de la tecnología y de internet, se ha dado lugar a nuevos métodos de comunicación entre los consumidores y las entidades bancarias. Ejemplo de ello, es la banca online y las *Fintech*, que permiten realizar operaciones financieras online sin necesidad de acudir presencialmente a los establecimientos.

Según una encuesta realizada por KPMG a diversas entidades financieras, un 80% de las mismas ofrece la posibilidad de contratar cuentas corrientes *online* sin necesidad de asistir presencialmente a las oficinas. Otros servicios que se pueden realizar vía internet son la contratación de tarjetas de crédito (en un 67% de los casos), préstamos personales, fondos de inversión y depósitos en un 80%, mientras que el 73% de entidades permite la contratación digital de planes de pensiones y seguros (KPMG, 2017).

No obstante, las entidades bancarias afirman que el hecho de guiar sus negocios hacia la transformación digital no va a suponer el cierre de sus oficinas, sino que el impacto conllevará a la reorganización y agrupación de las mismas, de tal forma que las oficinas seguirán siendo fundamentales, si bien se verá reducido el número de establecimientos físicos.

En la Gráfica 6 se puede observar la disminución del número de sucursales bancarias llevada a cabo desde 2010.



Gráfica 6: Variación del número sucursales bancarias en España. Fuente: Banco de España.

3.3. Principales entidades bancarias españolas

En esta sección se va a proceder a analizar las principales entidades bancarias españolas. De esta forma, se podrá contextualizar a cada una según su relevancia dentro del sistema financiero español. Así, estudiando las entidades que mayor peso ejercen en dicho sector, se podrá identificar la tecnología basada en IA que incluyen dentro de su actividad financiera, considerando a estas como entidades punteras, ya que poseen mayor disponibilidad de recursos pueden destinar a la innovación.

La banca española está conformada por un total de 43 entidades bancarias, muchas de las cuales operan tanto a nivel nacional como internacional (AEBANCA, 2018).

Dada la categoría del sector financiero a la que pertenecen, se encuentran bajo la supervisión del Banco de España y las de mayor volumen de activo también por el Banco Central Europeo.

De esta forma, se puede establecer un *ranking* entre las diez entidades financieras españolas dedicadas ofrecer servicios bancarios al público. El listado de dichas entidades se muestra en el Anexo I, junto con las principales partidas contables de cada una así como otro tipo de datos tales como el número de empleados y de oficinas que poseen. Dicha información ha sido obtenida de los estados financieros individuales del último ejercicio económico de cada una de ellas, disponibles en sus páginas *web* corporativas. Así pues, de todas ellas se han seleccionado las 5 de mayor volumen de activo para realizar una comparativa entre entidades atendiendo al análisis económico financiero de cada una de ellas. Por este motivo, se va a calcular diversos ratios con objeto de evaluar la rentabilidad, liquidez y riesgo de dichas entidades (San Frutos, 2016).

Para ello, en la Tabla 1 se muestran las principales partidas de dichas entidades que se han tenido en cuenta para el cálculo de los ratios.

		Santander	BBVA	CaixaBank	Bankia	Sabadell
En miles	Créditos (€)	70,824,99	75,210,315	17,041,675	6,320,607	1,905,553
	Efectivo (€)	51,931,192	30,922,000	16,438,533	4,354,390	14,816,295
	Activo (€)	608,375,88	399,940,355	306,566,878	206,345,732	178,987,816
	Depósitos (€)	58,020,84	68,241,671	16,327,267	6,078,800	1,634,324
	Pasivo (€)	539,609,05	362,531,197	285,710,975	193,811,322	168,699,729
	FFPP (€)	69,226,00	37,417,000	21,641,086	12,421,199	10,358,387
	Dividendos (€)	3,118,000	1,067,000	1,016,662	357,115	167,008
	Patrimonio Neto (€)	68,766,83	37,409,158	20,855,903	12,534,410	10,288,087
	Resultado (€)	3,301,178	2,315,617	1,162,560	833,668	539,867
	Ingresos por intereses (€)	7,381,000	4,877,000	4,288,692	2,471,354	3,425,446
	G. explotación (€)	6,113,000	4,551,000	3,947,271	1,956,562	2,188,295
	Margen Bruto (€)	10,357,000	8,412,000	6,730,115	3,816,293	3,816,293
	Nº acciones	16,236,574	6,667,886	5,981,438	3,084,963	5,564,719
	Nº empleados	31,036	26,042	29,383	15,486	15,319
	Nº oficinas	13,217	2,865	5,103	2,298	2,457

Tabla 1: Principales partidas de las CCAA de las cinco entidades a analizar. Fuente: Elaboración propia a partir de las CCAA de cada entidad.

3.3.1. Rentabilidad

Para analizar la rentabilidad económica de la entidad, es decir, comprobar qué capacidad tiene para generar beneficios, se han calculado el ROE (*Return On Equity*) y el ROA (*Return on Assets*) de las cinco principales entidades en el año 2018 a partir de las fórmulas siguientes:

$$ROE = \frac{\text{Beneficio Neto}}{\text{Fondos Propios}} \quad (1)$$

$$ROA = \frac{\text{BAII}}{\text{Activos Totales}} \quad (2)$$

Año 2018	Santander	BBVA	CaixaBank	Bankia	Sabadell
ROE	7.83%	11.50%	8.10%	7.00%	8.55%
ROA	0.54%	0.91%	0.50%	0.40%	0.15%

Tabla 2: Ratios de rentabilidad de las cinco principales entidades bancarias españolas. Fuente: elaboración propia a partir de las CCAA de cada entidad.

El ROE hace referencia a la rentabilidad financiera, es decir, la rentabilidad que perciben los accionistas debida a las inversiones realizadas en la entidad. Tal y como se puede observar en la Tabla 2, el banco BBVA es el que ofreció mayor ROE en el año 2018, 11.50%, mientras que Bankia presentaba el valor más bajo para este mismo año (7.00%). Esto significa que BBVA es

el que ofreció mayor rendimiento a los accionistas. Dicha entidad presenta un ratio de Beneficio Neto / Importe Neto de Cifra de Negocios superior al de las cuatro entidades restantes, además de una capitalización más reducida que en el caso del Banco Santander. Por tanto, dispone de menor cuantía en la partida de fondos propios, lo que conlleva a una mayor percepción de los beneficios por parte de los accionistas.

El ROE medio de estas cinco entidades es de 8.596%, estando Santander, CaixaBank, Bankia y Sabadell por debajo de dicha rentabilidad.

En cuanto al ROA, rentabilidad económica de los activos de la empresa, BBVA continúa siendo la entidad que ofrece un mayor porcentaje, 0.91% frente al 0.15% del banco Sabadell, ratio más bajo de las cinco entidades. Estos valores miden la rentabilidad total de activos de la empresa. El valor del ROA medio para estas entidades en 0,50%, viéndose superado únicamente por Santander y BBVA. Del mismo modo que en el ratio ROE, BBVA presenta mayor rentabilidad económica debido a que dispone de un mayor Beneficio Antes de Interese e Impuestos (BAII) en función del INCN (47.48% frente al 44.75% descrito por Banco Santander), además de un nivel de activos del 66% la partida de activos de Santander y, al encontrarse esta partida en el denominador del ratio, eleva la rentabilidad.

3.3.2. Liquidez

En la Tabla 3 se muestra el resultado de liquidez de las cinco principales entidades bancarias españolas, junto con la liquidez del sector bancario en España agregado. Para su cálculo, se ha tenido en cuenta el ratio de reservas primarias así como el de transformación, cuyas expresiones se muestran a continuación:

$$\text{Ratio reservas primarias} = \frac{\text{Efectivo, saldos en efectivo en bancos centrales y otros depósitos a la vista}}{\text{Activo Total}} \quad (2)$$

$$\text{Ratio de transformación} = \frac{\text{Créditos}}{\text{Depósitos}} \quad (3)$$

	Santander		BBVA		CaixaBank		Bankia		Sabadell		Global	
	2018	2017	2018	2017	2018	2017	2018	2017	2018	2017	2018	2017
Reservas primarias (%)	8.54	6.85	7.73	4.62	5.36	6.09	2.11	1.75	8.28	9.80	8.91	8.06
Ratio de transformación (%)	122.07	134.15	110.21	115.38	104.38	105.99	103.98	90.19	116.60	102.13	115.94	124.34

Tabla 3: Ratios de liquidez de las cinco principales entidades bancarias españolas y el sector global. Fuente: elaboración propia a partir de las CCAA de cada entidad y (AEBANCA, 2018).

Analizando los resultados obtenidos, se observa que el Banco Sabadell es el que mejor ratio de reservas primarias presenta para el ejercicio económico 2017, siendo además superior a los del sector global. Esto es debido a que presenta mayor cuantía de efectivo en proporción con su partida de activo, inferior al del resto de entidades. Un mayor valor de este ratio indica mayor liquidez de la entidad pues hace referencia a la capacidad de convertir en líquido sus activos.

De igual modo, se observa que Bankia presenta menor liquidez, con valores muy reducidos, tanto en 2017 como en 2018, lo que le puede conllevar a una limitación para hacer frente a su deuda, si bien en este último ejercicio ha incrementado su valor. No obstante, este continúa siendo muy reducido.

En cuanto a las tres entidades restantes, el Banco Santander es el que mayor ratio de liquidez describe, incrementando notablemente su valor de 2017 a 2018, al igual que ocurre con BBVA. Además, ambos se acercan al ratio de reservas primarias del sector, pues el nivel de efectivo que presenta es superior.

El ratio de transformación hace referencia a la capacidad de las entidades de hacer frente a sus deudas, en este caso, de devolver los depósitos a los clientes con el activo que obtendría de las partidas crediticias. De esta forma, se observa que exceptuando Bankia en 2017, todos los bancos presentan, a priori, la capacidad de hacer frente a sus deudas con sus activos líquidos disponibles. Además, Banco Santander es el que mayor ratio de transformación presenta, siendo incluso superior al ratio experimentado por el sector global para los dos ejercicios económicos analizados. El motivo por el cual esto sucede es que BBVA y Santander concede mayor volumen de créditos a sus clientes en comparación con las tres entidades restantes. Además, entre ambas, Santander presenta menor nivel de depósitos frente al total de activo, 10.75%, mientras que en BBVA esta proporción es del 18.82%, lo que significa que presenta mayor endeudamiento con respecto al volumen de activo.

3.3.3. Riesgo

Con el fin de estudiar la calidad del crédito, se han calculado la tasa de morosidad, entendida como el incumplimiento o demora en las obligaciones de pago y la tasa de cobertura, referente a la capacidad de la entidad para hacer frente a los impagos de los clientes. Las fórmulas a partir de las cuales se han calculado estos ratios se muestran a continuación:

$$\text{Ratio de morosidad} = \frac{\text{Créditos dudosos}}{\text{Total cartera de créditos+avales+riesgos}} \quad (4)$$

$$\text{Ratio de cobertura} = \frac{\text{Provisiones para insolvencias}}{\text{Provisiones morosas}} \quad (5)$$

Año 2018	Santander	BBVA	CaixaBank	Bankia	Sabadell
Ratio de morosidad	6.19%	3.90%	4.70%	6.50%	4.22%
Ratio de cobertura	45.00%	73.00%	54.00%	54.90%	54.10%

Tabla 4: Ratios de riesgo de las cinco principales entidades bancarias españolas. Fuente: elaboración propia a partir de las CCAA de cada entidad.

Observando los resultados de la Tabla 4, Bankia es la que presenta mayor ratio de morosidad, es decir, un 6,50% del total de la cartera de créditos de Bankia son dudosos. Le sigue de cerca el Banco Santander con un 6,19% y, por el contrario, BBVA presenta el menor porcentaje de clientes morosos en su cartera de créditos (3,90%).

En cuanto al ratio de cobertura, de igual modo BBVA es la que mayor valor presenta. Dado que la entidad dispone de menor tasa de morosidad, las provisiones destinadas para tal efecto son menos exigentes, lo que conlleva a un incremento del ratio de cobertura y protección frente a

impagos de los clientes. El caso contrario ocurre con Banco Santander que, es la entidad mayor ratio de morosidad presenta, después de Bankia, y a su vez las provisiones destinadas para cubrir impagos son más reducidas, por lo que su ratio de cobertura es reducido, inferior al 50%.

Por tanto, se puede decir que aquella que presenta mayor nivel de protección frente a posibles impagos es BBVA convirtiéndose, por tanto, en la entidad con menor riesgo asociado de las cinco analizadas.

3.3.4. Solvencia

El Comité de Supervisión Bancaria de Basilea acordó llevar a cabo una serie de medidas que permitiera realizar un mejor control del capital y liquidez de las entidades para fomentar a la existencia de un sistema bancario consistente. De esta forma, las medidas a llevar a cabo fueron recogidas bajo la normativa de Basilea III, que exige a las entidades disponer de mayor requerimiento de capital y que este disponga de mayor calidad. Del mismo modo se requiere incrementar la revisión de determinados activos, experimentar un aumento de las deducciones de capital e introducir un ratio de apalancamiento, dando lugar a colchones financieros de capital (Rodríguez, 2011).

De esta forma, el primer pilar exigido a las entidades es disponer de un ratio de capital de, al menos, un 8% en todo instante de tiempo con respecto a los activos ponderados por riesgo. De este, al menos un 6% ha de pertenecer a la categoría Tier1, mientras que el 2% restante será pertenecerá al Tier2.

$$Tier1 = \frac{\text{Capital de nivel 1}}{\text{Total de activos ponderados por riesgo}} \quad (6)$$

Año 2018	Santander	BBVA	CaixaBank	Bankia	Sabadell	Global
TIER 1	13.12%	13.19%	13.30%	15.31%	13.40%	11.54%
TIER 2	1.87%	2.51%	2.30%	2.26%	2.10%	-

Tabla 5: Ratios de solvencia de las cinco principales entidades bancarias españolas y el sector global. Fuente: elaboración propia a partir de las CCAA de cada entidad y (AEBANCA,2018).

Tras los resultados obtenidos en la Tabla 5, se observa que las entidades presentan un nivel de calidad y solvencia elevado, dado que la suma de ambos ratios supera el 8% mínimo exigido. Además, todas ellas superan el 6% exigido para el Tier1 y el 2% exigido para el Tier2, excepto el Banco Santander que cuenta con un Tier2 de 1.87%. Sin embargo, no se puede decir a priori que no tenga suficiente solvencia ni un nivel de calidad adecuado, ya que en conjunto suma un 14.99%, doblando casi los exigido en la normativa de Basilea III. Por tanto, se puede concluir que dichas empresas son solventes.

Este hecho llama mucho la atención especialmente en el caso de Bankia ya que los ratios anteriores indican que dicha entidad dispone de poca liquidez, rentabilidad y alto nivel de riesgo pero, sin embargo, presenta el mayor ratio Tier1 de las cinco entidades analizadas. Además, supera de igual modo el valor medio del sector bancario en su conjunto, resultando por tanto la entidad bancaria española de mayor ratio de solvencia. Todo ello puede ser debido a la intervención del FROB en el soporte económico de dicha entidad, aportando solvencia a la misma.

3.3.5. Eficiencia

Para el cálculo del ratio de eficiencia bancaria (gastos de explotación sobre margen bruto), se ha tenido en cuenta que los gastos de explotación están compuestos por los gastos de administración (gastos de personal y otros gastos de administración) y la suma de otros gastos de explotación.

$$\text{Ratio de eficiencia} = \frac{\text{Gastos de explotación}}{\text{Margen Bruto}} \quad (7)$$

Eficiencia	Santander	BBVA	CaixaBank	Bankia	Sabadell	Global
2018	59.02%	54.10%	58.65%	54.40%	57.34%	55.45%
2017	56.76%	48.85%	60.97%	69.73%	51.50%	53.71%

Tabla 6: Ratios de eficiencia de las cinco principales entidades bancarias españolas y el sector global. Fuente: elaboración propia a partir de las CCAA de cada entidad y (AEBANCA,2018).

Es importante tener en cuenta en este ratio que, cuanto más pequeño sea, más favorable es para la entidad.

En este sentido, y analizando la evolución experimentada de 2017 a 2018, la mayor parte de las entidades han empeorado su ratio de eficiencia, siguiendo la tendencia del conjunto de la banca española, a excepción de CaixaBank y Bankia que lo han disminuido. Estas dos entidades presentaban un ratio excesivamente alto en 2017, de modo que a finales de 2018 alcanzaron un nivel de eficiencia similar al del sector bancario español en su conjunto (véase Tabla 6).

BBVA es la entidad que lidera la lista para ambos años, gastando 0,4885 céntimos en cuestiones administrativas por cada euro de margen bruto generado en 2017 y 0.5410 céntimos en 2018. Estos valores son mejores incluso que los presentados por el conjunto de la banca española.

Tras el análisis y evaluación de los diferentes ratios económico-financieros de las cinco entidades bancarias españolas, se pueden extraer diversas conclusiones. Para ello, en la Tabla 7 se muestra un cuadro resumen de la posición que ocupan dichas entidades con respecto a cada ratio calculado, siendo 1 la mejor posición con respecto al resto de entidades, y 5 la peor posición.

	1	2	3	4	5
ROE	BBVA	Sabadell	CaixaBank	Santander	Bankia
ROA	BBVA	Santander	CaixaBank	Bankia	Sabadell
Reservas primarias	Santander	Sabadell	BBVA	CaixaBank	Bankia
Ratio transformación	Santander	Sabadell	BBVA	CaixaBank	Bankia
Ratio de mososidad	BBVA	Sabadell	CaixaBank	Santander	Bankia
Ratio de cobertura	BBVA	Bankia	Sabadell	CaixaBank	Santander
TIER 1	Bankia	Sabadell	CaixaBank	BBVA	Santander
TIER 2	BBVA	CaixaBank	Bankia	Sabadell	Santander
Eficiencia	BBVA	Bankia	Sabadell	CaixaBank	Santander

Tabla 7: Resumen de los diferentes ratios calculados, bancos ordenados de mejor a menor posición (1-5). Fuente: Elaboración propia.

