



UNIVERSIDAD  
DE MÁLAGA

UNIVERSIDAD DE MÁLAGA  
ESCUELA DE INGENIERÍAS INDUSTRIALES

PROGRAMA DE DOCTORADO EN INGENIERÍA MECÁNICA Y  
EFICIENCIA ENERGÉTICA

**MODELOS DE PREDICCIÓN DE CRISIS FINANCIERAS  
INTERNACIONALES CON TÉCNICAS DE APRENDIZAJE  
AUTOMÁTICO: APLICACIONES A LA REPUTACIÓN PAÍS**

Doctorando: David Alaminos Aguilera

**Tesis Doctoral**

Dirigida por:

Dr. José Ignacio Peláez Sánchez

Dr. Manuel Ángel Fernández Gámez


ABRIL DE 2021





UNIVERSIDAD  
DE MÁLAGA

AUTOR: David Alaminos Aguilera

 <https://orcid.org/0000-0002-2846-5104>

EDITA: Publicaciones y Divulgación Científica. Universidad de Málaga



Esta obra está bajo una licencia de Creative Commons Reconocimiento-NoComercial-SinObraDerivada 4.0 Internacional:

<http://creativecommons.org/licenses/by-nc-nd/4.0/legalcode>

Cualquier parte de esta obra se puede reproducir sin autorización pero con el reconocimiento y atribución de los autores.

No se puede hacer uso comercial de la obra y no se puede alterar, transformar o hacer obras derivadas.

Esta Tesis Doctoral está depositada en el Repositorio Institucional de la Universidad de Málaga (RIUMA): [riuma.uma.es](http://riuma.uma.es)



Dr. José Ignacio Peláez Sánchez, Catedrático de la Universidad de Málaga

**Informa:**

Como tutor, da el visto bueno a la presentación para la defensa de la tesis doctoral de D. David Alaminos Aguilera titulada "Modelos de predicción de crisis financieras internacionales con técnicas de aprendizaje automático: Aplicaciones a la reputación país" conforme con lo requerido en el Programa de Doctorado de Ingeniería Mecánica y Eficiencia Energética.

Lo que se hace constar a los efectos oportunos en Málaga a 12 de abril de 2021.

Atentamente,

A handwritten signature in black ink, appearing to read 'Peláez S.', with a horizontal line underneath.

Fdo.: Dr. José Ignacio Peláez Sánchez



UNIVERSIDAD  
DE MÁLAGA



Escuela de Doctorado

## DECLARACIÓN DE AUTORÍA Y ORIGINALIDAD DE LA TESIS PRESENTADA PARA OBTENER EL TÍTULO DE DOCTOR

D./Dña DAVID ALAMINOS AGUILERA

Estudiante del programa de doctorado INGENIERÍA MECÁNICA Y EFICIENCIA ENERGÉTICA de la Universidad de Málaga, autor/a de la tesis, presentada para la obtención del título de doctor por la Universidad de Málaga, titulada: **MODELOS DE PREDICCIÓN DE CRISIS FINANCIERAS INTERNACIONALES CON TÉCNICAS DE APRENDIZAJE AUTOMÁTICO: APLICACIONES A LA REPUTACIÓN PAÍS**

Realizada bajo la tutorización de JOSÉ IGNACIO PELÁEZ SÁNCHEZ y dirección de JOSÉ IGNACIO PELÁEZ SÁNCHEZ Y MANUEL ÁNGEL FERNÁNDEZ GÁMEZ (si tuviera varios directores deberá hacer constar el nombre de todos)

DECLARO QUE:

La tesis presentada es una obra original que no infringe los derechos de propiedad intelectual ni los derechos de propiedad industrial u otros, conforme al ordenamiento jurídico vigente (Real Decreto Legislativo 1/1996, de 12 de abril, por el que se aprueba el texto refundido de la Ley de Propiedad Intelectual, regularizando, aclarando y armonizando las disposiciones legales vigentes sobre la materia), modificado por la Ley 2/2019, de 1 de marzo.

Igualmente asumo, ante a la Universidad de Málaga y ante cualquier otra instancia, la responsabilidad que pudiera derivarse en caso de plagio de contenidos en la tesis presentada, conforme al ordenamiento jurídico vigente.

En Málaga, a 11 de ABRIL de 2021

Fdo.: DAVID ALAMINOS AGUILERA



Edificio Pabellón de Gobierno. Campus El Ejido.  
29071

Tel.: 952 13 10 28 / 952 13 14 61 / 952 13 71 10  
E-mail: doctorado@uma.es



JOSÉ IGNACIO PELÁEZ SÁNCHEZ y MANUEL ÁNGEL FERNÁNDEZ GÁMEZ, Catedrático del Departamento de Lenguajes y Ciencias de la Computación y Profesor Titular de Finanzas y Contabilidad, respectivamente, de la Universidad de Málaga.

Certificamos:

Que bajo nuestra dirección, D. David Alaminos Aguilera, licenciado en Economía, licenciado en Ciencias Actuariales y Financieras, Máster en Análisis Económico y Empresarial y Doctor en Economía y Empresa, ha realizado el trabajo de investigación correspondiente a su tesis doctoral titulada:

**"MODELOS DE PREDICCIÓN DE CRISIS FINANCIERAS INTERNACIONALES CON TÉCNICAS DE APRENDIZAJE AUTOMÁTICO: APLICACIONES A LA REPUTACIÓN PAÍS"**

Revisado el mismo, estimamos que puede ser presentado al Tribunal que ha de juzgarlo.

Y, para que conste a efectos de lo establecido en la normativa vigente, autorizamos la presentación de esta Tesis en la Universidad de Málaga.

Málaga a 12 de abril de 2021.



Fdo. José I. Peláez Sánchez

Fdo. Manuel Á. Fernández Gámez





*"Laissez faire et laissez passer, le monde va de lui  
même"*

Vincent de Gournay





Después de años de esfuerzo y sacrificio es gratificante observar cómo ha llegado el momento de finalizar esta tesis doctoral, que ha supuesto tal vez el mayor reto de mi vida hasta la fecha. Con ello, se cierra una etapa donde me propuse retos diferentes a los que había tenido anteriormente, que provocasen que saliese de mi zona de confort de estudio. Creo que esta tesis y este programa de doctorado han demostrado esa exigencia programada, sobre todo, al ser un campo de conocimiento muy diferente al mío. Al igual que en mi tesis de Economía, donde supuso un proceso de madurez personal, el presente caso salta de nivel al respecto. Como había comentado, la finalización de esta tesis no solo significa la culminación de un título académico sino seguramente el final de mi etapa como estudiante. Aunque seguiré de por vida "estudiando", ya que es mi forma de ver la vida, haciendo trabajos de investigación, que se ha convertido en unas de mis grandes pasiones. Pero una vez realice la lectura de esta tesis, comenzará un nuevo punto en mi camino personal, en el que podré mirar atrás para disfrutar de mis logros, y de igual forma, lo aprendido en mis errores cometidos en estos años como parte de mi aprendizaje continuo para ser mejor académico y mejor persona.

Me gustaría empezar dando las gracias a mis directores de tesis, en especial a Manuel Ángel Fernández, el cual tiene gran parte de culpa de mi tesis, como también en el caso de mi tesis anterior. Este trabajo es una demostración de nuestra obsesión por seguir conquistando nuevos horizontes, por muy exóticos que sean. Te estaré eternamente agradecido por esta maravillosa oportunidad y por continuar confiando en mí. También gracias a José Ignacio Peláez Sánchez por su paciencia y ayuda tanto como director como también tutor. Gracias por tu ayuda y por todos tus valiosos consejos.

Muchas gracias al Departamento de Lenguajes y Ciencias de la Computación por acogerme. Pero también sigo y seguiré agradeciendo al Departamento de Finanzas y Contabilidad el haberme acogido desde hace muchos años. Gracias por vuestro apoyo sincero y por aceptarme como uno más de la familia. Gracias por los bonitos momentos y experiencias que he podido vivir con vosotros. Sois grandes profesionales, pero, sobre todo, grandes personas.

Gracias a todas aquellas personas que han ejercido alguna influencia en mi trayectoria académica. Tanto aquéllas que en este momento recuerdo como a las que no. Tanto aquéllas que están como que ya, por desgracia, no están. Porque todos habéis participado en que no dejara de luchar por mis sueños. Porque todos habéis dejado vuestra pequeña huella en la persona que soy hoy y que me ha llevado hasta aquí. De corazón, gracias.

Por último, no podría olvidarme de mi familia. Gracias a mis padres y a mi hermana, las personas más importantes de mi vida, por estar siempre ahí, cuando más lo he necesitado, por apoyarme y soportarme, en ésta, mi mayor aventura. Os quiero y siempre lo haré.





# Índice

<b>RESUMEN.....</b>	<b>16</b>
<b>INTRODUCCIÓN.....</b>	<b>22</b>
<b>RESULTADOS .....</b>	<b>36</b>
<b>DISCUSIÓN.....</b>	<b>72</b>
<b>CONCLUSIONES .....</b>	<b>80</b>
<b>BIBLIOGRAFÍA.....</b>	<b>88</b>
<b>PUBLICACIONES .....</b>	<b>106</b>



# RESUMEN





Durante las últimas dos décadas, académicos de los campos del marketing y las relaciones públicas han prestado cada vez más atención a la reputación nacional. La marca país está definida por la combinación única y multidimensional de elementos que proporciona a la nación una diferenciación económica y cultural relevante para todos sus públicos objetivo.

Por otro lado, el fenómeno de la globalización ha provocado un aumento de la competencia corporativa, pero también entre los países. Ahora, éstos compiten por crear un mayor flujo de exportaciones, atraer más turistas e incrementar las inversiones extranjeras directas. Para ello, las instituciones públicas están empezando a utilizar métodos para mejorar la reputación de sus países. De esta manera, intentar establecer una ventaja competitiva sobre el resto de los países, sobre la base de que una reputación país fuerte puede contribuir al desarrollo sostenible. En la misma línea, se ha podido comprobar que la literatura previa ha relacionado la actuación financiera de un país con su reputación, principalmente, desde un punto de vista basado en el consumidor. Estos autores han puesto de manifiesto la necesidad de incorporar datos y variables sobre la estabilidad financiera de los países como una dimensión de la citada reputación país.

La presente tesis doctoral se focaliza en los tres aspectos más importantes de la dimensión financiera de la reputación país: la crisis de deuda soberana, la crisis de divisas y la crisis del sistema bancario. La literatura sobre la predicción de eventos de crisis financieras internacionales ha sido desarrollada principalmente con muestras reducidas y formadas por economías emergentes, ya que suelen ser países más vulnerables, y que estadísticamente, han sufrido una mayor frecuencia de crisis. No obstante, ha habido algunos intentos por crear modelos globales, pero han sido

construidos sólo para predecir situaciones en economías emergentes, incluyendo pocas economías avanzadas. Aun así, se demanda más investigación sobre modelos globales, relacionada con el incremento en la precisión y en el alcance de la información utilizada, ya que los trabajos que han obtenido altos niveles de precisión han utilizado muestras muy reducidas. Muchos de estos trabajos presentan, además, carencias sobre comparativas metodológicas que permitan encontrar la técnica empírica más apropiada para la predicción de este tipo de crisis.

Por este motivo, la presente tesis estudia el factor de estabilidad financiera como dimensión de la reputación país, a través de los modelos de predicción de crisis financieras internacionales creados en esta tesis. Por tanto, se trata de responder a cuestiones de investigación sobre la posibilidad de crear modelos capaces de predecir perfectamente dichos eventos de crisis y su influencia en la reputación país. Para aumentar la precisión de estos modelos de predicción se han tenido en cuenta técnicas computacionales que han arrojado excelentes resultados en la predicción económica. Para ofrecer una mayor diversidad explicativa y comparativa, se han desarrollado, además, tanto modelos globales como modelos regionales para África y Oriente Próximo, Asia, América Latina y Europa. Los resultados así obtenidos han sido objeto de tres publicaciones que integran la presente tesis doctoral en modalidad de compendio. La publicación "Sovereign Debt and Currency Crises Prediction Models using Machine Learning Techniques" (Alaminos, Peláez, Salas y Fernández-Gámez, 2021) utiliza diversas metodologías computacionales y compara sus niveles de precisión con datos de crisis de deuda soberana y de divisas, aplicando muestras de las regiones más importantes del mundo y un modelo global. Por su parte, la publicación "Currency Crises Prediction Using Deep Neural Decision Trees" (Alaminos, Becerra-Vicario, Fernández-

Gámez y Cisneros-Ruiz, 2019) construye modelos de predicción de crisis de divisas con metodología Deep Neural Decision Trees para varias regiones del mundo. Por último, la publicación "Predicting Systemic Banking Crises using Extreme Gradient Boosting" (Alaminos, Fernández-Gámez, Santos y Campos Soria, 2019) construye modelos de predicción de crisis de sistema bancario usando la técnica Extreme Gradient Boosting.



# INTRODUCCIÓN



La globalización ha causado competencia no sólo entre corporaciones multinacionales sino también entre naciones. Como afirma Anhholt (2002), "la globalización está convirtiendo al mundo en un supermercado gigantesco" donde los países compiten para estimular sus exportaciones, atraer el turismo, las inversiones extranjeras directas y la inmigración. Y en este contexto los gobiernos están recurriendo a técnicas de reputación para diferenciar a su país en la escena mundial a fin de establecer una ventaja competitiva sobre los países rivales (Kleppe y Mossberg, 2006).

Recientemente, diversos autores han demostrado la importancia de la influencia de la reputación del país de origen de una empresa para la comercialización internacional de sus productos, siendo incluso tan importante para la empresa como las propias señales de sostenibilidad que sus productos muestra al mercado (Cowan y Guzmán, 2020). Por ejemplo, las empresas energéticas son especialmente sensibles a la solvencia financiera de los países en los que presentan sus cuentas anuales.

A medida que las marcas corporativas agregan valor a los productos y servicios ofrecidos por la compañía, las marcas nacionales favorables pueden proporcionar a las naciones una ventaja competitiva en el mercado global (Anholt, 2002, 2007). Aunque una marca nacional tiene dimensiones y partes interesadas más complejas que una marca corporativa, muchos académicos reconocieron que una marca nacional también se puede administrar y mejorar (Anholt, 2007; Fan, 2010). Sin embargo, mientras que la marca corporativa se estudia extensamente, la marca nacional todavía se está examinando tanto conceptual como empíricamente. Según Fan (2010), el propósito de la marca nacional es mejorar la reputación del país. Fan (2010) sugirió distinguir entre identidad nacional e identidad de marca nacional. La identidad nacional se



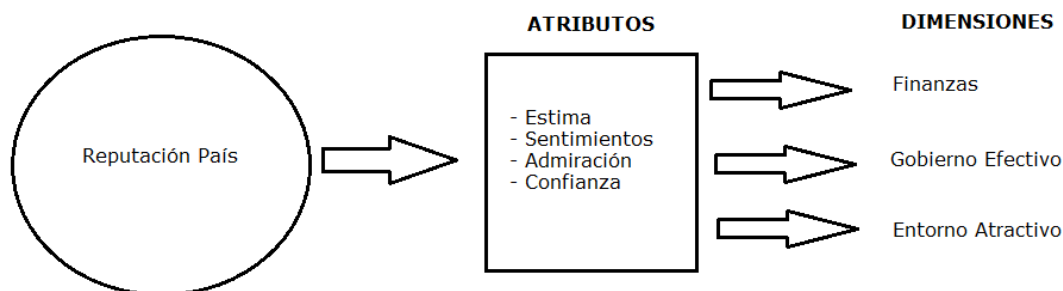
define por personas dentro de la nación, mientras que la identidad de marca de la nación se define por personas fuera de la nación. Así mismo argumenta que la marca nacional debe referirse a la imagen y a la reputación de las naciones en poder de los extranjeros, y la define como "un proceso mediante el cual las imágenes de una nación se pueden crear o alterar, monitorear, evaluar y administrar de manera proactiva para mejorar la reputación del país entre un público internacional objetivo" (p. 101). Por su parte, la reputación del país se encuentra en el centro de la marca nacional. La reputación del país a menudo se usa indistintamente con la imagen del país (Kleppe y Mossberg, 2006), y también para describir la marca nacional, la marca de destino y el marketing de lugar (Passow, Fehlmann y Grahlow, 2005).

Por lo tanto, la investigación de los factores que influyen y están influenciados por la reputación del país puede contribuir a una mejor comprensión de la marca nacional. Varios académicos inicialmente sugirieron una influencia bidireccional entre la reputación del país y la reputación corporativa (Nebenzahl, Jaffe y Lampert, 1997), y algunos estudios han explorado cómo influye la reputación del país en la reputación de las corporaciones de ese país (Fombrun, Ponzi, y Newbury, 2015). Sin embargo, sólo unos pocos estudios examinaron el otro lado de la moneda, a saber, la influencia de la reputación corporativa en la reputación del país (López, Gotsi y Andriopoulos, 2009).

Los países de buena reputación suelen atraer más inversiones (Cowan y Guzmán, 2020) y ostentan ventajas competitivas (Anholt, 2016). En este contexto, Reputation Institute (2017) declaró que los países se benefician de una sólida reputación a través de los siguientes factores: a) Más turistas. Numerosos estudios han abordado los efectos sobre el sector turístico (Fullerton y Kendrick,

2017). En todos ellos, esta hipótesis se apoya en que los países con mejor reputación atraen más turismo. b) Mejora de la diplomacia pública. Con respecto a la relación "marca nacional-diplomacia pública", Szondi (2008) afirma que existe una similitud entre ambos conceptos, ya que comparten el objetivo de mejorar la imagen de un país, aunque los enfoques para su desarrollo están lejos de ser coincidentes. En su importante trabajo de revisión, el autor concluye que una buena reputación país mejora la imagen y las posibilidades de diplomacia internacional (Simonin, 2008). c) Atraer conocimiento y talento. La reputación del país puede llevar a un posible empleado a trabajar en él. Harvey y Groutsis (2015) destacan que la reputación de los países es una variable clave en la atracción y retención de los mejores empleados. d) Aumento de las exportaciones/inversión extranjera. Kim (2016) argumenta que algunas corporaciones con reputación favorable en el país pueden tener ventajas competitivas en el mercado global a pesar de su baja reputación corporativa. Por el contrario, las corporaciones pertenecientes a países con reputación desfavorable intentan superar sus asociaciones con los países centrándose en la reputación corporativa (Dimitrova, Korschun y Yotov, 2017). La figura 1 ilustra las principales dimensiones que conforman la reputación país.

