



Facultad de Ciencias Económicas y Empresariales

ANÁLISIS DE LA EVOLUCIÓN DEL SECTOR BANCARIO EN TIEMPOS DE COVID-19

Autor: Inés Blanch Marín

Director: Karin Martin Bujack

MADRID | Junio 2022

RESUMEN

El objetivo principal de este trabajo es analizar la variación de la rentabilidad del sector bancario español tras la crisis provocada por la pandemia del COVID-19. Para ello, se pretende establecer cuáles son los principales indicadores financieros que afectan a la rentabilidad y cuál ha sido su evolución durante la crisis. Empleando dicha información, se quiere elaborar un modelo predictivo sobre la rentabilidad bancaria.

Palabras clave: sector bancario español, crisis, COVID-19, rentabilidad bancaria, indicadores financieros, modelo predictivo, regresión lineal múltiple, red neuronal artificial

ABSTRACT

The main objective of this paper is to analyse the variation in the profitability of the Spanish banking sector after the crisis caused by the COVID-19 pandemic. To this end, the aim is to establish which are the main financial indicators affecting profitability and how they have evolved during the crisis. Using this information, a predictive model of bank profitability is to be developed.

Key words: Spanish banking sector, crisis, COVID-19, bank profitability, financial indicators, predictive model, multiple linear regression, artificial neural network

ÍNDICE

I.	INTRODUCCIÓN.....	6
II.	CONTEXTUALIZACIÓN.....	7
	1. REVISIÓN HISTÓRICA DEL IMPACTO DE OTRAS CRISIS EN EL SECTOR BANCARIO ESPAÑOL.....	7
	1.1. La crisis de 1977-1985.....	7
	1.2. La crisis de Banesto.....	8
	1.3. La crisis de 2007.....	8
	2. LA CRISIS DEL COVID-19.....	11
	2.1. Introducción a la crisis del COVID-19.....	11
	2.2. Medidas adoptadas por el Banco Central Europeo.....	11
	2.3. Medidas adoptadas a nivel nacional.....	12
III.	METODOLOGÍA.....	14
	1. INDICADORES FINANCIEROS.....	14
	1.1. Rentabilidad.....	14
	1.2. Calidad del crédito.....	16
	1.3. Solvencia.....	18
	1.4. Liquidez.....	19
	2. MODELIZACIÓN PREDICTIVA.....	20
	2.1. Concepto.....	21
	2.2. Tipos de variables.....	21
	2.3. Técnicas de modelización predictiva.....	22
	2.3.1. <i>Regresión lineal múltiple.....</i>	22
	2.3.2. <i>Redes neuronales artificiales.....</i>	25
	2.4. Evaluación de la capacidad predictiva del modelo.....	28

IV.	ANÁLISIS EMPÍRICO.....	29
1.	OBTENCIÓN DE DATOS.	29
2.	IMPACTO DE LA CRISIS DEL COVID-19 EN EL SECTOR BANCARIO ESPAÑOL.	29
3.	MODELIZACIÓN PREDICTIVA.....	36
3.1.	Tratamiento de valores atípicos.....	36
3.2.	Regresión lineal múltiple.....	37
3.2.1.	<i>Cumplimiento de los requisitos.</i>	37
3.2.2.	<i>Partición del conjunto de datos.</i>	39
3.2.3.	<i>Modelo de regresión lineal múltiple.</i>	39
3.2.4.	<i>Análisis de los residuos.</i>	41
3.2.5.	<i>Evaluación de la capacidad predictiva del modelo.</i>	43
3.3.	Red neuronal artificial.....	43
3.3.1.	<i>Número de neuronas por capa y de capas ocultas.....</i>	43
3.3.2.	<i>Modelo de red neuronal artificial.</i>	43
3.3.3.	<i>Evaluación de la capacidad predictiva del modelo.</i>	45
3.4.	Comparación de técnicas de modelización predictiva.....	46
V.	CONCLUSIONES.	47
VI.	BIBLIOGRAFÍA.....	48

ÍNDICE DE TABLAS

Tabla 1: variables del modelo predictivo.	29
Tabla 2: variación de la media y la desviación típica con el tratamiento de los valores atípicos.....	37
Tabla 3: matriz de correlaciones.....	39
Tabla 4: resultados del entrenamiento del modelo de regresión lineal múltiple.	40
Tabla 5: análisis de la homocedasticidad de los residuos.....	46

ÍNDICE DE FIGURAS

Figura 1: esquema de una neurona artificial.....	26
Figura 2: esquema de una red neuronal artificial.	27
Figura 3: evolución de la calidad del crédito.....	30
Figura 4. evolución de la calidad del crédito.....	31
Figura 5: evolución de la solvencia.	32
Figura 6: evolución de la liquidez.	33
Figura 7: evolución de la eficiencia operativa.....	34
Figura 8: evolución de la rentabilidad bancaria.....	35
Figura 9: representación de los valores atípicos.....	36
Figura 10: relación entre el ROA y las variables predictoras.....	38
Figura 11: análisis de la normalidad de los residuos.	41
Figura 12: análisis de la homocedasticidad de los residuos.	42
Figura 13: representación gráfica de la red neuronal artificial.....	44
Figura 14: representación de gráfica de la relevancia de las variables predictoras en el modelo de red neuronal artificial.....	45

I. INTRODUCCIÓN.

La importancia de las entidades bancarias y el papel fundamental que adoptan en la economía hacen necesario analizar el impacto que estas han sufrido por la pandemia provocada por el COVID-19. Este sector ha sido uno de los más afectados en anteriores crisis y las consecuencias fueron devastadoras para la economía. Por ello, es tan fundamental analizar qué efecto ha tenido esta nueva crisis en el sector bancario y, en particular, en este trabajo nos centraremos en medir la variación de la rentabilidad de las entidades bancarias españolas tras la crisis del COVID-19.

Para ello, en primer lugar, se va a analizar el comportamiento del sector ante las crisis previas y, en concreto, las medidas adoptadas para paliar sus efectos, pues tienen una relación directa con la situación del sector antes de la crisis del COVID-19. Asimismo, para enfocar e introducir la crisis del COVID-19, se pretende analizar las medidas adoptadas a nivel de la Unión Europea y nacional para amortiguar sus efectos en la economía y, en particular, el efecto que han tenido en el sector bancario y en su recuperación.

En segundo lugar, se seleccionarán los indicadores financieros mediante los cuales se pretende llevar a cabo el análisis. Estos indicadores deben ser explicativos del comportamiento del sector bancario durante esta crisis y deben tener alguna relación con la rentabilidad de las entidades bancarias españolas. Para medir su evolución se utilizarán ratios financieros.

A continuación, para cumplir el principal objetivo de este trabajo, que consiste en realizar un análisis de la rentabilidad de las entidades del sector bancario español tras la crisis del COVID-19, se pretende realizar un modelo predictivo sobre ella utilizando los indicadores financieros seleccionados previamente como variables. Para ello, será necesario determinar las técnicas de modelización predictiva a utilizar. Por último, de la modelización predictiva se extraerán resultados y conclusiones sobre la relación entre la rentabilidad y las distintas variables.

II. CONTEXTUALIZACIÓN.

1. REVISIÓN HISTÓRICA DEL IMPACTO DE OTRAS CRISIS EN EL SECTOR BANCARIO ESPAÑOL.

La crisis económica provocada por la pandemia del COVID-19 no es la primera, ni será la última, a la que las entidades bancarias deban hacer frente. Para contextualizar este trabajo y comprender la evolución del sistema bancario se va a hacer un breve resumen de las crisis más recientes, puesto que a medida que han ido teniendo lugar, se han introducido soluciones y medidas que han provocado el desarrollo del sector. Hay que tener en cuenta que cada una de ellas se ha producido en un contexto monetario diferente, con un distinto nivel de desarrollo de la regulación bancaria (Ontiveros Baeza y Valero López, 2013). El análisis que se va a realizar se va a centrar únicamente en las principales causas y soluciones otorgadas a las crisis más recientes que han afectado al sector bancario, en concreto, la crisis de 1977-1985, la crisis de Banesto y la crisis de 2007.

1.1. La crisis de 1977-1985.

La crisis de 1977-1985 fue una crisis de muy larga duración que afectó a un elevado número de entidades bancarias, en concreto, a 56 bancos de los 110 que operaban en España. De acuerdo con Sudrià (2014), una de sus causas fue el proceso de liberalización al que se vio sometido el sector a partir de la aprobación de la Ley de ordenación bancaria (1962). En ella se establecieron nuevas condiciones de competitividad que llevaron a las entidades a implementar políticas expansivas con el objetivo de captar clientes. Sin embargo, el contexto de inflación y altos tipos de interés complicó su rentabilización. Asimismo, la liberalización financiera permitió a las entidades bancarias adquirir mucha más libertad a la hora de establecer sus políticas comerciales. No obstante, esto no fue acompañado del establecimiento de mecanismos de supervisión que permitiesen llevar un control de la viabilidad y los efectos de las operaciones.

Para resolver la crisis bancaria de 1977-1985 se implementaron sobre la marcha distintos instrumentos. Por una parte, se constituyeron los fondos de garantía de depósito (en adelante, “FGD”). Su función era, precisamente, garantizar los depósitos constituidos en las entidades bancarias en caso de suspensión de pagos o quiebra de estas. Asimismo, pocos años después de su creación se ampliaron las posibilidades de actuación de los FGD de forma que contribuyesen a reforzar la solvencia y el funcionamiento de las entidades, como la posibilidad de someter a las entidades integradas en el FGD a una auditoría

contable (Campos et al., 2007). Por otra parte, de la iniciativa del Banco de España y el sector bancario se creó la Corporación Bancaria, S.A, que trataba de aportar capacidad de gestión para solucionar las crisis de las entidades (Ontiveros Baeza y Valero López, 2013).

1.2. La crisis de Banesto.

La crisis de Banesto afectó al cuarto mayor banco por volumen de activos, de depósitos y de créditos del sistema bancario español de entonces. En 1993, el banco anunció la decisión de no pagar dividendo a cuenta debido a altos desajustes en su balance. Según el Banco de España, dichos desajustes tuvieron su origen en una elevada expansión crediticia en los años anteriores, en la no afluencia de los créditos morosos y en la inversión en activos que suponían importantes gastos y una nula rentabilidad. Esta situación llevó al Banco de España a tomar la decisión de sustituir al consejo de administración el 28 de diciembre de 1993. Asimismo, la crisis a la que se vio sometida la entidad produjo la suspensión de la cotización de sus acciones por parte de la Comisión Nacional del Mercado de Valores desde la fecha en la que se produjo la sustitución del consejo de administración hasta el 1 de febrero de 1994 (Tortella y García Ruiz, 2013).

Tras la intervención, se propuso un plan de saneamiento del banco que fue aprobado por el Banco de España, el FGD y la junta de accionistas. El eje principal del mismo consistió en la recapitalización del banco mediante una ampliación de capital por 180.000 millones de pesetas que asumió el FGD. Posteriormente, dicha participación se subastó entre los grandes bancos y fue adquirida por el Banco Santander (González Méndez y González Rodríguez, 2000).

1.3. La crisis de 2007.

La crisis de 2007, aunque se hizo patente en ese año, se fue gestando a lo largo de los años previos, conocidos como los años de bonanza económica. Maudos (2012) identifica el origen de los problemas del sector bancario español en una combinación de distintos factores: la propensión al endeudamiento de las entidades bancarias debido a los reducidos costes de financiación, la dependencia de las empresas españolas de la financiación bancaria, el incremento del crédito al sector privado y la concentración del crédito concedido por los bancos en el sector inmobiliario.

En 2008 afloraron desequilibrios económicos en España, cuya consecuencia fueron la entrada del país en recesión y la destrucción masiva de empleo. En este año se promulgó el Plan Español para el Estímulo de la Economía y el Empleo en el que se articularon distintas medidas de apoyo al sistema financiero. Entre otras, se creó un Fondo de Adquisición de Activos Financieros para apoyar la oferta de crédito a empresas y particulares; y se incrementó hasta los 100.000 euros por depositante el importe máximo garantizado por los Fondos de Garantía de Depósitos (Calvo Bernardino y De Vidales Carrasco, 2014).

El hecho de que numerosas entidades financieras se enfrentasen a problemas de viabilidad llevó a la aprobación entre 2008 y 2012 de varias normas¹ con el objetivo de, además de incrementar la solvencia y fortaleza de las entidades, mantener la confianza en el sistema financiero nacional (Villasante, 2012).

La situación de la economía española a comienzos de 2012 provocó un incremento en la exigencia de rentabilidad de la deuda pública española. Esto quiere decir que los inversores exigían una compensación, un mayor rendimiento, por asumir el riesgo de un impago parcial o total de la deuda pública española. Por tanto, se tradujo en un aumento de la prima de riesgo española, que es una medida del coste de financiación de un estado con respecto a Alemania (García Vaquero y Casado, 2011).

En este contexto, se encargó un análisis externo de carácter agregado a las consultoras Roland Berger y Oliver Wyman para evaluar la resistencia del sector bancario español en el supuesto de que se produjese un mayor deterioro de la economía. El 21 de junio de 2012 se publicaron los resultados de las pruebas de resistencia que indicaron que los problemas se concentraban principalmente en las entidades participadas por el Fondo de Reestructuración Ordenada Bancaria (en adelante, “FROB”) o que habían solicitado importantes cantidades de ayudas públicas. Los resultados de este análisis llevaron al gobierno español a solicitar asistencia financiera externa, y en la Cumbre celebrada en Bruselas el 29 de junio de 2012 se aprobó por los países del Eurogrupo el rescate de la banca española (Calvo Bernardino y De Vidales Carrasco, 2014). Para ello, España y la

¹ Nos referimos al Real Decreto-ley 9/2009, de 26 de junio, sobre reestructuración bancaria y reforzamiento de los recursos propios de las entidades de crédito, al Real Decreto-Ley 11/2010, de 9 de julio, de órganos de gobierno y otros aspectos del régimen jurídico de las Cajas de Ahorros, al Real Decreto-Ley 2/2011, de 18 de febrero, para el reforzamiento del sistema financiero, al Real Decreto-Ley 2/2012, de 3 de febrero, de saneamiento del sector financiero y al Real Decreto-Ley 18/2012, de 11 de mayo, sobre saneamiento y venta de los activos inmobiliarios del sector financiero.

Comisión Europea ratificaron el 20 de julio de 2012 el Memorándum de Entendimiento sobre las condiciones de Política Sectorial Financiera, que incluía las medidas concretas para reforzar la estabilidad financiera en España. A través de este Memorándum se pretendían alcanzar los objetivos de aumentar la flexibilidad del sector a largo plazo, reestablecer la financiación basada en el mercado, reducir la dependencia de del apoyo del Banco Central para asegurar la liquidez de las entidades y perfeccionar los mecanismos de control de riesgos (Carbó Valverde y Rodríguez Fernández, 2013).

La primera medida que se tomó tras la firma del Memorándum fue realizar una segunda prueba de estrés más amplia que el anterior. Gracias a los resultados de este análisis se clasificaron las entidades financieras españolas en distintos grupos: grupo 0, integrado por aquellas entidades que no requirieron de ayuda externa; grupo 1, formado por las entidades que habían sido nacionalizadas por el FROB antes de la solicitud del rescate bancario; y grupo 2, compuesto por las que presentaban déficit de capital y que no pudieron afrontar el déficit sin ayuda estatal (Calvo Bernardino y De Vidales Carrasco, 2014).

Posteriormente se aprobó la Ley 9/2012, de 14 de noviembre, de reestructuración y resolución de entidades de crédito. Esta ley, entre otras medidas, reguló los procesos de actuación temprana, aplicable a las entidades en caso de incumplimiento de los requerimientos de solvencia, liquidez o control interno si se puede corregir con los propios medios de la entidad; reestructuración, cuando se requieran medios públicos para asegurar la viabilidad; y resolución, en el caso de que la entidad sea inviable. Asimismo, estableció la creación de las sociedades de gestión de activos para concentrar los activos que pueden dañar el balance de las entidades de crédito y trasladar los riesgos vinculados a los mismos (Fernández Torres, 2014).

Finalmente, una vez alcanzado el compromiso por parte del gobierno para implantar las reformas estructurales que corrigiesen los desequilibrios macroeconómicos y corregir el déficit público, se transfirió en diciembre de 2012 y en febrero de 2013 el primer y segundo tramo, respectivamente, del rescate bancario (Calvo Bernardino y De Vidales Carrasco, 2014).