Para concluir con el presente análisis económico financiero, en líneas generales se puede decir que BBVA es el banco español que mejor ratio de rentabilidad presenta. Desde el punto de vista del accionista, resulta más favorable la inversión en BBVA ya que es la que mayor rentabilidad en función del capital invertido les ofrece. Además, su nivel de riesgo es inferior al del resto de entidades, de igual modo que la eficiencia es la mayor de los bancos analizados.

Por otro lado, el Banco Santander dispone de mayor liquidez que el resto de entidades analizadas en cuanto al ratio de transformación se refiere, mientras que el Banco Sabadell dispone de liquidez elevada atendiendo a la capacidad de hacer líquidos sus efectivos, saldos en efectivos en bancos centrales y otros depósitos a la vista.

Finalmente, Bankia a pesar de disponer de peores ratios que el resto de entidades analizadas en lo referente a liquidez, rentabilidad y riesgo, es la entidad bancaria que mayor nivel de solvencia presenta en el contexto español.

No obstante, el análisis realizado se basa en las partidas principales del balance y cuenta de pérdidas y ganancias de dichas entidades, por lo que para poder obtener conclusiones exhaustivas de dichas entidades es necesario contrastar con otro tipo de información que pueda ser relevante en la valoración de cada una de las entidades.

Capítulo 4. Inteligencia artificial en el sector financiero.

A pesar de que la inteligencia artificial puede parecer ser un descubrimiento reciente, lo cierto es que tiene cabida en el sector financiero desde hace mucho tiempo, con la llegada del reconocimiento automático de dígitos (Hanmandlu et al., 2003). Esta aplicación resulta ser el primer gran avance de la inteligencia artificial en dicho sector ya que permite acelerar numerosos procesos financieros. Por ejemplo, los cajeros automáticos tienen la habilidad de leer y actualizar cartillas bancarias, liberando así de esta tarea al banquero, pudiéndose dedicar a tareas menos repetitivas.

En los últimos años, la presencia de la inteligencia artificial en el sector financiero se ha visto incrementada. Por una parte, esto puede ser debido a la gran cantidad de datos generados cada día, así como a la creación de sistemas de cálculo de mayor capacidad y menor coste asociado. De esta forma, se espera que el número de datos disponibles en 2020 será de 44 zettabytes, lo que supondría un incremento de 456.96% con respecto a los existentes en 2015 (Institute of International Finance, 2016). Este incremento viene impulsado principalmente por la expansión de Internet. El aumento de la cobertura y conexiones a internet, conlleva a un incremento del número de datos, procedentes de diversas fuentes, como los motores de búsqueda de internet, principalmente, así como redes sociales tales como *Facebook*, *Twitter* y *Youtube* (Strategy & Machines, 2018) (véase Figura 3).

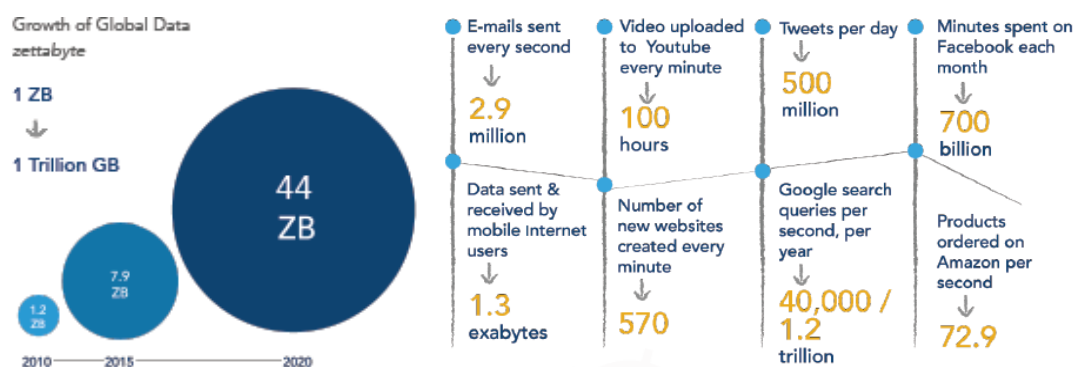


Figura 3: Incremento del número de datos y principales fuentes de generación de ellos. Fuente: (Institute of International Finance, 2016), (Strategy & Machines, 2018)

Este incremento de la inteligencia artificial, conlleva a la creación de nuevas empresas y *start ups* que basan su actividad en el diseño y desarrollo de aplicaciones inteligentes. De esta forma, se ha visto incrementada la financiación de capital riesgo asociada a dichas *start ups*, de forma que, como se observa en la Gráfica 7, ese incremento se produce de forma progresiva desde 2012 hasta 2016, experimentándose un alto crecimiento entre este último año y 2017.



Gráfica 7: Financiación capital riesgo a *start-ups* especializadas en aplicaciones de inteligencia artificial. Fuente: (Strategy & Machines, 2018).

Con el desarrollo e innovación de las tecnologías, se ha dado lugar a sistemas inteligentes mucho más complejos que permiten realizar funciones más avanzadas. Por ejemplo, los *chatbots* en el entorno financiero tienen gran afluencia especialmente sobre los *millennials*, gracias al asesoramiento ofrecen (Belgavi, 2017). Ejemplo de ellos son *Charlie* de *Propel*, o *Plum*, de *Facebook*. Estos asistentes están en contacto con las cuentas bancarias de los usuarios, lo que les permite conocer fácilmente su estado de ingresos y gastos. Además, estos sistemas cognitivos permiten a los usuarios llevar un seguimiento y planificaciones personalizados que les permite realizar un plan de ahorros y actuaciones futuras.

Otra de las aportaciones al sector financiero, es que la inteligencia artificial ofrece una mayor precisión en cuanto a análisis de la información se refiere. Así, con el empleo de tareas basadas en inteligencia artificial tales como el reconocimiento de imágenes o el procesado natural de lenguaje, que permite a los sistemas inteligentes comprender el lenguaje en diferentes formatos (lectura de textos, artículos y noticias, entre otros), posibilita la conformación bases de datos sólidas procedentes de diversas fuentes (Chui et al., 2018). Este hecho permite a las empresas encontrar fuertes oportunidades en el mercado ya que, por una parte es posible realizar amplios análisis de la competencia mientras que por otra se obtiene información acerca de los gustos de los consumidores, lo que favorece a la personalización de productos (Bughin et al., 2018). Cabe añadir, que la automatización de tareas conlleva a una reducción del tiempo necesario para implementarlas, lo que contribuirá a un incremento de la calidad de servicio ofrecido al cliente, con el consecuente aumento de su satisfacción, principal objetivo de las entidades (Baccala et al., 2018). La automatización también conlleva a una disminución de costes asociados, lo que repercute, por una parte, en la disminución del precio de los productos, y , por otra, favorece a que determinados servicios que se dirigían tradicionalmente a un reducido número de clientes pueda en esta ocasión expandirse a un mercado más amplio.

En las siguientes secciones, se va a proceder a analizar las diferentes aplicaciones de inteligencia artificial existentes en la actualidad en el entorno financiero, así como a mencionar algunos de los sistemas cognitivos más innovadores. Del mismo modo, resulta conveniente mencionar las posibles limitaciones que pueden presentarse en el desarrollo de sistemas inteligentes. Para finalizar, se hará un análisis de las principales aplicaciones de inteligencia artificial incluidas en este caso, dentro del sector bancario español.

4.1. Aplicaciones de la inteligencia artificial en el sector financiero

En la Figura 4 representada a continuación, se muestran las principales aplicaciones de la inteligencia artificial en finanzas. Como se puede observar estas aplicaciones están presentes en toda la cadena de valor, que abarcan desde tareas relacionadas con el procesamiento y generación de servicios, pasando por actividades intermedias que tienen que ver con el control de operaciones, hasta alcanzar finalmente la distribución del servicio a los consumidores finales.

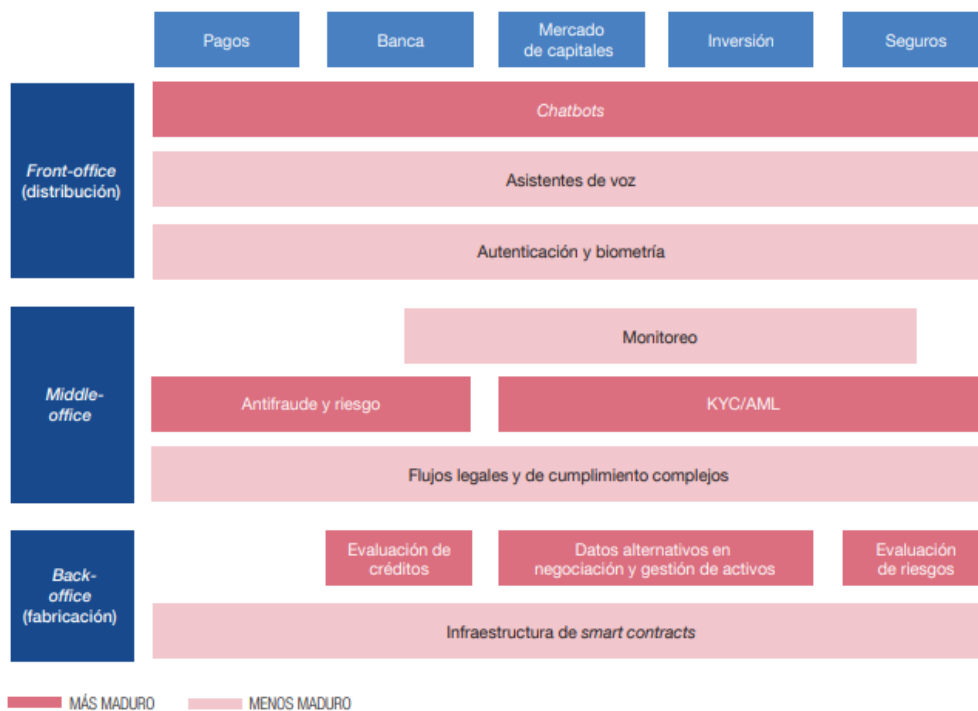


Figura 4: Principales aplicaciones de inteligencia artificial en diferentes instituciones financieras y fases de la cadena de valor, atendiendo al grado de madurez. Fuente: (NEXT, 2017)

Así pues, en el eslabón más bajo de esta cadena de valor, la inteligencia artificial contribuye con sistemas de evaluación de créditos y de riesgo, así como en la búsqueda de datos alternativos para la gestión y negociación de activos en cuanto al mercado de capitales y de inversión se refiere.

En una fase intermedia, donde se llevan a cabo tareas de control de operaciones, o *middle-office* según su nomenclatura en inglés, se puede observar cómo tanto la banca como las entidades de pago integran en su actividad sistemas inteligentes maduros relacionados con medidas anti fraude y control de blanqueo de dinero, mientras que el resto de entidades realizan tareas de verificación y control de clientes, similar a las tareas llevadas a cabo en la banca. Además, en las tareas de control, la inteligencia artificial puede contribuir a la consecución de flujos legales complejos, si bien estas tecnologías actualmente son menos maduras. Lo que es común a todos los tipos de entidades, es disponer de sistemas de inteligentes basados en la atención y asistencia a los usuarios. De esta forma, las aplicaciones más desarrolladas hasta el momento son los *chatbots* y también importantes aunque menos desarrollados los asistentes de voz y aplicaciones de autenticación y biométricas (Fernández, 2019). A continuación, se va a proceder a hacer una breve

descripción de cada una de estas técnicas, así como a hacer mención de los sistemas más importantes desarrollados hasta el momento.

4.1.1. *Chatbots*

Los *chatbots* son programas informáticos integrados en plataformas de mensajería, diseñados para que las empresas respondan de forma automática a cualquier tipo de pregunta de los usuarios y en cualquier momento del día. Dicha comunicación, se realiza vía *online*, utilizando para ello lenguaje natural. Se trata, por tanto, de *chats* en los que predomina la transparencia, cuya función principal es la atención al cliente, así como el asesoramiento en las tareas de contratación de productos y servicios (Belgavi, 2017). De esta forma, sirven como medio de comunicación entre los clientes y la entidad en cualquier momento del día, lo que permite experimentar una reducción del tiempo empleado en dichos procesos, evitando así desplazamientos hasta los establecimientos físicos. Algunos ejemplos de ello son *Charlie* de BBVA o *SoluZionador* de Wizink.

Además, la utilidad de estos chatbots puede llegar más lejos. Por ejemplo, el Banco Santander ha diseñado un *chatbot* destinado a solventar las preguntas que puedan surgirles a los gestores de seguros, en lugar de dirigirse directamente a los clientes. Del mismo modo, CaixaBank, junto con la colaboración de IBM, ha lanzado recientemente otro *chatbot* destinado a ayudar a los trabajadores de su plantilla comercial (Valera, 2018).

Otro ejemplo de aplicación de la inteligencia artificial a este sector que actúa como asistente aunque no existe una comunicación directa propiamente dicha es *Moneystream*. Se trata de una aplicación cuya función es interconectar el calendario de los usuarios junto con sus cuentas bancarias, de forma que estos puedan comprobar día a día su actividad financiera realizada. Adicionalmente, cuando una transacción es llevada a cabo, se le envía una notificación al cliente, ya sea por mensajería móvil o por correo electrónico como notificación. Todo ello, permite al usuario planificarse y llevar un registro diario fácilmente de su estado financiero.

4.1.2. Asistentes virtuales de voz

Se trata de agentes diseñados para estar en contacto cercano con los usuarios. Similar a Siri, de Apple o Cortana, de Windows, los asistentes virtuales en el sector financiero establecen comunicaciones verbales con los clientes de las entidades. De esta forma, se les facilita llevar un control de sus estados financieros en tiempo real. A modo de ejemplo, Kasisto es un agente virtual diseñado por SRI Internacional, mismos creadores de SIRI, cuya misión es ofrecer atención personalizada a los usuarios (Digibank (DBS), 2017).

4.1.3. Autenticación biométrica

En los últimos años, se ha visto incrementado el número de ciberataques y usurpación de datos vía *web*, lo que puede afectar a cualquier tipo de transacción *online* (CN-CERT, 2018). Esto tiene repercusión directa sobre las entidades financieras, así como empresas tanto del sector público como privado, dada la gran afluencia de transacciones virtuales realizadas. Concretamente, según estadísticas del CSIS (Centro de Estudios Estratégicos e Internacionales), el coste subyacente de estos ataques sobre la economía mundial supera los 400.000 millones de dólares. Por este motivo, surge la necesidad de aplicar técnicas de autenticación precisas para proteger la integridad de los clientes, fomentando de igual modo a la presencia de un clima de confianza en el usuario (Karp, 2015). La biometría consiste en hacer uso de identificativos fisiológicos tales como la huella dactilar, el iris o el reconocimiento facial, entre otros, que permiten la inequívoca identificación del individuo.

Así, entre las tres técnicas de reconocimiento biométrico más empleadas en los bancos, según un análisis llevado a cabo por Biometix, son la huella digital, el reconocimiento de venoso del dedo, y la voz (Karp, 2015) (véase Gráfica 8).



Gráfica 8: Uso de tecnologías biométricas en los bancos. Fuente: Biometix

En España, destaca Ecertic Digital Solutions, empresa cuya actividad consiste en ofrecer soportes de identificación automática (Ecertic, 2018). Concretamente, dispone de técnicas de reconocimiento facial y huella digital que, aplicadas a la banca y agencias de seguros, agilizan los procesos de contratación y transacciones. Al permitir la identificación biométrica empleando soportes digitales, los movimientos de capitales y transacciones, así como contratación y cancelaciones de seguros pueden ser llevados a cabo en cualquier momento del día, agilizando los procesos.

En este contexto, se puede situar a las *start ups* ZestFinance, CrediVidya y Lenddo, que permite a sus clientes identificarse con técnicas biométricas de forma que pueden acceder al servicio *online* financiero sin necesidad de asistir presencialmente a un centro físico.

4.1.4. Antifraude y control del blanqueo de capitales

El hecho de analizar amplias bases de datos, permite encontrar un patrón entre los mismos. Este hecho facilita la detección de anomalías de forma que cuando se encuentran movimientos fuera de lo común, podría indicar que determinados individuos están realizando tareas ilegales como puede ser el blanqueo de dinero y otro tipo de fraudes.

En este sentido, IBM proporciona amplias soluciones contra el fraude y otro tipo de delitos, aportando herramientas a sus clientes para hacer frente a posibles amenazas y anticiparse a delitos (IBM, 2018).

Otra compañía que dedica parte de su actividad a la detección de fraude es Shift Technology, que destina el uso de la inteligencia artificial a la búsqueda de reclamaciones fraudulentas por parte de determinados clientes.

4.1.5. Evaluación crediticia

La evaluación crediticia, también conocida como *credit scoring*, persigue la automatización de toma de decisiones referidas a la concesión de créditos y otro tipo de operaciones de riesgos. De esta forma, la inteligencia artificial realiza su aportación ya que, por un lado, permite el análisis de datos a gran escala y por otro, contribuye a la automatización de tareas. De esta forma, permite obtener métricas de evaluación de créditos muy precisas en períodos de tiempo reducidos. Entidades como ZestFinance, Aire, Visor y kreditech son fuertes competidores en esta área (Ketterer, 2017).

4.1.6. Datos alternativos en negociación y gestión de activos

En el área de los mercados de valores y entidades de inversión, donde el precio de los activos fluctúa diariamente, resulta esencial disponer de buenos modelos predictivos que ayuden a la toma de decisiones. Además, existen diferencias notorias en función del período de tiempo que se desea que transcurra entre la toma de decisiones. Así, las estrategias a largo plazo sirven para predecir tendencias alcistas o bajistas en los precios, para lo que es necesario analizar la mayor cantidad posible de datos macroeconómicos. Este tipo de estrategia suele ser adoptado por los gestores de fondos (Gitman & Joehnk, 2005).