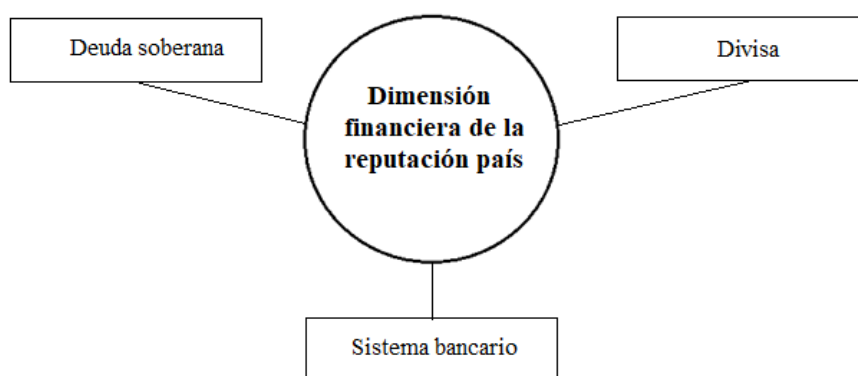
**FIGURA 1. LA REPUTACIÓN PAÍS Y SUS DIMENSIONES**



Fuente: Elaboración propia a partir de la información de Reputation Institute (2017)

La dimensión de la reputación país que hace referencia a situación financiera ha sido resaltada (Leiva-Soto, 2014; Mariutti y Tech, 2015; Teodorović y Popesku, 2016; Amador y Phelan, 2018; Papadopoulos, Ibrahim, De Nisco y Napolitano, 2018; Melnyk y Varibusova, 2019). Estos autores han manifestado la necesidad de incorporar datos y variables sobre la estabilidad financiera de los países como un factor más de importancia de la reputación del país. La figura 2 resume los componentes que, a su vez, formarían parte de la dimensión financiera de la reputación país.

**FIGURA 2. DIMENSIÓN FINANCIERA DE LA REPUTACIÓN PAÍS**



Fuente: Elaboración propia

En los estudios previos que han abordado la referida dimensión financiera de la reputación país destacan dos principales líneas de investigación. Por un lado, los que tienen por objetivo elaborar un modelo de predicción para pronosticar crisis en algunos de los componentes mencionados. Estos son, con diferencia, la mayor parte de los trabajos. Dentro de este grupo podrían incluirse también aquéllos que proponen modelos de "advertencia temprana", y que anticipan los sucesos de crisis. Por otro lado, también se ha constatado que en la última década han ido surgiendo estudios que proponen modelos globales para la predicción de dichas crisis. Estos

modelos, por lo general, han buscado los factores determinantes de crisis en países de una región geográfica relativamente amplia.

En lo que respecta a la crisis de deuda soberana, los estudios previos se han centrado principalmente en países emergentes (Sarlin, 2011; Boonman, Jacobs y Kuper, 2015; Dufrénot y Paret, 2018; Dsoulia, Khanb, Kakabadseb y Skouloudis, 2018). También, algunos han abordado los países emergentes y en vías de desarrollo (Savona y Vezzoli, 2015; Arazmuradov, 2016). Finalmente, Dawood, Horsewood y Strobel (2017) y Alaminos et al. (2019a) modelizaron el impago de deuda pública para predecirlo tanto por diferentes regiones (África, América Latina, Asia y Europa) como de forma global. Entre ellos, Manasse y Roubini (2009) demostraron que no todas las crisis son iguales: difieren según si el gobierno enfrenta insolvencia, falta de liquidez o varios riesgos macroeconómicos. También caracterizaron el conjunto de elementos fundamentales que pueden asociarse con una zona relativamente "libre de riesgos". Esta clasificación es importante para discutir las opciones de políticas adecuadas para prevenir crisis y mejorar el tiempo de respuesta.

En cuanto a los métodos utilizados, un considerable número de investigadores han aplicado métodos estadísticos para la predicción de la crisis de deuda soberana, destacando el modelo logit (Lukkezen y Rojas-Romagosa, 2016; Dawood, Horsewood y Strobel, 2017; Dufrénot y Paret, 2018). Igualmente, los autores Savona y Vezzoli (2015) y Boonman, Jacobs y Kuper (2015) usaron modelos de regresión, Fioramanti (2008) aplicaron redes neuronales artificiales (RNA), y Sarlin (2011) desarrolla la aplicación del mapa de autoorganización (SOM), una herramienta de visualización basada en RNA. Entre ellos, Fioramanti (2008) concluye que, gracias a la alta flexibilidad de las RNA y su capacidad para aproximarse a una relación no lineal, un sistema de alerta temprana basado en RNA

puede, en ciertas condiciones, superar a los métodos más convencionales. Por su parte, Sarlin (2011) demuestra que SOM es una herramienta viable para monitorear los indicadores de los incumplimientos soberanos, facilitando el análisis de datos financieros multidimensionales.

Por su parte, entre las variables más significativas en estos modelos de predicción de crisis de deuda soberana, destacan las relacionadas con la apertura comercial, la deuda exterior a corto plazo y el nivel de reservas (Ciarlone y Trebeschi, 2005). Fioramanti (2008) señala como variables explicativas el crecimiento del PIB, la rentabilidad de la letra del tesoro de EE.UU. y el nivel de deuda externa sobre el total de las reservas. Otros autores han demostrado que la tasa de interés de la Reserva Federal de EE.UU. desempeña un papel importante en el aumento de la probabilidad de incumplimiento (Savona y Vezzoli, 2015; Arazmuradov, 2016). Por último, Dawood, Horsewood y Strobel (2017) muestran que la deuda total del país, el tipo de interés global y la cuenta corriente en la balanza de pagos son los principales determinantes de los incumplimientos de los países a nivel global.

Finalmente, y en referencia a los niveles de precisión, los estudios previos sobre predicción de crisis de deuda soberana se han situado en diferentes niveles. Alrededor del 80%, los estudios de Fuertes y Kalotychoy (2007), Arazmuradov (2016) y Dufrénot y Paret (2018). Y cercanos al 90%, las investigaciones de Fioramanti (2008), Manasse y Roubini (2009), Savona y Vezzoli (2015) y Dawood, Horsewood y Strobel (2017).

De otra parte, respecto a la predicción de crisis de divisas, destacan los estudios sobre países emergentes de Lin, Khan, Chang y Wang (2008), Comelli (2013), Candelon, Dumitrescu y Hurlin (2014),

Chaudhuri (2014), Ramli, Ismail y Hooy (2015), Mulder, Perrelli y Rocha (2016) y Boonman, Jacobs, Kuper y Romero (2019). Otros autores se han centrado en países asiáticos (Fratzscher, 2003; Yu, Lai y Wang, 2006; Yu, Wang, Lai y Cong, 2007; Pham, 2017). Y por su parte, Al-Assaf (2017) investigó las diferencias de un conjunto habitual de indicadores que se utilizan en los sistemas de alerta temprana de crisis de divisas para el caso de Jordania y Egipto. También Karimi y Voia (2019) analizaron los orígenes de las crisis de divisas para un grupo de economías de la OCDE. Estos trabajos previos han utilizado un considerable número de métodos estadísticos, destacando Logit (Boonman, Jacobs, Kuper y Romero, 2019; Boonman y Urbina, 2020), y Probit (Steinberg, Koesel y Thompson, 2015; Karimi y Voia, (2019). Además, otros estudios previos ha aplicado RNA (Lin, Khan, Chang y Wang, 2008; Sevim, Oztekin, Bali, Gumus y Guresen, 2014), SOM (Sarlin y Marghescu, 2011), Support Vector-Machine (Chaudhuri, 2014), y Deep Neural Decision Trees (Alaminos et al., 2019b). Con los métodos descritos, gran parte de los estudios previos alcanzan un rango de precisión del 67-85% (Candelon, Dumitrescu y Hurlin, 2014; Bucevska, 2015; Boonman, Jacobs, Kuper y Romero, 2019), mientras que el rango 90-97% encontramos las investigaciones de Yu, Lai y Wang (2006), Sarlin y Marghescu (2011), Comelli (2013), Chaudhuri (2014), Ramli, Ismail y Hooy (2015) y Alaminos et al. (2019b). Así mismo, la variables más significativas en estos estudios han hecho referencia a las exportaciones (Candelon, Dumitrescu y Hurlin, 2014; Al-Assaf, 2017; Karimi y Voia, 2019), a la tasa de cambio real de la divisa (Ramli, Ismail y Hooy, 2015; Karimi y Voia, 2019), a la relación entre la reserva y la oferta monetaria (Candelon, Dumitrescu y Hurlin, 2014; Al-Assaf, 2017), al saldo de la cuenta corriente (Sarlin y Marghescu, 2011; Bucevska, 2015), y al crecimiento del PIB (Comelli, 2013; Bucevska, 2015).

Finalmente, la literatura previa sobre predicción de crisis del sistema bancario se ha dirigido tanto a economías avanzadas como a emergentes. Los autores Laina, Nyholm y Sarlin (2015), Antunes, Bonfim, Monteiro, y Rodrigues (2018), Ristolainen (2018) y Filippopoulou, Galariotis y Spyrou (2020) han enfocado sus investigaciones en países desarrollados, principalmente europeos. Otros autores se han centrado en países emergentes (Davis, Karim y Liadze, 2011; Caggiano, Calice y Leonida, 2014; Demirguc-Kunt y Detragiache, 2005; Chen, Abebe, Zhang y Jahera, 2015) y a nivel global (Davis y Karim, 2008; Ristolainen, 2018; y Alaminos et al., 2019c). Esta literatura sobre crisis de los sistemas bancarios ha utilizado métodos estadísticos y computacionales. Entre los estadísticos destacan logit, logit multivariante y logit multinomial (Brooks, Brown y Treepongkaruna, 2014; Caggiano, Calice y Leonida, 2014; Laina, Nyholm y Sarlin, 2015; Hamdaoui, 2016; Ari y Cergibozan, 2016). Y con técnicas computacionales, los estudios de Ristolainen (2018), Dabrowski, Beyes y de Villiers (2016) y Joy, Rusnak, Smidkova y Vasicek (2017). Como resultado de los modelos desarrollados, se ha señalado que entre las variables que mejor predicen las crisis bancarias se encuentran el nivel de crecimiento del PIB (Davis y Karim, 2008; Antunes, Bonfim, Monteiro, y Rodrigues, 2018), la inflación (Demirguc-Kunt y Detragiache, 2005; Ristolainen, 2018), el tipo de interés real (Demirguc-Kunt y Detragiache, 2005; Davis y Karim, 2008; Kauko, 2014), la oferta monetaria con respecto a las reservas (Davis y Karim, 2008; Gramlich, Miller, Oet y Ong, 2010; Ristolainen, 2018), el crédito doméstico en relación al PIB (Davis y Karim, 2008; Sohn y Park, 2016; Ristolainen, 2018), y el crecimiento del precio de las viviendas (Antunes, Bonfim, Monteiro, y Rodrigues, 2018). También estos estudios han proporcionado notables niveles de precisión en sus estimaciones. Por ejemplo, destacamos los realizados por Drehmann y Juselius (2014),

Hamdaoui (2016), Antunes, Bonfim, Monteiro, y Rodrigues (2018) y Ristolainen (2018), con niveles superiores al 80%.

Del análisis efectuado sobre los estudios que abordan la dimensión financiera de la reputación país se ha podido constatar la existencia de un patrón definido en lo que se refiere a la construcción de modelos regionales frente a modelos globales. Así mismo, que gran parte de los trabajos emplean técnicas estadísticas y computacionales. Sin embargo, han resultado escasas las referencias que se pronuncian a favor o en contra del uso de un tipo de modelo u otro (Qin y Chengying, 2014; Ramli, Ismail y Hooy, 2015; Dawood, Horsewood y Strobel, 2017). Y del mismo modo, que hay pocos estudios que concluyan sobre la superioridad de los métodos computacionales (Alaminos, Becerra-Vicario, Fernández-Gámez y Cisneros-Ruiz, 2019).

Una explicación factible a esta carencia de un patrón delimitado en la literatura sobre la elaboración de un tipo determinado de modelos podría basarse en la frecuente utilización de muestras heterogéneas de países, o de muestras con posibles conjuntos de variables explicativas muy diversas. Como afirman Platt y Platt (2008), este tipo de muestras pudiera ser la razón de la discrepancia entre los buenos resultados de clasificación ex-post y los comparativamente decepcionantes resultados de validación ex-ante, ya que los indicadores utilizados como variables independientes pueden verse afectados por efectos propios del país o región en cuestión. En este sentido, Joy, Rusnak, Smidkova y Vasicek (2017) comprobaron que las economías emergentes y avanzadas muestran diferencias importantes en diversas medidas de salud financiera. Hay que apuntar que esta idea fue tenida en cuenta por Sevin et al. (2014), Boonman, Jacobs, y Kuper (2015) y Joy, Rusnak, Smidkova y Vasicek (2017), quienes analizaron la influencia de los efectos propios



de los países en los indicadores macroeconómicos y financieros y su aplicación en la predicción de las crisis financieras internacionales. Todos ellos llegaron a la conclusión de que el modelo obtenido para una muestra heterogénea de países tiene menos capacidad predictiva que el elaborado para un único país.

Otros autores adoptaron un enfoque basado en el ajuste de los modelos globales introduciendo países muy dispares (Cumperayot y Kouwenberg, 2013; Davis, Karim y Liadze, 2011), o la inclusión de variables que recojan diferentes atributos de características propias de las regiones o países representados en la muestra (Bi y Traum, 2012; Sevim et al., 2014; Ari y Cergibozan, 2016). A pesar de ello, los resultados de clasificación en los modelos con una amplia representación geográfica, incluso con dichas variables incluidas, no eran superiores a los obtenidos con modelos más reducidos, confirmando que existe el hueco para mejorar los resultados de precisión y la información explicativa de los modelos (Joy et al., 2017; Dufrénot y Paret, 2018; Boonman, Jacobs, Kuper y Romero, 2019; Antunes, Bonfim, Monteiro y Rodrigues, 2018; Boonman y Urbina, 2020; Filippopoulou, Galariotis y Spyrou, 2020).

En definitiva, es posible que la ausencia de una conclusión sobre la existencia de un modelo global con una alta precisión para cada tipo de crisis tratada en esta tesis sea debida a que no se hayan podido comparar de forma homogénea un tipo de modelos y otros dada la disparidad de metodologías, enfoques, bases de datos disponibles, periodos temporales y países utilizados. Además, la escasez de modelos globales no ha permitido una investigación en profundidad sobre qué métodos podrían incrementar la precisión de los mismos. A esto se añade explorar las posibilidades de aplicaciones que tendría estos modelos de predicción, que no sólo acometan la función de instrumentos empíricos de prevención de crisis financieras,

sino que también aportan un mayor conocimiento en otras áreas como la reputación país, donde se ha mostrado posible que las crisis financieras tenga influencia (Amador y Phelan, 2018). Esta reputación país puede afectar a las posibilidades futuras de mercado de las empresas de gran proyección internacional, como por ejemplo las empresas energéticas, a la hora de proyectar confianza en sus productos. En consecuencia, este hueco existente en la literatura nos ha motivado a perseguir los siguientes objetivos de investigación. En primer lugar, construir modelos globales y regionales para la predicción de crisis de deuda soberana, de divisas y del sistema bancario. Y, en segundo lugar, contrastar si la aplicación de métodos computacionales consigue mejores resultados de precisión que los métodos estadísticos en la construcción de los citados modelos de predicción de crisis. Los objetivos señalados están relacionados, pues, con las tres siguientes cuestiones de investigación:

*Primera: ¿Es posible disponer de un modelo de predicción de crisis de deuda soberana útil para medir con alta precisión la dimensión financiera de la reputación país?*

*Segunda: ¿Es posible construir un modelo de predicción de crisis de divisas con una alta precisión para utilizarse en la cuantificación de la dimensión financiera de la reputación país?*

*Tercera: ¿Puede desarrollarse un modelo de predicción de crisis del sistema bancario con la suficiente robustez para que pueda ser utilizado en la valoración de la dimensión financiera de la reputación país?*



# RESULTADOS



Los resultados obtenidos en la presente tesis doctoral han sido objeto de tres publicaciones en revistas científicas internacionales. La primera de ellas es "Sovereign Debt and Currency Crises Prediction Models using Machine Learning Techniques" (Alaminos, Peláez, Salas y Fernández-Gámez, 2021). Con esta publicación se ha dado respuesta a la primera cuestión de investigación planteada (¿Es posible disponer de un modelo de predicción de crisis de deuda soberana útil para medir con alta precisión la dimensión financiera de la reputación país?).

Este estudio analiza el riesgo de impago de los gobiernos y su influencia en la reputación de un país. Para ello se han construido modelos de predicción de crisis regionales y globales utilizando técnicas computacionales.

Las crisis de deuda soberana ocurren en el momento en el que un país comente un impago de su deuda pública. Los modelos previos sobre predicción de crisis de deuda soberana han demostrado que los mejores predictores son el volumen de la deuda externa, el crecimiento de las reservas de divisas y la capacidad de los ingresos de explotación para pagar la deuda. Sin embargo, los resultados de precisión recogido en estos trabajos previos han sido insuficientes, dejando esta cuestión como una línea en la que seguir avanzando (Dawood, Horsewood y Strobel, 2017). El objetivo de esta publicación ha sido contribuir a aumentar la precisión de los modelos de predicción de crisis de deuda soberana construyendo nuevos modelos utilizando diversas metodologías computacionales, que han obtenido excelentes resultados de predicción en estudios previos relacionados con la economía y las finanzas (Rawal y Agarwal, 2019). Concretamente, se ha utilizado perceptrón multicapa, máquinas de vectores de soporte, árboles de decisión difusos, AdaBoost, Extreme Gradient Boosting, bosques aleatorios, red de creencia profunda y

árboles de decisión neuronales de aprendizaje profundo. Una síntesis de los aspectos metodológicos de cada una de estas técnicas de clasificación aparece a continuación.