Las devastadoras consecuencias de la crisis hicieron necesaria la adopción de medidas internacionales para reforzar el sistema bancario, entre las que destaca, por su gran importancia, el Acuerdo de Basilea III de 2011. El Comité de Supervisión Bancaria de

Basilea es un organismo que se encarga, a nivel mundial, de fortalecer la regulación y supervisión bancaria para mejorar la solvencia, liquidez y gestión de riesgos de los bancos (Poveda Anadón, 2001). Este Comité publicó en junio de 2011 el mencionado Acuerdo de Basilea III. En él se establecen requisitos mínimos relacionados con el capital y la liquidez que deben cumplir las entidades bancarias con actividad internacional con el objetivo de alcanzar un sistema financiero solvente y estable (Ibáñez Sandoval y Domingo Ortuño, 2013).

2. LA CRISIS DEL COVID-19.

2.1. Introducción a la crisis del COVID-19.

A diferencia de las crisis explicadas en la sección anterior, la crisis del COVID-19 no tuvo como origen una crisis económica ni financiera, sino una pandemia. Para limitar los contagios por el COVID-19 el gobierno de España, de igual forma que la mayoría de los gobiernos extranjeros, estableció distintas medidas restrictivas, como el confinamiento o la limitación de aforos, que fueron evolucionado a medida que lo hacía la pandemia. Dichas medidas, aunque esenciales para frenar la pandemia, tuvieron un impacto negativo en la economía. Esto se debe a que la actividad económica en sectores como el turístico, el hotelero o el de la construcción se paralizó o ralentizó, lo que supuso una disminución en la oferta. Asimismo, la pandemia provocó un detrimento de los ingresos de las familias y las empresas, por lo que la demanda también se vio mermada (Banco de España, 2020).

Sin embargo, a pesar de que el origen de la crisis no fuese económico ni financiero, el sector bancario ha desempeñado un papel fundamental en ella para canalizar el crédito a las empresas y hogares (Alberni et al., 2020). Debido a la regulación que se implementó para otorgar soluciones a crisis anteriores, las entidades bancarias españolas se encontraban al inicio de la pandemia en una posición de solvencia y estabilidad. Carbó Valverde et al. (2020) indican que la regulación y las reformas que habían tenido lugar en el sector financiero para su fortalecimiento tras las crisis previas resultaron cruciales durante la crisis provocada por el COVID-19.

2.2. Medidas adoptadas por el Banco Central Europeo.

Además de partir de una posición de solvencia, el sistema bancario vio potenciado su liquidez por las distintas medidas expansivas adoptadas por el Consejo de Gobierno del Banco Central Europeo. El objetivo de las medidas era garantizar la liquidez del sistema

financiero de la Unión Europea, potenciar el crédito bancario y evitar que las condiciones de financiación de las empresas y particulares se endureciesen. Dichas medidas se articularon en torno a programas de compra de activos y operaciones de financiación a plazo más largo (Bernoth et al., 2020).

Por una parte, se creó el programa de compras de emergencia frente a la pandemia (en adelante, “PEPP”, por sus siglas en inglés). A través de este, el Banco Central Europeo compró una serie de activos, entre los que se incluían bonos del estado o bonos corporativos, y, de esa manera, inyectó dinero y liquidez en la economía (Aguilar et al., 2020). Inicialmente, el PEPP fue dotado por 750 millones de euros, pero en junio se incrementó dicha cantidad en 600 millones de euros y en diciembre en otros 500 millones de euros (Castillo et al., 2021).

Por otra parte, en cuanto a las operaciones de financiación a plazo más largo, destaca la mejora de las operaciones de financiación a plazo más largo con objetivo específico III (en adelante, “TLTRO III”, por sus siglas en inglés) con la que se pretendía incentivar la concesión de crédito a aquellos sectores más afectados por la crisis (Aguilar et al., 2020). En los TLTRO, las condiciones de financiación que pueden obtener las entidades bancarias están vinculadas a los préstamos que estas conceden a las empresas y los hogares. Por tanto, a través de una mejora de las condiciones de financiación para hacerlas más ventajosas se pretendía asegurar la financiación del sector privado (Castillo et al., 2021). Asimismo, se introdujeron nuevas operaciones de financiación a plazo más largo de emergencia frente a la pandemia (“PELTRO”, por sus siglas en inglés) (Aguilar et al., 2020).

2.3. Medidas adoptadas a nivel nacional.

A nivel nacional también se establecieron medidas para paliar los efectos de la pandemia en la economía. En este sentido, se aprobaron distintas normas² para introducir medidas de apoyo a las empresas y hogares.

² Entre otros, el Real Decreto-ley 6/2020, de 10 de marzo, por el que se adoptan determinadas medidas urgentes en el ámbito económico y para la protección de la salud pública; el Real Decreto-ley 7/2020, de 12 de marzo, por el que se adoptan medidas urgentes para responder al impacto económico del COVID-19; el Real Decreto-ley 8/2020, de 17 de marzo, de medidas urgentes extraordinarias para hacer frente al impacto económico y social del COVID-19; el Real Decreto-ley 9/2020, de 27 de marzo, por el que se adoptan medidas complementarias, en el ámbito laboral, para paliar los efectos derivados del COVID-19; o el Real Decreto-ley 11/2020, de 31 de marzo, por el que se adoptan medidas urgentes complementarias en el ámbito social y económico para hacer frente al COVID-19.

Entre las medidas de apoyo a las empresas destacó la creación de líneas de avales públicos, gestionados a través del Instituto de Crédito Oficial, que garantizan su liquidez. Asimismo, otra medida esencial fue la modificación de la regulación de los Expedientes de Regulación Temporal de Empleo para incluir como causa de fuerza mayor para su aplicación la pérdida de actividad como consecuencia del COVID-19 (Calviño, 2020).

En cuanto a las medidas de apoyo a los hogares, destacaron las dirigidas hacia colectivos vulnerables, como el establecimiento de moratorias en la deuda hipotecaria de la vivienda habitual y el acceso garantizado a los suministros básicos. Asimismo, se ha apoyó a los autónomos estableciendo moratorias en la deuda hipotecaria de los bienes inmuebles afectos a su actividad y otorgando prestaciones extraordinarias por cese de actividad (Torres y Fernández, 2020).

Con estas medidas se pretendió potenciar la liquidez y solvencia de las empresas y hogares de tal forma que el impacto de la pandemia en la economía no fuese tan potente y pudiese recuperarse prontamente con el fin de las medidas restrictivas (Torres y Fernández, 2020).

III. METODOLOGÍA.

1. INDICADORES FINANCIEROS.

Los indicadores financieros permiten valorar la situación financiera de una entidad. En este apartado se van a detallar aquellos que pueden haberse visto afectados por la pandemia provocada por el COVID-19: la rentabilidad, la calidad del crédito, la solvencia, la liquidez y la eficiencia operativa.

Asimismo, se van a explicar los ratios financieros con los que se miden dichos indicadores. Un ratio financiero es una división entre dos cuentas de balance, de la cuenta de resultados o de ambos. Sirve para interpretar el estado financiero de una entidad bancaria con respecto a un indicador determinado (López Pascual y Sebastián González, 2005).

1.1. Rentabilidad.

Debido al gran impacto que se estima que la pandemia provocada por el COVID-19 tenga a medio y largo plazo en la rentabilidad bancaria, como se explicará a continuación, en este trabajo se pretende llevar a cabo un modelo predictivo sobre dicho indicador financiero. En este sentido, Sukmadewi (2020) señala que es muy común que la información financiera de una entidad en el pasado se utilice para hacer predicciones financieras. Para ello, es necesario determinar qué otros indicadores se han podido ver afectados por la pandemia y cuál es su efecto en la rentabilidad, puesto que se utilizarán como variables de dicho modelo.

Es necesario, por tanto, definir qué se entiende por rentabilidad bancaria. Buchory (2015) señala que esta indica el nivel de capacidad de la entidad bancaria para obtener beneficios a través de todas las fuentes existentes. En otras palabras, relaciona los beneficios que obtiene la entidad con los recursos necesarios para ello (Kaushik y López, 1996).

En un estudio llevado a cabo por McKinsey & Company en 2020, se estima que la crisis provocada por el COVID-19 afectará al sector bancario en dos etapas: en una primera, se pondrán de manifiesto importantes pérdidas crediticias; y, en una segunda, se reducirán los beneficios obtenidos por las entidades bancarias. La principal conclusión de dicho

estudio hace referencia a que el mayor desafío al que se va a enfrentar el sector bancario después de la crisis provocada por el COVID-19 va a ser un nivel de baja rentabilidad³.

Carbó Valverde et al. (2021) identifican la baja rentabilidad del sector bancario español como un problema estructural del sector. Indican que se debe, en gran medida, a las políticas expansivas extraordinarias que se implementaron tras la crisis financiera de 2007 y, especialmente, al mantenimiento de los tipos de interés bajos durante un periodo de tiempo muy prolongado.

Es necesario determinar de qué manera puede medirse la rentabilidad bancaria. A tal efecto, puede hacerse uso de distintos ratios. Entre ellos, los más utilizados son el ratio de rentabilidad financiera o rentabilidad sobre los recursos propios (en adelante, “ROE”, por sus siglas en inglés) y el ratio de rentabilidad económica (en adelante, “ROA”, por sus siglas en inglés) (López Pascual y Sebastián González, 2005).

De acuerdo con Rahman et al. (2015) y Dietrich y Wanzenried (2011), el ROA es el principal ratio utilizado en la literatura para predecir la rentabilidad bancaria. Esto se debe a que proporciona información sobre la eficiencia en la gestión de los activos del banco para generar beneficios. En otras palabras, el ROA es el ratio más importante para comparar la eficiencia y el rendimiento operativo de un banco, porque relaciona los beneficios que obtiene la entidad bancaria con los activos que esta ha invertido para ello. De esta forma, un ROA alto indica un alto nivel de beneficios obtenidos por la entidad en comparación con los activos de los que dispone y, por tanto, una alta rentabilidad (Amalia y Nugraha, 2021). El ROA se calcula de la siguiente manera:

$$ROA = \frac{\textit{Beneficio neto}}{\textit{Activos totales}}$$

Como se ha indicado, otro ratio que se utiliza habitualmente para medir la rentabilidad es el ROE. El ROE mide la capacidad que tiene una empresa para generar riqueza a favor de sus accionistas en relación con los recursos propios que emplea para financiarse (Ross et al., 2018). Se calcula de acuerdo con la siguiente fórmula:

$$ROE = \frac{\textit{Beneficio neto}}{\textit{Fondos propios}}$$

³ En este sentido, también Carbó Valverde et al. (2021), BBVA (2020) y Castelló Muñoz (2020).

El ROE y el ROA se relacionan mediante la fórmula de Dupont (Ross et al., 2018):

$$ROE = ROA \cdot \frac{Activos}{Patrimonio\ neto}$$

De acuerdo con dicha fórmula, dos bancos con el mismo ROA pueden tener un mayor o menor ROE en función de su nivel de apalancamiento. De esta forma, los bancos que tienen un elevado nivel de fondos propios muestran un menor ROE que los que se encuentran muy apalancados (Rahman et al., 2015). Dietrich y Wanzenried (2011) señalan que este es, precisamente, el principal motivo por el que el ROE no es el mejor ratio para medir la rentabilidad en el sector bancario. En este sentido, indican que los bancos que presentan un alto coeficiente de apalancamiento, es decir, que disponen de menores fondos propios, presentan un ROE alto. No obstante, estos autores señalan también que el ROE no tiene en cuenta el mayor riesgo asociado a un alto apalancamiento. Por ese motivo, en este estudio vamos a utilizar el ROA para medir la rentabilidad bancaria y, en el modelo predictivo que se efectuará en apartados posteriores, será la variable que se intentará predecir.

1.2. Calidad del crédito.

La calidad del crédito de una entidad bancaria hace referencia a la habilidad de los clientes del banco de cumplir sus obligaciones, es decir, de devolver el capital y el interés pactado (Sukmadewi, 2020). Debido a la pandemia provocada por el COVID-19, muchos negocios turísticos y de restauración se han visto obligados a cerrar o a limitar su aforo durante varios meses para evitar los contagios. Esas extraordinarias circunstancias, han provocado que los ingresos de los negocios se hayan reducido durante un largo periodo de tiempo. Esto puede conllevar, de acuerdo con un estudio llevado a cabo por Castelló Muñoz (2020), un incremento en la morosidad del crédito de este tipo de sectores⁴. En esta línea, BBVA (2020) prevé que el número de préstamos no cobrados aumente debido a la pandemia.

En este sentido, las entidades bancarias deben calificar como créditos dudosos (en adelante, “NPL”, por sus siglas en inglés) aquellos sobre los que existen motivos para creer que no van a poder ser devueltos por el cliente. El Fondo Monetario Internacional (2006) indica que los créditos deben ser clasificados como NPL cuando los pagos de principal e intereses se hayan retrasado 90 días o más. Por tanto, los NPL proporcionan

⁴ En este sentido, también KPMG (2020).

información sobre el riesgo que existe de un incumplimiento de las obligaciones por parte de los clientes de las entidades bancarias (Buchory, 2015).

Por ello, para medir la calidad del crédito, se va a emplear el ratio entre los NPL y los créditos totales (en adelante, “ratio de NPL”), que indica la eficiencia de un banco en recibir los pagos de principal e intereses por los créditos concedidos (Buchory, 2015). Se calcula de la siguiente manera:

$$\text{Ratio de NPL} = \frac{NPL}{\text{Créditos totales}} \cdot 100$$

Asimismo, una entidad bancaria tiene la obligación de provisionarse frente a las posibles pérdidas derivadas de los créditos que no va a recuperar. En este sentido, la Norma Internacional de Información Financiera n.º 9, que entró en vigor en 2018, establece que el cálculo de las provisiones se debe hacer en función de la pérdida esperada (Cohen y Edwards, 2017). En otras palabras, la función de estas provisiones consiste en cubrir las pérdidas crediticias en las que la entidad bancaria prevé incurrir (Duran y Lozano-Vivas, 2014).

Una baja calidad de crédito conlleva un impacto en la rentabilidad bancaria (Oino, 2021; Rahman y Khan, 2015). Esto se debe a que, si los clientes de las entidades bancarias no devuelven el principal prestado y los intereses devengados, la capacidad del banco para otorgar nuevos créditos se verá limitada. Por tanto, sus beneficios disminuirán y, con ello, la rentabilidad del banco (Buchory, 2015).

Por ello, para medir la calidad de los créditos de las entidades bancarias, en este estudio también se va a emplear el ratio entre las provisiones para pérdidas crediticias sobre los créditos totales (en adelante, “ratio de provisiones”). Un ratio elevado indica que la entidad espera incurrir en elevadas pérdidas crediticias y, por tanto, que su calidad del crédito no es buena (Dietrich y Wanzanried, 2011). Esta medida indica la capacidad que tiene el banco para absorber las pérdidas esperadas (Zhang et al., 2013). Se calcula conforme a la siguiente fórmula:

$$\text{Ratio de provisiones} = \frac{\text{Provisiones para pérdidas crediticias}}{\text{Créditos totales}} \cdot 100$$

1.3. Solvencia.

La solvencia bancaria se refiere a la capacidad que tiene una entidad bancaria para hacer frente a sus obligaciones con su patrimonio existente. Así, un banco es insolvente cuando el valor de mercado de su activo menos el valor de mercado de su pasivo exigible (deudas u obligaciones con terceros) es negativo o, de otro modo, cuando el valor de mercado de sus fondos propios es negativo (Sarina Salas, 1993). En este sentido, la volatilidad del mercado financiero y el empeoramiento de la calidad crediticia debido a la pandemia provocada por el COVID-19 pueden suponer un riesgo para la solvencia de las entidades bancarias (Ramos López, 2021).

Para fortalecer la solvencia de las entidades bancarias, el Acuerdo de Basilea III de 2011 estableció un capital mínimo que estas deben tener en función de cuánto riesgo tengan sus activos. Esto es, si los activos de un banco, como por ejemplo, los créditos, tienen mucho riesgo, el capital que debe mantener el banco será mayor que si su riesgo es bajo (Aiyar et al., 2015; Rahman y Khan, 2015). A dicho capital mínimo se le denomina capital regulatorio y, como se ha indicado, su objetivo es minimizar el riesgo de insolvencia. De esta manera, los bancos quedan obligados a mantener un nivel de capital suficiente que les permita cubrir pérdidas inesperadas (Duran y Lozano-Vivas, 2014).

De esta forma, las entidades bancarias que poseen una elevada capitalización pueden enfrentarse a crisis inesperadas, como la pandemia, con solvencia y sin que se su rentabilidad se vea afectada (Oino, 2021; Dietrich y Wanzanried, 2011; Carbó Valverde et al., 2021). Así lo probaron Nguyen y Nghiem en un estudio llevado a cabo en 2015, cuyos resultados indicaron que los bancos altamente capitalizados tendían a ser más eficientes y enfrentarse a menos riesgos de insolvencia, lo que se traducía en un efecto positivo para su rentabilidad.