Por el contrario, las estrategias a corto plazo son adoptadas por especialistas financieros que buscan obtener rentabilidades en periodos de tiempo muy reducidos.

Un ejemplo, sería *Neokami*, de Alemania, que ha diseñado una plataforma que permite predecir variaciones en el precio de las acciones y de las materias primas durante diferentes períodos de tiempo. Para ello, combina notas de analistas e historiales de variación del precio de la acción como pueden ser los índices bursátiles junto con otro tipo de datos procedentes del sentimiento que tienen los usuarios a cerca de determinadas empresas, expresados en redes sociales como *Twitter* y otras fuentes de *internet*. Esta aplicación se encuentra disponible para el público general.

Existe otro tipo de aplicaciones que sirven tanto para clientes como para intermediarios financieros. Ejemplo de ello puede ser *CloneAlgo* que por una parte, permite al usuario contactar con un corredor de bolsa especializado y, por otra facilita herramientas de análisis con técnicas combinadas de probabilidad e inteligencia artificial para la gestión del riesgo a intermediarios de mercados de valores y gestores de fondos de inversiones.

4.2. Limitaciones de la inteligencia artificial

A pesar de las aportaciones que puede realizar la inteligencia artificial a la sociedad también existen limitaciones para su uso.

La primera de ellas procede de la necesidad de disponer de grandes bases de datos para su correcto funcionamiento. Hay determinadas circunstancias en las que puede resultar difícil encontrar bases de datos lo suficientemente amplias para ajustarse a las necesidades requeridas, especialmente si se requiere de algoritmos de clasificación.

Además, existen situaciones es las que, para que las máquinas inteligentes adquieran el conocimiento deseado, es necesario aportarles a estas datos etiquetados, es decir, una indicación junto a cada variable de entrada que le indique a qué categoría pertenece. Este tipo de aprendizaje se conoce como aprendizaje supervisado. De esta forma, en muchas ocasiones se requiere que las personas etiqueten manualmente los datos, lo que supone una necesidad de tiempo invertido en dicha tarea (Jiang et al., 2017).

Por otra parte, cada sistema inteligente es desarrollado para una aplicación concreta, por lo que resulta difícil poder transmitir la información inter-sistema, de modo que se limita la capacidad de emplear estos sistemas en contextos para los que no han sido diseñados.

Además, existe también una limitación ética hacia dichos sistemas cognitivos. Numerosas personas se cuestionan acerca de si introducir sistemas inteligentes en diversos ámbitos de la vida cotidiana puede ocasionar la pérdida de libertades humanas, por ejemplo en el ámbito de la conducción con la inclusión de los coches autónomos. Otro sector cuestionado puede ser el de la salud. Según una encuesta realizada en octubre del año 2018 a 1.000 sujetos de entre 18 y 65 años acerca de su conformidad con la implantación de sistemas inteligentes en la práctica clínica, a la pregunta “¿Cuáles son las principales ventajas que ve en la posibilidad de recibir un diagnóstico de un sistema de IA?”, un 53% de los encuestados respondieron que era un método más veloz, un 42% indicó que utiliza datos con mayor precisión, mientras que un 11% declaró que no ve ninguna ventaja. En esta misma encuesta, se realizó la pregunta contraria: “¿Y desventajas?”. De acuerdo con poco más de la mitad de los encuestados (51%), la principal desventaja es la falta de interacción con un ser humano; un 36% respondió con la falta de experiencia e inteligencia aportada por el doctor, mientras que un 10% no vio ninguna desventaja (Canci, 2018).

De esta forma se observa que, a pesar del incremento que se espera que la inteligencia artificial experimente en diversas áreas, existen limitaciones a su implantación, ya sean debidas puramente al desarrollo tecnológico de las mismas o por barreras procedentes de convenciones sociales.

4.3. Inclusión de la inteligencia artificial en las principales entidades bancarias españolas.

En esta sección se va a proceder a analizar las aplicaciones basadas en inteligencia artificial desarrolladas dentro en la banca española. Como se ha observado en el análisis económico financiero de las cinco entidades bancarias españolas de mayor volumen de activo, las que mayor cuantía de dicha partida presentan son Banco Santander, BBVA y CaixaBank, además de disponer de mayor rentabilidad y liquidez. Por tanto, se ha considerado que dichas entidades son las que mayor capacidad tienen dentro del marco nacional de realizar inversiones en tecnologías punteras, como es el caso de la IA. De esta forma, se va establecer una comparativa entre el Banco Santander, BBVA y CaixaBank basada en aspectos puramente cualitativos acerca la inclusión de la inteligencia artificial en las diferentes fases de la cadena de valor de cada uno de estos bancos.

Dichas entidades bancarias tienen presencia en el marco internacional. Por tanto, se tratará de comprobar el grado de madurez que la inteligencia artificial presenta dentro del sector financiero español, en comparación con las aplicaciones desarrolladas por las mismas entidades en el contexto internacional.

La metodología a desarrollar consiste en analizar cada una de las tecnologías descritas en la Figura 4 que cada uno de estos bancos ofrece al público, mencionando las aplicaciones más relevantes con una breve descripción de las mismas para, en última instancia proceder a realizar la comparativa entre entidades. Para ello, tres aplicaciones van a ser consideradas:

- El uso de *chatbots* y asistentes virtuales. Estos serán analizados de forma conjunta ya que finalidad de ambos es la misma, suplir la necesidad de los clientes y empleados referida a la resolución de posibles dudas y la gestión de transacciones, siendo la diferencia entre ambas el grado de desarrollo de las tecnologías empleadas.
- Medidas de autenticación biométrica, analizando las diferentes técnicas de identificación que cada una integra en sus servicios.
- *Credit scoring*.

Para ello, se va a emplear información cualitativa extraída de la página *web* corporativa de cada una de las entidades.

4.3.1. Banco Santander

El Banco Santander fue fundado el 15 de mayo de 1857, doblando su balance entre los años 1900 y 1919. En febrero de 1920, Emilio Botín y López fue nombrado primer presidente fijo del banco, teniendo actualmente por presidenta a Ana Patricia Botín. Está considerada una de las grandes entidades financieras en todo el mundo operando, además de en el continente europeo, en toda América y en el continente asiático.

Forma parte tanto del IBEX 35 como del Dow Jones EURO STOXX 50 y, a fecha de 31 de diciembre de 2018, contaba con un total de 608.376 millones de euros en su partida de activo. Otras cifras relativas al banco en esta misma fecha son las 13.217 oficinas y 31.036 empleados que lo constituían.

Así mismo, una de sus últimas operaciones ha sido la absorción jurídica del Banco Popular efectuada el pasado año 2018.

A continuación, se van a describir las principales aplicaciones inteligentes desarrolladas por Banco Santander.

- ***Chatbots y asistentes virtuales de voz***

El Banco Santander dispone en España de un *chatbot online* destinado al asesoramiento de sus clientes de forma que ante cualquier duda o cuestión que le surja al usuario acerca de la entidad puede ponerse en contacto con dicho *chatbot*, y este tratará de solventarla en la medida de lo posible.

La novedad que aporta el Banco Santander en relación al uso de *chatbots* en el sector financiero se ve reflejado en el *bot* corporativo que incluye en algunas de sus entidades, cuyo uso está destinado exclusivamente a los empleados. Así, se les proporciona un medio de consulta en lo referente a la contratación de seguros.

El Banco Santander es un grupo internacional, por lo que tiene presencia en otras áreas geográficas. De este modo, en Reino Unido ha introducido un *chatbot* mucho más sofisticado al que se puede acceder por medio de la aplicación móvil denominada *SmartBank*. Esta facilita la iteración directa entre el banco y los clientes pues, a diferencia del existente en España, permite ordenar la realización de transferencias y otras transacciones como pueden ser el seguimiento de gastos, comprobar el estado actual de la cuenta corriente o informar de un robo o pérdida de tarjetas de crédito para que sean desactivadas, entre otras.

Otro ejemplo de *chatbot* proporcionado por esta entidad en el ámbito internacional se encuentra en Argentina, especializado en materia de hipotecas y créditos.

En cuanto a los asistentes virtuales de voz se refiere destaca *Sherpa*, agente inteligente especializado en la interfaz de voz que Santander incorpora en su aplicación móvil. Diseñada por Anboto, empresa vasca, *Sherpa* es un asistente de voz similar a Siri, destinado para su uso en sistemas operativos *Android*. De esta forma, permite la comunicación en lenguaje natural entre el cliente y el asistente cognitivo.

- ***Autenticación y biométrica***

El Banco Santander está haciendo uso de la biométrica para diversas funcionalidades. Por una parte, fomenta a la disminución de impagos y prevención anti fraude. El hecho de hacer uso de técnicas biométricas, favorece a la preservación de la identidad de los usuarios y a su protección. En este contexto, *Openbank*, banco *online* del grupo Santander, está comenzando a incorporar sistemas de reconocimiento de imágenes para el proceso de inscripción a dicha banca *online* en países como Brasil, México y España.

En cuanto a la autenticación mediante huella dactilar para permitir el acceso a las aplicaciones de *Openbank*, estas están siendo instauradas en países como España, Polonia, Estados Unidos, Brasil y Portugal.

Finalmente, el empleo del reconocimiento de voz también se está potenciando en México. Gracias al sistema inteligente *VocalPassword* diseñado por Nuance, es posible hacer uso del

reconocimiento de voz en sustitución de tareas como la introducción de PIN y contraseñas en los servicios de asistencia telefónica al cliente, de forma que permite identificar a los clientes únicamente a partir de su voz.

- ***Credit scoring***

El Banco Santander, junto con SAS, empresa dedicada al diseño de *software* y analítica, persiguen crear modelos únicos en los cuales se obtengan métricas de predicción más precisas, para lo que será necesario combinar inteligencia artificial junto con la minería de datos. Todo ello permitirá, entre otras cosas, mejorar los sistemas actuales existentes de *credit scoring* al proporcionar mayores precisiones de predicción.

4.3.2. BBVA

Banco Bilbao Vizcaya Argentaria, S.A., más conocido por sus siglas BBVA, es considerada una de las instituciones financieras más grandes del mundo, estando presente en España, América y Turquía. Fue fundado el 28 de mayo de 1857 en Bilbao, España. A fecha de 31 de diciembre de 2018, contaba con un total de activo de aproximadamente 399.940 millones de euros, constituyendo el segundo banco más grande de España. En esa misma fecha, contaba con 2.865 oficinas y 26.042 empleados dentro del territorio español. Igual que el Banco Santander, forma parte del IBEX 35 y del Dow Jones EURO STOXX 50.

El Banco BBVA también introduce aplicaciones inteligentes en su cadena de valor. Las más importantes serán descritas a continuación.

- ***Chatbots y asistentes virtuales de voz***

El fondo de inversión Propel Venture Partners, de BBVA, ha introducido a *Charlie* en su página *web* corporativa, para ayudar al usuario a la gestión de sus finanzas. De momento, el pingüino *Charlie* solo tiene presencia en Estados Unidos. Según indican sus inversores, esta aplicación está dirigida a los *millennials*, generación que acostumbra a realizar la mayoría de sus gestiones *online*. Además, permite realizar transacciones de dinero por medio de aplicaciones como *Facebook Messenger* o *Telegram*. Así, este *chatbot* fue introducido en 2016 y en la actualidad cuenta con aproximadamente 250.000 usuarios. Está destinado a clientes con conocimientos financieros limitados para, de esta forma, ayudarles a ahorrar y hacer un uso eficiente de sus recursos.

En España, la entidad incorpora distintos *chatbots*. Uno de ellos es menos sofisticado que *Charlie* y su utilidad se limita a acciones más sencillas tales como consulta del saldo disponible, del número de cuenta o la geolocalización de los cajeros más cercanos.

BBVA también dispone de asistentes virtuales. Este es el caso de *Smart Assistant*, lanzado en 2017 y con una tecnología tan desarrollada que le ha permitido evolucionar a dispositivos de *Google Home* y *Google Assistant*, motivo por el cual ha recibido el reconocimiento de Planeta Chatbot 2018.

En el ámbito internacional, BBVA e IPSofT han implantado el asistente de voz Amelia en México tras 18 años de investigación. Este agente es capaz de, mediante el empleo de técnicas de

inteligencia artificial, comprender las emociones de los usuarios y adaptarse a ellas, de forma que atienda a las reclamaciones de los interlocutores.

Por otra parte, Garanti Bank del grupo BBVA ha incorporado *UGI* como asistente de voz en Turquía. *UGI* facilita la realización de transacciones a partir de las instrucciones indicadas por los clientes, ya que son capaces de comunicarse en lenguaje natural. Este asistente, ha recibido el premio EFMA a la innovación debido al planteamiento multicanal que describe. Por una parte, permite la comunicación cliente-asistente, y por otra conecta a este último con la entidad.

▪ **Autenticación y biometría**

Selfie&Go, se trata de un sistema revolucionario en cuanto al reconocimiento biométrico se refiere, dentro del contexto financiero. Tanto es así que ha sido seleccionada como una de las 100 mejores ideas del año en la categoría de pagos móviles. Se trata de una aplicación de pago, de momento únicamente habilitada en el restaurante Central de BBVA desde mediados de 2018. Con ella, los comensales pueden realizar el pago del menú diario posando unos instantes para una cámara situada al lado del cajero. Esta se encarga por una parte, de visualizar el menú escogido para calcular su importe y, por otra, de reconocer el rostro del cliente, que está registrado en la base de datos. Cuando este proceso de reconocimiento finaliza, se realiza el cobro automático, ya que la cuenta del cliente se asocia a la cara del mismo. Esta aplicación ha sido realizada junto con la *start up* Veridas y Das-Nano, de Pamplona.

Esta misma *start up* en colaboración con BBVA, ha permitido que los clientes nuevos accedan a la banca *online* empleando canales digitales. De esta forma, han desarrollado un proyecto denominado Alta Inmediata que posibilita a los usuarios entrar a formar parte del banco *online* a partir de un *selfie* de reconocimiento.

Otra aplicación de autenticación biométrica en España surge de la cooperación de BBVA con *Samsung*, dando lugar a un sistema de reconocimiento biométrico a través del iris que permite el acceso de los clientes a la aplicación de banca móvil. Esta tecnología queda recogida bajo el nombre *Samsung Pass*, que permite también la identificación mediante huella dactilar.

De igual modo, BBVA está iniciando un proyecto de investigación para tratar de encontrar formas de pago alternativas en los comercios, que permitan realizar pagos automáticamente evitando pasar por el cajero. Para ello, estudian la posibilidad de incluir etiquetas RFID³ en los productos de forma que a la salida de la tienda, se lea la información automáticamente, calcule el precio de la compra y se realice la transacción.

▪ **Credit scoring**

BBVA dispone de simulador de *credit scoring* en su página web, que calcula la posibilidad de que a un determinado cliente se le conceda un préstamo basándose en su historial de pagos.

³ RFID son dispositivos de radiofrecuencia que permiten el almacenamiento y envío de datos acerca de diferentes productos. Así, un objeto que integre estas etiquetas puede ser reconocido por un receptor de RFID.

4.3.3. CaixaBank

CaixaBank, S.A. fue fundado en la ciudad de Barcelona en 2011 por LaCaixa, quien aportó sus activos y pasivos para su creación. A fecha de 31 de diciembre de 2018, contaba con un total de activo de casi 306.567 millones de euros, además de una red de 5.103 oficinas y 29.383 empleados en España. Con estas cifras, está situada como el tercer banco más grande del país.

El 14 de enero del año 2016, creó ImaginBank, el primer banco español destinado a ofrecer el servicio de banca *online*, con el objetivo de captar 500.000 clientes de la generación *millennial* para el término de 2017. Así, CaixaBank es líder en banca digital en España, con una tasa de penetración del 32% en el mercado. De esta forma, CaixaBank disponía de 6.1 millones de clientes en su servicio digital, lo que supone el 58% del total de clientes de CaixaBank en el entorno español.

CaixaBank destaca en el sector financiero por las aportaciones realizadas a cerca del pago móvil y *contactless*, del cual fue pionero en el marco europeo, y por el desarrollo de los primeros cajeros *contactless* del mundo. No obstante, también ha implementado otras aplicaciones tecnológicas que serán comentadas en los siguientes epígrafes.

- **Chatbots y asistentes virtuales**

Gina es un *chatbot* ofertado por ImaginBank, servicio de banca online de CaixaBank. Permite el fraccionamiento en el pago mediante tarjetas de crédito. Este es el primer *bot* que permite llevar a cabo transacciones reales dentro del sector financiero español. El cliente realiza una consulta vía texto o voz al agente acerca del pago a plazos en operaciones recientes, y le indica cuál de ellas admite la posibilidad de ser fraccionada.

Tras *Gina*, otros *chatbots* han sido desarrollados. Este es el caso de *Neo*, cuyo ámbito de actuación se encuentra en *CaixaBankNow*. Se trata de un *chat* especializado en ofrecer servicios de asistencia y resolución de dudas de clientes vía texto y voz. Esta aplicación también permite observar el estado de las cuentas bancarias desde el *smartwatch*, sin la necesidad de recurrir a la aplicación móvil, ni de asistir físicamente a las sucursales.

BrokerNow es una aplicación adicional dentro de CaixaBank que ofrece información sobre la bolsa y todo tipo de acciones, opciones, *warrants*, futuros y fondos cotizados (ETFs) de más de 25 mercados en todo el mundo, actualizados en tiempo real. Igualmente, permite enviar órdenes de compra y venta si así lo desea el usuario.

Por otra parte, junto con la colaboración de IBM Watson, CaixaBank dispone de un asistente virtual que puede dar respuesta al 80% de las consultas de los gestores físicos de la entidad. Este agente está dirigido especialmente a los empleados de sus sucursales. Dispone de una gran base de datos que recoge información tanto de clientes y servicios como de marcos normativos y legislativos, de forma que ante cualquier duda del empleado puede ofrecer respuesta, en un 80% de los casos.