El Perceptrón Multicapa (MLP) es un modelo de RNA supervisada, de alimentación hacia delante, que está compuesta por una capa de unidades de entrada, otra capa de salida y un número determinado de capas intermedias, llamadas capas ocultas, sin conexiones con el exterior. Cada sensor de entrada estaría conectado con las unidades de la segunda capa, éstas a su vez con las de la tercera capa, y así sucesivamente. La red tendrá como objetivo establecer una correspondencia entre un conjunto de datos de entrada y un conjunto de salidas deseadas. Para ello se ha realizado un ajuste de pesos  $W$  a partir de la información procedente del conjunto muestral, considerando que tanto la arquitectura como las conexiones de la red son conocidas, siendo su misión obtener aquellos pesos que minimicen el error de aprendizaje. Dado, pues, un conjunto de pares de patrones de aprendizaje  $\{(x_1, y_1), (x_2, y_2) \dots (x_p, y_p)\}$  y una función de error  $\varepsilon(W, X, Y)$ , el proceso de entrenamiento implica la búsqueda del conjunto de pesos que minimiza el error de aprendizaje  $E(W)$  (Lee y Yeo, 2016), como aparece en (1).

$$\min_W E(W) = \min_W \sum_{i=1}^p \varepsilon(W, x_i, y_i) \quad (1)$$

Las máquinas de vectores de soporte (SVM) han mostrado un buen desempeño sobre una amplia variedad de problemas de clasificación en los que tiende a minimizar el error de generalización, es decir, los errores del clasificador sobre nuevas instancias. En términos geométricos, SVM puede ser visto como el intento de encontrar una superficie ( $\sigma$ ) que separe a los ejemplos positivos de los negativos por el margen más amplio posible (Hearst et al., 1998). La búsqueda de que la distancia mínima entre él y un ejemplo de

entrenamiento sea máxima se realiza a través de todas las superficies ( $\sigma_1, \sigma_2, \dots$ ) en el espacio  $A$ -dimensional que separan a los ejemplos positivos de los negativos en el conjunto de entrenamiento (conocidas como superficies de decisión). Una ventaja importante de SVM es que permite construir clasificadores no lineales, es decir, el algoritmo representa datos de entrenamiento no lineales en un espacio de alta dimensionalidad (llamado el espacio de características), y construye el hiperplano que tiene el margen máximo.

Por su parte, el algoritmo C4.5 es una extensión del algoritmo ID3. Este es un algoritmo que se puede usar para establecer un árbol de decisión según los atributos que se dividen en subconjuntos más pequeños, donde el proceso de formar un árbol de decisión o regla depende de la decisión de obtener un valor de la información (Rawal y Agarwal, 2019). En general, C4.5 se forma siguiendo el siguiente orden: a) selecciona los atributos como raíz; b) crea una rama para cada valor; y c) repite el proceso para cada rama hasta que todos los casos de las ramas tienen la misma clase. La ganancia más alta se usa para la selección de atributos como la raíz, según la ecuación (2):

$$Gain(S, A) = Entropy(S) - \sum_{i=1}^n \frac{|S_i|}{|S|} Entropy(S_i) \quad (2)$$

donde  $S$  es el conjunto de casos,  $A$  son los atributos,  $n$  es el número de partición del atributo  $A$ , y  $S_i$  es el número de casos en la partición  $i$ -ésima. A su vez, el valor de la Entropía es el expresado en la ecuación (3).

$$Entropy(S) = - \sum_{i=1}^n p_i \log_2 p_i \quad (3)$$

donde  $p_i$  es la proporción de  $S_i$ .



Los árboles de decisión difusos siguen la misma estructura básica de los árboles de decisión descritos anteriormente. Estos árboles de decisión difusos permiten que los datos sigan simultáneamente múltiples ramas de un nodo con diferentes grados de satisfacción en el intervalo (0-1) (Lee, Chung y Shyu, 2017; Prashanth, Parthiban y Dhanalakshmi, 2018).

AdaBoost es una máquina de aprendizaje meta-algoritmo que puede ser utilizado en conjunción con otros tipos de algoritmos de aprendizaje para mejorar su rendimiento. La salida de los otros algoritmos de aprendizaje (clasificadores 'débiles') se combina en una suma ponderada que representa la salida final del clasificador impulsado (Alfaro et al., 2008; Zhou y Lai, 2017). Un clasificador Boost es un clasificador expresado de la forma que aparece en la ecuación (4).

$$F_T(x) = \sum_{t=1}^T f_t(x) \quad (4)$$

donde cada  $f_t$  es un aprendiz débil que toma un objeto  $x$  como entrada y devuelve un resultado de valor real que indica la clase del objeto. La señal de la salida del clasificador débil identifica la clase de objeto predicho y el valor absoluto da la confianza en esa clasificación. Del mismo modo, la  $T$  del clasificador de capa será positivo si se cree que la muestra estará en la clase positiva, y negativo en caso contrario.

XGBoost es una técnica de aumento de gradiente eficiente y escalable que ha demostrado un mayor poder de predicción que otros algoritmos populares (Chen y Guestrin, 2016; Lee, Chung y Shyu, 2017; Chang, Chang y Wu, 2018). Es un modelo de conjunto que se utiliza para problemas de aprendizaje supervisado y que consiste en conjuntos de árbol de clasificación y regresión (CART). Para predecir

una variable  $y_i$ , XGBoost define el modelo de la forma expresada en la ecuación (5).

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i) f_k \in F \quad (5)$$

donde  $K$  es el número total de árboles,  $f_k$  para el árbol  $k$  es una función en el espacio funcional  $F$ , y  $F$  es el conjunto posible de todos los CARTs.

Por su parte, los bosques aleatorios (en inglés, Random Forests) son una técnica de conjunto que promedia las predicciones de una gran cantidad de árboles de decisión no correlacionados (Breiman, 2001; Ho, 1995). Los bosques aleatorios se basan en ideas de dos dominios: empaquetamiento para construir cada árbol en una muestra de arranque diferente de los datos de entrenamiento, y selección aleatoria de características para crear los árboles. El algoritmo de entrenamiento es bastante simple y se puede resumir del siguiente modo. Para cada uno de los árboles del conjunto, se extrae una muestra de los datos de entrenamiento. Al hacer crecer el árbol  $T_b$  sobre  $Z$ , se seleccionan aleatoriamente las características que están disponibles como candidatos para la división en el nodo respectivo (Hastie, Tibshirani y Friedman, 2009). Finalmente, se agrega el árbol crecido  $T_b$  al conjunto. Durante la inferencia, cada uno de los árboles hace una predicción  $\hat{c}_b(x)$  para la etiqueta de clase de la nueva observación  $x$ . La predicción final del bosque aleatorio  $\hat{c}_{RF}(x)$  es entonces el voto mayoritario de los árboles, es decir,  $\hat{c}_{RF}(x) = \text{voto mayoritario}\{\hat{c}_b(x)\}$ .

La Red de Creencia Profunda (RCP) es una clase de red neural profunda donde las dos capas superiores se modelizan como una memoria asociativa bipartita no dirigida, es decir, unas máquinas restringidas de Boltzmann (RBM). Las capas inferiores constituyen un modelo gráfico dirigido, una denominada red de creencias

sigmoideas. La diferencia entre las redes de creencias sigmoideas y RCP está en la parametrización de las capas ocultas (Bengio, 2009), como viene expresado en la ecuación (6).

$$P(v, h^1, \dots, h^l) = P(h^{l-1}, h^l) \left( \prod_{k=0}^{l-2} P(h^{k+1} | h^k) \right) \quad (6)$$

donde  $v$  es el vector de unidades visibles,  $P(h^{k-1} | h^k)$  es la probabilidad condicional de unidades visibles en el nivel  $k$ . La distribución conjunta en el nivel superior,  $P(h^{l-1}, h)$ , es una RBM, siendo  $x(n) = [1, x_1(n), x_2(n), \dots, x_m(n)]^T$ . Otra forma de describir un DBN con un modelo más simple se muestra en la expresión (7).

$$w(n) = [b, w_1(n), w_2(n), \dots, w_m(n)]^T \quad (7)$$

Por último, los Árboles de Decisión Neuronales de Aprendizaje Profundo (DNNT) -en inglés, Deep Neural Decision Trees- son modelos de árbol de decisión ejecutados por redes neuronales de aprendizaje profundo, donde cualquier configuración de ponderaciones de DNNT corresponde a un árbol de decisión específico y, por lo tanto, es interpretable (Yang, Morillo y Hospedales, 2018). El algoritmo se inicia implementando una función de 'soft binning' (Dougherty et al., 1995) para calcular la tasa de error por cada nodo. En general, una función 'binning' toma como entrada un escalar real  $x$  y produce un índice de los 'containers' a los que pertenece  $x$ . La función de activación del algoritmo DNNT se realiza a partir de una red neuronal definida como se muestra en la ecuación (8).

$$\pi = f_{w,b,\tau}(x) = \text{softmax}((wx + b)/\tau) \quad (8)$$

donde  $w$  es una constante y su valor se establece como  $w = [1, 2, \dots, n + 1]$ ,  $\tau > 0$  es un factor de temperatura, y  $b$  está construido como se define en la ecuación (9).

$$b = [0, -\beta_1, -\beta_1 - \beta_2, \dots, -\beta_1 - \beta_2 - \dots - \beta_n] \quad (9)$$

La red neuronal definida en la ecuación (9) produce una codificación de la función 'binning'  $x$ . Por su parte, en caso de que  $\tau$  tiende a 0 (que suele ser el caso más habitual), se realiza el muestreo del vector usando el método de Straight-Through Gumbel-Softmax (Jang et al., 2017). Dada nuestra función 'binning' definida anteriormente, la idea clave es construir el árbol de decisiones a través del producto de Kronecker. Supongamos que tenemos una instancia de entrada  $x \in R^D$  con  $D$  características. Intercalando cada característica  $x_d$  con su propia red neuronal  $f_d(x_d)$ , podemos encontrar todos los nodos finales de los árboles de decisión, como se expresa en la ecuación (10).

$$z = f_1(x_1) \otimes f_2(x_2) \otimes \dots \otimes f_D(x_D) \quad (10)$$

donde  $z$  ahora también es un vector que indica el índice del nodo de hoja donde llega la instancia  $x$ .

A pesar de la importante capacidad explicativa de las técnicas de minería de datos, cuando se utiliza una gran cantidad de variables también es necesario cuantificar su impacto. Esto se hace a través del análisis de sensibilidad. Este análisis tiene como objetivo determinar la importancia relativa de las variables independientes en relación con la variable dependiente (Delen, Kuzey y Uyar, 2013; Efimov y Sulieman, 2017). Esta técnica busca reducir los modelos a las variables más importantes e ignorar o eliminar las menos

importantes. Una variable se considera más importante que otra si aumenta la varianza, en comparación con el conjunto de variables del modelo. El método de Sobol (Saltelli, 2002) se utiliza para descomponer la varianza de la salida total  $V(Y)$  proporcionada por el conjunto de ecuaciones expresadas en (11).

$$V(Y) = \sum_i V_i + \sum_i \sum_{j>1} V_{ij} + V_{1,2,\dots,k} \quad (11)$$

donde  $V_i = V(E(Y|X_i))$  y  $V_{ij} = V(E(Y|X_i, X_j)) - V_i - V_j$

Los índices de sensibilidad son determinados por  $S_{ij} = V_{ij}/V$ , donde  $S_{ij}$  indica el efecto de interacción entre dos factores. La descomposición de Sobol permite la estimación de un índice de sensibilidad total  $S_{Ti}$ , el cual mide la suma total de los efectos de la sensibilidad involucrada por las variables independientes.

Por su parte, la base de datos utilizada para la construcción de los modelos predicción de crisis de deuda soberana consistió en un gran conjunto de información (30 variables explicativas crudas o transformadas, con frecuencia anual) con respecto a un panel (desequilibrado) de 115 países desarrollados y emergentes en el período 1970-2017. Se intenta replicar la muestra utilizada por Dawood, Horsewood y Strobel (2017) como trabajo de referencia, ampliando el rango de tiempo y la cantidad de países, además de incluir los atributos de los indicadores sobre la calificación crediticia y sobre las condiciones políticas. Las variables macroeconómicas han sido extraídas del Banco Mundial, mientras que los indicadores del rating crediticio proceden de las estadísticas de Fitch Ratings y las variables políticas del proyecto POLITY IV, realizado por el Center for Systemic Peace (<http://www.systemicpeace.org/inscrdata.html>). La selección de países se guía principalmente por la disponibilidad de datos, y abarca cuatro regiones principales: África y Medio Oriente,

Asia, América Latina y Europa. El conjunto de datos de la muestra se ha dividido en tres grupos mutuamente excluyentes, el 70% para muestras de entrenamiento, el 10% para las muestras de validación y el 20% para muestras de prueba. Posteriormente elegimos el conjunto de variables que produjeron el máximo de aciertos de clasificación en el conjunto de validación, y hemos ofrecido resultados de acuerdo con el número de aciertos promedio en el conjunto de prueba. Por último, la clasificación y la predicción consisten en utilizar el modelo desarrollado para predecir las crisis analizadas.

Para la variable dependiente en los modelos, se toma los mismos criterios que el trabajo referenciado (Dawood, Horsewood y Strobel, 2017). Por lo tanto, en el caso de las economías emergentes, la variable dependiente denota como 1 si ocurre cualquiera de los cuatro eventos siguientes, y cero en caso contrario: a) el interés acumulado y/o los atrasos del capital exceden el 5% de la deuda pendiente; b) recibir un préstamo del FMI que exceda el 100% de la cuota del país; c) el crédito acumulado obtenido del FMI aumenta por encima del 200% de la cuota; d) participar en una reestructuración de la deuda (recompras o reducciones) o en un plan de reprogramación que involucra más del 20% de la deuda pendiente. Para los países desarrollados, además de los dos eventos que involucran los préstamos del FMI, la variable dependiente también se denota como 1 si la deuda pública pendiente excede el 150% del valor nominal del PIB. En la tabla 1 se exponen el conjunto de variables utilizado, con su definición y signo esperado.

**TABLA 1. DEFINICIÓN DE LAS VARIABLES INDEPENDIENTES PARA LA CRISIS DE DEUDA SOBERANA**

Atributo	Abreviatura	Descripción	Signo Exp.
<b>Exposición a la deuda</b>	TDEB	Deuda externa bruta como % del PIB	+
	IMFC	Préstamos procedentes del FMI como % del PIB	+
	GINT	Global LIR	+
<b>Sector Exterior</b>	FXR	Reservas totales (sin oro) como % del PIB	-
	TRO	Ratio de exportaciones más importaciones con respecto al PIB	+/-
	EXPG	Ratio del crecimiento anual de las exportaciones	-
	CACC	Cuenta de la balanza de pagos como % del PIB	-
	FDI	Flujos de inversión directa extranjera como % del PIB	-
<b>Factores Macroeconómicos Domésticos</b>	RGDP	Crecimiento anual del PIB real	-
	INF	Ratio de cambio en el índice de precios al consumo	+
	M2R	Ratio de oferta monetaria (M2) dividido por las reservas	+
	REER	Desviación del ratio de tipo de cambio real efectivo de la divisa (media móvil de último 5 años)	-
	GOVS	Gasto final del gobierno central como % del PIB	+/-
	NSAV	Ahorro total como % del PIB	-
	CON	Evento de crisis de deuda soberana en algún país de la misma región (t-1)	+
<b>Sector Bancario</b>	DCRE	Ratio del crédito domestico como % del GDP	+/-
	BASS	Ratio de los activos bancarios como % del GDP	-
	GBL	Reclamaciones bancarias netas sobre el gobierno central	+
<b>Indicadores de Calificación Crediticia</b>	SCLR	Escala de la calidad crediticia del bono de deuda pública a largo plazo en moneda local	+/-
	SCFR	Escala de la calidad crediticia del bono de deuda pública a largo plazo en moneda extranjera	+/-
	SBS	Ratio de interés pagado sobre bono de deuda pública a 10 años	+
	CDS	Precio del seguro de incumplimiento de bono de deuda pública	+
<b>Factores Políticos</b>	FRAG	Puntuación de fragmentación política (tensiones regionales/étnicas)	+
	POLI	Puntuación de política combinada (puntuación de autocracia menos puntuación de democracia)	+/-
	DUR	Durabilidad del régimen político (variable de control de 'POLI')	+
	PERS	Número de años transcurridos desde el último cambio político radical y abrupto. (variable de control de 'POLI')	+
	RIR	Puntuación de la magnitud de los episodios de guerra civil que involucran al país (por año)	+
	SFI	Índice de fragilidad estatal	+
	EFEE	Efectividad de la política económica medida por el PIB per cápita	-

Los resultados del análisis de sensibilidad y precisión obtenidos en cada etapa según la submuestra de datos (entrenamiento, validación y pruebas) del modelo global, África y Medio Oriente, Asia, Latinoamérica y Europa, se muestran en las Tablas 2 y 3, respectivamente. Después de observar los resultados del análisis de sensibilidad, el modelo global muestra que variables como TRO son significativas en todas las metodologías aplicadas. Otra variable que muestra parecida significación es FXR, que muestra altos niveles de

sensibilidad. Por su parte, las variables que representan la calidad crediticia, como SCFR y SBS, también tienen alta importancia de acuerdo con los resultados obtenidos. Si generalizamos el modelo en la muestra de prueba, el nivel de clasificación se mueve en un rango de 87,67% - 97,80%, mostrando la técnica FDT con una precisión de 97,80% con datos de prueba. Finalmente, los valores de RMSE (figura 3) resultantes de las metodologías utilizadas se mueven en un intervalo de 0,33 - 0,22, mostrando que FDT proporciona el error más bajo (0,22).