En este estudio, para medir la solvencia de un banco se va a utilizar el ratio de adecuación de capital (en adelante, “CAR”, por sus siglas en inglés). Esta medida relaciona el capital del banco con el riesgo de sus activos e indica si el capital de la entidad es adecuado para soportar el riesgo que tienen o generan sus activos (Amalia y Nugraha, 2021). Se calcula de la siguiente manera:

$$CAR = \frac{\text{Capital Nivel 1} + \text{Capital Nivel 2}}{\text{Activos ponderados por riesgo}} \cdot 100$$

Para comprender la fórmula es necesario entender los conceptos de capital de nivel 1 y de nivel 2 y el de activos ponderados por riesgo, todos ellos regulados en el Acuerdo de Basilea III.

El capital de nivel 1 se compone, entre otros, por el capital social, los activos intangibles y las reservas de ingresos que hayan sido auditadas. Los instrumentos que se han mencionado permiten que el capital nivel 1 absorba pérdidas mientras la entidad continúa en funcionamiento, es decir, sin requerir que cese en sus operaciones (Ibáñez Sandoval y Domingo Ortuño, 2013). A diferencia del capital de nivel 1, el de nivel 2 está destinado a cubrir las pérdidas de la entidad en caso de liquidación. Entre otros instrumentos, se incluyen en el capital de nivel 2 la deuda a plazo subordinada o los instrumentos de capital híbrido (Rodríguez de Codes Elorriaga, 2010).

En cuanto al concepto de los activos ponderados por riesgo, consiste en multiplicar cada activo por un porcentaje mayor o menor en función del riesgo de este. De esta forma, si un activo tiene mucho riesgo el porcentaje será mayor, e implicará que la entidad deba reservar una mayor cantidad de capital. Por el contrario, cuanto más seguros sean los activos, menor será el porcentaje por el que se multipliquen y menos capital reservará el banco (Amalia y Nugraha, 2021).

1.4. Liquidez.

Gualandri et al. (2009) define la liquidez de una entidad bancaria como su capacidad para cumplir con sus obligaciones monetarias en el corto y largo plazo. Dichas obligaciones pueden derivar, por ejemplo, de depósitos en cuentas corrientes o líneas de crédito (López Pascual y Sebastián González, 2005). KPMG (2020) identifica un riesgo de liquidez en las entidades bancarias españolas provocado por la pandemia. El estudio indica que este riesgo puede manifestarse a través de la retirada de depósitos en los bancos debido a la disminución de ingresos que han sufrido los depositantes.

Una gran cantidad de los activos bancarios son préstamos y, para poder hacer uso de dichos activos, la entidad bancaria debe esperar a su vencimiento. Por tanto, estos activos no son líquidos (Sukmadewi, 2020). De esta forma, una de las principales medidas de liquidez de una entidad bancaria consiste en relacionar el importe de los créditos otorgados por la entidad y el del total de los depósitos que dispone (Iskandar, 2017). Este ratio (en adelante, “LTD”, por sus siglas en inglés) indica hasta qué punto los bancos han

empleado el dinero de los depósitos para proporcionar préstamos. Matemáticamente, se expresa de la siguiente manera:

$$LTD = \frac{\textit{Préstamos}}{\textit{Depósitos}}$$

Continuando con lo anterior, un LTD elevado indica que la entidad bancaria podría tener problemas de liquidez, puesto que la mayor parte de su activo se encuentra en estado ilíquido. En sentido contrario, un LTD bajo indica que, atendiendo a los depósitos de la entidad, esta podría conceder más préstamos y obtener una mayor rentabilidad.

1.5. Eficiencia operativa.

La eficiencia operativa consiste en que la entidad bancaria haga un uso adecuado y apropiado de los factores productivos (Sukmadewi, 2020). En este sentido, ha cobrado aun más importancia en la crisis del COVID-19, puesto que la gestión de costes es esencial para que las entidades bancarias sean rentables y alcancen los objetivos de beneficios marcados (Maudos, 2020; Buchory, 2015).

Para medir la eficiencia operativa puede hacerse uso de la relación entre los gastos y los ingresos operativos (Iskandar, 2017). Se representa mediante la siguiente fórmula matemática:

$$\textit{Ratio de eficiencia operativa} = \frac{\textit{Gastos operativos}}{\textit{Ingresos operativos}}$$

Un ratio de eficiencia operativa bajo indica que la gestión operativa no es eficiente o, en otras palabras, que los recursos que se están invirtiendo no se corresponden con un incremento de los ingresos. En sentido contrario, si los recursos se invierten eficientemente, los ingresos que generan aumentan y, por tanto, el ratio incrementa (Rahman y Khan, 2015).

2. MODELIZACIÓN PREDICTIVA.

Una vez determinados los indicadores financieros que se han podido ver afectados por la pandemia provocada por el COVID-19 y, puesto que se pretende llevar a cabo un modelo predictivo sobre la rentabilidad bancaria, se va a explicar de forma breve en qué consiste

la modelización predictiva y los conceptos necesarios para entender el modelo que se pretende efectuar.

2.1. Concepto.

Strickland (2015) define la modelización predictiva como aquella que consiste en hacer uso de una serie de técnicas para analizar hechos históricos o actuales con la finalidad de efectuar predicciones sobre el futuro. En otras palabras, consiste en la aplicación de distintas técnicas sobre datos históricos y actuales de diferentes variables para encontrar una relación entre ellas. Una vez encontrada dicha relación, se utiliza sobre datos nuevos para realizar predicciones sobre los valores futuros de una variable concreta.

Asimismo, Wessler (2018) indica que la importancia de la modelización predictiva reside en poder determinar lo que el entorno va a realizar en el futuro. Por lo tanto, tiene el potencial de proveer con una ventaja poderosa a todos aquellos que aprovechen las conclusiones obtenidas.

2.2. Tipos de variables.

Para llevar a cabo el proceso explicado en el párrafo anterior es necesario contar con dos tipos de variables. Dickey (2012) diferencia entre la variable objetivo o dependiente y las variables predictoras o independientes. La variable objetivo recibe tal nombre por tratarse, precisamente, de la variable cuyo valor se quiere predecir. También se la conoce como la variable dependiente porque su valor depende de los valores que tengan otras variables. Estas otras variables reciben el nombre de independientes, porque su valor no depende de los valores de otras variables. También se las conoce como variables predictoras puesto que son las que se utilizan para predecir el valor de la variable objetivo. Así pues, la modelización predictiva se utiliza para encontrar las relaciones entre las variables predictoras y la variable objetivo.

En este trabajo, como se ha adelantado en apartados anteriores, se pretende desarrollar un modelo predictivo de la rentabilidad del sector bancario español. En concreto, la variable objetivo o dependiente que se va a utilizar es el ROA de los bancos españoles, que es uno de los ratios que miden la rentabilidad. Las variables predictoras o independientes que se van a utilizar son los ratios que miden aquellos indicadores financieros de las que depende la rentabilidad bancaria y que ya se han explicado en los apartados anteriores.

2.3. Técnicas de modelización predictiva.

Hemos mencionado que para analizar los datos históricos o actuales de las variables predictoras y objetivo se emplean distintas técnicas. En esta sección vamos a explicar las dos técnicas que se van a utilizar en el modelo predictivo en apartados posteriores: la regresión lineal múltiple y las redes neuronales artificiales. La regresión lineal múltiple se ha escogido por su simplicidad y fácil comprensión. Sin embargo, como se explicará a continuación, para poder realizar una regresión lineal múltiple es necesario que se cumplan ciertos requisitos. Por este motivo, y porque se trata de una técnica que permite detectar patrones y tramas que son difíciles de apreciar mediante otras técnicas (Gestal Pose, 2009), se va a emplear también una red neuronal artificial.

2.3.1. Regresión lineal múltiple.

a. Concepto.

Las técnicas de regresión de modelización predictiva permiten obtener una relación matemática, una ecuación, entre las variables predictoras y la variable objetivo. Es decir, lo que se obtiene es la forma matemática en la que la variable dependiente y las independientes se relacionan (Dickey, 2012). En este sentido, para poder calcular el valor futuro de la variable objetivo bastaría con insertar los valores que se hayan medido de las variables predictoras en la ecuación matemática obtenida (Strickland, 2015).

En función del número de variables predictoras se distinguen dos tipos de regresión lineal: regresión lineal simple, si en el modelo se emplea una única variable predictora, o regresión lineal múltiple, si se utiliza más de una variable predictora (Dickey, 2012). En este trabajo vamos a centrarnos en la regresión lineal múltiple, puesto que para el modelo que se desarrollará en apartados posteriores se van a emplear varias variables predictoras.

Por ello, si se realizase una representación gráfica de los valores de las variables predictoras y los de la variable objetivo y de la ecuación que las relaciona se obtendría un hiperplano en un espacio multidimensional (Pardo Merino y Ruiz Díaz, 2005).

La ecuación matemática a la que nos referimos en el párrafo anterior, por tanto, adopta la siguiente forma:

$$Y = \alpha + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + e$$

Esta ecuación representa que la variable objetivo (Y) se interpreta como una combinación lineal de un conjunto de variables predictoras (X_n). En este sentido, los coeficientes que acompañan a las variables predictoras (β_n) indican la relevancia o el peso que tiene la variable independiente en la ecuación. Además, la ecuación incluye un componente aleatorio (e) que representa los residuos, es decir, todo lo que influye en la variable objetivo que no depende de las variables predictoras (Pardo Merino y Ruiz Díaz, 2005). Según López González y Ruiz Soler (2011), los residuos representan la discrepancia o la falta de ajuste entre el valor real de la variable objetivo y el que determina el modelo. En otras palabras, todo aquello que influye en el valor de la variable objetivo que el modelo no puede explicar.

b. Estimación de los coeficientes del modelo.

Hemos mencionado que los coeficientes o parámetros que acompañan a las variables predictoras (β_n) indican la relevancia o el peso de dicha variable en la ecuación, o dicho de otro modo, cuánto impacta en la variable objetivo un cambio en la variable predictora. Estos parámetros, que son desconocidos, deben ajustarse para que el peso de la variable independiente en el modelo sea lo más cercano posible a la realidad (Strickland, 2015). Este proceso se puede llevar a cabo de distintas maneras, puesto que hay distintas medidas de grado de ajuste que se pueden minimizar. En este estudio nos vamos a centrar en los mínimos cuadrados, que es la medida que vamos a utilizar en nuestro modelo. Esta medida se basa en la distancia que hay entre los datos reales y los datos representados en el hiperplano generado por la ecuación del modelo, y se eleva al cuadrado porque, de otro modo, al haber algunas distancias positivas y otras negativas se anularían las unas con las otras al sumarlas. De esta forma, la manera de ajustar los parámetros del modelo es minimizar dicha medida, es decir, minimizar la suma del cuadrado de las distancias entre los datos reales y los representados por el modelo (Pardo Merino y Ruiz Díaz, 2005).

Para comprobar si la estimación de los coeficientes (β_n) del modelo es fiable en este estudio se va a analizar el valor del estadístico t y el p-valor de cada uno de los coeficientes estimados. Ambas medidas evalúan la hipótesis nula de que el valor que debería adoptar el coeficiente al que se refieren es 0. Un valor de coeficiente 0 indica que la variable predictora a la que acompaña no debería incluirse en el modelo, puesto que no tiene ningún impacto en la variable objetivo. Un t-valor alto y un p-valor bajo indican que la hipótesis nula (que el coeficiente al que se refieren es 0) puede ser rechazada y que, por

tanto, el valor del coeficiente no es 0. De esta manera, estas medidas permiten conocer si las variables predictoras que se están utilizando en el modelo contribuyen a explicar el valor de la variable objetiva (Strickland, 2015).

c. Bondad de ajuste del modelo.

Una vez se ha diseñado el modelo y se han estimado sus coeficientes, es necesario analizar alguna medida que indique su bondad de ajuste, es decir, medir si el modelo se ajusta bien a un conjunto de datos. La medida que se va a utilizar en este estudio es el coeficiente de determinación (R^2). Esta medida se basa en analizar la variabilidad de la variable objetivo y determinar qué parte de ella está explicada por el modelo (por las variables predictoras y sus coeficientes) y qué parte se debe a los residuos.

Por tanto, la variabilidad o varianza de la variable objetivo, el rango de valores que puede tomar, puede descomponerse en dos componentes: la variabilidad que explica el modelo de regresión, que viene proporcionada por las variables predictoras y sus coeficientes; y la variabilidad que no explica el modelo, que viene proporcionada por los residuos. Esta segunda se atribuye a factores externos que no están relacionados con las variables predictoras (Rojo Abuín, 2007).

La variabilidad de la variable objetivo se denomina variabilidad total y, si elevamos su valor al cuadrado, se obtiene lo que se denomina la suma del cuadrado total (SCT). Igualmente, la variabilidad de los residuos se conoce como variabilidad restante que, si se eleva al cuadrado, se obtiene lo que se conoce como la suma del cuadrado de los residuos (SCR) (Montero Granados, 2016).

Atendiendo a todo lo anterior, el coeficiente de determinación se calcula de la siguiente manera:

$$R^2 = 1 - \frac{SCR}{SCT}; 0 \leq R^2 \leq 1$$

El coeficiente de determinación toma valores comprendidos entre el 0 y el 1. El valor 0 indica que el ajuste del modelo a los datos es pésimo, puesto que la variabilidad total del modelo se corresponde exclusivamente con la variabilidad restante de los residuos. En otras palabras, la variabilidad de la variable objetivo no está explicada por el modelo. De otro modo, el valor 1 indica que el ajuste del modelo a los datos es óptimo, puesto que la varianza residual es nula. Esto implica que la variabilidad total de la variable objetivo

queda explicada por el modelo al corresponderse con la variabilidad determinada por las variables predictoras y sus coeficientes (Uriel Jiménez, 2013).

d. Requisitos para la aplicación de la regresión lineal múltiple.

El cumplimiento de determinados requisitos es necesario para efectuar una regresión lineal múltiple.

El primero de ellos, y quizás el más evidente, es que entre las variables predictoras y la variable objetivo haya una relación lineal. El incumplimiento de este requisito puede deberse a dos factores principales. El primero de ellos es que la relación entre las variables predictoras y la variable objetivo es no lineal y, por tanto, la técnica de regresión lineal múltiple para averiguar la relación entre ellas no es la adecuada (Shalev-Shwartz y Ben-David, 2014). El segundo factor es que haya un error de especificación en el modelo, esto es, que no se haya incluido en el modelo alguna variable predictora relevante o que se hayan incluido variables irrelevantes (Montero Granados, 2016).

El segundo requisito consiste en que no haya multicolinealidad entre las variables predictoras. Dickey (2012) define la multicolinealidad como una superposición o una fuerte correlación entre las variables predictoras. Dado que se espera que las variables predictoras tengan un impacto en la variable objetivo, de forma que se pueda predecir el valor de esta última a partir del valor de las primeras, es normal y esperable que haya correlaciones entre ellas. Sin embargo, si dos variables predictoras están fuertemente correlacionadas o, en otras palabras, una de ellas puede expresarse como una combinación lineal de la otra, es probable que al estimar sus coeficientes se obtengan resultados erróneos. Por ejemplo, es posible que una de ellas aparezca como no significativa en el modelo o con signo contrario. Para solucionar este problema es necesario eliminar una de las variables fuertemente correlacionadas del modelo (Montero Granados, 2016).

Por último, el tercer requisito consiste en que los residuos se distribuyan de forma normal y con homocedasticidad, es decir, que su varianza sea constante (Shalev-Shwartz y Ben-David, 2014).

2.3.2. *Redes neuronales artificiales.*

a. Concepto.

Strickland (2015) define las redes neuronales artificiales como un grupo interconectado de nodos que se asimila a las redes neuronales en un cerebro. Las redes neuronales

biológicas están formadas por varias unidades de aparatos computacionales, las neuronas, que están conectadas entre ellas formando una red de comunicación compleja a través de la cual se llevan a cabo distintas funciones. McCulloch y Pitts (1990) se basaron en dicha estructura para diseñar la primera red neuronal artificial.

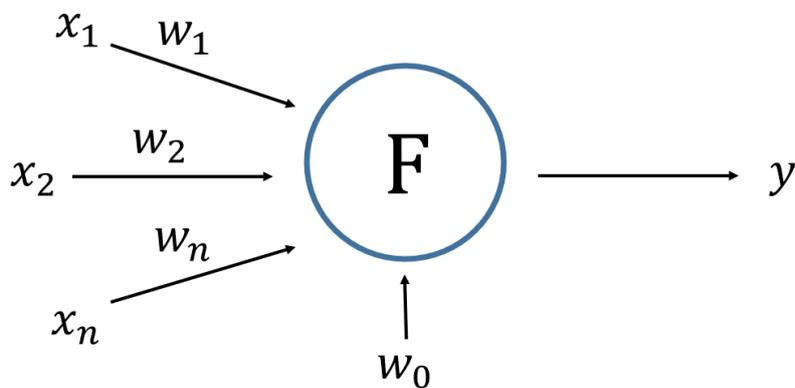
b. La neurona artificial.