- **Autenticación biométrica**

Caixabank es pionero en la inclusión de reconocimiento facial en cajeros automáticos en España para fomentar la seguridad de los clientes. Esta innovación fue posible gracias a la colaboración conjunta con Fujitsu y FacePhi. Se lanzó a principios de año en Barcelona y espera expandirse en lo que queda de año al resto de cajeros del país.

No obstante, previamente al éxito obtenido con el reconocimiento facial, CaixaBank ya ofrecía servicio de identificación biométrica en lo referente al acceso a aplicaciones y consultas de los estados financieros de los clientes. Además, en la actividad cotidiana de la entidad, las firmas y contrataciones se recogen bajo la firma con huella dactilar.

Otra aportación de la biométrica a CaixaBank consiste en la identificación facial denominada *FaceID* para clientes con *iPhoneX*.

- **Credit Scoring:**

CaixaBank dispone en sus aplicaciones móviles de simuladores que permiten a los clientes conocer si el banco le concedería o no determinados préstamos atendiendo al historial registrado del consumidor, analizando de igual modo los requisitos que cumplían anteriores clientes del banco, a quienes les fue concedido un préstamo bajo las mismas prestaciones.

4.3.4. Análisis comparativo

Tras la identificación de las principales aplicaciones basadas en inteligencia artificial integradas en las tres entidades bancarias de mayor volumen de activo en el marco español, se va a proceder a realizar una comparativa entre ellas. A continuación se muestra un cuadro resumen con dichas aplicaciones así como la utilidad que satisfacen y el entorno en el que han sido implantadas, distinguiendo entre implantación global o nacional (véase Tabla 8).

		Banco Santander		BBVA		CaixaBank	
		G	E	G	E	G	E
Chatbots y asistentes virtuales	Asesoramiento y consulta general de clientes	×	×	×	×	×	×
	Asesoramiento especializado en hipotecas y créditos	×					
	Asistencia a empleados	×	×			×	×
	Gestor de transacciones y finanzas	×		×	×		
	Fraccionamiento de pago					×	×
	Bolsa <i>online</i>					×	×
Autenticación biométrica	Identificación vía voz	×		×			
	Identificación vía huella dactilar	×	×	×	×	×	×
	Identificación vía reconocimiento facial	×	×	×	×	×	×
	Identificación vía reconocimiento del iris			×	×		
	Pago mediante reconocimiento facial			×	×		
	Transacciones en cajeros mediante reconocimiento facial					×	×
Credit scoring	Simulador de préstamos	×	×	×	×	×	×

Tabla 8: Cuadro resumen de las aplicaciones de inteligencia artificial integradas en Banco Santander, BBVA y CaixaBank, atendiendo a la necesidad que satisfacen así como al ámbito de aplicación: G) aplicación global, E) en España. Fuente: Elaboración propia.

A partir de la Tabla 8 expuesta, se pueden extraer varias conclusiones. En primer lugar, es importante destacar la presencia de aplicaciones de inteligencia artificial en España por parte de CaixaBank, ya que todos sus desarrollos en este campo están presentes en el territorio nacional. Entre ellos, se encuentran aplicaciones orientadas sobre todo a asesoramiento y consulta del cliente, pero también a reconocimiento facial y vía huella dactilar. Seguidamente, la utilización de técnicas de IA en BBVA también tiene fuerte presencia en nuestro país, implementando aplicaciones más innovadoras como reconocimiento a partir del iris o pago mediante la exploración facial. Por otra parte, Santander tiene mayor desarrollo de forma global.

En segundo lugar, se comparan los servicios ofrecidos en general por cada una de estas entidades. Los *chatbots* y asistentes virtuales, están dirigidos a la consulta y asesoramiento tanto a clientes como a empleados por parte del Banco Santander, mientras que BBVA introduce también estas aplicaciones en las gestiones de distintas transacciones. CaixaBank es la que más peso tiene en esta categoría, ofreciendo servicios diversificados y especializados en el desarrollo de *chatbots* destinados a la consulta de la bolsa y el empleo de *chatbots* que gestionan el método de pago de sus clientes.

En cuanto a la autenticación biométrica, el banco español que mayor inversión realiza es BBVA, tanto en el entorno nacional como internacional, haciendo uso de tres de las técnicas de reconocimiento tales como facial, digital e iris. Además, en comparación con las otras dos

entidades que destinan esta tecnología a la identificación de clientes, BBVA también lo utiliza como medio de realización de transacciones y el pago directo. CaixaBank también apuesta por emplear el reconocimiento facial como medio de protección de clientes al instaurarlo en los cajeros automáticos.

Por último, mencionar la técnica de *credit scoring*, a través de la cual se puede anticipar automáticamente la posible concesión o no de un crédito a un cliente. Este tipo de aplicaciones está presente en las tres entidades dentro del territorio español.

Capítulo 5. Modelo de predicción de transacciones.

En el presente capítulo, se va a hacer uso de la inteligencia artificial para proponer un modelo predictivo aplicable al sector financiero. Concretamente, consistirá en crear una arquitectura de red neuronal que sea capaz de predecir si un determinado cliente realizará o no transacciones futuras, independientemente de la cantidad a transferir. Previamente a ello, se realizará un análisis de las diversas metodologías existentes en el campo del *machine learning* para la resolución de problemas de clasificación que nos permitirá seleccionar la técnica óptima a emplear.

5.1. Técnicas de *machine learning* disponibles para la resolución de problemas de clasificación.

Tradicionalmente, los métodos empleados para desarrollar modelos de predicción y clasificación estaban fundamentados en metodologías estadísticas y de probabilidad. Sin embargo, con la llegada de la inteligencia artificial y el *machine learning*, han surgido diversas técnicas capaces de obtener soluciones mucho más precisas, mediante el aprendizaje de patrones característicos a partir de un gran número de ejemplos o instancias de entrenamiento.

Dada la diversidad por una parte, de las diferentes metodologías existentes y, por otra, del tipo de problema a resolver, no es posible denominar un clasificador global que sea igual de efectivo en todas las áreas. En este sentido, cualidades como la precisión obtenida, la velocidad en la toma de decisiones, el tiempo de aprendizaje, así como la complejidad y comprensibilidad de los modelos, son comparadas a la hora de la seleccionar el clasificador a emplear.

Además, otra particularidad a tener en cuenta es que se suele exigir que los modelos de clasificación se caractericen por su habilidad de generalización, es decir, que los modelos generados tengan una alta capacidad para predecir con éxito nuevos datos de entrada.

Por todo ello, a continuación se muestra una tabla comparativa de cinco de las técnicas más utilizadas para la clasificación basadas en inteligencia artificial (ver Tabla 9).

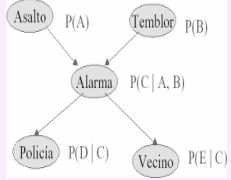
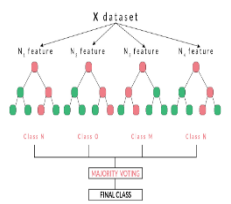
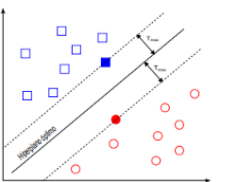
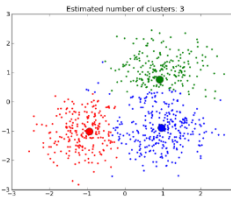
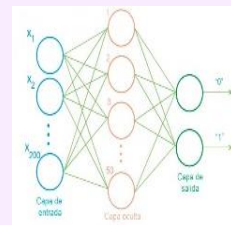
TÉCNICAS DE CLASIFICACIÓN	DESCRIPCIÓN	REPRESENTACIÓN	VENTAJAS	INCONVENIENTES
REDES DE BAYES	Se basa en la implementación de un grafo en el que se representan las probabilidades condicionales bayesianas ⁴ de la transición entre sucesos (Friedman et al., 1997).		-Rápido en la tarea de clasificación y aprendizaje.	-No es muy bueno con variables continuas. -No siempre se puede hacer uso del condicional.
ÁRBOLES DE DECISIÓN ALEATORIOS	Es la agrupación de varios árboles de decisión formados a partir de variables seleccionadas aleatoriamente dentro de un conjunto. La predicción global se obtiene a partir de la ponderación de la predicción individual de cada árbol (Medina-Merino & Ñique-Chacón, 2017).		-Fácil de interpretar. -Pueden trabajar con relaciones no lineales. -Trabaja con grandes volúmenes de datos.	-Difícil de generalizar. -Sobreajuste.
MÁQUINAS DE SOPORTE VECTORIAL (SVM)	Tratan de encontrar hiperplanos que maximicen la separación entre dos grupos de forma equidistante (Carmona, 2014). Útil para modelos de regresión y de clasificación binaria.		-Fácil generalización -Bajo coste computacional	-Complejo cuando los datos no son separables linealmente.
“CLUSTERING”	Consiste en dividir un conjunto de individuos en diferentes subconjuntos, de forma que cada uno de los integrantes de cada grupo sean similares entre ellos, y se diferencien del resto de grupos (Jain, Murty, & Flynn, 1999).		-Trabaja con grandes bases de datos. - Baja latencia.	-Hay que conocer de antemano el número de clusters que se desea excepto si se trata de clustering jerárquico. -En clustering jerárquico se produce acumulación de errores.
REDES NEURONALES ARTIFICIALES	Inspiradas en el comportamiento neuronal de los seres humanos. Adquieren conocimiento a partir de la experiencia. Permite obtener predicciones a partir de datos de forma no lineal (Trujillano Cabello et al., 2005).		-Gran capacidad de extracción de características. - Fácil generalización. - Tolerancia ante fallos.	-Tiempo de aprendizaje elevado. -Requieren grandes bases de datos. -Sistemas complejos.

Tabla 9: Comparativa de diversas técnicas de clasificación. Fuente: Elaboración propia

⁴ Teorema de Bayes: Se utiliza para recalcular probabilidades cuando se dispone de información adicional. Una vez conocida la probabilidad de un suceso a priori (A_i) y algún tipo de información extra, permite

obtener la probabilidad a posteriori, de forma que:
$$P\left(\frac{A_i}{B}\right) = \frac{P(A_i) * P\left(\frac{B}{A_i}\right)}{P(B)}$$

Para la elección del modelo a emplear, resulta conveniente resaltar que, en función de la información contenida en los datos, el método a emplear puede variar. De esta forma, los tipos de aprendizaje se pueden dividir en tres categorías (Jiang et al., 2017):

- Aprendizaje supervisado: el modelo recibe como parámetros de entrada las variables sobre las cuales se desea obtener un patrón, y la categoría a la que estas pertenecen. De esta forma, el sistema inteligente aprenderá a identificar cada característica extraída con la categoría a la que pertenece de manera que, ante nuevas entradas desconocidas pueda predecir dicha categoría. De los métodos de clasificación explicados anteriormente, las redes bayesianas, los árboles de decisión aleatorios, las máquinas de soporte vectorial y el perceptrón multicapa hacen uso de este tipo de aprendizaje.
- Aprendizaje no supervisado: en este caso no se dispone de la información referente a la categoría de cada variable. El método de *clustering* hace uso de dicho tipo de aprendizaje.
- Aprendizaje semi-supervisado: Consiste en un tipo de aprendizaje híbrido entre los dos anteriores. De esta forma, solo una parte de las muestras proporcionan como parámetro de entrada la categoría a la que pertenecen.

En este caso, tal y como se explicará en la sección 6.3.1, se dispone de datos etiquetados, es decir, se conoce la clase a la que pertenecen cada uno de ellos por lo que se emplearán técnicas de aprendizaje supervisado. Además, dichas variables son continuas y se requiere de gran capacidad de generalización, de modo que el clasificador pueda ser empleado en diversas ocasiones con diferentes muestras de entrada. Por este motivo, no resulta conveniente emplear redes bayesianas ni árboles de decisión. Además, las SVM pueden resultar complejas cuando las variables no son separables linealmente, por lo que se ha escogido implementar un modelo basado en redes neuronales artificiales para llevar a cabo la tarea de clasificación. Concretamente, la arquitectura a desarrollar consistirá en un perceptrón multicapa.

5.2. El perceptrón multicapa.

El perceptrón multicapa es una red neuronal artificial posterior al perceptrón simple, que surge para poder afrontar la distribución no lineal que siguen la mayoría de conjuntos de datos (Gardner & Dorling, 1998). Este tipo de arquitectura ha sido muy empleada en el sector financiero. Diversos artículos demuestran su aplicabilidad a tareas como la predicción de insolvencia empresarial (Tkáč & Verner, 2016), *credit scoring* (West, Dellana, & Qian, 2005), la detección de apuros financieros (Becerra, Galvão, & Abou-Seada, 2005), (Aydin & Cavdar, 2015), la respuesta del cliente a la campaña de telemarketing directo del banco (Asare-Frempong & Jayabalan, 2017) y el análisis de la importancia de factores demográficos en las elecciones de los consumidores (Hu & Tsoukalas, 2003), entre otras.

Es posible establecer una semejanza entre los fundamentos de las redes neuronales y el comportamiento biológico del cerebro humano (G. P. Zhang, 2000). Las redes neuronales están formadas por neuronas conectadas entre sí que permiten la transmisión de información. Una vez que un estímulo (información) llega a la neurona, esta ha de activarse para procesar la información

y hacerla fluir hacia el resto de neuronas hasta alcanzar el conocimiento. En la Figura 5, se muestra el símil entre una neurona artificial y una neurona real, del mismo modo que se puede apreciar el algoritmo que formula el comportamiento matemático de las neuronas artificiales.




Figura 5: Comparativa entre una neurona real y una artificial. Fuente: www.definicionabc.com

5.2.1. Estructura del perceptrón multicapa

Así pues, el perceptrón multicapa es una red neuronal artificial basada en aprendizaje supervisado compuesta de, al menos, tres capas (Trujillano Cabello et al., 2005):

- Capa de entrada: cada una de las neuronas que la conforman se corresponden a las variables de entrada a considerar en el problema.
- Capa de salida: proporciona el resultado o clasificación final del sistema.
- Capas ocultas o *hidden layers*: capas situadas entre la de entrada y la de salida; ha de haber al menos una. En función del número de capas ocultas que haya, se puede hablar de redes neuronales poco profundas (*Shallow Neural Networks*) o muy profundas (*Deep Neural Networks*). A las capas ocultas llegan las salidas de las capas anteriores. Las neuronas de las capas ocultas se encargan de procesar toda la información que les llega creando transformaciones de los datos de entrada para obtener información con un alto nivel de abstracción.

5.2.2. Modo de funcionamiento de un perceptrón multicapa

El proceso de entrenamiento del perceptrón multicapa se puede definir en dos fases. La primera de ellas es la propagación hacia delante o *feedforward* (Figura 6), donde las variables de entrada recorren toda la arquitectura hasta llegar a la salida de la misma. Para ello, en cada iteración, la información se transmite entre las neuronas de las diferentes capas. Para procesar la información, las neuronas aplican una función de umbralización (también conocida como función de activación) a la suma de los productos de las activaciones anteriores por sus pesos correspondientes.




Figura 6: Propagación hacia delante de una red neuronal artificial. Activación de las neuronas. Fuente: Elaboración propia.

Convencionalmente, las funciones de activación más empleadas son la tangente hiperbólica, la función sigmoide y la ReLU. De esta forma, tras la activación de la última capa se obtiene la probabilidad final, otorgando a cada clase o categoría la probabilidad de ocurrencia. Cabe añadir, que en la última capa es común hacer uso de otro tipo de función de umbralización conocida como *softmax*. A continuación, en la Tabla 10 se muestran gráfica y matemáticamente algunas de las posibles funciones de activación (Karlik & Olgac, 2011):

FUNCIÓN DE UMBRALIZACIÓN	EXPRESIÓN MATEMÁTICA	GRÁFICA	RANGO DE UMBRALIZACIÓN
Sigmoide	$f(x) = \frac{1}{1 + e^{-x}}$		[0,1]
Lineal	$f(x) = cx$		$[-\infty, \infty]$
ReLU	$f(x) = \begin{cases} x, & x > 0 \\ 0, & x \leq 0 \end{cases}$		[0,∞]
Tangente hiperbólica	$f(x) = \frac{2}{1 + e^{-2x}} - 1$		[-1,1]

Tabla 10: Funciones de activación comunes. Fuente: elaboración propia.

Hasta este momento, la red carece de conocimiento. Cuando la información llega a la capa de salida, se produce la predicción. En este momento, se le ha de indicar a la red el resultado real que debería haber obtenido, i.e. *groundtruth*. Así, se calcula la diferencia entre el valor real y el

predicho. Para ello, diversas funciones pueden ser empleadas, siendo la más común la entropía cruzada de Shannon, cuya expresión se muestra a continuación:

$$H(y, \hat{y}) = \sum_i y_i \log\left(\frac{1}{\hat{y}_i}\right) = - \sum_i y_i \log(\hat{y}_i) \quad (8)$$

donde y_i hace referencia a la probabilidad de cada componente, y \hat{y}_i a la de la predicción.

En este momento se procede a ajustar los pesos de las capas anteriores, dando lugar a la segunda fase del perceptrón, conocida como retropropagación o propagación hacia atrás (*backpropagation*). La idea principal es recorrer la arquitectura a la inversa, realizando un ajuste en los pesos hasta encontrar el valor óptimo de los mismos, que minimicen el error del modelo. Es en esta fase donde la red adquiere conocimiento. Para más información, consultar (Al-Masri, 2019).