Los resultados del análisis de sensibilidad del modelo construido con la muestra de África y Medio Oriente indican que las variables más significativas son IMFC, M2R, SCFR y SBS. En cuanto a los resultados de precisión obtenidos, si generalizamos el modelo en la muestra de prueba, el nivel de clasificación se mueve en un rango de 88,67% - 100%, siendo la técnica FDT la de mayor precisión, 100%. Otras técnicas como AdaBoost y XGBoost también muestran un alto nivel de precisión (superior al 95%). Los valores de RMSE (figura 3) producidos por las metodologías utilizadas se mueven en un intervalo de 0,24 - 0,07, mostrando nuevamente a FDT como el algoritmo con menor error.

Las variables TRO, FXR, SCFR y SBS tienen el mayor impacto en el análisis de sensibilidad del modelo asiático. En cuanto a los resultados de precisión, el nivel de clasificación se mueve en un rango de 8,44% - 96,82%, mostrando que FDT presenta una precisión de 96,82% con datos de prueba. En este modelo asiático, los valores de RMSE (figura 3) se mueven en un intervalo de 0,38 - 0,26, siendo nuevamente la técnica FDT como el algoritmo que arroja el menor error. En cuanto al modelo latinoamericano, se observa que las variables más significativas son TRO, FXR, SCFR y SBS, y que el nivel de clasificación se mueve en un rango de 87,65% - 98,85%,



mostrando que FDT obtiene los mejores resultados de precisión. Finalmente, tras examinar los resultados del análisis de sensibilidad, el modelo europeo muestra que las variables de mayor impacto son TDEB, M2R, FXR, SCFR y SBS, que el nivel de clasificación se mueve en un rango de 86,36% - 99,76%, y que FDT consigue la mayor precisión. Otras técnicas como AdaBoost y XGBoost también han obtenido altos niveles de precisión, superando el 98% en la muestra de pruebas.

**TABLA 2. ANÁLISIS DE SENSIBILIDAD PARA LA CRISIS DE DEUDA SOBERANA**

	MLP		SVM		FDT		AdaBoost		XGBoost		RF		DBN		DNDT	
	Var.	Sens.	Var.	Sens.	Var.	Sens.	Var.	Sens.	Var.	Sens.	Var.	Sens.	Var.	Sens.	Var.	Sens.
<b>Global</b>	SBS	0,624	SBS	0,482	TRO	0,875	TRO	0,915	TRO	0,767	TRO	0,927	TRO	0,712	TRO	0,755
	TRO	0,619	FXR	0,428	FXR	0,752	SCFR	0,651	FXR	0,724	INF	0,452	FXR	0,561	FXR	0,727
	FXR	0,482	INF	0,415	SCFR	0,452	SBS	0,562	SFI	0,406	SFI	0,451	SFI	0,325	SFI	0,652
	SFI	0,375	TRO	0,345	INF	0,375	FXR	0,519	SCFR	0,319	SCFR	0,282			SCFR	0,321
	GINT	0,304			SFI	0,375										
<b>África y Oriente Próximo</b>	IMFC	1,294	IMFC	1,601	IMFC	1,370	IMFC	0,916	IMFC	1,039	IMFC	1,023	IMFC	1,261	IMFC	1,069
	POLI	0,621	TDEB	0,612	TDEB	0,493	SCFR	0,634	GOVS	0,526	TDEB	0,521	POLI	0,542	TDEB	0,653
	SCFR	0,458	POLI	0,452	GOVS	0,452	TDEB	0,451	TDEB	0,427	M2R	0,378	GOVS	0,346	M2R	0,631
			M2R	0,325	POLI	0,452	GOVS	0,175	SCFR	0,237	SBS	0,325	M2R	0,315	POLI	0,329
			GDPG	0,321	SCFR	0,355			POLI	0,194	GOVS	0,315	SCFR	0,301		
		GOVS	0,305							GDPG	0,312					
<b>Asia</b>	CACC	1,350	CACC	1,342	CACC	1,157	CACC	0,897	CACC	1,309	CACC	1,215	CACC	0,945	CACC	1,051
	POLI	0,615	GDPG	0,621	REER	0,626	TDEB	0,436	REER	0,571	SCLR	0,623	TDEB	0,621	REER	0,548
	SCLR	0,521	M2R	0,385	NSAV	0,502	NSAV	0,421	TDEB	0,425	POLI	0,525	IMFC	0,324	NSAV	0,451
	NSAV	0,502	POLI	0,317	TDEB	0,428	GINT	0,325	FXR	0,381	REER	0,519	POLI	0,317	SCLR	0,329
	REER	0,493			POLI	0,317			NSAV	0,359	FXR	0,417			POLI	0,308
								GDPG	0,345	TDEB	0,314					
										GDPG	0,312					

Nota: Var: Variables; Sens: Sensibilidad

**TABLA 2. ANÁLISIS DE SENSIBILIDAD PARA LA CRISIS DE DEUDA SOBERANA (CONTINUACIÓN)**

	MLP		SVM		FDT		AdaBoost		XGBoost		RF		DBN		DNDT	
	Var.	Sens.	Var.	Sens.	Var.	Sens.	Var.	Sens.	Var.	Sens.	Var.	Sens.	Var.	Sens.	Var.	Sens.
<b>América Latina</b>	TRO	1,682	GOVS	0,910	TRO	1,145	TRO	1,206	TRO	1,243	TRO	1,324	TRO	0,910	TRO	1,231
	SFI	0,956	TDEB	0,653	SFI	0,625	SFI	0,625	SCLR	0,652	GOVS	0,563	IMFC	0,675	SCLR	0,634
	SCLR	0,679	IMFC	0,611	SCLR	0,452	IMFC	0,362	GOVS	0,423	SCLR	0,458	SCLR	0,452	IMFC	0,564
	IMFC	0,454	TRO	0,563	IMFC	0,427	GOVS	0,324	INF	0,321	GINT	0,328	SFI	0,346	SFI	0,415
	REER	0,428	INF	0,510	REER	0,329					SFI	0,315	SBS	0,324	GINT	0,357
	SBS	0,421	SFI	0,462	GINT	0,317							GINT	0,314		
			SCLR	0,452												
			REER	0,323												
		FXR	0,322													
<b>Europa</b>	TDEB	1,428	TDEB	1,351	TDEB	1,351	TDEB	1,452	TDEB	1,046	M2R	1,014	M2R	0,988	TDEB	1,152
	M2R	1,145	M2R	1,05	M2R	1,145	M2R	1,231	M2R	1,023	TDEB	0,965	TDEB	0,872	M2R	1,061
	GOVS	0,851	GINT	0,452	GOVS	0,325	GINT	0,514	GOVS	0,627	GDPG	0,621	GINT	0,329	GOVS	0,324
	EFEE	0,462	EFEE	0,344			CACC	0,347	CDS	0,325	GOVS	0,384	GOVS	0,314	CACC	0,314
			CACC	0,321			CDS	0,322	GINT	0,316	CDS	0,312				
			GOVS	0,307			EFEE	0,261								

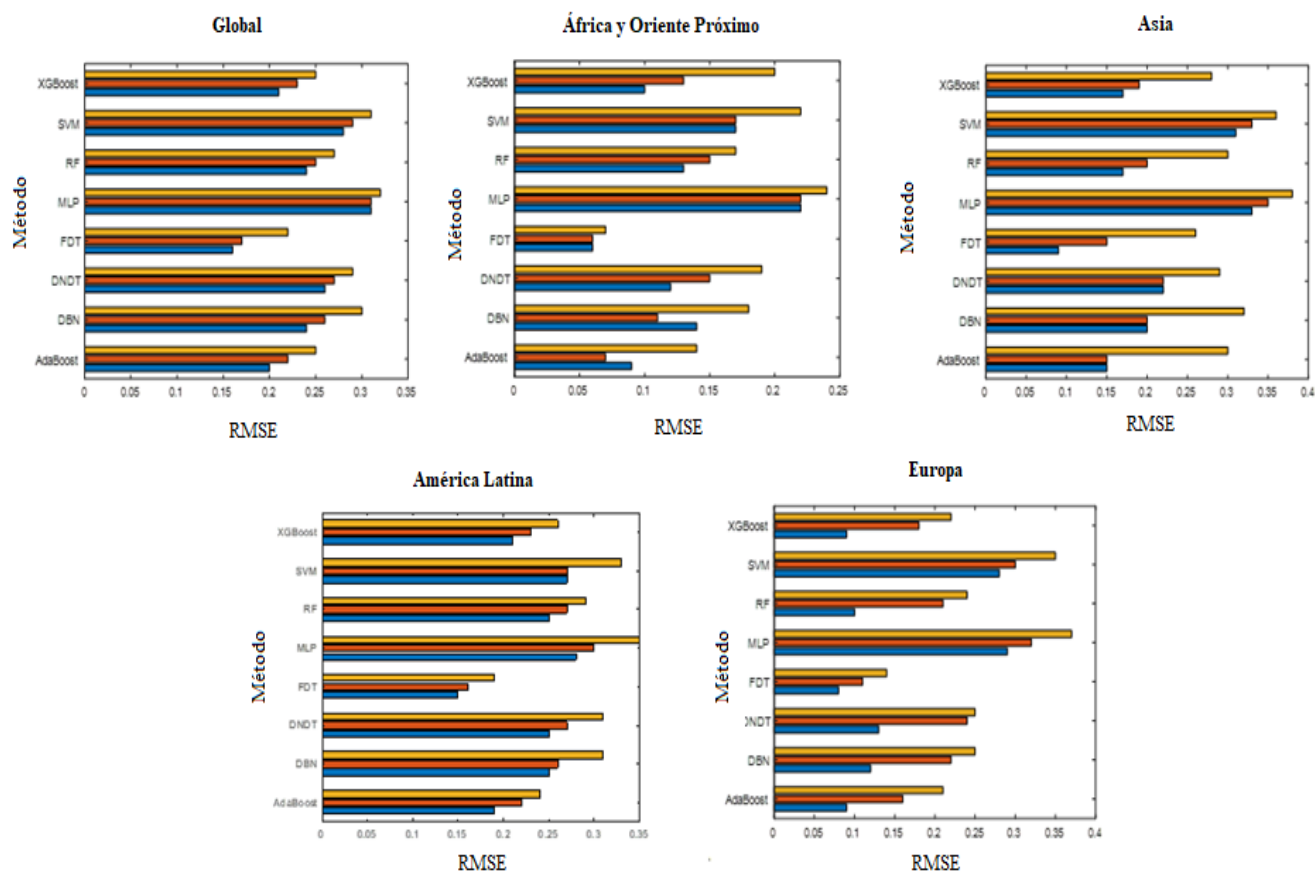
Nota: Var: Variables; Sens: Sensibilidad

**TABLA 3. ANÁLISIS DE PRECISIÓN PARA CRISIS DE DEUDA SOBERANA**

Método	Clasificación	Global	África y Oriente Próximo	Asia	América Latina	Europa
<b>MLP</b>	Entrenamiento	88,88	90,28	88,70	87,35	88,82
	Validación	87,96	89,04	86,04	86,39	86,76
	Testeo	87,67	88,67	85,44	87,65	86,36
<b>SVM</b>	Entrenamiento	91,09	92,80	91,30	90,06	91,12
	Validación	89,41	90,98	88,41	89,72	90,67
	Testeo	88,62	90,02	88,01	88,42	89,45
<b>FDT</b>	Entrenamiento	98,95	100,00	100,00	99,22	100,00
	Validación	98,13	100,00	98,52	99,03	99,91
	Testeo	97,80	100,00	96,82	98,95	99,76
<b>AdaBoost</b>	Entrenamiento	98,48	97,30	99,49	98,74	99,49
	Validación	97,63	99,34	96,54	98,33	99,75
	Testeo	96,08	98,40	95,97	97,13	99,45
<b>XGBoost</b>	Entrenamiento	97,38	96,71	97,84	97,33	99,29
	Validación	96,65	96,12	96,02	97,81	99,65
	Testeo	94,42	95,26	95,43	95,44	98,19
<b>RF</b>	Entrenamiento	95,46	97,95	97,25	94,88	98,92
	Validación	94,68	96,25	95,89	96,28	97,80
	Testeo	92,49	95,40	94,98	93,83	95,50
<b>DBN</b>	Entrenamiento	95,30	95,27	96,83	94,10	98,46
	Validación	93,17	94,69	94,20	95,06	96,46
	Testeo	91,71	93,70	93,95	93,76	94,02
<b>DNDT</b>	Training	96,29	97,13	97,81	94,12	99,36
	Validation	94,79	96,22	96,44	95,70	98,94
	Testing	93,43	95,30	95,20	94,23	97,58

Nota: Los valores están expresados en porcentajes

**FIGURA 3. VALORES DE RMSE PARA MODELOS DE PREDICCIÓN DE CRISIS DE DEUDA SOBERANA.**



Nota: entrenamiento (azul); validación (naranja); testeo (amarillo).

Siguiendo con las cuestiones de investigación planteadas en la presente tesis, y como respuesta a la segunda cuestión (¿Es posible construir un modelo de predicción de crisis de divisas con una alta precisión para utilizarse en la cuantificación de la dimensión financiera de la reputación país?), se ha realizado la publicación “Currency Crises Prediction using Deep Neural Decision Trees” (Alaminos, Becerra-Vicario, Fernández-Gómez y Cisneros-Ruiz, 2019). Este trabajo tiene como objetivo el análisis del riesgo reputacional de un país a partir de una caída significativa en el valor de su moneda.

Una crisis de divisa soberana sucede cuando el valor de la moneda de un país sufre una abrupta caída anual en los mercados de divisas. Este tipo de crisis ha sido habitualmente un tema de continuo estudio en la literatura financiera. La importancia del valor de una divisa determina el acceso que tiene un país al comercio internacional y en la forma en la que se relaciona con el resto del mundo. Por tanto, una pérdida de cotización en su divisa puede representar un daño en la reputación país (Amador y Phelan, 2018). Los resultados de precisión obtenidos por los trabajos previos sobre modelos para predecir crisis de divisas han mostrado relativamente bajos niveles de precisión, por lo que en la literatura se sugiere ahondar en la mejora de este aspecto (Sevim et al., 2014). En consecuencia, el objetivo de nuestra publicación ha sido aumentar la precisión de los modelos regionales y globales de predicción de crisis de divisas basados en la comparativa de diferentes técnicas computacionales tales como regresión logística, perceptrón multicapa, máquinas de vectores de soporte, AdaBoost y árboles de decisión neuronales de aprendizaje profundo. La teoría de estos métodos ha sido explicada en la primera publicación de esta tesis, salvo el método de regresión logística, que será expuesta brevemente a continuación.

El modelo de regresión logística (Logit) es un modelo no lineal de clasificación, a pesar de que contiene una combinación lineal de parámetros y observaciones de las variables explicativas (Cox, 2018). La función logística se encuentra acotada entre 0 y 1, proporcionando, por tanto, la probabilidad de que un elemento se encuentre en uno de los dos grupos establecidos. A partir de un suceso dicotómico, el modelo Logit predice la probabilidad de que el suceso tenga o no lugar. Si la estimación de la probabilidad es superior a 0,5 entonces la predicción es que sí pertenece a ese grupo, y en caso contrario, supondría que pertenece al otro grupo considerado. Para estimar el modelo se parte del cociente entre la

probabilidad de que un suceso ocurra y la probabilidad de que éste no ocurra. La probabilidad de que un suceso ocurra vendrá determinada por la expresión (12).

$$P(Y_i = 1/x_i) = \frac{e^{(\beta_0 + \beta_1 X_1 + \dots + \beta_k X_k)}}{1 + e^{(\beta_0 + \beta_1 X_1 + \dots + \beta_k X_k)}} = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X_1 + \dots + \beta_k X_k)}} \quad (12)$$

donde  $\beta_0$  es el término constante del modelo y  $\beta_1, \dots, \beta_k$  los coeficientes de las variables.

Por otro lado, la base de datos utilizada para la construcción de los modelos de predicción de crisis de divisas incluye 32 variables explicativas de 163 países desarrollados, emergentes y en vías desarrollo en el período 1970-2017. La variable dependiente está construida a partir de la definición de Laeven y Valencia (2018). Así, una crisis de divisas está definida como una depreciación nominal de la moneda con respecto al dólar estadounidense de al menos el 30 por ciento, que también es al menos 10 puntos porcentuales más alta que la tasa de depreciación en el año anterior. Las variables macroeconómicas han sido extraídas del Banco Mundial y elegidas a partir de las experiencias de Kaminsky (1998), Sevim et al. (2014) y Ramli, Ismail y Hooy (2015). Por su parte, las variables políticas proceden del proyecto POLITY IV, siguiendo los factores utilizados por Rother (2009). En la tabla 4 se exponen el conjunto de variables utilizado, con su definición y signo esperado.