McCulloch y Pitts (1990) diseñaron una neurona artificial como un dispositivo con un número n de entradas y una única salida. De esta forma, la neurona recibe información a través de sus n entradas. Esta información se representa en el vector \bar{x} , que contiene los datos de entrada (x_1, x_2, \dots, x_n) . Estos datos de entrada llegan a la neurona ponderados por un peso, que representa la intensidad de las conexiones sinápticas entre las neuronas. El conjunto de los pesos (w_1, w_2, \dots, w_n) se representa en el vector \bar{w} . La neurona, como unidad mínima computacional de la red, aplica una función de activación (F) a la suma ponderada de los datos de entrada \bar{x} por su peso \bar{w} y un sesgo (w_0). De esta manera, se obtiene un escalar (y), que es el dato de salida que se va a transmitir a la siguiente neurona. La función de activación evalúa la información de entrada y si supera un determinado umbral de activación, se transmite el dato de salida a otras neuronas. En caso contrario, se reajustan los pesos que ponderan los datos de entrada y se vuelve a iniciar el proceso.

Matemáticamente, la actividad de la neurona se representa mediante la siguiente ecuación:

$$y = F\left(\sum_{n=1}^n w_n x_n + w_0\right)$$

Figura 1: esquema de una neurona artificial.



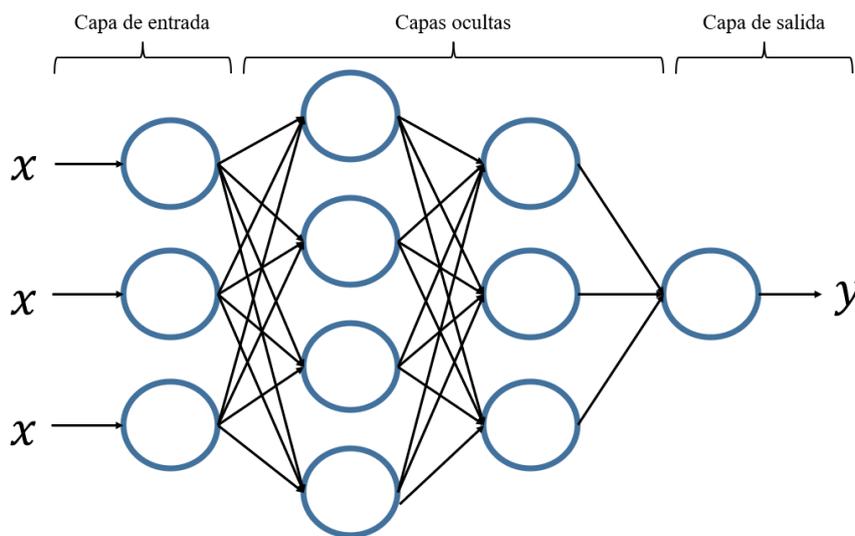
Fuente: elaboración propia.

c. La red neuronal artificial.

Consecuentemente, una red neuronal se compone de varias neuronas donde las salidas de unas están conectadas con las entradas de otras. De esta forma, cada neurona aplica la función de activación a la suma ponderada de la información que recibe por sus entradas y transmite el resultado a la siguiente neurona (Salas, 2004).

En la red, las neuronas se disponen en diferentes capas o niveles. La primera capa se denomina capa de entrada; la última, capa de salida; y todas las intermedias, capas ocultas. Si se trata de una red neuronal prealimentada, las neuronas transmiten la información a las neuronas de la siguiente capa. En las redes neuronales recurrentes la información puede transmitirse también a neuronas que se encuentren en capas anteriores (Shalev-Shwartz y Ben-David, 2014). Para llevar a cabo el modelo predictivo en apartados posteriores de este trabajo se va a utilizar una red neuronal prealimentada.

Figura 2: esquema de una red neuronal artificial.



Fuente: elaboración propia.

d. Ajuste de los pesos de la red neuronal artificial.

Para poder realizar predicciones, la red neuronal artificial ajusta los pesos de la información que reciben las neuronas de tal forma que se minimice una función de error determinada (Gestal Pose, 2009). Esto se lleva a cabo comparando la salida que proporciona la red neuronal artificial con la salida deseada y minimizando el error de desempeño de la red (Gómez Rojas et al., 2004). A la hora de ajustar los pesos, es importante que la red neuronal artificial mantenga una capacidad de generalización alta,

lo que permitirá que, ante la entrada de datos nuevos, la red proporcione resultados coherentes (Gestal Pose, 2009). En otras palabras, es importante que la red no se sobreajuste a los datos con los que ha sido entrenada para que funcione correctamente con datos nuevos.

2.4. Evaluación de la capacidad predictiva del modelo.

El objetivo con el que se crean los modelos es predecir el valor de la variable objetivo. Como se ha explicado, se van a utilizar dos técnicas distintas para la construcción del modelo y se van a obtener resultados distintos para la variable objetivo en función de cuál de ellas se aplique. Es necesario, por tanto, evaluar la capacidad predictiva del modelo en función de la técnica utilizada.

En este trabajo vamos a utilizar como medidor de la capacidad predictiva del modelo la medida de la raíz del error cuadrático medio. Esta medida mide el error entre el valor de la variable objetivo real y el valor que se obtiene del modelo aplicando la siguiente fórmula:

$$RMSE = \sqrt{\frac{\sum(Y_{real} - Y_{predicha})^2}{n}}$$

Al comparar el valor de la variable objetivo predicho con el modelo ($Y_{predicha}$) con su valor real (Y_{real}) puede determinarse cuál de las dos técnicas, la regresión lineal múltiple o la red neuronal, se adapta mejor al conjunto de datos.

IV. ANÁLISIS EMPÍRICO.

1. OBTENCIÓN DE DATOS.

En la sección anterior se han explicado las variables que se van a emplear para realizar la modelización predictiva sobre la rentabilidad bancaria. Asimismo, como se ha detallado, se han escogido estos indicadores financieros por su impacto, de acuerdo con la literatura revisada, en la variable objetivo. A modo de recapitulación, incluimos la tabla 1.

Tabla 1: variables del modelo predictivo.

INDICADOR FINANCIERO	RATIO	TIPO DE VARIABLE
Rentabilidad	ROA	Variable objetivo
Calidad del crédito	Ratio de NPL	Variable predictora
Calidad del crédito	Ratio de provisiones	Variable predictora
Solvencia	CAR	Variable predictora
Liquidez	LTD	Variable predictora
Eficiencia operativa	Ratio de eficiencia operativa	Variable predictora

Fuente: elaboración propia.

Para analizar la evolución de cada indicador financiero durante la crisis del COVID-19 se van a utilizar datos de los ratios de las principales entidades bancarias españolas desde 2012 hasta 2021. En concreto, las entidades bancarias de las que se van a obtener los datos son: Banco Santander, BBVA, CaixaBank, Sabadell, Bankinter, Bankia y Kutxabank. Dichos datos se van a adquirir desde 2012 hasta 2021⁵ con la base de datos de FactSet. Asimismo, con estos mismos datos se efectuará en apartados posteriores un modelo predictivo sobre la rentabilidad bancaria.

2. IMPACTO DE LA CRISIS DEL COVID-19 EN EL SECTOR BANCARIO ESPAÑOL.

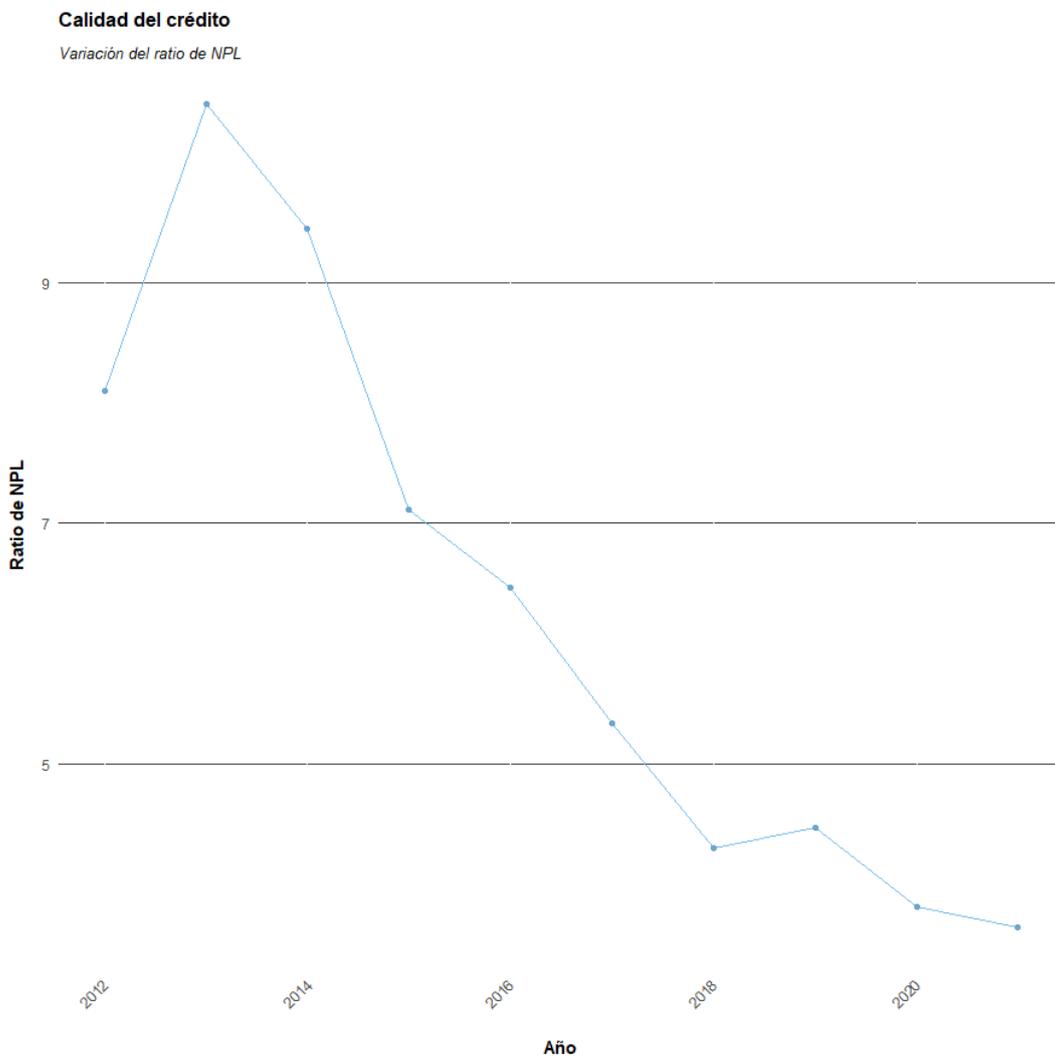
En esta sección se pretende analizar el impacto de la pandemia provocada por el COVID-19 en cada uno de los indicadores detallados en la sección anterior: rentabilidad bancaria, calidad del crédito, solvencia, liquidez y eficiencia operativa. Para ello, se va a analizar la evolución de los ratios financieros que miden dichos indicadores.

⁵ Dado que Bankia se fusionó con CaixaBank en 2021, los datos de esta entidad empleados son de 2012 a 2020.

El primer indicador financiero que se va a analizar es la evolución de la calidad del crédito, medido por el ratio de NPL y el ratio de provisiones.

En la figura 3 se representa en el eje de ordenadas la media del ratio de NPL de las principales entidades bancarias españolas, calculado como el porcentaje de los NPLs respecto a los créditos totales, y en el eje de abscisas los años desde 2012 hasta 2021. Como se observa, el ratio disminuyó durante 2020 y 2021, lo que puede deberse a que las importantes medidas concedidas para el apoyo de las empresas y los hogares les permitieron cumplir sus obligaciones para con las entidades bancarias y no incurrir en mora.

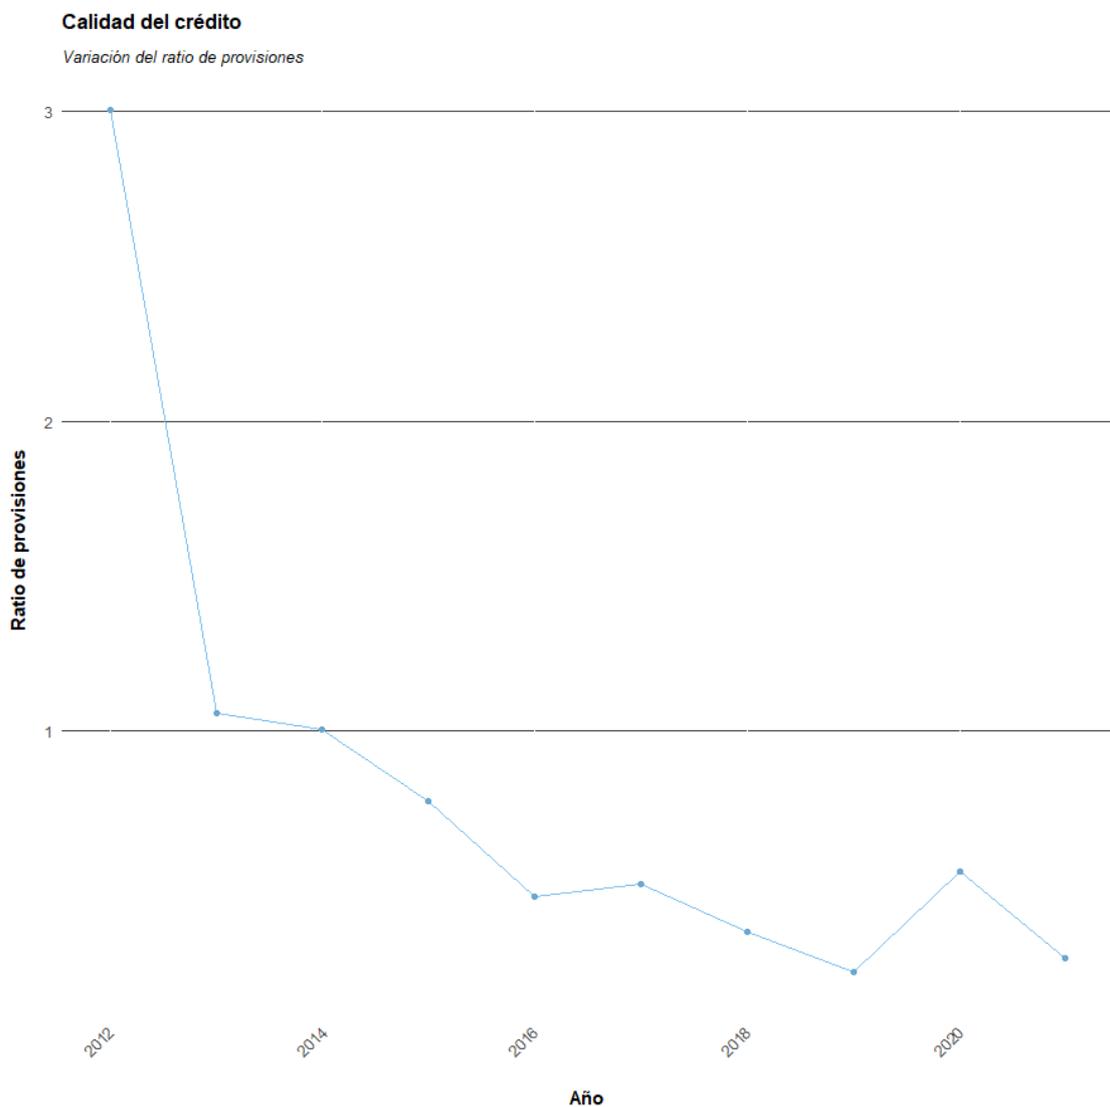
Figura 3: evolución de la calidad del crédito.



Fuente: elaboración propia.

En la figura 4 se representa en el eje de ordenadas la media del ratio de provisiones de las principales entidades bancarias españolas, calculado como el porcentaje de las provisiones respecto a las pérdidas crediticias y créditos totales, y en el eje de abscisas los años desde 2012 hasta 2021. Como se aprecia, el ratio aumentó sustancialmente durante 2020. Esto implica que en dicho año se dotó una mayor cantidad de provisiones para cubrir las pérdidas esperadas por las entidades bancarias debido a la pandemia del COVID-19.