La actualización de los pesos consiste en ajustar el valor que los mismos presentaban en la fase de propagación hacia delante previa por un factor que tenga en cuenta las pérdidas obtenidas. Esta expresión variará en función del optimizador de pesos empleado. Uno de ellos es el optimizador de descenso por gradiente estocástico, SGD (Ruder, 2017). De esta forma, la actualización consistirá en restar al peso actual, la derivada del error en función de los pesos anteriores (9), junto con un parámetro conocido como tasa de aprendizaje o *learning rate* (10).

$$\nabla J_i = \frac{\partial Error}{\partial w_i} \quad (9)$$

$$W(t+1) = W(t) - \eta \nabla J \quad (10)$$

Cuando ambas fases finalizan, se dice que ha transcurrido una época. El mismo procedimiento se repetirá tantas épocas como el especialista indique. En cada época, si el clasificador está adecuadamente diseñado, la red irá adquiriendo cada vez más conocimiento, mejorará la precisión y disminuirán las pérdidas.

En la Figura 7 se muestra la arquitectura de un perceptrón multicapa con una única capa oculta, así como indicadores de la fase de propagación hacia delante y retropropagación.




Figura 7: Arquitectura de un perceptrón multicapa con una única capa oculta. Indicadores de la fase de propagación hacia delante y retropropagación. Fuente: Elaboración propia.

5.3. Material empleado

5.3.1. Base de datos

Los datos empleados para el diseño de la aplicación que se presentará a continuación, han sido extraídos de una base de datos depositada en *Kaggle* (Kaggle, 2019). Adquirida por Google en 2017, *Kaggle* es una comunidad *online* representada por apasionados de la inteligencia artificial y analistas de datos cuya función principal es ofrecer bases de datos públicas y organizar concursos para la resolución de diversos problemas relacionados con el análisis de datos, empleando para ello diversas técnicas entre las que se encuentran el *machine learning* y la inteligencia artificial, entre otras.

Concretamente, los datos que se han obtenido para el propósito del presente trabajo fin de grado fueron propuestos para ofrecer una solución al enigma de si un cliente de una entidad financiera, Santander en este caso, realizará o no transacciones futuras, independientemente de la cantidad a transferir. Tal y como se informa en la plataforma, las variables proporcionadas se corresponden con datos reales analizados por la propia entidad cuando ha de resolver este tipo de cuestiones.

Así pues, el *dataset* proporcionado consiste en dos archivos “.csv”. En el primero de ellos se encuentran los datos de entrenamiento que emplearemos para entrenar la red de clasificación diseñada, y en el que aparecen tanto las variables a analizar como el *groundtruth* o *target*⁵. En este caso, dada la confidencialidad de los datos, desconocemos qué representan las variables analizadas, lo que limitará la interpretación final del modelo, aunque no es ningún inconveniente a la hora de su planteamiento. El segundo archivo contiene los datos de test, con las mismas características que el archivo con los datos de entrenamiento y que sirve para, una vez entrenado y validado el modelo, testear si la red de clasificación consigue predecir correctamente. No obstante, en este caso no disponemos del *groundtruth* de las muestras de test, ya que se lo reserva *Kaggle* en su dominio para comprobar los resultados obtenidos por los diferentes participantes y seleccionar así a los ganadores del concurso. En ambos archivos se dispone de 200 variables a analizar, representadas por un total de 200.000 clientes (i.e. instancias del conjunto de datos).

5.3.2. Entorno de programación

Para el diseño de la presente aplicación se ha hecho uso del entorno de programación *Google colab*, que permite programar en la nube ofreciendo una GPU gratuita, para lo que se emplea el lenguaje de programación *Python3.0*.

Revisando la literatura existente para la resolución de problemas de clasificación con técnicas *machine learning*, tal y como se ha comentado anteriormente, se ha optado por la implementación de un modelo de red neuronal, el perceptrón multicapa.

Para ello, se va a emplear librerías existentes para la resolución de este tipo de problemas, y que pertenecen a “Keras” y “sklearn”, principalmente. Keras dispone de implementaciones ya realizadas de bloques para la construcción de redes neuronales, ya sean redes neuronales comunes

⁵ El *target* hace referencia a las etiquetas de cada muestra, es decir, indicar a que categoría pertenece cada cliente. En este caso, la etiqueta puede ser 0 o 1 en función de si el cliente realiza o no transacciones.

(NN, atendiendo a sus siglas en inglés), o algunas más específicas, tales como las redes neuronales recurrentes y las redes neuronales convolucionales (RNN, CNN).

5.4. Análisis estadístico de los datos

Previamente al diseño de la red de clasificación, resulta interesante hacer un análisis estadístico de los datos proporcionados. Lo primero de todo será comprobar la ausencia de datos o casos perdidos en los archivos de entrenamiento y test.

Una vez verificado que todos los datos están disponibles, se procede a estudiar la distribución de los mismos. Para ello, se puede hacer uso de diferentes métricas estadísticas. Dado que se dispone de 200 variables, en el presente documento se muestra el análisis únicamente de ocho de ellas, de las cuales la mitad pertenecen a la base de datos de entrenamiento y el resto a la de testeo, si bien este estudio se ha realizado para el conjunto muestral completo (véase [AnezoII](#)).

El primer análisis a realizar debe ser en referencia a la única variable categórica de nuestra base de datos, el *target*, que será cero o uno dependiendo de si el cliente pertenece a la clase que realiza o no transacciones, respectivamente. De las 200.000 muestras del fichero “.csv” de entrenamiento, tan solo 20098, representan la clase 1, mientras que los 179.902 restantes corresponden al *target* igual a cero. Es decir, un 89.951% representan a la clase 0, por lo que se puede afirmar que existe un claro desbalanceo en los datos. En la Figura 8 que se muestra a continuación, se puede apreciar fácilmente esta cuestión, con la representación de las frecuencias absolutas y relativas del *target*.




Figura 8: Frecuencias relativas y absolutas de la variable categórica de la base de datos de entrenamiento. Fuente: Elaboración propia.

El resto de variables que conforman ambas bases de datos son cuantitativas y continuas, por lo que se ha decidido hacer un estudio de posición y dispersión de cada una de ellas. Para ello, se ha hecho uso de las herramientas histograma y *box-whiskers*, así como el cálculo numérico de diversas métricas. A continuación, en la Figura 9 se muestran los diferentes diagramas así como una tabla resumen que recoge las medidas obtenidas para seguidamente proceder a su análisis.




Figura 9: Representación de la distribución de las variables de entrenamiento (izquierda) y testeo (derecha).
Fuente: Elaboración propia

Analizando los histogramas obtenidos de cada variable, se puede comprobar que describen una distribución normal ya que las muestras se pueden aproximar por la campana de Gauss. Además, a simple vista se podría descartar también la existencia de datos anómalos que alteren dicha distribución. Sin embargo, parece que en algunas ocasiones hay asimetría, ya que hay más condensación de datos en la parte derecha o izquierda del diagrama, generándose así asimetría positiva o negativa, respectivamente. No obstante, se analizará de forma más exhaustiva con el cálculo de métricas. De la Figura 9 se puede observar que tanto la media como el rango (eje horizontal) varían en función de la variable analizada por lo que antes de alimentar al perceptrón multicapa propuesto, habrá que estandarizar los datos en el rango $[-1,1]$ para que todas las variables adquieran la misma importancia.

Estas afirmaciones también pueden ser corroboradas con el cálculo de estadísticos de diverso orden. La mediana es muy similar a la media en todas las variables, lo que conlleva a que los datos son normales y simétricos, centrados en el valor medio, por lo que es de esperar que el coeficiente de asimetría sea reducido. Esta simetría de los datos puede reafirmarse con la interpretación del coeficiente de asimetría estandarizado que, al encontrarse dentro del rango $[-2,2]$ y muy cercano a cero en todos los casos indica que los datos son simétricos. Además, cabe añadir que en determinadas ocasiones, este coeficiente adquiere signo positivo y en otras ocasiones signo negativo, por lo que indica una pequeña asimetría a diferentes lateralidades de la media, tal y como se había previsto con el análisis la Figura 9; si bien, al tratarse de unos valores tan reducidos, es un indicador de que las muestras proceden de una población normal simétrica. Además, en la mayoría de los casos, el intervalo intercuartílico es reducido, indicador de que hay poca dispersión en los datos, pues, el intervalo intercuartílico por definición es el intervalo en el cual se concentra el 50% de los datos. El hecho de que estos estén centrados en un intervalo pequeño, indica que no hay mucha dispersión.

Finalmente, en cuanto al análisis de la curtosis, se puede afirmar que todos los datos encontrados son planicúrticos, ya que presentan un coeficiente de curtosis negativo (ver Tabla 11).

	Var_0	Var_1	Var_2	Var_3	Var_0	Var_1	Var_2	Var_3
Media	10.68	-1.63	10.72	6.8	10.66	-1.62	10.71	6.79
Mediana	10.53	-1.61	10.58	6.83	10.51	-1.59	10.56	6.82
Varianza	9.24	16.40	6.98	4.18	9.22	16.32	6.94	4.21
Desviación típica	3.04	4.05	2.64	2.04	3.04	4.04	2.63	2.05
Coefficiente de variación	0.29	-2.49	0.25	0.3	0.28	-2.49	0.25	0.30
Rango	19.91	25.42	17.24	13.23	22.13	24.43	16.36	13.16
Intervalo intercuartílico	0.75	0.88	0.59	0.46	0.81	0.82	0.66	0.49
Asimetría	0.24	0.05	0.26	-0.003	0.23	0.04	0.26	-0.003
Coef. Asimetría estandari.	0.078	0.013	0.099	-0.001	0.07	0.011	0.099	-0.002
Curtosis	-0.27	-0.61	-0.34	-0.603	-0.26	-0.6	-0.32	-0.61
Coef. Curtosis estandari.	-0.09	-0.15	-0.13	-0.29	-0.09	-0.15	-0.12	-0.3

Tabla 11: Parámetros estadísticos de las cuatro primera variables de la base de datos de entrenamiento (izquierda) y testeo (derecha). Fuente: Elaboración propia.

De forma mucho más práctica, se representarán los datos en diagrama de bigotes, de forma que se puedan percibir, de forma visual, todos los parámetros estadísticos analizados hasta el momento.

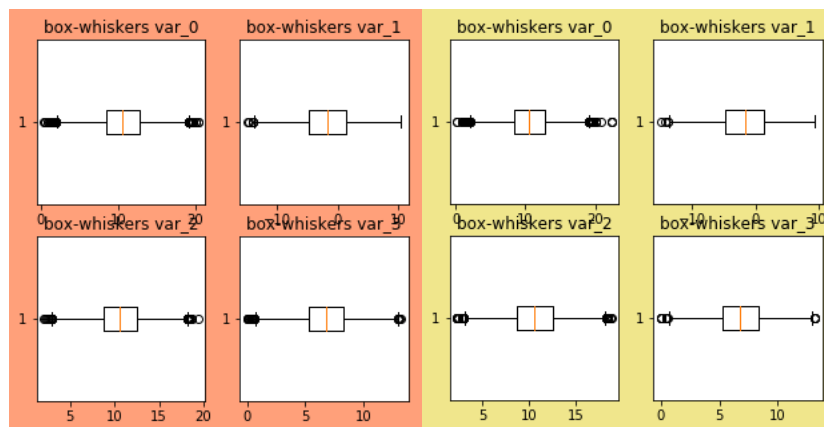


Figura 10: Diagrama "box-whiskers" de las cuatro primeras variables de la base de datos de entrenamiento (izquierda) y testeo (derecha). Fuente: Elaboración propia.

Es fácil comprobar nuevamente la normalidad y simetría de los datos, ya que todos los *box-whiskers* presentan la misma estructura: cajas con la media prácticamente en el centro, aproximadamente mismo tamaño de los "bigotes", y la presencia de muy pocos datos anómalos, mientras que los existentes no están muy dispersos.

A continuación, se decide analizar la matriz de correlación y de covarianza entre las variables para comprobar la posible existencia de relación lineal entre las variables del modelo. Sin embargo, como se ha mencionado anteriormente, se desconoce qué indicador representa cada variable, por lo que es posible que no todos los datos se encuentren en la misma escala. Si esta afirmación se cumple, la covarianza no supondrá una visión objetiva de la relación lineal. Por este motivo, se va a presentar el coeficiente de correlación únicamente. Si esta relación es lineal, lo común será que presente valores en torno a 1, bien sea positiva o negativamente. Para ello, se ha hecho uso de la siguiente expresión:

$$R_{ij} = \frac{cov(x_i x_j)}{\sqrt{var(x_i) * var(x_j)}} \quad (11)$$

Donde $cov(x_i x_j)$ hace alusión a la covarianza entre dos variables, y se obtiene como,

$$cov(x_i x_j) = \frac{\sum_i (x_i - \bar{X})(y_i - \bar{Y})}{N-1} \quad (12)$$

	0	1	2	3
0	1.000	-0.001	0.007	0.004
1	-0.001	1.000	0.004	0.102
2	0.007	0.004	1.000	0.001
3	0.004	0.102	0.001	1.000

Tabla 12: Matriz de correlación de las cuatro primeras variables de entrenamiento. Fuente: Elaboración propia.

Como se puede observar en la Tabla 12, los coeficientes de correlación entre variables son prácticamente cero, por lo que no existe relación lineal entre las mismas. Esta matriz se encuentra de forma detallada para las 200 variables del conjunto de entrenamiento en el Anexo I.

A pesar de que no existe linealidad entre las variables dos a dos, puede darse el caso de que la linealidad se dé para un conjunto más amplio de las variables (Tusell, 2011). Este término se conoce como multicolinealidad. Existen diversos métodos para su detección⁶; en este caso se ha escogido analizar la matriz inversa de la matriz de correlación.

	0	1	2	3
0	1.00006	0.00057	-0.00657	-0.00379
1	0.00057	1.00002	-0.00398	-0.00001
2	-0.00657	-0.00398	1.00006	-0.00098
3	-0.00379	-0.00001	-0.00098	1.00002

Tabla 13: Matriz de multicolinealidad de las cuatro primeras variables de entrenamiento. Fuente: Elaboración propia.

Dado que nuevamente se obtienen valores muy cercanos a cero, se puede descartar la existencia de multicolinealidad.

⁶ Actualmente, no existe ningún modelo único y decisivo para la determinación de la multicolinealidad. Entre las diferentes propuestas hasta el momento se encuentran los métodos de Belsley, Kuh y Welsh y el cálculo de la matriz inversa de la de correlación.

5.5. Descripción de la arquitectura diseñada

5.5.1 Preprocesado de datos

Previamente al entrenamiento de la red neuronal es necesario realizar un preprocesado de los datos. Para ello, se ha de tener en cuenta que, para el correcto funcionamiento de una arquitectura neuronal los datos han de dividirse en tres conjuntos:

- Datos de entrenamiento. Conformarán el proceso de entrenamiento. Es el conjunto de datos destinado a llevar a cabo el procedimiento propagación hacia delante y retropropagación y, por tanto, los datos encargados de que la red adquiera conocimiento.
- Datos de validación. Se trata de un conjunto de datos de tamaño más reducido que los de entrenamiento. La idea principal es realizar una validación de forma paralela al entrenamiento de modo que se analiza si el sistema está adquiriendo conocimiento adecuadamente. Si el patrón de pérdidas y precisión de los datos de validación se asemejan al de entrenamiento, será sinónimo de que el modelo es generalizable, ya que actúa del mismo modo con datos diferentes.
- Datos de test: Una pequeña proporción de los datos, generalmente entre el 20%-30% de los datos disponibles se reservan para testear el modelo. Una vez finalizada la fase de entrenamiento y validación, se realizan predicciones con los datos de test. Sirve para comprobar qué precisión tiene el sistema, es decir, si realiza de forma idónea o no las predicciones. Aquí es cuando se comprobará si el modelo diseñado es un buen clasificador.

Atendiendo a todo ello, se va a proceder a adaptar estas particiones a la base de datos de este proyecto. La base de datos está conformada por 200.000 clientes tanto en entrenamiento como en test (trainX, testX, respectivamente), cada uno representado por 200 variables, además del target (trainY) en el caso de los clientes de entrenamiento (véase Tabla 14).

Datos ⁷	Dimensiones
trainX	(200.000,200)
trainY	(200.000,1)
testX	(200.000,200)

Tabla 14: Dimensiones originales de los datos proporcionados. Fuente: Elaboración propia.

No obstante, cabe recordar que en este caso, carecemos de la partición de datos correspondientes a validación, por lo que se ha de dividir los datos de entrenamiento, de modo que se obtenga una muestra representativa para realizar una validación del modelo, previamente al testeo del mismo y extracción de las predicciones. Por este motivo, se ha decidido dividir el *training set* en dos partes, el 80% de las muestras se destinarán a entrenar el modelo, mientras que el 20% restante se emplearán para la validación del mismo. Esta partición se realiza de forma automática empleando la función “*train_test_split*” ofrecida por la librería *sklearn*. Finalmente, la distribución de los datos queda de la siguiente manera (véase Tabla 15):

⁷ Recordemos que en el caso de los datos de test no disponemos del *target*.

Datos	Dimensiones
train_X	(160.000,200)
train_Y	(160.000,1)
val_X	(40.000,200)
val_Y	(40.000,1)
testX	(200.000,200)

Tabla 15: Dimensiones originales de los datos tras realizar las particiones requeridas. Fuente: Elaboración propia.

Una vez establecidas las particiones de datos y previamente al entrenamiento de los mismos, lo primero que se ha de realizar es un preprocesado de los datos. Es necesario confeccionar una normalización de estos ya que, como se ha mencionado en el apartado de análisis estadístico, cada variable presenta un rango diferente. Así pues, al normalizar se pretende que las variables adquieran la misma relevancia, quedando todas ellas normalizadas en el rango $[-1,1]$, tanto para los datos disponibles en el *trainingset*⁸ como los de test. Para ello se ha escogido la función *MinMaxScaler* del *framework sklearn*, cuya normalización viene dada por la siguiente ecuación:

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}} * (max - min) + min \quad (13)$$

donde,

- X : valores del conjunto de datos que se desea normalizar.
- X_{max} , X_{min} : valores máximo y mínimo del conjunto de datos a normalizar, respectivamente.
- max , min : valores máximo y mínimo del rango en el cual se quiere normalizar, respectivamente. En este caso en particular, max sería igual a la unidad mientras que min será -1.