**TABLA 4. DEFINICIÓN DE LAS VARIABLES INDEPENDIENTES PARA LA CRISIS DE DIVISAS**

Atributo	Abreviatura	Descripción	Signo Exp.
<b>Exposición de Deuda</b>	TDEB	Deuda externa bruta como % del PIB	+
	STD	Deuda externa bruta a corto plazo como % del PIB	+
	RIR	Tipo de interés crediticia ajustada por inflación	+
<b>Sector Exterior</b>	FXR	Reservas totales (sin oro) como % del PIB	-
	TRO	Ratio de exportaciones más importaciones con respecto al PIB	+/-
	IMP	Importaciones de bienes y servicios en dólares (USD) actuales	+/-
	EXP	Exportaciones de bienes y servicios en dólares (USD) actuales	-
	CACC	Cuenta de la balanza de pagos como % del PIB	-
	PINV	Inversión de cartera neta en dólares (USD) actuales	-
	FDI	Flujos de inversión directa extranjera como % del PIB	-
<b>Factores Macroeconómicos Domésticos</b>	RGDP	PIB real anual en dólares (USD) actuales	-
	GDPG	Crecimiento anual del PIB real	-
	INF	Ratio de cambio en el índice de precios al consumo	+
	M2M	Crecimiento anual de oferta monetaria (M2)	+
	M2R	Ratio de oferta monetaria (M2) dividido por las reservas	+
	REER	Desviación del ratio de tipo de cambio real efectivo de la divisa (media móvil de último 5 años)	-
	GOVS	Gasto final del gobierno central como % del PIB	+/-
	FCF	Formación bruta de capital fijo en dólares (USD) actuales	-
	UNE	Desempleo total como % de la fuerza laboral total	+
	CON	Evento de crisis de deuda soberana en algún país de la misma región (con un retardo de un año)	+
	SPEG	Régimen de tipo de cambio aplicado a una moneda para mantener su valor estable frente a una moneda de reserva.	+
	PEG	Régimen de tipo de cambio en el que el valor de una moneda se fija contra el valor de la moneda de otro país.	+
	<b>Sector Bancario</b>	DCRE	Ratio del crédito domestico como % del GDP
LIR		Tasa bancaria que satisface las necesidades de financiamiento a corto y mediano plazo	-
DIR		Tasa pagada por los bancos por depósitos a la vista, a plazo o de ahorro	-
<b>Factores Políticos</b>	POLI	Puntuación de política combinada (puntuación de autocracia menos puntuación de democracia)	-
	DUR	Durabilidad del régimen político expresado en años (variable de control de 'POLI')	+
	PERS	Número de años transcurridos desde el último cambio político radical y abrupto (variable de control de 'POLI')	+
	SFI	Índice de fragilidad estatal (A mayor nivel de puntuación, mayor riesgo de fragilidad)	+
	LGOV	Variable binaria que se denota con 1 un gobierno de ideología de izquierda, y 0 en caso contrario	+
	ELEC	Variable binaria que se denota con 1 el año de elecciones generales, y 0 en caso contrario	+
	TURN	Rotación anual de agentes políticos con veto (1-año en el que ha habido cambio de gobierno; 0-caso contrario)	+
	YEAR	Años en el cargo del presidente del gobierno nacional	+
	EFEE	Efectividad de la política económica medida por el PIB per cápita	-

La tabla 5 muestra los niveles de precisión que hemos alcanzado en la clasificación de las crisis de divisas con las metodologías aplicadas. El método DNDT fue el que logró mayor



capacidad de clasificación, seguido de AdaBoost, MLP, SVM y Logit. Con DNDT, la precisión de clasificación obtenida con los datos de entrenamiento fue 99,17%, 98,02%, 99,68%, 100%, 99,16% para los modelos de África y Oriente Medio, América Latina, Asia del Sur y Oriental, Europa y Global, respectivamente. La precisión obtenida mediante la validación fue del 98,85%, 97,39%, 99,03%, 99,61%, 98,87% para los modelos de África y Oriente Medio, América Latina, Asia del Sur y Oriental, Europa y Global, respectivamente. Por último, la precisión de los datos de las pruebas fue del 98,24% para África y Oriente Medio, el 96,40% para América Latina, el 98,54% para Asia, el 99,07% para Europa y el 98,43% para el modelo global.

**TABLA 5. RESULTADOS DE PRECISIÓN DE LOS MODELOS DE CRISIS DE DIVISAS**

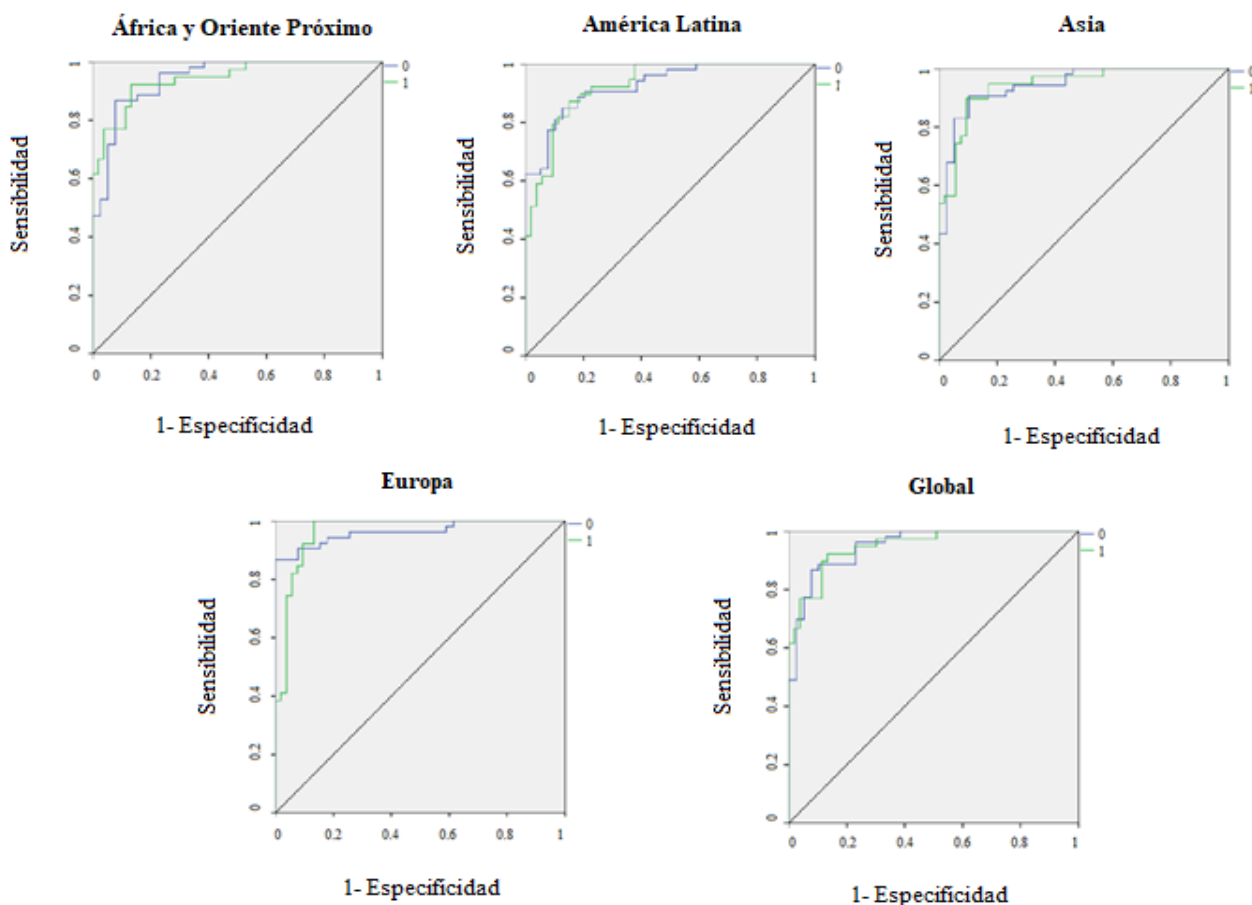
<b>Modelo</b>	<b>Clasificación</b>	<b>Logit</b>	<b>MLP</b>	<b>SVM</b>	<b>AdaBoost</b>	<b>DNDT</b>
África y Oriente Próximo	Entrenamiento	91,52	94,44	93,38	95,25	99,17
	Validación	90,84	93,91	92,57	94,57	98,85
	Testeo	90,25	93,62	92,18	94,11	98,24
América Latina	Entrenamiento	91,16	94,12	93,04	95,08	98,42
	Validación	90,72	93,37	92,68	94,21	97,79
	Testeo	90,20	92,85	91,95	93,36	96,90
Asia	Entrenamiento	91,64	95,06	93,47	96,17	99,68
	Validación	91,03	94,52	93,02	95,64	99,03
	Testeo	90,62	94,13	92,61	95,19	98,54
Europa	Entrenamiento	92,19	95,43	93,81	96,86	100,00
	Validación	91,58	95,10	93,22	96,42	99,61
	Testeo	90,88	94,46	92,93	95,73	99,07
Global	Entrenamiento	91,59	94,84	93,33	95,95	99,16
	Validación	90,94	94,27	92,65	95,34	98,87
	Testeo	90,37	93,76	91,83	94,28	98,43

Nota: Los valores están expresados en porcentajes

La bondad de ajuste de los modelos desarrollados se mide mediante las curvas ROC y el error cuadrático medio (RMSE). El área

de la curva ROC para los cinco modelos con DNDT es cercana a 1, lo que indica niveles satisfactorios en todos los casos (figura 4). La raíz del error cuadrático medio (RMSE) para las 500 iteraciones en las estimaciones con los datos de prueba se muestra en la Tabla 6. El RMSE es menor a 0,30 en todos los modelos construidos con DNDT, y también muestra un ajuste cercano para todos los modelos. Por último, la figura 5 muestra la precisión alcanzada por DNDT en cada una de las 500 iteraciones realizadas para cada modelo.

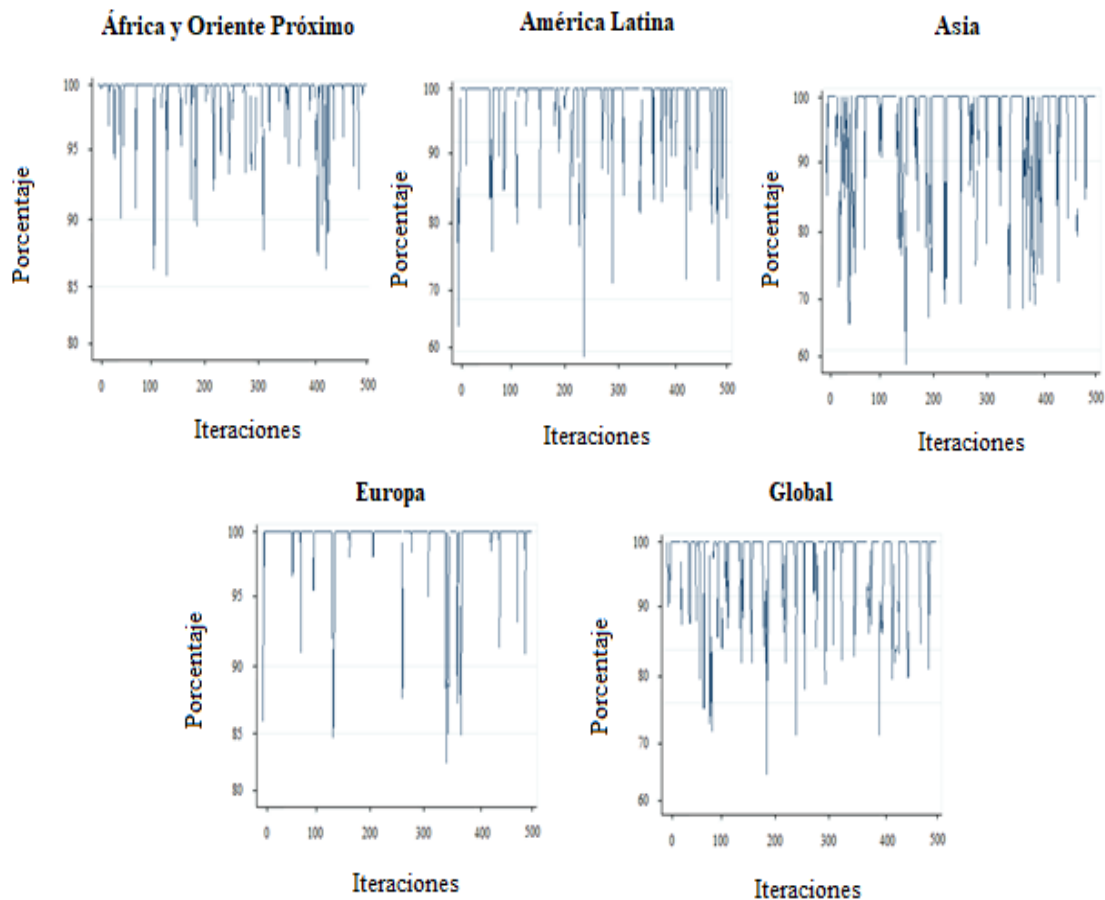
**FIGURA 4. RESULTADOS DE LAS CURVAS ROC PARA LOS MODELOS CREADOS CON DNDT**



**TABLA 6. RESULTADOS DE RMSE DE LOS MODELOS ESTIMADOS**

<b>Modelo</b>	<b>RMSE</b>		
	<b>Entrenamiento</b>	<b>Validación</b>	<b>Testeo</b>
África y Oriente Próximo	0,13	0,15	0,19
América Latina	0,21	0,25	0,24
Asia	0,12	0,16	0,18
Europa	0,09	0,12	0,14
Global	0,18	0,21	0,23

FIGURA 5. RESULTADOS DE LAS 500 ITERACIONES REALIZADAS CON DNDT



La tabla 7 detalla los resultados del análisis de sensibilidad obtenidos en cada etapa según la submuestra de datos (entrenamiento, validación y testeo) con los datos relacionados con las crisis de divisas. En el modelo global, las variables más significativas son M2M, M2R, TRO, FDI y REER. Esto muestra que un aumento significativo en la oferta monetaria y en los flujos de inversión extranjera pueden decidir la existencia de una crisis monetaria global.

El modelo de África y Oriente Medio muestra que M2M, M2R e IED son importantes con la mayoría de las técnicas utilizadas. Por

tanto, los aumentos de la oferta monetaria y, con ello, un aumento de la proporción de esta oferta sobre las reservas de divisas del país, así como un bajo nivel de flujos de inversión extranjera directa, son los mejores predictores de crisis cambiarias en esta región.

El modelo asiático muestra que las variables FXR, TRO, M2R y CACC muestran altos niveles de sensibilidad. Por lo tanto, un aumento significativo en la oferta monetaria y una balanza de pagos deficiente parecen ser los mejores predictores de crisis cambiarias en Asia. Las variables TRO, RGDP, TDEB y M2R son significativas en la mayoría de los modelos construidos en América Latina. Estos resultados indican que un aumento significativo en la relación entre la oferta monetaria y las reservas, un bajo nivel de crecimiento económico y apertura comercial, así como un alto nivel de deuda pública, son los factores más importantes para predecir una crisis cambiaria. Los resultados del análisis de sensibilidad en el modelo europeo muestran que las variables de M2M, DCRE, FCF y TDEB son las de mayor impacto en la mayoría de las técnicas aplicadas. Estos resultados indican que un aumento significativo en el crecimiento de la oferta monetaria y unos altos niveles del crédito son factores especialmente significativos para detectar las crisis de divisas en Europa.

**TABLA 7. ANÁLISIS DE SENSIBILIDAD PARA LA CRISIS DE DIVISAS**

	Logit		MLP		SVM		AdaBoost		DNDT	
	Var.	Sens.	Var.	Sens.	Var.	Sens.	Var.	Sens.	Var.	Sens.
<b>Global</b>	FCF	1,294	M2M	1,315	TRO	1,314	M2M	1,248	M2M	1,248
	M2M	1,132	POLI	0,632	M2R	0,981	M2R	1,172	M2R	1,172
	M2R	0,847	FCF	0,553	FCF	0,814	TRO	0,834	TRO	0,834
	TDEB	0,673	M2R	0,523	TDEB	0,72	CACC	0,624	CACC	0,624
	TRO	0,517	TDEB	0,497	FDI	0,689	REER	0,597	REER	0,597
	CACC	0,427	CACC	0,437	POLI	0,445	POLI	0,382	TDEB	0,439
	SFI	0,397	TRO	0,435	GOVS	0,421	FDI	0,375	POLI	0,382
			REER	0,321	CACC	0,418	TDEB	0,318	FDI	0,375
<b>África y Oriente Próximo</b>	M2M	1,965	FDI	1,237	PINV	1,428	FDI	1,304	M2M	1,732
	M2R	0,876	M2M	1,226	FDI	1,121	FCF	1,283	FDI	1,178
	FDI	0,831	REER	0,985	TRO	0,925	M2M	0,728	FCF	0,785
	PINV	0,742	FCF	0,742	M2M	0,825	TRO	0,685	TRO	0,748
	DCRE	0,732	M2R	0,653	GOVS	0,756	CACC	0,572	DCRE	0,627
	TRO	0,652	POLI	0,653	FCF	0,647	GOVS	0,561	M2R	0,62
	FCF	0,625	CACC	0,652	DCRE	0,357	POLI	0,452	PINV	0,531
	FXR	0,354	SFI	0,582	POLI	0,349	M2R	0,34	POLI	0,493
	SFI	0,329	DCRE	0,538					CACC	0,483
		PINV	0,368							

Nota: Var. Variables; Sens: Sensibilidad

TABLA 7. ANÁLISIS DE SENSIBILIDAD PARA LA CRISIS DE DIVISAS (CONTINUACIÓN)

	Logit		MLP		SVM		AdaBoost		DNDT	
	Var.	Sens.	Var.	Sens.	Var.	Sens.	Var.	Sens.	Var.	Sens.
<b>Asia</b>	FXR	1,248	CACC	1,652	PINV	1,562	TRO	1,351	TRO	1,351
	TRO	1,125	TRO	1,223	TRO	1,132	CACC	1,181	CACC	1,181
	CACC	0,751	M2R	0,562	FXR	0,924	EXP	0,657	EXP	0,657
	M2R	0,649	RIR	0,523	FDI	0,896	FXR	0,634	FXR	0,634
	GDPG	0,567	TDEB	0,452	POLI	0,651	REER	0,349	REER	0,349
	RIR	0,519	EXP	0,377	CACC	0,563				
	EXP	0,473	FCF	0,327	EXP	0,547				
		POLI	0,324	GDPG	0,524					
<b>América Latina</b>	TRO	1,358	TRO	1,314	GDPG	1,505	TRO	1,253	TRO	1,253
	FCF	1,106	RGDP	1,256	TRO	1,285	RGDP	1,173	RGDP	1,173
	STD	0,835	FCF	0,788	M2M	0,895	FCF	0,593	TDEB	0,726
	RGDP	0,793	TDEB	0,687	DCRE	0,852	TDEB	0,435	FCF	0,593
	TDEB	0,427	FDI	0,649	FCF	0,683	IMP	0,415	IMP	0,415
	DCRE	0,417	DCRE	0,427	TDEB	0,652	RIR	0,317	DCRE	0,301
	GOVS	0,395	POLI	0,354	FDI	0,649	DCRE	0,301		
<b>Europa</b>	M2M	1,517	DCRE	1,528	FCF	1,528	DCRE	1,518	DCRE	1,518
	DCRE	1,317	M2M	1,234	M2M	1,293	M2M	1,494	M2M	1,494
	TDEB	1,231	FCF	1,176	DCRE	1,184	FCF	0,843	FCF	0,843
	FCF	0,475	PINV	0,965	STD	0,765	TDEB	0,648	TDEB	0,586
	STD	0,375	TDEB	0,326	TDEB	0,652	STD	0,415		
	SFI	0,229	EXP	0,315	PINV	0,541				
				SFI	0,437					

Nota: Var. Variables; Sens: Sensibilidad

Por último, el estudio que forma parte de esta tesis doctoral y que trata de dar respuesta a la tercera cuestión de investigación (¿Puede desarrollarse un modelo de predicción de crisis del sistema bancario con la suficiente robustez para que pueda ser utilizado en la valoración de la dimensión financiera de la reputación país?), ha sido objeto de la publicación "Predicting Systemic Banking Crises using Extreme Gradient Boosting" (Alaminos, Fernández-Gámez, Santos y Campos-Soria, 2019). En este trabajo se analiza el sistema bancario de un país como un factor clave por su posición de liderazgo dentro del sistema financiero nacional. La solvencia y estabilidad de este sistema financiero respalda parte de la dimensión financiera de la reputación país.

