



Universidad de Jaén

Escuela de Doctorado

TESIS DOCTORAL



**EXPOSICIONES EN SITUACIÓN DE IMPAGO.
ESTIMACIÓN DE PARÁMETROS PARA EL CÁLCULO DE
CAPITAL REGULATORIO Y SU PREDICCIÓN MEDIANTE
APRENDIZAJE AUTOMÁTICO**

PRESENTADA POR:

Marta Ramos

DIRIGIDA POR:

Dr. D. Antonio Partal Ureña

Dr. D. Pilar Gómez Fernández-Aguado

Dr. D. Luis Martínez López

JAÉN, 15 MAYO 2023

ISBN

Agradecimientos

Nací en una familia imperfecta, como todas, que ha sabido transmitirme mi bien máspreciado, la Fe. Además, me educaron para que pudiese tener capacidad de esfuerzo, e interés por investigar, estudiar, leer, conocer... y tener al mismo tiempo un pensamiento crítico, lo cual es clave para la vida. También se aseguraron de que pudiese tener herramientas para desarrollar mi creatividad. Mis padres y hermanos forman el mejor nido desde el que poder volar, y al que poder volver, cuando la vida lo permite, para compartir buenas comidas, conversaciones y risas... en definitiva buenos ratos. Siempre me regalaron las palabras que necesitaba escuchar para seguir adelante con este doctorado. Por todo eso me siento muy agradecida de tenerlos.

Poco después de que comenzase mi carrera profesional en el área de riesgo de crédito, tuve la suerte inmensa de dar con Antonio y Pilar. Después de un tiempo colaborando puntualmente en temas de investigación, comencé el doctorado con ellos. A lo largo del mismo, pasé por tres trabajos de tres países distintos y di a luz a mis tres hijos. En todo este tiempo he podido descubrirles como personas y como profesionales, y he comprobado que hay tres apelativos que les describen a la perfección:

- Director, viene del latín y significa “el que guía en línea recta hacia un punto”.
- Tutor, derivado del verbo latín *tueri*, que significa “observar, vigilar y proteger”.
- Maestro se asocia con una raíz indoeuropea presente en el griego *meGas* que significa “grande, importante”.

En todo momento supieron guiarme para llegar a lograr los objetivos del doctorado, tanto a nivel académico como personal. No ha sido un proceso fácil, pero siempre han estado acompañándome y animándome para que continuase, a pesar de las piedras más o menos grandes que nos fuimos encontrando en el camino. En ningún momento les ha faltado cercanía y empatía, acompañándome como verdaderos tutores. Además, tienen una característica que valoro especialmente en las personas, y es la transparencia, ya que hace que me inspiren confianza. Por ello, además de buenos profesionales, son grandes personas y, por tanto, merecedores del título de maestros. Gracias a su paciencia, flexibilidad y buenos consejos he podido terminar el doctorado, en un contexto bastante complejo, sin percibir en ningún momento exigencia por su parte. Esto es verdaderamente admirable y digno de reconocimiento. También me gustaría agradecer el soporte de Luis, que ha estado disponible siempre que lo hemos necesitado.

Han pasado ya diez años desde que mi marido y yo empezamos nuestra aventura de vida juntos. Ocho años de matrimonio y tres hijos después, este doctorado llega a su fin. A lo largo de este tiempo, mi marido me ha demostrado ser un verdadero cabeza de familia, aportándonos seguridad en cada cambio, en cada dificultad, celebrando cada alegría, haciendo de guía, de referente, de baluarte. Un compañero de vida preparado para actuar, defender, proteger, animar ante cualquier eventualidad, con fuerza y decisión... un auténtico bombero de la vida. Verdadero ejemplo de renuncia y de entrega. Poder ser madre, doctoranda y profesional a tiempo completo, no sería posible sin su ayuda. Nunca se me planteó la duda de dejar el doctorado por dedicarme a mi familia porque nunca me lo ha reprochado, al contrario, siempre me ha regalado palabras de ánimo. Y mis hijos, qué decir de ellos, con su inocencia, desparpajo, generosidad, alegría y amor, hacen que pueda ver la belleza de cada día, y que todo esfuerzo merezca la pena. Son pequeños valientes que, sin darse cuenta, nos enseñan más ellos a nosotros que al contrario. Son mis ángeles en la tierra, que algún día se reunirán con sus hermanitos en el cielo. Este doctorado se ha podido llevar a cabo gracias al equipazo que tengo en casa. Ellos me han ido dando el impulso y la fuerza que necesitaba en cada momento.

Por último y más importante, no puedo más que dar gracias a Dios por muchas razones. Por ponerme en el camino a todas las personas que me facilitaron este viaje. Por regalarnos siempre una comunidad que está pendiente y reza por nosotros. Por hacernos nacer y crecer en el seno de nuestras familias, curiosamente tan distintas, pero que tanto nos apoyan y cuidan. Familias amplias, con muchas buenas personas que nos han dejado y dejan buenos recuerdos cada vez que hay oportunidad de coincidir, como nuestros abuelos, tíos abuelos, nuestros tíos, primos, padrinos, etc. Por regalarnos a nuestros amigos, que son como familia, y que tantas veces, sin saberlo, dan un soplo de aire fresco a nuestro matrimonio. Por compañeros de trabajo que más que nada han sido eso, compañeros, y por eso es un placer hacer equipo con ellos. Sobre todo, gracias por ser un Padre bueno, que nos cuida, nos protege y nos hace infinidad de regalos, cuidando cada detalle. Gracias a Jesús por demostrarnos en su propia carne lo que es AMAR de verdad. Gracias al Espíritu Santo que tantas veces nos renueva. Y gracias a María por ser una Madre cercana, estando presente en todos y cada uno de los pasos que damos, siempre disponible para darnos un abrazo de madre y echarnos una mano. Este doctorado es un detalle más de tantos que no merezco pero que Dios no deja de regalarme, porque Él es así de espléndido.

Índice

1. Resumen.....	5
2. Introducción	8
2.1. Riesgo de crédito de exposiciones en impago.....	9
2.2. Técnicas de aprendizaje automático.....	10
3. Objetivos.....	12
4. Resultados	14
4.1. Modelos regulatorios propuestos	14
4.2. Aprendizaje automático para la predicción de la ELBE	17
4.2.1. Compensación hacia adelante.....	19
4.2.2. Propagación hacia atrás.....	21
4.2.3. Predicción de ELBE en dos escenarios	22
5. Discusión.....	26
6. Conclusiones.....	27
7. Bibliografía.....	29
8. Publicaciones.....	36

1. Resumen

El Comité de Supervisión Bancaria de Basilea (BCBS, por sus siglas en inglés) es un organismo establecido en el año 1974 por los bancos centrales de los países del G-10, está compuesto en la actualidad por las autoridades de supervisión bancaria de 27 países. Su función principal es fortalecer la solidez de las instituciones financieras, con este fin, ha emitido tres acuerdos sobre legislación y regulación bancaria desde sus inicios. Se trata de Basilea I (1988), Basilea II (2006) y Basilea III (2011). Cada uno de ellos forma una guía completa para las entidades bancarias en lo que respecta a la determinación del capital mínimo exigido en función de los riesgos a los que se expone cada entidad. Aunque sus directrices regulatorias no tienen la fuerza legal para ser adoptadas, la mayoría de los países tienden a implementar estas políticas en la regulación. El 26 de junio de 2013 se divulgó el marco legal en el que se articulan estas propuestas en la Unión Europea, denominado Reglamento sobre Requisitos de Capital (2013), en adelante RRC.

El segundo de los mencionados acuerdos, Basilea II, publicado en junio de 2004, ofrece un marco de capital regulatorio más completo que el anterior. Se resuelven así debilidades presentes en la propuesta primera, sobre todo en cuanto a la estimación de riesgos se refiere. Directrices que se han ido adoptando e implementando en los distintos países a lo largo de los últimos años. Una de las categorías de riesgos que supone más consumo de capital, desarrollada ampliamente en Basilea II, es el riesgo de crédito. Para la obtención del capital regulatorio, las autoridades supervisoras han de evaluar bajo el método que las entidades proponen para realizar este cálculo. Este puede ser Estándar o estar basado en calificaciones internas (es decir, el método denominado IRB, por sus siglas en inglés), que a su vez puede ser IRB Básico o IRB Avanzado. Para poder utilizar un método IRB las entidades han de verificar una serie de condiciones que garantizan que están bajo el paraguas regulatorio de Basilea. Este trabajo estará centrado en el último de los métodos mencionados, cuya adopción por parte de las entidades requiere, en términos generales, de la estimación de tres parámetros fundamentales para el riesgo de crédito: severidad (Loss Given Default, LGD), probabilidad de incumplimiento¹ (Probability of Default, PD) y exposición en el momento de incumplimiento (Exposure at Default, EAD).

¹ A lo largo de la presente tesis se utilizarán los conceptos *impago* e *incumplimiento* indistintamente.

En el caso de estimación de los parámetros IRB Avanzados para exposiciones en situación de impago, la severidad correspondiente se denomina LGD in-default. Además, la regulación introduce para estos casos un parámetro que representa la mejor estimación de la pérdida esperada (Expected Loss Best Estimate, ELBE) que, junto con la LGD in-default, se utiliza para calcular los activos ponderados por riesgo (APRs), que son la esencia del capital regulatorio, asociado a estas exposiciones. En la presente investigación, nos centramos en la estimación de estos dos parámetros en base a lo dispuesto en los documentos regulatorios de referencia. A este respecto, Basilea II² y, en particular, el RRC tan sólo esbozan unas líneas generales³. Por tanto, puede existir gran heterogeneidad en los modelos existentes de ELBE y LGD in-default y en los resultados que arrojan. En consecuencia, se podría observar una gran variabilidad, en términos de APRs, no asociada a características propias de la cartera de impagados sino a las diferencias entre modelos. Esto es contrario a la filosofía subyacente del uso de métodos IRB Avanzados para el cálculo de capital regulatorio.