5.5.2. Arquitectura del perceptrón multicapa

Llegados a este punto, se va a proceder a diseñar la arquitectura del modelo. Se ha optado por una estructura secuencial, a la cual se le añadirán capas según la arquitectura de red diseñada. Se añadirán tantas capas densas como capas se desea que tenga la red. Los parámetros de entrada para establecer dichas capas serán el número de neuronas que se desea en cada capa, así como la función de activación de los pesos a la salida de cada una de ellas. Para la definición de la primera capa densa, necesariamente se le ha de indicar adicionalmente el número de entradas que ha de tener, es decir, las doscientas variables de las que se dispone. Mientras que para la última densa, el número de neuronas se corresponde con el número de salidas en las que se han de clasificar los datos; en este caso dos, una que identifique a aquellos clientes que sí realizan transacciones y otra que indique el caso contrario.

⁸ Se ha de tener en cuenta que, en el caso de los datos de entrenamiento, la primera columna se corresponde con el *target*, que ya tiene sus valores a cero o a uno, por lo que en este caso se han de excluir de la normalización.

A continuación se requiere configurar el proceso de aprendizaje, para lo que se emplea la función “*model.compile*” de *Keras*. Los argumentos de entrada necesarios para esta compilación son tres: la función de pérdidas a minimizar, el optimizador de pesos y la lista de métricas a considerar en la clasificación. En este caso, la función de pérdidas que se ha empleado es la entropía binaria cruzada (8) que mide la diferencia entre la distribución de probabilidad real y la estimada, de forma que cuanto menor sea esta diferencia, mejor será la estimación (más se asemeja a la realidad).

Determinados todos los parámetros se procede a entrenar la red mediante la instrucción *model.fit*, dotándole de los datos de entrenamiento y validación, así como del número de épocas que realizará el procedimiento.

Dado que los datos originales presentan un claro desbalanceo en cuanto al número de datos por categoría se refiere, resulta conveniente añadir un parámetro adicional a la fase de entrenamiento. Este consiste en un índice que mide el nivel de desproporción existente entre categorías. De esta forma, el objetivo perseguido es que en la actualización de pesos se preste mayor atención a la clase con menor número de muestras.

Durante el procedimiento de entrenamiento se va generando una historia que informa de las pérdidas del modelo en cada época, así como otras métricas especificadas en el momento de la compilación. En este caso, se ha solicitado el reporte de la precisión.

Una vez entrenado el modelo, se utilizan los pesos obtenidos para realizar las predicciones que se desean. Para determinar si el modelo hace o no buenas predicciones, se realiza una predicción con los datos de test disponibles, comprobando así la fiabilidad del modelo propuesto. En este caso, al no disponer del *target* en los datos de test no podremos realizar esta comprobación pues, aunque realicemos la predicción, no sabremos si se ajusta o no a la actuación real de los clientes. Por este motivo, se ha decidido realizar la predicción sobre los datos de validación pues si disponemos del *target* de cada cliente, y de esta forma observar el nivel de precisión del modelo, así como otras métricas ofrecidas por el informe de clasificación facilitado por *sklearn*.

Hasta ahora, se ha definido la arquitectura base del perceptrón, si bien quedaría por determinar los hiperparámetros a emplear. Para ello, se han llevado a cabo diversas pruebas partiendo de los parámetros escogidos a priori que mejor se ajustarían al problema, y posteriormente se han realizado algunas modificaciones de manera experimental para obtener una mejor precisión.

5.5.3. Elección de los hiperparámetros del modelo

- **Número de capas densas y neuronas:** inicialmente se optó por introducir cuatro capas densas, cuyo número de neuronas era 200 en la primera capa, 100 y 50 en la segunda y tercera capa, y 2 en la capa de salida. La elección de esta estructura proviene de que partimos de 200 variables y se van reduciendo a la mitad en las capas posteriores. Sin embargo, se comprobó que la precisión media del modelo mejora con una estructura 200-50-2, ya que de esta forma se evita tender al sobreajuste de los datos⁹.
- **Técnica de *Dropout*:** en las situaciones en las que parece haber sobreajuste se introduce *dropout* entre las capas densas. El objetivo es desconectar determinadas conexiones aleatorias entre neuronas, siendo el porcentaje de neuronas desconectadas el parámetro de *dropout* introducido. En el diseño final del perceptrón propuesto no requiere el uso de *dropout* (Srivastava, Hinton, Krizhevsky, & Salakhutdinov, 2014).
- **Función de activación:** la función de activación escogida es la *Relu* para todas las capas excepto para la última, en la que se emplea activación *softmax*.
- **Optimizador:** se ha escogido el optimizador SGD, descenso por gradiente estocástico, que se encarga de actualizar los pesos en la fase de retropropagación. Así pues, para cada conjunto de datos se realiza el paso de propagación hacia delante, luego calcula el error y lo acumula para posteriormente actualizar los pesos en la fase de retropropagación. Para ello, hay que indicarle la tasa de aprendizaje a la que ha de trabajar, cuyo valor finalmente es de 0.005. Previamente a esta conclusión, se han realizado pruebas con diversos optimizadores y con diferentes tasas de aprendizaje, si bien 0.005 es la más acertada. Si dotamos al sistema de una tasa de aprendizaje mayor, el sistema aprende demasiado rápido, produciéndose variaciones bruscas en la precisión obtenida e incluso propiciando que nunca se llegue al mínimo global (o local) de la función objetivo, mientras que, si utilizamos una *learning rate* más pequeña, el sistema tarda más en acercarse al objetivo.
- **Tamaño del *batch*:** para el procesamiento de grandes bases de datos suele ser común agrupar los datos en lotes más pequeños para acelerar el proceso. El tamaño de estas agrupaciones es comúnmente conocido en este campo como tamaño del “*batch*”. En este caso, dada la gran cantidad de datos a analizar, se ha escogido un *batch* de 256.

En la Tabla 16 se muestra un cuadro resumen de la arquitectura e hiperparámetros empleados.


Hiperparámetro		Valor
Capas densas	Nº capas	3
	Nº neuronas	200-50-2
Dropout		-
Función de activación		Relu-Relu-Softmax
Optimizador		SGD
Tasa de aprendizaje		0.005
Tamaño del batch		256
Número de épocas		200

Tabla 16: Resumen de los hiperparámetros del modelo. Fuente: Elaboración propia.

⁹ El sobreajuste, también conocido como *overfitting* ocurre en *machine learning* cuando la implementación de un modelo se ajusta en exceso a los datos específicos empleados para su entrenamiento de forma que dicho modelo pierde la capacidad de generalizar a otro conjunto de datos.

5.6. Resultados

A continuación, se muestran los resultados obtenidos para el modelo final propuesto. Para ello, se han valorado diversos aspectos. El primero de ellos es la representación gráfica de las pérdidas y la precisión producidas en el proceso de entrenamiento y validación. Así pues, se ha de tener en cuenta que idealmente la curva de validación debe ser lo más similar a la de entrenamiento, y que se desea una precisión lo más cercana al 100% (o lo que es lo mismo pérdidas tendiendo a cero). A medida que aumenta el número de épocas recorridas, las curvas deben tender cada vez más a dichos valores. Además, se desea que estas curvas no sean ruidosas sino que estén suavizadas, sin que se produzcan grandes picos ni variaciones anómalas.



Gráfica 9: Resultados de las pérdidas y precisión de las fases de entrenamiento y validación del modelo. Fuente: Elaboración propia.

Como se puede apreciar en la Gráfica 9 las pérdidas tienden a alcanzar un valor de 0.23, aparentemente dicho valor puede resultar elevado, no obstante la precisión final obtenida en la fase de entrenamiento se encuentra en torno al 91.5%.

Para comprobar cómo predice dicho modelo, en primer lugar, se realiza la predicción de los clientes que conforman la base de datos de validación. Normalmente, lo que se predice no es la validación sino el test, pero, como se ha mencionado anteriormente nuestro conjunto de test carece de *groundtruth* por lo que no podemos evaluar el rendimiento del modelo con este conjunto de datos. Procediendo de este modo, la precisión obtenida para el conjunto de validación es la siguiente.

	Precisión	Sensibilidad	F1-score	Muestras
Clase 0	0.92	0.99	0.95	35.949
Clase 1	0.71	0.27	0.4	4.051
Media/Total	0.90	0.917	0.894	40.000

Tabla 17: Informe de clasificación del modelo. Fuente: Elaboración propia.

Así pues, la precisión obtenida en la predicción es del 90%, de forma que el modelo únicamente predeciría erróneamente el 10% de los casos. A modo de objeción, el hecho de que el modelo obtenga peores resultados de clasificación en la clase 1 es que los datos están desbalanceados, es decir, hay más clientes que pertenecen a la clase 0 que a la clase 1, lo que limita al modelo conocer todos los posibles patrones de actuación de estos últimos clientes a pesar de incluir el índice de

balanceo. No obstante, dado que se ha introducido un índice de balanceo de clases, se ha prestado mayor atención a la clase más desfavorecida.

La sensibilidad mide la proporción de positivos actuales que han sido bien identificados.

$$TPR = \frac{VP}{VP+FN} \quad (14)$$

F1-score tiene en cuenta la precisión y la sensibilidad.


$$F_1 - score = 2 \frac{Precisión * Sensibilidad}{Precisión + Sensibilidad} \quad (15)$$

Para la determinación de si el modelo es o no aceptable, se plantea otra métrica, conocida como el área bajo la curva. Para ello, se dibuja la curva ROC, curva característica operativa del receptor en función de dos parámetros, la tasa de verdaderos positivos y la tasa de falsos positivos. La primera tasa hace referencia a la exhaustividad, es decir, los verdaderos positivos frente a los verdaderos positivos y falsos negativos. La tasa de falsos positivos contempla el cociente entre falsos positivos y falsos positivos más verdaderos negativos.

$$FPR = \frac{FP}{FP+VN} \quad (16)$$

La curva representa los verdaderos positivos frente a los falsos negativos, y el área de la curva no es más que el área que se encuentra debajo de la ROC, por lo que se requiere que sea lo más cercano a la unidad posible, que indicaría que todas las predicciones son correctas.

En la Gráfica 10, se muestra dicha ROC, cuya área bajo la curva alcanza el valor de 0.86825, de forma que el 86.8% de los valores predichos están realmente bien identificados.



Gráfica 10: Representación de la curva ROC. Fuente: Elaboración propia.

Otra posible métrica a analizar es la realización de una matriz de confusión. Para favorecer a su correcta interpretación, resulta conveniente mencionar cuatro posibles resultados obtenidos en la clasificación:

- Verdaderos positivos (VP): hace referencia a las muestras clasificadas como que realizan transacciones y en la realidad el cliente las realiza.
- Falsos positivos (FP): la clasificación indica que se realiza transacción y la realidad es que no la realiza.
- Verdaderos negativos (VN): la muestra analizada pertenece a un cliente que no realiza transacciones y la clasificación así lo indica.

- Falsos negativos (FN): el modelo predice que no se realiza transacción pero en la realidad si se realiza.


Atendiendo a estas posibles identificaciones, estas mismas son recogidas en la Tabla 18, donde la diagonal principal hace referencia a los casos verdaderos (positivo y negativo en función de la case), mientras que la diagonal inversa se corresponde con clasificaciones erróneamente realizadas.

		Clases reales	
		0	1
Clases predichas	0	35485	464
	1	2937	1114

Tabla 18: Matriz de confusión. Fuente: Elaboración propia.

Llegados a este punto, se puede emplear la base de datos de test para conocer qué predicciones obtendríamos. Así pues, se procede a introducir las muestras de test a nuestro modelo de predicción de transacciones bancarias. De las 200.000 muestras de test, prácticamente el 97% son clasificadas como clase 0, mientras que poco más del 3% pertenecen a la clase 1, con una precisión del 90%, según nuestro modelo (véase Gráfica 11).

Frecuencia relativa de las predicciones



Gráfica 11: Porcentaje de clientes pertenecientes a cada clase tras la predicción de las muestras de test. Fuente: Elaboración propia.

De esta forma no se permite conocer el nivel de precisión alcanzado pues se desconocen las etiquetas de los datos, no obstante dado que en la Gráfica 9 parece no haber sobreajuste, el modelo presentaría la capacidad de generalización y, por tanto, los resultados recientemente obtenidos estarían bien predichos, con una precisión del 90%.

Para concluir, se puede observar que los modelos de clasificación basados en inteligencia artificial ofrecen predicciones con un alto nivel de precisión y de forma rápida, analizando grandes bases de datos en un tiempo reducido. Así pues, se ha permitido implementar un perceptrón multicapa capaz de analizar bases de datos conformadas por 200 variables y 200.000 muestras, obteniendo una precisión de clasificación del 90%. No obstante, se podría intentar incrementar dicho valor por medio de una reducción de las pérdidas de entrenamiento ya que, recordemos, estas presentaban el valor de 0.23. En este sentido, podría tratarse de realizar experimentos con otro tipo de optimizadores, así como con tasas de aprendizajes diferentes que puedan contribuir a la reducción de las pérdidas experimentadas en la fase de entrenamiento.

Capítulo 6. Conclusiones

Tras el análisis de la influencia de la inteligencia artificial en el sector financiero, diversas conclusiones pueden ser expuestas. En primer lugar, el impacto que la inteligencia artificial espera experimentar en un futuro cercano será exponencialmente superior a los realizados hasta el momento. Sin embargo, dado que se requiere de una fuerte inversión en sus inicios, se va a generar una brecha entre aquellos países con suficientes recursos en el momento de partida con respecto a las economías menos desarrolladas. Además, el impacto se va a producir en todos los sectores económicos.

En lo que al sector financiero se refiere, la banca española comienza a recuperarse después del periodo de crisis experimentado durante los años previos. También se puede concluir que se está desarrollando una reestructuración en el sistema bancario, evidenciado por dos motivos principales. Por una parte, las entidades se han agrupado para afrontar las circunstancias acaecidas en la crisis y, por otra, la llegada de la banca *online* y el empleo de la inteligencia artificial satisface determinados servicios, lo que provoca una disminución de la necesidad de asistir presencialmente a los establecimientos físicos.

Además, en cuanto a las entidades bancarias con mayor relevancia en el marco financiero español actual respecta, BBVA es la que mayor rentabilidad, eficiencia y cobertura presenta, además de disponer de un menor ratio de morosidad; mientras que Santander, posee mayor liquidez. En cuanto a la solvencia se refiere, Bankia ocupa la primera posición por el momento.

Por otra parte, se han podido analizar diferentes aplicaciones existentes en la actualidad, tales como los *chatbots*, asistentes virtuales y sistemas de autenticación biométrica. Además, en lo que respecta al sector bancario español, las tres entidades con mayor volumen de activo hacen uso de dichas aplicaciones con el doble objetivo de satisfacer las necesidades de los clientes ofreciéndoles asistencia inmediata, al mismo tiempo que las entidades optimizan sus recursos asociados. Igualmente, cabe añadir que CaixaBank es el banco que más apuesta por el empleo de *chatbots* con diferentes funcionalidades, mientras que BBVA hace mayor uso en España de la autenticación biométrica, empleando para ello diversas técnicas tales como el reconocimiento facial, de iris y de huella digital. Por otra parte, Santander también hace uso de dichas técnicas, pero apuesta más por el impulso internacional de las mismas, presentando aplicaciones menos maduras en el entorno español.

De esta forma, se alcanza un sistema bancario digitalizado que permite y facilita el acceso a las entidades de forma segura, desde cualquier lugar y en cualquier instante de tiempo.

No obstante, tal y como se ha comentado, existen distintas limitaciones a la evolución de la inteligencia artificial tales como la dificultad de encontrar modelos generalizables o la escasez de datos etiquetados, entre otras.

Con respecto al modelo de predicción de transacciones futuras diseñado, se muestra el potencial que la inteligencia artificial supone para el sector financiero. Con una base de datos histórica de actuaciones de clientes, se pueden diseñar modelos de predicción con una precisión razonable,

que puede ayudar en gran medida a la toma de decisiones de las entidades financieras. Así pues, se ha mostrado una de las arquitecturas que la inteligencia artificial propone, el perceptrón multicapa. De esta forma, se ha permitido obtener un modelo capaz de predecir si un determinado cliente realizará o no transacciones futuras con una precisión del 90%.

La limitación impuesta por la confidencialidad de los datos, impide la correcta interpretación de los resultados obtenidos, pues desconocemos qué información aporta cada una de las variables analizadas. Además, disponemos de un desbalanceo entre clases que puede limitar al aprendizaje, por lo que, para incrementar la precisión obtenida con la consiguiente disminución de casos falsos positivos y falsos negativos, resultaría conveniente repetir el entrenamiento de la red con un mayor número de datos que representen la clase '1' del problema. De esta forma, se favorecería a que el modelo fuera capaz de extraer las características esenciales de dicha clase, favoreciendo por tanto a la correcta identificación y clasificación de clientes.

Además, el hecho de disponer de modelos predictivos capaces de analizar grandes bases de datos puede facilitar a las entidades bancarias conocer el patrón de actuación de determinado tipo de clientes. En este caso, no se ha podido extraer conclusiones relevantes acerca de qué variables y valores de las mismas se encuentran presentes en los clientes que realizan transacciones, dado que no se dispone de la información sobre qué identifica cada una de dichas variables. No obstante, en la práctica real el modelo diseñado permitiría a las entidades analizar dichas variables y tomar medidas futuras encaminadas a potenciarlas y obtener un mayor provecho de dicha información.