Las recientes crisis han demostrado que la imagen del sistema bancario puede influir significativamente en la exposición financiera de un país con el exterior, y por tanto, en su reputación (Dell'Atti y Trotta, 2016). Para analizar este evento de crisis del sistema bancario se han construido modelos de predicción regionales y globales. A tal fin, se ha utilizado la metodología XGBoost, que ha obtenido altos niveles de precisión en estudios previos (Basak, Kar, Saha, Khaidem y Dey, 2019). Una crisis del sistema bancario está definida como una situación en la que los sectores corporativos y financieros de un país experimentan una gran cantidad de impagos, y las instituciones financieras y empresas se enfrentan a grandes dificultades para reembolsar los préstamos a tiempo.

La muestra utilizada en esta tercera publicación está conformada por los 163 países desarrollados, emergentes y en vías de desarrollo que aparecen en la base de datos del Banco Mundial (World Bank Open Data). Por su parte, de dicha muestra se ha obtenido un conjunto de 28 variables explicativas seleccionadas de la



literatura previa (Kauko, 2014; Laeven y Valencia, 2018; Ristolainen, 2018). Estas variables son de carácter macroeconómico y están referidas al período 1970-2017. A su vez, la variable dependiente queda definida por las siguientes señales: (1) signos significativos de dificultades financieras en el sistema bancario; y (2) medidas de intervención de política bancaria significativas (Laeven y Valencia, 2018). En este sentido, existen dificultades financieras cuando se producen eventos como pánicos bancarios, importantes pérdidas en el sector bancario y/o liquidaciones bancarias. Por su parte, se considera que las intervenciones en el sector bancario son significativas si se han utilizado al menos tres de las siguientes seis medidas: (1) un amplio respaldo de liquidez (5 por ciento de los depósitos y pasivos a no residentes); (2) costes brutos de reestructuración bancaria (al menos el 3 por ciento del PIB); (3) nacionalizaciones bancarias significativas; (4) garantías significativas puestas en marcha; (5) compras significativas de activos (al menos el 5 por ciento del PIB); (6) Depósitos congelados y/o bancos cerrados. Esta variable dependiente se denota como 1 en los años en los que se produce la crisis bancaria, y 0 para el caso contrario. Estos modelos se han desarrollado utilizando 500 conjuntos de datos aleatorios, a los que se aplicó una validación cruzada de 10 veces, dividiendo aleatoria y mutuamente excluyentes el conjunto de muestras disponible en un 70% para la muestra de entrenamiento y un 30% para la muestra de prueba. La tabla 8 muestra las variables independientes utilizadas en la presente investigación.

**TABLA 8. DEFINICIÓN DE LAS VARIABLES INDEPENDIENTES PARA LA CRISIS DE SISTEMA BANCARIO**

<b>Atributo</b>	<b>Abreviatura</b>	<b>Concepto</b>	<b>Signo Exp.</b>
<b>Factores Macroeconómicos</b>	GDP per Capita	PIB real anual per cápita en dólares (USD) actuales	-
	Real GDP Growth	Crecimiento anual del PIB real	-
	Inflation	Ratio de cambio en el índice de precios al consumo	+
	M2 Multiplier Growth	Crecimiento anual de la oferta monetaria (M2)	+
	M2/Reserves	Ratio de oferta monetaria (M2) dividido por las reservas	+
	REER Overall	Desviación del ratio de tipo de cambio real efectivo de la divisa (media móvil de último 5 años)	-
	Gov Spending	Gasto final del gobierno central como % del PIB	+/-
	Real House Price	Variación anual del precio de la vivienda residencia	+
	Unemployment	Desempleo total como % de la fuerza laboral total	+
	Terms of Trade	Ratio de exportaciones más importaciones con respecto al PIB	+/-
Current Account	Cuenta de la balanza de pagos como % del PIB	-	
<b>Sector Bancario</b>	Domestic Credit	Ratio del crédito domestico como % del PIB	+/-
	Credit Private Sector	Ratio crédito del sector privado como % del PIB	+
	Credit Growth	Crecimiento anual del crédito doméstico	-
	Household Loans	Cantidad de préstamos de los hogares en dólares (USD) actuales	+
	Real Interest Rate	Tasa bancaria que satisface las necesidades de financiamiento a corto y mediano plazo	+/-
	Demand Deposits	Demanda de depósitos en dólares (USD) actuales	+
	Bank Assets	Ratio de los activos bancarios como % del PIB	-
	Foreign Bank Liabilities	Nivel de activos bancarios extranjeros con respecto a los activos bancarios totales	+
	Bank Liquid Reserves	Nivel de reservas bancarias liquidas con respecto a los activos bancarios totales	-
Gov Bank Assets	Reclamaciones bancarias netas sobre el gobierno central	+	
<b>Enlaces Financieros</b>	Oil Price	Precio del petróleo West Texas Intermediate en dólares (USD) actuales	+
	Market Capitalization	Capitalización bursátil con respecto al PIB	-
	Stock Prices	Variación del índice bursátil principal del país	-
	Stock Prices Volatility	Índice de volatilidad (VIX) realizado por Chicago Board Options Exchange	+
<b>Factores Políticos y Gobernanza</b>	Kaopen	Índice de medición del grado de apertura financiera (Índice de Chinn-Ito, actualización de 2017)	-
	Conflict	variable ficticia que adquiere el valor 1 si un país está experimentando un conflicto armado y 0 en caso contrario	+
	SFI	Índice de fragilidad del estado	+

Por su parte, la tabla 9 muestra los resultados obtenidos por XGBoost para los modelos de cada continente y para el modelo global. La precisión de los modelos con muestra de entrenamiento asciende al 98,58%; 98,32%; 99,60%; 99,82% y 99,14% para África y Oriente Próximo, América Latina, Asia, Europa y Global, respectivamente. Con muestra de testeo, la precisión es del 98,48%; 96,71%; 98,95%; 99,59% y 98,53% para los modelos de África y Oriente Próximo, América Latina, Asia, Europa y Global, respectivamente. Los resultados de este trabajo muestran que los modelos desarrollados con XGBoost consiguen una capacidad de predicción superior a la obtenida en estudios previos. Cabe destacar el caso del modelo global, que consigue una precisión del 98,53%.

**TABLA 9. RESULTADOS DE LA PRECISIÓN EN LA PREDICCIÓN DE CRISIS DE SISTEMA BANCARIO**

Modelo	Clasificación (%)		RMSE		Curva COR	Variables Significativas
	Entrenamiento	Testeo	Entrenamiento	Testeo		
África y Oriente Próximo	99,58	98,48	0,12	0,19	0,95	Real GDP Growth, M2 Multiplier Growth, REER Overall, Demand Deposits, Bank Liquid Reserves, Domestic Credit, Market Capitalization, Oil Price
América Latina	98,32	96,71	0,19	0,27	0,93	Real GDP Growth, Current Account, Inflation, M2/Reserves, REER Overall, Bank Assets, Credit Growth, Demand Deposits
Asia	99,60	98,95	0,11	0,16	0,97	M2 Multiplier Growth, Bank Assets, Demand Deposits, Bank Liquid Reserves, Domestic Credit, Market Capitalization, Oil Price
Europa	99,82	99,59	0,08	0,12	0,98	Real GDP Growth, GDP per Capita, M2/Reserves, Bank Assets, Credit Growth, Credit Private Sector, Domestic Credit, Household Loans
Global	99,14	98,53	0,15	0,22	0,97	Inflation, M2/Reserves, REER Overall, Bank Assets, Demand Deposits, Bank Liquid Reserves, Credit Growth, Credit Private Sector, Market Capitalization

Por su parte, la tabla 10 muestra los valores de sensibilidad de todas las variables utilizadas en la investigación. La variable Demand Deposits ha sido significativa en todos los modelos, ya que más depósitos relativos a los activos hacen que el sistema bancario sea más seguro (Kauko, 2014). Este resultado muestra diferencias con el trabajo de Ristolainen (2018), donde la variable M2/Reserves fue su variable más significativa en todos los modelos. Otras variables concernientes al sector bancario, como Bank Assets, Domestic Credit, Credit Growth y Bank Liquid Reserves, también han sido altamente significativa en tres de los cuatro modelos, evidenciando que los eventos de crisis pueden ocurrir por problemas de liquidez (Kauko, 2014), de riesgo y de rentabilidad sobre activos (Dabrowski et al., 2016). Aun así, otros trabajos empíricos previos no obtuvieron una alta significatividad con dichas variables. Con respecto a las variables macroeconómicas, las variables más significativas son Real GDP Growth y M2/Reserves. Demuestran que el lento crecimiento del PIB y un bajo ratio de M2/Reserves son una señal de advertencia y que predicen las crisis. Estos resultados están en consonancia con los mostrados por otros estudios previos como Davis et al. (2011), Dabrowski et al. (2016), Hamdaoui (2016) y Ristolainen (2018), pero también muestra diferencias con los resultados de Caggiano et al. (2014). Por otro lado, la variable Inflation no ha resultado altamente significativa, a diferencia de otros trabajos previos como el de Dabrowski et al. (2016) y Ristolainen (2018). En la misma línea, la variable Terms of Trade tampoco ha resultado significativa en ninguno de los modelos estimados, a diferencia de los resultados mostrados por Caggiano et al. (2014). Por último, ninguna de las variables de gobierno ha resultado significativas, a diferencia de los resultados obtenidos por Caggiano et al. (2014).

**TABLA 10. ANÁLISIS DE SENSIBILIDAD PARA LAS VARIABLES DE LA CRISIS DE SISTEMA BANCARIO**

<b>Variables</b>	<b>África y Oriente Próximo</b>	<b>América Latina</b>	<b>Asia</b>	<b>Europa</b>	<b>Global</b>
GDP per Capita	0,000	0,000	0,000	0,325	0,000
Real GDP Growth	1,355	0,547	0,000	1,124	0,000
Inflation	0,000	0,362	0,000	0,087	0,142
M2 Multiplier Growth	0,526	0,000	0,142	0,000	0,000
M2/Reserves	0,000	0,425	0,000	0,572	0,525
REER Overall	0,637	1,042	0,000	0,000	0,272
Gov Spending	0,000	0,000	0,000	0,000	0,000
Real House Price	0,000	0,000	0,000	0,000	0,000
Unemployment	0,000	0,000	0,000	0,000	0,000
Terms of Trade	0,000	0,000	0,000	0,000	0,000
Current Account	0,000	0,255	0,000	0,000	0,000
Domestic Credit	0,318	0,848	0,572	0,127	0,000
Credit Private Sector	0,000	0,096	0,000	0,325	0,142
Credit Growth	0,000	0,275	0,502	0,731	1,075
Household Loans	0,000	0,000	0,000	0,089	0,000
Real Interest Rate	0,000	0,000	0,000	0,000	0,000
Demand Deposits	0,526	0,000	0,117	0,000	0,125
Bank Assets	0,000	0,425	0,970	0,572	0,502
Foreign Bank Liabilities	0,000	0,000	0,000	0,000	0,000
Bank Liquid Reserves	0,125	0,000	1,204	0,000	0,327
Gov Bank Assets	0,000	0,000	0,000	0,000	0,000
Oil Price	0,754	0,000	0,224	0,000	0,000
Market Capitalization	0,133	0,000	0,375	0,000	0,275
Stock Prices	0,000	0,000	0,000	0,000	0,000
Stock Prices Volatility	0,000	0,000	0,000	0,000	0,000
Kaopen	0,000	0,000	0,000	0,000	0,000
Conflict	0,000	0,000	0,000	0,000	0,000
SFI	0,000	0,000	0,000	0,000	0,000



# DISCUSIÓN





Los resultados obtenidos para la predicción de las crisis de deuda soberana señalan un conjunto de variables significativas que se repiten en prácticamente la totalidad de los modelos estimados. Variables del atributo de exposición a la deuda como TDEB y IMFC hacen que el aumento de los niveles de deuda provoque también un aumento en la probabilidad de crisis de deuda pública. Estas variables significativas coinciden con los resultados de los trabajos previos de Dawood, Horsewood y Strobel (2016) y Savona y Vezzona (2015), que muestran la gran importancia del nivel de endeudamiento en la probabilidad de impago. Por su parte, algunas variables del sector bancario que han resultado significativas en trabajos previos (Dawood, Horsewood y Strobel, 2016) no lo han sido en nuestras estimaciones. Por el contrario, ha sido más habitual en nuestros modelos observar mayor significatividad en variables del atributo de sector exterior como FXR y M2R, que implican una alta acumulación de divisa extranjera para el pago de la deuda de las instituciones públicas de un país. Este hecho no ha sido refutado, o al menos, no con tanta significatividad, por trabajos previos (Boonman, Jacobs y Kuper, 2015; Dufrénot y Paret, 2018). Existen otras variables significativas como SCFR y SBS que no han sido contrastadas tampoco por la literatura previa. Dichas variables muestran que un empeoramiento de la calificación crediticia del país y un aumento de los intereses pagados hacen más difícil conseguir financiación y pagar la deuda, por lo que aumenta el riesgo de impago por las dificultades en la refinanciación de dicha deuda (Baum, Schäfer y Stephan, 2016). Por último, las variables políticas más significativas, pero con una intensidad más débil que las nombradas anteriormente, han sido: SFI (en los modelos de América Latina y Global) y POLI (Savoni y Vezzona, 2015).

Los resultados sobre impago de deuda soberana muestran que los modelos desarrollados con el C4.5 difuso (DDT) aumentan la

capacidad de predecir las crisis de deuda soberana, obteniendo mejores ratios tanto de precisión como de otros criterios de selección. Principalmente, cabe destacar el caso del modelo global, que consigue una precisión del 97,8%, muy superior al 87,1% obtenido por Dawood, Horsewood y Strobel (2016) utilizando regresión logística. En la misma línea, mejora los resultados obtenidos por Savona y Vezzona (2015), que alcanzaron un 87% de precisión con árboles de regresión para economías emergentes. Por su parte, también nuestra metodología mejora la capacidad de predicción de otras técnicas computacionales como las RNA utilizadas por Fioramanti (2008), con la que obtuvo un 85% de precisión para una muestra de países emergentes. Aun así, otras metodologías han mostrado una capacidad predictiva consistente a lo largo de los modelos construidos, tanto en el global como en los regionales. Son el caso de las técnicas AdaBoost, XGBoost y DNDT, que han mostrado un promedio de predicción en testeo cercano al 95% de acierto, convirtiéndolos en opciones interesantes para tratar la predicción de crisis de deuda soberana.

Por su parte, los resultados arrojados en el estudio de las crisis de divisas señalan igualmente un conjunto de variables significativas habitual en buena parte de los modelos estimados. La variable FCF ha sido significativa en muchos de los modelos, mostrando la importancia que tiene la evolución de la inversión neta de un país en el aumento del riesgo de crisis de divisa. Este resultado contradice la experiencia anterior de Boonan et al. (2017) en la que esta variable no fue significativa. Continuando con las variables domésticas macroeconómicas, las variables concernientes a la oferta monetaria (M2M y M2R) han demostrado una alta significatividad, evidenciando que un aumento drástico de la oferta monetaria perjudica a la cotización de la divisa. Por otro lado, la variable INF no ha resultado significativa, al contrario que en trabajos previos como en los de

Chaudhuri (2014) y Sevim et al. (2014). Otra variable como REER tampoco ha sido refutada como factor significativo, a diferencia de lo mostrado en los trabajos de Boonman, Jacobs, Kuper y Romero (2019) y Boonman y Urbina (2020). Así mismo, variables del atributo de sector exterior como TRO y CACC se muestran como variables más significativas debido a la importancia del comportamiento que tiene el comercio internacional de un país en la cotización, algo que refuta los resultados de los trabajos previos de Candelon, Dumitrescu y Hurlin (2014) y Ramli, Ismail y Hooy (2014).

Respecto a los resultados sobre el caso de las crisis de divisas, se ha conformado que los modelos desarrollados con DNDT obtienen una capacidad predictiva cercana al 100% tanto en los modelos regionales como en el modelo global, obteniendo niveles de precisión más altos que en estudios anteriores. La precisión del modelo global es del 96,38%, aunque la comparación de este modelo es difícil, ya que es el primer modelo creado para predecir las crisis monetarias a nivel mundial. Otros estudios han obtenido niveles de precisión más bajos, como Candelon, Dumitrescu y Hurlin (2014), con una precisión del 84,62% utilizando el modelo de panel dinámico. Del mismo modo, también hemos mejorado los resultados obtenidos por Sevim et al. (2014), que obtuvieron un 93,8% de precisión utilizando redes neuronales para Turquía. Nuestra metodología también tiene un mayor poder predictivo que otras técnicas computacionales como el algoritmo híbrido de k vecinos más cercanos y SVM, que obtuvieron un 97% de precisión para una muestra de países emergentes (Ramli, Ismail y Hooy, 2014).