En el RRC, se hace referencia en repetidas ocasiones a la Autoridad Bancaria Europea (ABE), establecida en 2011, con la función principal de crear guías con carácter general para asegurar la homogenización de las prácticas bancarias. Es decir, en algunos artículos del RRC tan sólo se dan directrices generales, advirtiendo que la ABE se encargará de hacer una futura publicación referente a esta área, y esto es lo que sucede con las exposiciones en situación de impago. Como respuesta, la ABE publicó dos documentos: el estándar técnico regulatorio en evaluación de metodología IRB (2016) y la guía en PD, LGD y tratamiento de exposiciones en situación de impago (2017). En comparación con la RRC, ambas publicaciones aportan más de detalle en la descripción de la metodología IRB aplicable para el cálculo de capital en el caso de exposiciones en default.

En resumen, el presente trabajo trata de establecer una propuesta para la construcción de los modelos mencionados, LGD in-default y ELBE en línea con la normativa vigente y las directrices de referencia de la ABE. Posteriormente, la metodología propuesta es aplicada en bases de datos de ciertas entidades financieras españolas y se lleva a cabo un análisis comparativo del resultado obtenido.

² En la publicación del tercer acuerdo, Basilea III, no se han añadido elementos nuevos en referencia a esta área específica del riesgo de crédito que nos ocupa.

³ En contraposición, se ofrece un nivel mayor de detalle para la estimación de parámetros asociados a exposiciones que no están en situación de impago.

Por otra parte, considerando que la crisis del coronavirus ha sido un evento histórico único de gran impacto económico, la validez de los métodos tradicionales de estimaciones prospectivas, basados en datos históricos, se ha visto comprometida. De cara a ofrecer una solución a este desafío, se propone una estimación del parámetro ELBE, basada en técnicas de aprendizaje automático, para dos escenarios: en el contexto actual y suponiendo la inexistencia de la pandemia. A continuación, se realiza una comparación de ambos escenarios que arroja conclusiones de gran interés. La metodología propuesta, a pesar de su naturaleza novedosa, sigue estando basada en las mencionadas directrices regulatorias. Los modelos propuestos, y aplicados en base a la información de carteras hipotecarias de entidades españolas, demuestran ser fácilmente extensibles y adaptables a otras bases de datos para la estimación de los parámetros para el cálculo de capital regulatorio de exposiciones en impago.

2. Introducción

En primer lugar, conviene resaltar el elevado impacto, a nivel internacional, de los acuerdos de Basilea ya mencionados. Desde 2011, BCBS publica un informe sobre los avances en la aplicación del marco regulador de Basilea con carácter generalmente bianual, como parte de su Programa de Evaluación de la Consistencia Regulatoria (RCAP, por sus siglas en inglés). El resultado de dicho informe se puede visualizar en una tabla en la que se presenta el estado de la implementación de Basilea III (2022) para 20 jurisdicciones miembros del BCBS, siendo la Unión Europea y Estados Unidos dos de ellas⁴. Dicha tabla muestra un estado mayoritariamente avanzado de dicha implementación. Por otra parte, una encuesta conducida por el Instituto para la Estabilidad Financiera (FSI, por sus siglas en inglés, 2013), recoge la información recibida por 98 países, no perteneciente a ninguna jurisdicción miembro del BCBS ni a la Unión Europea y que están sujetos a la implementación del conjunto de medidas recogidas en los acuerdos de Basilea. De los resultados de la encuesta se extrae que 35 países ya habían implementado modelos IRB, o bien, tenían prevista una próxima implementación. Ambos informes muestran que existe un amplio espectro de entidades bancarias que han implementado o deberán desarrollar una metodología adecuada para el cálculo de capital y pérdida esperada asociados a sus exposiciones de la cartera de impagados.

Como señala un informe de riesgo de la ABE (2022a), los indicadores de riesgo de la industria bancaria de la UE se mantienen benignos por el momento. La proporción de tasa de morosidad⁵ que está por encima del 8% ha ido decreciendo paulatinamente, desde el 4.1% registrado en marzo de 2020 hasta el 0.0% de diciembre de 2022. De hecho, la tasa de morosidad media se mantiene en torno al 1.8% a finales de 2022. Según los datos del informe de seguimiento de una firma de consultoría (2022), la tasa de morosidad española se situaba en el 2.8% en junio de 2022. Sin embargo, el mencionado informe de la ABE del trimestre anterior (2022b) señala que la alta inflación, presente en el panorama económico actual, podría tener un impacto sustancial en las empresas y familias más vulnerables. Esta nueva crisis económica que se ha iniciado podría elevar de nuevo el volumen de exposiciones en impago a altos niveles, tal y como se observó tras la crisis financiera desencadenada en 2008 (Karadima y Louri, 2021). Estudios recientes también apuntan a un incremento de la ratio de morosidad a nivel mundial como consecuencia de la crisis de la COVID-19 (OCDE, 2021). A partir de las

⁴ Mientras que las demás son: AR, AU, BR, CA, CN, HK, IN, ID, JP, KR, MX, RU, SA, SG, ZA, CH, TR y GB, siguiendo la codificación propuesta en la norma ISO 3166-1 alpha-2.

⁵ En inglés: non-performing loans (NPL) ratio.

referidas publicaciones, se puede concluir que existe una amplia y creciente necesidad de una adecuada definición de la metodología utilizada para la cobertura por riesgo de crédito de exposiciones en impago.

A lo largo de los años de doctoranda, ha sido fundamental realizar un análisis de la literatura actual relativa al tema para evaluar posteriormente las posibles lagunas aún por cubrir para enfocar la presente investigación. A continuación, se presenta una resumida exposición de las principales investigaciones en la literatura analizada. En primer lugar, se comienza con un apartado dedicado a las metodologías propuestas con respecto a la modelización de los mencionados parámetros de riesgo de crédito que requiere la regulación para la cartera de préstamos incumplidos. Después, se exploran las publicaciones sobre aprendizaje automático que son relevantes para el tema de investigación.

2.1. Riesgo de crédito de exposiciones en impago

Existen pocas propuestas metodológicas con enfoque IRB para exposiciones de préstamos impagados. Cabe destacar que generalmente no se siguen rigurosamente las directrices regulatorias. De hecho, muchas de las publicaciones no tenían aun como referencia las aclaraciones que incluye la guía de la ABE en PD, LGD y tratamiento de exposiciones en situación de impago (2017). Por ejemplo, en la misma se explica que la LGD in-default no ha de estimarse como una LGD que incluya únicamente un efecto de declive económico⁶, esto es, estresar la LGD para considerar condiciones del momento más débil del ciclo. La guía va más allá, especificando que la LGD in-default ha de estimarse, no sólo considerando dicho efecto de recesión, sino también posibles pérdidas adicionales que se puedan registrar a lo largo del proceso de recuperación de la deuda.

Dermine y Neto de Carvalho (2006, 2008) analizan las pérdidas después del incumplimiento mediante el uso de dos métodos que tienen como variable el tiempo en impago. El primero de los métodos sigue la propuesta de Altman (1989) y Altman y Suggit (2000), donde se analiza el porcentaje de préstamos malos y dudosos después de un número determinado de años desde el origen del préstamo y, a continuación, se hace un ajuste basado en el estimador Kaplan-Meier (1958) que corrige el efecto de datos censurados. El segundo método se basa en una estimación empírica de la función log-log. Por su parte, Weissbach y Von Lieres und Wilkau (2010) realizan dos estimaciones de capital económico para exposiciones en impago y

⁶ Downturn, en inglés.

proponen la estimación de ambos ELBE y LGD in-default mediante modelos de factor único. El uso de análisis de supervivencia y modelos de mixturas de distribuciones, entre otros, es considerado por Zhang y Thomas (2012) para la modelización de la ratio de recuperación y la predicción de la LGD. Altman y Kalotay (2014) modelizan las recuperaciones de deuda impagada mediante una mixtura de distribuciones Gaussianas. Finalmente, Fenech et al. (2016) retoman el uso del estimador Kaplan-Meier para el cálculo de la supervivencia de entidades financieras que están cercanas a la bancarrota, en otras palabras, su capacidad de recuperación.

Cabe señalar que el componente temporal de la pérdida inesperada, o LGD in-default, adquiere en la modelización una especial relevancia, tal y como señala la referida guía de la ABE (2017). Existen varios artículos de interés con respecto a este componente en la estimación las pérdidas y recuperaciones de la cartera. Altman et al. (2004) exponen una discusión sobre la presencia de volatilidad en las ratios de recuperación, basado en datos recogidos en varios países en distintas épocas del ciclo económico. Así, concluyen en la asunción del modelo de Merton (1974), dicha volatilidad desaparece con una adecuada diversificación de la cartera, lo que entra en contradicción con la evidencia empírica mostrada. Gürtler y Hibbeln (2013) concluyen que la mayoría de los préstamos normalmente tardan cierto tiempo en salir de situación de impago y encuentran una correlación positiva entre la LGD y el tiempo de resolución. Betz et al. (2016) también analizan el tiempo de resolución y esbozan conclusiones que están en línea con el trabajo de Gürtler y Hibbeln.