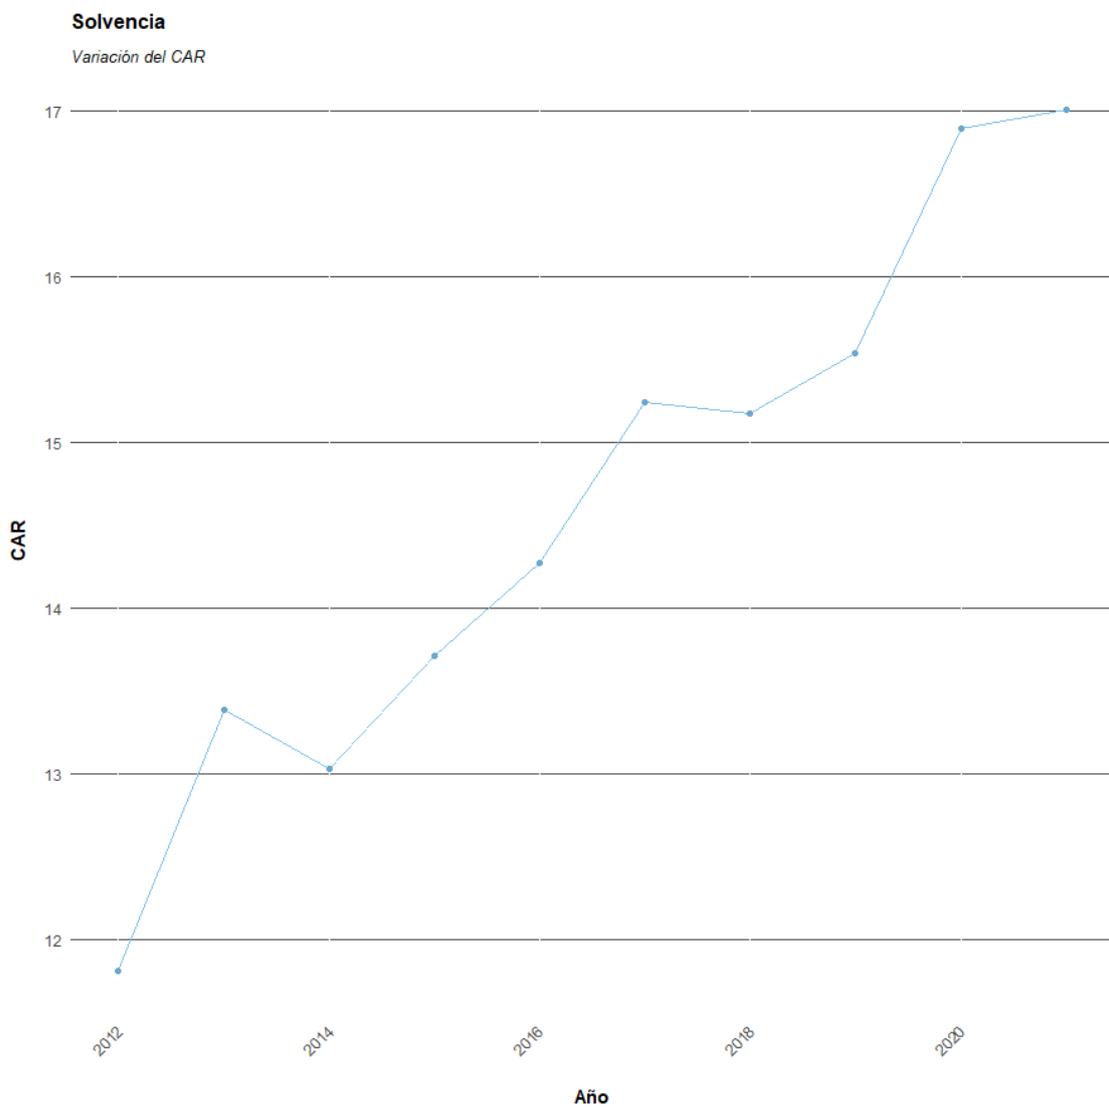
Figura 4. evolución de la calidad del crédito.



Fuente: elaboración propia.

El siguiente indicador que se va a analizar es la solvencia bancaria, medida a través del CAR. En la figura 5 se representa en el eje de ordenadas la media del CAR de las principales entidades bancarias españolas, calculado como el porcentaje de la suma del capital de nivel 1 y de nivel 2 respecto a los activos ponderados por riesgo, y en el eje de abscisas los años desde 2012 hasta 2021. Como se aprecia, el ratio, que ya era elevado antes de la crisis del COVID-19, aumentó significativamente en 2020 y se mantuvo elevado 2021. Esto se debe, según el Banco de España (2021), a la mejora del capital nivel 1 que se encuentra en el numerador de dicho ratio.

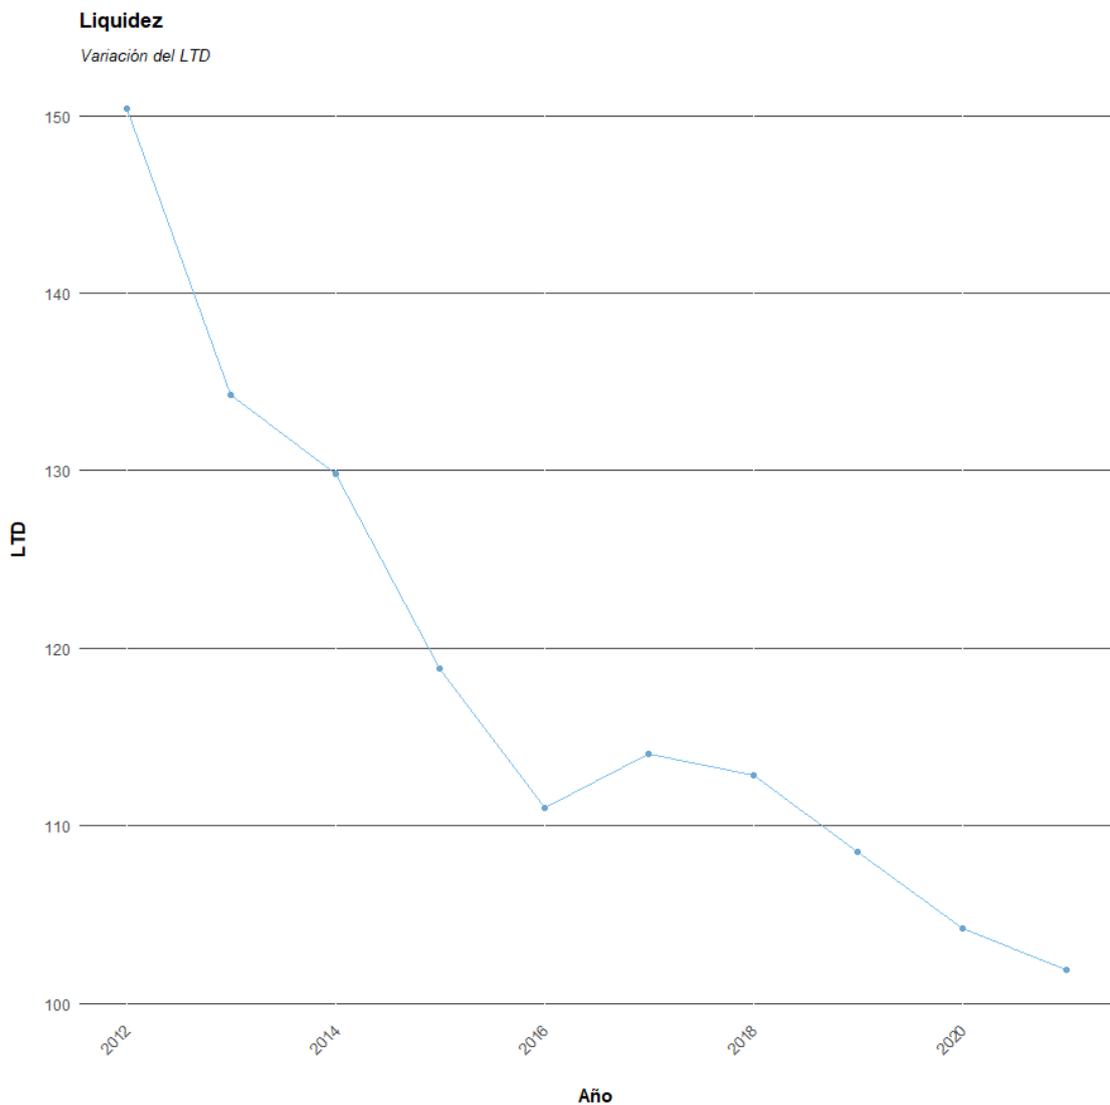
Figura 5: evolución de la solvencia.



Fuente: elaboración propia.

A continuación, se analiza el indicador de liquidez, medido por el LTD. En la figura 6 se representa en el eje de ordenadas la media del LTD de las principales entidades bancarias españolas, calculado como el porcentaje de los préstamos respecto a los depósitos, y en el eje de abscisas los años desde 2012 hasta 2021. Puede observarse que durante los años 2020 y 2021 disminuyó, aunque hay que desatacar que la tendencia en los años previos ya era negativa. Como se ha explicado anteriormente, una de las causas de la crisis de 2008 fue la elevada concesión de créditos al sector privado, por lo que tiene sentido que el LTD siga una tendencia negativa si, como consecuencia de dicha crisis, se está prestando de una manera más moderada.

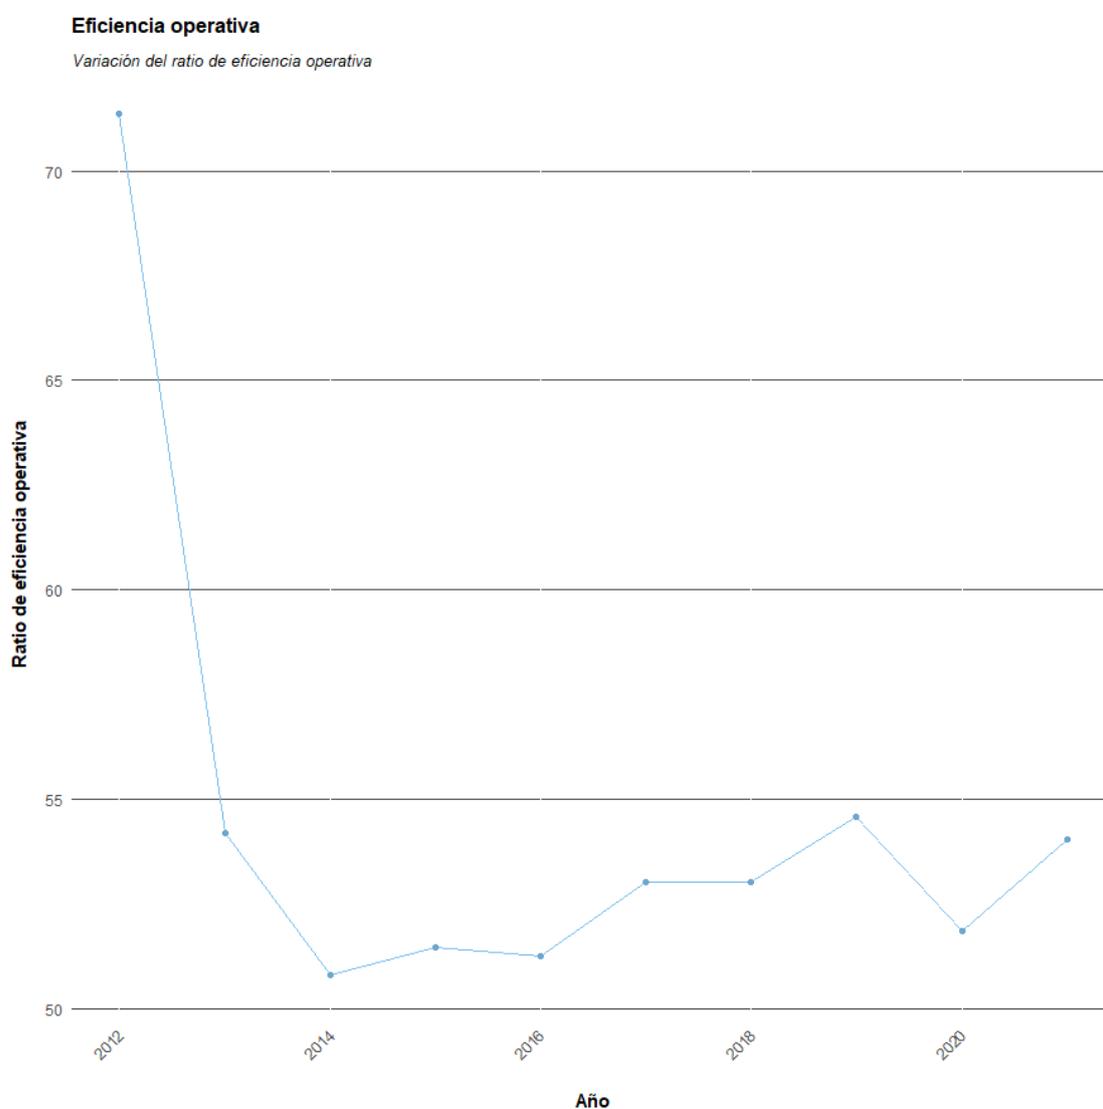
Figura 6: evolución de la liquidez.



Fuente: elaboración propia.

Seguidamente, se analiza el indicador de eficiencia operativa, medido por el ratio de eficiencia operativa. En la figura 7 se representa en el eje de ordenadas la media del ratio de eficiencia operativa, calculado como el porcentaje de los gastos operativos respecto a los ingresos operativos, y en el eje de abscisas los años desde 2012 hasta 2021. Puede observarse que dicho ratio disminuyó en 2020, lo que se debe, probablemente, a que por el COVID-19 las entidades bancarias ahorraron muchos costes al cerrar las oficinas debido al teletrabajo. En 2021, con la vuelta al trabajo presencial, el ratio volvió a sus niveles de antes de la pandemia.

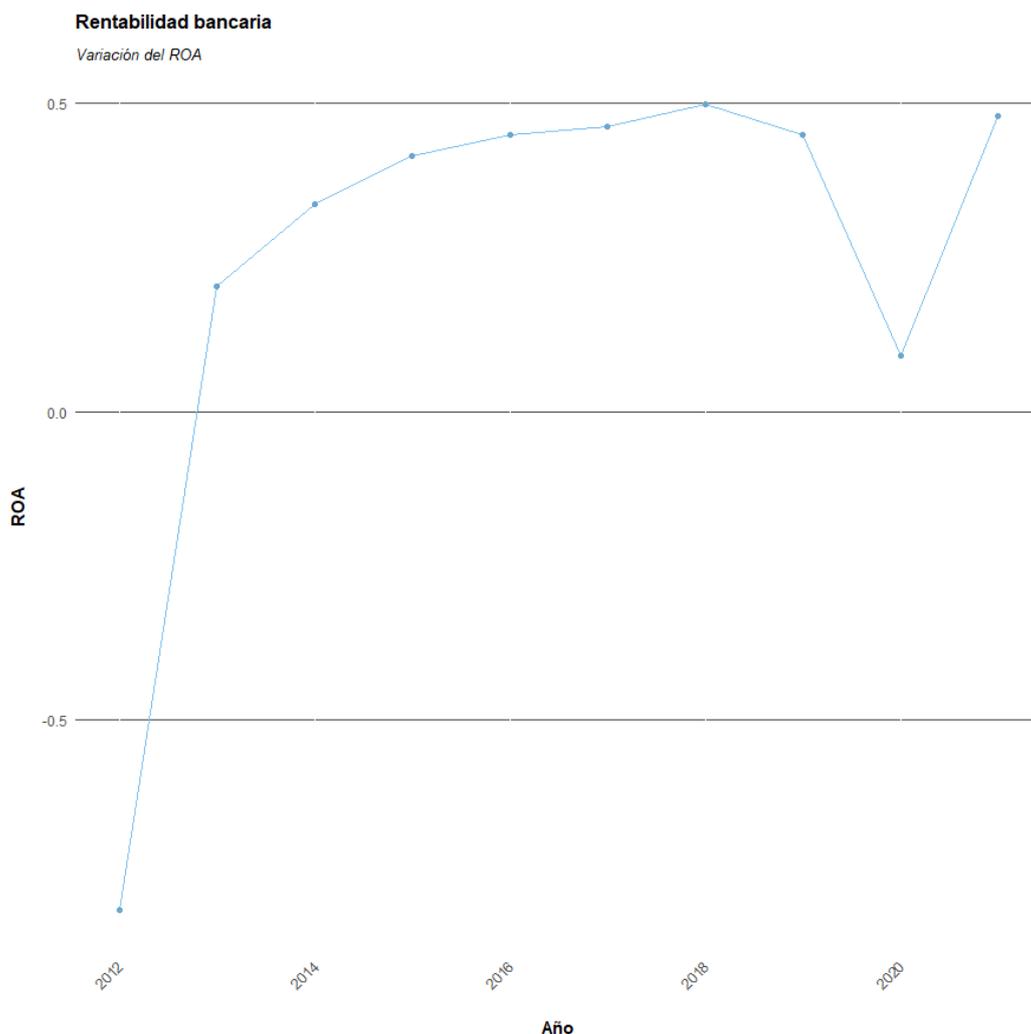
Figura 7: evolución de la eficiencia operativa.