Capítulo 7. Líneas de trabajo futuro

Para finalizar, resulta conveniente establecer una línea de investigación futura que permita conocer más en detalle la inclusión de la inteligencia artificial en el sector financiero.

Por una parte, dada la poca disponibilidad pública de datos actuales sobre el impacto hasta ahora experimentado por la inteligencia artificial en España, dado que gran parte de los informes actuales se basan en perspectivas futuras, resultaría favorecedor disponer de fuentes de búsqueda de información adicionales para realizar un análisis más exhaustivo de la situación actual.

Además, se ha permitido conocer la influencia de la inteligencia artificial en el sector bancario español. En este sentido, conocemos las aplicaciones desarrolladas por las entidades españolas con, aparentemente, mayor potencial de investigación e innovación. Sin embargo, se carece de información cuantitativa que permita conocer el impacto real de dichas aplicaciones. De esta forma, resultaría interesante que las diferentes entidades desarrollaran sistemas de evaluación que permitan comprobar la aceptación social y el grado de penetración que los sistemas inteligentes de la banca española experimentan sobre sus clientes por medio, por ejemplo, de un estudio de mercado como puede ser la realización de encuestas a dichos consumidores.

En cuanto al modelo de predicción propuesto se refiere, sería conveniente poder ampliar la base de datos proporcionada, así como conocer el significado de cada una de las variables disponibles, de forma que pueda contribuir a la obtención de modelos de clasificación más precisos y de los cuales se pueda extraer mayor información adicional, relevante para las entidades.

Referencias

- AEBANCA. (2018). *Anuario estadístico de la Banca en España 2018*. Retrieved from <http://aebadm.aebanca.es/wp-content/uploads/2019/07/anuario-estadistico-2018.pdf#page=179>
- Al-Masri, A. (2019). How Does Back-Propagation in Artificial Neural Networks Work? Retrieved April 8, 2019, from <https://towardsdatascience.com/how-does-back-propagation-in-artificial-neural-networks-work-c7cad873ea7>
- Asare-Frempong, J., & Jayabalan, M. (2017). Predicting customer response to bank direct telemarketing campaign. *2017 International Conference on Engineering Technology and Technopreneurship, ICE2T 2017, 2017-Janua*, 1–4. <https://doi.org/10.1109/ICE2T.2017.8215961>
- Aydin, A. D., & Cavdar, S. C. (2015). Prediction of Financial Crisis with Artificial Neural Network: An Empirical Analysis on Turkey. *International Journal of Financial Research*, 6(4). <https://doi.org/10.5430/ijfr.v6n4p36>
- Baccala, M., Curran, C., Garret, D., Likens, S., Rao, A., Ruggles, A., & Shehab, M. (2018). 2018 AI predictions. *PwC*, 1–25. Retrieved from <https://www.thomsonreuters.com/en/reports/2018-ai-predictions.html>
- Becerra, V. M., Galvão, R. K. H., & Abou-Seada, M. (2005). Neural and wavelet network models for financial distress classification. *Data Mining and Knowledge Discovery*, 11(1), 35–55. <https://doi.org/10.1007/s10618-005-1360-0>
- Belgavi, V. (2017). Chatbot: The intelligent banking assistant. *PwC*. Retrieved from <https://www.pwc.in/consulting/financial-services/fintech/fintech-insights/chatbot-the-intelligent-banking-assistant.html>
- Brayne, S., McKellar, S., & Tzafestas, K. (2018). Artificial Intelligence in the Sciences & Patent Analytics: Market Developments and Intellectual Property Landscape. In *January 2018*. Retrieved from <https://www.ip-pragmatics.com/media/1049/ip-pragmatics-artificial-intelligence-white-paper.pdf>
- Bughin, J., Seong, J., Manyika, J., Chui, M., & Joshi, R. (2018). Notes from the AI frontier: Modeling the global economic impact of AI. *McKinsey Global Institute, September*, 1–64. Retrieved from <https://www.mckinsey.com/featured-insights/artificial-intelligence/notes-from-the-ai-frontier-modeling-the-impact-of-ai-on-the-world-economy>
- Calvo, A., Alberto, J., Gámir, P., Rodríguez, L., & Cuervo, Á. (2014). *Economía y Empresa*. Retrieved from www.conlicencia.com
- Canci, C. (2018). Nuevos hábitos y expectativa de innovación de la inteligencia artificial en medicina. *Italiani e Salute Digitale*. Retrieved from <https://cristinacenci.nova100.ilsole24ore.com/wp-content/uploads/sites/134/2018/10/Diapositiva1.jpg>
- Carmona, E. J. (2014). *Tutorial sobre Máquinas de Vectores Soporte (SVM)* (p. 25). p. 25. Retrieved from <http://www.ia.uned.es/~ejcarmona/publicaciones/%5B2013-Carmona%5D SVM.pdf>
- Chui, M., Harryson, M., Manyika, J., Roberts, R., Chung, R., Heteren, A. van, & Nel, P. (2018). *Notes from the AI frontier Applying AI for social good*. 52. Retrieved from <https://www.mckinsey.com/featured-insights/artificial-intelligence/applying-artificial-intelligence-for-social-good>
- Ciberamenazas y tendencias 2018*. (2018). Retrieved from <https://www.ccn-cert.cni.es/informes/informes-ccn-cert-publicos/2856-ccn-cert-ia-09-18-ciberamenazas-y-tendencias-2018-resumen-ejecutivo-2018/file.html>
- Cornet, A., Kässer, M., Müller, T., & Tschiesner, A. (2017). The road to artificial intelligence in mobility--smart moves required. *McKinsey*. Retrieved from <https://www.mckinsey.com/industries/automotive-and-assembly/our-insights/the-road-to>

- artificial-intelligence-in-mobility-smart-moves-
required?utm_source=Statista+Global&utm_campaign=413c3bbf4c-
All_Camp_ReportStream_0008&utm_medium=email&utm_term=0_afecd21
- Desouza, K. C. (2001). Intelligent agents for competitive intelligence: Survey of applications. *Competitive Intelligence Review*, 12(4), 57–63. <https://doi.org/10.1002/cir.1032>
- Digibank (DBS). KAI Banking & DBS digibank. , Digibank 1–20 (2017).
- Dreyfus, H. L., & Dreyfus, S. E. (1991). Making a Mind Versus Modelling the Brain: Artificial Intelligence Back at the Branchpoint. In *Understanding the Artificial: On the Future Shape of Artificial Intelligence* (pp. 33–54). https://doi.org/10.1007/978-1-4471-1776-6_3
- Ecertic. (2018). Ecertic - Digital Solutions. Retrieved June 10, 2019, from <https://www.ecertic.com/>
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115–118. <https://doi.org/10.1038/nature21056>
- Fernández, A. (2019). *Inteligencia artificial en los servicios financieros*.
- Ferrucci, D., Levas, A., Bagchi, S., Gondek, D., & Mueller, E. T. (2013). Watson: Beyond Jeopardy! *Artificial Intelligence*, 199–200, 93–105. <https://doi.org/10.1016/J.ARTINT.2012.06.009>
- Fidora, A., & Sierra, C. (2011). *Ramon Llull: From the Ars Magna to Artificial Intelligence*.
- Friedman, N., Geiger, D., & Goldszmit, M. (1997). Bayesian Network Classifiers. *Machine Learning*, 29(2/3), 131–163. <https://doi.org/10.1023/a:1007465528199>
- G. P. Zhang. (2000). Neural networks for classification: a survey. *IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews*, 30(4), 451–462. Retrieved from <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.330.284&rep=rep1&type=pdf>
- Gardner, M. ., & Dorling, S. . (1998). Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences. *Atmospheric Environment*, 32(14–15), 2627–2636. [https://doi.org/10.1016/S1352-2310\(97\)00447-0](https://doi.org/10.1016/S1352-2310(97)00447-0)
- Gitman, L. J., & Joehnk, M. D. (2005). *Fundamentos de inversion*. Retrieved from https://books.google.es/books?hl=es&lr=&id=ITMNR9MUjuAC&oi=fnd&pg=PP17&dq=estrategias+de+inversion+en+bolsa&ots=A7HqBNO9R&sig=gwQVCwq2k8mgzLFicY_Y_7ZqIHn8#v=onepage&q=largo plazo&f=false
- Grewal, D., Roggeveen, A. L., & Nordfält, J. (2017). The Future of Retailing. *Journal of Retailing*, 93(1), 1–6. <https://doi.org/10.1016/J.JRETAI.2016.12.008>
- Häne, C., Heng, L., Lee, G. H., Fraundorfer, F., Furgale, P., Sattler, T., & Pollefeys, M. (2017). *3D Visual Perception for Self-Driving Cars using a Multi-Camera System: Calibration, Mapping, Localization, and Obstacle Detection*. Retrieved from <http://arxiv.org/abs/1708.09839>
- Hanmandlu, M., Murali Mohan, K. R., Chakraborty, S., Goyal, S., & Choudhury, D. R. (2003). Unconstrained handwritten character recognition based on fuzzy logic. *Pattern Recognition*, 36(3), 603–623. [https://doi.org/10.1016/S0031-3203\(02\)00069-9](https://doi.org/10.1016/S0031-3203(02)00069-9)
- Hassabis, D., & Silver, D. (2017). AlphaGo’s next move. *DeepMind*. Retrieved from <https://deepmind.com/blog/alphagos-next-move/>
- Hengstler, M., Enkel, E., & Duelli, S. (2016). Applied artificial intelligence and trust—The case of autonomous vehicles and medical assistance devices. *Technological Forecasting and Social Change*, 105, 105–120. <https://doi.org/10.1016/J.TECHFORE.2015.12.014>
- Home - Keras Documentation. (n.d.). Retrieved May 20, 2019, from <https://keras.io/>
- Hu, M. Y., & Tsoukalas, C. (2003). Explaining consumer choice through neural networks: The stacked generalization approach. *European Journal of Operational Research*, 146(3), 650–660. [https://doi.org/10.1016/S0377-2217\(02\)00368-5](https://doi.org/10.1016/S0377-2217(02)00368-5)
- IBM. (2018). Soluciones contra el fraude bancario. Retrieved May 29, 2019, from <https://www.ibm.com/analytics/es/es/business/fraud-protection/bank-fraud-solution/>
- Institute of International Finance. (2016). *DIGITIZING INTELLIGENCE: AI, ROBOTS AND*

- THE FUTURE OF FINANCE.* Retrieved from https://www.iif.com/portals/0/Files/private/ai_report_copy.pdf
- Jain, A. K., Murty, M. N., & Flynn, P. J. (1999). Data clustering: a review. *ACM Computing Surveys*, 31(3), 264–323. <https://doi.org/10.1145/331499.331504>
- Jiang, F., Jiang, Y., Zhi, H., Dong, Y., Li, H., Ma, S., ... Wang, Y. (2017). Artificial intelligence in healthcare: past, present and future. *Stroke and Vascular Neurology*, 2(4), 230–243. <https://doi.org/10.1136/svn-2017-000101>
- Juniper Research. (2019, April 10). *AI Spending by Retailers to Reach \$12 Billion by 2023*. Retrieved from <https://www.juniperresearch.com/press/press-releases/ai-spending-by-retailers-to-reach-12-billion>
- Kaggle. (2019). Santander Customer Transaction Prediction | Kaggle. Retrieved May 15, 2019, from <https://www.kaggle.com/c/santander-customer-transaction-prediction/rules>
- Karlik, B., & Olgac, A. V. (2011). Performance Analysis of Various Activation Functions in Generalized MLP Architectures of Neural Networks. *International Journal of Artificial Intelligence And Expert Systems*, 1(4), 111–122. Retrieved from <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.740.9413&rep=rep1&type=pdf>
- Karp, N. (2015). Biometría: el futuro de los pagos móviles. *BBVA Research*. Retrieved from https://www.bbvaesearch.com/wp-content/uploads/2015/07/150721_US_EW_Biometrics_esp.pdf
- Ketterer, J. A. (2017). *Digital Finance: New Times, New Challenges, New Opportunities*. Retrieved from <https://publications.iadb.org/en/digital-finance-new-times-new-challenges-new-opportunities>
- KPMG, & FUNCAS. (2017). *El nivel de madurez digital - Sector financiero en España*. Retrieved from <https://assets.kpmg/content/dam/kpmg/es/pdf/2017/04/nivel-madurez-digital-sector-financiero-espana-kpmg-funcas.pdf>
- Krebs, W., McCarley, J., Kozek, T., Miller, G., Sinai, M., & Werblin, F. (1999). An Evaluation of a Sensor Fusion System to Improve Drivers' Nighttime Detection of Road Hazards. *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, 43(23), 1333–1337. <https://doi.org/10.1177/154193129904302315>
- Luger, G. F. (2005). *Artificial intelligence-Structures and strategies for complex problem solving* (Six Editio; Pearson, Ed.).
- Makridakis, S. (2017). The forthcoming Artificial Intelligence (AI) revolution: Its impact on society and firms. *Futures*, 90, 46–60. <https://doi.org/10.1016/J.FUTURES.2017.03.006>
- Manzano, D., & Valer, F. J. (2013). *Guía del Sistema Financiero Español* (7ª).
- Mecanismo Único de Resolución - Consilium. (n.d.). Retrieved July 5, 2019, from <https://www.consilium.europa.eu/es/policies/banking-union/single-resolution-mechanism/>
- Medina-Merino, R. F., & Níque-Chacón, C. I. (2017). Bosques aleatorios como extensión de los árboles de clasificación con los programas R y Python. *Interfases*, 0(010), 165. <https://doi.org/10.26439/interfases2017.n10.1775>
- Minsky, M. (2007). *The emotion machine: Commonsense thinking, artificial intelligence, and the future of the human mind*. Retrieved from https://books.google.es/books?hl=es&lr=&id=OqbMnWDKIJ4C&oi=fnd&pg=PA1&dq=The+emotion+machine:+Commonsense+thinking,+artificial+intelligence,+and+the+future+of+the+human+mind&ots=uEGdSxHdPt&sig=Ri3Xswu939iyWB_A81jBwjAZASw
- Modha, D. S., Ananthanarayanan, R., Esser, S. K., Ndirango, A., Sherbondy, A. J., & Singh, R. (2011). Cognitive computing. *Communications of the ACM*, 54(8), 62–71. <https://doi.org/10.1145/1978542.1978559>
- Moor, J. (2006). The Dartmouth College Artificial Intelligence Conference: The Next Fifty Years. *AI Magazine*, 27(4), 87–87. <https://doi.org/10.1609/AIMAG.V27I4.1911>
- Moran, G. (2018). This artificial intelligence won't take your job, it will help you do it better. *Fast Company*. Retrieved from <https://www.fastcompany.com/90253977/this-artificial-intelligence-wont-take-your-job-it-will-help-you-do-it-better>

- NEXT, A. (2017). *Machine intelligence & augmented finance*. 561–568. Retrieved from <https://next.autonomous.com/augmented-finance-machine-intelligence>
- Noor, A. K. (2015). *Potential of Cognitive Computing and Cognitive Systems*. <https://doi.org/10.1515/eng-2015-0008>
- Pan, Y. (2016). Heading toward Artificial Intelligence 2.0. *Engineering*, 2(4), 409–413. <https://doi.org/10.1016/J.ENG.2016.04.018>
- Pérez, F. (2011). *Crecimiento y competitividad. Trayectoria y perspectivas de la economía española*. Retrieved from <https://www.bbva.com/es/scoring-programa-aprueba-credito/>
- Polacco, A., & Backes, K. (2018). The Amazon Go Concept: Implications, Applications, and Sustainability. In *Backes / Journal of Business and Management* (Vol. 24). [https://doi.org/10.6347/JBM.201803_24\(1\).0004](https://doi.org/10.6347/JBM.201803_24(1).0004)
- Rao, A. S., Verweij, G., & Cameron, E. (2017). Sizing the prize: What's the real value of AI for your business and how can you capitalise? *PwC*, 32. Retrieved from <https://www.pwc.com/gx/en/issues/analytics/assets/pwc-ai-analysis-sizing-the-prize-report.pdf>
- Reinsel, D., Gantz, J., & Rydning, J. (2018). The Digitization of the World - From Edge to Core. *IDC White Paper*, (November), US44413318. Retrieved from <https://www.seagate.com/files/www-content/our-story/trends/files/idc-seagate-data-age-whitepaper.pdf>
- Rodríguez, E. (2011). Las nuevas medidas de Basilea III en materia de capital. *Estabilidad Financiera*. Retrieved from <https://www.bde.es/f/webbde/Secciones/Publicaciones/InformesBoletinesRevistas/RevistaEstabilidadFinanciera/10/Nov/Fic/ref0119.pdf>
- Ruder, S. (2017). *An overview of gradient descent optimization algorithms* *. Retrieved from <http://caffe.berkeleyvision.org/tutorial/solver.html>
- San Frutos, A. L. (2016). *¿Cómo interpretar el balance de un banco?* Retrieved from <https://www.bbva.com/es/interpretar-balance-banco/>
- Scikit-learn: machine learning in Python — documentation. (n.d.). Retrieved June 3, 2019, from <https://scikit-learn.org/stable/>
- Srivastava, N., Hinton, G., Krizhevsky, A., & Salakhutdinov, R. (2014). Dropout: A Simple Way to Prevent Neural Networks from Overfitting. In *Journal of Machine Learning Research* (Vol. 15). Retrieved from <http://www.jmlr.org/papers/volume15/srivastava14a/srivastava14a.pdf>
- Strategy, E., & Machines, H. (2018). *The Age of Artificial Intelligence Towards a European Strategy for Human-Centric Machines EPSC Strategic Notes Build the environment*. (29). Retrieved from https://ec.europa.eu/epsc/sites/epsc/files/epsc_strategicnote_ai.pdf
- The Rise of AI. (2016). *Scientific American*, 314(6), 44–45. Retrieved from <http://www.nature.com/doifinder/10.1038/scientificamerican0616-44>
- Tkáč, M., & Verner, R. (2016, January 1). Artificial neural networks in business: Two decades of research. *Applied Soft Computing Journal*, Vol. 38, pp. 788–804. <https://doi.org/10.1016/j.asoc.2015.09.040>
- Trujillano Cabello, J., Badía Castelló, M., March Llanes, J., Rodríguez Pozo, Á., Serviá Goixart, L., & Sorribas Tello, A. (2005). Redes neuronales artificiales en Medicina Intensiva. Ejemplo de aplicación con las variables del MPM II. *Med Intensiva*, 29(1), 13–20. [https://doi.org/10.1016/S0210-5691\(05\)74198-X](https://doi.org/10.1016/S0210-5691(05)74198-X)
- Turing, A. M. (2009). Computing Machinery and Intelligence. In *Parsing the Turing Test* (pp. 23–65). https://doi.org/10.1007/978-1-4020-6710-5_3
- Tusell, F. (2011). *Análisis de Regresión. Introducción Teórica y Práctica basada en R*. Retrieved from <http://www.et.bs.ehu.es/~etptupaf/nuevo/ficheros/estad3/nreg1.pdf>
- Valera, M. (2018). *Los chatbots son las 'apps' del futuro*. Retrieved from <https://www.bbva.com/es/chatbots-apps-futuro/>
- Wei, J., Snider, J. M., Kim, J., Dolan, J. M., Rajkumar, R., & Litkouhi, B. (2013). Towards a



viable autonomous driving research platform. *2013 IEEE Intelligent Vehicles Symposium (IV)*, 763–770. <https://doi.org/10.1109/IVS.2013.6629559>