2.2. Técnicas de aprendizaje automático

El marco metodológico de la inteligencia artificial es denominado aprendizaje automático, en inglés Machine Learning (ML), término acuñado por Samuel (1959). Hay varias aplicaciones en el uso de técnicas de aprendizaje automático disponibles en la literatura académica con fines predictivos. Por ejemplo, son ampliamente utilizadas en el procesamiento de imágenes. Ahmen y Hammami (2022) compilan una década de estudios que incluyen aplicaciones de ML e inteligencia artificial en temas financieros, como la predicción de bancarrota y cotización de acciones, gestión de cartera, finanzas comportamentales o supervisión del blanqueo de capitales. Al-Maadid et al. (2022) utilizan ML para evaluar el papel de las noticias sobre la COVID-19 en la predicción del rendimiento de acciones. Moscatelli et al. (2020) y Barbaglia et al. (2021) recogen estudios de predicciones de impago crediticio con ML. Alonso Robisco y Carbó Martínez (2022a) evalúan el impacto económico en instituciones financieras de utilizar modelos de ML para predecir el impago crediticio para el cálculo de

capital regulatorio. Otras investigaciones recogen aplicaciones de ML para la estimación de calificaciones crediticias, como las realizadas por Machado y Karray (2022), Yu et al. (2020) Li et al. (2020) y Yu et al. (2021). Bellotti et al. (2021) utilizan ML para predecir las ratios de recuperación de los préstamos morosos. También se han encontrado publicaciones recientes con propuestas que incluyen el uso de ML para la predicción de capital regulatorio (García-Céspedes y Moreno, 2022) y LGD (Bastos y Matos, 2022). Sin embargo, el uso de técnicas de ML para predecir parámetros regulatorios lleva presente en la industria bancaria desde hace unos años, y su uso está cada vez más extendido, tal y como señalan Huck (2019) y Alonso Robisco y Carbó Martínez (2022b)

3. Objetivos

En primer lugar, se propone una metodología para la estimación de los parámetros LGD in-default y ELBE, que ha sido aplicada en varias bases de datos y publicada como documento de trabajo (2018) y como artículo (2021). La metodología IRB publicada tiene dos características principales: se ha diseñado siguiendo las directrices regulatorias relevantes para las exposiciones en impago y, además, se trata de una propuesta novedosa en la literatura académica, ya que no existen modelos regulatorios LGD in-default y ELBE publicados hasta la fecha.

A causa de la situación económica generada por la COVID-19, se aplicaron una serie de medidas por gran parte de los gobiernos estatales, con el propósito de limitar el avance de la enfermedad. Indudablemente, una situación excepcional como esta repercute en el contexto económico a todos los niveles. Como consecuencia, se publicaron análisis del impacto del brote de dicha enfermedad en varias áreas económicas, como en los modelos de negocio (Seetharaman, 2020), los tipos de cambio (Narayan, 2021), los rendimientos de las empresas (Hu y Zhang, 2021), la distribución de ingresos (O'Donoghue et al, 2020) y el mercado de valores (Sharif et al., 2020), entre otros. Además, se produjo una desaceleración económica que complicó la gestión del riesgo financiero en las instituciones de crédito.

La estimación de dichos parámetros IRB Avanzados para exposiciones en situación de impago ha estado tradicionalmente basada en datos históricos. Sin embargo, las bases de datos existentes no tenían registrado ningún evento similar a la situación sanitaria y económica mencionada antes de que esta se produjese. Para la presente investigación, se exploraron metodologías novedosas con el fin de realizar una predicción del parámetro ELBE que incorpore el impacto de la pandemia, tal y como se refleja en el artículo publicado (2023). Siempre se ha buscado que el enfoque desarrollado esté en línea con la regulación vigente aplicable a modelos IRB.

El punto de partida han sido los datos históricos de la cartera hipotecaria de ciertas entidades crediticias españolas y cierto indicador macroeconómico que resulta clave para el desarrollo del modelo. En particular, la propuesta se apoya en la ratio de desempleo, y sus proyecciones publicadas por Banco de España (2020) y por el Fondo Monetario Internacional (2020). Entonces, mediante una metodología de ML, se realiza una predicción del parámetro ELBE para el año 2022 en base a dos escenarios. En el primero se tiene en cuenta el impacto de

la COVID-19 y en el segundo se asume que no ha existido tal pandemia. Para este fin, se propone utilizar una técnica de aprendizaje automático basada en una red neuronal multicapa de compensación hacia adelante⁷, denominada red neuronal profunda⁸, y mediante un aprendizaje de propagación hacia atrás⁹ basado en un algoritmo de descenso de pendiente en lotes¹⁰, descrito por Skansi (2018).

⁷ Feedforward, en inglés.

⁸ Deep Neural Network (DNN), en inglés.

⁹ Backpropagation, en inglés.

¹⁰ Batch gradient descent, en inglés.

4. Resultados

4.1. Modelos regulatorios propuestos

Como se refleja en el primero de los artículos publicados (2021), el modelo ELBE se estima para cada fecha en la que los flujos de recuperación se registran. Siendo $[0, T] \subset \mathbb{R}$ un intervalo de tiempo, y $0 < t_0 < t_1 < \dots < t_k < \dots < t_n < T$ y $0 < \tilde{t}_0 < \tilde{t}_1 < \dots < \tilde{t}_k < \dots < \tilde{t}_m < T$, dos particiones de dicho intervalo, de manera que $t_0 < \tilde{t}_0$ y $\tilde{t}_m < t_n$, siendo además las recuperaciones de deuda registradas a lo largo de dicho intervalo expresadas como $r_{\tilde{t}_0}, r_{\tilde{t}_1}, \dots, r_{\tilde{t}_k}, \dots, r_{\tilde{t}_m}$ de manera que $\tilde{t}_i \in (0, T)$ y, siendo la EAD la exposición en el momento del incumplimiento, la ELBE se define de la siguiente manera:

$$ELBE_{t_k} := 1 - \left[\left(\sum_{\tilde{t}_i > t_k} r_{\tilde{t}_i} \right) / \left(EAD - \sum_{\tilde{t}_i > t_k} r_{\tilde{t}_i} \right) \right] \quad (1)$$

La calibración se realiza en base a la metodología ELBE mostrada en la ecuación (1) y utilizando los datos del conjunto E, que recoge las recuperaciones utilizadas para la estimación de pérdidas esperadas e inesperadas. Es decir, se calcula la curva $ELBE_{t_i}^E$ para todo $t_i \in (0, T)$, obteniendo los siguientes resultados del *Gráfico 1*.

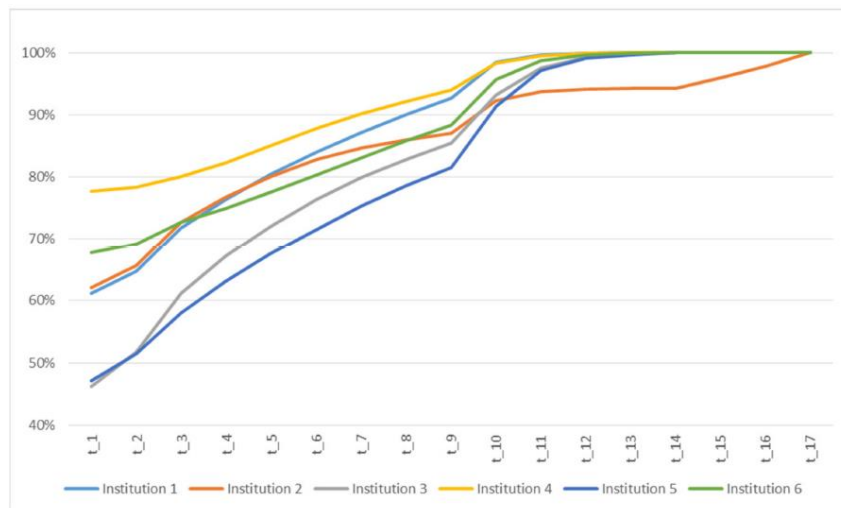


Gráfico 1. ELBE estimada para las instituciones españolas por tiempo de incumplimiento.

Por otra parte, la LGD in-default, se obtiene como resultado de añadir un suplemento a la ELBE. Este es estimado siguiendo un enfoque conservador, capturando la incertidumbre del proceso de recuperación, así como la tendencia observada durante un periodo de recesión económica. Para ello, se considera que el último momento registrado tras el incumplimiento es

$t_s \in (0, T)$ para cierto $s > 0$ y se define $ELBE_{t_i}^{C,p}$ como el percentil p de la distribución ELBE en el momento t_i evaluado para los elementos del conjunto C . Entonces, se define la siguiente diferencia:

$$\Delta_p^{E,I}(t_i) := ELBE_{t_i}^{C,p} - ELBE_{t_i}^{I,50} \quad \forall p \in [50, 100]$$

Por lo tanto, el siguiente indicador se define:

$$\delta_p := \#\{i \in \{1, \dots, s\} / \Delta_p^{E,I}(t_i) < 0, \forall p \in [50, 100]\}$$

En base a lo anterior, se establecen dos errores cuadráticos medios, uno siguiendo la definición usual y el otro ajustado, de manera que sólo considera los valores negativos de $\Delta_p^{E,I}(t_i)$, tal y como se presenta a continuación:

$$RMSE_p := \sqrt{(1/s) \sum_{i=1}^s \Delta_p^{E,I}(t_i)^2} \quad \forall p \in [50, 100]$$

$$RMSE_p^{neg} := \begin{cases} \sqrt{(1/\delta_p) \sum_{\{i \in \{1, \dots, s\} / \Delta_p^{E,I}(t_i) < 0\}} \Delta_p^{E,I}(t_i)^2} & \text{si } \delta_p > 0 \\ 0 & \text{si } \delta_p = 0 \end{cases} \quad \forall p \in [50, 100]$$

Con estos dos errores, se determina el indicador de ajuste mixto, MAI¹¹ por sus siglas en inglés, de la siguiente manera:

$$MAI_p := RMSE_p + RMSE_p^{neg} \quad \forall p \in [50, 100]$$

A partir de aquí, se calcula el percentil p^* tal que $MAI_{p^*} = \min \{MAI_p / p = 2n \quad \forall n \in \mathbb{N} / 24 < n < 51\}$.