Fuente: elaboración propia.

Los indicadores analizados tienen un impacto en la rentabilidad bancaria, que se mide a través del ROA. En la figura 8 se representa en el eje de ordenadas la media del ROA, calculado como el porcentaje del beneficio neto respecto a los activos totales, y en el eje de abscisas los años desde 2012 hasta 2021. Se puede observar que el ROA disminuyó bastante en 2020 por la crisis del COVID-19. Del análisis efectuado en los párrafos anteriores puede concluirse que dicha disminución se debe, al menos en parte, al aumento de la dotación de provisiones. No obstante, cabe mencionar que en 2021 el ROA alcanzó el valor que tenía antes de la crisis. A pesar de ello, y dado que la literatura revisada en la sección anterior mostraba una preocupación por la evolución futura de la rentabilidad bancaria, se ha seleccionado dicho ratio como la variable objetivo del modelo predictivo que se va a llevar a cabo en el siguiente apartado de este trabajo.

Figura 8: evolución de la rentabilidad bancaria.



Fuente: elaboración propia.

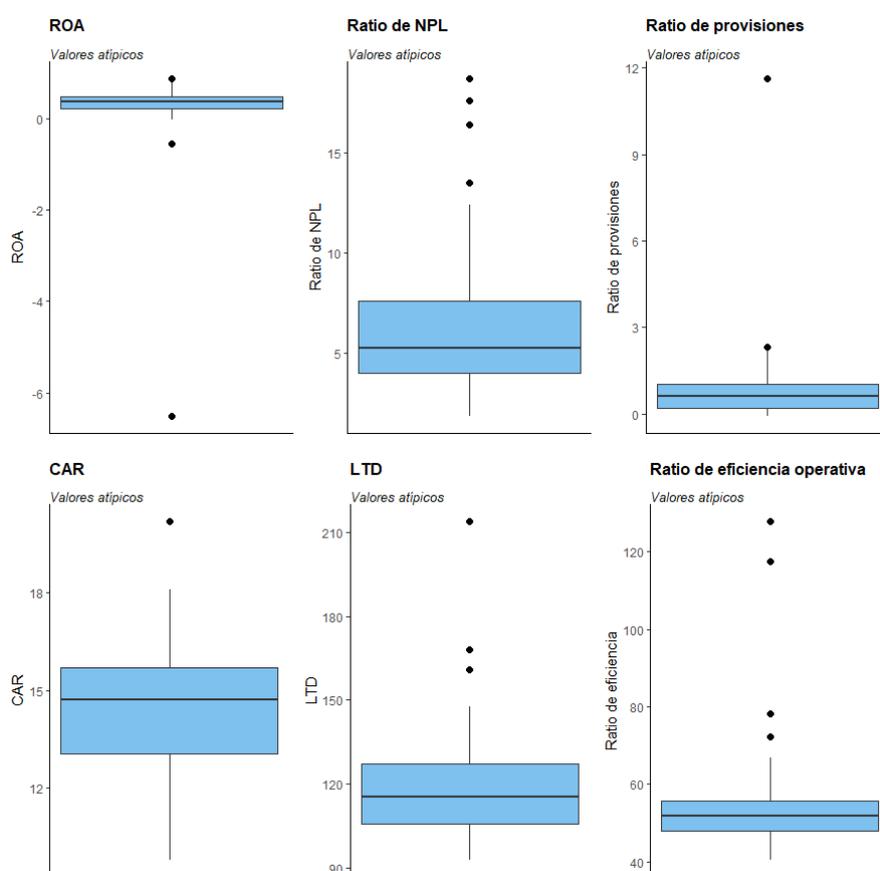
3. MODELIZACIÓN PREDICTIVA.

3.1. Tratamiento de valores atípicos.

Al inicio de una modelización predictiva es imprescindible llevar a cabo un tratamiento de los valores atípicos de las variables del conjunto de datos que se va a emplear. Se conocen como valores atípicos aquellos que tienen valores muy distintos a las otras observaciones del conjunto de datos. En concreto, se consideran valores atípicos los que se encuentran a una distancia mayor de 1,5 veces del rango intercuartílico del primer o tercer cuartil (Aggarwal, 2017).

A continuación, se incluye la figura 9 con la representación gráfica de los valores atípicos que presenta el conjunto de datos empleado. En el eje de ordenadas de cada gráfico se representan los ratios de las entidades bancarias españolas. Se observa que todas las variables presentan valores atípicos, señalados con puntos, que deben ser tratados para evitar la distorsión del análisis.

Figura 9: representación de los valores atípicos.



Fuente: elaboración propia.

En este trabajo, el tratamiento de los valores atípicos se va a realizar imputando su valor por los valores de los percentiles 5% y 95%, en función de si son valores atípicamente bajos o altos.

La principal consecuencia del tratamiento de los valores atípicos consiste en que la desviación típica de los datos de cada variable disminuye, al reducirse el rango en el que se distribuyen los valores. Asimismo, la media de los datos de cada variable también puede verse afectada. A continuación, en la tabla 2, se comparan ambos estadísticos, la media y la desviación típica, antes y después de realizar la imputación de los valores atípicos.

Tabla 2: variación de la media y la desviación típica con el tratamiento de los valores atípicos.

	ROA	Ratio de NPL	Ratio de provisiones	CAR	LTD	Ratio de eficiencia operativa
Media inicial	0,25	6,36	0,83	14,57	118,84	54,57
Media final	0,35	6,16	0,69	14,54	117,28	52,89
Diferencia	40,00%	-3,25%	-16,87%	-0,20%	-1,31%	-3,08%
DT inicial	0,86	3,56	1,45	1,92	19,13	13,64
DT final	0,19	2,99	0,60	1,83	14,16	6,89
Diferencia	-77,91%	-16,01%	-58,62%	-4,69%	-25,89%	-49,49%

Fuente: elaboración propia.

De la información que contiene esta tabla se desprende que la variable que más valores atípicos tenía era el ROA, seguida del ratio de provisiones y el ratio de eficiencia operativa.

3.2. Regresión lineal múltiple.

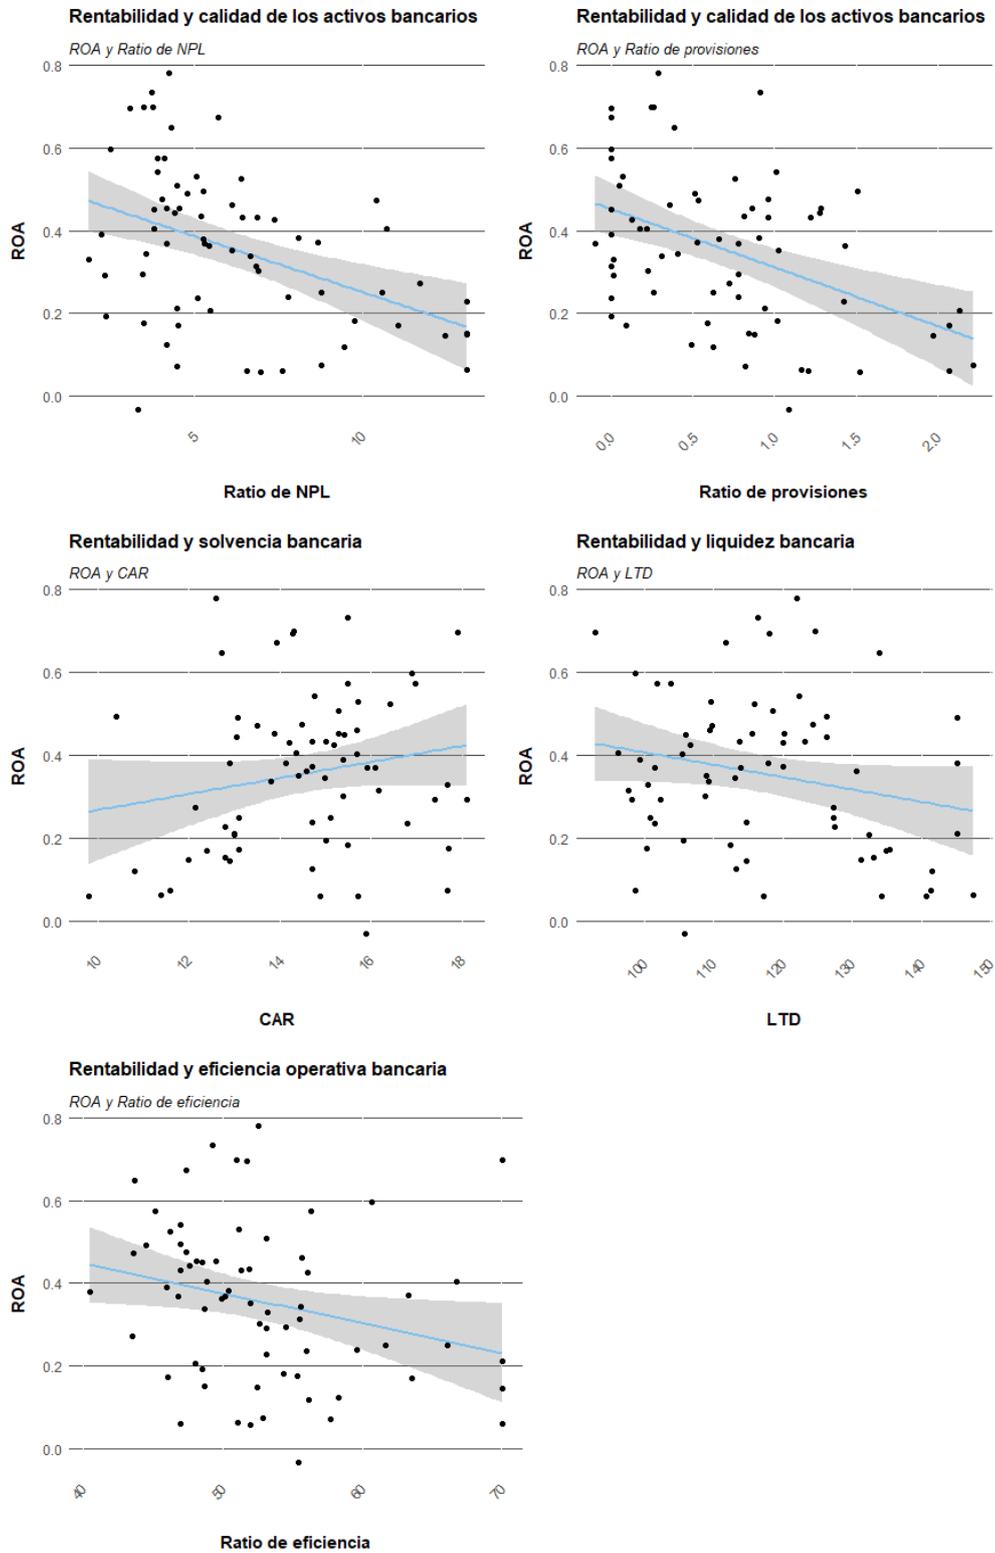
3.2.1. Cumplimiento de los requisitos.

En apartados anteriores se ha explicado que para realizar una regresión lineal múltiple es necesario el cumplimiento de determinados requisitos.

El primero de ellos consiste en que la relación entre la variable objetivo y las variables predictoras sea lineal. Para comprobarlo se incluye la figura 10 con la representación gráfica de cada variable predictora en el eje de abscisas y el ROA en el eje de ordenadas

y, como se observa, no existe una clara tendencia lineal. Por ello, es de esperar que los resultados del modelo de regresión lineal múltiple no sean óptimos.

Figura 10: relación entre el ROA y las variables predictoras.



Fuente: elaboración propia.

El segundo requisito consiste en que no haya multicolinealidad entre las variables predictoras. Para determinar el cumplimiento de dicho requisito en el conjunto de datos utilizado, se ha calculado la matriz de correlaciones entre dichas variables y se incluye en la tabla 3. Como se puede observar, las variables predictoras más correlacionadas son LTD y CAR con un índice de correlación de -0,786; seguidas de LTD y el ratio de provisiones, con un índice de 0,575. Así, puede concluirse que no existe multicolinealidad entre las variables predictoras.

Tabla 3: matriz de correlaciones.

	Ratio de NPL	Ratio de provisiones	CAR	LTD	Ratio de eficiencia operativa
Ratio de NPL	1,000	0,313	-0,551	0,380	0,127
Ratio de provisiones	0,313	1,000	-0,499	0,575	0,000
CAR	-0,551	-0,499	1,000	-0,786	0,054
LTD	0,380	0,575	-0,786	1,000	-0,136
Ratio de eficiencia operativa	0,127	0,000	0,054	-0,136	1,000

Fuente: elaboración propia.

El último requisito hace referencia a la distribución de los residuos que se obtienen con la aplicación del modelo de regresión lineal múltiple. Por ello, se analizará en apartados posteriores.

3.2.2. Partición del conjunto de datos.

Para poder entrenar el modelo y efectuar predicciones es necesario realizar una partición de los datos. De esta forma, el 70% de ellos se destina al conjunto de entrenamiento y el 30% de ellos al conjunto de prueba. El modelo se va a entrenar con el conjunto de entrenamiento y las predicciones se van a llevar a cabo con el conjunto de prueba. Así, se puede medir el rendimiento del modelo con datos con los que no ha sido entrenado.

3.2.3. Modelo de regresión lineal múltiple.

El modelo de regresión lineal múltiple se crea introduciendo el ROA como variable objetivo y el resto como variables predictoras:

```
rlm <- lm (data = train, formula = ROA ~ `Ratio de eficiencia`
          + `Ratio de provisiones` + `Ratio de NPL` + CAR + LTD)
```

Los resultados que se obtienen de entrenar el modelo se resumen en la tabla 4.

Tabla 4: resultados del entrenamiento del modelo de regresión lineal múltiple.

	Coefficientes estimados (β_n)	T-valor	P-valor	Relevancia
α	2,05	3,76	0,00	***
Ratio de NPL	-0,03	-3,98	0,00	***
Ratio de provisiones	-0,14	-3,58	0,00	***
CAR	-0,04	-2,27	0,03	*
LTD	-0,01	-1,73	0,09	.
Ratio de eficiencia operativa	-0,01	-2,16	0,04	*

Fuente: elaboración propia.

Los resultados obtenidos con el modelo de regresión lineal múltiple indican que las variables predictoras más relevantes (***) son el ratio de NPL y el ratio de provisiones. Estas dos variables además tienen un mayor t-valor (en términos absolutos) y un menor p-valor, por lo que se puede rechazar la hipótesis nula de que el coeficiente estimado debería ser 0. Asimismo, son relevantes (*) el CAR y el ratio de eficiencia operativa, con un t-valor y p-valor que también permiten rechazar la hipótesis nula. Más discutible es la significancia del LTD (.), que tiene el menor t-valor (en términos absolutos) y el mayor p-valor.