Los resultados obtenidos para la predicción de crisis del sistema bancario señalan, además, un conjunto de variables significativas. La variable Demand Deposits ha sido significativa en todos los modelos, ya que a mayor nivel de depósitos relativos a los activos hacen que el

sistema bancario sea más estable (Kauko, 2014). Otras variables concernientes al sector bancario, como Bank Assets, Domestic Credit, Credit Growth y Bank Liquid Reserves, también han sido altamente significativa en tres de los cuatros modelos, evidenciando que los eventos de crisis pueden ocurrir por problemas de liquidez (Kauko, 2014). Estos resultados están en consonancia con los mostrados por otros estudios previos (Davis et al., 2011; Dabrowski et al., 2016; Hamdaoui, 2016; Ristolainen, 2018), pero también muestra diferencias con los resultados de Caggiano et al. (2014). Por otro lado, la variable Inflation no ha resultado altamente significativa, a diferencia de otros trabajos previos como en los de Davis et al. (2011), Dabrowski et al. (2016) y Ristolainen (2018). En la misma línea, la variable Trade Openness tampoco ha resultado significativa en ninguno de los modelos estimados, a diferencia de los resultados mostrados por Davis et al. (2011) y Caggiano et al. (2014). Por último, ninguna de las variables de gobierno ha resultado significativas, a diferencia de los resultados de Caggiano et al. (2014) y Hasanov y Bhattacharya (2018).

Los resultados de nuestro estudio indican, además, que los modelos desarrollados con XGBoost consiguen una capacidad de predicción de una crisis bancaria en el entorno del 95%, y en comparación con estudios previos obtiene mejores ratios para los modelos regionales y globales. Principalmente, cabe destacar el caso de estos últimos, para los que se consigue un 96,53% mejorando el resultado del modelo global de Ristolainen (2018). Otros trabajos también han conseguido precisiones inferiores a nuestros resultados, como es el caso de Dabrowski et al. (2016) utilizando redes bayesianas. En la misma línea, se mejora los resultados obtenidos por Sevim et al. (2014), que alcanzaron un 81% de precisión con árboles de decisión binaria para una muestra global, los de Caggiano

et al. (2014) con logit multinomial, y los de Hamdaoui (2016) utilizado medias móviles bayesianas.



# CONCLUSIONES





Con objeto de disponer de instrumentos para la valoración de la dimensión financiera de la reputación país, hemos desarrollado modelos globales y regionales robustos para predecir crisis financieras internacionales, concretamente las relativas a la deuda soberana, a la cotización de la divisa y para el sistema bancario. De igual manera, se intenta mostrar la superioridad de las técnicas computacionales con respecto a las estadísticas en términos de nivel de precisión. Se ha tratado de aclarar estas cuestiones superando la ausencia previa de conclusiones definitivas debida a la falta de homogeneidad provocada por la disparidad de metodologías, enfoques, bases de datos disponibles, periodos temporales y países, entre otros asuntos.

Los resultados del estudio realizado nos han permitido obtener las conclusiones que aparecen en continuación. En primer lugar, confirmar la existencia de diferencias entre los modelos globales y los regionales, y, además, que los modelos globales incluso pueden mostrar una capacidad de precisión similar a la media de la arrojada por los modelos regionales. A tal efecto, los modelos de predicción de deuda soberana global para las regiones estudiadas (África y Oriente Próximo, Asia, América Latina y Europa) han obtenido una capacidad de precisión del 97,80%, 100%, 96,82%, 98,85% y 99,76%, respectivamente. Por su parte, esta relación de precisión para los modelos construidos en el estudio de la crisis de divisas muestra una precisión del 98,43%, 98,24%, 98,54%, 96,90% y 99,07% para la muestra global, de África y Oriente Próximo, Asia, América Latina y Europa, respectivamente. Esto demuestra el alto nivel de robustez de los modelos construidos con respecto a trabajos previos.

En segundo lugar, también hemos constatado que la aplicación de métodos computacionales incrementa el nivel de precisión mostrado por las técnicas estadísticas, todo ello a tenor de la

comparación efectuada entre niveles de acierto para datos de las muestras de testeo y los valores de RMSE obtenidos. Los mejores métodos para la crisis de deuda soberana han sido DDT, AdaBoost, XGBoost y DNDT. Para la predicción de la crisis de divisas, las mejores técnicas han sido DNDT, XGBoost, RF y RCP. Por último, XGBoost ha presentado los mejores rendimientos en la predicción de crisis del sistema bancario.

Con respecto a las variables explicativas de las crisis de deuda soberana, en el conjunto de los modelos estimados han aparecido como significativas algunas variables de manera continuada. Son las variables relacionadas con la exposición a la deuda del país, más concretamente TDEB, que muestra la importancia de un alto nivel de endeudamiento público en el impago soberano, y IMFC, que indica la influencia de una alta dependencia del crédito proporcionado por el FMI como una posible causa del aumento de la probabilidad de impago. Por otra parte, las variables del sector exterior relacionadas con el nivel de reservas de divisas extranjeras acumuladas por un país, como FXR y M2R, muestran la importancia de un nivel alto de reservas de divisas con el que poder hacer frente a pagos internacionales de deuda. Por último, las variables de SCFR y SBS arrojan también una significatividad continuada, mostrando que los intereses pagados y la calificación crediticia son factores importantes a la hora de evaluar la posibilidad de acaecer un impago soberano.

Los resultados de los modelos de predicción de crisis de divisas así mismo demuestran que un grupo reducido de variables son significativas de manera consistente. Este es el caso de la variable FCF, señalando cómo un bajo nivel de dinamismo en inversión neta en el país puede provocar una caída acusada del valor de la divisa. De igual manera, las variables que representa la oferta monetaria, como son M2M y M2R, indican que un aumento de la oferta monetaria

en el mercado hace perder cotización a la divisa. Variables del atributo de sector exterior como TRO y CACC también se presentan como variables significativas debido a la importancia de la apertura comercial de un país. Por último, en el caso de variables políticas, DUR y YEAR señalan una mayor incidencia de crisis de divisas en aquellos países donde se perpetúan regímenes políticos, como es lógico, cercanos al totalitarismo.

Respecto a la predicción de crisis del sistema bancario, la variable Demand Deposits es la más significativa, mostrando que el nivel de depósitos relativos a los activos es un factor esencial en la estabilidad del sistema bancario. Otras variables propias del sector bancario, como Bank Assets, Domestic Credit, Credit Growth y Bank Liquid Reserves también han obtenido altos niveles de significatividad en los modelos construidos, indicando que existe un alto riesgo de crisis por problemas de liquidez y una baja rentabilidad de los activos. Un crecimiento reducido del PIB y un alto ratio de M2/Reserves son claras señales para anticipar una crisis sistémica bancaria.

En tercer lugar, los modelos desarrollados pueden ayudar a proporcionar un mayor conocimiento de cuáles son los antecedentes de la reputación país desde su dimensión financiera. La inclusión de esta dimensión estudiada en la presente investigación puede actualizar y mejorar los análisis de fortalezas país tan importantes para las instituciones públicas con el objetivo de conseguir una mejor posición del país en el mundo. Esta mejor posición de la imagen del país puede atraer mayores flujos de capital, aumentando así el nivel de inversiones. Por tanto, una mejor percepción de la gestión financiera del país puede mejorar, por un lado, su posición en los mercados financieros, y por otro lado, la reputación país en beneficio de las empresas del mismo. En un mundo globalizado, las empresas siempre intentan expandirse en mercados ajenos al suyo, lo que hace

vital disfrutar de una buena imagen de país de origen con el fin de mejorar la percepción de los bienes y servicios ofrecidos. Una pobre reputación de un país en cuanto al pago de sus obligaciones de deuda, así como una moneda inestable, puede repercutir negativa a las empresas de dicho país en otros mercados en relación con la búsqueda de financiación, proveedores y asociaciones con otras empresas. Por ejemplo, estas consecuencias pueden tener influencia en la reputación corporativa de las empresas energéticas, donde la calidad de la imagen de su país de origen es vital para las relaciones internacionales. En la misma línea, deben analizar la reputación país de aquellos países a los que venden sus productos, con objeto de comprobar la fiabilidad del cliente y su situación financiera, siendo algunos indicadores importantes el estado de su divisa, de su sistema bancario y de la deuda soberana.

Esta investigación tiene algunas limitaciones, principalmente la disponibilidad de datos históricos de países emergentes. Dado que se trata de una investigación realizada desde una perspectiva global, requiere un alcance de información mucho mayor en comparación con otros estudios realizados en este campo. Además, la investigación futura podría profundizar en otros tipos de información política para analizar su influencia tanto en las crisis financieras estudiadas como en el impacto de la reputación país. Sería conveniente relacionar la influencia de las crisis financieras sufridas por un país en las exportaciones o turismo, dimensiones importantes en la reputación país a través de modificaciones de los modelos de fortaleza país, como principales herramientas de medición de la reputación. Asimismo, y para aumentar la capacidad de generalización de los resultados en el estudio de la reputación país, se podrían incluir mayores análisis sobre el impacto que tiene la solidez financiera de un país en la reputación corporativa, tanto en las grandes empresas como en aquéllas que deseen expandirse internacionalmente.





# BIBLIOGRAFÍA





Alaminos, D., Fernández, S.M., García, F., y Fernández, M.A. (2018). Data Mining for Municipal Financial Distress Prediction, *Advances in Data Mining, Applications and Theoretical Aspects. Lecture Notes in Computer Science.*, 10933, 296-308.

Alaminos, D., Fernández, S.M., Neves, P.M., y Santos, J.C. (2019a). Predicting Sovereign Debt Crises with Fuzzy Decision Trees. *Journal of Scientific and Industrial Research*, 78(11), 733-737.

Alaminos, D., Becerra-Vicario, R., Fernández-Gómez, M.A., y Cisneros-Ruiz, A.J. (2019b). Currency Crises Prediction using Deep Neural Decision Trees. *Applied Sciences*, 9(23), 5227.

Alaminos, D., Fernández-Gómez, M.A., Santos, J.C. y Campos-Soria, J.A. (2019c). Predicting Systemic Banking Crises using Extreme Gradient Boosting. *Journal of Scientific and Industrial Research*, 78(9), 571-575.

Alaminos, D., Peláez, J.I., Salas, M.B. y Fernández-Gómez, M.A., (2021). Sovereign Debt and Currency Crises Prediction Models Using Machine Learning Techniques. *Symmetry*, 13(4), 652.

Alfaro, E., García, N., Gómez, M., y Elizondo, D. (2008). Bankruptcy forecasting: An empirical comparison of AdaBoost and neural networks. *Decision Support Systems*, 45(1), 110-122.

Anholt, S. (2002). Nation branding: a continuing theme. *Journal of Brand Management*, 10(1), 59-60.

Anholt, S. (2007), *Competitive Identity: The New Brand Management for Nations Cities and Regions*, Palgrave Macmillan, Basingstoke.

Antunes, A., Bonfim, D., Monteiro, N., y Rodrigues, P.M.M. (2018). Forecasting banking crises with dynamic panel probit models. *International Journal of Forecasting*, 34(2), 249-275.

Amador, M., y Phelan, C. (2018). Reputation and Sovereign Default. Federal Reserve Bank of Minneapolis, Staff Report 564.

Arazmuradov, A. (2016). Assessing sovereign debt default by efficiency. *The Journal of Economic Asymmetries*, 13(C), 100-113.

Ari, A., y Cergibozan, R. (2016). The Twin Crises: Determinants of Banking and Currency Crises in the Turkish Economy. *Emerging Markets Finance and Trade*, 52(1), 123-135.

Al-Assaf, G. (2017). An Early Warning System for Currency Crisis: A Comparative Study for the Case of Jordan and Egypt. *International Journal of Economics and Financial Issues*, 7(3), 43-50.

Baum, C.F., Schäfer, D. y Stephan, A. (2016). *Journal of Financial Stability*, 24, 117-131.

Basak, S., Kar, S., Saha, S., Khaidem, L. y Deya, S.R. (2016). Predicting the direction of stock market prices using tree-based classifiers. *The North American Journal of Economics and Finance*, 47, 552-567.

Bengio, Y. (2009) Learning Deep Architectures For Artificial Intelligence. *Foundations and Trends in Machine Learning*, 2(1), 1-127.

Berg, B., y Pattillo, C (1999). Predicting currency crises: The indicators approach and an alternative. *Journal of International Money and Finance*, 18(4), 561-586.

Billio, M., Casarin, R., Costola, M., y Pasqualini, A. (2016). An entropy-based early warning indicator for systemic risk. *Journal of International Financial Markets, Institutions and Money*, 45, 42-59.

Boonman, T.M., Jacobs, J.P.A.M., y Kuper, G.H. (2015) Sovereign Debt Crises in Latin America: A Market Pressure Approach. *Emerging Markets Finance and Trade*, 51(6), S80-S93.

Boonman, T.M., Jacobs, J.P.A.M., Kuper, G.H., y Romero, A. (2019). Early Warning Systems for Currency Crises with Real-Time Data. *Open Economies Review*, 1-23.

Boonman y Urbina, A.E.S. (2020). Extreme Bounds Analysis in Early Warning Systems for Currency Crises. *Open Economies Review*, 31(2), 431-470.

Brooks, B. y Treepongkaruna (2014). Banking crises: Identifying dates and determinants. *Journal of International Financial Markets, Institutions and Money*, 32, 150-166.

Bucevska, V. (2015). Currency Crises in EU Candidate Countries: An Early Warning System Approach. *PANOECONOMICUS*, 62(4), 493-510.

Breiman, L. (2001). Random forests. *Machine learning*, 45(1):5–32.

Caggiano, G., Calice, P., y Leonida, L. (2014). Early Warning Systems and Systemic Banking Crises in Low Income Countries: A Multinomial Logit Approach. *Journal of Banking & Finance*, 47, 258–269.

Caggiano, G., Calice, P., Leonida, L., y Kapetanios, G. (2016). Comparing logit-based early warning systems: Does the duration of systemic banking crises matter? *Journal of Empirical Finance*, 37(C), 104–116.

Candelon, B., Dumitrescu, E.I., y Hurlin, C. (2014). Currency crisis early warning systems: Why they should be Dynamic. *International Journal of Forecasting*, 30, 1016–1029.

Ciarlone, A., y Trebeschi, G. (2005). Designing an early warning system for debt crises. *Emerging Markets Review*, 6, 376–395.

Chang, Y.C., Chang, K.H., y Wu, G.J. (2018). Application of eXtreme gradient boosting trees in the construction of credit risk assessment models for financial institutions. *Applied Soft Computing*, 73, 914–920.

Chaudhuri, A. (2014). Support Vector Machine Model for Currency Crisis Discrimination. ArXiv, submitted on 3 March 2014, arXiv:1403.0481.

Chen T, y Guestrin C. (2016). XGBoost: A scalable tree boosting system, Retrieved March 9, from the arXiv database (arXiv:1603.02754).

Chen, X., Abebe, A., Zhang, K., y Jahera, J.S. (2015). Country Banking Crisis Prediction using Transvariation Analysis. *Review of Pacific Basin Financial Markets and Policies*, 18(1), 1550001.

Christofides, C., Eicher, T.S., y Papageorgiou, C. (2016). Did established Early Warning Signals predict the 2008 crises? *European Economic Review*, 81(C), 103-114.

Comelli, F. (2013). Comparing Parametric and Non-parametric Early Warning Systems for Currency Crises in Emerging Market Economies. *IMF Working Paper*, WP/13/134.

Cowan, K., y Guzmán, F. (2020). How CSR reputation, sustainability signals, and country-of-origin sustainability reputation contribute to corporate brand performance: An exploratory study. *Journal of Business Research*, 117, 683-693.

Cox, D.R. (2018). *Analysis of Binary Data*. 2<sup>nd</sup> Edition, Routledge. New York.

Cumperayot, P., y Kouwenberg, R. (2013). Early warning systems for currency crises: A multivariate extreme value approach. *Journal of International Money and Finance*, 36, 151-171.

Dabrowski, J.J., Beyers, C., y de Villiers, J.P. (2016). Systemic banking crisis early warning systems using dynamic Bayesian networks. *Expert Systems with Applications*, 62, 225-242.

Davis, E.P., y Karim, D. (2008). Comparing early warning systems for banking crises. *Journal of Financial Stability*, 4(2), 89-120.

Davis, E.P., Karim, D., y Liadze, I. (2011). Should multivariate early warning systems for banking crises pool across regions? *Review of World Economics*, 147(4), 693-716.

Dawood, M., Horsewood, N., y Strobel, F. (2017). Predicting Sovereign Debt Crises: An Early Warning System Approach. *Journal of Financial Stability*, 28, 16-28.

Delen, D., Kuzey, C., y Uyar, A. (2013). Measuring firm performance using financial ratios: A decision tree approach. *Expert Systems with Applications*, 40, 3970–3983.

Dell'Atti, S. y Trotta, A. (2016). *Managing Reputation in The Banking Industry*. Springer International Publishing, Cham, Suiza.

Demirgüç-Kunt, A. y Detragiache, E. (1998). The Determinants of Banking Crises in Developing and Developed Countries. *IMF Economic Review*, 45(1), 81-109.

Demirguc-Kunt, A., y Detragiache, E. (2000). Monitoring Banking Sector Fragility: A Multivariate Logit Approach. *The World Bank Economic Review*, 14(2), 287–307.

Demirguc-Kunt, A., y Detragiache, E. (2005). Cross-Country Empirical Studies of Systemic Bank Distress: A Survey. IMF Working Paper No. 05/96.

Dimitrova, B.V., Korschun, D., y Yotov, Y.V. (2017). When and how country reputation stimulates export volume. *International Marketing Review*, 34 (3), 377-402.

Drehmann, M., y Juselius, M. (2014). Evaluating early warning indicators of banking crises: Satisfying policy requirements. *International Journal of Forecasting*, 30(3), 759-780.