Por tanto, se llega al suplemento que refleja la pérdida inesperada evaluando la ecuación (2) sobre a los elementos del conjunto E .

$$\Delta_{p^*}^E(t_i) := ELBE_{t_i}^{E,p^*} - ELBE_{t_i}^{E,50} \quad \forall t_i \in (0, T), i \in \{1, \dots, n\}$$

¹¹ Mixed Adjustment Indicator.

Para asegurar la monotonía, se aplica un ajuste a la curva que además añade conservadurismo a la misma.

$$\widehat{\Delta}_{p^*}^E(t_i) := \max \{ \Delta_{p^*}^E(t_{i-1}), \Delta_{p^*}^E(t_i)/t_i \in (0, T] \wedge i \in \{2, \dots, n\} \}$$

Finalmente, la LGD in-default se determina de la siguiente manera:

$$LGD_{t_i} := ELBE_{t_i}^E - \widehat{\Delta}_{p^*}^E(t_i) \quad \forall t_i \in (0, T), i \in \{1, \dots, n\}$$

Considerando que las curvas estimadas no han de exceder el 100%, ya que dejarían de comprenderse de manera intuitiva, se limitan con este fin. El suplemento de pérdidas inesperadas y la LGD in-default resultantes se presentan en el *Gráfico 2* y *Gráfico 3* que se muestran a continuación:




Gráfico 2. Suplemento de pérdida inesperada de las entidades españolas por tiempo de impago.




Gráfico 3. LGD in-default estimada de las instituciones españolas por tiempo en incumplimiento.

4.2. Aprendizaje automático para la predicción de la ELBE

El modelo de la ELBE resulta el punto de partida para el segundo artículo publicado (2023), utilizando las bases de datos de tres entidades de crédito españolas para obtener la ELBE por año de incumplimiento, como se muestra en el *Gráfico 4*.

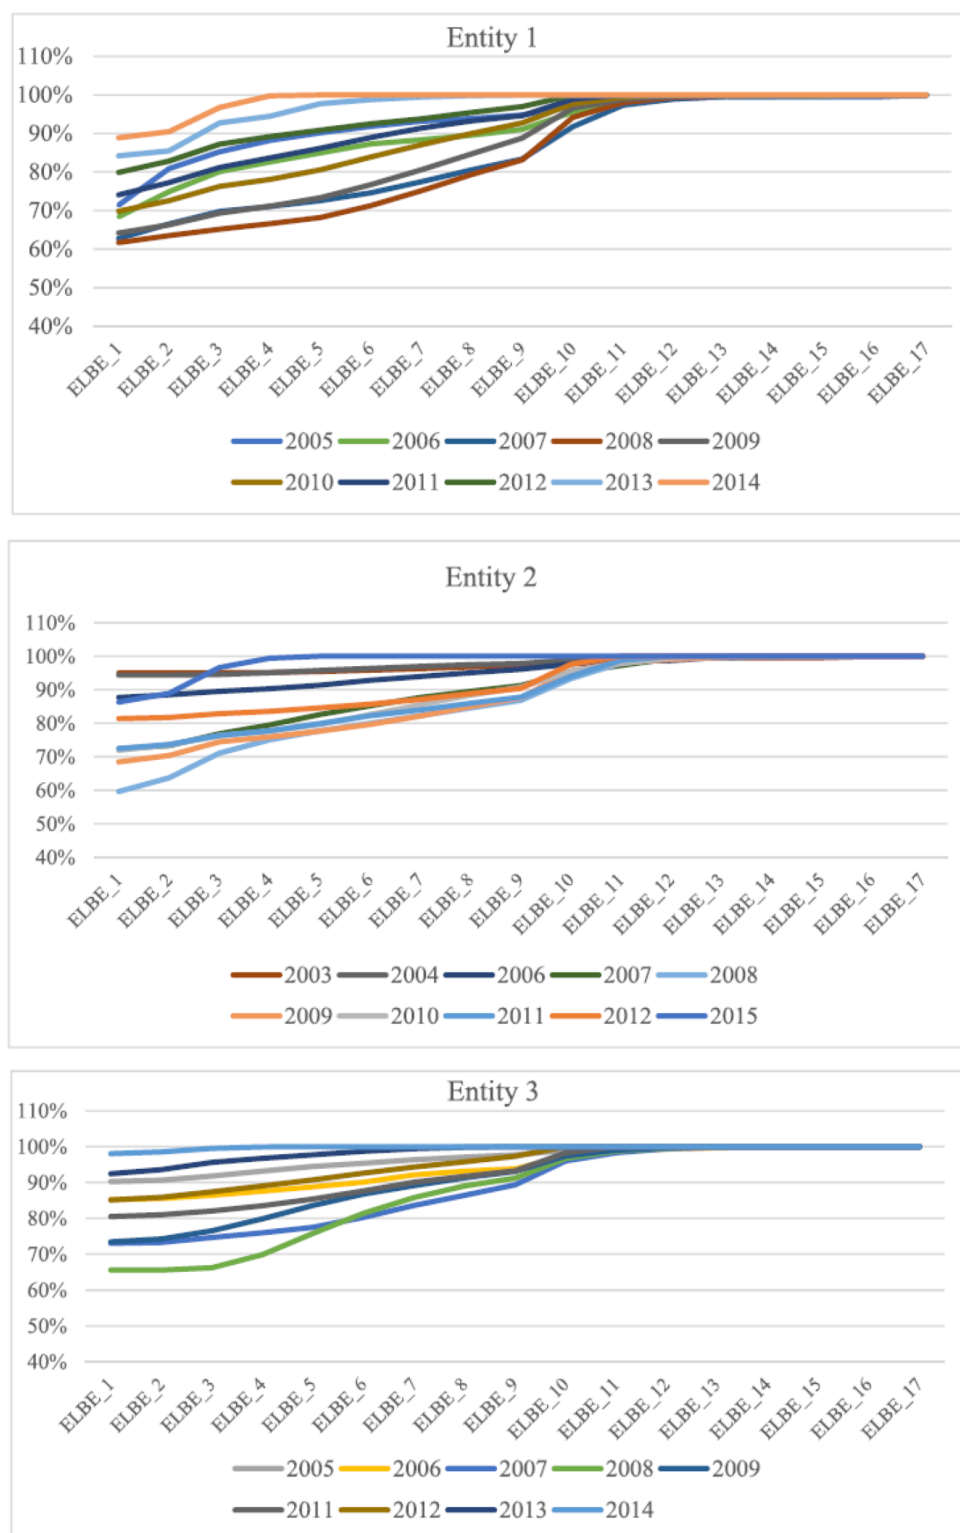


Gráfico 4. ELBE calculada para las instituciones españolas por año de incumplimiento.

Esta ELBE forma una base de datos reducida en tamaño, que se divide en conjuntos de entrenamiento (82%) y testeo (18%) para a la aplicación de un método de aprendizaje automático, o ML. Debido al carácter limitado de los datos, no se puede conseguir otro subconjunto de validación. Sin embargo, con estos datos se logra llevar a cabo una técnica de alto desempeño.

De esta forma, se construye una red neuronal profunda de cinco capas en base a la combinación de dos funciones de activación: las denominadas sigmoideal y PReLU. El método utilizado tiene dos fases. En primer lugar, se lleva a cabo una fase de compensación hacia adelante. Después, se realiza un aprendizaje supervisado con propagación hacia atrás, mediante un algoritmo de descenso de pendiente en lotes.

Para dar con la combinación óptima de las funciones de activación, se testea la precisión del ajuste de la red neuronal, utilizando como referencia una ELBE objetivo. La estructura óptima elegida resulta ser la D que se muestra a continuación, en la *Tabla 1*.

Estructura	Funciones de activación			
	1 ^a	2 ^a	3 ^a	4 ^a
A	Sigmoideal	Sigmoideal	Sigmoideal	Sigmoideal
B	PReLU/ReLU	PReLU/ReLU	PReLU/ReLU	PReLU/ReLU
C	PReLU/ReLU	Sigmoideal	Sigmoideal	Sigmoideal
D	PReLU/ReLU	PReLU/ReLU	Sigmoideal	Sigmoideal

Tabla 1. Funciones de activación propuestas para testeo entre las cinco capas de la red neuronal.

Además, se añade una componente de sesgo que es igual a uno, ya que Buddhtha et al. (2019) demostraron para una estructura de aprendizaje automático similar que la precisión del ajuste mejoraba significativamente al añadir dicha componente.

De esta manera, se construye la estructura que se muestra en el *Gráfico 5*, donde se representa la interacción entre las matrices que forman la red neuronal a lo largo de las cinco capas definidas.