Con los datos obtenidos, la ecuación matemática que relaciona la variable objetivo con las variables predictoras es la siguiente:

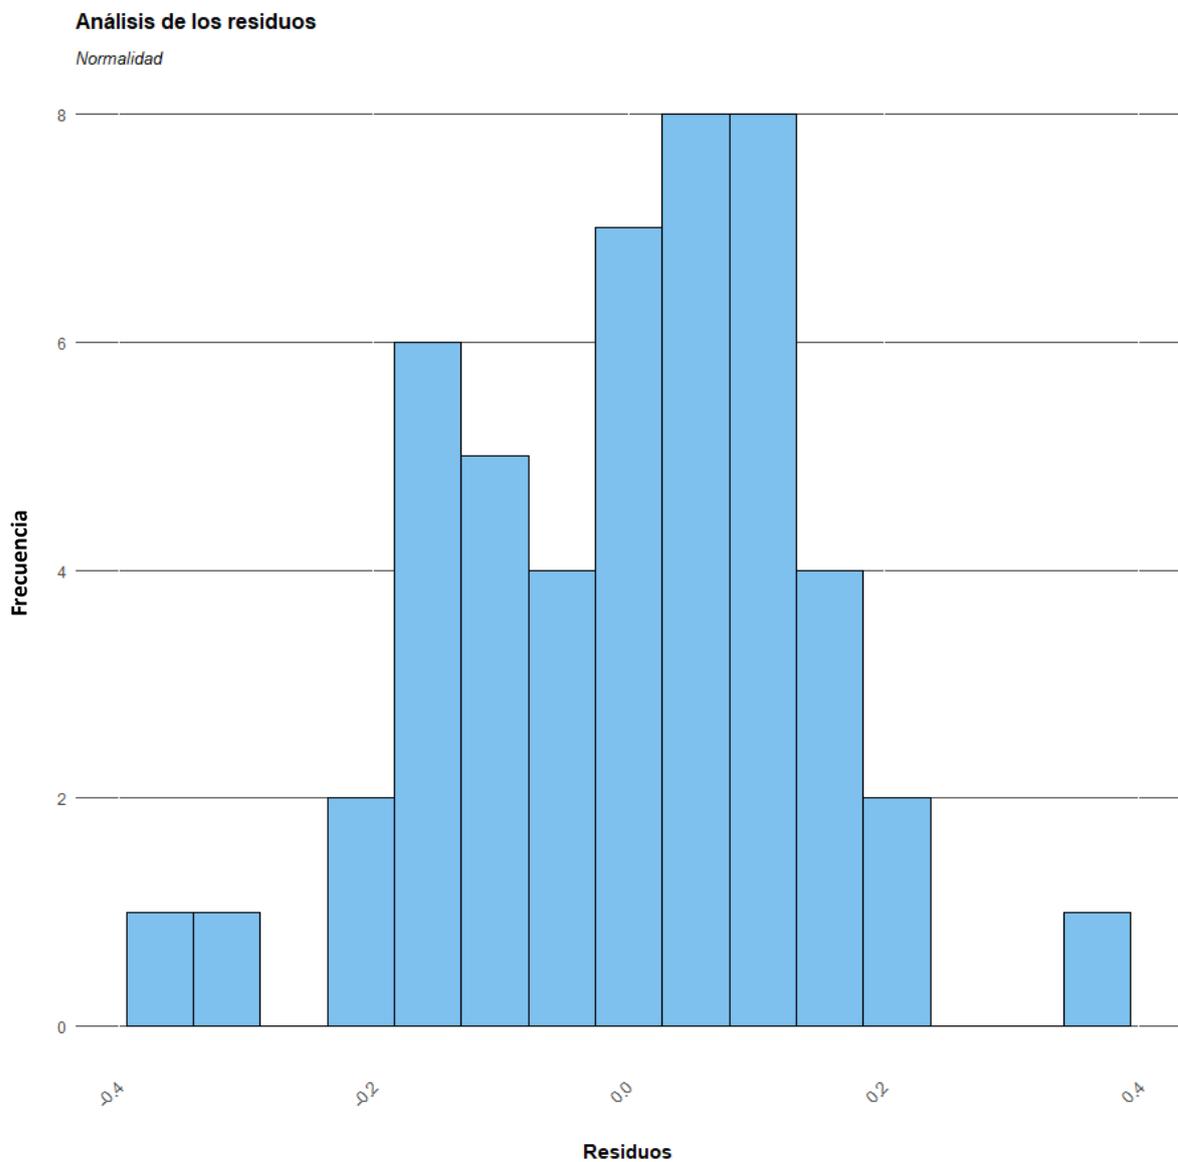
$$ROA = 2,05 - 0,03 \cdot \text{Ratio de NPL} - 0,14 \cdot \text{Ratio de provisiones} - 0,04 \cdot \text{CAR} \\ - 0,01 \cdot \text{LTD} - 0,01 \cdot \text{Ratio de eficiencia operativa}$$

Asimismo, el coeficiente de determinación (R^2) obtenido es de 0,5315, lo que supone que el modelo explica algo más de la mitad de la varianza de la variable objetivo.

3.2.4. Análisis de los residuos.

Las dos condiciones que deben cumplir los residuos en un modelo de regresión lineal son que se distribuyan con normalidad y con homocedasticidad. Para comprobar la distribución normal de los residuos, se incluye en la figura 11 su histograma. En el eje de abscisas se representa el valor de los residuos y en el eje de ordenadas su frecuencia. Como se observa, la distribución de los residuos es normal, por lo que se cumple el requisito.

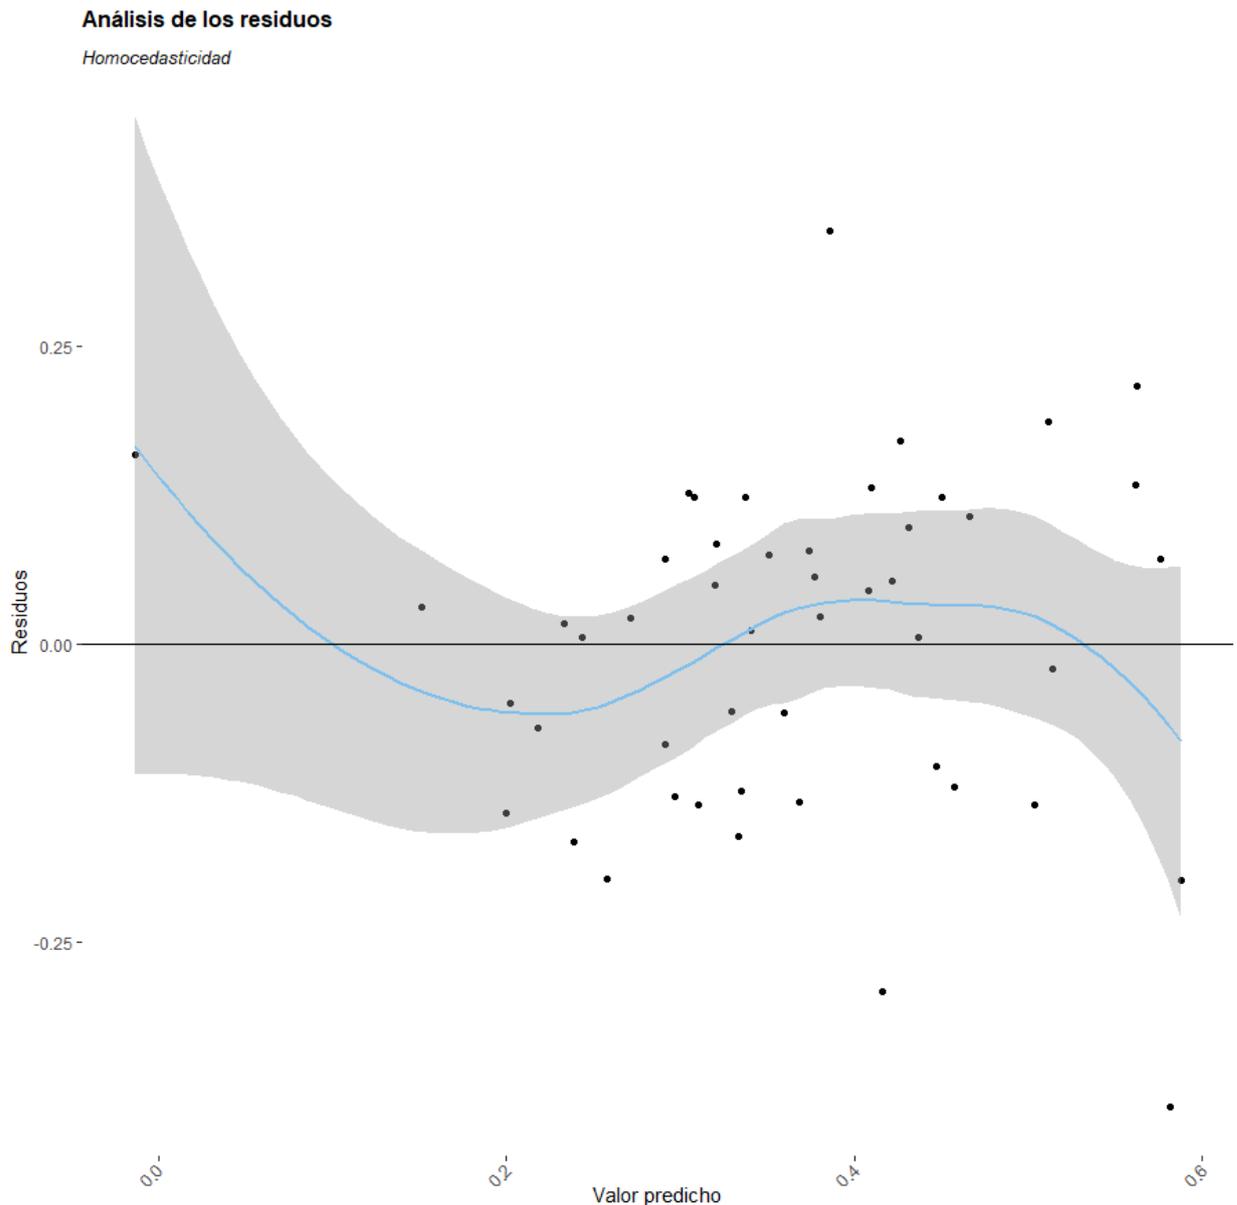
Figura 11: análisis de la normalidad de los residuos.



Fuente: elaboración propia.

Para analizar el cumplimiento del requisito de la homocedasticidad en los residuos, se ha representado en la figura 12 el valor de los residuos en el eje de las ordenadas frente al valor del ROA predicho en el eje de las abscisas. De esta manera, como los residuos se distribuyen a una distancia constante de la línea que marca el 0 se puede afirmar la homocedasticidad de estos.

Figura 12: análisis de la homocedasticidad de los residuos.



Fuente: elaboración propia.

Por tanto, se cumplen el requisito de normalidad y homocedasticidad de los residuos en el modelo de regresión lineal múltiple.

3.2.5. Evaluación de la capacidad predictiva del modelo.

La capacidad predictiva del modelo se va a evaluar mediante la métrica del error cuadrático medio (RMSE), que mide el error entre el ROA real y el obtenido aplicando el modelo.

Para realizar la predicción se utiliza el conjunto de prueba, es decir, el 30% de las observaciones con las que no se ha entrenado el modelo. El RMSE obtenido es de 1,16. Este valor se comparará con el obtenido utilizando la red neuronal artificial para determinar con cuál de las dos técnicas se logra una mejor predicción.

3.3. Red neuronal artificial.

3.3.1. Número de neuronas por capa y de capas ocultas.

Como se ha explicado en secciones anteriores, una red neuronal artificial se compone de distintas neuronas artificiales colocadas en varias capas ocultas. La función que se va a utilizar para realizar el modelo de red neuronal artificial, *nnet*, limita el número de capas ocultas a una única.

Para determinar el de neuronas en la capa oculta (*size*) se realiza un proceso de validación cruzada con los valores del 1 al 15. De esta forma, al entrenar el modelo se realizan varias iteraciones probando cuál de estos valores da un mejor resultado. De esta manera, también se estima otro hiperparámetro (*decay*) que evita que el modelo estimado se sobreajuste a los datos proporcionados. En este caso, se prueban los valores 0,01, 0,0075, 0,005, 0,0025 y 0,001. Es decir, mediante validación cruzada se estima cuál de los siguientes valores es el óptimo para utilizar en la red neuronal.

```
grid <- expand.grid (size = 1:15, decay = c(0.01, 0.0075, 0.005, 0.0025, 0.001))
```

3.3.2. Modelo de red neuronal artificial.

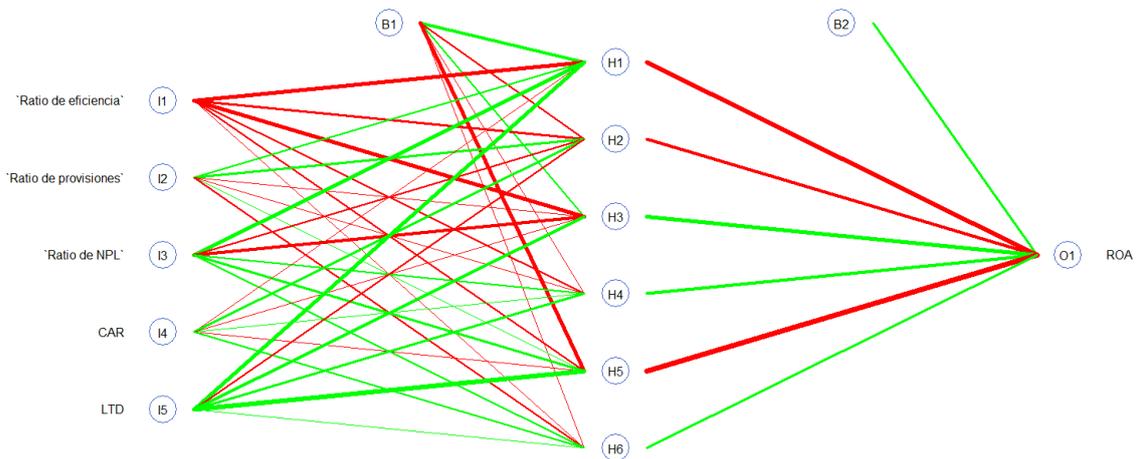
El modelo de red neuronal artificial se crea con la función *nnet*, se introduce el ROA como variable objetivo y el resto como variables predictoras. También se incluyen los hiperparámetros (*size* y *decay*) que se deben optimizar:

```
net <- train (ROA ~ `Ratio de eficiencia` + `Ratio de provisiones` + `Ratio de NPL`  
+ CAR + LTD,  
data=trainproc, method="nnet", trControl=controlnn, tuneGrid=grid)
```

El resultado obtenido indica que el número de neuronas óptimo es 6 y que el mejor valor de *decay* es 0,001.

A continuación, se incluye la figura 13 con la representación gráfica de la red neuronal artificial. En verde se observan las relaciones positivas y en rojo las negativas.

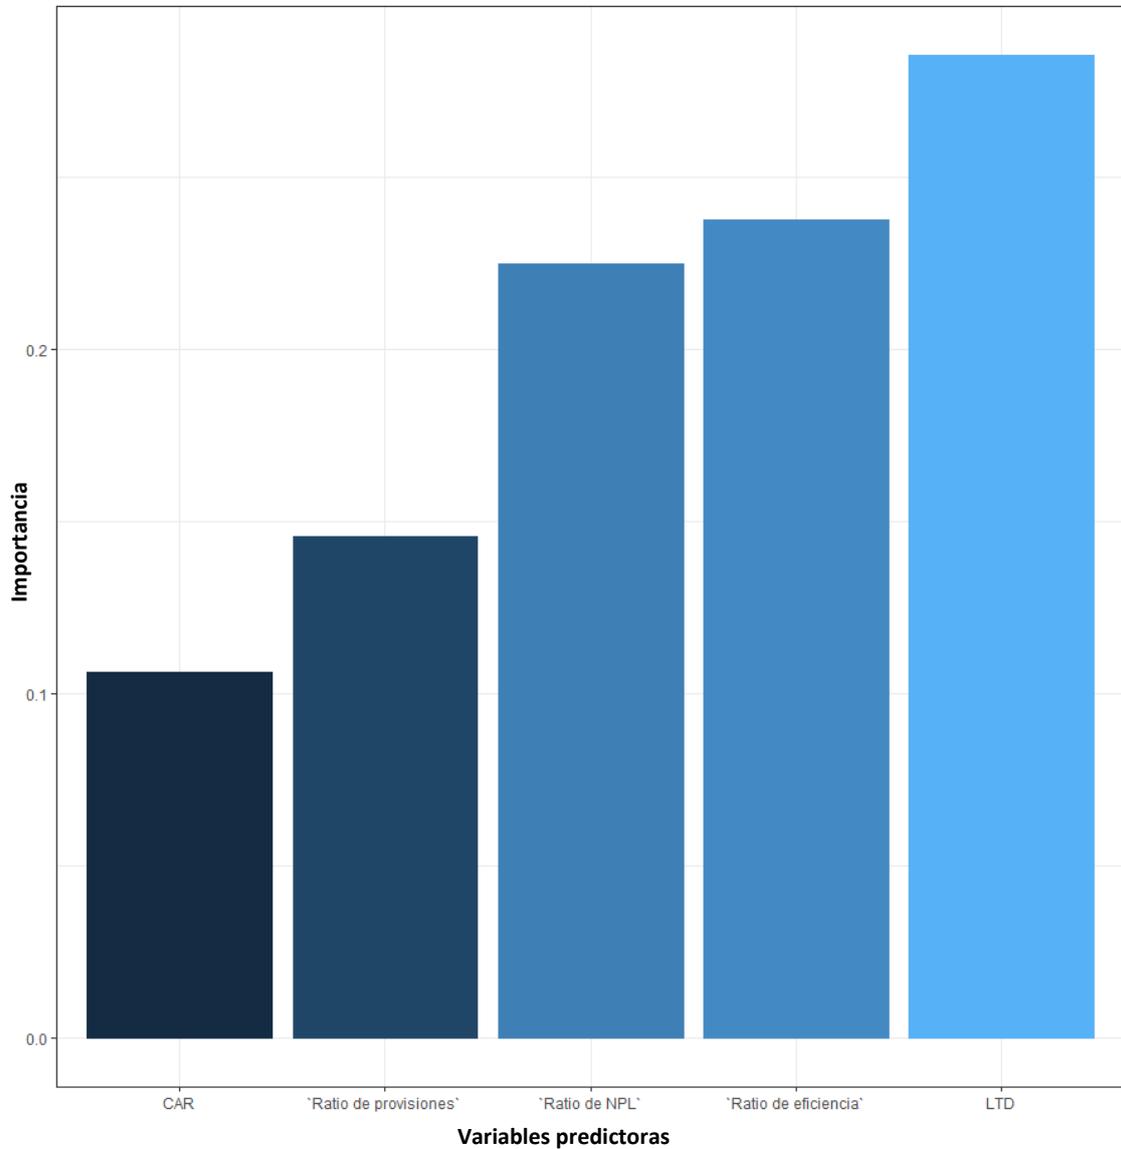
Figura 13: representación gráfica de la red neuronal artificial.