West, D., Dellana, S., & Qian, J. (2005). Neural network ensemble strategies for financial decision applications. *Computers and Operations Research*, 32(10), 2543–2559. <https://doi.org/10.1016/j.cor.2004.03.017>

Anexo I

Entidades bancarias	Miles de €										
	Total Activo 2018	Total Activo 2017	Patrimonio Neto 2018	Patrimonio Neto 2017	Total Pasivo 2018	Total Pasivo 2017	Resultado 2018	Resultado 2017	Nº Empleados	Nº Empleados	Nº oficinas 2018
1 Banco Santander, S.A.	608,375,879	492,414,388	68,766,830	70,566,787	539,609,050	421,847,601	3,301,178	3,006,310	31,036	21,860	13,217
2 Banco Bilbao Vizcaya	399,940,355	400,082,908	37,409,158	38,210,585	362,531,197	361,872,323	2,315,617	2,082,719	26,042	26,633	2,865
3 CaixaBank Banca Privada	306,566,878	308,398,557	20,855,903	21,981,146	285,710,975	286,417,411	1,162,560	1,428,131	29,383	29,470	5,103
4 Bankia, S.A.	206,345,732	215,043,906	12,534,410	12,792,345	193,811,322	202,251,561	833,668	468,752	15,486	17,217	2,298
5 Banco Sabadell, S.A.	178,987,816	177,642,750	10,288,087	11,061,146	168,699,729	166,581,604	539,867	519,170	15,319	15,374	2,457
6 Bankinter, S.A.	75,870,564	71,103,670	4,233,947	4,069,936	71,636,616	67,033,734	505,020	472,487	4,525	4,483	444
7 Kutxabank, S.A.	48,018,544	46,614,613	4,887,551	4,829,845	43,130,993	41,784,768	262,928	184,417	3,742	3,858	581
8 Abanca	50,974,302	50,914,966	4,229,121	3,925,876	46,745,181	46,989,090	369,867	291,958	4,675	4,428	630
9 Cajamar Caja Rural,	34,361,270	44,604,564	2,752,590	2,752,203	31,608,680	41,852,361	65,459	50,385	4,454	4,675	949
10 Liberbank, S.A.	39,987,736	25,186,170	2,688,255	2,573,533	37,299,481	22,612,637	94,937	-345,544	3,137	2,288	679

Tabla 19: Principales partidas de las 10 entidades bancarias españolas con mayor partida de activo. Fuente: Elaboración propia a partir de las Cuentas Anuales de cada entidad.

Anexo II

En este anexo se muestran las medidas estadísticas referentes a las 200 variables, tanto de la base de datos de entrenamiento como la de test, empleadas en el modelo de clasificación basado en la arquitectura de un perceptrón multicapa.

1. Histogramas




Figura 11: Histograma de las 200 variables de entrenamiento. Fuente: Elaboración propia




Figura 12: Histograma de las 200 variables de test. Fuente: Elaboración propia.

2. Diagrama *box-whiskers*

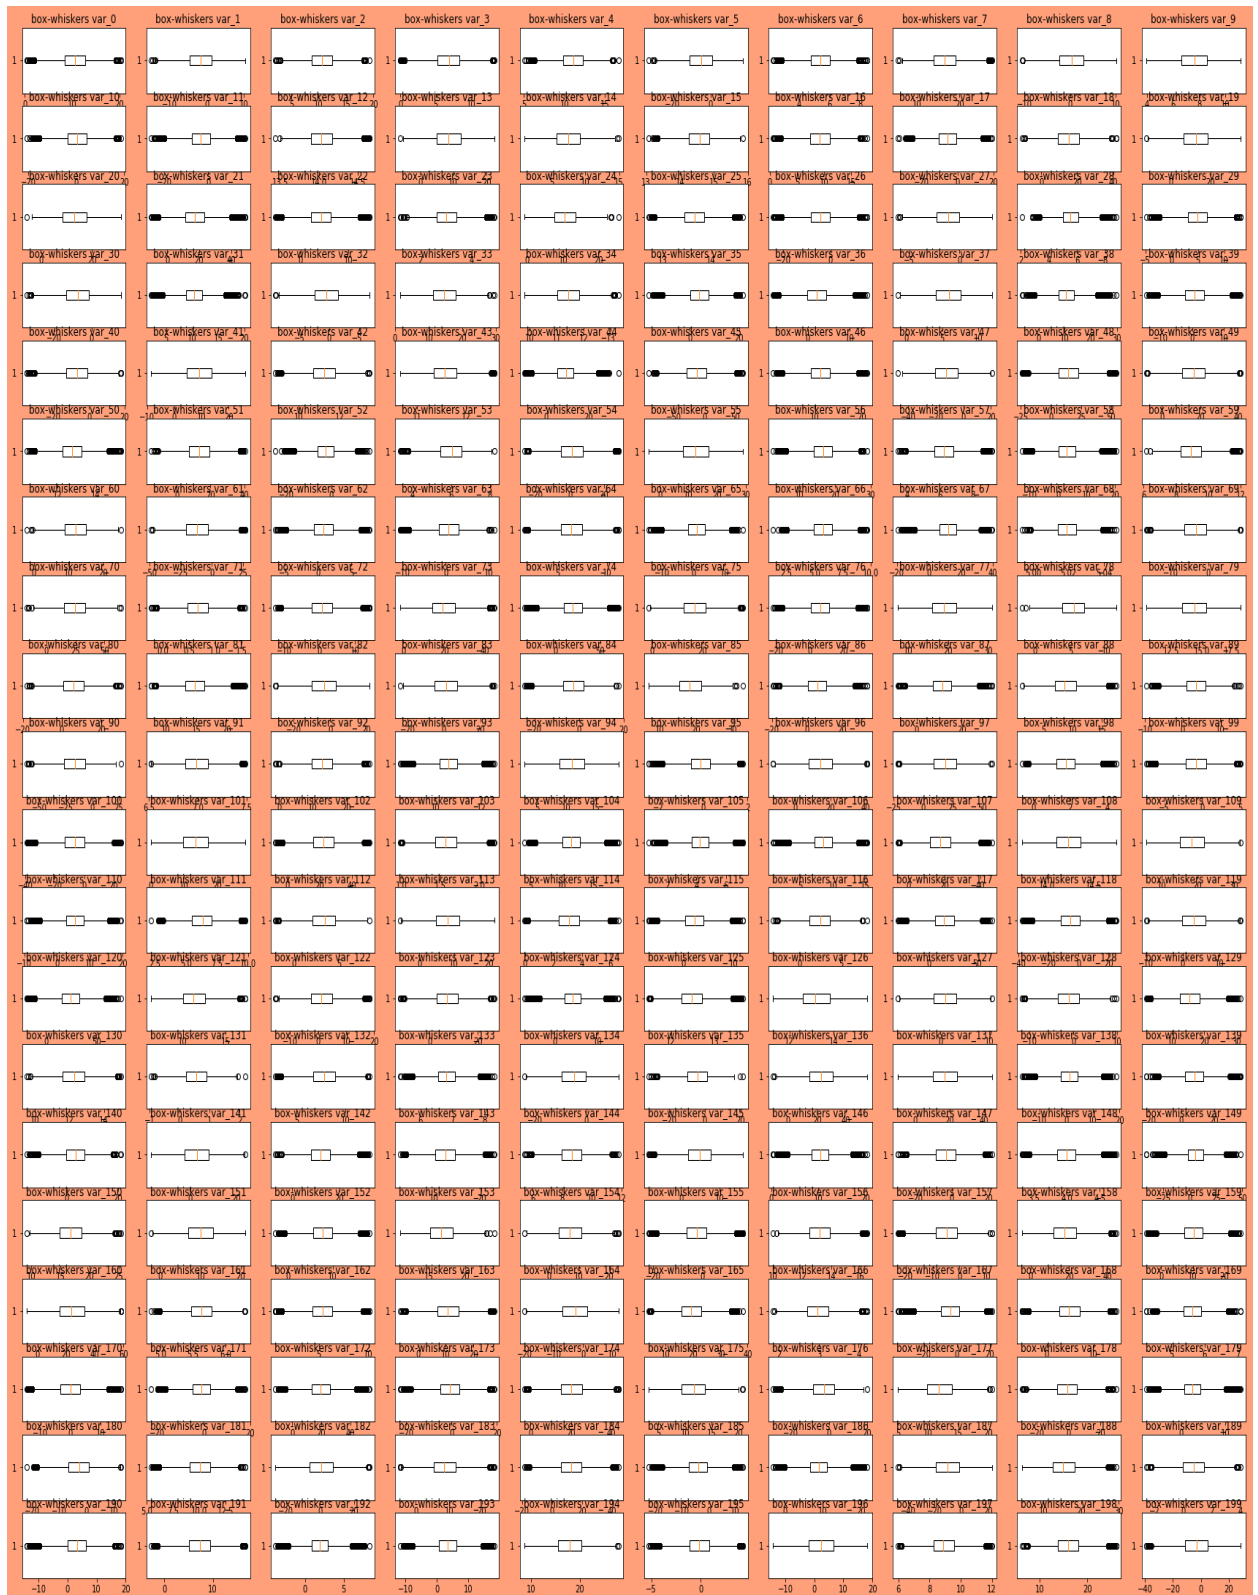


Figura 13: Diagrama *box-whiskers* de las 200 variables de entrenamiento. Fuente: Elaboración propia.




Figura 14: Diagrama box-whiskers de las 200 variables de test. Fuente: Elaboración propia.

3. Matriz de correlación

En la Figura 16 se muestra la matriz de correlación en forma de imagen, teniendo en cuenta las 200 variables que conforman la base de datos de entrenamiento. Así, se ha obtenido la matriz de correlación numérica y, tras ello, cada valor numérico se ha transformado a píxeles de color.

Para ello, se ha hecho uso de la escala de color *jet* en *Python*, cuya correspondencia en escala numérica se muestra a continuación:



Figura 15: Mapa de color 'jet'.

Como se observa en la imagen de la izquierda de la Figura 16, las variables no guardan correlación entre ellas ya que, exceptuando la diagonal principal de la matriz, el resto de variables guardan una relación lineal cercana a cero, que se corresponde al color azul.

Si realizamos un zoom a las 20 primeras variables, observamos cómo el coeficiente de correlación fluctúa manteniéndose siempre en valores cercanos a cero.

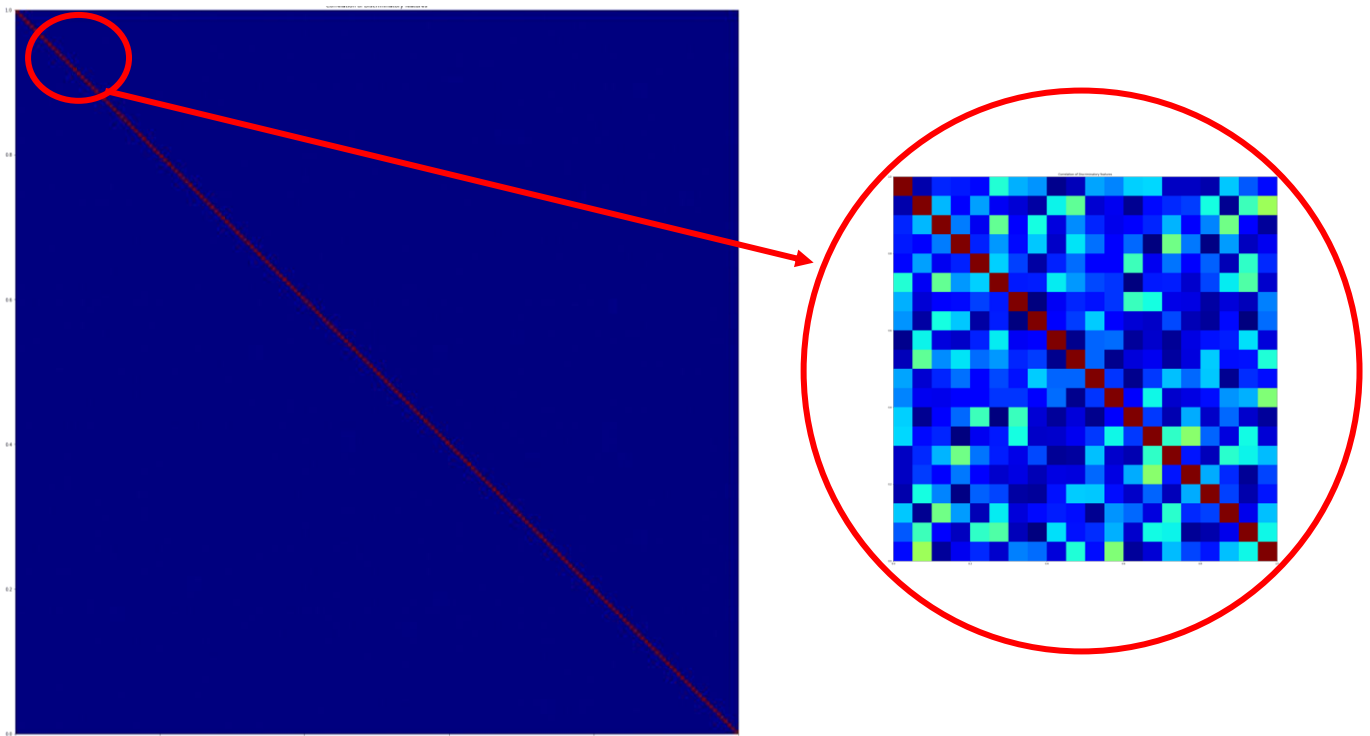


Figura 16: Matriz de correlación en escala de color 'jet'. Fuente: elaboración propia.

4. Matriz de multicolinealidad

El mismo procedimiento que el realizado para la obtención de la matriz de correlación ha sido desempeñado para el cálculo de la matriz de multicolinealidad. En este caso, la escala de color empleada ha sido *gist_rainbow*.



Figura 17: Mapa de color 'gist-rainbow'.

Al igual que en el caso anterior, se puede descartar la presencia de multicolinealidad existente en las variables, si bien determinados casos puntuales adquieren valores en torno a 0.5.

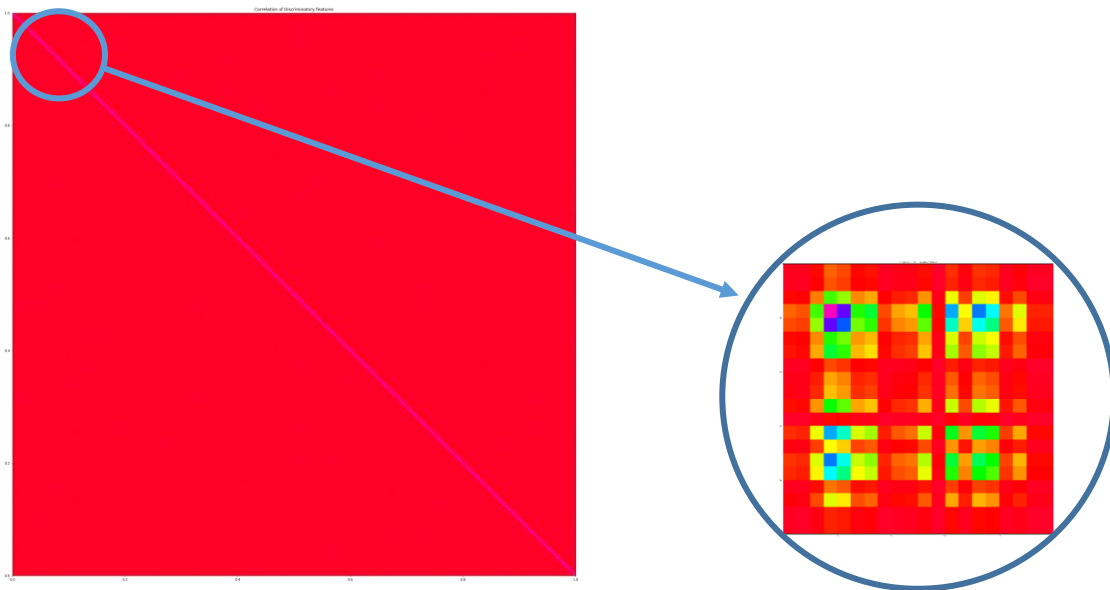


Figura 18: Matriz de multicolinealidad en escala de color 'gist-rainbow'. Fuente: elaboración propia