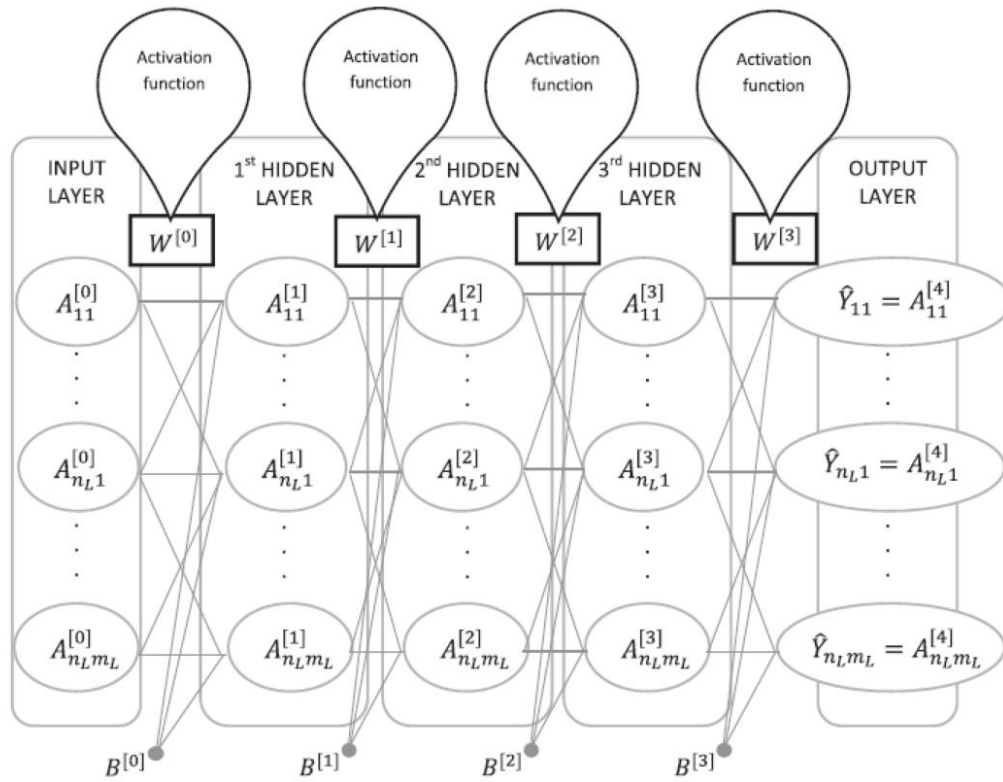


Gráfico 5. Estructura de la red neuronal profunda utilizada en el modelo de aprendizaje automático.

4.2.1. Compensación hacia adelante

La metodología utilizada en la fase de compensación hacia adelante es la que se indica a continuación:

$$Z^{[l]} = W^{[l]}A^{[l-1]} + B^{[l]}$$

$$A^{[l]} = g^{[l]}(Z^{[l]})$$

donde,

$A^{[l]}$ es la matriz de salida de la capa l ;

$g^{[l]}$ es la función de activación de la capa l ;

$Z^{[l]}$ es la matriz salida neta de la capa l ;

$W^{[l]}$ es la matriz de pesos de la capa $l - 1$ a la l ; y

$B^{[l]}$ es la matriz de sesgo de la capa $l - 1$ a la l .

Entonces, la activación de salida es:

$$\hat{Y} = A^{[L]}$$

donde L es la última capa.

El error de salida se calcula en base al error cuadrático medio (MSE por sus siglas en inglés):

$$MSE = \frac{\sum_{i=0}^{n_L} \sum_{j=0}^{m_L} (Y_{ij} - \hat{Y}_{ij})^2}{n_L + m_L}$$

donde,

Y es la matriz de salida objetivo;

n_L es el número de filas de la matriz Y ; y

m_L es el número de columnas en la matriz Y .

En la arquitectura seleccionada hay cinco capas ($L=4$), y las funciones de activación son PReLU y sigmoideal. Ambas se aplican elemento a elemento como se define a continuación respectivamente:

$$A_{ij}^{[l]} = g^{[l]}(Z_{ij}^{[l]}) = \begin{cases} \alpha Z_{ij}^{[l]}, & \text{si } Z_{ij}^{[l]} < 0 \\ Z_{ij}^{[l]}, & \text{si } Z_{ij}^{[l]} \geq 0 \end{cases} \text{ siendo } l = 1, 2 \text{ y } \alpha \in [0, 1)$$

$$A_{ij}^{[l]} = g^{[l]}(Z_{ij}^{[l]}) = \frac{1}{1 + e^{-Z_{ij}^{[l]}}} \text{ siendo } l = 3, 4$$

donde,

i es la fila de la matriz $Z^{[l]}$; y

j es la columna de la matriz $Z^{[l]}$.

Sobre la muestra de entrenamiento, se calcula el ajuste para distintos parámetros α de la función PReLU. A continuación, se evalúa también el ajuste en base a la muestra de testeo. Para ello, se analizan el coeficiente de correlación (CC) y el R cuadrado (R^2), que se definen a continuación:

$$CC = \frac{E[(X - \mu_X)(Y - \mu_Y)]}{\sigma_X \sigma_Y}$$

donde,

σ_X es la variación estándar de la variable X ; y

σ_Y es la variación estándar de la variable Y .

$$R^2 = \frac{\sigma_{XY}^2}{\sigma_X^2 \sigma_Y^2}$$

donde,

σ_{XY} es la covarianza de (X, Y) ;

σ_X^2 es la varianza de la variable X ; y

σ_Y^2 es la varianza de la variable Y .

La bondad del ajuste resultante determina que los parámetros α óptimos para cada entidad son los que se presentan en la *Tabla 2*.

Banco	α
1	0.5
2	0.9
3	0.7

Tabla 2. Factores multiplicativos óptimos, de la función PReLU, por entidad.

4.2.2. Propagación hacia atrás

A continuación, el algoritmo de propagación hacia atrás se aplica para actualizar los pesos en cada iteración, de manera que converjan a una solución donde la salida de la red neuronal profunda se ajuste adecuadamente a la salida objetivo. Los sesgos se van actualizando de la misma manera.

$$\tilde{W}^{[l]} = \tilde{W}^{[l-1]} + d\tilde{W}^{[l]}$$

$$d\tilde{W}^{[l]} := (dW^{[l]}|dB^{[l]})$$

$$dW^{[l]} = -\eta\Delta^{[l]}A^{[l-1]}$$

$$dB^{[l]} = \eta\Delta^{[l]}$$

Considerando que \odot es un operador que indica una multiplicación de matrices elemento a elemento, también llamado producto Hadamard (Neudecker et al, 1995), las siguientes matrices se construyen:

$$\Delta^{[l]} = (Y - \hat{Y}) \odot (1 - Y) \odot Y$$

$$g'(Z^{[l]}) = (1 - A^{[l]}) \odot A^{[l]}, \text{ donde } l = L - 1, L - 2$$

$$g'(Z^{[l]}) = \begin{cases} \alpha, \text{ si } Z_{ij}^{[l]} < 0 \\ 1, \text{ si } Z_{ij}^{[l]} \geq 0 \end{cases} \text{ donde } l = L - 3, L - 4$$

donde,

i es la fila de la matriz $Z^{[l]}$; y

j es la columna de la matriz $Z^{[l]}$.

Por último, la matriz $\Delta^{[l]}$ se construye hacia atrás como se indica a continuación:

$$\Delta^{[l-1]} = W^{[l-1]}\Delta^{[l]} \odot g'(Z^{[l-1]}), \text{ donde } l = 1, \dots, 4$$

4.2.3. Predicción de ELBE en dos escenarios

El modelo se utiliza para predecir la ELBE del año 2022, en base a las variables de entrada que figuran en la *Tabla 3*. La variable de nivel de riesgo es un ranking de entidades construido en base a las estadísticas de tipos de terminación de contrato de cada una, y los indicadores de ciclo económico se generan como combinación lineal de dichas estadísticas.

Categoría	Variable	Definición
Relativa al momento temporal	X_1	Tasa de desempleo (-1 año)
	X_2	Tasa de desempleo (-2 años)

	X_3	Tasa de desempleo (-3 años)
	X_4	Tasa de desempleo (-4 años)
	X_5	Tasa de desempleo (-5 años)
	X_6	Tasa de desempleo (-6 años)
	X_7	Tasa de desempleo (-7 años)
	X_8	Combinación lineal de tasas de desempleo
	X_9	Año de incumplimiento
	X_{10}	Año de observación – Año de incumplimiento
	X_{11}	Nivel de riesgo
Relativa a la entidad	X_{12}	Indicador del ciclo económico [1]
	X_{13}	Indicador del ciclo económico [2]
	X_{14}	Porcentaje de dación en pago y adjudicación
Relativa al momento temporal y a la entidad	X_{15}	Porcentaje de refinanciación
	X_{16}	Porcentaje de otros tipos de terminación
	X_{17}	Combinación lineal de ciertos tipos de terminación

Tabla 3. Definición y categorización de las variables de entrada del modelo ELBE.

Las variables salida del modelo vienen reflejadas en la *Tabla 4*, y corresponden a la predicción de la variable ELBE en una serie de momentos temporales tras el incumplimiento.

Variable	Tiempo de impago
$ELBE_1$	1 mes
$ELBE_2$	2 meses
$ELBE_3$	2 trimestres
$ELBE_4$	3 trimestres
$ELBE_5$	4 trimestres
$ELBE_6$	5 trimestres

$ELBE_7$	6 trimestres
$ELBE_8$	7 trimestres
$ELBE_9$	8 trimestres
$ELBE_{10}$	3 años
$ELBE_{11}$	4 años
$ELBE_{12}$	5 años
$ELBE_{13}$	6 años
$ELBE_{14}$	7 años
$ELBE_{15}$	8 años
$ELBE_{16}$	9 años
$ELBE_{17}$	Más de 10 años

Tabla 4. Definición de las variables de salida del modelo ELBE.