Fuente: elaboración propia.

Los pesos que se atribuyen a cada variable predictora en la red neuronal artificial conllevan que algunas variables tengan una mayor relevancia que otras en el modelo. Así, se puede obtener qué importancia porcentual ha tenido cada variable en el modelo. Con estos datos se ha realizado la figura 14, en la que se representa en el eje de las abscisas cada una de las variables predictoras y su importancia, en tanto por uno, en el eje de las ordenadas. Puede observarse que las variables que más importancia han adquirido en el modelo son el LTD, el ratio de eficiencia y el ratio de NPL.

Figura 14: representación de gráfica de la relevancia de las variables predictoras en el modelo de red neuronal artificial.



Fuente: elaboración propia.

3.3.3. Evaluación de la capacidad predictiva del modelo.

De igual manera que en el modelo de regresión lineal múltiple, la capacidad predictiva se va a evaluar mediante la métrica del error cuadrático medio (RMSE) utilizando el conjunto de prueba, con el que no se ha entrenado el modelo. El RMSE obtenido es 0,20.

3.4. Comparación de técnicas de modelización predictiva.

En las secciones anteriores se han entrenado dos modelos con dos técnicas distintas: predicción lineal múltiple y red neuronal artificial. Cada modelo se ha empleado para predecir el valor del ROA de un conjunto de datos con el que no había sido entrenado. Asimismo, los resultados predichos se han contrastado con los reales y se ha obtenido el RMSE de cada modelo. Mediante la comparación de dicha métrica se puede determinar con cuál de las dos técnicas se realizan mejores predicciones para el conjunto de datos empleado. El RMSE obtenido con cada técnica se puede observar en la tabla 5.

Tabla 5: análisis de la homocedasticidad de los residuos.

	Regresión lineal múltiple	Red neuronal artificial
RMSE	1,16	0,2

Fuente: elaboración propia.

Por lo tanto, dado que el RMSE obtenido con la red neuronal artificial es inferior al de la regresión lineal múltiple, se puede afirmar que con el modelo que emplea la primera técnica se efectuarán predicciones más precisas.

Hay dos motivos principales por los que la predicción con la regresión lineal múltiple es menos precisa que la de la red neuronal artificial. El primero de ellos es que no se cumplen todos los requisitos necesarios para emplear dicha técnica pues, como se ha explicado antes, la relación entre las variables predictoras y el ROA no es lineal. El segundo de ellos se resume en que el coeficiente de determinación (R^2) obtenido con el modelo de regresión lineal múltiple es 0,5315. Esto implica que hay elementos que afectan a la variabilidad del ROA que no se recogen en el modelo, como, por ejemplo, otros indicadores financieros que no se hayan tenido en cuenta en este trabajo.

V. CONCLUSIONES.

Las medidas adoptadas para solventar las crisis económicas previas, como el Acuerdo de Basilea III, han posicionado al sector bancario en una situación de solvencia y estabilidad desde la que se ha enfrentado a la crisis provocada por la pandemia del COVID-19. Por el contrario, las crisis anteriores se originaron por desequilibrios económicos o financieros, por lo que, las entidades bancarias se encontraron en un grave estado de inestabilidad. A pesar de la sólida posición de las entidades bancarias, la crisis del COVID-19 ha influido en los resultados del sector.

El principal efecto de la crisis del COVID-19 ha sido la disminución de la rentabilidad bancaria, medida por el ROA. Para analizar las causas de este descenso, en este trabajo se ha analizado la evolución de otros indicadores financieros. De todos ellos, destaca la caída del ratio de provisiones en 2020 por el incremento de la dotación para cubrir las pérdidas esperadas. Asimismo, es notable la disminución del ratio de eficiencia operativa en 2020, que probablemente se deba a la disminución del gasto operativo por el cierre de oficinas.

Para poder medir la variación de la rentabilidad de las entidades bancarias españolas tras la crisis del COVID-19, se han realizado dos modelos predictivos con dos técnicas distintas. Utilizando la regresión lineal múltiple, se ha obtenido un RMSE de 1,16; y utilizando la red neuronal artificial un RMSE de 0,20. De esta forma, se puede concluir que el modelo de la red neuronal artificial realiza mejores predicciones sobre el conjunto de datos escogido y que, por tanto, es un mejor modelo para cumplir el objetivo de este trabajo. Asimismo, comparando ambos modelos se detecta que la relevancia otorgada en cada uno de ellos a las variables predictoras es diferente. De este modo, mientras que en el modelo de regresión lineal múltiple priman el ratio de NPL y el ratio de provisiones, en la red neuronal artificial lo hacen el LTD y el ratio de eficiencia.

VI. BIBLIOGRAFÍA.

- Aggarwal, C.C. (2017). An Introduction to Outlier Analysis. En Springer (Ed.), *Outlier Analysis*, pp. 1-34.
- Aguilar, P, Arce, O., Hurtado, S., Martínez-Martín, J., Nuño, G. y Thomas, C. (2020). La respuesta de la política monetaria del Banco Central Europeo frente a la crisis del COVID-19. *Documentos ocasionales del Banco de España, 2026*, pp. 1-28.
- Aiyar, S., Calomiris, C. W. y Wieladek, T. (2015). Policy Corner. Bank Capital Regulation: Theory, Empirics and Policy. *IMF Economic Review, 63*(4), pp- 955-983.
- Alberni, M., Rodríguez, M. y Rojas, F. (2020). Alivio de capital y liquidez ante el COVID-19: implicaciones para la banca española. *Cuadernos de información económica, 276*, pp. 51.
- Amalia, S. y Nugraha, N. M. (2021) The Impact of Financial Ratio Indicators on Banking Profitability in Indonesia. *Turkish Journal of Computer and Mathematics Education, 12*(8), pp. 580-588.
- Banco de España. (2020). Informe de Estabilidad Financiera de primavera 2020.
- Banco de España. (2021). Informe de Estabilidad Financiera de otoño 2021.
- BBVA. (2020). Impact of COVID-19 on the banking sector. *BBVA Research*.
- Bernoth, K., Dany-Knedlik, G., y Gilbert, A. (2020). ECB and Fed monetary policy measures against the economic effects of the coronavirus pandemic have little effect. *Deutsches Institut für Wirtschaftsforschung, 3*, pp. 1-9.
- Buchory, H. A. (2015). Banking Profitability: How does the Credit Risk and Operational Efficiency Effect? *Journal of Business and Management Sciences, 3* (4), pp. 118-123.
- Calviño Santamaría, N. (2020). Las medidas de política económica en el contexto de la COVID-19. *Economistas, 187*, pp. 8-14.
- Calvo Bernardino, A. y De Vidales Carrasco, I. M. (2014). Crisis y cambios estructurales en el sector bancario español: Una comparación con otros sistemas financieros. *Estudios de Economía Aplicada, 32*(2), 535-566.
- Campos, P., Yagüe, M. y Chinchetru, I. (2007). Un nuevo marco de seguro de depósitos para España. *Banco de España Estabilidad financiera, 12*, 95-110.

- Carbó Valverde, S. y Rodríguez Fernández, F. (2013). Progresos recientes en la reestructuración y recapitalización bancarias en España. *Cuadernos de información económica*, 234, pp. 13-20.
- Carbó Valverde, S., Cuadros Solas, P. J. y Rodríguez Fernández, F. (2021). Informe sobre el sector bancario español en un entorno de cambios en la productividad. *Funcas*, pp. 1-45.
- Castelló Muñoz, E. (2020). Estrategias de las empresas de servicios financieros en la crisis del coronavirus. *Economistas*, 170, pp. 93-103.
- Castillo, S., Doménech, R. y Jiménez, M. (2021). La política monetaria en la eurozona ante la COVID-19. *Papeles de Economía Española*, 170, pp. 76-97.
- Cohen, B. H. y Edwards, G. A. (2017). El provisionamiento en función de las pérdidas crediticias esperadas. *Informe Trimestral del BPI*, pp. 1-21.
- Dickey, D. A. (2012). Introduction to Predictive Modeling with Examples. *SAS Global Forum: Statistics and Data Analytics*, 337, pp. 1-14.
- Dietrich, A. y Wanzenried, G. (2011). Determinants of bank profitability before and during the crisis: Evidence from Switzerland. *Journal of International Financial Markets, Institutions & Money*, 21, pp. 307-327.
- Duran, M. A. y Lozano-Vivas, A. (2014). Risk shifting in the US banking system: an empirical analysis. *Journal of Financial Stability*, 13, pp. 64-74.
- Fernández Torres, I. (2014). La reestructuración de las Entidades de crédito (bajo la Ley 9/2012). *Documentos de Trabajo del Departamento del Derecho Mercantil Universidad Complutense Madrid*, pp. 1-53.
- Fondo Monetario Internacional. (2006). Financial soundness indicators. Compilation guide.
- García Vaquero, V. y Casado, C. (2011). La ampliación de los diferenciales soberanos en la zona del euro durante la crisis. *Boletín económico Banco de España*, 83, pp. 1-11.
- Gestal Pose, M. (2009). *Introducción a las Redes de Neuronas Artificiales*. Universidade da Coruña, pp. 1-20.
- Gómez Rojas, G. A., Henao López, J. C. y Salazar Isaza, H. (2004) Entrenamiento de una red neuronal artificial usando el algoritmo simulated annealing. *Scientia et Technica*, 24, pp. 13-18.

- González Méndez, V. M. y González Rodríguez, F. (2000). Un análisis de los efectos de la crisis de Banesto sobre la banca y la industria. *Investigaciones Económicas*, XXIV(3), 611-640.
- Gualandri, E., Landi, A. y Venturelli, V. (2009). Financial Crisis and New Dimensions of Liquidity Risk: Rethinking Prudential Regulation and Supervision. *CEFIN Working Papers*, 13, pp. 1-24.
- Ibáñez Sandoval, J. P. y Domingo Ortuño, B. (2013). La transposición de Basilea III a la legislación europea. *Banco de España Estabilidad financiera*, 25, 65-97.
- Ibáñez Sandoval, J. P. y Domingo Ortuño, B. (2013). La transposición de Basilea III a la legislación europea. *Banco de España Estabilidad financiera*, 25, 65-97.
- Iskandar, Y. (2017). The Effect of Non Performing Loans, Operating Expense to Operating Income, and Loan to Deposit Ratio on Stock Return at Conventional Banks. *Journal of Entrepreneur and Entrepreneurship*, 6(1), pp. 25-30.
- Kaushik, S. K. y López, R. H. (1996). Profitability of credit unions, commercial banks and savings banks: A comparative analysis. *The American Economist*, 40 (1), pp. 66-78.
- KPMG. (2020). COVID-19: implicaciones en el sector financiero. Análisis de los principales impactos y planes de acción.
- López González, E. y Ruiz Soler, M. (2011). Análisis de datos con el Modelo Lineal Generalizado: Una aplicación con R. *Revista Española de Pedagogía*, 69, pp. 59-80.
- López Pascual, J. y Sebastián González, A. (2005) Gestión bancaria: Factores claves en un entorno competitivo. *McGraw Hill*. 3ª Edición.
- Maudos, J. (2012). El impacto de la crisis en el sector bancario español. *Cuadernos de Información Económica*, 226, 155-163.
- Maudos, J. (2020). Resiliencia de la banca española frente a la crisis del COVID-19: comparativa europea. *Cuadernos de Información Económica*, 276, pp. 41-49.
- McCulloch, W. S. y Pitts, W. (1990) A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biology*, 52, pp. 99-115.
- McKinsey & Company. (2020). A test of resilience: Banking through the crisis, and beyond. *McKinsey Global Banking Annual Review*, pp. 1-53.

- Montero Granados, R. (2016). Modelos de regresión lineal múltiple. *Documentos de Trabajo en Economía Aplicada: Universidad de Granada*, pp. 1-61.
- Moral Peláez, I. (2006). Modelos de regresión: lineal simple y regresión logística. *Métodos estadísticos para enfermería nefrológica*, 14, pp. 195-214.
- Nguyen, T. P. T. y Nghiem, S. H. (2015). The Interrelationship among Default Risk, Capital Ratio and Efficiency: Evidence from Indian Banks. *Managerial Finance*, 41(5), pp. 507-525.
- Oino, I. (2021). Bank solvency: The role of credit and liquidity risks, regulatory capital and economic stability. *Banks and Bank Systems*, 16 (4), pp. 84- 100.
- Ontiveros Baeza, E. y Valero López, F. J. (2013). Las crisis bancarias en España, 1977-2012. *Revista de la Historia de la Economía y de la Empresa*, VII, 277-317.
- Pardo Merino, A. y Ruiz Díaz, M. A. (2005). Análisis de regresión lineal: El procedimiento regresión lineal. En McGraw-Hill (Ed.), *Análisis de datos con SPSS 13 Base*, pp. 337-377.
- Poveda Analón, R. (2001). Las recomendaciones del Comité de Supervisión Bancaria de Basilea. *Revista de Estabilidad Financiera*, 1, pp. 31-58.
- Rahman, M. M., Hamid, K. y Khan, A. M. (2015). Determinants of Bank Profitability: Empirical Evidence from Bangladesh. *International Journal of Business and Management*, 10(8), pp. 135-150.
- Ramos López, E. (2021). La reacción del sector bancario ante la pandemia de la COVID-19. *Cofin-Habana*, 15, pp. 1-12.
- Rodríguez de Codes Elorriaga, E. (2010). Las nuevas medidas de Basilea III en materia de capital. *Banco de España: Estabilidad financiera*, 19, pp. 1-11.
- Rojo Abuín, J. M. (2007). Regresión lineal múltiple. *Instituto de Economía y Geografía*, II, pp. 1-31.
- Ross, S. A., Westerfield., R. W., Jaffe, J. F., y Jordan, B. D. (2018). *Corporate Finance. Core Principles & Applications* (5 ed.). Nueva York: McGraw-Hill Education International Edition.
- Salas, R. (2004). *Redes Neuronales Artificiales*. Universidad de Valparaíso, pp. 1-7.

- Sarina Salas, J. (1993). Indicadores de solvencia bancaria y contabilidad a valor de mercado. *Banco de España: Servicio de estudios*, 9312, pp. 1-69.
- Shalev-Shwartz, S. y Ben-David, S. (2014). *Understanding Machine Learning: From Theory to Algorithms*. Cambridge University Press.
- Strickland, J. S. (2015). *Predictive Analytics using R*. Lulu Inc.
- Sudrià, C. (2014). Las crisis bancarias en España: Una perspectiva histórica. *Estudios de Economía Aplicada*, 32(2), 473-496.
- Sukmaedewi, R. (2020). The Effect of Capital Adequacy Ratio, Loan to Deposit Ratio, Operating-Income Ratio, Non Performing Loans, Net Interest Margin on Banking Financial Performance. *ECO-Buss*, 2(2), pp. 1-10.
- Torres, R. y Fernández, M. J. (2020). La política española y el COVID-19. *Cuadernos de información económica*, 275, pp. 1-7.
- Tortella, G. y García Ruiz, J. L. (2013). *Spanish Money and Banking: A History* (1 ed.). Londres: Palgrave Macmillan.
- Uriel Jiménez, E. (2013). Regresión lineal múltiple: estimación y propiedades. *Universidad de Valencia*, pp. 1-38.
- Villasante, P. P. (2012). La crisis y los bancos españoles. *Economistas*, 131, pp. 130-135.
- Wessler, M. (2018). *Big Data Analytics For Dummies*. John Wiley & Sons Inc.
- Zhang, J., Jiang, C., Qu, B. y Wang, P. (2013). Market concentration, risk-taking, and bank performance: Evidence from emerging economies. *International Review of Financial Analysis*, 30, pp. 149-157.