Dougherty, J., Kohavi, R., y Sahami, M. (1995) Supervised and unsupervised discretization of continuous features. Machine Learning: Proceedings of the Twelfth International Conference, 1995. Morgan Kaufmann Publishers, San Francisco, California, USA.

Dsoulia, O., Khan, N., Kakabadse, N.K., y Skouloudis, A. (2018). Mitigating the Davos dilemma: towards a global self-sustainability index. *International Journal of Sustainable Development & World Ecology*, 25(1), 81-98.

Dufrénot, G., y Paret, A.G. (2018). Sovereign debt in emerging market countries: not all of them are serial defaulters. *Applied Economics*, 50(59), 6406-6443.

Efimov D., y Sulieman H. (2017) Sobol Sensitivity: A Strategy for Feature Selection. Mathematics Across Contemporary Sciences. AUS-ICMS 2015. Springer Proceedings in Mathematics & Statistics, vol 190. Springer, Cham.

Fan, Y. (2006). Nation branding: what is being branded? *Journal of Vacation Marketing*, 12(1), 5-14.

Feenstra, R.C., y Taylor, A.M. (2012). International Macroeconomics. Second Edition. Worth Publishers, New York, NY, USA.



Filippopoulou, C., Galariotis, E., y Spyrou (2020). An early warning system for predicting systemic banking crises in the Eurozone: A logit regression approach. *Journal of Economic Behavior & Organization*, 172, 344-363.

Fioramanti, M. (2008). Predicting sovereign debt crises using artificial neural networks: A comparative approach. *Journal of Financial Stability*, 4, 149-164.

Fombrun, C., Ponzi, L., y Newburry, W. (2015). Stakeholder Tracking and Analysis: The RepTrak® System for Measuring Corporate Reputation. *Corporate Reputation Review*, 18, 3-24.

Fratzscher, M. (2003). On currency crises and contagion. *International Journal of Finance & Economics*, 8(2), 109-129.

Fuertes, A.M., y Kalotychou, E. (2007). Optimal design of early warning systems for sovereign debt crises. *International Journal of Forecasting*, 23, 85-100.

Fullerton, J., y Kendrick, A. (2017). Country reputation as a moderator of tourism advertising effectiveness. *Journal of Marketing Communications*, 23 (3), 260-272.

Gramlich, D., Miller, G.L., Oet, M.V., y Ong, S.J. (2010). Early warning systems for systemic banking risk: critical review and modeling implications. *Banks and Bank Systems*, 5(2), 199-211.

Hamdaoui (2016) Are systemic banking crises in developed and developing countries predictable? *Journal of Multinational Financial Management*, 37-38, 114-138.

Harvey, W.S., y Groutsis, D. (2015). Reputation and talent mobility in the Asia Pacific. *Asia Pacific Journal of Human Resources*, 53(1), 22-40.

Hastie, T., Tibshirani, R., y Friedman, J. (2009). Random forests, in *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*, 2nd Edition, (New York, NY: Springer), 587–603.

Hearst, M., Schölkopf, B., Dumais, S., Osuna, E. y Platt, J. (1998). Trends and controversies - Support vector machines. *IEEE Intelligent systems*, 13(4), 18-28.

Heidari, E., Sobati, M.A., y Movahedirad, S. (2016). Accurate prediction of nanofluid viscosity using a multilayer perceptron artificial neural network (MLP-ANN). *Chemometrics and Intelligent Laboratory Systems*, 155, 73-85.

Jang, E., Gu, S., y Poole, B. (2017). Categorical reparameterization with Gumbel-Softmax. Retrieved Nov 3, 2016, from the arXiv database (arXiv:1611.01144).

Joy, M., Rusnak, M., Smidkova, K., y Vasicek, B. (2017). Banking and Currency Crises: Differential diagnostics for developed countries. *International Journal of Finance & Economics*, 22(1), 44-67.

Kaminsky, G.L. (1998). Currency and banking crises: the early warnings of distress. *International Finance Discussion Papers* 629, Board of Governors of the Federal Reserve System (U.S.).

Kauko, K. (2014). How to foresee banking crises? A survey of the empirical literature. *Economic Systems*, 38(3), 289-308.

Kalapanidas, E., Avouris, N., Craciun, M., y Neagu, D. (2003). Machine Learning Algorithms: a Study on Noise Sensitivity. First Balkan Conference in Informatics, 2003 November; 356-365. Thessaloniki, Grecia.

Kaminsky, G.L. (1998). Currency and banking crises: the early warnings of distress. International Finance Discussion Papers 629, Board of Governors of the Federal Reserve System (U.S.).

Karimi, M., y Voia, M.C. (2019). Empirics of currency crises: A duration analysis approach. *Review of Financial Economics*, 37(3), 428-449.

Kleppe, I.A., Iversen, N.M. y Stensaker, I.G. (2002). Country images in marketing strategies: conceptual issues and an empirical Asian illustration. *Journal of Brand Management*, 10(1), 61-74.

Laeven, L., y Valencia, F. (2018). Systemic Banking Crises Revisited. IMF Working Paper, WP/18/206.

Lainà, P., Nyholm, J., y Sarlin, P., (2015). Leading indicators of systemic banking crises: Finland in a panel of EU countries. *Review of Financial Economics*, 24(C), 18-35.

Land, M. y Schmidt, P.G. (2016). The early warnings of banking crises: Interaction of broad liquidity and demand deposits. *Journal of International Money and Finance*, 61, 1-29.

Laeven, L., y Valencia, F. (2012). Systemic Banking Crises Database: An Update. IMF Working Paper, WP/12/163.

Lascu, D., Ahmed, Z.U., Ahmed, I. y Min, T.H. (2020). Dynamics of country image: evidence from Malaysia. *Asia Pacific Journal of Marketing and Logistics*, próximamente.

Lee, D., y Yeo, H. (2016). Real-Time Rear-End Collision-Warning System using a Multilayer Perceptron Neural Network. *IEEE Transactions on Intelligent Transportation Systems*, 17(11), 3087-3097.

Lee Y.C., Chung P.H., y Shyu J.Z. (2017). Performance evaluation of medical device manufacturers using a hybrid fuzzy MCDM, *Journal of Scientific and Industrial Research*, 76(1), 28-31.

Leiva-Soto, R. (2014). The media reputation of Spain during the global financial crisis. *Communication & Society*, 27 (2), 1-20.

Lin, C.S., Khan, H.A., Chang, R.Y., y Wang, Y.C. (2008). A new approach to modeling early warning systems for currency crises: Can a machine-learning fuzzy expert system predict the currency crises effectively? *Journal of International Money and Finance*, 27, 1098-1121.

López, C., Gotsi, M., y Andriopoulos, C. (2011). Conceptualising the influence of corporate image on country image. *European Journal of Marketing*, 45(11/12), 1601-1641.

Lukkezen, J., y Rojas-Romagosa, H. (2016). A Stochastic Indicator for Sovereign Debt Sustainability. *FinanzArchiv / Public Finance Analysis*, 72(3), 229–267.

Manasse, P., Roubini, N., y Schimmelpfennig, A. (2003). Predicting Sovereign Debt Crises (November 2003). IMF Working Paper, No. 03/221, 1-41.

Manasse, P., y Roubini, N. (2009). "Rules of thumb" for sovereign debt crises. *Journal of International Economics*, 78(2), 192-205.

Mariutti, F., y Tech, R. (2015). Are we talking the Same Language? Challenging Complexity in Country Brand Models. *Athens Journal of Business & Economics*, Athens Institute for Education and Research (ATINER), 1(1), 49-62.

Melnyk, T.M., y Varibrusova, A.S. (2019). Variable indicators affecting the country's brand strategy effectiveness and competitiveness in the world. *Management Science Letters*, 9, 1685–1700.

Mulder, C., Perrelli, R., y Rocha, M.D. (2016). The Role of Bank and Corporate Balance Sheets on Early Warning Systems of Currency Crises—An Empirical Study. *Emerging Markets Finance and Trade*, 52(7), 1542-1561.

Nebenzahl, I.D., Jaffe, E.D., y Lampert, S.I. (1997). Towards a theory of country image effect on product evaluation. *Management International Review*, (37) 1, 27-49

Papadopoulos, N., Ibrahim, Y., De Nisco, A., y Napolitano, M.R. (2018). The Role of Country Branding in Attracting Foreign

Investment: Country Characteristics and Country Image. *MERCATI E COMPETITIVIT*, 2018/2, 2, 85-108.

Passow, T., Fehlmann, R., y Grahlow, H. (2005). Country reputation—From measurement to management: The case of Liechtenstein. *Corporate Reputation Review*, 7, 309–326.

Pham, T.H.A. (2017). Are global shocks leading indicators of currency crisis in Vietnam? *Research in International Business and Finance*, 42, 605-615.

Prashanth, K.D., Parthiban, P., y Dhanalakshmi R. (2018). Evaluation and ranking of criteria affecting the supplier's performance of a heavy industry by fuzzy AHP method, *Journal of Scientific and Industrial Research*, 77(5), 268-270.

Qin, X. y Chengying, L. (2014). Capital account openness and early warning system for banking crises in G20 countries. *Economic Modelling*, 39(C), 190-194.

Ramli, N.A., Ismail, M.T, y Hooy, H.C. (2015). Measuring the accuracy of currency crisis prediction with combined classifiers in designing early warning system. *Machine Learning*, 101(1-3), 85-103.

Rawal, B., y Agarwal, R. (2019). Improving Accuracy of Classification Based on C4.5 Decision Tree Algorithm Using Big Data Analytics. Computational Intelligence in Data Mining. *Advances in Intelligent Systems and Computing*, 711, 203-211.

Reinhart, C., Kaminsky, G., y Lizondo, S. (1998). Leading Indicators of Currency Crises. IMF Staff Papers, 45(1), 1-48.

Reputation Institute (2017). Country Reprtrak 2017. The World's Most Reputable Countries. Boston, Massachusetts.

Ristolainen, K. (2018). Predicting Banking Crises with Artificial Neural Networks: The Role of Nonlinearity and Heterogeneity. *The Scandinavian Journal of Economics*, 120 (1), 31-62.

Rother, B. (2009). The Determinants of Currency Crises: A Political-Economy Approach Hardcover. Palgrave Macmillan, Londres.

Saltelli, A. (2002). Making best use of model evaluations to compute sensitivity indices. *Computer Physics Communications*, 145, 280–297.

Sarlin, P. (2011). Sovereign debt monitor: A visual Self-organizing maps approach. 2011 IEEE Symposium on Computational Intelligence for Financial Engineering and Economics (CIFEr). Paris, Francia.

Sarlin, P., y Marghescu, D. (2011). Visual predictions of currency crises using self-organizing maps. *Intelligent Systems in Accounting, Finance and Management*, 18(1), 15-38.

Savona, R., y Vezzoli, M. (2015). Fitting and Forecasting Sovereign Defaults using Multiple Risk Signals. *Oxford Bulletin of Economics and Statistics*, 77, 1 0305–9049.

Sevim, C., Oztekin, A., Bali, O., Gumus, S., y Guresen, E. (2014). Developing an early warning system to predict currency crises. *European Journal of Operational Research*, 237, 1095–1104.

Simonin, B.L. (2008). Nation Branding and Public Diplomacy: Challenges and Opportunities. *The Fletcher Forum of World Affairs*, 32(3), 19-34.

Sohn, B., y Park, H. (2016). Early warning indicators of banking crisis and bank related stock returns. *Finance Research Letters*, 18(C), 193-198.

Steinberg, D.A., Koesel, K.J., y Thompson, N.W. (2015). Political Regimes and Currency Crises. *Economics & Politics*, 27(3), 337-361.

Szondi, G. (2008). Public Diplomacy and Nation Branding: Conceptual Similarities and Differences. Discussion Papers in Diplomacy, Netherlands Institute of International Relations 'Clingendael', ISSN 1569-2981. Den Haag, Países Bajos.

Teodorović, M., y Popesku, J. (2016). Country Brand Equity Model: Sustainability Perspective. *Marketing*, 47(2), 111-128.

Vaccaro, G., Cabrera, F.E., Peláez, J.I., y Vargas, G. (2020). Comparison matrix geometric index: A qualitative online reputation metric. *Applied Soft Computing*, 96, 106687.

Wang, W., y Lu, Y. (2018). Analysis of the Mean Absolute Error (MAE) and the Root Mean Square Error (RMSE) in Assessing Rounding Model. In IOP Conference Series: Materials Science and Engineering (Vol. 324, No. 1, p. 012049). IOP Publishing

Yang, Y. Garcia-Morillo, I., y Hospedales, T.M. (2018). Deep Neural Decision Trees. 2018 ICML Workshop on Human Interpretability in Machine Learning (WHI 2018), Stockholm, Sweden.



Yu, L., Lai, K.K., y Wang, S.Y. (2006). Currency Crisis Forecasting with General Regression Neural Networks. *International Journal of Information Technology & Decision Making*, 5(3), 437–454.

Yu, L., Wang, S., Lai, K.K., y Cong, G. (2007). Currency Crisis Forecasting with a Multi-Resolution Neural Network Learning Approach. Proceedings of KSS'2007: The Eighth International Symposium on Knowledge and Systems Sciences: November 5-7, 2007. Japan Advanced Institute of Science and Technology.

Zhou, L., y Lai, K.K. (2017). AdaBoost Models for Corporate Bankruptcy Prediction with Missing Data. *Computational Economics*, 50(1), 69-94.

# PUBLICACIONES



Las tres publicaciones que componen la presente tesis doctoral en modalidad de compendio son reproducidas a continuación. También, están disponibles en los siguientes enlaces:

Alaminos, D., Peláez, J.I., Salas, M.B., y Fernández-Gámez, M.A. (2021). Sovereign Debt and Currency Crises Prediction Models using Machine Learning Techniques. *Symmetry*, 13(4), 652. <https://doi.org/10.3390/sym13040652>

<https://www.mdpi.com/2073-8994/13/4/652>

Resumen: La deuda soberana y las divisas juegan un papel cada vez más influyente en el desarrollo de cualquier país, dada la necesidad de obtener financiamiento y establecer relaciones internacionales. Un tema recurrente en la literatura sobre crisis financieras ha sido la predicción de crisis de deuda soberana y de divisas debido a su extrema importancia en la actividad económica internacional. Sin embargo, las limitaciones de los modelos existentes están relacionadas con la precisión y la literatura pide más investigación sobre el tema y carece de diversidad geográfica en las muestras utilizadas. Este artículo presenta nuevos modelos para la predicción de crisis de deuda soberana y de divisas, utilizando diversas técnicas computacionales, que aumentan su precisión. Además, estos modelos presentan experiencias con una amplia muestra global de las principales zonas geográficas del mundo, como África y Medio Oriente, Latinoamérica, Asia, Europa y globalmente. Nuestros modelos demuestran la superioridad de las técnicas computacionales sobre las estadísticas en términos del nivel de precisión, siendo los mejores métodos para la crisis de la deuda soberana: árboles de decisión difusos, AdaBoost, aumento de gradiente extremo y árboles de decisión neuronal de aprendizaje profundo, y para pronosticar la crisis de divisas: árboles de decisión neuronal de aprendizaje

profundo, aumento de gradiente extremo, bosques aleatorios y una red de creencias profundas. Nuestra investigación tiene un gran impacto y potencialmente significativo en la adecuación de la política macroeconómica de los países frente a los riesgos derivados de las crisis financieras y proporciona instrumentos que permiten mejorar el equilibrio en las finanzas de los países.

Alaminos, D., Becerra-Vicario, R., Fernández-Gámez, M.A., y Cisneros-Ruiz, A.J. (2019). Currency Crises Prediction using Deep Neural Decision Trees. *Applied Sciences*, 9(23), 5227. <https://doi.org/10.3390/app9235227>

<https://www.mdpi.com/2076-3417/9/23/5227>

Resumen: Las crisis de divisas son eventos importantes en el sistema monetario internacional. Afectan a la política monetaria de los países y están asociados a riesgos de vulnerabilidad para las economías abiertas. Se han realizado muchas investigaciones sobre el comportamiento de estos eventos y se han desarrollado modelos para predecir caídas en la cotización de las divisas. Sin embargo, las limitaciones de los modelos existentes muestran que se requiere más investigación en esta área, ya que los modelos aún tienen una precisión limitada y solo se han desarrollado para países emergentes. Este artículo presenta un modelo global innovador para predecir crisis de divisas. El análisis está diferenciado geográficamente por regiones, considerando tanto países emergentes como desarrollados y puede estimar con precisión escenarios futuros de crisis de divisas a nivel global. Utiliza una muestra de 162 países que permite mostrar la heterogeneidad regional de los indicadores de alerta. El método utilizado fue el árbol de decisión neuronal profundo (DNDT), una técnica basada en árboles de decisión implementada por redes neuronales de aprendizaje profundo, que se comparó con otras

metodologías ampliamente aplicadas en predicción. Nuestro modelo tiene un importante potencial para la adaptación de la política macroeconómica a los riesgos derivados de caídas en el valor de las monedas, brindando herramientas que ayudan a asegurar la estabilidad financiera a nivel global.

Alaminos, D., Fernández-Gámez, M.A., Santos, J. A., y Campos-Soria, J.A. (2019). Predicting Systemic Banking Crises using Extreme Gradient Boosting. *Journal of Scientific & Industrial Research*, 78(9), 571-575.

<http://nopr.niscair.res.in/handle/123456789/50493>

Resumen: Teniendo en cuenta la gran capacidad de las técnicas de árboles de decisión para extraer información útil de grandes bases de datos y para manejar variables heterogéneas, este artículo aplica Extreme Gradient Boosting para la predicción de crisis bancarias sistémicas. Con este fin, se han construido modelos de predicción para diferentes regiones y una muestra global. Los resultados obtenidos muestran que el Extreme Gradient Boosting supera el poder predictivo de los modelos existentes en la literatura anterior y brinda más información explicativa sobre las causas que producen las crisis bancarias sistémicas, siendo la demanda de depósitos, el nivel de crédito interno y los activos bancarios algunos de los factores más significativos.