Para predecir la ELBE de 2022, se crean dos escenarios: el primero presupone que a la situación económica de 2022 no se ha visto afectada por la pandemia, y el segundo tiene en cuenta el impacto del brote de la COVID-19. Para este propósito se utilizan las previsiones de las variables de desempleo publicadas por el Banco de España (BdE, 2020), presentadas en la *Tabla 5*, del escenario base y del 3, respectivamente. Al comparar estas previsiones con las del Fondo Monetario Internacional (FMI, 2020) se observa cierta consistencia. El resto de las variables se nutren con la información histórica disponible en torno a la crisis financiera de 2008. Los parámetros resultantes se denominan pre-COVID-19 ELBE y post-COVID-19 ELBE.

Fecha de publicación	Escenarios	Previsiones del BdE		Previsiones del FMI	
		2020	2021	2020	2021
Diciembre 2019	Base	13.70%	13.20%		
	Escenario 1	18.30%	17.50%		
Abril 2020				20.80%	17.50%
	Escenario 2	20.60%	19.10%		
	Escenario 3	21.70%	19.90%		

Tabla 5. Predicciones de la tasa de desempleo en España.

La ELBE resultante para cada entidad, en cada uno de los escenarios propuestos, se presenta en el *Gráfico 6*.

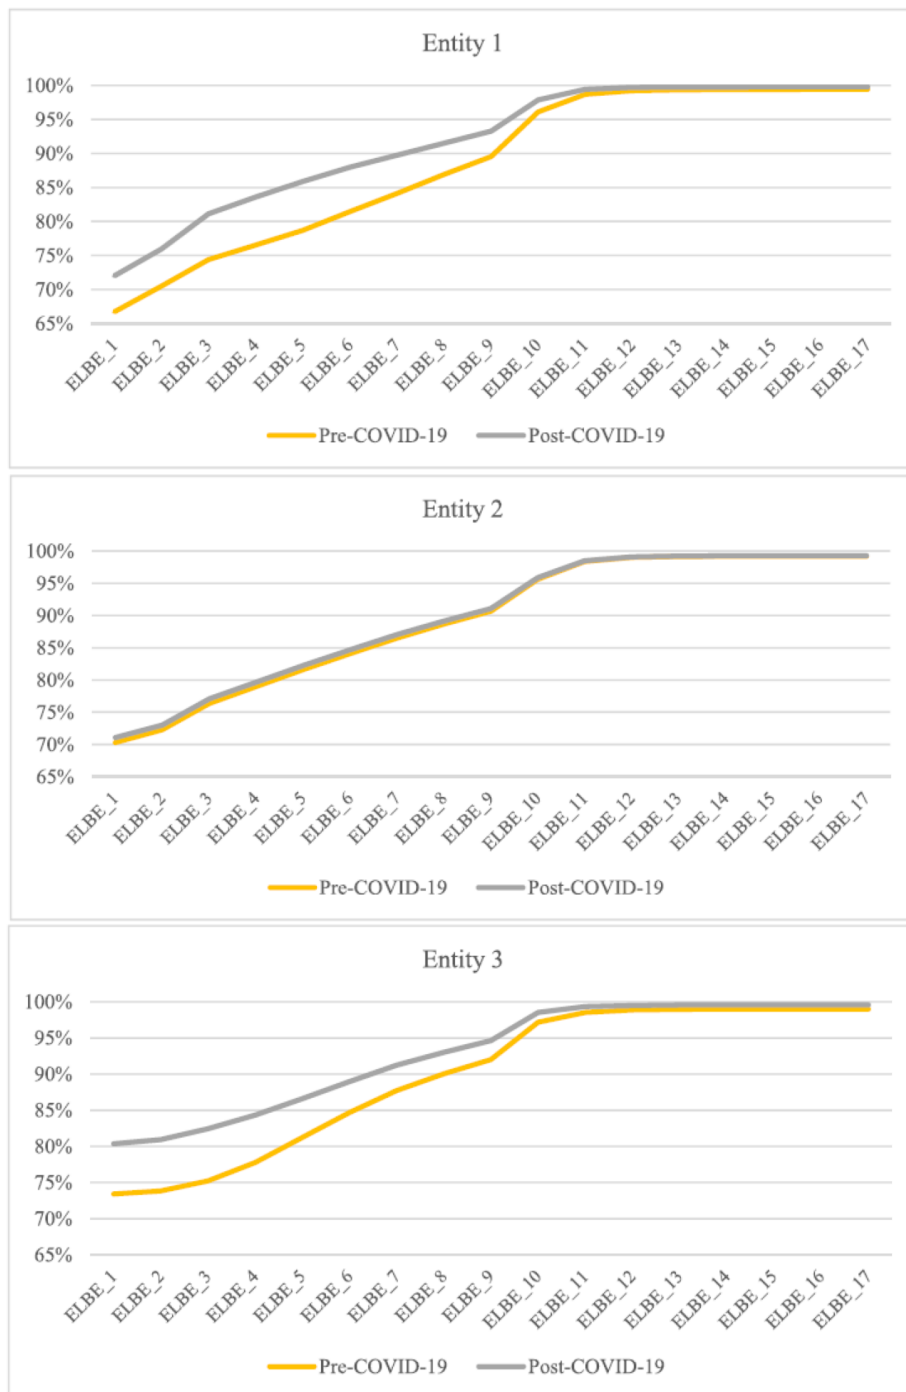


Gráfico 6. ELBE de 2023 por entidad, predicha en base a los dos escenarios descritos.

5. Discusión

Se considera que las metodologías de la ELBE y la LGD in-default propuestas cumplen con las directrices regulatorias, al tener en consideración los siguientes factores:

- La ELBE refleja condiciones económicas recientes, es decir, cercanas a la fecha de referencia.
- La LGD in-default considera efectos potencialmente adversos en las condiciones económicas a lo largo del proceso de recuperación esperado, así como condiciones de recesión económica. A su vez, se le aplica un grado adicional de conservadurismo debido a la monotonía impuesta.
- Como consecuencia de lo anterior, el suplemento de pérdidas inesperadas es siempre mayor que cero.

Por otra parte, se ha conseguido desarrollar un modelo de red neuronal basado en técnicas de ML con muy buen desempeño. Además, se ha demostrado que puede servir de base para predecir dos tipos de ELBE en base a escenarios distintos, uno de ellos basado en condiciones económicas sin precedentes.

Desde un punto de vista cualitativo, la comparación mostrada para cada entidad refleja que el impacto de la pandemia en la ELBE es de mayor o menor medida según la entidad considerada. Por lo tanto, se evidencia que el modelo ha conseguido capturar características intrínsecas a cada institución bancaria.

Como era de esperar, el nivel de la pre-COVID-19 ELBE converge con mucha rapidez al 100%. Esto se debe a que la calidad de las carteras de préstamos impagados es riesgo elevado, y por ello, están asociadas a un gran volumen de pérdida esperada. Sin embargo, todavía se refleja un empeoramiento en la calidad crediticia de la cartera debido al impacto del brote de COVID-19, esto es, un incremento en la pérdida esperada reflejada en la post-COVID-19 ELBE.

6. Conclusiones

A lo largo de la investigación realizada, se realiza una propuesta concreta y novedosa de modelos IRB para exposiciones en impago, en base a las referencias regulatorias que son relevantes para dichos modelos. Aunque ambos ELBE and LGD in-default han sido implementados en base a datos hipotecarios de entidades españolas, la metodología propuesta puede aplicarse fácilmente a otros tipos de cartera.

Por otra parte, el impacto económico de la pandemia de coronavirus todavía sigue presente, determinados agentes económicos no han experimentado aún la recuperación completa. Las medidas aplicadas por muchos gobiernos para paliar su efecto, con la intención de controlar la emergencia sanitaria, llevó a la economía a ralentizarse, y consecuentemente, a un incremento en el desempleo y a impactos adversos en la calidad de los activos de los bancos, tal y como se refleja en la nota temática de la ABE (2020). Este difícil contexto económico se está viendo acentuado con una nueva ola de recesión que se aproxima actualmente.

En medio de esta incertidumbre, el modelo de predicción de la ELBE que se propone es flexible, de manera que se puede adaptar para estimar el impacto de eventos económicos sin precedentes. La metodología que se presenta está apoyada en un algoritmo de ML que puede acomodar distintos escenarios y utilizar varios tipos de variables que, en principio, pueden resultar relevantes para llevar a cabo dicha predicción. Una de las ventajas claras de este tipo de técnicas de aprendizaje automático es que va otorgando de manera automática pesos a las variables, de esta forma, si alguna de ellas resulta ser poco relevante, el propio algoritmo terminará por cancelarla asignándole un peso nulo.

La capacidad de adaptación de la metodología presentada para otro tipo de estimación prospectiva supone una ventaja altamente reseñable para las entidades bancarias, al poder aplicarse para la estimación de provisiones y cálculo de capital regulatorio y económico. Esto supone que, si el uso de esta metodología se extiende a lo largo del sistema bancario, estará más preparado para enfrentarse a desafíos derivados de circunstancias excepcionales. Las predicciones resultantes podrían servir como referencia para reajustar las estrategias bancarias, mitigando así el impacto de una posible crisis, y asegurando una industria financiera más robusta.

Las bases de datos de las carteras de impagados son normalmente limitadas en tamaño. Sin embargo, tal y como se demuestra en esta investigación, es factible desarrollar un modelo de predicción de alto desempeño y con resultados válidos y fiables. Esto se puede conseguir gracias a metodologías basadas en algoritmos ML.

Existe alguna limitación en la investigación llevada a cabo. Cuando se desarrollan modelos con fines regulatorios, es requisito el poder documentarlos de manera que sean entendibles por los supervisores bancarios y por las áreas de control. Sin embargo, las metodologías de aprendizaje automático tienen una complejidad alta de manera inherente, por lo tanto, puede ser difícil lograr una perfecta comprensión de la documentación asociada. En este sentido, el uso de este tipo de metodologías resulta complicado, pero altamente ventajoso, por las razones ya esgrimidas.

7. Bibliografía

- Ahmed, S. and Hammami, H., (2022). Artificial intelligence and machine learning in finance: a bibliometric review. *Research in International Business and Finance*, 61, 101646. <https://doi.org/10.1016/j.ribaf.2022.101646>
- Al-Maadid, A., Alhazbi, S. and Al-Thelaya, K. (2022). Using machine learning to analyze the impact of coronavirus pandemic news on the stock markets in GCC countries. *Research in International Business and Finance*, 61, 101667. <https://doi.org/10.1016/j.ribaf.2022.101667>
- Alonso Robisco, A. and Carbó Martínez, J. M. (2022a). Can machine learning models save capital for banks? evidence from Spanish credit portfolio. *International Review of Financial Analysis*, 84, 102372. <https://doi.org/10.1016/j.irfa.2022.102372>
- Alonso Robisco, A. and Carbó Martínez, J. M. (2022b). Measuring the model risk-adjusted performance of machine learning algorithms in credit default prediction. *Financial Innovation*, 8, 70. <https://doi.org/10.1186/s40854-022-00366-1>
- Altman, E. (1989). Measuring corporate bond mortality and performance. *The Journal of Finance*, 44, 909-922. <https://doi.org/10.1111/j.1540-6261.1989.tb02630.x>
- Altman, E. and Kalotay, A. (2014). Ultimate recovery mixtures. *Journal of Banking and Finance*, 40, 116-129. <https://doi.org/10.1016/j.jbankfin.2013.11.021>
- Altman, E., Resti, A. and Sironi, A. (2004). Default recovery rates in credit risk modelling: A review of the literature and empirical evidence. *Economic Notes*, 33, 183-208. <https://doi.org/10.1111/j.0391-5026.2004.00129.x>
- Altman, E. and Suggit, H. (2000). Default rates in the syndicated bank loan market: A mortality analysis. *Journal of Banking and Finance*, 24, 224-253. [https://doi.org/10.1016/S0378-4266\(99\)00058-8](https://doi.org/10.1016/S0378-4266(99)00058-8)
- Bank of Spain (2020). Escenarios macroeconómicos de referencia para la economía española tras el COVID-19. *Economic Bulletin* 2/2020. <https://www.bde.es/f/webbde/GAP/Secciones/SalaPrensa/COVID-19/be2002-art1.pdf>
- Basel Committee on Banking Supervision (1998). International convergence of capital measurement and capital standards (updated to April 1998).

Basel Committee on Banking Supervision (2006). Basel II: International Convergence of Capital Measurement and Capital Standards. A Revised Framework - Comprehensive Version.

Basel Committee on Banking Supervision (2011). Basel III: A global regulatory framework for more resilient banks and banking systems - revised version June 2011.

Basel Committee on Banking Supervision (2022). RCAP: Basel III implementation dashboard as of 30 September 2022. <https://www.bis.org/temp/panels/smartembed5.htm?hasTabs=true&isResponsive=true&minWidth=500&midWidth=1100&url=https://dataviz.bis.org/t/MED/views/RcapBasel3ImplementationStatus/Overview?:isGuestRedirectFromVizportal=y&embed=y>

Barbaglia, L., Manzan, S. and Tosetti, E. (2021). Forecasting loan default in Europe with machine learning. *Journal of Financial Econometrics*, 21(2), 569-596. <https://doi.org/10.1093/jjfinec/nbab010>

Bastos, J. A. and Matos, S. M. (2022). Explainable models of credit losses. *European Journal of Operational Research*, 301(1), 386–394. <https://doi.org/10.1016/j.ejor.2021.11.009>

Bellotti, A., Brigo, D., Gambetti, P. and Vrins, F. (2021). Forecasting recovery rates on non-performing loans with machine learning. *International Journal of Forecasting*, 37(1), 428–444. <https://doi.org/10.1016/j.ijforecast.2020.06.009>

Betz, J., Kellner, R. and Roesch, D. (2016). What drives the time to resolution of defaulted bank loans? *Finance Research Letters*, 18, 7-31. <https://doi.org/10.1016/j.frl.2016.03.013>

Buddhtha, S., Natasha, C., Irwansyah, E. and Budiharto, W. (2019). Building an artificial neural network with backpropagation algorithm to determine teacher engagement based on the Indonesian teacher engagement index and presenting the data in a web-based GIS. *International Journal of Computational Intelligence Systems*, 12(2), 1575–1584. <https://doi.org/10.2991/ijcis.d.191101.003>

Dermine, J. and Neto de Carvalho, C. (2006). Bank loan losses-given-default: A case study. *Journal of Banking and Finance*, 30, 1219-1243. <https://doi.org/10.1016/j.jbankfin.2005.05.005>

Dermine, J. and Neto de Carvalho, C. (2008). Bank loan-loss provisioning, central bank rules vs. estimation: The case of Portugal. *Journal of Financial Stability*, 4, 1-22. <https://doi.org/10.1016/j.jfs.2007.12.001>

Ernst and Young (2022). Non-performing exposures tracker, Q2 2022. https://assets.ey.com/content/dam/ey-sites/ey-com/en_gl/topics/emeia-financial-services/ey-npe-tracker-q2-2022.pdf?download

European Parliament and Council (2013). Regulation (EU) No 575/2013 of the European Parliament and of the Council of 26 June 2013 on prudential requirements for credit institutions and investment firms and amending Regulation (EU) No 648/2012. <https://eur-lex.europa.eu/legal-content/EN/TXT/PDF/?uri=CELEX:32013R0575&from=EN>

European Banking Authority (2016). Final draft regulatory technical standards on assessment methodology for IRB approach. EBA/RTS/2016/03. <https://www.eba.europa.eu/sites/default/documents/files/documents/10180/1525916/e8373cbc-cc4b-4dd9-83b5-93c9657a39f0/Final%20Draft%20RTS%20on%20Assessment%20Methodology%20for%20IRB.pdf?retry=1>.

European Banking Authority (2017). Guidelines on PD estimation, LGD estimation and treatment of defaulted assets. EBA/GL/2017/16. <https://www.eba.europa.eu/sites/default/documents/files/documents/10180/2033363/6b062012-45d6-4655-af04-801d26493ed0/Guidelines%20on%20PD%20and%20LGD%20estimation%20%28EBA-GL-2017-16%29.pdf?retry=1>.

European Banking Authority , (2020). The EU banking sector: First insights into the COVID-19 impacts. Thematic Note. EBA/REP/2020/17. https://www.eba.europa.eu/sites/default/documents/files/document_library/Risk%20Analysis%20and%20Data/Risk%20Assessment%20Reports/2020/Thematic%20notes/883986/Thematic%20note%20-%20Preliminary%20analysis%20of%20impact%20of%20COVID-19%20on%20EU%20banks%20%28E2%80%93%20May%202020.pdf

European Banking Authority (2022a). Risk Dashboard, data as of Q4 2022. https://www.eba.europa.eu/sites/default/documents/files/document_library/Risk%20Anal

ysis%20and%20Data/Risk%20dashboard/Q4%202022/1054309/EBA%20Dashboard%20-%20Q4%202022.pdf

European Banking Authority (2022b). Risk Dashboard, data as of Q3 2022. https://www.eba.europa.eu/sites/default/documents/files/document_library/Risk%20Analysis%20and%20Data/Risk%20dashboard/Q4%202022/1054309/EBA%20Dashboard%20-%20Q4%202022.pdf

Fenech, J. P., Yap, Y. K. and Shafik, S. (2016). Modelling the recovery outcomes for defaulted loans: A survival analysis approach. *Economic Letters*, 145, 79-82. <https://doi.org/10.1016/j.econlet.2016.05.015>

Financial Stability Institute (2013). Basel II, 2.5 and III Implementation – July 2013. <https://www.bis.org/fsi/fsiop2013.pdf>

García-Céspedes, R. and Moreno, M. (2022). The generalized Vasicek credit risk model: a machine learning approach. *Financial Research Letters*, 47(A), 102669 <https://doi.org/10.1016/j.frl.2021.102669>

Gürtler, M. and Hibbeln, M. (2013). Improvements in loss given default forecasts for bank loans. *Journal of Banking and Finance*, 37(7), 2354-2366. <https://doi.org/10.1016/j.jbankfin.2013.01.031>

Hu, S. and Zhang, Y. (2021). COVID-19 pandemic and firm performance: cross-country evidence. *International Review of Economics and Finance*, 74, 365–372. <https://doi.org/10.1016/j.iref.2021.03.016>

Huck, N. (2019). Large data sets and machine learning: applications to statistical arbitrage. *European Journal of Operational Research*, 278(1), 330–342. <https://doi.org/10.1016/j.ejor.2019.04.013>

International Monetary Fund (2020). World Economic Outlook, April 2020: The great lockdown. <https://www.imf.org/en/Publications/WEO/Issues/2020/04/14/weoapril-2020>

Kaplan, E. I. and Meier, P. (1958). Nonparametric estimation for incomplete observations. *Journal of the American Statistical Association*, 53, 457-481.

- Karadima, M. and Louri, H. (2021). Economic policy uncertainty and non-performing loans: The moderating role of bank concentration. *Finance Research Letters*, 38, Article 101458. <https://doi.org/10.1016/j.frl.2020.101458>
- Li, J.-P., Mirza, N., Rahat, B. and Xiong, D. (2020). Machine learning and credit ratings prediction in the age of fourth industrial revolution. *Technological Forecasting and Social Change*, 161, 120309. <https://doi.org/10.1016/j.techfore.2020.120309>
- Machado, M. R. and Karray, S. (2022). Assessing credit risk of commercial customers using hybrid machine learning algorithms. *Expert Systems with Applications*, 200, 116889. <https://doi.org/10.1016/j.eswa.2022.116889>
- Merton, R. C. (1974). On the pricing of corporate debt: The risk structure of interest rates. *The Journal of Finance*, 29, 449-470. <https://doi.org/10.2307/2978814>
- Moscatelli, M., Parlapiano, F., Narizzano, S. and Viggiano, G. (2020). Corporate default forecasting with machine learning. *Expert Systems with Applications*, 16, 113567. <https://doi.org/10.1016/j.eswa.2020.113567>
- Narayan, P. K. (2021). Understanding exchange rate shocks during COVID-19. *Financial Research Letters*, 45, 102181. <https://doi.org/10.1016/j.frl.2021.102181>
- Neudecker, H., Polasek, W. and Liu, S. (1995). The heteroskedastic linear regression model and the Hadamard product a note. *Journal of Economics*, 68 (2), 361–366. [https://doi.org/10.1016/0304-4076\(94\)01655-J](https://doi.org/10.1016/0304-4076(94)01655-J)
- Ramos González, M., Partal Ureña, A. and Gómez Fernández-Aguado P. (2018). Proposal on ELBE and LGD in-default: Tackling capital requirements after de financial crisis. *European Central Bank Working Paper Series No. 2165*. <https://www.ecb.europa.eu/pub/pdf/scpwps/ecb.wp2165.en.pdf>
- Ramos González, M., Partal Ureña, A. and Gómez Fernández-Aguado, P. (2021). Regulatory estimates for defaulted exposures: a case study of Spanish mortgages. *Mathematics*, 9(9), 997. <https://doi.org/10.3390/math9090997>
- Ramos González, M., Partal Ureña, A. and Gómez Fernández-Aguado, P. (2023). Forecasting for regulatory credit loss derived from the COVID-19 pandemic: A machine learning approach.

Research in International Business and Finance, 64, 101907.
<https://doi.org/10.1016/j.ribaf.2023.101907>

Samuel, A.L. (1959). Some studies in machine learning using the game of checkers. *IBM Journal of Research and Development*, 44, 206-226. <https://doi.org/10.1147/rd.33.0210>

Seetharaman, P. (2020). Business models shifts: Impact of COVID-19. *International Journal of Information Management*, 54, 102173. <https://doi.org/10.1016/j.ijinfomgt.2020.102173>

Sharif, A., Aloui, C. and Yarovaya, L. (2020). COVID-19 pandemic, oil prices, stock market, geopolitical risk and policy uncertainty nexus in the US economy: Fresh evidence from the wavelet-based approach. *International Review of Financial Analysis*, 70, 101496. <https://doi.org/10.1016/j.irfa.2020.101496>

Skansi, S. (2018). *Introduction to deep learning*. Springer. <https://doi.org/10.1007/978-3-319-73004-2>

O'Donoghue, C., Sologon, D. M., Kyzyma, I. and McHale, J. (2020). Modelling the distributional impact of the COVID-19 crisis. *Fiscal Studies*, 41(2), 321–336. <https://ftp.iza.org/dp13235.pdf>

Organisation for Economic Co-operation and Development (2021). *The COVID-19 crisis and banking system resilience: Simulation of losses on non-performing loans and policy implications*. <https://www.oecd.org/daf/fin/financial-markets/COVID-19-crisis-and-banking-system-resilience.pdf>

Weissbach, R. and Von Lieres und Wilkau, C. (2010). Economic capital for non-performing loans. *Financial Markets and Portfolio Management*, 24(1), 67-85. <https://ssrn.com/abstract=1626373>

Yu, B., Li, C., Mirza, N. and Umar, M. (2021). Forecasting credit rating of decarbonized firms: comparative assessment of machine learning models. *Technological Forecasting and Social Change*, 174, 121255. <https://doi.org/10.1016/j.techfore.2021.121255>

Yu, L., Huang, X. and Yin, H. (2020). Can machine learning paradigm improve attribute noise problem in credit risk classification? *International Review of Economics and Finance*, 70, 440-455. <https://doi.org/10.1016/j.iref.2020.08.016>

Zhang, J. and Thomas, L. C. (2012). Comparisons of linear regression and survival analysis using single and mixture distributions approaches in modelling LGD. *International Journal of Forecasting*, 28, 204-215. <https://doi.org/10.1016/j.ijforecast.2010.06.002>

8. Publicaciones

Las tres publicaciones que componen la presente tesis doctoral en modalidad de compendio están descritas a continuación.

8.1. Tackling capital requirements after de financial crisis

Referencia

Ramos González, M., Partal Ureña, A. and Gómez Fernández-Aguado P. (2018). Proposal on ELBE and LGD in-default: Tackling capital requirements after de financial crisis. European Central Bank Working Paper Series No. 2165.

Resumen

Tras la crisis financiera iniciada en 2008, el volumen de préstamos impagados aumentó significativamente. Al mismo tiempo, las directrices normativas relativas a métodos IRB para el cálculo de capital asociado a exposiciones en mora estaban escritas en términos muy generales. Bajo estas circunstancias, estas carteras de impagados, que son de alto riesgo, corren peligro de ser gestionadas de forma heterogénea e inadecuada por las entidades financieras que han sido autorizadas para utilizar el sistema IRB, con la consiguiente variabilidad indebida de los Activos Ponderados por Riesgo. Este artículo presenta una propuesta de modelos IRB Avanzados para préstamos en mora, en línea con la normativa vigente, que reflejan adecuadamente el riesgo de crédito asociado. Se obtienen los dos parámetros ELBE y LGD in-default, respaldados por un indicador innovador, denominado Mixed Adjustment Indicator (MAI), que se introduce para asegurar una adecuada estimación. La metodología presentada es de baja complejidad y se puede aplicar sobre las bases de datos comúnmente utilizadas en las instituciones de crédito, tal y como se ilustra con dos ejemplos.

Fecha de publicación: 28 junio 2018

Estado: Publicado

Categoría: Investigación económica

Tipo de publicación: Documento de trabajo

Ubicación: <https://www.ecb.europa.eu/pub/pdf/scpwps/ecb.wp2165.en.pdf>

8.2. Regulatory estimates for defaulted exposures

Referencia

Ramos González, M., Partal Ureña, A. and Gómez Fernández-Aguado, P. (2021). Regulatory estimates for defaulted exposures: a case study of Spanish mortgages. *Mathematics*, 9(9), 997.

Resumen

Los requerimientos de capital derivados del Acuerdo de Basilea fueron emitidos para establecer un marco regulatorio transnacional. En este marco, se han publicado expectativas sobre la medición del riesgo financiero en varios documentos de la ABE y el BCE. Entre otros temas, incluyen especificaciones sobre la estimación y calibración de modelos para la medición del riesgo de crédito, haciendo especial referencia a modelos IRB Avanzados para activos en situación de incumplimiento. En base a ello, se presenta una propuesta concreta de ELBE y LGD in-default que se calibra sobre las base de datos de las carteras de hipotecas de las seis instituciones financieras más importantes de España. El resultado permite comparar las particularidades del perfil de riesgo asociado a cada una de las carteras referidas. Finalmente, se da una interpretación a los resultados obtenidos desde el punto de vista económico.

Fecha de publicación: 28 abril 2021

Estado: Publicado

Categoría: Matemáticas

Tipo de publicación: Artículo

Ubicación: <https://doi.org/10.3390/math9090997>

8.3. Forecasting for regulatory credit loss derived from the COVID-19 pandemic

Referencia

Ramos González, M., Partal Ureña, A. and Gómez Fernández-Aguado, P. (2023). Forecasting for regulatory credit loss derived from the COVID-19 pandemic: A machine learning approach. *Research in International Business and Finance*, 64, 101907.

Resumen

El impacto económico de la pandemia de COVID-19 supuso un desafío de cara a la gestión de riesgos en las instituciones financieras. Las consecuencias derivadas de una situación sin precedentes son difíciles de prever con certeza utilizando métodos tradicionales. La pérdida crediticia regulatoria, la ELBE, se pronostica para la cartera hipotecaria utilizando técnicas de aprendizaje automático. De esta manera, se estima la proyección de dos ELBE para el 2022: la primera tiene en cuenta el impacto de este contexto pandémico, mientras que para la segunda se presupone la inexistencia de la pandemia. Finalmente, se comparan los resultados concluyendo que la referida crisis afecta negativamente incluso a las carteras de impagados, a pesar de ser de alto riesgo por naturaleza. Además, se observa que la magnitud del impacto depende de la idiosincrasia de cada entidad. El método propuesto tiene un rendimiento excelente y puede ser de utilidad para la estimación de pérdidas esperadas e inesperadas que se han visto afectadas por eventos de extraordinaria magnitud.

Fecha de publicación: 16 febrero 2023

Estado: Publicado

Categoría: Finanzas internacionales

Tipo de publicación: Artículo

Ubicación: <https://doi.org/10.1016/j.ribaf.2023.101907>